


**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**  
**FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA**



**TESIS**

**ANÁLISIS MULTIVARIABLE DE LA SEÑAL EEG PARA IDENTIFICAR LA  
INTENCIÓN DE MOVIMIENTO EN MIEMBROS INFERIORES**


**POR**

**ING. JAZMÍN ALEJANDRA MARTÍNEZ ALVARADO**

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE  
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA ELÉCTRICA**

**JUNIO, 2017**

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN  
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA  
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO**



**TESIS**

**ANÁLISIS MULTIVARIABLE DE LA SEÑAL EEG PARA IDENTIFICAR LA  
INTENCIÓN DE MOVIMIENTO EN MIEMBROS INFERIORES**

**POR**

**ING. JAZMÍN ALEJANDRA MARTÍNEZ ALVARADO**

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE MAESTRÍA  
EN CIENCIAS DE LA INGENIERÍA ELÉCTRICA**

**JUNIO, 2017**

**UNIVERSIDAD AUTONOMA DE NUEVO LEON**  
**FACULTAD DE INGENIERIA MECANICA Y ELECTRICA**  
**SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO**

Los miembros del Comité de Tesis recomendamos que la Tesis «Análisis multivariable de la señal EEG para identificar la intención de movimiento en miembros inferiores» realizada por la alumna Ing. Jazmín Alejandra Martínez Alvarado, con número de matrícula 1770320, sea aceptada para su defensa como opción al grado de Maestría en Ciencias de la Ingeniería Eléctrica.

El Comité de Tesis



\_\_\_\_\_  
Dra. Griselda Quiroz Compeán  
Directora



\_\_\_\_\_  
Dr. Miguel Ángel Platas Garza  
Revisor



\_\_\_\_\_  
Dra. Aurora Espinoza Valdez  
Revisora

Vo. Bo.



\_\_\_\_\_  
Dr. Simón Martínez Martínez  
Subdirector de Estudios de Posgrado

San Nicolás de los Garza, Nuevo León, junio de 2017

*A los amores de mi vida  
Andrés, Arleth y Andrés Jr.  
y a mis papás.*

# Agradecimientos

Quiero agradecer especialmente a mi asesora de tesis la Dra. Griselda Quiroz por su guía, su tiempo, su gran conocimiento y la confianza que depositó en mí a lo largo de todo este tiempo. Al Dr. Miguel Platas por su gran conocimiento y el apoyo que recibí de su parte como mi co-asesor de tesis. Al Dr. David Diaz por su gran apoyo como coordinador del posgrado en los momentos que lo necesité. A la Dra. Aurora Espinoza y al Dr. Ricardo Salido de la Universidad de Guadalajara por su ayuda y guía en la realización de parte de este trabajo. Agradezco a la Facultad de Ingeniería Mecánica y Eléctrica (FIME), a la Universidad Autónoma de Nuevo León, así como a todo el cuerpo académico del Posgrado de Ingeniería Eléctrica por la calidad del posgrado que cursé.

Agradezco infinitamente a mi esposo Andrés Gerd Morales Andrade por su apoyo, su ayuda, su paciencia, su amor y hasta por sus enojos ya que gracias a todo eso es que lo pudimos lograr. Agradezco a Dios por mandarme a mis dos hijos hermosos Arleth y Andrés los cuales son el motor más grande que me da las fuerzas para seguir desarrollándome personal y profesionalmente. A mi mamá Odilia Alvarado Loera porque aún a la distancia siempre tengo su apoyo, su ayuda, su amor y muchas otras cosas más, a mi papá y a mis hermanos porque de una u otra forma siempre están ahí para apoyarme.

Quiero agradecer a mis compañeros Jorge, Víctor, Pio, Arvizu, Mario, Pachicano, Debanhi y Luis por su apoyo, su amistad, el tiempo compartido y en especial a Eddy y Tello por escucharme, apoyarme, darme consejos, en fin, por su gran amistad.

Gracias al Consejo Nacional de Ciencia y Tecnología (CONACYT) por otorgarme la beca número 404021, al Programa para el Desarrollo Profesional Docente (PRODEP-SEP) por su apoyo financiero (103.5 /15/14156) para poder realizar una estancia de investigación en la Universidad de Guadalajara llevada a cabo del 5 al 16 de septiembre del 2016. Agradezco al programa de Apoyo

a la Investigación Científica y Tecnológica de la UANL, a través del proyecto IT437-15, para participar en el VIII Congreso Nacional de Tecnología Aplicada a Ciencias de la Salud llevado a cabo en la facultad de medicina de la Universidad Autónoma de Nuevo León del 15 al 17 de junio del 2017. Agradezco al CUCEI de la Universidad de Guadalajara por la oportunidad de realizar una estancia de investigación en sus instalaciones.

Finalmente quiero dar gracias por todas las cosas buenas y malas que me han pasado en la vida ya que probablemente gracias a eso hoy puedo culminar este nuevo ciclo de mi vida.

Junio 2017

# RESUMEN

Ing. Jazmín Alejandra Martínez Alvarado

Candidata para el grado de Maestro en Ciencias en Ingeniería Eléctrica

Universidad Autónoma de Nuevo León

Facultad de Ingeniería Mecánica y Eléctrica, 2017

Título del estudio:

## ANÁLISIS MULTIVARIABLE DE LA SEÑAL EEG PARA IDENTIFICAR LA INTENCIÓN DE MOVIMIENTO EN MIEMBROS INFERIORES

Número de páginas: 89.

### RESUMEN

Un porcentaje elevado de individuos a nivel mundial presentan algún tipo de discapacidad motriz que afecta su calidad de vida. Actualmente existen varios tipos de terapias, entre ellas, la neurorehabilitación, que permiten al individuo recuperar parcial o totalmente la función motriz. En este trabajo se pretende identificar la actividad motriz de miembros inferiores del cuerpo humano mediante el análisis de la señal electroencefalográfica (EEG). Esto se realiza mediante la medición EEG no invasiva utilizando, el sistema B-Alert X10 de Advanced BrainMonitoring® el cual adquiere inalámbricamente las señales EEG, electrooculográfica (EOG) y electrocardiográfica (ECG) y registra la actividad de nueve electrodos situados de acuerdo al estándar internacional 10-20 en el cuero cabelludo del individuo (el cuero cabelludo nos provee una medida directa de la actividad sináptica cortical). A las señales EEG se les efectúa un procesamiento para extraer sus características espaciales y frecuenciales con la intención de clasificar distintas tareas controladas

de movimiento (caminata a distintas velocidades). Para la extracción de características espaciales, la metodología propuesta está basada en el cálculo de coherencia del EEG y sus grafos de conectividad asociados. Para la extracción de características frecuenciales se propone utilizar la transformada de Fourier y la transformada wavelet. Respecto al método de clasificación se utilizó una red neuronal artificial (RNA) perceptrón multicapa. Los resultados sugieren la existencia de patrones de conectividad cerebral estables y caracterizables que nos permiten tener resultados de clasificación importantes que servirían para futuras aplicaciones en neurorehabilitación.

**Profesora asesora: Dra. Griselda Quiroz Compeán.**

# Índice general

<b>1. Introducción</b>	<b>1</b>
1.1. Justificación . . . . .	1
1.2. Antecedentes . . . . .	2
1.3. Hipótesis y objetivos . . . . .	4
1.3.1. Hipótesis . . . . .	4
1.3.2. Objetivo general . . . . .	4
1.3.3. Objetivos particulares . . . . .	4
1.3.4. Organización del documento . . . . .	4
<b>2. Métodos de análisis</b>	<b>5</b>
2.1. Coherencia de una señal . . . . .	5
2.2. Grafos . . . . .	6
2.2.1. Tipos de Grafos . . . . .	7
2.2.2. Matriz Laplaciana . . . . .	8
2.3. Transformada de Fourier y transformada wavelet . . . . .	9
2.3.1. Conceptos preliminares . . . . .	9
2.3.2. Transformada de Fourier . . . . .	13
2.3.3. Transformada wavelet . . . . .	14
2.4. Clasificación . . . . .	16
2.4.1. Redes neuronales artificiales . . . . .	18

<b>3. Procesamiento de señales</b>	<b>25</b>
3.1. Protocolo experimental . . . . .	25
3.2. Adquisición . . . . .	26
3.2.1. Preprocesamiento . . . . .	28
3.3. Implementación numérica . . . . .	32
3.3.1. Obtención de las características espaciales . . . . .	32
3.3.2. Obtención de características frecuenciales . . . . .	37
3.3.3. Implementación numérica de la clasificación . . . . .	39
<b>4. Resultados</b>	<b>42</b>
4.1. Resultados de Conectividad . . . . .	42
<b>5. Conclusiones y trabajo a futuro</b>	<b>82</b>
5.1. Conclusiones . . . . .	82
5.2. Trabajo a Futuro . . . . .	83
<b>A. Productividad académica</b>	<b>89</b>

# Índice de figuras

2.1. Grafo simple. . . . .	7
2.2. Grafo ponderado. . . . .	8
2.3. Proyección ortogonal sobre un subespacio. . . . .	12
2.4. Esquemático del procedimiento de descomposición de una señal $\varphi[n]$ mediante DWT, donde $g[n]$ es un filtro pasa altas y $h[n]$ es un filtro pasa bajas. . . . .	15
2.5. Clasificación: a) linealmente separable b) no linealmente separable. . . . .	17
2.6. Función sigmoïdal. . . . .	19
2.7. Función tangente hiperbólica. . . . .	20
2.8. Función signo. . . . .	20
2.9. Esquema básico de una RNA. . . . .	21
2.10. Propagación de la señal en una RNA perceptrón multicapa. a) Cálculo de la salida $y_1$ correspondiente a la salida de la neurona 1, b) Cálculo de la salida $y_5$ correspondiente a la salida de la neurona 5. . . . .	22
2.11. Retropropagación del error en una RNA perceptrón multicapa. a) Retropropagación del error de la salida a la neurona 4, b) Retropropagación del error a la capa de neuronas anterior en este caso, de la neurona 4 y 5 hacia la neurona 1. . . . .	23
2.12. Ajuste de pesos $w$ , donde $w'_{(x_1)1}$ y $w'_{(x_1)2}$ son los pesos actualizados. . . . .	24
3.1. Distribución de los electrodos del sistema de adquisición de señales B-Alert X10 de Advanced Brain Monitoring® , de acuerdo con el estándar internacional 10-20. . . .	27

3.2. Sujeto de estudio utilizando el sistema de adquisición de señales B-Alert X10 de Advanced Brain Monitoring®. a) Vista lateral de la colocación del sistema de adquisición, b) Distribución de los electrodos de acuerdo al estándar 10-20, c) Colocación de los electrodos faciales. . . . . 27

3.3. Partición del experimento completo en secciones, donde  $E_i$  es el  $i$ -ésimo electrodo del registro con  $i = 1, 2, \dots, 9$ . . . . . 28

3.4. Bandas de frecuencia de la señal EEG. . . . . 29

3.5. Bandas  $\alpha$  y  $\beta$  de frecuencia de la señal EEG. . . . . 30

3.6. Proceso de ventaneo de la primera sección ( $V1$ ). En este ejemplo se tienen 45 ventanas de un segundo iniciando en el tiempo cero de la sección (recuadros rosa oscuro, numeración inferior). Además, se tienen 45 ventanas superpuestas iniciando en el tiempo 0.5 segundos de la sección (recuadros claros, numeración superior). En total la sección tiene 90 ventanas de tiempo, por lo que se calculan 90 matrices de coherencia. Este procedimiento se repite en la tercera sección ( $V2$  con 90 ventanas) y en la sección cinco ( $V1$  con 90 ventanas). . . . . 31

3.7. Proceso de ventaneo de la segunda sección ( $T1$ ). En este ejemplo se tienen 16 ventanas de un segundo iniciando en el tiempo cero de la sección (recuadros rosa oscuro, numeración inferior). Además, se tienen 15 ventanas superpuestas iniciando en el tiempo 0.5 segundos de la sección (recuadros claros, numeración superior). En total la sección tiene 31 ventanas de tiempo, por lo que se calculan 31 matrices de coherencia. Este procedimiento se repite en la cuarta sección ( $T2$  con 31 ventanas). 31

3.8. Matriz de coherencia umbralizada correspondiente al sujeto 1 en la actividad  $V1$ , banda  $\alpha$  y su grafo correspondiente. . . . . 34

3.9. Ejemplo de la obtención del grado de conectividad de la actividad  $V1$  del sujeto 1, banda  $\alpha$ . . . . . 35

3.10. Matriz Laplaciana correspondiente a  $V3$  del sujeto de estudio 3, banda  $\beta$ . . . . . 36

3.11. Vector conformado por los valores propios de la matriz de la Figura 3.10 correspondiente a  $V3$  del sujeto de estudio 3, banda  $\beta$ . . . . . 36

3.12. Vector conformadao por los valores propios de la matriz de la Figura 3.10 correspondiente a  $V3$  del sujeto de estudio 3, banda  $\beta$ . . . . . 37

3.13. Representación gráfica del espectro de frecuencia en las bandas  $\alpha$  y  $\beta$  (de un solo ventaneo) resultado de aplicar la transformada de Fourier a la señal EEG proveniente del electrodo C3, del sujeto 1. . . . . 38

3.14. Vector de características frecuenciales de la banda  $\alpha$  y  $\beta$  aplicando la trasformada de Fourier a la señal proveniente del electrodo C3 del sujeto 1. . . . . 38

3.15. Representación grafica del los coeficientes de la DWT Db1 de 14 niveles, aplicada a la señal proveniente del electrodo C3, del sujeto 1. . . . . 39

3.16. Matriz de coeficientes de la DWT Db1 de 14 niveles aplicada a la señal proveniente del electrodo C3 del sujeto 1, cada columna representa el vector de coeficientes en cada instante de tiempo. . . . . 39

4.1. Grafos de la actividad completa, sujeto 1, banda  $\alpha$ . . . . . 42

4.2. Grafos de la actividad completa, sujeto 1, banda  $\beta$ . . . . . 43

4.3. Grafos de la actividad completa, sujeto 2, banda  $\alpha$ . . . . . 43

4.4. Grafos de la actividad completa, sujeto 2, banda  $\beta$ . . . . . 43

4.5. Grafos de la actividad completa, sujeto 3, banda  $\alpha$ . . . . . 44

4.6. Grafos de la actividad completa, sujeto 3, banda  $\beta$ . . . . . 44

4.7. Grado de conexión, banda  $\alpha$ ,  $V1$ , 3 sujetos. . . . . 45

4.8. Grado de conexión, banda  $\alpha$ ,  $V2$ , 3 sujetos. . . . . 45

4.9. Grado de conexión, banda  $\alpha$ ,  $V3$ , 3 sujetos. . . . . 46

4.10. Grado de conexión, banda  $\beta$ ,  $V1$ , 3 sujetos. . . . . 46

4.11. Grado de conexión, banda  $\beta$ ,  $V2$ , 3 sujetos. . . . . 47

4.12. Grado de conexión, banda  $\beta$ ,  $V3$ , 3 sujetos. . . . . 47

4.13. Velocidades, sujeto 1, banda  $\alpha$ . . . . . 48

4.14. Transiciones, sujeto 1, banda  $\alpha$ . . . . . 49

4.15. Velocidades, sujeto 1, banda  $\beta$ . . . . . 50

4.16. Transiciones, Sujeto 1, banda  $\beta$ . . . . . 51

4.17. Velocidades, sujeto 2, banda $\alpha$ . . . . .	52
4.18. Transiciones, sujeto 2, banda $\alpha$ . . . . .	53
4.19. Velocidades, sujeto 2, banda $\beta$ . . . . .	54
4.20. Transiciones, Sujeto 2, banda $\beta$ . . . . .	55
4.21. Velocidades, sujeto 3, banda $\alpha$ . . . . .	56
4.22. Transiciones, sujeto 3, banda $\alpha$ . . . . .	57
4.23. Velocidades, sujeto 3, banda $\beta$ . . . . .	58
4.24. Transiciones, Sujeto 3, banda $\beta$ . . . . .	59
4.25. Resultado de clasificación de actividades para el sujeto 1 con una RNA perceptrón multicapa, utilizando transformada de Fourier, a) Electrodo C3, b) Electrodo FZ ,CZ, C3 Y F4. . . . .	61
4.26. Resultado de clasificación de actividades para el sujeto 2 con una RNA perceptrón multicapa, utilizando transformada de Fourier, a) Electrodo C3, b) Electrodo FZ ,CZ, C3 Y F4. . . . .	62
4.27. Resultado de clasificación de actividades para el sujeto 3 con una RNA perceptrón multicapa, utilizando transformada de Fourier, a) Electrodo C3, b) Electrodo FZ ,CZ, C3 Y F4. . . . .	63
4.28. Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente del electrodo C3. . . . .	65
4.29. Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente del electrodo C3. . . . .	66
4.30. Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente del electrodo C3. . . . .	66
4.31. Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente del electrodo C3. . . . .	68

4.32. Resultado de la clasificación de actividades para el sujeto 2, con una RNA percep- trón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente del electrodo C3. . . . .	69
4.33. Resultado de la clasificación de actividades para el sujeto 1, con una RNA percep- trón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente del electrodo C3. . . . .	69
4.34. Resultado de la clasificación de actividades para el sujeto 3, con una RNA percep- trón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente del electrodo C3. . . . .	71
4.35. Resultado de la clasificación de actividades para el sujeto 1, con una RNA percep- trón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente del electrodo C3. . . . .	72
4.36. Resultado de la clasificación de actividades para el sujeto 1, con una RNA percep- trón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente del electrodo C3. . . . .	72
4.37. Resultado de la clasificación de actividades para el sujeto 1, con una RNA percep- trón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . .	74
4.38. Resultado de la clasificación de actividades para el sujeto 1, con una RNA percep- trón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . .	75
4.39. Resultado de la clasificación de actividades para el sujeto 1, con una RNA percep- trón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . .	75
4.40. Resultado de la clasificación de actividades para el sujeto 2, con una RNA percep- trón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . .	77

4.41. Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . . 78

4.42. Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . . 78

4.43. Resultado de la clasificación de actividades para el sujeto 3, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . . 80

4.44. Resultado de la clasificación de actividades para el sujeto 3, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . . 81

4.45. Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4. . . . . 81

5.1. Localización espacial de los electrodos FZ, CZ, C3 y F4 seleccionados por su dinámica de conectividad . . . . . 83

# Capítulo 1

## Introducción

### 1.1. Justificación

Más de mil millones de personas al rededor del mundo viven con alguna forma de discapacidad, de ellas, casi 200 millones experimentan dificultades considerables en sus capacidades. Se estima que en años futuros, la discapacidad será un problema mayor ya que se está viendo un aumento mundial en enfermedades crónicas tales como la diabetes, las enfermedades cardiovasculares, el cáncer y los trastornos de la salud mental, las cuales pueden desencadenar algún tipo de discapacidad. Según la encuesta mundial de salud, el 15.6% de personas mayores de 15 años viven con una discapacidad, y de éstas el 2.2% tiene dificultades relacionadas con afecciones tales como la tetraplejía, depresión grave o ceguera [1].

En el caso de México, la encuesta nacional de salud y nutrición (ENSANUT) 2012, informa que, para la población de seis años o más, uno de los tres tipos de discapacidad que tuvo la prevalencia más alta fue la de dificultad para caminar, moverse, subir o bajar escaleras. Esta discapacidad tiene un 4.9% de prevalencia en hombres y un 5.8% en mujeres, siendo más alto el porcentaje en el grupo de adultos de 20 o más años. Lo anterior puede atribuirse a la discapacidad que se asocia con las enfermedades crónicas no transmisibles, la obesidad y los accidentes [2]. Con la idea de proponer soluciones tecnológicas a este problema de salud, se han realizado muchas investigaciones tales como las llamadas interfaces cerebro computadora BCIs (por las siglas en ingles de

*brain computer interfaces*), las cuales buscan desarrollar aparatos que puedan de alguna manera hacer más llevadera dicha situación, ayudando a los pacientes a realizar actividades de las que se encuentran limitados.

## 1.2. Antecedentes

Las BCIs son una tecnología basada en la adquisición y procesamiento de señales cerebrales para el control de diversos dispositivos. Su objetivo principal es proporcionar un canal de comunicación entre el cerebro del usuario y un dispositivo mecatrónico para personas con daño motriz severo [3]. Usualmente las BCIs se enfocan en reconocer eventos que son adquiridos por métodos como la electroencefalografía (EEG). El caso más importante de las aplicaciones BCI es en el contexto clínico, desarrollado para pacientes con esclerosis lateral amiotrofia, lesión de la médula espinal y otros trastornos de la función del movimiento, con el fin de controlar dispositivos, tales como una silla de ruedas o un robot. En estos, la entrada es una señal cerebral obtenida a partir de EEG o alguna otra medición directa de la actividad cerebral, y la salida es tomada como una señal de control [4].

La intención de comprender la actividad neural de los humanos no es algo reciente. Uno de los pioneros en la adquisición de señales EEG fue el científico alemán Hans Berger, quien en 1929, especulaba acerca de la posibilidad de leer pensamientos a partir de trazos de EEG utilizando sofisticados análisis matemáticos. Así mismo, la intención de usar la información neural en desarrollo tecnológico ha sido de interés durante mucho tiempo [5]. Grey Walter, uno de los pioneros en la aplicación de EEG en robótica, cibernética e inteligencia artificial, construyó el primer analizador de frecuencia con la intención de discriminar los pensamientos y el lenguaje en el EEG humano [5]. De un tiempo a la fecha se han realizado varios estudios donde se demuestra que esas especulaciones de las que se hablaban, hoy en día pueden ser realizables. Por mencionar algunos trabajos de investigación relacionados con el tema, se puede observar el ejemplo en el que Bian et al., en el año 2011 presentaron un nuevo método para el reconocimiento de las señales EEG de actividad motriz, el cual optimiza exhaustivamente las características del espacio tiempo-frecuencia de manera específica para el usuario. El método crea redes de tiempo y frecuencia optimizadas y adapti-

vamente selecciona canales para filtros de patrones espaciales comunes con el objetivo de mejorar su energía [6]. En el año 2013, Márquez *et al.*, realizaron un estudio donde el principal objetivo era el análisis y clasificación de las señales EEG para identificar el movimiento en el brazo utilizando ocho canales del EEG para obtener la información, usaron también la transformada wavelet para extraer las características de tiempo y frecuencia y así obtener las entradas para el clasificador que consistió en una RNA perceptrón multicapas [7]. En el 2014, Blokland *et al.*, buscaban mejorar el rendimiento actual de conmutadores cerebrales basados en ritmos sensoriomotores en pacientes con tetraplejia, y examinar la diferencia de rendimiento entre el movimiento actual y el intento de movimiento para un grupo de usuarios combinando el electroencefalograma con la espectroscopia de infrarrojo cercano [8]. En el año 2015, Robinson *et al.*, probaron la factibilidad que tiene el utilizar un amplificador de señales EEG de bajo costo comercial que utiliza un número limitado de electrodos para desarrollar un sistema de control motriz mediante BCI, cuyo objetivo fue extraer la actividad cerebral responsable del movimiento imaginado y el movimiento ejecutado, que puede ser utilizado para identificar la tarea realizada por el usuario (movimiento de la mano) usando el EEG registrado simultáneamente [9]. En ese mismo año Shiman *et al.*, investigaron la decodificación de las señales EEG de cinco movimientos funcionales realizados con la misma extremidad hacia un mismo escenario, para ello se utilizó un sistema de adquisición de señales EEG de 32 canales, el BCI que se utilizó estaba basado en extensiones multiclase de patrones espaciales comunes espectralmente tabulados y un clasificador de análisis discriminante lineal [10].

Por lo anterior, surge el interés de analizar el comportamiento de la señal EEG al realizar alguna actividad, con la finalidad de poder extraer sus características espaciales y frecuenciales y poder relacionarlas con alguna actividad motriz. Por su utilidad en las terapias de enfermedades neuromotrices de miembros inferiores, en este trabajo se analizan las características de la señal EEG durante la caminata.

## **1.3. Hipótesis y objetivos**

### **1.3.1. Hipótesis**

El conocer las características espaciales y frecuenciales de la señal EEG permite identificar la actividad motriz de miembros inferiores del cuerpo humano.

### **1.3.2. Objetivo general**

Realizar el procesamiento espacial y frecuencial multivariable que permita relacionar la señal EEG a una actividad motriz de los miembros inferiores.

### **1.3.3. Objetivos particulares**

- Implementar una metodología para la selección de características espaciales y frecuenciales de la actividad neural medida mediante EEG.
- Implementar un método de clasificación multivariable que relacione variables motrices (caminata a dos velocidades diferentes) con las características espaciales y frecuenciales de las señales EEG.

### **1.3.4. Organización del documento**

Este documento se encuentra organizado de la siguiente manera: en el Capítulo 2 se describen los métodos matemáticos utilizados para la extracción de características espaciales y frecuenciales de la señal EEG. En el caso de las características espaciales se utilizó el cálculo de coherencia, así como el trazo de los grafos asociados. Para las características frecuenciales se analizaron la transformada de Fourier y la transformada wavelet discreta (DWT), para el clasificador se usó el método de la RNA perceptrón multicapa. En el Capítulo 3 se presenta el protocolo experimental así como la implementación numérica de las metodologías discutidas en el Capítulo 2. En el Capítulo 4 se presentan los resultados de la investigación, así como una discusión de los mismos. En el Capítulo 5 se presenta las principales conclusiones y el posible trabajo futuro de esta investigación.

# Capítulo 2

## Métodos de análisis

En este capítulo se hablara acerca de los métodos de análisis utilizados en el desarrollo de la presente tesis. Con los cuales se obtuvieron las características espaciales y frecuenciales requeridas por el clasificador para obtener la clasificación correcta de las actividades motrices, de igual manera se habla del tipo de clasificador utilizado.

### 2.1. Coherencia de una señal

La coherencia y covarianza en un registro EEG son medidas de la escala de interrelaciones funcionales entre pares de regiones neocorticales. Estas medidas están estrechamente correlacionadas con las medidas cognitivas o de comportamiento. Por ejemplo, los patrones de covarianza de potenciales evocados, incluyendo la variación de la contingencia negativa, dependen de la ejecución de una tarea. El valor de covarianza normalizado por el producto de las diferencias individuales se llama el coeficiente de la función de correlación; éste es una función del tiempo de retardo entre las señales. Por ejemplo, una forma de onda de potencial evocado localizado en el cuero cabelludo se puede correlacionar con otra ubicación sólo después de algún retardo de tiempo, quizás asociado con la propagación de la señal [11].

La coherencia es una función de frecuencia que mide la interrelación estadística de dos señales a través de varios coeficientes en el dominio de la frecuencia. En otras palabras, la coherencia indica que tan bien se relaciona el canal  $i$  con el canal  $j$ . Los coeficientes de coherencia son valores

normalizados entre 0 y 1.

Para determinar la conectividad de los electrodos de un registro EEG, es necesario calcular la coherencia espectral en el dominio de la frecuencia  $f$  mediante:

$$\gamma_{ij}(f) = \frac{|G_{ij}(f)|^2}{G_{ii}(f)G_{jj}(f)} \quad (2.1)$$

donde  $G_{ii}$  es la densidad espectral de la serie de tiempo  $i$ ,  $G_{jj}$  es la densidad espectral de la serie de tiempo  $j$  y  $G_{ij}$  es la densidad de espectro cruzado de las dos señales. De esta ecuación se obtiene un conjunto de valores de coherencia en un intervalo de frecuencia.

Cuando se calcula la coherencia entre electrodos estos conjuntos se pueden agrupar en una matriz simétrica  $G$  de  $n \times n$  llamada matriz de coherencia, definida a continuación. Considere  $f_s$  como la frecuencia de muestreo de una señal y  $f_s/2$  como la frecuencia de Nyquist. El valor de coherencia promedio en el rango de frecuencias determinado por la frecuencia de Nyquist está definido como:

$$G = (2/f_s) \sum_{f=1}^{f_s} \gamma_{ij}(f) \quad (2.2)$$

Cada coeficiente de  $G$  determina la interrelación entre electrodos.

## 2.2. Grafos

Los grafos son estructuras discretas que constan de vértices (nodos) y de aristas que conectan entre sí esos vértices. Hay varios tipos de grafos, que se diferencian entre sí por el tipo y número de aristas que pueden conectar cada par de vértices. La representación y definición matemática de un grafo es la siguiente. Un grafo  $G$  es un par  $G=(V,E)$ , donde  $V$  es un conjunto finito de vértices y  $E$  es un multiconjunto de pares no ordenados de vértices denotados por  $(x,y)$ , que se denominan lados o aristas. Dentro de la nomenclatura de los grafos denotamos a  $V(G)$  como el conjunto de vértices del grafo  $G$  y a  $E(G)$  como el conjunto de aristas del grafo  $G$ . Otros conjuntos que se deben mencionar son el conjunto  $v(G)$  y el  $\varepsilon(G)$  que representan el número de vértices y el número de aristas del grafo  $G$ , respectivamente [13].

### 2.2.1. Tipos de Grafos

Como se mencionó anteriormente existen diferentes tipos de grafos, algunos de ellos son los grafos simples, multigrafos, pseudografos, grafos dirigidos, multigrafos dirigidos, etc.

#### Grafo Simple

Un grafo simple  $G=(V,E)$  consta de  $V$  , un conjunto no vacío de vértices, y de  $E$  , un conjunto de pares no ordenados de elementos distintos de  $V$  , a estos pares se les llama aristas. En la Figura 2.1 se muestra la estructura de un grafo simple.




Figura 2.1: Grafo simple.

#### Grafo Ponderado

Un grafo ponderado es aquel grafo en el que se asigna un valor a cada una de las aristas. Los grafos ponderados se utilizan usualmente para representar redes informáticas, para calcular el costo en líneas de comunicación telefónica, los tiempos de respuesta de computadoras o la distancia entre componentes activos de una red. En la Figura 2.2 se muestra la estructura de un grafo ponderado.




Figura 2.2: Grafo ponderado.

### 2.2.2. Matriz Laplaciana

La teoría de matrices y el álgebra lineal se pueden utilizar para analizar matrices de adyacencia de grafos. Los métodos algebraicos son especialmente eficaces en el tratamiento de los grafos, los cuales son regulares y simétricos. En algunas ocasiones, los valores propios se denominan como la conectividad algebraica de un grafo [12]. Dado el grafo  $G = (V, E)$  y su matriz de adyacencia  $A(G)$ , la matriz Laplaciana, o también llamada el Laplaciano de un grafo, se calcula mediante:

$$L(G) = D - A(G) \quad (2.3)$$

donde  $D$  es una matriz diagonal de dimensión  $|V| \times |V|$ , cuyo  $i$ -ésimo elemento es el grado de  $i$ -ésimo vértice y  $A(G)$  es la matriz de adyacencia.

El Laplaciano tiene las siguientes propiedades sobre la topología de un grafo.

1. La matriz  $L(G)$  es semidefinida positiva.
2. Cero es siempre un valor propio de  $L(G)$  con multiplicidad al menos unitaria, esto es,  $\lambda_0 = 0$ .
3. Si  $G$  está desconectado, entonces  $\lambda_0$  tiene multiplicidad mayor que uno.
4. Si  $G$  es conexo, entonces  $\lambda_1 > 0$ .
5. La multiplicidad de  $\lambda_0$  indica cuantos componentes conexos tiene  $G$ .

## 2.3. Transformada de Fourier y transformada wavelet

En esta sección se habla sobre los conceptos preelminares que se siguen para llegar a comprender los métodos de la transformada de Fourier y la DWT utilizados para la extracción de características frecuenciales.

### 2.3.1. Conceptos preliminares

En esta sección se habla de los conceptos preliminares a la DWT en los cuales se encuentra el tema de la transformada de Fourier, así como la base de su funcionamiento que son las bases y espacios vectoriales.

#### Bases y espacios vectoriales

Un espacio vectorial (real o complejo) es una terna formada por un conjunto de vectores ( $E$ ) y dos operaciones, la suma vectorial  $\oplus$  y el producto por un escalar  $\odot$ . Una base de un espacio vectorial  $E$  es cualquier sistema de vectores  $x_1, x_2, \dots, x_n$  que son generadores de  $E$  y son linealmente independientes.

La definición de un producto interno en  $R^3$  puede ser generalizada a  $R^n$  para cualquier dimensión  $n$ . Para dos vectores  $X = (x_1, x_2, \dots, x_n)$ ,  $Y = (y_1, y_2, \dots, y_n)$  en  $R^n$ , el producto interno euclidiano está dado por:

$$\langle X, Y \rangle = \sum_{n=-\infty}^{\infty} x_n y_n \quad (2.4)$$

Cuando se estudia la Transformada de Fourier se utiliza el exponencial complejo. Considerando espacios vectoriales complejos así como reales, la definición anterior de producto interno para  $R^n$  puede ser modificada por vectores en  $C^n$  por el conjugado del segundo factor. Recordando que el conjugado de un número complejo  $z = x + iy$  es definido como  $\bar{z} = x - iy$ . Note que  $z\bar{z} = x^2 + y^2$ , que por definición es  $|z|^2$  (el cuadrado de la longitud de  $z = x + iy$  es considerado como un vector en el plano desde (0,0) hasta (x,y)) [16]. Si  $Z = (z_1, z_2, \dots, z_n)$  y  $W = (w_1, w_2, \dots, w_n)$  son vectores en  $C^n$  entonces:

$$\langle Z, W \rangle = \sum_{n=-\infty}^{\infty} z_n \bar{w}_n \quad (2.5)$$

La norma de un vector se define a partir del producto interno como:

$$\|Z\| = \sqrt{\langle Z, Z \rangle} \quad (2.6)$$

Y la distancia entre los dos vectores  $Z$  y  $W$  es la norma de su diferencia:

$$d = \|Z - W\| \quad (2.7)$$

### Espacio $L^2$ y $l^2$

El espacio  $L^2([a, b])$  es el conjunto de todas las funciones cuadráticas integrables definidas en  $a \leq t \leq b$ , y se representa de la siguiente manera:

$$y = f\left(\sum_k w_k x_k\right) \quad (2.8)$$

El espacio  $l^2$  es el conjunto de todas las secuencias  $X = \dots x_{-1}, x_0, x_1, \dots, x_i \in C$ , con  $\sum_{-\infty}^{\infty} |x_n|^2 < \infty$ , en el cual el producto punto está definido como [16]:

$$\langle X, Y \rangle_{l^2} = \sum_{-\infty}^{\infty} x_n \bar{y}_n \quad (2.9)$$

### Expansión de series de señales

Una expansión lineal de señales implica que, dada cualquier señal  $x$  de algún espacio  $S$ , donde  $S$  puede ser de dimensión finita ( $R^n, C^n, etc.$ ) o de dimensión infinita ( $l_2(Z), L_2(R)$ ), se puede encontrar un conjunto de señales elementarias  $\{\varphi_i\}_{i \in Z}$  para ese espacio, y  $x$  se puede escribir como una combinación lineal [17].

$$x = \sum_i \alpha_i \varphi_i \quad (2.10)$$

donde el conjunto  $\{\varphi_i\}$  es completo para el espacio  $S$ , si todas las señales  $x \in S$  pueden ser expandidas como en la ecuación anterior. En ese caso existirá también un conjunto dual  $\{\tilde{\varphi}_i\}_{i \in Z}$  tal que los coeficientes de expansión en la ecuación anterior puedan ser calculados como:

$$\alpha_i = \sum_n \tilde{\varphi}_i[n] x[n] \quad (2.11)$$

cuando  $x$  y  $\tilde{\varphi}_i$  son secuencias discretas y:

$$\alpha_i = \int \tilde{\varphi}_i(t) x(t) dt \quad (2.12)$$

cuando son funciones reales continuas en el tiempo.

Como se puede observar las expresiones anteriores son el producto interno de  $\tilde{\varphi}_i$ 's con la señal  $x$ , denotado por  $\langle \tilde{\varphi}_i, x \rangle$ . Un caso particular es cuando el conjunto  $\varphi_i$  es ortonormal y completo; por lo tanto, se tiene una base ortonormal para  $S$  y la base y el dual son la misma, esto es,  $\varphi_i = \tilde{\varphi}_i$ . Entonces

$$\langle \varphi_i, \varphi_j \rangle = \delta[i - j] \quad (2.13)$$

con:

$$\delta = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (2.14)$$

Los vectores en un sistema ortonormal son linealmente independientes, dado que  $\sum \alpha_i \varphi_i = 0$  implica  $0 = \langle \varphi_j, \sum \alpha_i \varphi_i \rangle = \sum \alpha_i \langle \varphi_i, \varphi_j \rangle = \alpha_j$ . Un sistema ortonormal en un espacio vectorial  $E$  es una base ortonormal si abarca a  $E$ .

### Bases ortonormales

Para un conjunto de vectores  $S = \{\varphi_i\}$ , para ser una base ortonormal primero se debe de verificar que el conjunto de vectores  $S$  sean ortonormales y por lo tanto  $S$  sea completo, esto es, que cada vector del espacio a representar puede ser expresado como una combinación lineal de los

vectores de  $S$ . En otras palabras, un sistema ortonormal  $\{\varphi_i\}$  es llamado base ortonormal para  $E$  si para cada  $y$  en  $E$  [17]:

$$y = \sum_k \alpha_k \varphi_k \quad (2.15)$$

Los coeficientes  $\alpha_k$  de la expansión son llamados coeficientes de Fourier de  $y$  (con respecto a  $\{\varphi_i\}$ ) y están dados por:

$$\alpha_k = \langle \varphi_k, y \rangle \quad (2.16)$$

### Proyección ortogonal y aproximación por mínimos cuadrados

Un vector de un espacio de Hilbert  $E$  tiene que ser aproximado por un vector situado en un subespacio (cerrado)  $S$ . Se asume que  $E$  es separable, así,  $S$  contiene una base ortonormal  $\{\varphi_1, \varphi_2, \dots\}$ . Entonces la proyección ortogonal de  $y \in E$  sobre  $S$  esta dada por [17]:

$$\hat{y} = \sum_i \langle \varphi_i, y \rangle \varphi_i \quad (2.17)$$




Figura 2.3: Proyección ortogonal sobre un subespacio.

En la Figura 2.3 se puede observar que la diferencia  $d = y - \hat{y}$  satisface  $d \perp S$ , y en particular  $d \perp \hat{y}$ , así como:

$$\|y\|^2 = \|\hat{y}\|^2 + \|d\|^2 \quad (2.18)$$

Una propiedad importante de tal aproximación es que es mejor en el sentido de los mínimos cuadrados, es decir:

$$\min \|y - \varphi\| \quad (2.19)$$

Para  $\varphi$  en  $S$  se logra mediante  $\varphi = \sum_i \alpha_i \varphi_i$  con:

$$\alpha_i = \langle \varphi_i, y \rangle \quad (2.20)$$

### 2.3.2. Transformada de Fourier

La transformada de Fourier de una señal continua en el tiempo se define como:

$$\varphi(e^{j\omega t}) = \int_{-\infty}^{\infty} \varphi(t) e^{-j\omega t} dt \quad (2.21)$$

La transformada de Fourier de una señal de energía finita discreta en el tiempo  $\varphi(n)$  se define como [18]:

$$\varphi(\omega) = \sum_{n=-\infty}^{\infty} \varphi(n) e^{-j\omega n} \quad (2.22)$$

donde  $\varphi(\omega)$  representa el contenido en frecuencia de la señal  $\varphi(n)$ .

Existen diferencias entre la transformada de Fourier para señales continuas y la transformada de Fourier para señales discretas en el tiempo. Por ejemplo, para señales continuas el espectro de señal es de  $(-\infty, \infty)$ , por el contrario para una señal discreta en el tiempo es  $(-\pi, \pi)$  o también se puede expresar como de  $(0, 2\pi)$ . Por lo tanto se dice que  $\varphi(\omega)$  es periódica de periodo  $2\pi$ , como se observa a continuación:

$$\begin{aligned} \varphi(\omega + 2\pi k) &= \sum_{n=-\infty}^{\infty} \varphi(n) e^{-j(\omega + 2\pi k)n} \\ &= \sum_{n=-\infty}^{\infty} \varphi(n) e^{-j\omega n} e^{-j2\pi kn} \end{aligned}$$

$$= \sum_{n=-\infty}^{\infty} \varphi(n) e^{-j\omega n} = \varphi(\omega) \quad (2.23)$$

por lo tanto  $\varphi(\omega)$  es periódica de periodo  $2\pi$ .

La segunda diferencia es consecuencia de la naturaleza discreta en el tiempo de la señal. Para la señal discreta en el tiempo, la transformada de Fourier es una suma de términos en lugar de una integración, como en el caso de las señales continuas en el tiempo.

Como  $\varphi(\omega)$  es una función periódica puede expandirse en serie de Fourier. Los coeficientes de Fourier de esta expansión en serie son los valores de la secuencia  $\varphi(n)$ . Para demostrar este punto, se evalúa la secuencia  $x(n)$  a partir de  $\varphi(\omega)$ . En primer lugar, multiplicamos ambos lados de la ecuación (2.22) por  $e^{j\omega m}$  e integramos en el intervalo  $(-\pi, \pi)$ . Así, tenemos:

$$\int_{-\pi}^{\pi} \varphi(\omega) e^{j\omega m} d\omega = \int_{-\pi}^{\pi} \left[ \sum_{n=-\infty}^{\infty} \varphi(n) e^{-j\omega n} \right] e^{-j\omega m} d\omega \quad (2.24)$$

La integral del lado derecho de la ecuación puede evaluarse si se puede intercambiar el orden de las operaciones de suma e integración. Este intercambio puede hacerse si la serie

$$\varphi_N(\omega) = \sum_{n=-N}^N \varphi(n) e^{-j\omega n} \quad (2.25)$$

converge uniformemente a  $\varphi(\omega)$  cuando  $N \rightarrow \infty$ . Intercambiando el orden de las operaciones de suma e integración en la ecuación se obtiene

$$\varphi_N = \frac{1}{2\pi} \int_{-\pi}^{\pi} \varphi(\omega) e^{j\omega n} d\omega \quad (2.26)$$

esta ecuación muestra que es la expresión correspondiente a los coeficientes de la serie de Fourier de una función que es periódica de periodo  $2\pi$ .

### 2.3.3. Transformada wavelet

La transformada wavelet continua (CWT) es representada con la siguiente ecuación:

$$CWT(a, b) = \int_{-\infty}^{\infty} \varphi(t) \psi_{a,b}^*(t) dt \quad (2.27)$$

donde  $\varphi(t)$  representa la señal analizada,  $a$  y  $b$  representan el factor de escala y la traslación a lo largo del eje del tiempo respectivamente, y el  $\psi_{a,b}^*(\cdot)$  es el complejo conjugado de  $\psi_{a,b}(\cdot)$ , conocida como la wavelet madre y es obtenida escalando la wavelet en una escala  $a$  y un tiempo  $b$  [19].

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-a}{a}\right) \quad (2.28)$$

La DWT puede ser vista como una extensión de la transformada clásica de Fourier, con la diferencia de que Fourier está definida en una misma escala, mientras que las wavelets son multiescala. El esquemático del procedimiento de descomposición a multiresolución de una señal  $\varphi[n]$  se muestra en la Figura 2.4.




Figura 2.4: Esquemático del procedimiento de descomposición de una señal  $\varphi[n]$  mediante DWT, donde  $g[n]$  es un filtro pasa altas y  $h[n]$  es un filtro pasa bajas.

El primer filtro  $g[n]$  es un filtro pasa altas y el segundo filtro  $h[n]$  es un filtro pasa bajas. La Salida del remuestreo del filtro pasa altas arroja el detalle 1 (D1), y la salida del remuestreo del filtro pasa bajas arroja la aproximación 1 (A1), y así sucesivamente se repite con cada salida del filtro pasa bajas. Existe una gran variedad de wavelet madres entre las que se usaron se encuentran la Daubechies 1 (Db1) o también conocida como Haar, Daubechies 4 (Db4), Daubechies 8 (Db8) y Daubechies 16 (Db16), con diferentes cantidades de escalamiento o niveles. La familia de

las wavelets Daubechies cuenta con la propiedad de fase lineal, lo que es necesario para la reconstrucción, pueden ser ortogonales y biortogonales, de soporte compacto y es posible usarse tanto en CWT como en DWT.

## 2.4. Clasificación

La clasificación consiste en asignar un objeto, conjunto de características, etc. en una de las clases disponibles utilizando el método de análisis discriminante el cual es una técnica estadística capaz de decirnos que variables permiten diferenciar a los grupos y cuantas de estas variables son necesarias para poder llevar a cabo la mejor clasificación posible. Existen dos tipos de clasificadores, lineales y no lineales, los clasificadores lineales son generalmente más robustos que los no lineales, esto se debe a que los clasificadores lineales tienen menos parámetros para sintonizar y, por tanto, es menos probable que tengan sobre ajuste [15].

La clasificación puede ser linealmente separable o no linealmente separable. La Figura 2.5 muestra un problema de clasificación de doble luna, donde las muestras en diferentes colores indican las distintas actividades a clasificar:

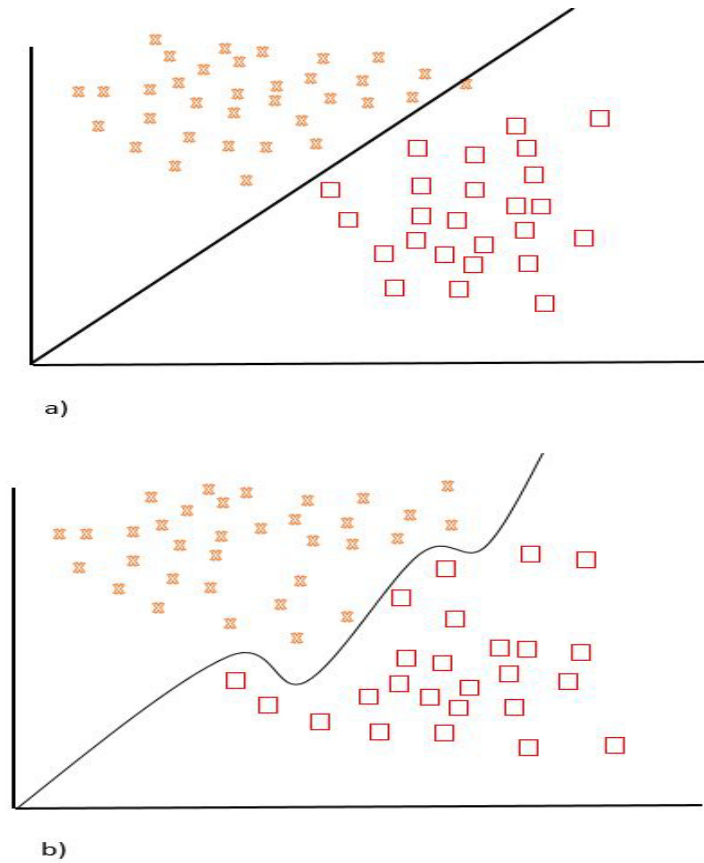


Figura 2.5: Clasificación: a) linealmente separable b) no linealmente separable.

Existen varios tipos de clasificadores entre ellos se encuentran:

- Clasificador de bayes: El clasificador de Bayes, minimiza el error de clasificación tomando en cuenta una función de riesgo promedio [20].
- Clasificador por máquina de soporte vectorial (MSV): Este clasificador se basa en la construcción de un hiperplano, basándose en un subconjunto de datos de entrenamiento que maximizan la distancia entre ambas clases, con los cuales se establece una superficie de decisión [20].
- Clasificador con análisis de componentes principales (PCA): Es un método estadístico de simplificación y reducción de la dimensionalidad de un conjunto de datos con numerosas variables [21].

- Clasificador por RNA perceptrón multicapa.

En este trabajo se utiliza el clasificador basado en RNA, el cuál se describe a continuación.

### 2.4.1. Redes neuronales artificiales

Las RNA se definen como sistemas de mapeos no lineales cuya estructura se basa en principios observados en los sistemas nerviosos de humanos y animales. Constan de un número grande de procesadores simples ligados por conexiones con pesos. Las unidades de procesamiento se denominan neuronas. Cada unidad recibe entradas de otros nodos y genera una salida simple escalar que depende de la información local disponible, guardada internamente o que llega a través de las conexiones con pesos. Las neuronas artificiales simples fueron introducidas por McCulloch y Pitts en 1943 [22]. Los elementos que conforman a una RNA son:

- Un conjunto de neuronas (para el procesamiento).
- Un estado de activación para cada neurona, equivalente a la salida de la neurona.
- Conexiones entre las neuronas, definidas por un peso que determina el efecto de una señal de entrada en la neurona.
- Una regla de propagación, que determina la entrada efectiva de una neurona a partir de las entradas externas.
- Una función de activación que actualiza el nuevo nivel de activación basándose en la entrada efectiva y la activación anterior.
- Una entrada externa que corresponde a un término determinado como bias para cada neurona.
- Un método para reunir la información, correspondiente a la regla del aprendizaje.
- Un ambiente en el que el sistema va a operar, con señales de entrada e incluso señales de error.

La neurona puede ser descrita de la siguiente manera:

$$y = f\left(\sum_k w_k x_k\right) \quad (2.29)$$

donde,  $x_k$  son señales de salida de otros nodos o entradas externas,  $w_k$  son los pesos de conexión de la neurona  $k$ , y  $f(\bullet)$  es la función simple o función de activación.

La entrada total  $u$  de la neurona  $k$  es la suma de los pesos de las entradas conectadas, más un bias  $\theta$ , como se puede observar en la siguiente ecuación:

$$u = \sum_j w_j x_j + \theta \quad (2.30)$$

Si el peso  $w_j$  es positivo se habla de una excitación y si el peso es negativo se considera una inhibición de la entrada. La regla que logra establecer el efecto de la entrada total  $u(t)$  en la activación de la neurona  $k$  se denomina función de activación, entre las más frecuentes encontramos las siguientes:

1. **Función sigmoideal:** Con esta función el valor dado por la función es cercano a uno de los valores asintóticos, esto hace que el valor de salida esté comprendido en la zona alta o baja del sigmoide, ver Figura 2.6.

$$F_k(u) = \frac{1}{1 + e^{-u}} \quad (2.31)$$




Figura 2.6: Función sigmoideal.

2. **Función de la tangente hiperbólica:** Esta función es utilizada cuando se presentan variaciones suaves de valores positivos y negativos de la señal a clasificar, ver Figura 2.7.

$$F_k(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}} \quad (2.32)$$




Figura 2.7: Función tangente hiperbólica.

3. **Función signo:** Es una función definida a trozos, que obtiene el signo de cualquier número real que se tome por entrada, ver Figura 2.8.

$$Y = \text{sgn}(x) \begin{cases} +1, \text{ si } x > 0 \\ -1, \text{ si } x < 0 \end{cases} \quad (2.33)$$




Figura 2.8: Función signo.

## Perceptrón Multicapa

El perceptrón multicapa es una RNA que consta de múltiples capas y permite obtener la salida deseada con el procesamiento de los datos de entrada. Este tipo de RNA es uno de los primeros esfuerzos por presentar el aprendizaje supervisado, el cual es una técnica de aprendizaje automático que se basa en los datos de entrada y salidas deseadas para ajustar los pesos de la RNA en función del error generado con el fin de aproximar una función no lineal o algún tipo de relación.

En la figura 2.9 se muestra el esquema básico de una RNA perceptrón multicapa.

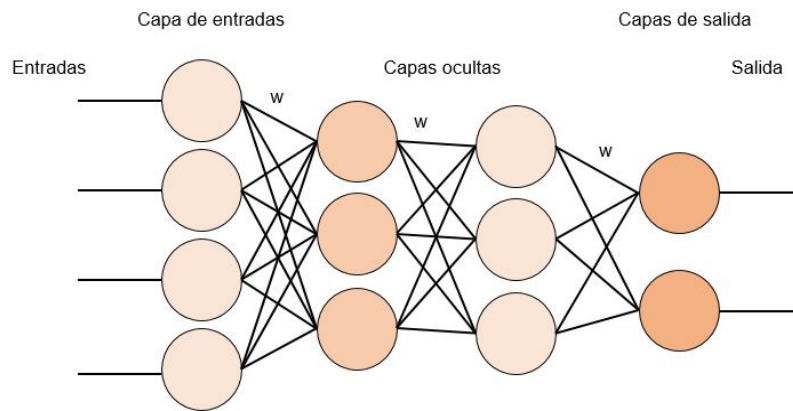


Figura 2.9: Esquema básico de una RNA.

El algoritmo de retropropagación para redes multicapa realiza la actualización de pesos y ganancias con base en el error cuadrático medio. Si se considera la RNA de tres capas con dos entradas y una salida de la Figura 2.9, se puede observar que a cada neurona la constituye dos unidades, donde la primera suma los productos de las entradas por sus respectivos pesos, y la segunda unidad contiene la función de activación. La señal  $e$  es la salida de la suma, y  $y = f(e)$  es la señal de salida de la función de activación, así como la salida de la neurona.

Para enseñar a la RNA es necesario primero llevar a cabo el entrenamiento con un conjunto de datos el cual consta de señales de entrada asignadas a salidas deseadas (denominadas  $z$ ). El entrenamiento es un proceso iterativo y en cada una de las iteraciones los pesos de los nodos se modifican usando nuevos datos del conjunto de entrenamiento. Las modificaciones de los pesos se calculan empleando el algoritmo de retropropagación del error para el entrenamiento supervi-

sado. Es posible determinar los valores de salida de cada neurona en cada capa de la RNA, en la Figura 2.10 se observa como se propaga la señal a través de la RNA, donde los pesos  $w_{mn}$  corresponden a la conexión de la salida de la neurona  $m$  con la entrada de la neurona  $n$ .

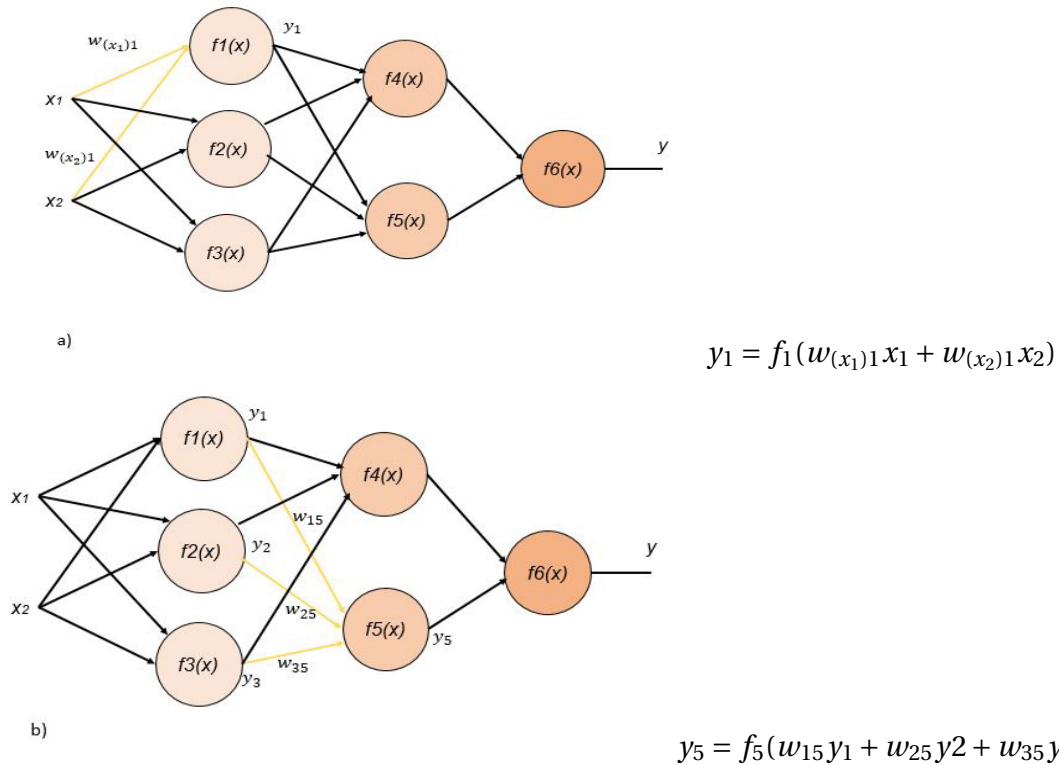


Figura 2.10: Propagacion de la señal en una RNA perceptrón multicapa. a) Calculo de la salida  $y_1$  correspondiente a la salida de la neurona 1, b) Calculo de la salida  $y_5$  correspondiente a la salida de la neurona 5.

En el siguiente paso, la salida de la RNA es comparada con el valor de la salida deseada, esto define un error  $\delta$  de la señal, esto es  $\delta = z - y$ . El error producido en las capas internas no se puede conocer y lo que hace el algoritmo de retropropagación es propagar el error de regreso a todas las neuronas cuya salida fue la entrada de la última neurona; esto se logra multiplicando el error por el peso, como se muestra en la Figura 2.11.

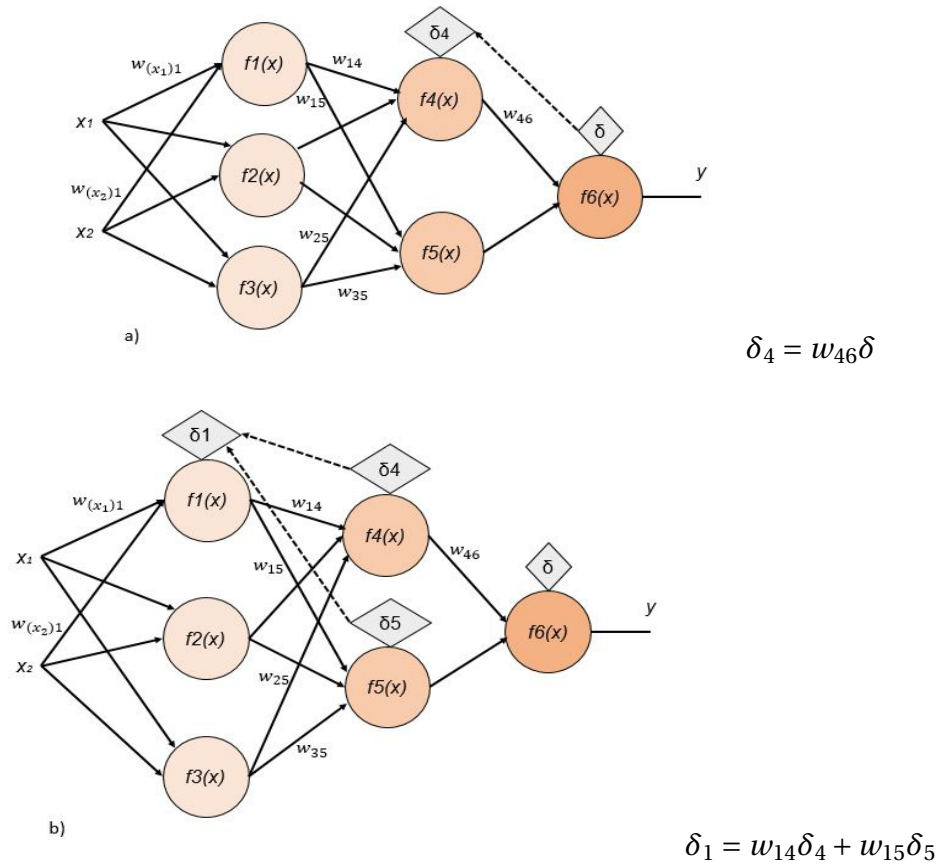


Figura 2.11: Retropropagación del error en una RNA perceptrón multicapa. a) Retropropagación del error de la salida a la neurona 4, b) Retropropagación del error a la capa de neuronas anterior en este caso, de la neurona 4 y 5 hacia la neurona 1.

El siguiente paso es el ajuste de los pesos  $w$ , esto se hace una vez que se conocen los errores. Se definen los coeficientes  $\eta$ , que afectan la velocidad de aprendizaje, y se pueden definir mediante varios métodos. Uno de ellos implica que al inicio del proceso de entrenamiento se elige un valor grande, el cual va a ir descendiendo conforme avanza el proceso. El siguiente método inicia con valores pequeños que aumentan a medida que el proceso avanza y de nuevo disminuye en la etapa final. Iniciar el proceso con un valor pequeño de  $\eta$  permite establecer los signos de los pesos, la modificación de los pesos se hace de la siguiente manera:

$$w'_{(x_1)1} = w_{(x_1)1} + \eta \delta_1 \frac{df_1(e)}{de} x_1 \tag{2.34}$$

$$w'_{(x_2)1} = w_{(x_2)1} + \eta \delta_1 \frac{df_1(e)}{de} x_2 \tag{2.35}$$

donde  $w_{(x_1)1}$  y  $w_{(x_2)1}$  son los pesos que existen entre la entrada  $x_1$  y  $x_2$  respectivamente y la neurona 1.




Figura 2.12: Ajuste de pesos  $w$ , donde  $w'_{(x_1)1}$  y  $w'_{(x_1)2}$  son los pesos actualizados.

En el siguiente capítulo se presenta la aplicación de estos métodos en la clasificación de actividades motrices mediante el análisis espacial y frecuencial multivariable de la señal EEG.

# Capítulo 3

## Procesamiento de señales

En este capítulo se hablara del protocolo experimental, de la adquisición y procesamiento de las señales EEG así como de la implementación numérica utilizada para la extracción de las características espaciales y frecuenciales de la señal.

### 3.1. Protocolo experimental

El objetivo del experimento es la clasificación de actividades motrices. Para lo cual se requiere adquirir la señal EEG de los sujetos de estudio durante la realización de actividades, en este caso caminata sobre una caminadora a dos velocidades (4 y 6 *mph*), posteriormente se extraen las características espaciales y frecuenciales de la señal y se clasifican las actividades motrices. Se consideran datos experimentales obtenidos anteriormente por el cuerpo académico del DIE de FIME-UANL [23],[24]. En el experimento participaron tres voluntarios, cada uno de ellos proporcionó su consentimiento de manera verbal para la utilización de los datos generados durante el experimento. Los criterios de participación incluyen que el sujeto no tenga ninguna patología neuromotora, que el día del experimento se presente descansado, con el cabello limpio sin ningún tipo de fijador o crema.

El equipo utilizado para la realización del experimento fue una caminadora XTERRA®trail racer 3.0 y un sistema de adquisición de señales EEG de Advanced Brain Monitoring®. El experimento consistió en realizar dos actividades de caminata a diferentes velocidades sobre la cami-

nadora. La primera velocidad ( $V1$ ) es lenta (4 *mph*) y la segunda velocidad ( $V2$ ) es mayor pero sin llegar a ser considerada como trote, 6 *mph*, permaneciendo en cada velocidad por un minuto.

En el experimento, el sujeto parte del estado de reposo, comienza caminando en  $V1$ , después de un minuto se hace el cambio a  $V2$ . Entre cada velocidad existe un intervalo de tiempo llamado transición uno ( $T1$ ) que es el tiempo que se tarda en acelerar de la  $V1$  a la  $V2$ . Transcurrido el minuto en  $V2$  se regresa a  $V1$  durante el intervalo de tiempo en el cambio de  $V2$  a  $V1$  se lleva a cabo una desaceleración, a este periodo se le llama transición dos ( $T2$ ). El sujeto de estudio realiza un minuto de caminata en  $V1$ . El experimento concluye después de esto, por lo que el tiempo total es de tres minutos. Se toma en cuenta que durante el experimento se le avisaba verbalmente al sujeto sobre el cambio de velocidades; en ese momento él sujeto realizaba tres parpadeos indicando el cambio de velocidad. Se realizaron 10 repeticiones del experimento, con un descanso de un minuto y medio entre cada una de las repeticiones para evitar fatiga.

## 3.2. Adquisición

Para adquirir la señal EEG durante el experimento, se utilizó el sistema B-Alert X10 de Advanced Brain Monitoring®, con una frecuencia de muestreo de 256 *Hz*, el cual tiene integrado la adquisición inalámbrica de las señales EEG, EOG y ECG. El sistema cuenta con registro de 9 electrodos de acuerdo al estándar internacional 10-20 (Fz, F3, F4, Cz, C3, C4, POz, P3 y P4). El preprocesamiento de la señal (filtrado de ruido y artefactos) se realizó con el banco de filtros del sistema de adquisición. La Figura 3.1 muestra la distribución de los electrodos y la Figura 3.2 muestra a un sujeto de estudio utilizando el sistema B-Alert X10 de Advanced Brain Monitoring®.

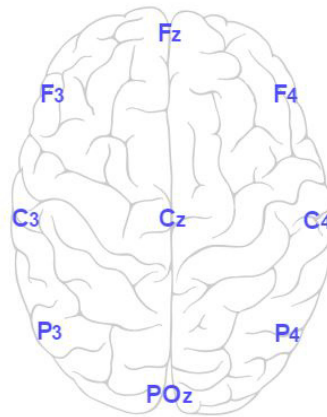


Figura 3.1: Distribución de los electrodos del sistema de adquisición de señales B-Alert X10 de Advanced Brain Monitoring®, de acuerdo con el estándar internacional 10-20.




Figura 3.2: Sujeto de estudio utilizando el sistema de adquisición de señales B-Alert X10 de Advanced Brain Monitoring®, a) Vista lateral de la colocación del sistema de adquisición, b) Distribución de los electrodos de acuerdo al estándar 10-20, c) Colocación de los electrodos faciales.

El experimento completo consta de una señal  $E_i$  por electrodo, por cada repetición. Para realizar el procesamiento de señales, cada una de ellas se dividió en cinco secciones, cada sección corresponde a las actividades realizadas, tal como se muestra en la Figura 3.3.




Figura 3.3: Partición del experimento completo en secciones, donde  $E_i$  es el  $i$ -ésimo electrodo del registro con  $i = 1, 2, \dots, 9$ .

Sección	Actividad
V1	Caminata en velocidad uno.
T1	Transición en cambio de velocidad uno a velocidad dos.
V2	Caminata en velocidad dos.
T2	Transición en cambio de velocidad dos a velocidad uno.
V1	Caminata en velocidad uno.

Tabla 3.1: Secciones del experimento completo.

En la Tabla ?? se puede observar la manera como fue seccionada la señal dependiendo de cada actividad realizada, de esta manera se realizó el filtrado de bandas por sección y el estudio de coherencia para la obtención de los grafos de conectividad, así como las gráficas de grado de conexión y gráficas de desconexiones de los electrodos.

### 3.2.1. Preprocesamiento

#### Bandas de frecuencia

Mediante la realización de investigaciones de la señal EEG se a observado que al procesar la señal, las distintas bandas de frecuencia que muestra el espectro tienen características que pueden ir cambiando conforme cambie la edad de las personas. Se conocen como banda  $\delta$ ,  $\theta$ ,  $\alpha$  y  $\beta$ , las cuales oscilan entre los 0.5 y 30 Hz y la banda  $\gamma$  la cual abarca las frecuencias arriba de los 30 Hz.

La banda  $\delta$  abarca las frecuencias de 0.5 a 4 *Hz*, esta señal se asocia con el sueño profundo y el estado de vigilia. Al ser señales generadas en el centro del cerebro llegan con atenuación y se pueden confundir con movimientos de los músculos del cuello y de la mandíbula.

La banda  $\theta$  abarca las frecuencias de 4 a 8 *Hz*, en esta banda se concentra la inspiración creativa, meditación profunda y el material inconsciente. Juega un papel importante en la niñez y se examinan los cambios que hay en ella con el paso del tiempo para estudios emocionales y de maduración.

La banda  $\alpha$ , abarca las frecuencias de 8 a 13 *Hz* se presentan cuando el individuo está totalmente relajado sin nada de atención ni concentración. Con los ojos cerrados se producen ondas  $\alpha$ . Se dice que es un patrón de espera o exploración producido por las regiones visuales del cerebro. El origen y significado fisiológico aún es desconocido.

La banda  $\beta$  abarca las frecuencias de 13 a 30 *Hz*. Esta banda es asociada al pensamiento y atención activa en el mundo exterior y a la resolución de problemas complejos, estas se encuentran en las regiones central y frontal del cerebro, la onda central puede ser bloqueada o anulada por la actividad motriz o estimulación táctil.

Al obtener el espectro de frecuencias de la señal se pueden observar las distintas bandas de frecuencia de la señal EEG [14], como se muestra en la Figura 3.4.

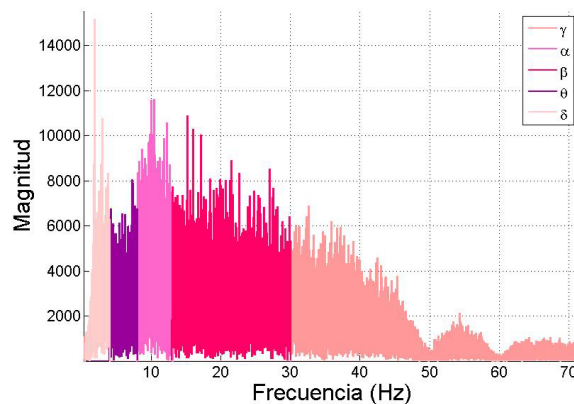


Figura 3.4: Bandas de frecuencia de la señal EEG.

Dado que las bandas relacionadas con la locomoción son la  $\alpha$  y  $\beta$ , se implementaron filtros chevsheve tipo 1, para filtrar las señales [24], en la Figura 3.5 se muestran las bandas de interés.




Figura 3.5: Bandas  $\alpha$  y  $\beta$  de frecuencia de la señal EEG.

Con la finalidad de realizar el análisis de coherencia de la señal y su posterior representación en grafos, la señal preprocesada es analizada por ventanas en cada una de las cinco secciones previamente definidas. La ventana tiene un tamaño fijo de un segundo y se superpone cada 0.5 segundos para tener mayor información sobre la dinámica del proceso. Las Figuras 3.6 y 3.7 muestran un ejemplo del ventaneo en la sección  $V1$  y  $T1$ , respectivamente. Los recuadros rosas oscuros muestran la ventana de 1 segundo y los recuadros claros muestran la superposición de 0.5 segundos. Para cada ventana se hace el cálculo de coherencia, por lo que se obtiene una matriz de coherencia por ventana.

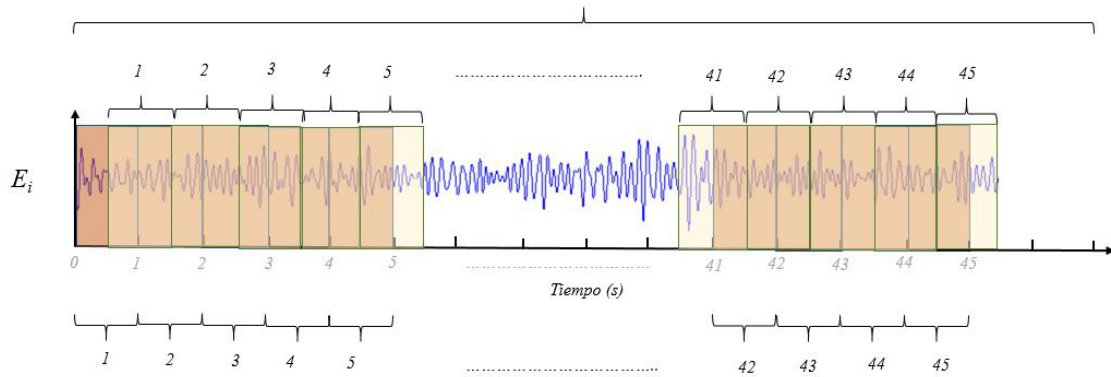


Figura 3.6: Proceso de ventaneo de la primera sección (V1). En este ejemplo se tienen 45 ventanas de un segundo iniciando en el tiempo cero de la sección (recuadros rosa oscuro, numeración inferior). Además, se tienen 45 ventanas superpuestas iniciando en el tiempo 0.5 segundos de la sección (recuadros claros, numeración superior). En total la sección tiene 90 ventanas de tiempo, por lo que se calculan 90 matrices de coherencia. Este procedimiento se repite en la tercera sección (V2 con 90 ventanas) y en la sección cinco (V1 con 90 ventanas).

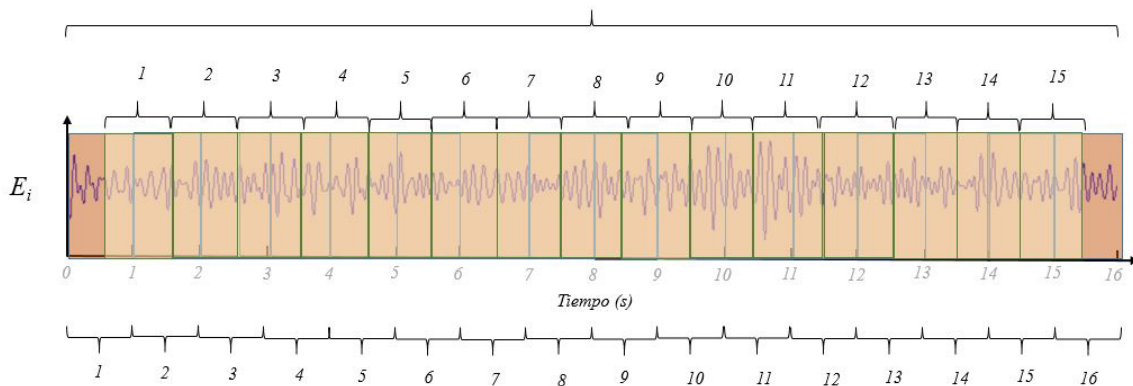


Figura 3.7: Proceso de ventaneo de la segunda sección (T1). En este ejemplo se tienen 16 ventanas de un segundo iniciando en el tiempo cero de la sección (recuadros rosa oscuro, numeración inferior). Además, se tienen 15 ventanas superpuestas iniciando en el tiempo 0.5 segundos de la sección (recuadros claros, numeración superior). En total la sección tiene 31 ventanas de tiempo, por lo que se calculan 31 matrices de coherencia. Este procedimiento se repite en la cuarta sección (T2 con 31 ventanas).

Una vez filtradas las señales en las bandas  $\alpha$  y  $\beta$  y separadas en cada sección V1, T1, V2, T2 y V1 e implementando el proceso de ventaneo se procede con la implementación numérica del

análisis de coherencia, grado de conectividad, desconectividad y obtención de los grafos de conectividad con el fin de obtener las características espaciales de la señal EEG durante las tareas motrices definidas en el protocolo experimental.

### 3.3. Implementación numérica

Los métodos de análisis del capítulo anterior fueron implementados numéricamente usando MatLab 2014b <sup>®</sup>. Primero se implementó el análisis de coherencia para obtener las características espaciales de las actividades motrices medidas a través del grado de conexión de sus grafos asociados. Este análisis proporciona el conjunto de electrodos más conectados durante las tareas motrices. Con esta información se resuelve el problema de clasificación en dos escenarios: a) considerando como características las magnitudes del espectro de Fourier de las bandas  $\alpha$  y  $\beta$  de los electrodos más conectados y, b) considerando el espectro de Fourier de las mismas bandas, pero ahora considerando sólo la información del electrodo C3. Posteriormente se realiza el mismo procedimiento, pero ahora utilizando características frecuenciales de la DWT. El detalle de la implementación numérica de cada método se describe a continuación.

#### 3.3.1. Obtención de las características espaciales

Como se vio anteriormente, la coherencia indica que tan relacionadas se encuentran dos señales; por tanto, en la aplicación de este trabajo el objetivo es tener una medida cuantitativa de qué tan relacionado está un electrodo con el resto de los electrodos. Con el cálculo de coherencia entre las señales de los electrodos se obtienen las matrices simétricas provenientes del ventaneo por secciones, esta matriz indica con que electrodos se conecta un determinado electrodo y con que fuerza. En este caso se obtienen matrices de tamaño  $9 \times 9$  debido a que el sistema de adquisición de señales EEG es de nueve canales.

Para cada actividad realizada obtenemos diferente número de matrices de coherencia, en la Tabla 3.2 se muestra cuantas matrices se obtuvieron para cada actividad (número de matrices por cada una de las 10 repeticiones de la actividad).

Actividad	Número de Matrices
V1	90
T1	30
V2	90
T2	30
V1	90

Tabla 3.2: Número de matrices de coherencia de cada sección del experimento completo. V1(caminata a 4 *mph*), V2(caminata a 6 *mph*), T1 (transición entre V1 y V2), T2 (transición entre V2 y V1)

Para obtener la matriz de cada grafos fue necesario primero realizar el promedio de las matrices simétricas de las 10 repeticiones, y a continuación se obtiene el promedio del total de matrices de coherencia de toda la actividad, de esta manera se obtiene una sola matriz simétrica de  $9 \times 9$  por cada una de las actividades realizadas, la cual se tiene que normalizar entre 0 y 1, para posteriormente aplicarle un umbral variable que se obtiene de la siguiente manera.

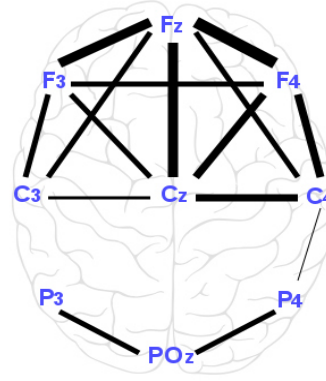
$$U(i) = u(i) + (1 - u(i))/2 \quad (3.1)$$

donde  $U(i)$  es el valor del umbral y  $u(i)$  es el mínimo valor de la matriz de coherencia (sin incluir la diagonal). Aplicando este umbral se obtiene una nueva matriz de los valores que sobrepasen dicho umbral, esta matriz es la que se utiliza para el trazo de los grafos.

A partir de la información de la matriz de coherencia umbralizada se realizan los grafos de conectividad. En la figura 3.8 se muestra la matriz umbralizada y su grafo representativo, de V1 del sujeto de estudio 1 de la banda  $\alpha$ , donde se puede observar que, dependiendo del valor del coeficiente de correlación, es el grosor de la arista entre los nodos representativos a esos electrodos, si el coeficiente es mayor, el grosor será mayor también.

	Poz	Fz	Cz	C3	C4	F3	F4	P3	P4
Poz	0	0	0	0	0	0	0	0.706	0.716
Fz		0	0.931	0.717	0.721	0.997	1	0	0
Cz			0	0.609	0.829	0.756	0.831	0	0
C3				0	0	0.768	0	0	0
C4					0	0	0.826	0	0.598
F3						0	0.773	0	0
F4							0	0	0
P3								0	0
P4									0

(a) Matriz umbralizada correspondiente a la V1.



(b) Grafo correspondiente a la V1.

Figura 3.8: Matriz de coherencia umbralizada correspondiente al sujeto 1 en la actividad V1, banda  $\alpha$  y su grafo correspondiente.

**Grado de conectividad**

En esta sección se obtiene la dinámica del grado de conectividad, el cual nos indica que tan fuertemente conectado, o, que tan conectado se encuentra un electrodo con respecto a los demás, mientras el valor de grado de conectividad obtenido sea más grande, nos puede indicar que, el electrodo en cuestión se conecta con varios electrodos o que las conexiones que tiene son fuertes. Estos datos se obtienen a partir de la matriz simétrica utilizada para el trazo de los grafos, a partir de ella se calcula la suma por fila, lo que da como resultado un vector de  $9 \times 1$  ( ya que son 9 electrodos). En la Figura 3.9 se muestra un ejemplo de como obtener el grado de conectividad.

	Poz	Fz	Cz	C3	C4	F3	F4	P3	P4		GRADO
<b>Poz</b>	0	0	0	0	0	0	0	0.706	0.716	.....	1.421
<b>Fz</b>	0	0	0.931	0.717	0.721	0.997	1	0	0	.....	4.365
<b>Cz</b>	0	0.931	0	0.609	0.829	0.756	0.831	0	0	.....	3.955
<b>C3</b>	0	0.717	0.609	0	0	0.768	0	0	0	.....	2.094
<b>C4</b>	0	0.721	0.829	0	0	0	0.826	0	0.598	.....	2.974
<b>F3</b>	0	0.997	0.756	0.768	0	0	0.773	0	0	.....	3.294
<b>F4</b>	0	1	0.831	0	0.826	0.773	0	0	0	.....	3.430
<b>P3</b>	0.706	0	0	0	0	0	0	0	0	.....	0.706
<b>P4</b>	0.716	0	0	0	0.598	0	0	0	0	.....	1.314

Figura 3.9: Ejemplo de la obtención del grado de conectividad de la actividad V1 del sujeto 1, banda  $\alpha$ .

Posteriormente se hizo un análisis sobre que tan desconectados se encuentran los electrodos al realizar las actividades. Para esto se obtuvo la matriz laplaciana a partir de las matrices de coherencia (una matriz Laplaciana por cada matriz de coherencia, por cada repeticion) ver Figura ???. En la diagonal principal de la matriz Laplaciana se encuentra el grado de conectividad de cada electrodo; por tanto el primer paso es calcular los valores propios de cada una de las matrices laplacianas, con ellos se forma una matriz donde las columnas representaban los electrodos y las filas es el total de matrices por actividad. La nueva matriz que se muestra en la Figura 3.10 es la que se utiliza para saber si el electrodo se encuentra desconectado, esto se puede saber si el número de ceros es mayor a 1. De esta matriz se cuenta la cantidad de ceros que existen por renglón y se obtiene un vector con la cantidad de ceros encontrados. Finalmente se agrupan los vectores en una matriz donde se incluyen los vectores resultantes de las 10 repeticiones y se obtiene la moda de cantidad de ceros en las repeticiones para saber si hubo variaciones, en que estado permaneció más tiempo, etc. Por lo anterior si la moda es 1, quiere decir que el electrodo permaneció conectado, si es diferente a 1 implica que en ese intervalo hubo desconexión.

	Poz	Fz	Cz	C3	C4	F3	F4	P3	P4
Poz	2.569	0	-0.838	0	0	0	0	-0.867	-0.864
Fz	0	4.195	-0.975	-0.749	-0.659	-1	-0.831	0	0
Cz	-0.838	-0.957	5.226	-0.695	-0.639	-0.792	0	-0.655	-0.650
C3	0	-0.749	-0.695	2.184	0	-0.741	0	0	0
C4	0	-0.659	-0.639	0	1.298	0	0	0	0
F3	0	-1	-0.792	-0.741	0	3.209	-0.676	0	0
F4	0	-0.831	0	0	0	-0.676	1.507	0	0
P3	-0.867	0	-0.655	0	0	0	0	2.146	-0.624
P4	-0.864	0	-0.650	0	0	0	0	-0.624	2.138

Figura 3.10: Matriz Laplaciana correspondiente a  $V3$  del sujeto de estudio 3, banda  $\beta$ .

Valores propios
0
0.6359
1.2568
1.8024
2.7658
3.3616
3.6201
4.9074
6.1206

Figura 3.11: Vector conformado por los valores propios de la matriz de la Figura 3.10 correspondiente a  $V3$  del sujeto de estudio 3, banda  $\beta$ .

	Poz	Fz	Cz	C3	C4	F3	F4	P3	P4
1	0	0.636	1.257	1.802	2.766	3.362	3.620	4.907	6.121
2	0	0.404	1.095	1.372	2.200	2.842	3.880	4.961	6.166
3	0	0	0.303	0.978	1.667	1.981	3.687	4.127	4.859
4	0	0.597	1.278	2.943	4.358	4.953	5.484	6.253	6.724
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
87	0	0.728	1.348	1.636	2.677	2.811	4.272	5.407	6.173
88	0	0.286	0.563	1.375	1.673	2.825	3.871	4.788	5.563
89	0	0.236	0.667	1.477	2.409	3.716	4.339	4.905	5.392
90	0	0.417	0.886	1.437	2.172	3.345	3.523	4.551	6.442

Figura 3.12: Vector conformado por los valores propios de la matriz de la Figura 3.10 correspondiente a  $V_3$  del sujeto de estudio 3, banda  $\beta$ .

### 3.3.2. Obtención de características frecuenciales

Las características frecuenciales de la señal EEG se extrajeron utilizando dos métodos: la transformada de Fourier con ventaneos cuya frecuencia de muestreo es de 256 Hz obteniendo 166 ventanas por toda la señal, para el procesamiento se utilizó la función *fft* de Matlab®. El otro método es la DWT, las wavelets madre utilizadas son la Db1, Db4, Db8 y Db16 de 7, 10 y 14 niveles, el procesamiento se realizó con la función *wavedec* de Matlab®. Ambos procedimientos tanto el de la transformada de Fourier como el de la DWT se realizaron tanto para la señal adquirida del electrodo C3, como para la señal adquirida del conjunto de electrodos FZ, CZ, C3 y F4.

En la Figura 3.13 se muestran los datos de interés de las bandas  $\alpha$  y  $\beta$  de la señal EEG de un solo ventaneo de 256 Hz, de la señal proveniente del electrodo C3 del sujeto de estudio 1. Mientras que en la Figura 3.14 se muestra el valor cuantitativo de cada elemento de las bandas  $\alpha$  y  $\beta$  los cuales son las entradas al clasificador.

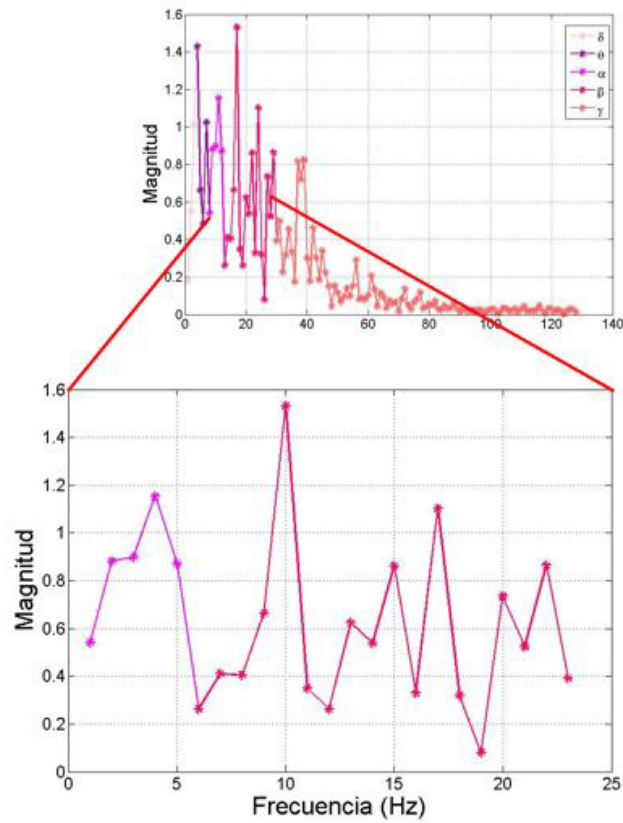


Figura 3.13: Representación gráfica del espectro de frecuencia en las bandas  $\alpha$  y  $\beta$  (de un solo ventaneo) resultado de aplicar la transformada de Fourier a la señal EEG proveniente del electrodo C3, del sujeto 1.

0.541	0.882	0.899	1.153	0.871	0.263	0.410	0.405	0.665	1.531	0.350	0.262	0.623	0.537	0.862	0.328	1.102	0.320	0.080	0.734	0.523	0.864	0.391
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------

Figura 3.14: Vector de características frecuenciales de la banda  $\alpha$  y  $\beta$  aplicando la transformada de Fourier a la señal proveniente del electrodo C3 del sujeto 1.

En la Figura 3.15 se muestra la gráfica de los detalles resultantes de la DWT *Db1* de 14 niveles con la señal proveniente del electrodo C3 del sujeto 1. Mientras que en la Figura 3.16 se muestra el valor cuantitativo de cada elemento de los niveles, los cuales son las entradas al clasificador.

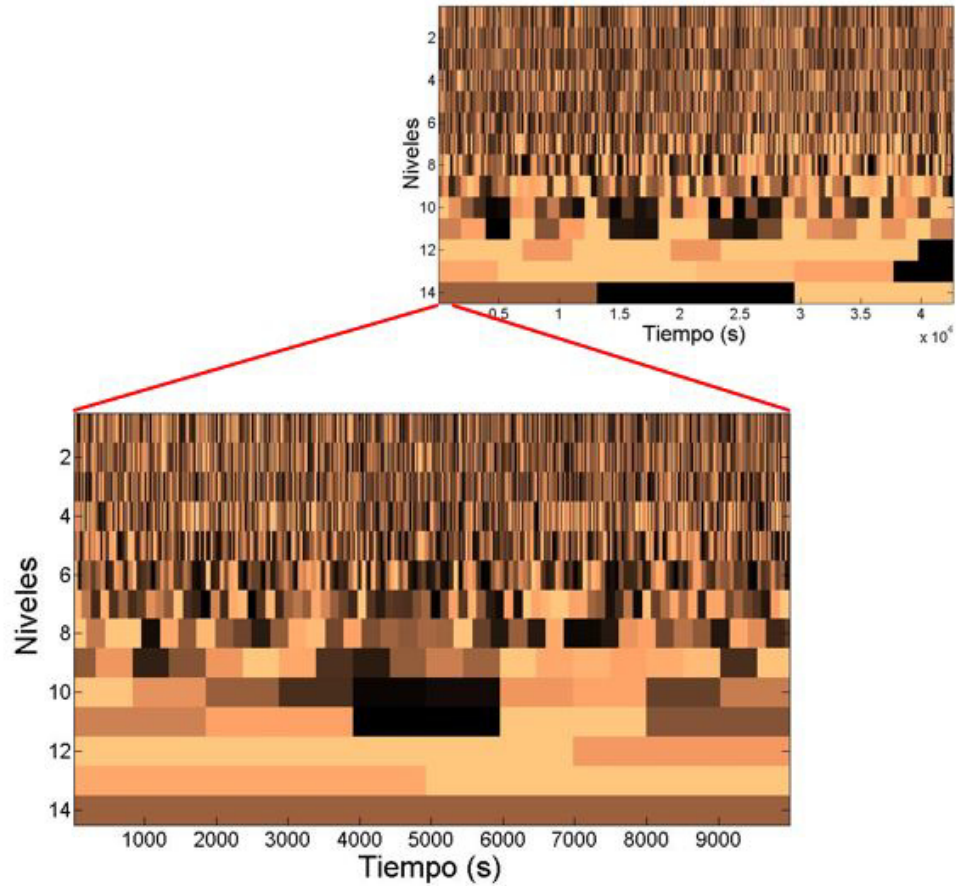


Figura 3.15: Representación grafica del los coeficientes de la DWT Db1 de 14 niveles, aplicada a la señal proveniente del electrodo C3, del sujeto 1.

<b>t1</b>	62	142	144	96	48	121	103	189	40	124	57	165	83	43
<b>t2</b>	62	142	144	96	48	121	103	189	40	124	57	165	83	43
<b>t3</b>	153	142	144	96	48	121	103	189	40	124	57	165	83	43

Figura 3.16: Matriz de coeficientes de la DWT Db1 de 14 niveles aplicada a la señal proveniente del electrodo C3 del sujeto 1, cada columna representa el vector de coeficientes en cada instante de tiempo.

### 3.3.3. Implementación numérica de la clasificación

El objetivo de este punto es clasificar las actividades (caminata a dos velocidades) realizadas por el sujeto de estudio. Para realizar la clasificación se utilizó la RNA perceptrón multicapa utili-

zando el *toolbox nntool* de Matlab® el cual requiere tener los datos de entrada, un vector de tareas objetivo. La configuración de la RNA varia según la entrada que tenga, las Tablas 3.3 y 3.4 muestran la arquitectura y los parámetros utilizados en la RNA utilizando la transformada de Fourier, y las Tablas 3.5 y 3.6 muestran la arquitectura y los parámetros de la RNA utilizando la DWT.

ELECTRODO(S)	ACTIVIDAD	ENTRADAS	NEURONAS EN CAPA OCULTA	NEURONAS EN CAPA DE SALIDA
E-C3	V1, V2, V1	23	47	1
E-FZ, CZ, C3, F4	V1, V2, V1	92	185	1

Tabla 3.3: Arquitectura de la RNA utilizando la transformada de Fourier para la extracción de características frecuenciales de la señal del electrodo C3 y de los electrodos FZ, CZ, C3 y F4.

ELECTRODO(S)	ACTIVIDAD	NÚMERO DE ÉPOCAS	GRADIENTE MÍNIMO	TAMAÑO DEL PASO
E-C3	V1, V2, V1	1000	1x10 <sup>-7</sup>	.001
E-FZ, CZ, C3, F4	V1, V2, V1	1000	1X10 <sup>-7</sup>	.001

Tabla 3.4: Parámetros de entrenamiento de la RNA utilizando la transformada de Fourier para la extracción de características frecuenciales de la señal del electrodo C3 y de los electrodos FZ, CZ, C3 y F4.

ELECTRODO(S)	ACTIVIDAD	TIPO DE DWT	NIVELES	ENTRADAS	NEURONAS CAPA OCULTA	NEURONAS CAPA SALIDA
E-C3	V1, V2, V1	Db1,Db4, Db8,Db16	7	7	15	1
			10	10	21	1
			14	14	29	1
E-FZ, CZ, C3, F4	V1, V2, V1	Db1,Db4, Db8,Db16	7	7	15	1
			10	10	21	1
			14	14	29	1

Tabla 3.5: Arquitectura de la RNA utilizando la DWT para la extracción de características frecuenciales de la señal del electrodo C3 y de los electrodos FZ, CZ, C3 y F4. Utilizando las wavelets madre Db1, Db4, Db8 y Db16.

ELECTRODO(S)	ACTIVIDAD	TIPO DE DWT	NIVELES	NÚMERO DE ÉPOCAS	GRADIENTE MÍNIMO	TAMAÑO DEL PASO
E-C3	V1, V2, V1	Db1,Db4, Db8,Db16	7	1000	$1 \times 10^{-7}$	.001
			10	1000	$1 \times 10^{-7}$	.001
			14	1000	$1 \times 10^{-7}$	.001
E-FZ, CZ, C3, F4	V1, V2, V1	Db1,Db4, Db8,Db16	7	1000	$1 \times 10^{-7}$	.001
			10	1000	$1 \times 10^{-7}$	.001
			14	1000	$1 \times 10^{-7}$	.001

Tabla 3.6: Parámetros de la RNA utilizando la DWT para la extracción de características frecuenciales de la señal del electrodo C3 y de los electrodos FZ, CZ, C3 y F4. Utilizando las wavelets madre Db1, Db4, Db8 y Db16.

# Capítulo 4

## Resultados

### 4.1. Resultados de Conectividad

#### Grafos representativos de conectividad

A continuación se muestran los grafos representativos de conectividad por actividad, por sujeto, por banda, creados a partir de las matrices de coherencia umbralizadas, agrupados para una mayor apreciación de los cambios entre velocidades y transiciones.




Figura 4.1: Grafos de la actividad completa, sujeto 1, banda  $\alpha$ .




Figura 4.2: Grafos de la actividad completa, sujeto 1, banda  $\beta$ .




Figura 4.3: Grafos de la actividad completa, sujeto 2, banda  $\alpha$ .




Figura 4.4: Grafos de la actividad completa, sujeto 2, banda  $\beta$ .




Figura 4.5: Grafos de la actividad completa, sujeto 3, banda  $\alpha$ .




Figura 4.6: Grafos de la actividad completa, sujeto 3, banda  $\beta$ .

### Grado de conectividad y desconectividad

En esta sección se muestran los resultados de la dinámica del grado de conectividad de los electrodos y de la desconectividad de los mismos.

En las Figuras 4.7 a la 4.12 se muestran las gráficas del grado de conectividad por sujeto de los 9 electrodos al realizar las 5 actividades. En las Figuras 4.13 a la 4.24 se muestra el resultado obtenido del calculo de la moda de desconexiones de los tres sujetos, por actividad realizada.

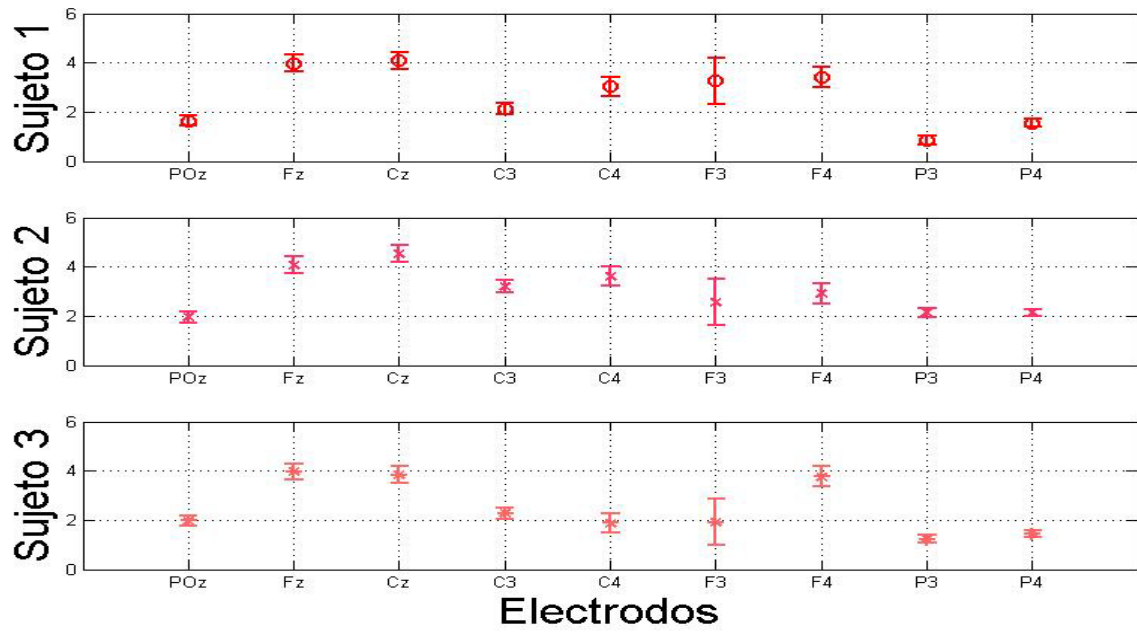


Figura 4.7: Grado de conexión, banda  $\alpha$ , V1, 3 sujetos.




Figura 4.8: Grado de conexión, banda  $\alpha$ , V2, 3 sujetos.




Figura 4.9: Grado de conexión, banda  $\alpha$ , V3, 3 sujetos.




Figura 4.10: Grado de conexión, banda  $\beta$ , V1, 3 sujetos.




Figura 4.11: Grado de conexión, banda  $\beta$ , V2, 3 sujetos.







Figura 4.12: Grado de conexión, banda  $\beta$ , V3, 3 sujetos.



(a) V1.




(b) V2.




(c) V3.

Figura 4.13: Velocidades, sujeto 1, banda  $\alpha$ .




(a) T1.




(b) T2.


Figura 4.14: Transiciones, sujeto 1, banda  $\alpha$ .



(a) V1.




(b) V2.




(c) V3.

Figura 4.15: Velocidades, sujeto 1, banda  $\beta$ .




(a) T1.




(b) T2.


Figura 4.16: Transiciones, Sujeto 1, banda  $\beta$ .



(a) V1.




(b) V2.




(c) V3.

Figura 4.17: Velocidades, sujeto 2, banda  $\alpha$ .




(a) T1.




(b) T2.


Figura 4.18: Transiciones, sujeto 2, banda  $\alpha$ .



(a) V1.




(b) V2.




(c) V3.

Figura 4.19: Velocidades, sujeto 2, banda  $\beta$ .




(a) T1.




(b) T2.


Figura 4.20: Transiciones, Sujeto 2, banda  $\beta$ .



(a) V1.




(b) V2.




(c) V3.

Figura 4.21: Velocidades, sujeto 3, banda  $\alpha$ .




(a) T1.




(b) T2.


Figura 4.22: Transiciones, sujeto 3, banda  $\alpha$ .



(a) V1.



(b) V2.



(c) V3.

Figura 4.23: Velocidades, sujeto 3, banda  $\beta$ .




### Clasificación de Actividades


Utilizando el método de la transformada de Fourier para la extracción de características, y la RNA perceptrón multicapa como clasificador (con diferente cantidad de neuronas en la capa oculta), se obtuvieron los siguientes resultados por sujeto de estudio y banda seleccionada, las cuales son  $\alpha$  y  $\beta$ , debido a que son las bandas asociadas al movimiento:

ELECTRODO(S)	SUJETO	PARÁMETRO	VALOR
E-C3	Sujeto 1	$V1_i$	92.15
		V2	44.82
		$V1_f$	85.96
		<b>Total</b>	<b>73.49</b>
	Sujeto 2	$V1_i$	96.77
		V2	3.27
		$V1_f$	90
		<b>Total</b>	<b>61.84</b>
	Sujeto 3	$V1_i$	87.09
		V2	77.96
		$V1_f$	91.52
		<b>Total</b>	<b>85.55</b>
E- FZ, CZ, C3, F4	Sujeto 1	$V1_i$	86.27
		V2	79.31
		$V1_f$	91.22
		<b>Total</b>	<b>85.54</b>
	Sujeto 2	$V1_i$	91.93
		V2	36.06
		$V1_f$	96
		<b>Total</b>	<b>73.41</b>
	Sujeto 3	$V1_i$	87.09
		V2	76.27
		$V1_f$	89.83
		<b>Total</b>	<b>84.44</b>

Tabla 4.1: Resultados de eficacia del clasificador obtenidos mediante la transformada de Fourier.




(a) RNA perceptrón multicapa (23-47-1), Electrodo C3.




(b) RNA perceptrón multicapa (92-185-1), Electrodo FZ, CZ, C3 Y F4.

Figura 4.25: Resultado de clasificación de actividades para el sujeto 1 con una RNA perceptrón multicapa, utilizando transformada de Fourier, a) Electrodo C3, b) Electrodo FZ, CZ, C3 Y F4.




(a) RNA perceptrón multicapa (23-47-1), Electrodo C3.




(b) RNA perceptrón multicapa (92-185-1), Electrodo FZ, CZ, C3 Y F4.

Figura 4.26: Resultado de clasificación de actividades para el sujeto 2 con una RNA perceptrón multicapa, utilizando transformada de Fourier, a) Electrodo C3, b) Electrodo FZ, CZ, C3 Y F4.



(a) RNA perceptrón multicapa (23-47-1), Electrodo C3.



(b) RNA perceptrón multicapa (92-185-1), Electrodo FZ, CZ, C3 Y F4.

Figura 4.27: Resultado de clasificación de actividades para el sujeto 3 con una RNA perceptrón multicapa, utilizando transformada de Fourier, a) Electrodo C3, b) Electrodo FZ, CZ, C3 Y F4.

Utilizando el método de la DWT para la extracción de características con las wavelets madre Db1, Db4, Db8 y Db16, todas de 7, 10 y 14 niveles y la RNA perceptrón multicapa como clasificador (con diferente cantidad de entradas y neuronas en la capa oculta), se obtuvieron los siguientes resultados por sujeto de estudio:

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E-C3	Sujeto 1	Db1	7	$V1_i$	90.51
				V2	25.93
				$V1_f$	89.86
				<b>Total</b>	<b>67.63</b>
			10	$V1_i$	100
				V2	99.55
				$V1_f$	99.56
				<b>Total</b>	<b>99.69</b>
			14	$V1_i$	100
		V2		99.97	
		$V1_f$		100	
		<b>Total</b>		<b>99.99</b>	
		Db4	7	$V1_i$	96.53
				V2	25.65
				$V1_f$	93.55
				<b>Total</b>	<b>70.64</b>
			10	$V1_i$	96.42
				V2	92.60
				$V1_f$	97.85
				<b>Total</b>	<b>95.57</b>
			14	$V1_i$	100
		V2		99.98	
		$V1_f$		100	
		<b>Total</b>		<b>99.99</b>	
Db8	7	$V1_i$	92.23		
		V2	23.83		
		$V1_f$	92.53		
		<b>Total</b>	<b>68.34</b>		
	10	$V1_i$	97.04		
		V2	96.99		
		$V1_f$	99.16		
		<b>Total</b>	<b>97.75</b>		
	14	$V1_i$	100		
V2		99.99			
$V1_f$		99.97			
<b>Total</b>		<b>99.99</b>			

Tabla 4.2: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 1 con las wavelets madre Db1, Db4 y Db8 de 7, 10 y 14 niveles, utilizando información del electrodo C3.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E-C3	Sujeto 1	Db16	7	$V1_i$	89.88
				V2	29.4
				$V1_f$	93.13
				<b>Total</b>	<b>69.78</b>
			10	$V1_i$	99.5
				V2	90.25
				$V1_f$	98.72
				<b>Total</b>	<b>95.99</b>
			14	$V1_i$	100
				V2	99.98
				$V1_f$	100
				<b>Total</b>	<b>99.99</b>

Tabla 4.3: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 1 con la wavelet madre Db16 de 7, 10 y 14 niveles, utilizando información del electrodo C3.




Figura 4.28: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente del electrodo C3.




Figura 4.29: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente del electrodo C3.




Figura 4.30: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente del electrodo C3.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E-C3	Sujeto 2	Db1	7	$V1_i$	91.03
				V2	33.97
				$V1_f$	90.65
				<b>Total</b>	<b>70.88</b>
			10	$V1_i$	99.2
				V2	93.41
				$V1_f$	99.96
				<b>Total</b>	<b>97.39</b>
			14	$V1_i$	100
				V2	99.97
				$V1_f$	100
				<b>Total</b>	<b>99.99</b>
		Db4	7	$V1_i$	93.84
				V2	25.54
				$V1_f$	93.44
				<b>Total</b>	<b>69.74</b>
			10	$V1_i$	99.58
				V2	98.26
				$V1_f$	100
				<b>Total</b>	<b>99.24</b>
			14	$V1_i$	99.98
				V2	99.96
				$V1_f$	99.98
				<b>Total</b>	<b>99.97</b>
Db8	7	$V1_i$	89.21		
		V2	34.88		
		$V1_f$	91.49		
		<b>Total</b>	<b>70.78</b>		
	10	$V1_i$	100		
		V2	96.2		
		$V1_f$	99.49		
		<b>Total</b>	<b>98.52</b>		
	14	$V1_i$	100		
		V2	99.99		
		$V1_f$	100		
		<b>Total</b>	<b>99.99</b>		

Tabla 4.4: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 2 con las wavelets madre Db1, Db4 y Db8 de 7, 10 y 14 niveles, utilizando información del electrodo C3.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E-C3	Sujeto 2	Db16	7	V1 <sub>i</sub>	90.93
				V2	32.33
				V1 <sub>f</sub>	90.5
				<b>Total</b>	<b>70.23</b>
			10	V1 <sub>i</sub>	99.6
				V2	93.35
				V1 <sub>f</sub>	99.48
				<b>Total</b>	<b>97.37</b>
			14	V1 <sub>i</sub>	99.99
				V2	100
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>99.99</b>

Tabla 4.5: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 2 con la wavelet madre Db16 de 7, 10 y 14 niveles, utilizando información del electrodo C3.




Figura 4.31: Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente del electrodo C3.

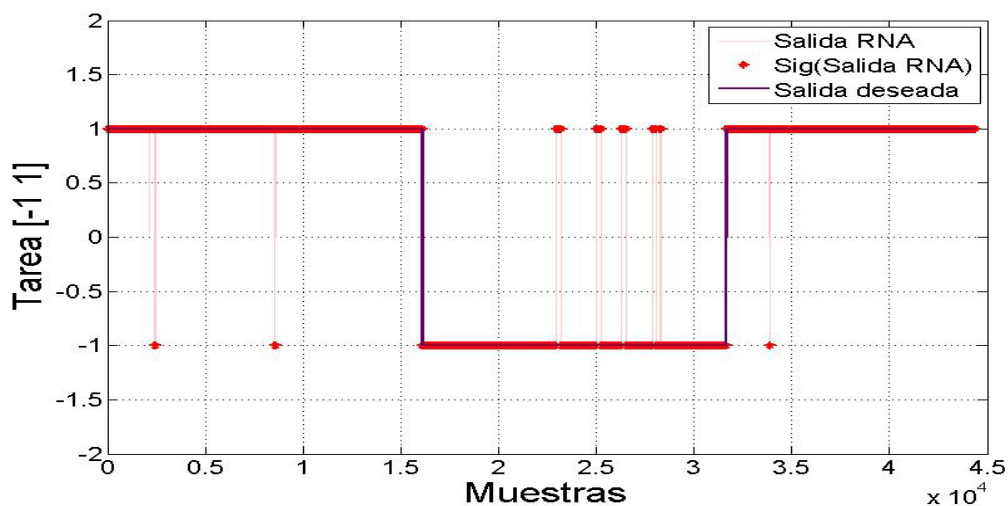


Figura 4.32: Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente del electrodo C3.




Figura 4.33: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente del electrodo C3.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E-C3	Sujeto 3	Db1	7	$V1_i$	94.88
				V2	38.96
				$V1_f$	86.76
				<b>Total</b>	<b>73.88</b>
			10	$V1_i$	100
				V2	96.97
				$V1_f$	99.99
				<b>Total</b>	<b>97.39</b>
			14	$V1_i$	100
				V2	99.96
				$V1_f$	100
				<b>Total</b>	<b>99.98</b>
		Db4	7	$V1_i$	94.63
				V2	43.1
				$V1_f$	86.48
				<b>Total</b>	<b>75.06</b>
			10	$V1_i$	99.19
				V2	98.73
				$V1_f$	100
				<b>Total</b>	<b>99.3</b>
			14	$V1_i$	100
				V2	100
				$V1_f$	100
				<b>Total</b>	<b>100</b>
Db8	7	$V1_i$	93.93		
		V2	42.63		
		$V1_f$	87.17		
		<b>Total</b>	<b>74.89</b>		
	10	$V1_i$	99.19		
		V2	97.34		
		$V1_f$	99.98		
		<b>Total</b>	<b>98.84</b>		
	14	$V1_i$	100		
		V2	100		
		$V1_f$	100		
		<b>Total</b>	<b>100</b>		

Tabla 4.6: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 3 con las wavelets madre Db1, Db4 y Db8 de 7, 10 y 14 niveles, utilizando información del electrodo C3.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E-C3	Sujeto 3	Db16	7	$V1_i$	94.87
				V2	42.72
				$V1_f$	86.11
				<b>Total</b>	<b>74.89</b>
			10	$V1_i$	100
				V2	97.22
				$V1_f$	99.15
				<b>Total</b>	<b>98.81</b>
			14	$V1_i$	100
				V2	99.98
				$V1_f$	100
				<b>Total</b>	<b>99.99</b>

Tabla 4.7: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 3 con la wavelet madre Db16 de 7, 10 y 14 niveles, utilizando información del electrodo C3.




Figura 4.34: Resultado de la clasificación de actividades para el sujeto 3, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente del electrodo C3.

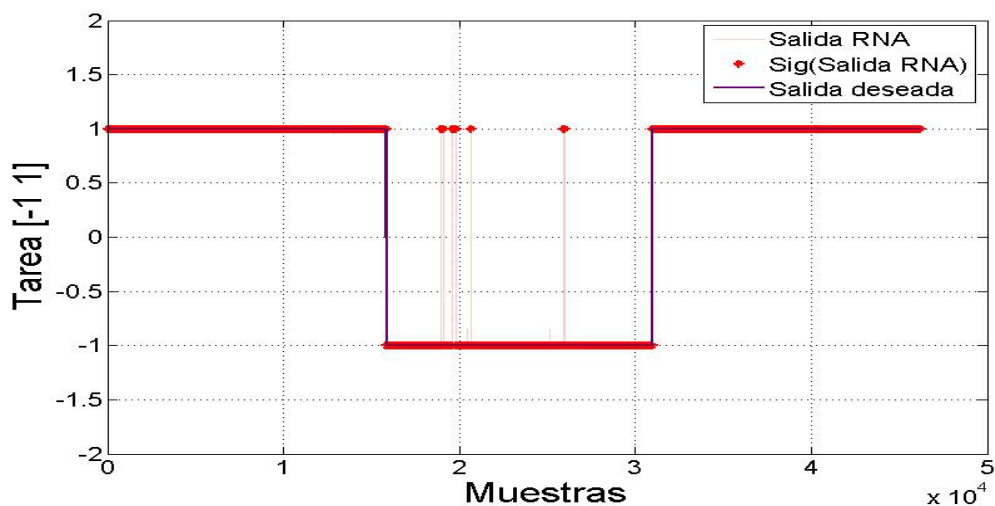


Figura 4.35: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente del electrodo C3.




Figura 4.36: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente del electrodo C3.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E- FZ, CZ, C3, F4	Sujeto 1	Db1	7	V1 <sub>i</sub>	94.11
				V2	21.72
				V1 <sub>f</sub>	92.92
				<b>Total</b>	<b>68.31</b>
			10	V1 <sub>i</sub>	100
				V2	98.03
				V1 <sub>f</sub>	99.78
				<b>Total</b>	<b>99.23</b>
			14	V1 <sub>i</sub>	100
		V2		99.97	
		V1 <sub>f</sub>		100	
		<b>Total</b>		<b>99.99</b>	
		Db4	7	V1 <sub>i</sub>	89.86
				V2	30.90
				V1 <sub>f</sub>	90.38
				<b>Total</b>	<b>69.36</b>
			10	V1 <sub>i</sub>	100
				V2	99.98
				V1 <sub>f</sub>	99.58
				<b>Total</b>	<b>99.85</b>
			14	V1 <sub>i</sub>	100
		V2		99.99	
		V1 <sub>f</sub>		99.99	
		<b>Total</b>		<b>99.99</b>	
Db8	7	V1 <sub>i</sub>	89.93		
		V2	28		
		V1 <sub>f</sub>	91.15		
		<b>Total</b>	<b>68.63</b>		
	10	V1 <sub>i</sub>	98.02		
		V2	94.41		
		V1 <sub>f</sub>	99.99		
		<b>Total</b>	<b>97.43</b>		
	14	V1 <sub>i</sub>	100		
V2		99.98			
V1 <sub>f</sub>		100			
<b>Total</b>		<b>99.99</b>			

Tabla 4.8: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 1 con las wavelets madre Db1, Db4 y Db8 de 7, 10 y 14 niveles, utilizando información de los electrodos FZ, CZ, C3 Y F4.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E- FZ, CZ, C3, F4	Sujeto 1	Db16	7	V1 <sub>i</sub>	91.01
				V2	24.08
				V1 <sub>f</sub>	92.28
				<b>Total</b>	<b>67.97</b>
			10	V1 <sub>i</sub>	100
				V2	93.14
				V1 <sub>f</sub>	99.38
				<b>Total</b>	<b>97.38</b>
			14	V1 <sub>i</sub>	100
				V2	99.13
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>99.69</b>

Tabla 4.9: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 1 con la wavelet madre Db16 de 7, 10 y 14 niveles, utilizando información de los electrodos FZ, CZ, C3 y F4.




Figura 4.37: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.




Figura 4.38: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.




Figura 4.39: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E- FZ, CZ, C3, F4	Sujeto 2	Db1	7	V1 <sub>i</sub>	87.99
				V2	35.63
				V1 <sub>f</sub>	88.46
				<b>Total</b>	<b>69.74</b>
			10	V1 <sub>i</sub>	100
				V2	96.70
				V1 <sub>f</sub>	97.98
				<b>Total</b>	<b>98.26</b>
			14	V1 <sub>i</sub>	100
		V2		87.11	
		V1 <sub>f</sub>		99.99	
		<b>Total</b>		<b>95.47</b>	
		Db4	7	V1 <sub>i</sub>	95.62
				V2	21.34
				V1 <sub>f</sub>	91.33
				<b>Total</b>	<b>68.31</b>
			10	V1 <sub>i</sub>	97.60
				V2	90.89
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>95.93</b>
			14	V1 <sub>i</sub>	100
				V2	99.99
				V1 <sub>f</sub>	99.98
				<b>Total</b>	<b>99.99</b>
Db8	7	V1 <sub>i</sub>	99.18		
		V2	14.55		
		V1 <sub>f</sub>	95.96		
		<b>Total</b>	<b>68.54</b>		
	10	V1 <sub>i</sub>	99.98		
		V2	97.98		
		V1 <sub>f</sub>	100		
		<b>Total</b>	<b>99.28</b>		
	14	V1 <sub>i</sub>	100		
		V2	99.91		
		V1 <sub>f</sub>	100		
		<b>Total</b>	<b>99.96</b>		

Tabla 4.10: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 2 con las wavelets madre Db1, Db4 y Db8 de 7, 10 y 14 niveles, utilizando información de los electrodos FZ, CZ, C3 y F4.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E- FZ, CZ, C3, F4	Sujeto 2	Db16	7	V1 <sub>i</sub>	94.32
				V2	32.55
				V1 <sub>f</sub>	91.62
				<b>Total</b>	<b>71.85</b>
			10	V1 <sub>i</sub>	100
				V2	98.35
				V1 <sub>f</sub>	99.96
				<b>Total</b>	<b>99.40</b>
			14	V1 <sub>i</sub>	100
				V2	100
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>100</b>

Tabla 4.11: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 2 con la wavelet madre Db16 de 7, 10 y 14 niveles, utilizando información de los electrodos FZ, CZ, C3 y F4.




Figura 4.40: Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.




Figura 4.41: Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.




Figura 4.42: Resultado de la clasificación de actividades para el sujeto 2, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E- FZ, CZ, C3, F4	Sujeto 3	Db1	7	V1 <sub>i</sub>	92.86
				V2	28.69
				V1 <sub>f</sub>	90.27
				<b>Total</b>	<b>70.97</b>
			10	V1 <sub>i</sub>	100
				V2	95.17
				V1 <sub>f</sub>	99.57
				<b>Total</b>	<b>98.27</b>
			14	V1 <sub>i</sub>	99.98
				V2	99.98
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>99.99</b>
		Db4	7	V1 <sub>i</sub>	91.49
				V2	32.72
				V1 <sub>f</sub>	89.81
				<b>Total</b>	<b>71.67</b>
			10	V1 <sub>i</sub>	99.99
				V2	96.60
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>98.88</b>
			14	V1 <sub>i</sub>	99.99
				V2	99.99
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>99.99</b>
Db8	7	V1 <sub>i</sub>	89.98		
		V2	34.57		
		V1 <sub>f</sub>	86.48		
		<b>Total</b>	<b>70.67</b>		
	10	V1 <sub>i</sub>	99.99		
		V2	98.30		
		V1 <sub>f</sub>	97.94		
		<b>Total</b>	<b>98.76</b>		
	14	V1 <sub>i</sub>	99.99		
		V2	99.97		
		V1 <sub>f</sub>	99.97		
		<b>Total</b>	<b>99.98</b>		

Tabla 4.12: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 3 con las wavelets madre Db1, Db4 y Db8 de 7, 10 y 14 niveles, utilizando información de los electrodos FZ, CZ, C3 y F4.

ELECTRODO(S)	SUJETO	TIPO DE DWT	NIVELES	ACTIVIDAD	EFICACIA
E- FZ, CZ, C3, F4	Sujeto3	Db16	7	V1 <sub>i</sub>	88.32
				V2	43.13
				V1 <sub>f</sub>	86.56
				<b>Total</b>	<b>72.93</b>
			10	V1 <sub>i</sub>	99.99
				V2	93.43
				V1 <sub>f</sub>	99.94
				<b>Total</b>	<b>97.82</b>
			14	V1 <sub>i</sub>	100
				V2	99.98
				V1 <sub>f</sub>	100
				<b>Total</b>	<b>99.99</b>

Tabla 4.13: Resultados de eficacia del clasificador obtenidos mediante la DWT para el sujeto 3 con la wavelet madre Db16 de 7, 10 y 14 niveles, utilizando información de los electrodos FZ, CZ, C3 y F4.

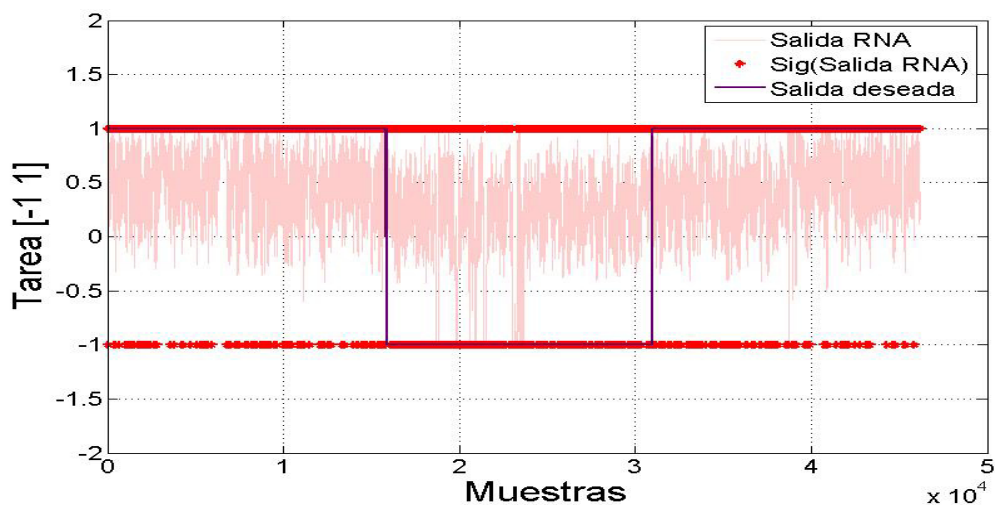


Figura 4.43: Resultado de la clasificación de actividades para el sujeto 3, con una RNA perceptrón multicapa (7-15-1), DWT Db1 de 7 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.




Figura 4.44: Resultado de la clasificación de actividades para el sujeto 3, con una RNA perceptrón multicapa (10-21-1), DWT Db1 de 10 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.




Figura 4.45: Resultado de la clasificación de actividades para el sujeto 1, con una RNA perceptrón multicapa (14-29-1), DWT Db1 de 14 niveles, utilizando la señal proveniente de los electrodos FZ, CZ, C3 y F4.

# Capítulo 5

## Conclusiones y trabajo a futuro

### 5.1. Conclusiones

Las principales contribuciones de esta investigación fueron las siguientes: se logró obtener información acerca de ciertos patrones de conectividad cerebral, observar que son estables y caracterizables y por ende permiten obtener resultados significativos en la clasificación de actividades motrices utilizando información de más áreas de la corteza cerebral, respecto a investigaciones que sólo utilizan información de un solo electrodo para la clasificación. Con los datos obtenidos de estas regiones se pudo realizar una comparación de resultados con la respuesta de clasificación cuando solo se toma en cuenta la información de un sólo electrodo, el cual es seleccionado porque se sabe de reportes previamente reportados en la literatura científica, en donde se indica que la región del electrodo C3 está relacionada con la motricidad. El estudio de coherencia y conectividad muestra que, los electrodos FZ, CZ, F4 y C3 (ver Figura 5.1) están fuertemente conectados durante las actividades motrices de los experimentos presentados en este trabajo. Lo que permite estimar en qué regiones del cerebro hay más dinámica representativa de las tareas motrices.




Figura 5.1: Localización espacial de los electrodos FZ, CZ, C3 y F4 seleccionados por su dinámica de conectividad .

Teniendo las características espaciales se analizaron dos tipos de métodos para la extracción de características frecuenciales de la señal. Uno de ellos fue la transformada de Fourier en cuyos resultados se pudo observar que para ambos casos (señal de los electrodos característicos, y señal del electrodo C3). El otro método de extracción de características frecuenciales fue el de la DWT. Para este fin se probaron 4 funciones madre: Db1, Db2, Db4 y Db8, con distintos niveles: 7, 10 y 14. La finalidad de probar diferentes funciones fue ver el comportamiento que presentaba el clasificador y el tiempo de ejecución, para tomar una decisión costo beneficio. Los resultados fueron un tanto deficientes en comparación con los obtenidos con la Transformada *wavelet*. Además de que la RNA al introducirle como entrada lo proveniente de la salida de la transformada de Fourier de la señal de los 4 electrodos consume un mayor tiempo de procesamiento. El tiempo de procesamiento de la RNA al tener como entrada lo proveniente de la salida de la DWT fue menor que con la transformada de Fourier, y los resultados obtenidos del clasificador marcaron una diferencia considerable. El estudio se realizó con una cantidad de sujetos de estudio baja, lo cual los resultados solo nos muestran una aproximación de lo que se deseaba obtener.

## 5.2. Trabajo a Futuro

Algunos puntos que son importantes mejorar y añadir son los siguientes:

- Realizar el protocolo experimental más controlado.

- Tener datos de un mayor número de sujetos de estudio.
- Utilizar la información obtenida para aplicarlo a la metodología seleccionada y poder obtener datos cinemáticos para poder aplicarlo en exoesqueletos.
- Probar con distintos métodos de clasificación y distintas wavelets madre.
- Aplicar a otros posibles casos de estudio no solo de miembros inferiores si no que se pudiera aplicar a miembros superiores.

# Nomenclatura

---

<b>EEG</b>	Electroencefalográfica.
<b>EOG</b>	Electrooculográfica.
<b>ECG</b>	Electrocardiográfica.
<b>BCI</b>	<i>Brain Computer Interface</i> (Interfaz Cerebro Computadora).
<b>V1</b>	Velocidad 1.
<b>V2</b>	Velocidad 2.
<b>T1</b>	Transición entre el cambio de <i>V1</i> a <i>V2</i> .
<b>T2</b>	Transición entre el cambio de <i>V2</i> a <i>V1</i> .
<b>DWT</b>	<i>Discrete wavelet transform</i> (Transformada wavelet discreta).
<b>RNA</b>	Red neuronal artificial.
<b>CWT</b>	<i>Continuous wavelet transform</i> (Transformada wavelet continua).
<b>Db1</b>	Daubechies 1.
<b>Db4</b>	Daubechies 4.
<b>Db8</b>	Daubechies 8.
<b>Db16</b>	Daubechies 16.
<b>MSV</b>	Maquina de soporte vectorial.
<b>PCA</b>	<i>Principal Component Analysis</i> (Análisis de componentes principales).

# Bibliografía

- [1] Chan M., Zoellick R. B., INFORME MUNDIAL SOBRE LA DISCAPACIDAD, *Organización Mundial de la Salud*, pp. 5-8, 2011.
- [2] Allen B., Rojas R., ENCUESTA NACIONAL DE SALUD Y NUTRICIÓN, *Instituto nacional de salud pública*, pp. 38-41, 2012.
- [3] Wolpaw J. R., BRAIN COMPUTER INTERFACE RESEARCH COMES OF AGE: TRADITIONAL ASSUMPTIONS MEET EMERGING REALITIES, *Journal of motor behavior* 42, pp 351-353, 2010.
- [4] Mussa-Ivaldi F. A., Casadio M., and Ranganathan R., THE BODY-MACHINE INTERFACE: A PATHWAY FOR REHABILITATION AND ASSISTANCE IN PEOPLE WITH MOVEMENT DISORDERS, *Expert review of medical devices* 10, pp. 145-147, 2013.
- [5] Birbaumer N., BREAKING THE SILENCE: BRAIN-COMPUTER INTERFACES (BCI) FOR COMMUNICATION AND MOTOR CONTROL, *Psychophysiology* 43, pp. 517-532, 2006.
- [6] Wu B., Wang Y., Chen W. and Zheng X., TIME-FREQUENCY OPTIMIZED SPATIAL PATTERNS FOR MOVEMENT-RELATED EEG DECODING, *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on, Cancun*, pp. 84-87, 2011.
- [7] Marquez A. P. and Muñoz G. R., ANALYSIS AND CLASSIFICATION OF ELECTROENCEPHALOGRAPHIC SIGNALS (EEG) TO IDENTIFY ARM MOVEMENTS, *10th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*, pp. 138-143, 2013.
- [8] Blokland Y., Spyrou L., Thijssen D., Eijsvogels T., Colier W., Floor-Westerdijk M., Vlek R., Bruhn J., Farquhar J., COMBINED EEG-FNIRS DECODING OF MOTOR ATTEMPT AND IMAGERY FOR

- BRAIN SWITCH CONTROL: AN OFFLINE STUDY IN PATIENTS WITH TETRAPLEGIA, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22, 2, pp. 222-229, 2014.
- [9] Robinson N. and Vinod A. P., BI-DIRECTIONAL IMAGINED HAND MOVEMENT CLASSIFICATION USING LOW COST EEG-BASED BCI, *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 3134-3139, 2015.
- [10] Shiman F, Irastorza-Landa N., Sarasola-Sanz A., SpÄ¼ler M., Birbaumer N. and Ramos-Murguialday A., TOWARDS DECODING OF FUNCTIONAL MOVEMENTS FROM THE SAME LIMB USING EEG, *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Milan*, pp. 1922-1925, 2015.
- [11] Nunez P, Srinivasan R., Westdorp A., Wijesinghe R., Tucker D., Silberstein R., Cadusch P., EEG COHERENCY I: STATISTICS, REFERENCE ELECTRODE, VOLUME CONDUCTION, LAPLACIANS, CORTICAL IMAGING, AND INTERPRETATION AT MULTIPLE SCALES, *Electroencephalography and clinical Neurophysiology*, pp. 499-515, 1997.
- [12] Chung, F. R. K., SPECTRAL GRAPH THEORY, *American Mathematical Society, Rhode Island, USA*, 2009
- [13] Diestel R., GRAPH THEORY, SPRINGER-VERLAG, NEW YORK, ELECTRONIC EDITION, 2005.
- [14] Proakis JG., Manolakis DG., DIGITAL SIGNAL PROCESSING, THIRD EDITION, PRENTICE-HALL, NEW JERSEY, 1996.
- [15] Muller K. R., Anderson C. W. and Birch G. E., LINEAR AND NONLINEAR METHODS FOR BRAIN-COMPUTER INTERFACES, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, pp. 165-9, 2003.
- [16] Bogess A. and Narcowich F. J., A FIRST COURSE IN WAVELETS WITH FOURIER ANALYSIS, PRENTICE-HALL, UPPER SADDLE RIVER, NJ, 2001.
- [17] Vetterli M., Kovačević J., WAVELETS AND SUBBAND CODING, PRENTICE-HALL, NEW JERSEY, 1995.

- [18] Vetterli M., Kovačević J., TRATAMIENTO DIGITAL DE SEÑALES, CUARTA EDICIÓN, PEARSON-PRENTICE-HALL, MADRID, 2007.
- [19] Übeyli E. D., COMBINED NEURAL NETWORK MODEL EMPLOYING WAVELET COEFFICIENTS FOR EEG SIGNALS CLASSIFICATION, *ELSEVIER Journal*, pp. 297-308, 2008.
- [20] Haykin S.O., NEURAL NETWORKS AND LEARNING MACHINES. PEARSON EDUCATION, 2011.
- [21] Vidal C., Malassidis E., Garc a. J. M., Mart n L., Robles M., Millet J., EL AN LISIS DE COMPONENTES PRINCIPALES COMO M TODOS DE CLASIFICACI N Y VISUALIZACI N DE TUMORES DE PARTES BLANDAS, *IX Congreso Nacional de Inform tica M dica*, pp. 213-215, 2002.
- [22] Ponce P., INTELIGENCIA ARTIFICIAL CON APLICACIONES A LA INGENIER A, 1ER. EDICI N, ALFAOMEGA, M XICO, 2010.
- [23] Mart nez-Mata A. O., AN LISIS DE LA SE NALIZACI N ELECTROENCEFALOGR FICA (EEG) Y ELECTROMIOGR FICA (EMG) DE LA LOCOMOCI N HUMANA, *Tesis de Maestr a, Universidad Aut noma de Nuevo Le n*, 2016.
- [24] Mercado-Cerda L. A., CONTROL OF A TIBIO-FEMORAL VIRTUAL JOINT BY MEANS OF A HYBRID EEG-EMG SCHEME, *Tesis de Maestr a, Universidad Aut noma de Nuevo Le n*, 2014.

# **Apéndice A**

## **Productividad académica**

Estancia de investigación en la División de Electrónica y Computación del CUCEI de la Universidad de Guadalajara, la cual se llevo a cabo del día 5 al 16 de septiembre del 2016. El cartel con título “Análisis de la Señal EEG para Identificar la Actividad Motriz de Miembros Inferiores”, fue aceptado para presentarlo en el VIII Congreso Nacional de Tecnología Aplicada a Ciencias de la Salud llevado a cabo en la facultad de medicina de la Universidad Autónoma de Nuevo León del 15 al 17 de junio del 2017, resultando como producto de investigación de la tesis.



Dra. Griselda Quiroz Compeán  
Profesora de la Facultad de Ingeniería Mecánica y Eléctrica  
Líder del Cuerpo Académico Tecnología e Innovación Mecatrónica  
Universidad Autónoma de Nuevo León  
Presente.-

Primero, permítame ofrecerle un sincero saludo. Por este medio deseo agradecer su visita a la División de Electrónica y Computación del CUCEI-UDG. Así como también al Dr. Miguel Ángel Platas Garza y a los alumnos del Posgrado en Ingeniería Eléctrica de la FIME-UANL y participantes del proyecto: M. C. Luis Antonio Mercado Cerda, Ing. Jorge Abraham Villanueva Leal e Ing. Jazmín Alejandra Martínez Alvarado. Dicha estancia de investigación se realizó del 5 al 16 de septiembre del año en curso. Lo anterior con el fin de realizar las actividades planeadas para alcanzar los objetivos planteados en el proyecto "*Diseño de interfaces cerebro computadora para el control de tecnologías de asistencia de miembros inferiores*", de la red "Biosistemas y biomecatrónica", formada por los cuerpos académicos "Biosistemas" (UDG-CA-789) y "Tecnología e Innovación Mecatrónica" (UANL-CA-272) y el grupo de investigación "Brain Machine Interface Lab", de la Universidad Miguel Hernández, en España.

Las actividades específicas que se realizaron durante la reunión de los cuerpos académicos fueron las siguientes:

1. Discusión de las condiciones del protocolo experimental.
2. Discusión del procesamiento que se realiza a las señales.
3. Realización del análisis de conectividad.
4. Discusión y establecimiento de una aproximación al modelo multivariable.

Reitero agradecimientos por atender a nuestra invitación, con el fin de alcanzar los resultados planteados en el proyecto de cuerpos académicos. Saludos cordiales.

ATENTAMENTE  
"Piensa y Trabaja"  
Guadalajara, Jalisco, a 18 de octubre del 2016

Dr. Carlos Alberto López Franco  
Jefe de Departamento de Ciencias Computacionales  
CUCEI-UDG

CUCEI - DIVEC  
  
DEPARTAMENTO DE  
CIENCIAS COMPUTACIONALES

# ANÁLISIS DE LA SEÑAL EEG PARA IDENTIFICAR LA ACTIVIDAD MOTRIZ EN MIEMBROS INFERIORES

J. Martínez-Alvarado<sup>a</sup>, M. Platas-Garza<sup>a</sup>, A. Espinoza-Valdez<sup>b</sup>, R. Salido-Ruiz<sup>b</sup>, G. Quiroz<sup>a</sup>

<sup>a</sup>Universidad Autónoma de Nuevo León, FIME, <sup>b</sup>Universidad de Guadalajara

<sup>a</sup>Av. Universidad S/N, Ciudad Universitaria, C.P. 66451, San Nicolás de los Garza, Nuevo León, México. Tel: +52 81 83294020 ext. 5773

<sup>b</sup>Calzada Olímpica No. 740, Ciudad Universitaria, C.P. 44840, Guadalajara, Jal, México. Tel. +52 33 3619 6913

[jazminmartinez2@hotmail.com](mailto:jazminmartinez2@hotmail.com), [miguel.platas@gmail.com](mailto:miguel.platas@gmail.com), [aurora.espinoza@academicos.udg.mx](mailto:aurora.espinoza@academicos.udg.mx),

[drsalidoruiz@gmail.com](mailto:drsalidoruiz@gmail.com), [griselda.quirozcm@uanl.edu.mx](mailto:griselda.quirozcm@uanl.edu.mx)


## Resumen

Un porcentaje elevado de individuos a nivel mundial presentan algún tipo de discapacidad motriz que afecta su calidad de vida. Por esta razón el objetivo principal de este trabajo es implementar un método de clasificación multivariable que relacione variables motrices (caminata a dos velocidades diferentes) con las características espaciales de la señal electroencefalográfica (EEG) adquiridas por medio del estudio de coherencia y conectividad y las características frecuenciales de la señal EEG adquiridas mediante la transformada de Fourier y la transformada wavelet.

## Introducción

Según la encuesta mundial de salud, el 15.6% de personas mayores de 15 años viven con una discapacidad, y de éstas el 2.2% tiene dificultades relacionadas con afecciones tales como la tetraplejía, depresión grave o ceguera [1]. La intención de comprender la actividad neural de los humanos no es algo reciente. Uno de los pioneros en la adquisición de señales EEG fue el científico alemán Hans Berger, quien en 1929, especulaba acerca de la posibilidad de leer pensamientos a partir de trazos de EEG utilizando sofisticados análisis matemáticos [2]. En este trabajo se pretende identificar la actividad motriz de miembros inferiores del cuerpo humano mediante el análisis de la señal electroencefalográfica (EEG).

Fig. 1. Sujeto de estudio utilizando el sistema de adquisición de señales B-Alert X-10 © de Advanced Brain Monitoring.



## Clasificación

### Red neuronal artificial (RNA) perceptrón multicapa [8].




Fig. 6. Esquema básico de una RNA.

Configuración de la RNA según el método de extracción de características frecuenciales:

- Transformada de Fourier: (92-185-1)
- Transformada wavelet (los 4 tipos):  
7 niveles (7-15-1)  
10 niveles (10-21-1)  
14 niveles (14-28-1)

## Resultados

Electrodos	Sujeto de estudio	Actividad	Eficacia
CZ,FZ,F4,C3	Sujeto1	V1	86.27
		V2	79.31
		V3	91.22
		Total	85.54




Fig. 7. Grafos de conectividad de la banda alfa en las distintas actividades motrices. V1(velocidad a 4 mph), V2(velocidad a 6mph).

Tabla 1. Resultado de eficacia del clasificador con la TF.

Electrodos	Sujeto de estudio	Niveles	Eficacia Total
CZ,FZ,F4,C3	Sujeto 1	7	67.63
		10	99.69
		14	99.99

Tabla 2. Resultado de eficacia del clasificador con la TW Db1.




Fig. 8. Respuesta del clasificador: a) Respuesta del clasificador con TF. con TW, b) Respuesta del clasificador Db1 de 10 niveles.

## Conclusiones

Se logró obtener información acerca de ciertos patrones de conectividad cerebral, se observó que son estables y caracterizables y nos permiten obtener resultados significativos en la clasificación de actividades motrices utilizando información de más áreas de la corteza cerebral. Los resultados de la clasificación de actividades obtenidos realizando la extracción de características frecuenciales mediante la transformada wavelet son mejores en comparación a los obtenidos al utilizar la transformada de Fourier.

## Referencias

1. Chan M., *et al.*, "Informe mundial sobre la discapacidad", Organización Mundial de la Salud, 2011, pp. 5-8.
2. Birbaumer N., "Breaking the silence: brain-computer interfaces (BCI) for communication and motor control", *psychophysiology* 43, 2006, pp. 517-532.
3. Nunez P., *et al.*, "EEG coherency I: statistics, reference electrode, volume Conduction, Laplacians, cortical imaging, and interpretation at multiple scales", *electroencephalography and clinical neurophysiology*, pp. 499-515, 1997.
4. Diestel R., "Graph theory", Springer-Verlag, New York, electronic edition, 2005.
5. Chung F. R. K., "Spectral graph theory", American mathematical society, Rhode Island, USA, 2009.
6. Vetterli M., *et al.*, "Tratamiento digital de señales", cuarta edición, Pearson Prentice-hall, Madrid, 2007.
7. Beyli E. D., "Combined neural network model employing wavelet coefficients for EEG signals classification" *Elsevier journal*, pp. 297-308, 2008.
8. Ponce P., "Inteligencia artificial con aplicaciones a la ingeniería", 1er. Edición, Alfaomega, México, 2010.

Los autores son miembros de la red de investigación "Biosistemas y Biomecatrónica" y agradecen a PRODEP-SEP por su apoyo financiero (103.5/15/14156). Jazmín Martínez agradece a CONACYT el otorgamiento de la beca número 404024.

## Objetivos

Realizar el procesamiento espacial y frecuencial multivariable que permita relacionar la señal EEG a una actividad motriz de los miembros inferiores.

## Extracción de características espaciales

### Coherencia de una señal [3].

$$\gamma_{ij}(f) = \frac{|G_{ij}(f)|^2}{G_{ij}(f)G_{jj}(f)}$$

$$G = 2/f_s \sum_{f=1}^{f_s} \gamma_{ij}(f)$$


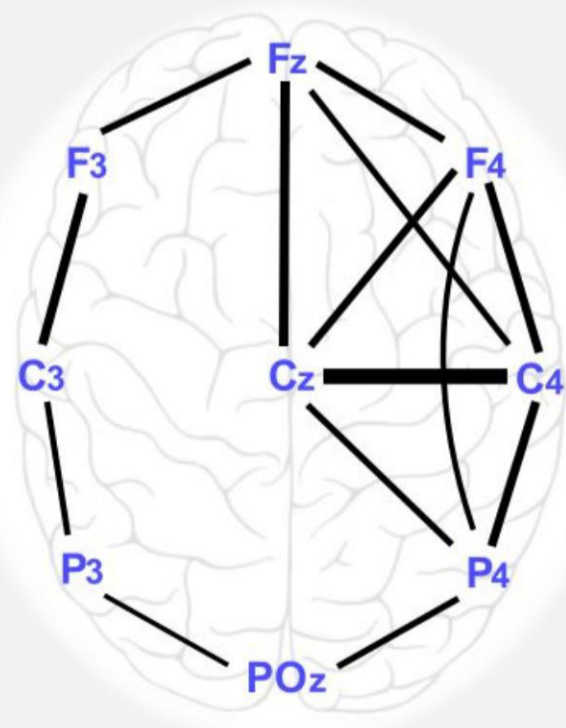


Fig. 2. Proceso de partición de la sección V1 para la obtención de las matrices de coherencia.

### Teoría de grafos y matriz Laplaciana [4,5].

Fig. 3. Grafo representativo de una matriz de coherencia.



$$L(G) = D - A(G)$$

Observando la dinámica de conectividad de los electrodos, se concluyó que los electrodos C3, CZ, FZ Y F4 son los que mayor información brindan y son los seleccionados para realizar la clasificación multivariable.

## Extracción de características frecuenciales

### Transformada de Fourier [6].

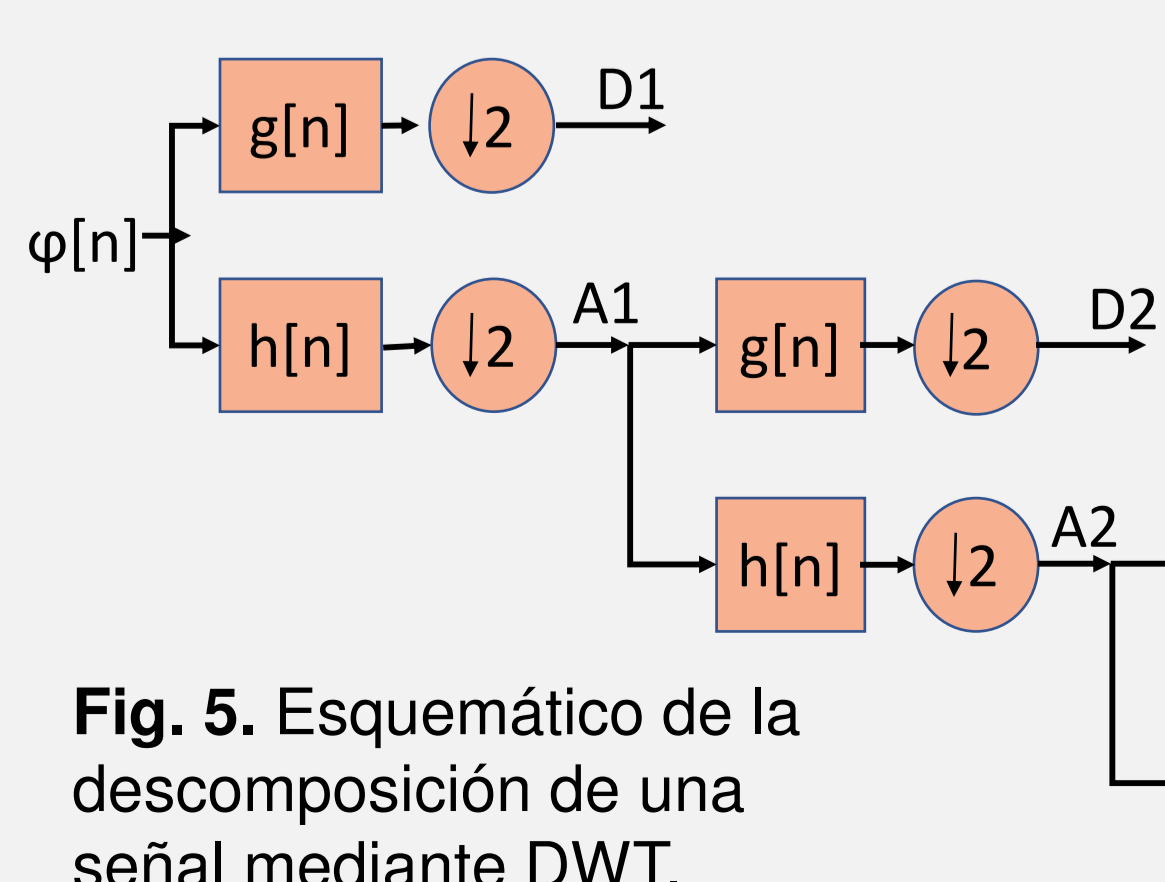


Fig. 5. Esquemático de la descomposición de una señal mediante DWT.




Fig. 4. Espectro de frecuencias.

### Transformada wavelet (TW) [7].

- Db1 (7,10,14 niveles)
- Db4 (7,10,14 niveles)
- Db8 (7,10,14 niveles)
- Db16 (7,10,14 niveles)