



**Universidad Autónoma de Querétaro**

Facultad de Ingeniería

Campus Aeropuerto



**Metodología Basada en los Parámetros de Hjorths Para la  
Detección del Deterioro Cognitivo Leve**

**TESIS**

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

**Presenta:**

Raymundo Vargas Parra

**Dirigida por:**

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Querétaro, Querétaro, Enero 2020



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



**“Metodología Basada en los Parámetros de Hjorths Para la Detección del Deterioro Cognitivo Leve”**

**Tesis**

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

**Presenta:**

Raymundo Vargas Parra

**Dirigido por:**

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Dr. Juan Pablo Amézquita Sánchez

Presidente

Dr. Carlos Andrés Pérez Ramírez

Secretario

Dr. Martín Valtierra Rodríguez

Vocal

Ing. Eduardo Martínez Segoviano

Suplente

Firma

Firma

Firma

Firma

Centro Universitario  
Querétaro, Qro.  
Enero 2020

## RESUMEN

El Deterioro Cognitivo Leve (DCL) es un padecimiento imperceptible entre la demencia y la enfermedad del Alzheimer. El DCL es caracterizado por la pérdida cognitiva de la memoria o pensamiento más allá de los cambios esperados por la edad. Los síntomas son imperceptibles, permitiendo que las personas con DCL continúen con su vida y actividades de manera normal. Para cuando se detecta este padecimiento, la enfermedad ya se encuentra evolucionada debido a que ya ha pasado mucho tiempo antes de su detección. Por lo tanto, un diagnóstico oportuno de DCL ayudaría a que los pacientes puedan recibir un tratamiento adecuado con el fin de reducir una posible conversión a Alzheimer y/o retrasar el progreso de la enfermedad.

Actualmente para hacer los estudios de detección de DCL, se utilizan estudios con electroencefalógrafos (EEGs) y megnetoencefalógrafos (MEGs), los cuales proporcionan las señales obtenidas del encéfalo. En este sentido, las investigaciones constan de hacer una relación de estas señales de personas sanas con las de personas con la enfermedad. Por lo tanto, en este trabajo de tesis se propone una técnica basada en la descomposición de la señal MEG en sus bandas características de frecuencias por medio de la Transformada Wavelet Discreta (TWD) y la aplicación de los Parámetros de Hjorths (PH) que exponen las propiedades o características de la señal con el fin de ser estas clasificadas por una red neuronal y así para entregar un diagnóstico de forma automática.

**Palabras Clave:** Deterioro Cognitivo Leve, Transformada Wavelet Discreta, Parámetros de Hjorths, ANOVA, Red Neuronal, Procesamiento de Bioseñales.

## DEDICATORIA

*Con un profundo amor dedico este trabajo de tesis a las personas que más amo en esta vida, primeramente a mi Dios por darme la capacidad, el aliento, la comprensión y su amor; a mi madre Estela Parra Valdés por su apoyo y amor incondicional, sus sacrificios, su motivación y su confianza; a mi padre José Raymundo Vargas Turán por su perseverancia, su educación, y su ejemplo.*

*Al igual hago una dedicatoria especial a un ser que me motivo y me inspiró a cursar esta carrera, a mi amado abuelo Raymundo Vargas Pérez (QEPD).*

## AGRADECIMIENTOS

Doy gracias a Dios porque reconozco que sin Él no hubiera podido llegar hasta este punto.

A mis padres José Raymundo Vargas Eurán y Estela Parra Valdés por su educación que me han brindado desde mi niñez y sus esfuerzos que han culminado en este logro.

A mi hermano Rogelio Vargas Parra por estar presente y al pendiente.

A mi novia Ivana Patricia Peñaloza Martínez por todo el apoyo y confianza que me ha depositado.

A mi asesor de tesis, al Dr. Juan Pablo Amézquita Sánchez, por su tiempo, su preocupación, sus enseñanzas y sus consejos.

A mis sinodales, al Dr. Carlos Andrés Pérez Ramírez, al Dr. Martín Valtierra Rodríguez y al Ing. Eduardo Martínez Segoviano, por sus enseñanzas, sus consejos y su paciencia.

A la Universidad Autónoma de Querétaro, mi Alma Mater, por los medios que proporcionó en mi formación.

A todos mis amigos que construyeron momentos y acompañaron en este proceso de aprendizaje.

A mis maestros que desde la niñez hasta ahora me han instruido y formado.

# ÍNDICE GENERAL

RESUMEN.....	III
DEDICATORIA.....	IV
AGRADECIMIENTOS.....	V
ÍNDICE GENERAL.....	VI
ÍNDICE DE FIGURAS.....	VIII
ÍNDICE DE TABLAS.....	X

## CAPÍTULO 1: Introducción

1.1. Introducción.....	1
1.2. Antecedentes.....	1
1.3. Justificación.....	3
1.4. Descripción del Problema.....	4
1.5. Hipótesis.....	5
1.6. Objetivos.....	5
1.6.1. Objetivo General.....	5
1.6.2. Objetivos Particulares.....	5
1.7. Planteamiento general.....	6

## CAPÍTULO 2: Fundamento teórico

2.1.Revisión de la literatura.....	9
2.2. Señales MEG.....	9
2.3. Procesamiento Digital de Señales.....	11
2.3.1. MATLAB.....	11
2.3.2. Transformada Wavelet Discreta.....	12
2.3.3. Parámetros de Hjorth.....	14
2.3.3.1. Actividad.....	15
2.3.3.2. Movilidad.....	15
2.3.3.3. Complejidad.....	15
2.3.4 ANOVA.....	16
2.3.5. Redes Neuronales.....	17

### **CAPÍTULO 3: Metodología**

3.1. Metodología.....	21
3.2. Material.....	22
3.3. Sistema de adquisición de las señales MEG.....	23
3.4. Procesamiento de la señal MEG.....	25

### **CAPÍTULO 4: Pruebas y resultados**

4.1. Puesta de Experimento.....	30
4.2. Resultados.....	31
4.3. Discusión de Resultados .....	42

### **CAPÍTULO 5: Conclusiones y perspectivas**

5.1 Conclusiones.....	46
5.2 Perspectivas.....	47

<b>Bibliografía.....</b>	<b>48</b>
--------------------------	-----------

<b>Anexos.....</b>	<b>51</b>
--------------------	-----------

## ÍNDICE DE FIGURAS

<b>Figura 1 1</b> Planteamiento general para el diagnóstico del DCL .....	6
<b>Figura 2.1</b> Sensor SQUID.....	10
<b>Figura 2.2</b> Composición de la ventana de MATLAB.....	12
<b>Figura 2.3</b> Árbol de descomposición de la Transformada Wavelet Discreta.....	13
<b>Figura 2.4</b> Representación de las funciones madre de la Transformada Wavelet...	14
<b>Figura 2.5</b> Distribución de datos para dos conjuntos .....	17
<b>Figura 2.6</b> Arquitectura de Perceptrón Multicapa.....	18
<b>Figura 3.1</b> Metodología propuesta.....	21
<b>Figura 3 2</b> Ubicación de los 148 sensores.....	23
<b>Figura 3.3.</b> Señal MEG (zona frontal): (a) persona sana y (b) persona con DCL ....	24
<b>Figura 3.4.</b> Señal Generada.....	25
<b>Figura 3.5.</b> Árbol de descomposición de la señal analizada.....	26
<b>Figura 3.6.</b> Descomposición de las 5 bandas de frecuencia, por medio de la Transformada Wavelet Discreta.....	27
<b>Figura 4.1.</b> Representación de la prueba de reconocimiento de las letras, donde los participantes en la primera fase memorizan las 5 letras “SMAQE”. Y en la segunda fase reconocen las letras .....	30
<b>Figura 4.2.</b> Bandas de Frecuencia de una (a) persona sana y una (b) persona con DCL .....	32
<b>Figura 4.3.</b> Distribución de datos estimada por medio de ANOVA para el sensor 120 banda Gamma del parámetro de Movilidad .....	33
<b>Figura 4.4.</b> Distribución de datos estimada por medio de ANOVA para el sensor 137 de la banda Gamma del parámetro de Movilidad .....	34
<b>Figura 4.5.</b> Distribución de datos estimada por medio de ANOVA para el sensor 119 de la banda Gamma del parámetro de Movilidad .....	34
<b>Figura 4.6.</b> Distribución de datos estimada por medio de ANOVA para el sensor 138 de la banda Gamma del parámetro de Movilidad .....	35
<b>Figura 4.7.</b> Distribución de datos estimada por medio de ANOVA para el sensor 115 de la banda Gamma del parámetro de Movilidad .....	35
<b>Figura 4.8.</b> Distribución de datos estimada por medio de ANOVA para el sensor 146 de la banda Delta del parámetro de Movilidad .....	36

<b>Figura 4.9.</b> Distribución de datos estimada por medio de ANOVA para el sensor 4 de la banda Beta del parámetro de Movilidad .....	36
<b>Figura 4.10.</b> Distribución de datos estimada por medio de ANOVA para el sensor 139 de la banda Gamma del parámetro de Movilidad .....	37
<b>Figura 4.11.</b> Distribución de datos estimada por medio de ANOVA para el sensor 114 de la banda Gamma del parámetro de Movilidad .....	37
<b>Figura 4.12.</b> Distribución de datos estimada por medio de ANOVA para el sensor 121 de la banda Gamma del parámetro de Movilidad .....	38
<b>Figura 4.13.</b> Distribución de datos estimada por medio de ANOVA para el sensor 102 de la banda Gamma del parámetro de Movilidad .....	38
<b>Figura 4.14.</b> Distribución de datos estimada por medio de ANOVA para el sensor 133 de la banda Gamma del parámetro de Movilidad .....	39
<b>Figura 4.15.</b> Distribución de datos estimada por medio de ANOVA para el sensor 2 de la banda Beta del parámetro de Movilidad .....	39
<b>Figura 4.16.</b> Distribución de datos estimada por medio de ANOVA para el sensor 101 de la banda Gamma del parámetro de Movilidad .....	40
<b>Figura 4.17.</b> Distribución de datos estimada por medio de ANOVA para el sensor 103 de la banda Gamma del parámetro de Movilidad .....	40
<b>Figura 4.18.</b> Estructura final de la red neuronal.....	42
<b>Figura 4.19.</b> Gráfica de la evolución del performance durante el entrenamiento de la red neuronal.....	43

## ÍNDICE DE TABLAS

<b>Tabla 3.1.</b> Información Clínica sobre los pacientes con DCL y sanos.....	23
<b>Tabla 3.2.</b> Resultados obtenidos de los parámetros de Hjorths aplicados a cada banda de frecuencia.....	28
<b>Tabla 4.1.</b> Valores de probabilidad obtenidos a través de ANOVA, así como media y desviación estándar de los diferentes conjuntos de datos.....	41
<b>Tabla 4.2.</b> Eficiencia de la metodología propuesta.....	44

Dirección General de Bibliotecas UAQ

# Capítulo 1

Introducción

Dirección General de Bibliotecas UAQ

## **1.1. Introducción**

A medida que el ser humano envejece, experimenta ciertos cambios cognitivos, los cuales pueden ir desde un nivel normal leve (conocido como deterioro cognitivo leve (DCL) o en inglés “Mild Cognitive Impairment (MCI)”) hasta un estado temprano de demencia conocido como Alzheimer. DCL es caracterizado por la pérdida cognitiva de la memoria o pensamiento más allá de los cambios esperados por la edad (Li et al. 2010). Aproximadamente, el 20% de la población por encima de los 60 años presenta un problema de DCL; sin embargo, los síntomas son imperceptibles, permitiendo que las personas con DCL continúen con su vida y actividades de manera normal. Trabajos recientes han mostrado que la pérdida cognitiva en personas con DCL puede llegar a ser reducida a tal punto que pueden llegar a regresar a la normalidad con el paso del tiempo; pero, anualmente el 15% de las personas con DCL progresan a Alzheimer (Pose & Manes 2010). Por lo tanto, un diagnóstico oportuno de DCL es de vital importancia, ya que los pacientes podrían recibir un tratamiento adecuado con el fin de reducir (a) una posible conversión a Alzheimer y (b) retrasar el progreso de la enfermedad.

## **1.2. Antecedentes**

Actualmente existe un amplio debate sobre cuáles son las herramientas más adecuadas para detectar el déficit de memoria por DCL, ya que aún no existe una prueba que permita detectar esta enfermedad con gran certeza. En este sentido, las pruebas de recuerdo diferido se utilizan ampliamente y un rendimiento pobre en éstas se asocian con altos riesgos de progresión a demencia (Li et al. 2010). Por otro lado, se ha estudiado la relación entre la resonancia magnética estructural y la enfermedad DCL (Pose & Manes 2010), en estas pruebas se observó un fenómeno llamado hipo-metabolismo en regiones temporales y parietales en pacientes con DCL, concluyendo que esta característica podría ser asociada a una tasa más elevada de progresión a demencia. Además, se observó en el estudio que las

personas con DCL, experimentan síntomas tales como apatía, agitación e irritabilidad con mayor frecuencia.

En la última década, diferentes métodos o metodologías basadas en técnicas neurofisiológicas, en particular electroencefalogramas (EEG) y magnetoencefalogramas (MEG), han sido propuestas internacionalmente para diagnosticar pacientes con DCL mostrando resultados prominentes en comparación a los previos métodos/pruebas mencionadas anteriormente (Amezquita-Sanchez et al. 2016). Estos métodos tienen la principal ventaja de medir la actividad eléctrica y magnética del cerebro generadas por las neuronas de la corteza cerebral eficientemente y no invasivamente sin la necesidad de una cirugía para implantar un sensor dentro del cerebro para medir las ondas del cerebro (Abaitua, 2012). En este sentido, Bruña et. al. (2012) presentaron una metodología basada en la entropía de las señales MEG para el diagnóstico de personas con DCL. Los autores observaron un decremento en los valores de entropía en pacientes con DCL en el área frontal del cerebro en comparación con personas sanas. Empleando esta variación en la entropía, los autores reportaron una eficacia del 65% distinguiendo personas con DCL de persona sanas. Poza y sus colaboradores (2012) desarrollaron una metodología basada en la Transformada Wavelet para el diagnóstico de personas con DCL empleando señales MEG. Los autores reportan una eficiencia del 68.9% para distinguir entre personas sanas y personas con DCL. Por otro lado, Timothy et al. (2017) recientemente desarrollaron una metodología basada en el análisis de recurrencia cruzada para el diagnóstico de personas con DCL empleando señales EEG. Los autores reportan una eficiencia del 70% para diagnosticar pacientes con DCL, cuando estos están en reposo y con los ojos cerrados.

A pesar de los resultados prometedores para el diagnóstico de personas con DCL empleando señales EEG o MEG, estas señales presentan características no estacionarias y poca eficiencia en los resultados obtenidos; por lo tanto, existe la necesidad de continuar investigando para desarrollar una metodología capaz de analizar este tipo de señales con el fin de poder diagnosticar personas con DCL de una forma temprana, automática y eficaz (Amezquita-Sanchez, et.al. 2016).

A nivel local, dentro de la Universidad Autónoma de Querétaro (UAQ), se han desarrollado varios trabajos/tesis enfocadas al diagnóstico de enfermedades de seres humanos. Por ejemplo, Vázquez, (2013) desarrolló una metodología basada en el procesamiento de imágenes obtenidas por una cámara termográfica con el fin de la detección temprana de pie diabético. Jiménez, (2015) segmentó de forma automáticamente imágenes provenientes de una cámara termográfica para la detección de ulceraciones en la planta de los pies de personas con pie diabético, Vega, (2016) desarrolló una metodología basada en el procesamiento de imágenes obtenidas a través de una cámara termográfica con el fin de la detección de cáncer de mama. Recientemente, Cruz (2018) desarrolló una metodología basada en la descomposición empírica de modos, fractales y redes neuronales para la clasificación automática del pensamiento (derecha, izquierda y reposo) usando señales EEG. Por otro lado, Vargas (2019) propuso una metodología basada en la descomposición empírica de modos, medidas no lineales y redes neuronales para la detección anticipada de un infarto. Piña (2019) combinó la dimensión fractal y lógica difusa para detectar anticipadamente un infarto hasta 1 hora antes. Carrasco (2019) diseñó y desarrolló un sistema de adquisición y procesamiento de señales cardiacas basado en el sistema LabVIEW y la transformada de Fourier. Finalmente, Ruiz (2019) combinó la transformada wavelet y los parámetros de Hjorth para realizar la clasificación de tres pensamientos imaginados (reposo, izquierda y derecha).

De acuerdo con las investigaciones realizadas en la UAQ, se observa que se está trabajando en diferentes métodos para el diagnóstico de enfermedades y clasificación de imaginación motora; sin embargo, en lo referido a DCL, no hay todavía trabajos que se enfoquen al análisis de señales MEG para el diagnóstico de DCL. Por lo tanto, esta tesis sentará las bases para el diagnóstico de personas con DCL.

### **1.3. Justificación**

Actualmente, no existe una cura o tratamiento para revertir el deterioro cognitivo en personas con DCL (Gutiérrez et al. 2016). Sin embargo, si esta enfermedad es diagnosticada de manera temprana o en su estado inicial, los pacientes podrían recibir un tratamiento adecuado con el fin de reducir (1) una posible conversión a Alzheimer y (2) retrasar el progreso de la enfermedad (Mazaheri et al. 2018).

Generalmente, DCL es determinado/identificado por (a) métodos tradicionales (la observación de terceros) y (b) métodos neurofisiológicos (interpretación de señales EEG y MEG), siendo estos últimos los que mejores resultados han presentado para determinar si una persona presenta DCL o no (Pose & Manes 2010); ya que, una persona con DCL presenta una (a) desconexión neuronal y (b) falta de sinapsis entre neuronas, características que son monitoreadas en las señales EEG y MEG, pero su correcta interpretación es una tarea muy complicada, ya que estas señales son de origen no estacionario (señales con características variantes), son de muy pequeña amplitud y están embebidas en una gran cantidad de ruido (Amezquita-Sanchez et al. 2016).

Por lo tanto, es necesario el desarrollo de una metodología basada en técnicas avanzadas de procesamiento de señales con el fin de estimar características dentro de las señales neurofisiológicas que permitan diagnosticar una persona con DCL, disminuyendo el tiempo en la detección de la enfermedad y así poder acceder a un tratamiento temprano.

### **1.4. Descripción del problema**

DCL es una enfermedad degenerativa que se caracteriza por la pérdida de la memoria, la cual genera un problema para el paciente en el no poder recordar ciertas tareas básicas, por lo que las personas cercanas/familiares son las que deben ayudar al paciente a realizar sus tareas básicas y en ciertos casos absorber los costos de los tratamientos para estas enfermedades, los cuales pueden ser

bastante elevados si la enfermedad es detectada en un estado avanzado (Gutiérrez et al. 2016).

Por estas razones, es de alta relevancia un diagnóstico oportuno de la enfermedad, ya que impactaría en la dependencia económica y de salud de la persona con DCL. Por lo tanto, un sistema capaz de diagnosticar una persona con DCL de manera eficiente y oportuna es indispensable, permitiéndole al paciente tener una mejor calidad de vida.

## **1.5. Hipótesis**

Mediante la combinación de la transformada wavelet, algoritmos de medición no lineal y con una red neuronal, es posible desarrollar una metodología que permita hacer el diagnóstico de personas con deterioro cognitivo leve.

## **1.6. Objetivos**

### **Objetivo General:**

Proponer y desarrollar una metodología basada la transformada wavelet, los parámetros de Hjorths (actividad, movilidad y complejidad) y redes neuronales para el diagnóstico de personas con DCL de forma automática.

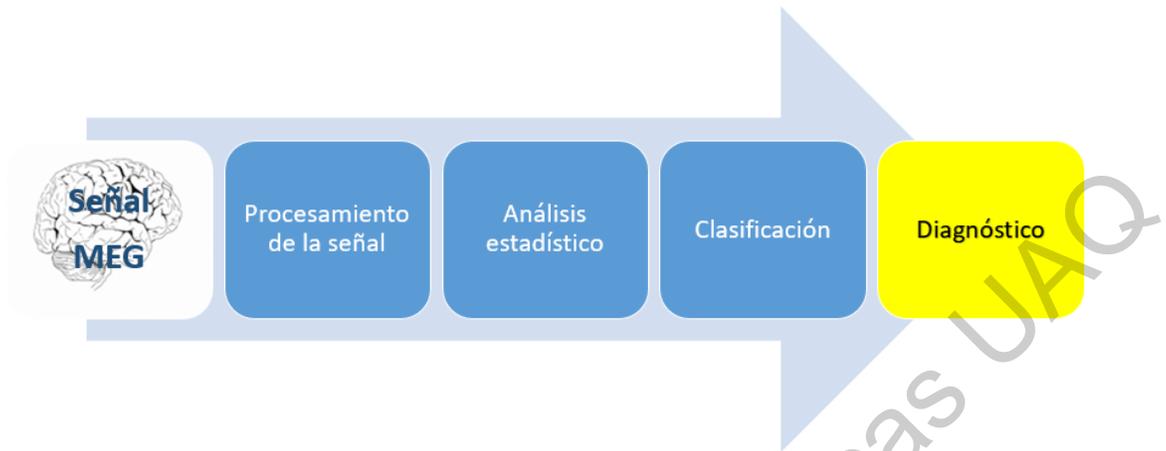
### **Objetivos Particulares:**

1. Desarrollar un algoritmo para la lectura de las señales obtenidas de magnetoencefalogramas mediante MATLAB para el análisis de las mismas.
2. Programar la transformada wavelet por medio de MATLAB para descomponer las señales MEG en sus diferentes bandas de frecuencia.

3. Programar los parámetros de Hjorths, actividad, movilidad y complejidad, a través de MATLAB para medir estas características de una señal en el dominio del tiempo.
4. Realizar un análisis estadístico, análisis de varianza, con el fin de determinar la característica, actividad, movilidad y complejidad, más discriminante para diferenciar entre una persona sana y una con DCL.
5. Diseñar un clasificador basado en redes neuronales empleando los valores más discriminantes obtenidos en el objetivo 4 para diferenciar una persona sana y una DCL automáticamente.
6. Realizar un análisis estadístico de las diferentes pruebas con el fin de validar la metodología propuesta buscando realizar el diagnóstico de manera eficiente y confiable.

### **1.7. Planteamiento general**

En la Figura 1 se muestra el planteamiento general para el diagnóstico de DCL, el cual está basado en 3 etapas: lectura/entendimiento de las señales, procesamiento y la clasificación de la señal con el fin de diagnosticar personas sanas y con DCL.



**Figura 1.1** Planteamiento General para el diagnóstico del DCL.

- a) **Señal MEG:** Esta primera etapa se enfoca al entendimiento y lectura de las señales MEG que describen la actividad eléctrica del cerebro de personas sanas y personas con DCL. Las señales MEG a entender/leer pertenecen a una base de datos proporcionada por el Dr. Mehran Ahmadiou del Instituto de Neurociencia de Holanda, la cual es de acceso libre bajo solicitud al correo mehranahmadiou@gmail.com. Esta base de datos comprende 18 señales MEG de personas sanas y 18 señales MEG de personas con DCL.
- b) **Procesamiento de la señal:** Una vez entendidas y leídas las señales MEG, como siguiente paso se emplean técnicas de procesamiento de señales avanzadas con el fin de encontrar características en la señal que permitan la distinción entre personas sanas y personas con DCL.
- c) **Análisis estadístico:** esta etapa tiene el propósito de evaluar las características estimadas en la etapa previa con el fin de identificar las características más discriminativas que permitan diferenciar entre una persona sana y una con DCL:
- d) **Clasificador:** Finalmente, una vez identificadas las características más discriminantes, estas son empleadas para construir/diseñar un clasificador con

el fin de que este estime de forma automática si la persona tiene DCL o está sana.

Dirección General de Bibliotecas UAQ

# Capítulo 2

Fundamento teórico

Dirección General de Bibliotecas UAQ

## 2.1 Revisión de la literatura

En esta sección se muestran los fundamentos matemáticos y conceptos emparentados en la metodología propuesta en este trabajo de tesis, la Transformada Wavelet Discreta, Parámetros de Hjorths, estudio estadístico ANOVA y redes neuronales para la detección de DCL empleando señales MEG.

## 2.2 Señales MEG

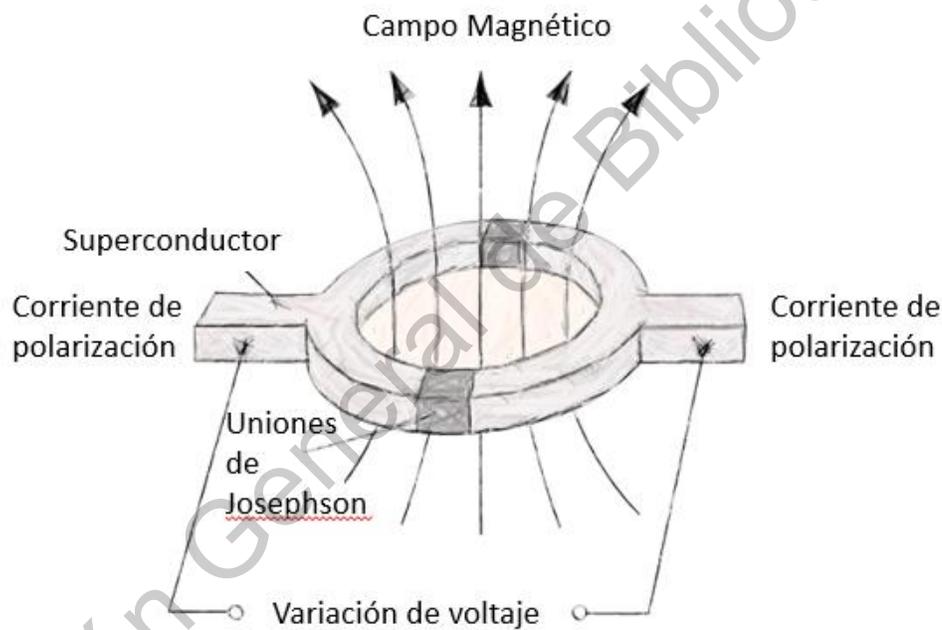
Las señales MEG son procedentes del biomagnetismo o campos magnéticos generados por sistemas biológicos, los cuales incluyen los flujos de corrientes neuronales y fibras musculares. Su principio hace referencia a la orientación perpendicular del campo con respecto a la dirección del flujo eléctrico y la generación del campo dipolar, cuya magnitud depende de la intensidad de la corriente que la produce. Estos campos magnéticos atraviesan las estructuras circundantes debido a que las sustancias no magnéticas presentan una permeabilidad similar a la del aire cuyo valor es uno (Maestú, et. al., 1999).

Las señales MEG han demostrado ser una buena herramienta para hacer estudios del encéfalo, ya que el campo magnético del cerebro refleja directamente los eventos neurofisiológicos del cerebro atravesando los tejidos sin tener alguna distorsión. De esta forma se pueden realizar estudios para reconocer ciertos eventos particulares en los trastornos neurodegenerativos (Vrba & Robinson, 2001; Wheless et al. 2004).

Las ventajas de usar las señales MEG es: (1) el contraste con el campo eléctrico, pues el campo magnético se ve afectado por los tejidos intermedios, (2) no se requiere una referencia mejorando así la conectividad funcional, (3) las mediciones son más sencillas ya que no es necesaria la aplicación de electrodos en el cuero cabelludo (Stam 2010).

La mayoría de las neuronas generan campos magnéticos que pueden ser captados en el exterior al poseer una orientación paralela a la superficie. En la actualidad, debido a las orientaciones físicas de las neuronas se cuenta con un gran número de sensores en un estudio, los cuales son arreglos de sensores SQUID (ver Figura 2.1) (por sus siglas en inglés que significan, dispositivo de interferencia de

superconducción), los cuales son sensores no invasivos y muy sensibles a la variable medida. Estos sensores consisten en 2 superconductores separados por finas capas aislantes que forman 2 uniones Josephson, dichas uniones tienen una baja disipación de potencia, por lo que su calentamiento resistivo limita la aplicabilidad (Rohlf, 1994); por esta razón, es necesario enfriar el sensor por debajo de la temperatura crítica para que el flujo magnético quede atrapado en el circuito. Los sensores SQUID en un estudio MEG están en una gran unidad de enfriamiento bañado en helio líquido a  $-269^{\circ}\text{C}$ , para que los pequeños cambios del campo magnético generado por las neuronas puedan inducir un flujo de corriente a la bobina colectora (Zhang et. al., 2014).



**Figura 2.1.** Sensor SQUID.

Cada señal MEG del encéfalo puede ser dividida en 5 bandas de frecuencia diferentes (Ahmadlou et. al. 2014):

- a) Delta (0.5 - 4 Hz): esta banda es caracterizada por su baja actividad cerebral, presente solo en etapas de sueño en adultos normales.

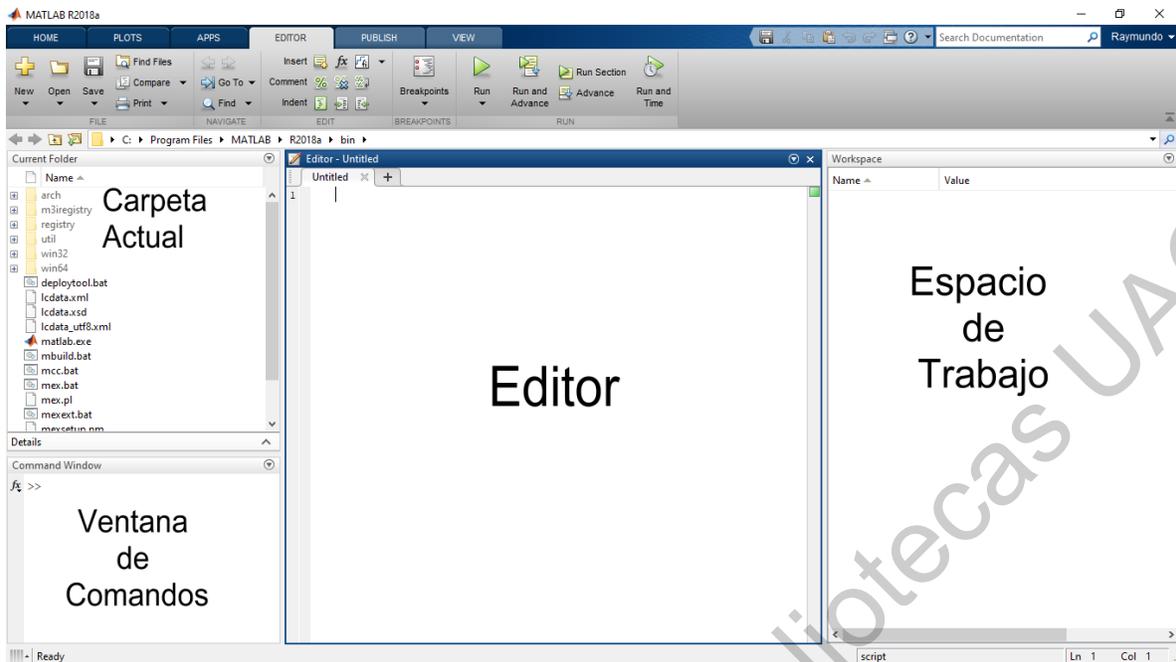
- b) Theta (4 – 8 Hz): esta banda existe en niños normales y en etapas de somnolencia y sueño de adultos, aparece una pequeña cantidad de actividad theta en la etapa de despertar en un adulto.
- c) Alpha (8 – 12 Hz): esta banda de frecuencia existe en adultos normales durante a relajación y la inactividad mental en etapas del adulto despierto. Aparece principalmente en el área occipital, esta banda es bloqueada al abrir los ojos (tener una atención visual) y otros esfuerzos mentales como pensar.
- d) Beta (13 - 30 Hz): localizada principalmente en la región de enfrente y central. Se encuentra presente en etapas de tensión y expectación.
- e) Gamma (30 – 70 Hz): se caracteriza por tener una alta frecuencia, generalmente se filtra esta señal porque no ha presentado importancia en estudios de cénicos ni psicológicos, pero se relacionan con tareas de un alto procesamiento cognitivo.

## **2.3 Procesamiento Digital de Señales**

Procesamiento digital de señales es un área de la ciencia y la ingeniería electrónica que se encarga de analizar, transformar, manipular y representar las señales. También es definido como un conjunto de técnicas y herramientas para el tratamiento de las señales en el dominio digital (Soria Olivas, et. al., 2003), en otras palabras, el procesamiento digital de señales se encarga de estimar características dentro de las señales con el objeto de poder asociarla a un fenómeno, en este caso a personas sanas y personas con DCL (Alvarado Moya, 2006).

### **2.3.1. MATLAB**

De acuerdo con MathWorks, MATLAB es un lenguaje de alto nivel que sirve para la expresión de ideas científicas y de ingeniería (MathWorks, 2019). MATLAB cuenta con una amplia variedad de biblioteca de algoritmos que incorpora novedosas técnicas en áreas como algebra lineal, procesamiento de señales e imágenes y sistemas de control.



**Figura 2.2** Composición de la ventana de MATLAB.

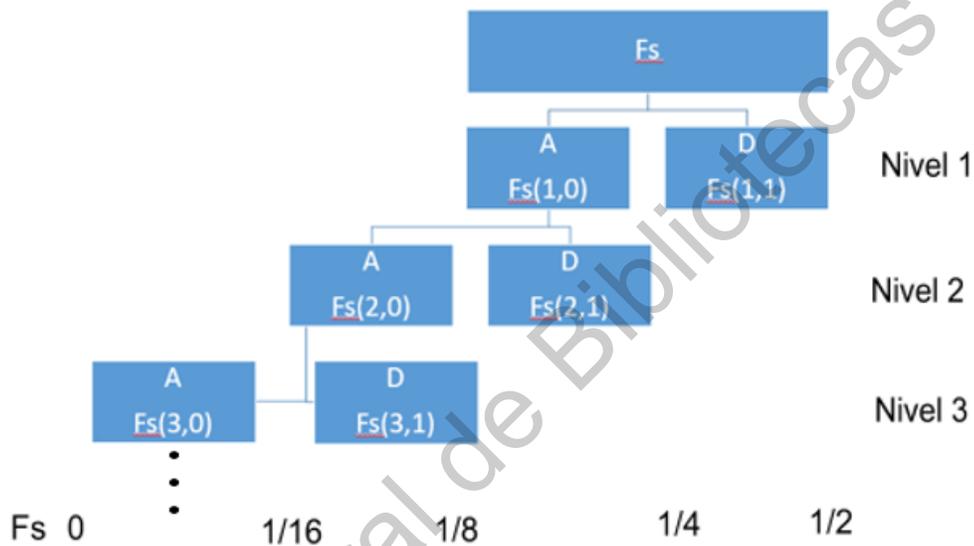
Como se muestra en la Figura 2.2 La ventana principal de Matlab cuenta con 4 sub-ventanas, la ventana de “carpeta actual”, la cual se emplea para desplegar los archivos contenidos en la carpeta de trabajo actual; la “ventana de comandos” la cual se usa para hacer el análisis del trabajo; la ventana de “editor” es el lugar donde se coloca la escritura del código a analizar y la ventana del “espacio de trabajo” se encarga de mostrar las variables con sus valores que se han utilizado en el trabajo.

### 2.3.2. Transformada Wavelet Discreta

La Transformada Wavelet Discreta (TWD) es una herramienta para el análisis de señales no estacionarias que proporciona una representación, descomposición y reconstrucción de la señal en el dominio de tiempo-frecuencia, siendo sus principales ventajas su eficiencia computacional, la compresión de datos y el análisis detallado de las señales (Nieto & Orozco, 2008).

La TWD se basa en el algoritmo de Mallat (ver Figura 2.3), el cual describe que la señal a analizar se descompone en un conjunto de filtros pasa-bajas y de

paso-altas que se le conocen como aproximaciones y detalles, respectivamente, y a su vez la aproximación obtenida en el primer nivel se divide en una nueva aproximación y un nuevo detalle, y así sucesivamente. Estas descomposiciones forman un árbol de diferentes bandas de frecuencia como se describe en la Figura 2.3, donde A son las aproximaciones y D son los detalles. El eje horizontal muestra frecuencia de muestreo ( $F_s$ ) que va de 0 hasta  $\frac{1}{2}F_s$ . Por ejemplo, en el nivel 1, la aproximación va de 0 hasta  $\frac{1}{4}F_s$ , el detalle va de  $\frac{1}{4}F_s$  hasta  $\frac{1}{2}F_s$ .



**Figura 2.3** Árbol de descomposición de la Transformada Wavelet Discreta.

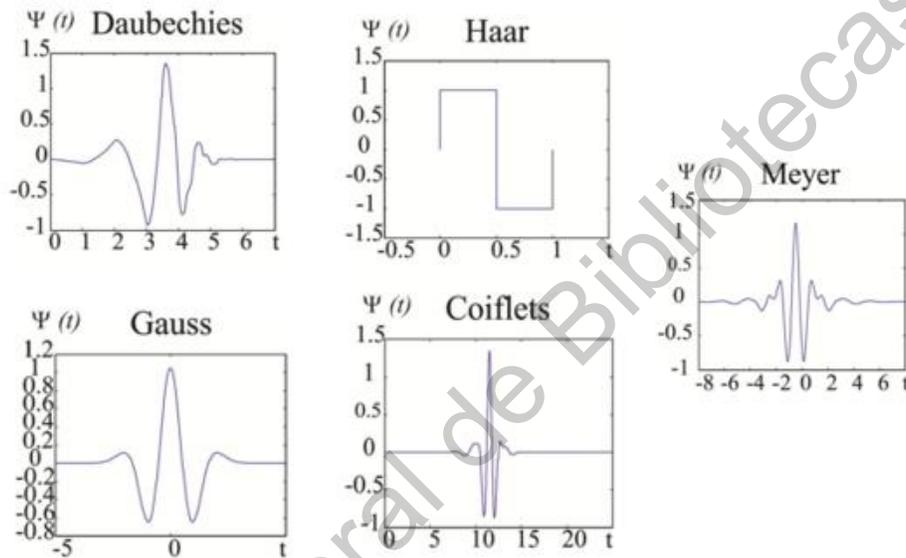
La TWD está definida por la siguiente ecuación:

$$DWT_{j,k} = \sum_N x(n) \overline{h_{j,k}(n)} \quad (2.1)$$

Donde  $x(n)$  y  $h(n)$  representa la señal discreta y la función wavelet o wavelet madre, respectivamente, del total de número de muestras,  $N$ , contenidas en la señal analizada  $x(n)$ .  $j$  y  $k$  representan el escalamiento y movimiento de la wavelet madre

Una wavelet madre es una pequeña onda de tiempo limitado, cuya energía se concentra en el tiempo alrededor de un punto, esto proporciona la herramienta para el análisis de fenómenos transitorios y no estacionarios Existen varias

propuestas para la Wavelet madre tales como lo es Daubechies, Haar, Gauss, Coiflets, Meyer (ver Figura 2.4), las cuales se dilatan y contraen para obtener las aproximaciones y detalles de la TWD (Amezquita-Sanchez & Adeli 2016). Es muy importante mencionar que la Daubechies 44 es la más recomendada para el análisis de señales biomédicas, ya que permite una descomposición correcta de la información (Rafiee et al. 2011). Por lo tanto, esta wavelet madre es empleada en este trabajo de tesis.



**Figura 2.4** Representación de las funciones madre de la Transformada Wavelet.

### 2.3.3. Parámetros de Hjorths

Los parámetros de Hjorths se refieren a la forma tradicional de convertir el patrón de Amplitud/Tiempo en una distribución de frecuencia con una complejidad reducida. Dichos parámetros permiten cuantificar las propiedades de los cambios dinámicos de una señal (Hjorth, 1970).

Esta dado por 3 parámetros: actividad, movilidad y complejidad (Obermaier et al. 2001); juntos caracterizan a la señal en términos de amplitud, escala de tiempo y complejidad respectivamente

### 2.3.3.1. Actividad

La actividad proporciona una medida de la varianza de la amplitud de la señal:

$$\text{Actividad}(y(t)) = \text{VAR}[y(t)] \quad (2.2)$$

La varianza (VAR) está definida como:

$$\text{VAR} = \frac{\sum(x_i - \bar{x})^2}{n-1} \quad (2.3)$$

Donde  $x_i$  son los valores de los términos de la señal y  $\bar{x}$  es la media de la señal. Y  $n$  es la longitud de la muestra.

### 2.3.3.2. Movilidad

La movilidad está definida como la raíz cuadrada de la relación entre las varianzas de la primera derivada y la amplitud, estas cantidades son dependientes de la amplitud media, por lo que la relación dependerá de la forma de la curva con el fin de que mida la pendiente media relativa. En otras palabras, la movilidad estima una medida de la desviación estándar de la pendiente con referencia a la desviación estándar de la amplitud de la siguiente manera:

$$\text{Movilidad}(y(t)) = \sqrt{\frac{\text{Actividad}\left(\frac{dy(t)}{dt}\right)}{\text{Actividad}(y(t))}} \quad (2.4)$$

### 2.3.3.3. Complejidad

La complejidad es una medida adimensional y proviene de la relación entre la movilidad de la primera derivada de la señal y la movilidad de la propia señal.

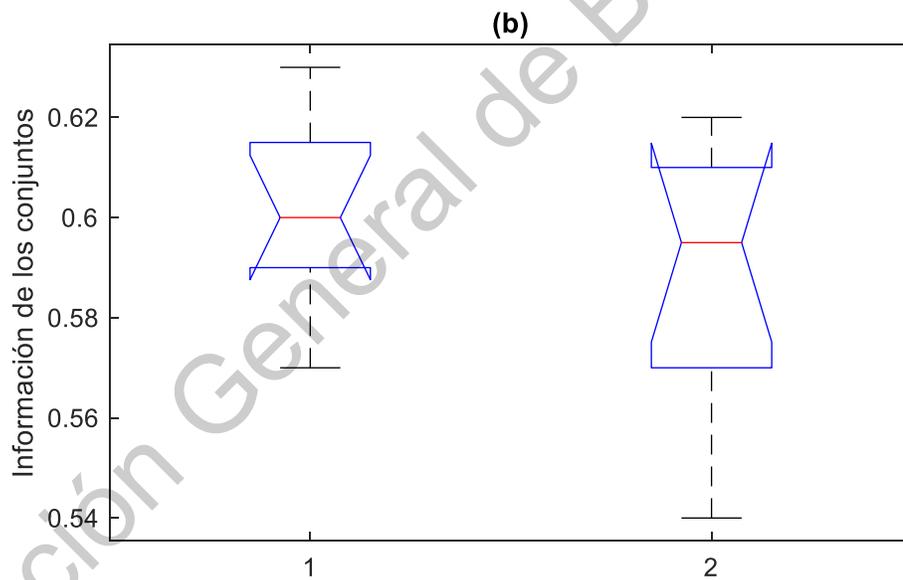
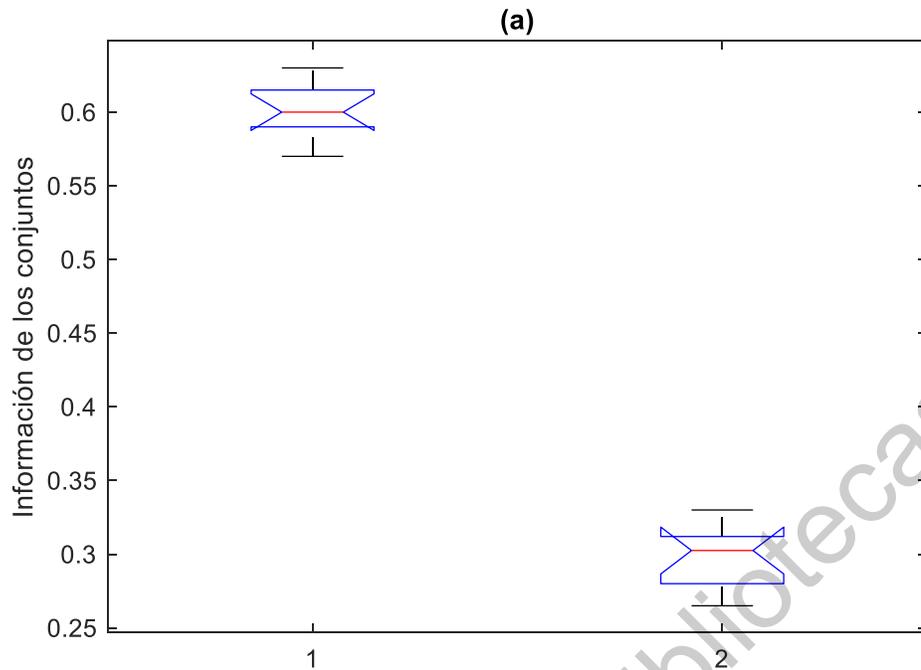
$$\text{Complejidad}(y(t)) = \frac{\text{Movilidad}\left(\frac{dy(t)}{dt}\right)}{\text{Movilidad}(y(t))} \quad (2.5)$$

Este parámetro se caracteriza por dar una medida de los detalles excesivos con referencia a la curva más “suave”, ya que la complejidad tiende a 1 cuando la señal a analizar es una señal senoidal pura.

#### **2.3.4. ANOVA**

El análisis de varianza o ANOVA permite evaluar la capacidad de las características estimadas por los indicadores no lineales, en este caso los parámetros de Hjorths para discriminar entre los diferentes casos/condiciones analizados (Pakyari & Balakrishnan, 2012). ANOVA se basa en un valor de probabilidad, valor  $p$ , el cual varía entre 0 y 1. Cuando el valor  $p$  tiende a cero significa que las características que se han analizado no comparte información, por lo que pueden ser empleadas para asociarla a los fenómenos estudiados; por otro lado, si el valor  $p$  tiende a 1 esto indica que las características evaluadas tienen una capacidad baja para diferenciar entre los diferentes fenómenos analizados (Lopez-Caracheo et al. 2018).

Con el fin de ejemplificar lo antes mencionado, la Figura 2.5 muestra la distribución de los datos de dos conjuntos, los cuales no presentan similitud (no traslapados) y otro que si presentan valores similares (traslapados). Para el primer ejemplo en valor  $p$  tiende a 0, indicando esa característica es capaz de diferenciar o ser asociado al fenómeno analizado. Por otro lado, en el segundo conjunto de datos el valor  $p$  tiende a 1, indicando que la característica seleccionada no es capaz de diferencias entre los fenómenos estudiados y por lo tanto no debe ser seleccionada.



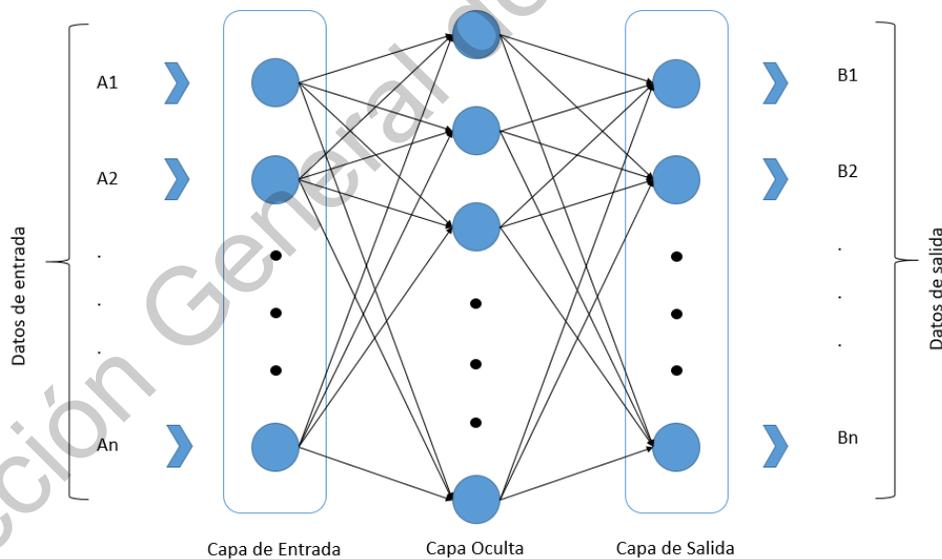
**Figura 2.5.** Distribución de datos para dos conjuntos (a) no traslapados y (b) traslapados.

### 2.3.5. Redes Neuronales

Una Red Neuronal Artificial (RNA) es una forma de computación o modelo inspirada en las neuronas cerebrales del ser humano. En el caso de las RNAs, estas

cuentan con neuronas artificiales (nodos) que presentan características de aprendizaje que pueden ser ocupadas en diferentes tareas tales como: Aprendizaje Adaptativo (aprende a realizar tareas basada en un entrenamiento), Auto-Organización (Puede crear su propia organización), Tolerancia a Fallos (reconoce patrones con ruido, distorsiones o patrones incompletos; ósea, puede seguir realizando su función aun con una parte de la red destruida) (Matich 2001).

Las conexiones neuronales se efectúan por medio de factores de peso a lo largo de las interconexiones de la red. En la RNA los pesos internos se ajustan durante el proceso de entrenamiento, por lo que los valores de entrada y de salidas deseadas se envían repetidamente y en cada repetición los pesos cambian hasta que la salida tenga los valores deseados (Lopez-Ramirez et al. 2016). Existen nodos de entrada, de salida y otros (capa oculta) que son internos a la red neuronal, por lo que la configuración de la RNA es llamada Perceptrón Multicapa (PMC) (ver Figura 2.6). El número de nodos en la capa de entrada dependerá del número de variables del problema.



**Figura 2.6** Arquitectura de Perceptrón Multicapa

La RNA llamada PMC es la más empleada para tareas de clasificación, ya que es capaz de separar las clases involucradas de una manera satisfactoria. Dado que no existe un método para definir los nodos de las capas ocultas, estas

dependen del problema a tratar, pues el aumentar los nodos ocultos puede generar carga computacional y no siempre se tiene un óptimo resultado para lo cual se recomienda que el número de neuronas en la capa oculta sea el doble de la entrada (Licon & Close, 2001).

En la forma de procesamiento de la neurona, cada unidad es un nodo  $S_j$  sumador no lineal definido por la ecuación:

$$S_j = \sum_{i=0}^n w_{ji} * a_i \quad (2.6)$$

donde  $w_{ji}$  es el factor de peso de la unidad  $i$  a la neurona  $j$  y  $a_i$  es la función de activación, definido como:

$$a_i = \frac{1}{1 + \exp(-S_j)} \quad (2.7)$$

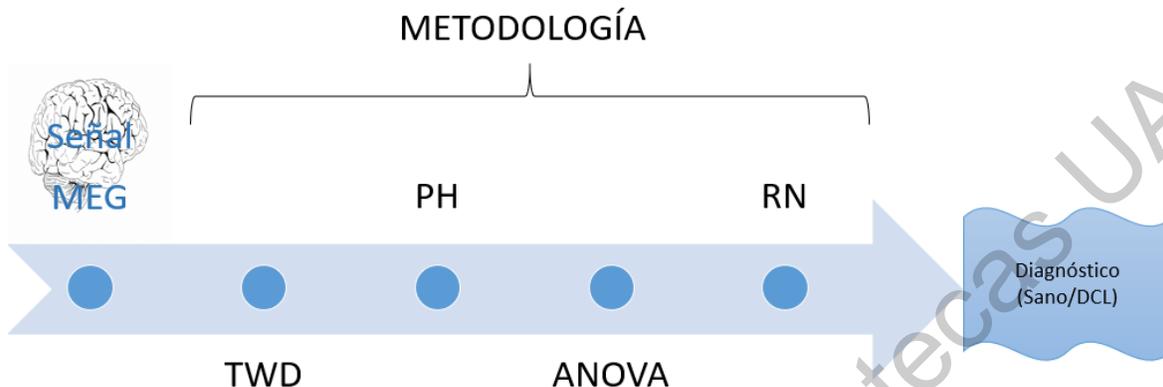
# Capítulo 3

## Metodología

Dirección General de Bibliotecas UAQ

### 3.1. Metodología

En la Figura 3.1 se observa el diagrama de la metodología propuesta en este trabajo de tesis, la cual consta de 4 pasos.



**Figura 3.1** Metodología propuesta.

Primeramente, las señales MEG proporcionadas (36 señales MEG: 18 de personas sanas y 18 de personas con DCL) por el Dr. Mehran Ahmadlou, las cuales se obtuvieron a partir de una diadema de 148 electrodos colocados con una separación entre ellos de 3 cm. (ver Figura 3.2), son analizadas por la transformada wavelet discreta (TWD) (Amezquita-Sanchez & Adeli. 2014), con el fin de descomponer las señales en las 5 bandas características del cerebro descritas en el capítulo anterior (Ahmadlou et al. 2014).

Una vez descompuesta las señales en sus bandas características, a cada banda de frecuencia se le aplican los Parámetros Hjorths (PH) (actividad, movilidad y complejidad), los cuales permiten cuantificar las propiedades de los cambios dinámicos de una señal (Obermaier et al. 2001) en términos de amplitud, en escala de tiempo y complejidad (Hjorth, 1970) de manera simple y compacta. Por lo tanto, estas características, medidas no lineales, pueden ser ocupadas para diagnosticar una persona sana y una con DCL. Posteriormente, las características estimadas para las diferentes señales MEG, personas sanas y con DCL, y las cinco bandas de frecuencia son analizadas estadísticamente a través de un análisis de varianza o

ANOVA, con el fin estimar cual o cuales son los más capaces de discriminar entre una persona sana y que presenta DCL.

Finalmente, las características más discriminantes seleccionadas a través de ANOVA son empleadas para diseñar un clasificador basado en redes neuronales para diagnosticar si la persona está sana o presenta DCL de forma automática

### **3.2. Material**

La base de datos proporcionada por el Dr. Mehran Ahmadiou cuenta con el monitoreo de 18 pacientes con DCL con un rango de edad de 71 a 78 años y 19 personas sanas con un rango de edad 70 a 80 años, las cuales fueron reclutados por Unidad Geriátrica del Hospital Universitario de San Carlo, Madrid.

El diagnóstico se realizó bajo los siguientes criterios: a) queja cognitiva corroborada por un informante (persona que permanece con el paciente al menos durante medio día por 4 días a la semana), b) deterioro cognitivo objetivo documentado por recuerdo tardío en la subprueba de Memoria Lógica de Wechsler, c) función cognitiva general normal de acuerdo con la evaluación del médico durante una entrevista estructurada con el paciente y un informante, y adicionalmente un mini examen de estado mental (MEEM), que es para conocer el estatus cognitivo y funcional y al igual se aplica una prueba para conocer el Estado Global de Deterioro (EGD) para lo cual se observa en la Tabla 3.1 que las personas con DCL no presentan un estado crítico pero si es suficiente para hacer una distinción entre los dos grupos. d) no lo suficiente deteriorado para llegar a la etapa de demencia. Con el propósito de hacer la evaluación y establecer el estado cognitivo de los pacientes con respecto a múltiples funciones cognitivas se realizó la prueba de (a) Memoria Lógica Inmediata (ML1), la cual trata de evaluar el recuerdo de historias presentadas oralmente y la prueba de (b) Memoria Lógica retraso (ML2) (Ahmadiou et. al. 2014), la cual evalúa la capacidad de recordar información de las historias en LM1 después de un retraso de 30 minutos, así como evaluar el reconocimiento de la información de las historias.

**Tabla 3.1.** Información Clínica sobre los pacientes con DCL y sanos.

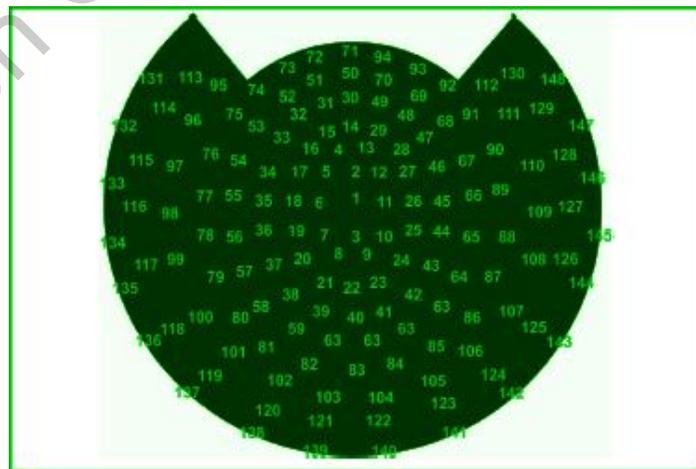
Grupo de sujetos	Muestras (sexo)	Edad	MEEM	EGD	ML1	ML2
DCL	18 (11 mujeres)	74.8±3	27.7±1	3	19.1±5	13.1±6
Sano	19 (12 mujeres)	71.6±8	29.5±0.7	1	42.5±8	26.7±7

La memoria Lógica Inmediata trata de evaluar el recuerdo de historias presentadas oralmente con el propósito de hacer una evaluación y establecer así el estado cognitivo con respecto a múltiples funciones cognitivas.

### 3.3. Sistema de adquisición de las señales MEG.

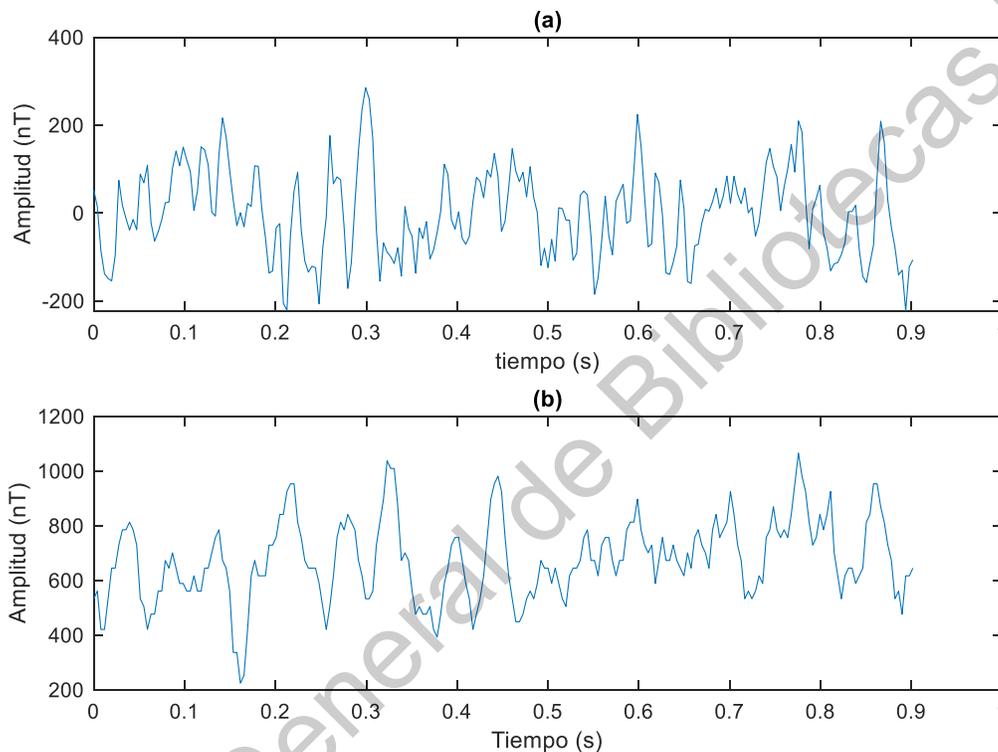
Con el fin de adquirir/monitorear las señales MEG de los diferentes pacientes de ambos grupos, se empleó la diadema MAGNES 2500 WH, 4D neuroimaging, la cual cuenta con 148 sensores para la medición magnética del cerebro como se muestra en la Figura 3.2. Es muy importante mencionar que los pacientes bajo estudio eran ubicados en un cuarto protegido magnéticamente, con el fin de reducir el ruido del ambiente. Las mediciones fueron realizadas entre las 9 AM y las 12 AM, con el fin de que el paciente descansará por la noche y presentará una buena concentración en las pruebas.

El sistema de monitoreo cuenta con una frecuencia de muestreo de 254 Hz con un filtro pasa bandas de 0.5-50 Hz, con el fin de monitorear las frecuencias correspondientes a la actividad cerebral.



**Figura 3.2** Ubicación de los 148 sensores.

Para este trabajo de tesis se evaluaron las señales cerebrales tomadas por los 148 sensores, de manera que se evalúa el comportamiento del cerebro o encéfalo de manera completa. Con fines ilustrativos las señales adquiridas por el sensor 30 (zona frontal) para una persona sana y una persona con DCL, respectivamente, son mostradas en la Figura 3.3. Es muy importante mencionar que esta señal es seleccionada de manera aleatoria.



**Figura 3.3.** Señal MEG (zona frontal): (a) persona sana y (b) persona con DCL.

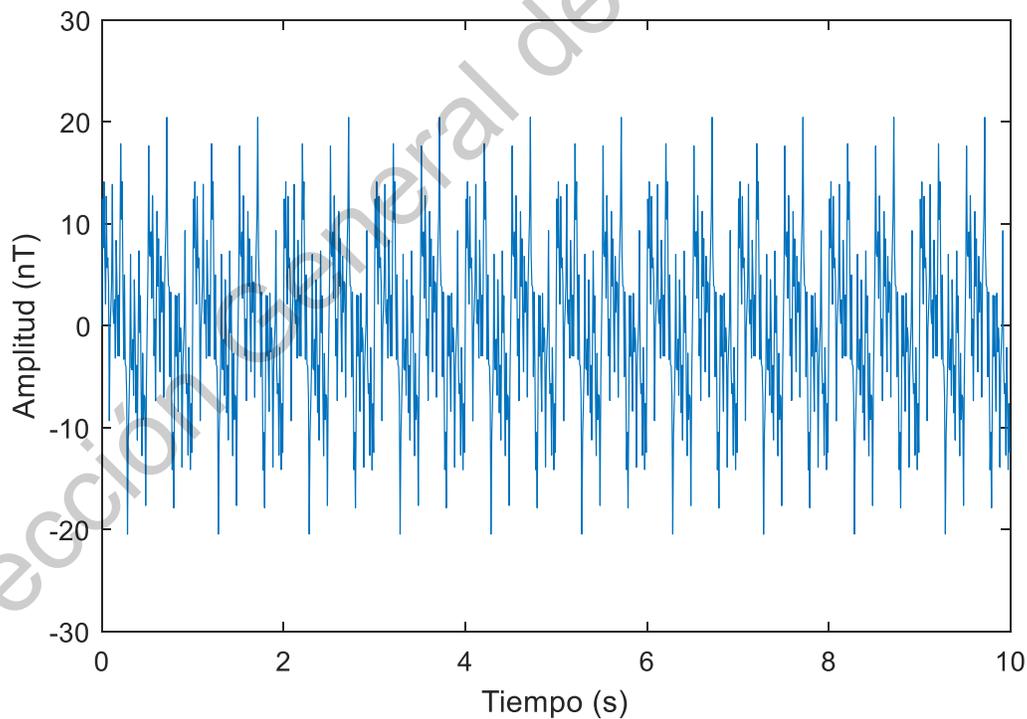
Como se puede apreciar en la Figura 3.3, las señales MEG de ambos grupos presentan un comportamiento no estacionario, lo que impide estimar características a simple vista que puedan ser asociadas al fenómeno estudiado. Por lo tanto, la importancia de proponer una metodología capaz de estimar características dentro de este tipo de señales que permitan diagnosticar una persona sana y una con DCL.

### 3.4. Procesamiento de la señal MEG

Con el fin de ilustrar los pasos dentro del preprocesamiento, TWD y los PH propuestos en este trabajo de tesis, una señal sintética semejante a una señal MEG con una amplitud (A) de 5nT, frecuencias (f) de 2, 6, 10, 20 y 45 Hz., una duración (t) de 10 segundos y una frecuencia de muestreo de 120 Hz, resultando en 1,200 muestras es analizada.

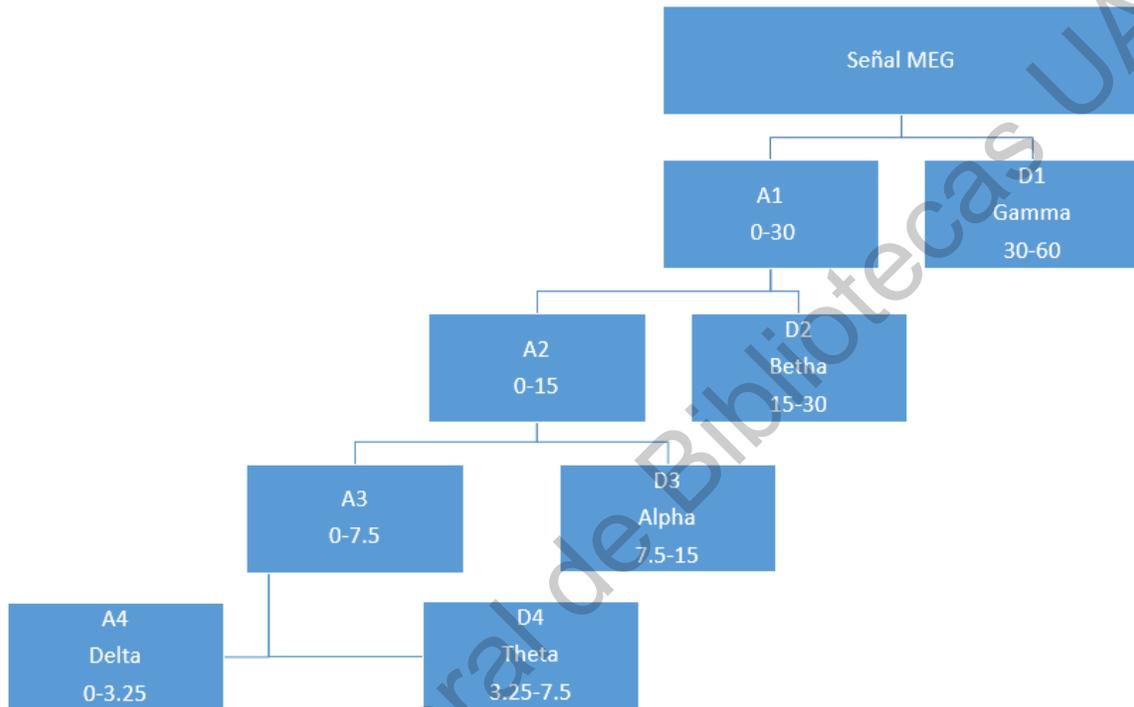
$$x = A * \sin(2 * \pi * f * t) \quad (3.1)$$

Una señal MEG es caracterizada por la gran cantidad de ruido que envuelve a la señal útil, tomando en cuenta esto la señal sintética es contaminada con un nivel alto de ruido, en este caso 1 dB (Maestú et. al. 1999). La Figura 3.4 muestra la señal sintética analizada sin ruido y con ruido.



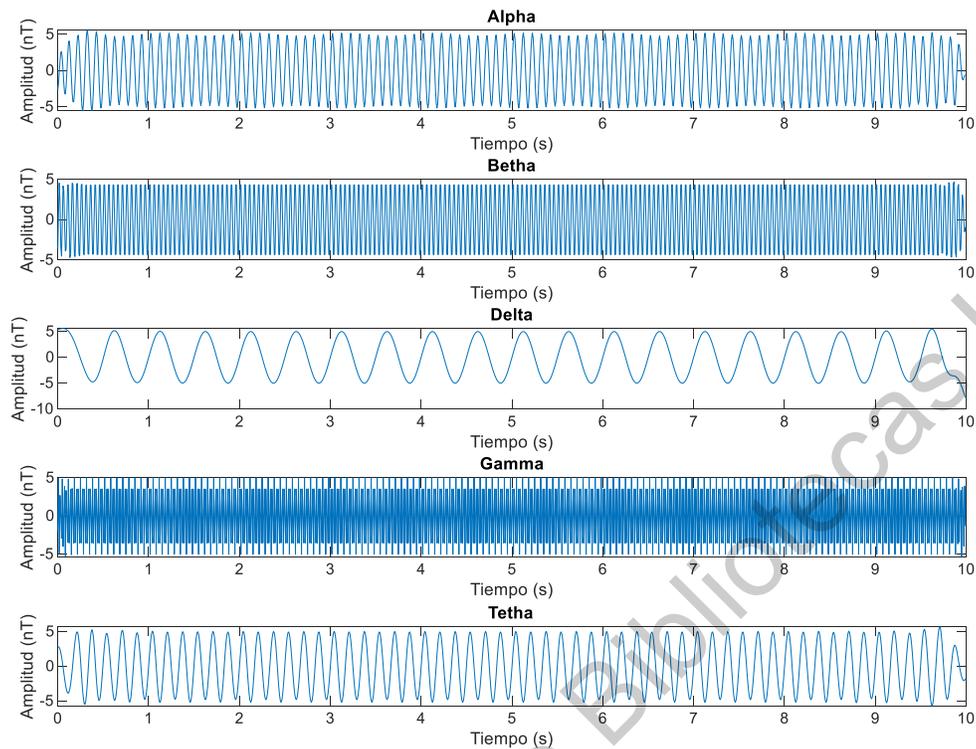
**Figura 3.4.** Señal Generada.

Siguiendo los pasos propuestos en la metodología, la señal es descompuesta a través de la TWD en sus diferentes bandas características de frecuencia del cerebro (ver Figura 3.5). Detalle 1 (D1): Gamma, Detalle 2 (D2): Betha, Detalle 3 (D3): Alpha, Detalle 4 (D4): Theta y Aproximación 4 (A4): Delta.



**Figura 3.5.** Árbol de descomposición de la señal analizada.

La Figura 3.6 muestra las diferentes descomposiciones/bandas de frecuencia estimada por la TWD, donde se puede observar que la TWD es capaz de separar eficientemente la señal en sus diferentes frecuencias



**Figura 3.6.** Descomposición de las 5 bandas de frecuencia, por medio de la Transformada Wavelet Discreta.

Una vez descompuesta la señal a través de la TWD, a cada banda de frecuencia se le aplican los parámetros de Hjorths (actividad, movilidad y complejidad). La Tabla 3.2 muestra los resultados obtenidos para cada banda de frecuencia (Alpha, Beta, Delta, Gamma y Theta) y los diferentes parámetros de Hjorths.

**Tabla 3.2.** Resultados obtenidos de los parámetros de Hjorths aplicados a cada banda de frecuencia.

<b>Banda\Hjorths</b>	<b>Actividad</b>	<b>Movilidad</b>	<b>Complejidad</b>
<b>ALPHA</b>	12.3296	0.5183	1.0007
<b>BETHA</b>	12.4283	1.0011	0.9997
<b>DELTA</b>	12.8338	0.1023	1.0267
<b>GAMMA</b>	12.4966	1.8485	0.9998
<b>THETA</b>	12.3078	0.3123	1.0033

Como se puede observar en la Tabla 3.2, diferentes valores son obtenidos para cada banda de frecuencia y cada parámetro. Por lo tanto, es de vital importancia analizar todas las bandas de frecuencias referentes a la actividad cerebral y los tres diferentes algoritmos de Hjorths con el fin de identificar patrones para la clasificación de personas sanas y con DCL

# Capítulo 4

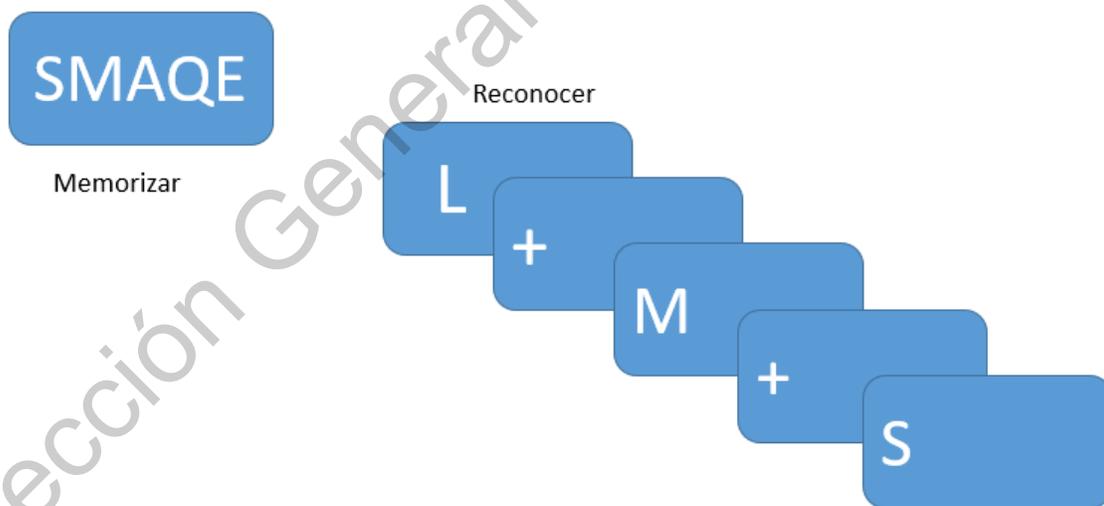
## Pruebas y Resultados

Dirección General de Bibliotecas UAQ

## 4.1. Puesta de Experimento

Con el fin de adquirir las señales MEG de los pacientes enrolados en el estudio, primeramente, se les mostraron 5 letras diferentes, de las cuales se les pidió que las memorizaran (ver Figura 4.1). Una vez mostradas las 5 letras a memorizar, se les presentaron diferentes letras por 1 segundo, una a la vez y se le pidió a cada paciente que presionara un botón con su mano derecha cuando detectara una letra de las 5 que se memorizó previamente. Las pruebas variaron entre cada paciente, en general están alrededor de 29 pruebas con 230 datos por cada una, el motivo de que varíen estas pruebas es debido al criterio que se tuvo al realizar el estudio pues se tuvo que remover los datos anormales, como los datos con ruido y las respuestas negativas del examen realizado. Cada una de las pruebas que se le realizó a cada paciente contó con una frecuencia de muestreo de 254 Hz.

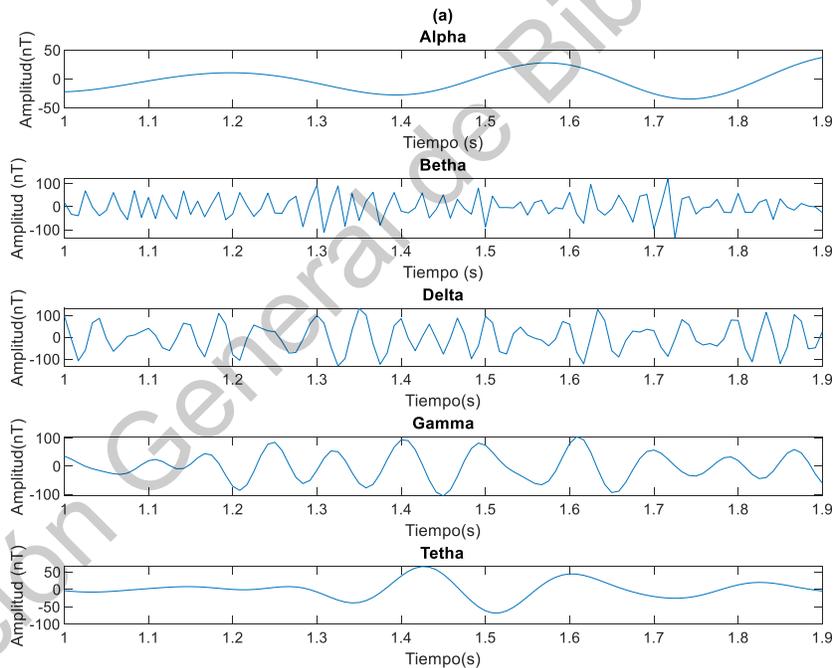
Los evaluadores clasificaron las respuestas en 4 categorías: aciertos, falsas alarmas, correctos rechazos y omisiones. Este estudio se realizó con el propósito de evaluar los patrones de conectividad funcional que apoyan el éxito del reconocimiento.

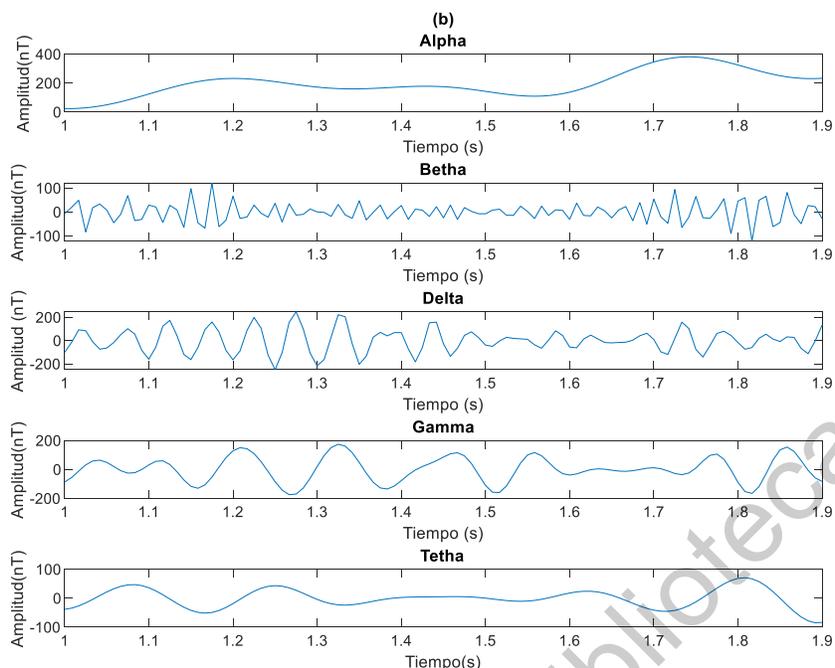


**Figura 4.1.** Representación de la prueba de reconocimiento de las letras, donde los participantes en la primera fase memorizan las 5 letras “SMAQE”. Y en la segunda fase reconocen las letras.

## 4.2. Resultados

Las señales MEG a analizar de personas con DCL y personas sanas presentan comportamientos que a simple vista son difíciles de diferenciar debido a sus propiedades no estacionarias como se mostró en el capítulo anterior, por lo que un método capaz de descubrir patrones en este tipo de señales. Primeramente, las señales son re-muestreadas de 254 a 120 Hz, lo que permite obtener una señal con 109 datos, esto con el fin de caer en las bandas de frecuencia relacionadas con la actividad cerebral. Posteriormente, siguiendo la metodología propuesta las señales son descompuestas por la TWD con el fin de obtener las 5 bandas de frecuencia características de la actividad cerebral. La Figura 4.2 muestra las 5 bandas de frecuencia obtenidas para una persona sana y una con DCL, respectivamente.

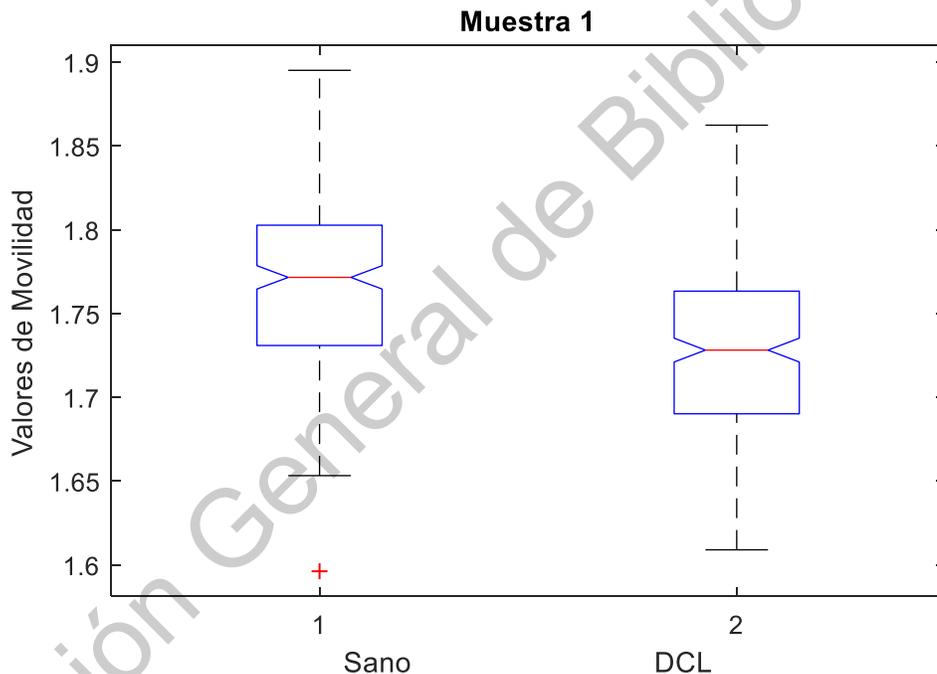




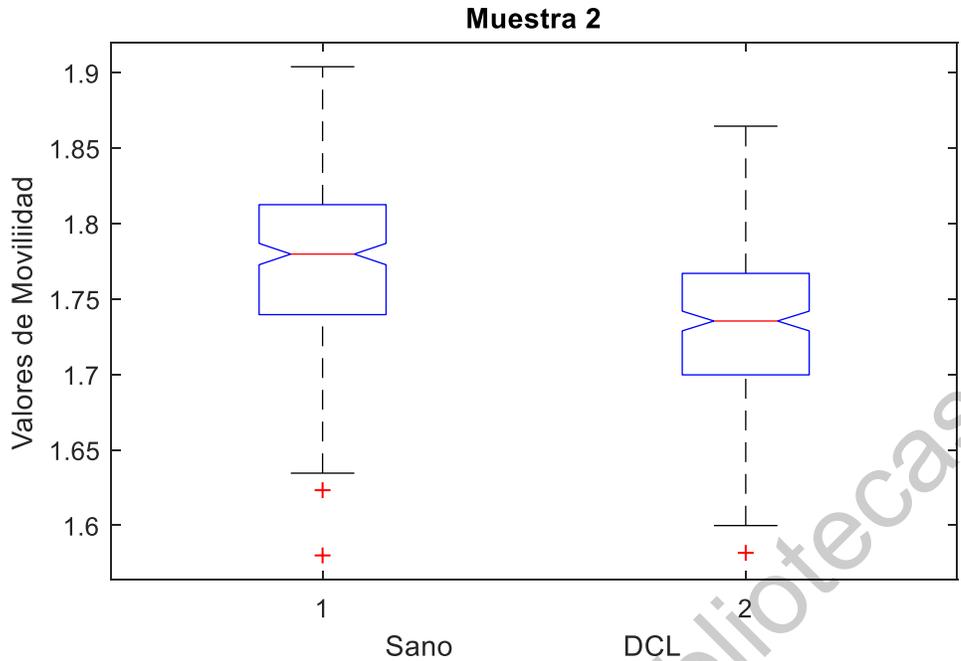
**Figura 4.2.** Bandas de Frecuencia de una (a) persona sana y una (b) persona con DCL.

Observando la Figura 4.2, es difícil la identificación de patrones que permita distinguir entre una persona sana y una con DCL; por lo tanto, la importancia de un indicador o medida capaz de identificar patrones o características en las diferentes bandas de frecuencia. Para realizar esta tarea como siguiente paso de la metodología propuesta, se aplican los parámetros de Hjorths o indicadores no lineales (actividad, movilidad y complejidad) a cada una de las bandas de frecuencia estimadas. Una vez aplicado estos indicadores a todas las pruebas, se emplea un análisis estadístico llamado ANOVA con el fin de determinar cuál o cuáles indicadores, así como la banda o bandas de frecuencia son las capaces de diferenciar entre una persona sana y una con DCL. Después de un análisis exhaustivo se determinó en base a los valores de probabilidad (valor-p) estimados por ANOVA, que el indicador de Movilidad en las bandas Gamma, Beta y Theta, siendo los sensores 120, 137, 119, 138, 115, 139, 114, 121, 102, 133, 101 y 103 de la banda gama; el sensor 146 de la banda delta y los sensores 4 y 2 de la banda

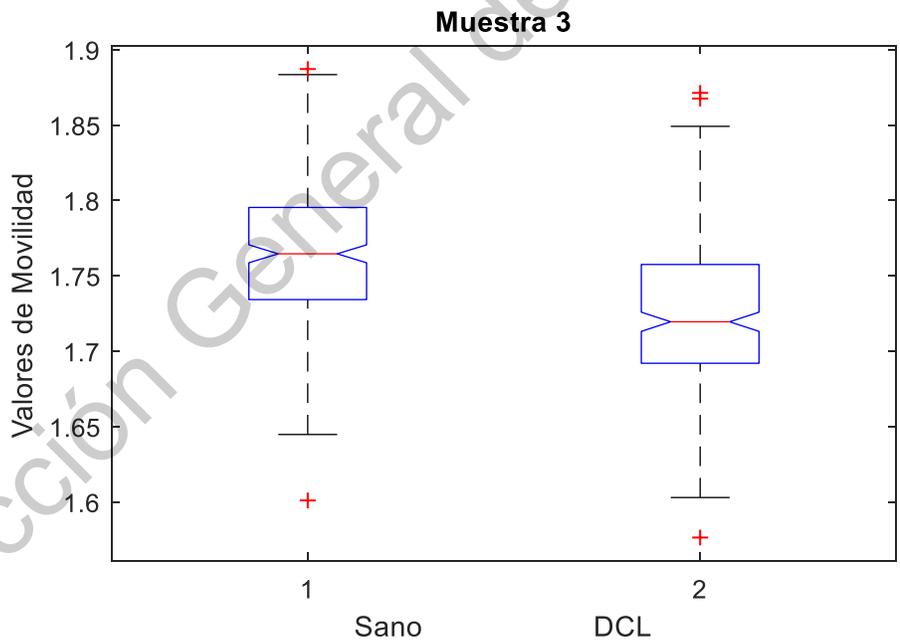
betha los más adecuados para distinguir entre una persona sana y una con DCL debido a que esta característica presenta una baja probabilidad de coincidencia. Las Figuras 4.3 a la 4.17 muestran la distribución de los datos de la movilidad para las bandas de frecuencia y sensores más discriminativos. Además, en la Tabla 4.1 se resume los valores de probabilidad de las 15 características más discriminantes, así como su valor medio y desviación estándar de las bandas y sensores de la característica más discriminativa (movilidad). Por otra parte, en la sección de anexos se muestran todos los valores “p” obtenidos del estudio ANOVA, tanto de Actividad, Complejidad y Movilidad de las 5 bandas de frecuencia, con el fin de ampliar la información obtenida en este trabajo de tesis.



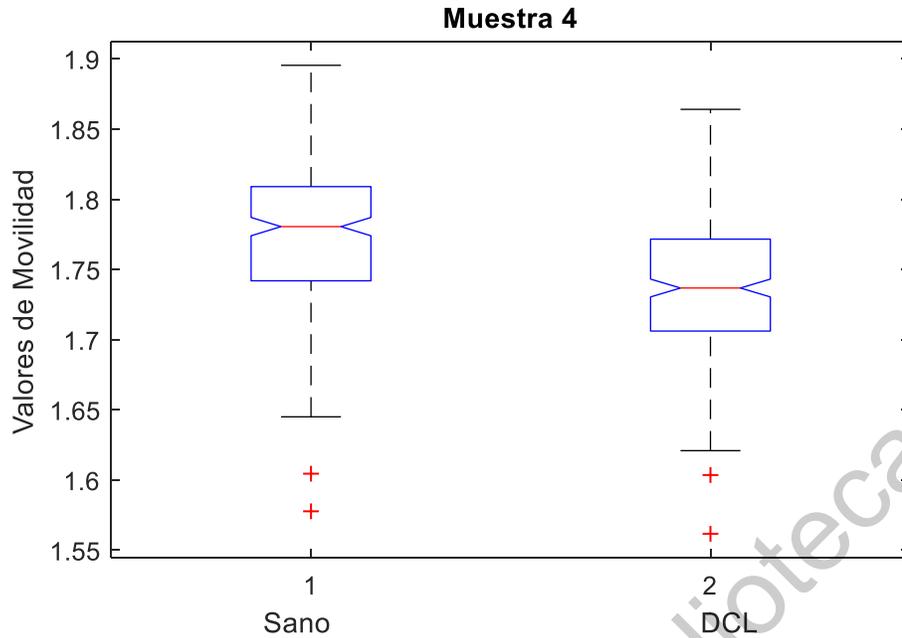
**Figura 4.3.** Distribución de datos estimada por medio de ANOVA para el sensor 120 banda Gamma del parámetro de Movilidad.



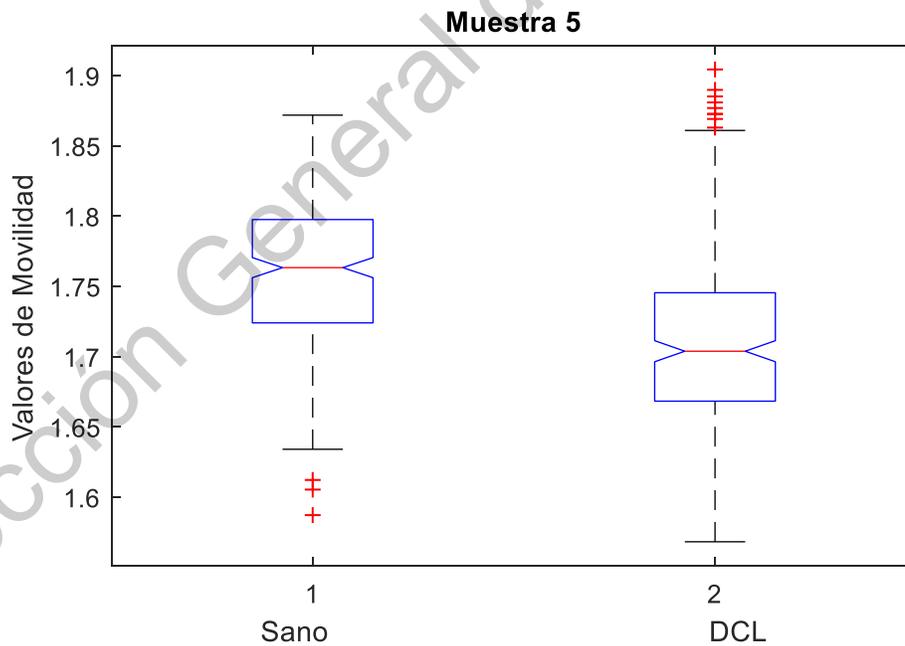
**Figura 4.4.** Distribución de datos estimada por medio de ANOVA para el sensor 137 de la banda Gamma del parámetro de Movilidad.



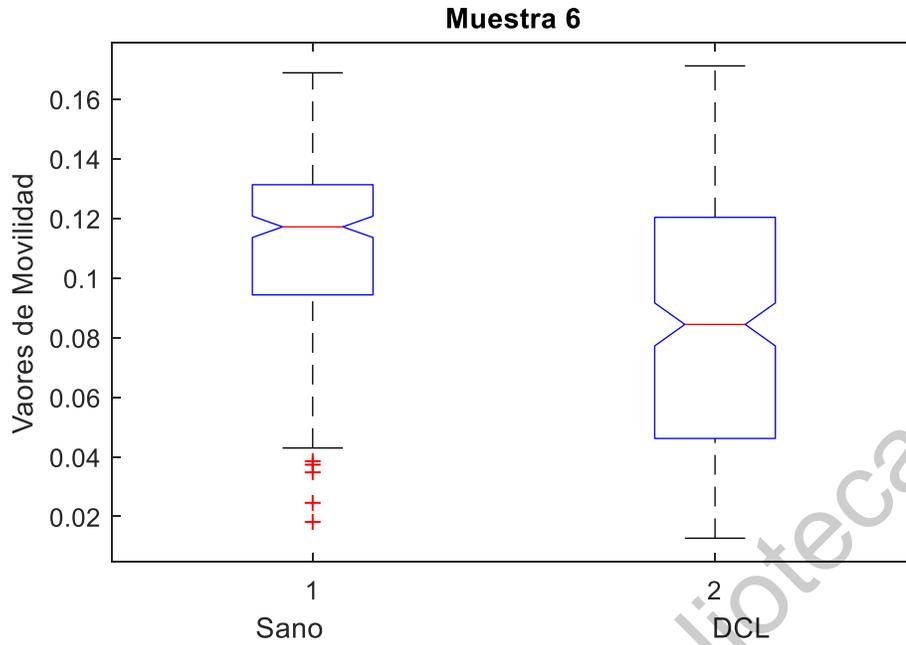
**Figura 4.5.** Distribución de datos estimada por medio de ANOVA para el sensor 119 de la banda Gamma del parámetro de Movilidad.



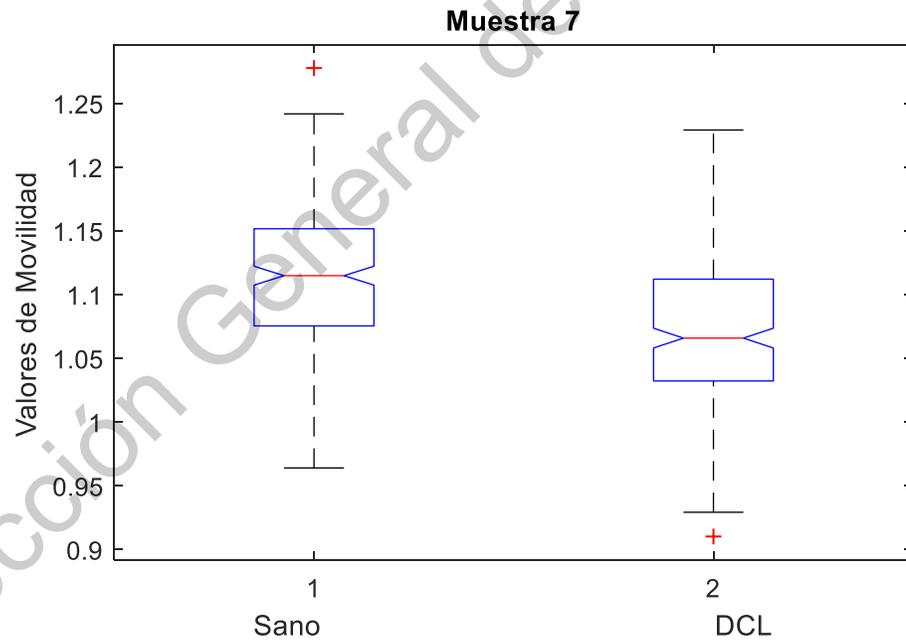
**Figura 4.6.** Distribución de datos estimada por medio de ANOVA para el sensor 138 de la banda Gamma del parámetro de Movilidad.



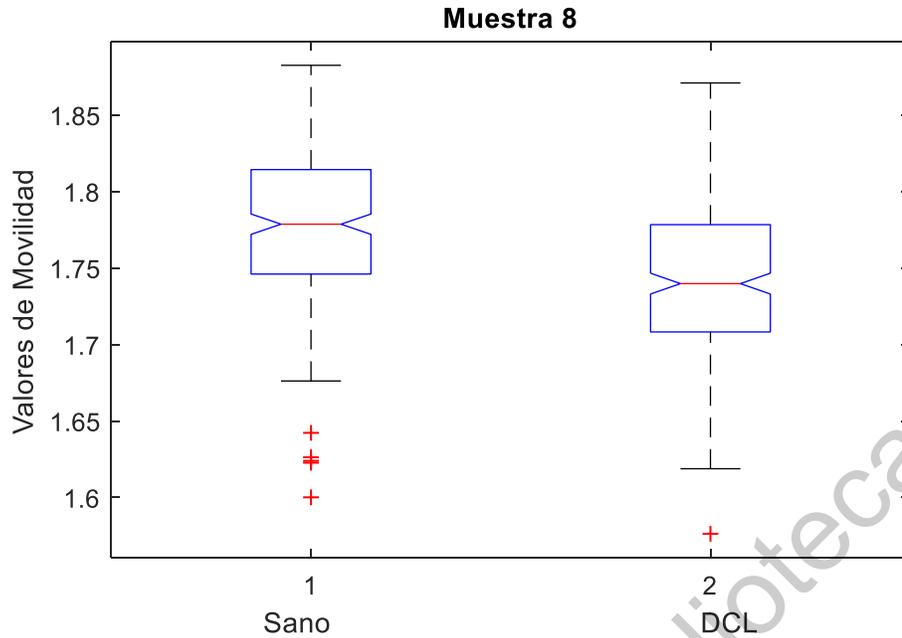
**Figura 4.7.** Distribución de datos estimada por medio de ANOVA para el sensor 115 de la banda Gamma del parámetro de Movilidad.



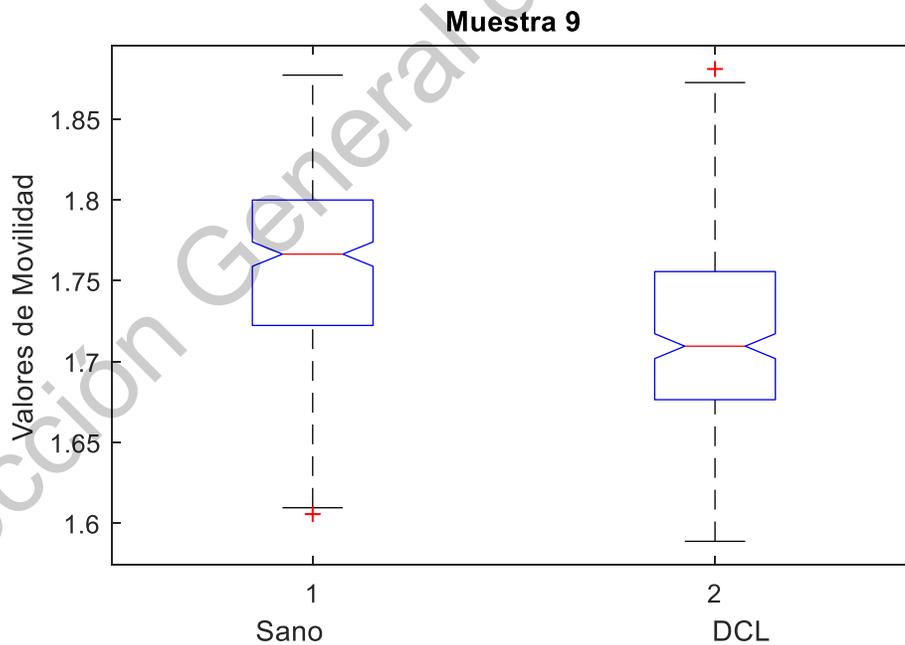
**Figura 4.8.** Distribución de datos estimada por medio de ANOVA para el sensor 146 de la banda Delta del parámetro de Movilidad.



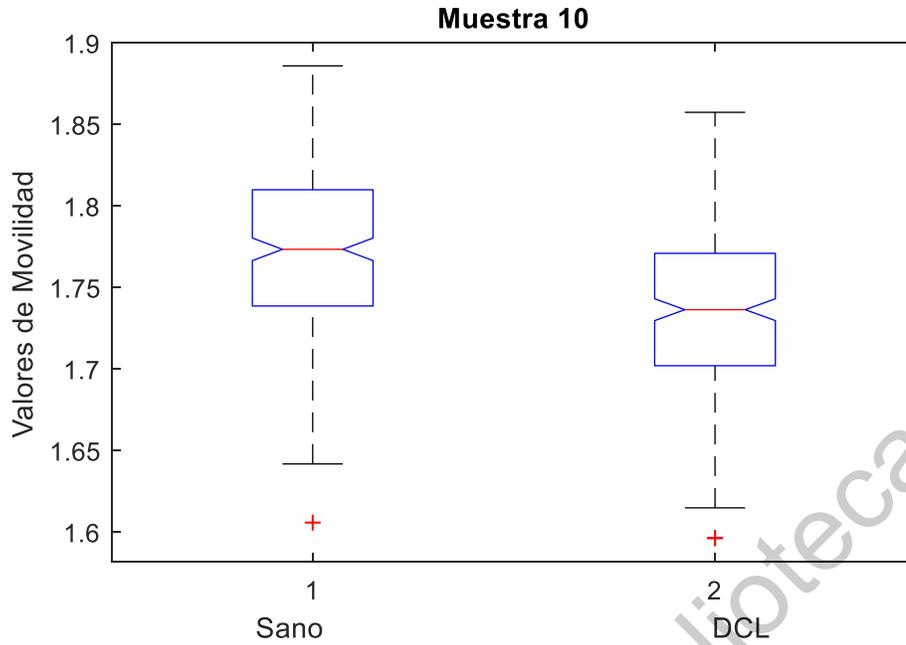
**Figura 4.9.** Distribución de datos estimada por medio de ANOVA para el sensor 4 de la banda Beta del parámetro de Movilidad.



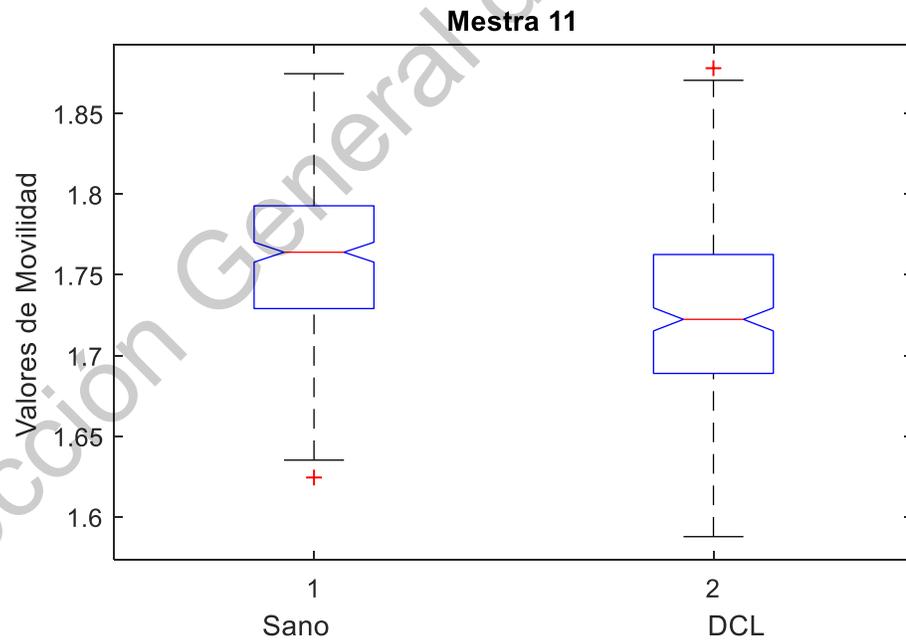
**Figura 4.10.** Distribución de datos estimada por medio de ANOVA para el sensor 139 de la banda Gamma del parámetro de Movilidad.



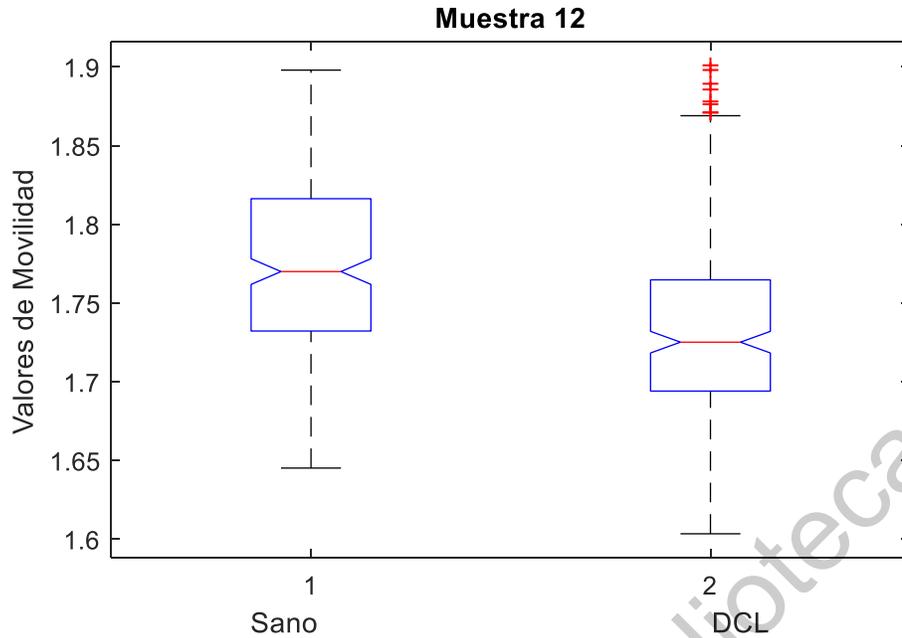
**Figura 4.11.** Distribución de datos estimada por medio de ANOVA para el sensor 114 de la banda Gamma del parámetro de Movilidad.



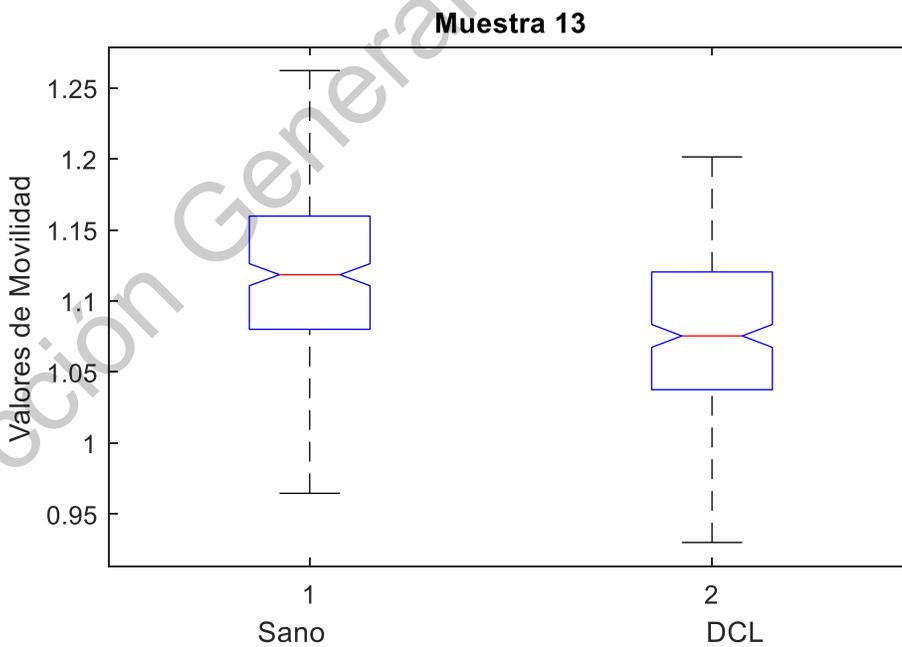
**Figura 4.12.** Distribución de datos estimada por medio de ANOVA para el sensor 121 de la banda Gamma del parámetro de Movilidad.



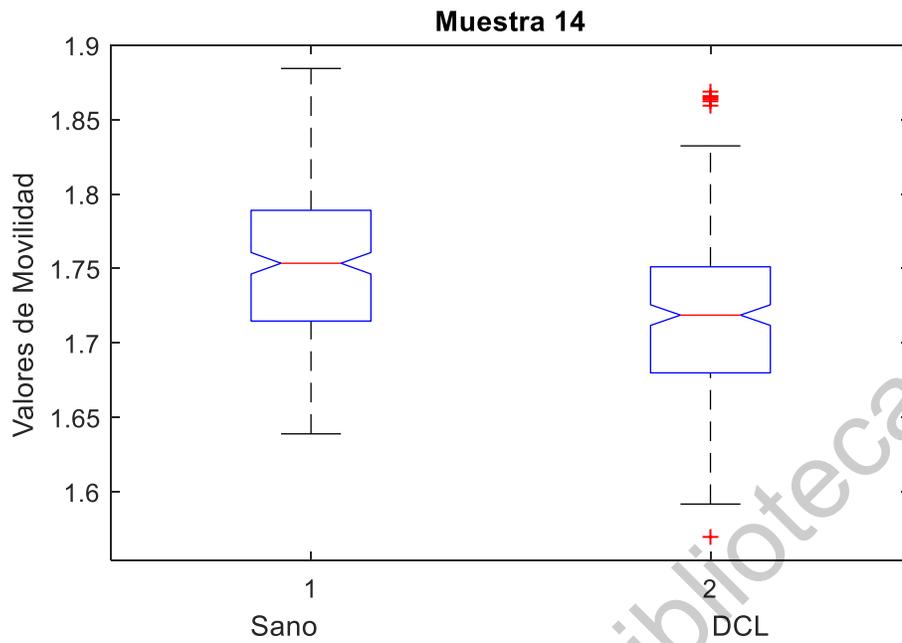
**Figura 4.13.** Distribución de datos estimada por medio de ANOVA para el sensor 102 de la banda Gamma del parámetro de Movilidad.



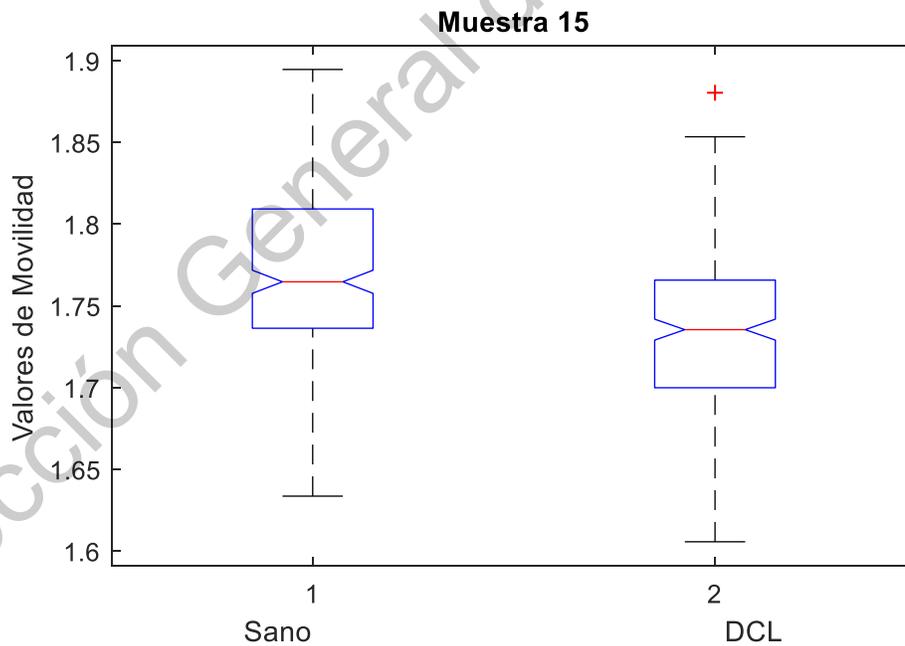
**Figura 4.14.** Distribución de datos estimada por medio de ANOVA para el sensor 133 de la banda Gamma del parámetro de Movilidad.



**Figura 4.15** Distribución de datos estimada por medio de ANOVA para el sensor 2 de la banda Beta del parámetro de Movilidad.



**Figura 4.16.** Distribución de datos estimada por medio de ANOVA para el sensor 101 de la banda Gamma del parámetro de Movilidad.



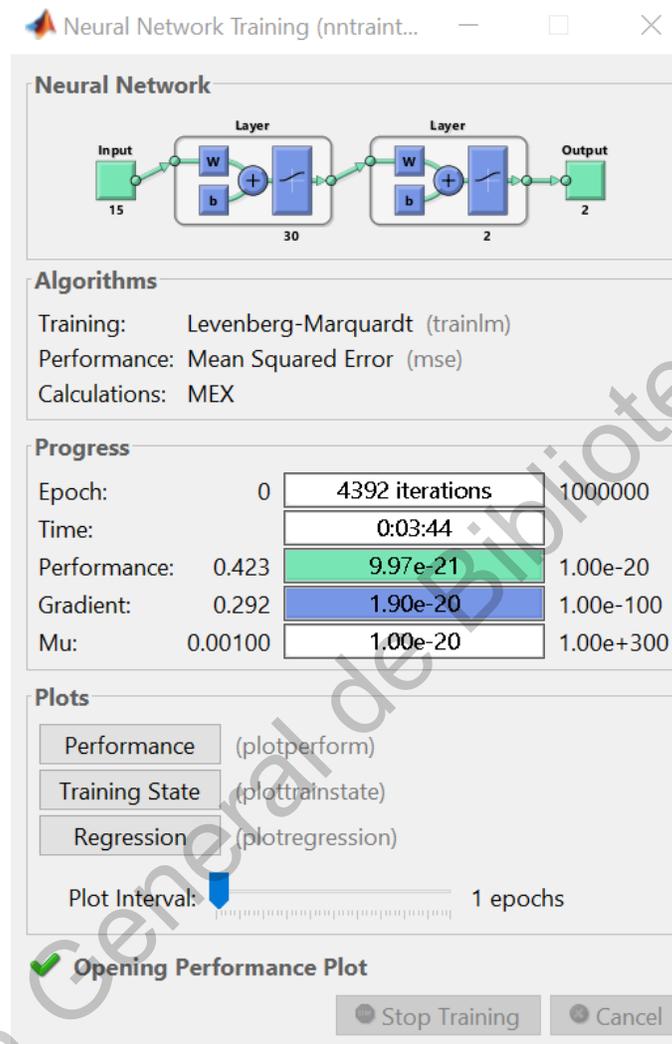
**Figura 4.17** Distribución de datos estimada por medio de ANOVA para el sensor 103 de la banda Gamma del parámetro de Movilidad.

**Tabla 4.1.** Valores de probabilidad obtenidos a través de ANOVA, así como media y desviación estándar de los diferentes conjuntos de datos.

Muestra	Sensor	Banda	Valor p	Sano Media/Desviación estándar		DCL Media/Desviación estándar	
1	120	gamma	1.20E-20	1.7716	0.0490	1.7282	0.0505
2	137	gamma	6.95E-20	1.7798	0.0534	1.7354	0.0486
3	119	gamma	1.97E-18	1.7646	0.0501	1.7195	0.0507
4	138	gamma	1.37E-17	1.7805	0.0513	1.7368	0.0487
5	115	gamma	1.32E-16	1.7633	0.0549	1.7038	0.0654
6	146	delta	3.78E-16	0.1171	0.028	0.0844	0.043
7	4	betha	6.57E-16	1.1148	0.0576	1.0658	0.0567
8	139	gamma	3.23E-15	1.7786	0.0496	1.7398	0.0505
9	114	gamma	3.54E-15	1.7665	0.562	1.7095	0.0604
10	121	gamma	4.09E-15	1.7734	0.0486	1.7363	0.0505
11	102	gamma	4.47E-15	1.7641	0.0498	1.7224	0.0522
12	133	gamma	9.65E-15	1.77	0.0551	1.7251	0.0554
13	2	betha	3.12E-14	1.1185	0.0599	1.0754	0.0548
14	101	gamma	3.46E-14	1.7535	0.0523	1.7187	0.0534
15	103	gamma	7.29E-14	1.7647	0.0511	2.7354	0.0486

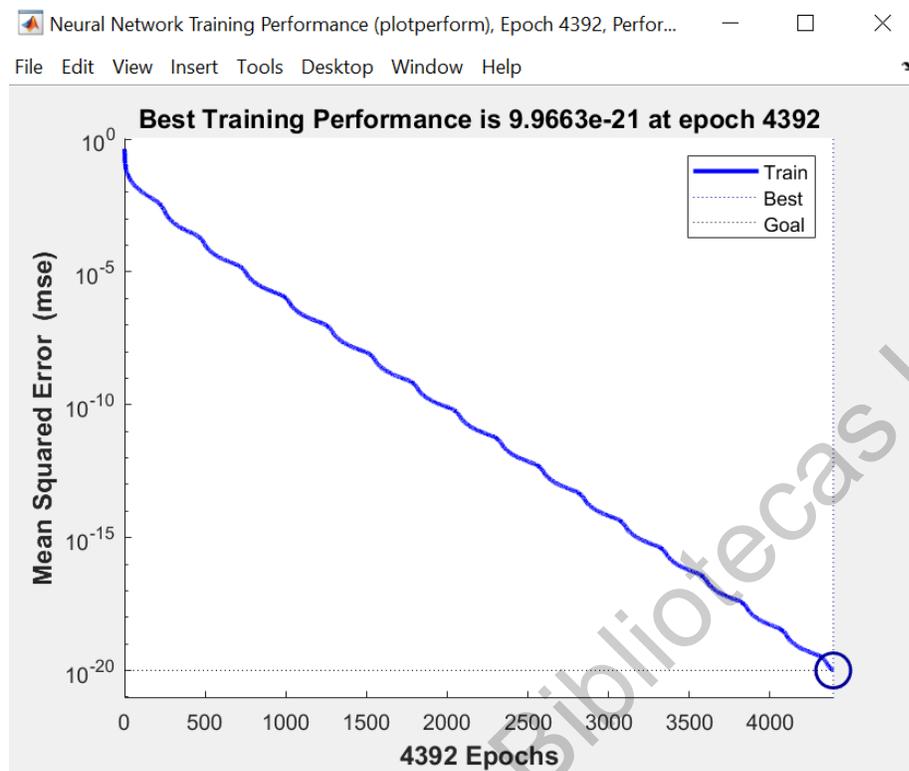
Finalmente, una vez determinados los sensores, bandas e indicador más discriminantes a través de ANOVA, los valores de los límites de estas características son empleadas para entrenar una red neuronal perceptrón multicapa a través del algoritmo Levenberg-Marquardt, donde se crearon 800 valores aleatorios de manera artificial, por cada una de las 15 características seleccionadas entre los límites obtenidos del estudio ANOVA, los primeros 400 corresponden a los valores relacionadas a las personas sanas y las otras 400 a los valores de personas DCL con el propósito de hacer el entrenamiento de la red neuronal con suficientes datos y la red pudiera entender las diferencias entre los dos conjuntos de datos. La red neuronal empleada tiene 15 entradas cada entrada con sus 800 valores, 30 neuronas en la capa oculta, ya que acorde a la literatura se recomienda que esta sea al doble de las entradas (Lopez-Ramirez et al. 2016), además que esta cantidad brindo buenos resultados en la clasificación y 2 salidas, las cuales corresponden a

una persona sana y una con DCL. La Figura 4.18 se muestra la estructura final de la red neuronal.



**Figura 4.18.** Estructura final de la red neuronal.

Es muy importante mencionar que el performance en una red neuronal indica que tanto ha entendido la relación de los diferentes conjuntos de datos de entrada con sus respectivas salidas, por lo que el performance obtenido en esta red indica que esta ha entendido las diferentes entradas-salidas, ya que mientras más cercano a cero este valor se presenta un mejor entendimiento. La Figura 4.19 se muestra la evolución del performance a lo largo del entrenamiento.



**Figura 4.19.** Gráfica de la evolución del performance durante el entrenamiento de la red neuronal.

Es muy importante mencionar que, para este trabajo de tesis, primeramente, empleó la mitad de las señales MEG para todo el proceso previamente descrito, para el entrenamiento de la red en base a los límites obtenidos de esto. La segunda mitad de las señales se usó para validar la eficiencia de la red, los cuales fueron probados en la estructura final de la red neuronal donde un 75% de eficiencia es obtenido.

### 4.3. Discusión de Resultados

Los resultados obtenidos por la metodología propuesta se presentan mediante una matriz de confusión mostrada en la Tabla 4.2. La matriz de confusión está compuesta por dos entradas, sano y DCL; y dos salidas con los estados que asignó la metodología. Por lo tanto, esta tabla resume el número de pruebas

clasificadas correcta e incorrectamente del total de pruebas realizadas. En particular, para evaluar la eficiencia de la metodología se probaron 522 señales MEG de las cuales 261 son de personas sanas y 261 de personas con DCL.

**Tabla 4.2.** Eficiencia de la metodología propuesta.

<b>Salida</b>	<b>Sano</b>	<b>DCL</b>	<b>Eficiencia (%)</b>
<b>Entrada</b>			
<b>Sano</b>	228	33	87.356
<b>DCL</b>	98	163	62.45
<b>Eficiencia Total</b>			75

Es muy importante mencionar que el resultado obtenido y mostrado en la Tabla 4.2 se intentó mejorar modificando el número de neuronas en la capa oculta; sin embargo, al incrementar la cantidad de neuronas en la capa oculta se obtenían resultados muy similares, pero a costa de un incremento en la carga computacional y complejidad de la red, por lo que en este trabajo de tesis la recomendación hecha por Lopez-Ramirez et al. (2016) fue la más adecuada ya que con el doble de neuronas en la capa oculta respecto a la entrada es suficiente para obtener un buen resultado.

Al momento de evaluar la segunda mitad de las señales MEG reales provenientes de personas sanas, la metodología reconoció que, de las 261 señales, 228 las evaluó correctamente y 33 no, lo que da un porcentaje de eficiencia del 87.356%. Por otro lado, al ingresar la segunda parte de las señales MEG reales provenientes de personas con DCL, 163 las clasificó de manera correcta y presentó 98 errores, por lo que se obtuvo una eficiencia del 62.45%. Por lo tanto, de manera general la metodología propuesta presenta una eficiencia del 75%, lo que representa un gran avance en esta área, ya que trabajos previos como el de Bruña et al. (2012) y el de Timothy et al. (2017) reportaron una eficiencia del 65% y 70%, respectivamente, por lo que la metodología propuesta presenta una mejora del 8.3% en comparación a los trabajos previamente reportados.

# Capítulo 5

## Conclusiones y Prospectivas

Dirección General de Bibliotecas UAQ

## 5.1. Conclusiones

DCL es caracterizado por la pérdida cognitiva de la memoria o pensamiento más allá de los cambios esperados por la edad, este deterioro es el precursor de la enfermedad el Alzheimer. Por lo tanto, un diagnóstico oportuno de DCL es de vital importancia, ya que los pacientes podrían recibir un tratamiento adecuado con el fin de reducir (a) una posible conversión a Alzheimer y (b) retrasar el progreso de la enfermedad. En este trabajo de tesis se aborda una metodología que permite el diagnóstico del DCL basada en la Transformada Wavelet Discreta para obtener las 5 bandas de frecuencia características del cerebro humano, los parámetros de Hjorths para la obtención de características de las señales, y redes neuronales para el aprendizaje de las diferencias entre las señales de personas sanas y de las enfermas.

De acuerdo a los resultados obtenidos se puede mencionar que la propuesta hecha en este trabajo de tesis se puede considerar como otra alternativa para el diagnóstico de DCL, ya que esta enfermedad es detectada principalmente de forma convencional a través de una entrevista con los familiares del paciente, por lo que un diagnóstico a través del procesamiento de señales brinda un opción que pudiera ayudar al médico a dar un diagnóstico más acertado y rápido, ya que la propuesta presenta una eficiencia del 75%, mejorando en un 8.3% las propuestas hechas recientemente por diferentes investigadores (Bruña et al. 2012, Timothy et al. 2017). Adicionalmente, es importante mencionar que la banda gamma está relacionada con tareas de un alto procesamiento cognitivo, la cual permitió estimar características relacionadas con el diagnóstico de la enfermedad de DCL. Cabe mencionar que en investigaciones previas se descarta el uso de la banda gamma para usos clínicos, ya que no tiene un impacto fisiológico debido a su alto rango de frecuencia (Adeli, et.al., 2003); sin embargo, Zhang et al. (2014) demostraron que los patrones de oscilación de la sincronía neural con distintos procesos visuales en tareas de atención se ven reflejados las ondas de la banda gamma superior (de 70 a 120 Hz) y gamma inferior (de 44 a 66 Hz), en especial en la de la región occipital. Por lo tanto, de esta investigación presentada por Zhang et al. (2014) y los resultados obtenidos en este trabajo de tesis se resalta el hecho de que la banda

gamma tiene mucho que aportar en el área neuronal; sin embargo, no se cierra la oportunidad de seguir investigando para encontrar más factores que justifiquen científicamente estas condiciones. Por lo tanto, este trabajo de tesis es un avance significativo en el tema del diagnóstico del DCL por medio de procesamiento de señales avanzado debido a que las características de la señal se analizaron por medio de técnicas de baja carga computacional y con una buena eficiencia, la cual mejoro la eficiencia.

## **5.2. Prospectivas**

De este trabajo se obtuvieron buenos resultados, pero en un trabajo futuro es importante seguir evaluando otras técnicas de baja carga computacional para estimar otra característica de la señal que permita una mayor diferenciación entre los dos grupos de personas sanas y con DCL. Algunos indicadores que podrían ser evaluados serian la dimensión fractal, la homogeneidad, entropías, entre otros. Además de otras técnicas de procesamiento de señales como lo es la descomposición empírica de modos, la transformada Wavelet de Paquetes, entre otras con el fin de poder incrementar la distinción entre personas sanas y con DCL. Al igual el análisis de la banda gamma que en este estudio y en la bibliografía se ha encontrado que es un área de interés por lo que un enfoque en esta banda podría traer un mejor porcentaje de eficiencia.

## Bibliografía

Abaitua, J. (2012). Procesado de Señales Eeg Para Un Interfaz Cerebro-Máquina (Bci). *Universidad Carlos III de Madrid*.

Adeli, et. al. (2003). Analysis of EEG records in an epileptic patient using wavelet transform, 123, 69–87.

Ahmadlou, M., et. al. (2014). Complexity of functional connectivity networks in mild cognitive impairment subjects during a working memory task. *Clinical Neurophysiology*, 125(4), 694–702.

Amezquita-Sanchez, J. P., et. al.. (2016). A New Methodology for Automated Diagnosis of Mild Cognitive Impairment (MCI) Using Magnetoencephalography (MEG). *Behavioural Brain Research* 305: 174–80.

Amezquita-Sanchez, J. P., & Hojjat, A. (2014). Signal Processing Techniques for Vibration-Based Health Monitoring of Smart Structures. *Archives of Computational Methods in Engineering*: 1–15.

Alvarado Moya, J. P. (2006). Procesamiento Digital de Señales. Costa Rica.

Bruña, R., et. al. (2012). Analysis of spontaneous MEG activity in mild cognitive impairment and Alzheimer's disease using spectral entropies and statistical complexity measures. *Journal of neural engineering*, 9(3), 036007.

Cruz Ramirez H (2018) Metodología basada en la descomposición empírica de modos completa y fractales para la clasificación de la imaginación motora usando señales electroencefalográficas. Tesis Licenciatura, UAQ.

Gutiérrez Robledo, et.at. (2016). *La Enfermedad de Alzheimer y Otras Demencias Como Problema Nacional de Salud*.

Hjorth, B. (1970). EEG ANALYSIS BASED ON TIME DOMAIN PROPERTIES. *Electroencephalography and Clinical Neurophysiology* 84(5): 306–10.

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

Li, Lin, et. al. (2010). Detection of Mild Cognitive Impairment Using Image Differences and Clinical Features. *10th IEEE International Conference on*

*Bioinformatics and Bioengineering 2010, BIBE 2010: 106–11.*

Licona, A. E. M., & Close, J. G. (2001). Definición de una red neuronal para clasificación por medio de un programa evolutivo. *Revista Mexicana de Ingeniería Biomédica*, 22, 4–11.

Lopez-caracheo, F., et. al. (2018). Fractal Dimension-based Methodology for Sudden Cardiac Death Prediction. 2018 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC), (Ropec), 1–6.

Lopez-Ramirez, et. al. (2016). EMD-based feature extraction for power quality disturbance classification using moments. *Energies*, 9(7), 1–15.

Maestú, C., et. al. (1999). Magnetoencefalografía : una nueva técnica de diagnóstico funcional en neurociencia, 28(11), 1077–1090.

MathWorks, (2019). <https://la.mathworks.com/products/matlab.html>.

Match, D. J. (2001). Cátedra: Informática Aplicada a la Ingeniería de Procesos- Orientación I Redes Neuronales: Conceptos Básicos y Aplicaciones. Rosario.

Mazaheri, Ali, et. al. (2018). EEG Oscillations during Word Processing Predict MCI Conversion to Alzheimer's Disease. *NeuroImage: Clinical* 17(June 2017): 188–97. <https://doi.org/10.1016/j.nicl.2017.10.009>.

Nieto, N., & Marcela Orozco, D. (2008). El Uso de La Transformada Wavelet Discreta En La Reconstrucción de Señales Senoidales, *Scientia et Technica Año XIV* 38: 381–86.

Obermaier, B., et. al. (2001). Hidden Markov Models for Online Classification of Single Trial EEG Data. *Pattern Recognition Letters* 22(12): 1299–1309.

Pakyari, R. & Balakrishnan, N. (2012). A general-purpose approximate goodness-of-fit test for progressively Type-II censored data, *IEEE Transactions on Reliability*. 61, 238-244.

Pose, M., & Facundo M. (2010). Deterioro Cognitivo Leve. Mild Cognitive Impairment. *Acta Neurol Colomb Suplemento* 263(31).

Poza, J., et. al., (2012). Analysis of Spontaneous MEG Activity in Mild Cognitive Impairment Using the Wavelet Turbulence. : 721–26.

Rafiee, J., et. al., (2011). Wavelet basis functions in biomedical signal processing. *Expert systems with Applications*, 38(5), 6190-6201.

- Rohlf, J. W. (1994). *Modern Physics from alpha to Z0*. (1994 Wiley, Ed.) (ilustrada).
- Soria Olivas, Emilio, et. al. (2003). *Señales y Sistemas En Tiempo Discreto. In Tratamiento Digital de Señales: Problemas y Ejercicios Resueltos*, Madrid, 1–10.
- Stam, C. J. (2010). Journal of the Neurological Sciences Use of magnetoencephalography ( MEG ) to study functional brain networks in neurodegenerative disorders. *Journal of the Neurological Sciences*, 289(1–2), 128–134.
- Timothy, L. T., Krishna, B. M., & Nair, U. (2017). Classification of mild cognitive impairment EEG using combined recurrence and cross recurrence quantification analysis. *International Journal of Psychophysiology*, 120, 86-95.
- Vázquez Rodríguez, P. (2013). *Evaluación termográfica del pie diabético y su asociación con la retinopatía diabética*. Maestría en Instrumentación y Control Automático. Tesis Maestría. Universidad Autónoma de Querétaro.
- Vega Mancilla, S. Y. (2016). *Procesamiento de imágenes termográficas en la detección de cáncer de mama*, Tesis de Maestría, Repositorio de la Universidad Autónoma de Querétaro.
- Vrba, J., & Robinson, S. E. (2001). *Signal Processing in Magnetoencephalography*. Elsevier Science, 25, 249–271.
- Wheless, J. W., et. al. (2004). Magnetoencephalography (MEG) and Magnetic Source Imaging (MSI). *The Neurologist*, 10(3), 138–153.
- Zhang, Y., et. al. (2014). Megnetoencefalografía: mapeo de la dinámica espaciotemporal de la actividad neuronal, 21(1), 45–53.

# Anexos

Valores p obtenidos por ANOVA para las 5  
bandas de frecuencias y los PH

ACTIVIDAD					
	alpha	betha	gamma	delta	theta
Sensor	Probabilidad	Probabilidad	Probabilidad	Probabilidad	Probabilidad
2	0.004863887	0.003991404	1.30E-12	0.938315544	0.001197644
3	5.85E-05	0.138361058	0.151326997	0.025403529	4.10E-07
4	0.011477044	0.000414359	8.11E-06	0.983952644	0.001210734
5	0.059241381	2.11E-06	8.12E-13	0.043096865	0.68972473
6	0.954883144	0.00174063	3.45E-12	0.077063032	0.257343895
7	8.38E-06	0.524314395	0.000585307	0.052970165	3.78E-05
8	5.17E-06	0.95712321	0.004480745	1.80E-05	1.09E-05
9	0.006504935	0.00285866	4.32E-05	5.15E-06	6.59E-05
10	0.477860723	4.73E-08	2.08E-08	0.04837844	0.000851887
11	0.119748325	2.61E-07	2.00E-10	0.869219584	0.003563154
12	0.000312901	0.005473732	1.82E-09	0.550859984	0.000349108
13	5.98E-05	0.389278905	3.99E-05	0.209340224	1.15E-05
14	0.197456405	0.005799236	5.60E-09	0.559712445	0.000801387
15	0.592451634	0.000803596	1.34E-10	0.98960535	0.000123869
16	0.449257127	1.88E-05	5.30E-11	0.49570663	0.035895711
17	0.020452196	2.03E-07	2.83E-12	0.126711506	0.735272593
18	0.886761457	0.002027402	3.40E-11	0.396258197	0.041825537
19	1.19E-05	0.210797691	0.000339257	0.004093627	6.46E-06
20	3.09E-07	0.363273803	8.11E-06	2.12E-08	4.13E-06
21	6.03E-07	0.5746964	0.003840142	1.10E-06	4.12E-06
22	0.000118638	0.006099187	0.000723534	8.56E-05	1.19E-06
23	0.023497772	1.12E-05	2.94E-05	1.48E-05	3.44E-06
24	3.42E-05	5.34E-14	1.63E-06	0.00029765	4.84E-05
25	0.941329125	3.42E-09	4.00E-10	0.108267911	0.000861423
26	0.291905265	6.84E-07	1.08E-09	0.747207772	0.003259921
27	0.003971404	0.00202535	4.70E-08	0.552713885	0.000461632
28	4.05E-05	0.076765224	1.90E-07	0.079556379	1.64E-06
29	0.000465965	0.045800913	5.29E-05	0.330847891	1.37E-07
30	0.812895579	0.00042305	3.74E-13	0.90085935	3.62E-05
31	0.358633534	0.000177526	3.10E-27	0.047681686	3.88E-09
32	0.593731144	4.52E-05	1.27E-10	0.060108117	3.09E-05
33	0.439901851	1.95E-05	1.59E-08	0.196448437	0.00080406
34	0.027866717	3.34E-08	7.75E-12	0.94038562	0.365566266
35	0.895612409	0.001139956	1.12E-09	0.296760767	0.004719659
36	2.84E-06	0.103020776	0.001383984	8.38E-07	2.17E-06
37	3.81E-08	0.047915305	0.003266121	5.27E-10	1.06E-06
38	5.44E-08	0.682491574	0.000598389	6.44E-10	3.75E-07
39	8.45E-07	0.288019026	0.000386551	1.75E-06	6.18E-08
40	1.29E-05	0.005048165	1.42E-05	5.91E-05	2.77E-08
41	0.000929047	0.001682018	0.004066553	2.68E-06	1.15E-08

42	0.196413969	1.60E-08	2.01E-09	5.45E-06	1.90E-06
43	0.469120662	4.95E-08	0.000721476	0.000214378	1.81E-05
44	0.831688561	1.93E-08	1.57E-09	0.114892991	0.000514067
45	0.551808876	3.10E-08	3.03E-11	0.272398982	0.006454935
46	0.780745992	9.25E-07	9.75E-11	0.399711761	0.001559068
47	0.000253343	0.098933493	8.17E-07	0.054995699	3.54E-06
48	1.71E-05	0.026203326	3.99E-09	0.568642437	4.20E-08
49	0.001480896	0.028360909	1.13E-09	0.324223688	1.39E-11
50	0.57357135	0.000259212	1.67E-11	0.398532692	6.04E-07
51	0.08515061	0.017861879	1.94E-09	1.23E-05	7.56E-12
52	0.815720353	0.000962124	6.72E-06	1.56E-05	0.000268639
53	0.381610552	6.12E-06	2.88E-10	0.000652859	6.89E-06
54	0.009981873	2.46E-08	9.67E-11	0.168144878	0.04193861
55	0.948027362	0.000122921	5.75E-08	0.000440152	0.000219492
56	1.23E-05	0.730486151	0.013853453	2.35E-08	1.19E-07
57	1.51E-08	0.122987969	0.022938806	4.22E-10	2.67E-07
58	4.32E-10	0.267016336	0.000251666	5.57E-12	5.04E-09
59	2.97E-09	0.705778416	2.53E-05	1.13E-07	2.28E-10
60	1.55E-08	0.089895284	5.75E-19	0.00032362	2.57E-11
61	1.24E-08	0.595312871	0.383222135	0.000805571	4.43E-11
62	8.11E-05	0.024491542	0.002710642	1.54E-05	8.00E-11
63	0.028251884	5.40E-05	0.00025155	2.98E-06	3.33E-10
64	0.272426686	6.73E-07	2.07E-07	9.78E-06	1.58E-07
65	0.669517388	6.94E-09	2.17E-10	0.000453903	0.000112697
66	0.02966833	4.80E-11	1.77E-11	0.880207985	0.004989202
67	0.043679531	8.97E-09	1.27E-12	0.537174625	0.002484574
68	1.14E-05	0.995920941	0.00075868	4.57E-07	1.78E-06
69	2.04E-06	0.137719959	8.14E-09	0.000827204	1.75E-08
70	3.19E-05	0.348057244	0.00210625	8.30E-06	3.38E-15
71	0.943578656	0.00310848	1.61E-18	0.000418625	2.15E-09
72	0.002240804	0.177217641	4.67E-06	2.89E-17	2.26E-16
73	0.320884427	0.002617632	1.25E-09	3.55E-13	2.00E-12
74	0.670053301	0.001075736	1.22E-08	3.43E-12	1.44E-12
75	0.576475628	7.13E-05	8.98E-07	3.23E-07	1.23E-07
76	0.00205396	1.40E-07	2.77E-14	0.000446272	0.012321114
77	0.710717211	0.000553096	0.000832184	7.83E-09	1.47E-05
78	1.94E-06	0.433280821	0.762669935	2.89E-12	3.89E-08
79	5.52E-09	0.055991508	0.866183333	1.42E-10	3.25E-08
80	5.56E-11	0.046425079	0.333320916	3.13E-09	2.54E-09
81	1.66E-12	0.124827589	0.250621857	2.42E-06	1.42E-11
82	4.57E-12	0.688018439	1.95E-07	0.001236835	6.91E-13
83	3.43E-10	0.943716163	3.58E-07	0.035573699	9.94E-14
84	6.92E-08	0.316482634	4.02E-09	0.080205305	1.52E-13

85	3.60E-05	0.045582003	1.13E-09	2.20E-05	1.15E-14
86	0.003124361	0.000781939	2.06E-06	5.25E-08	8.32E-14
87	0.085304505	1.15E-06	1.70E-08	3.73E-09	1.22E-08
88	0.58234722	7.40E-12	4.54E-11	4.16E-05	1.85E-05
89	0.000881454	6.71E-15	1.72E-12	0.03334576	0.000510622
90	0.141964306	9.61E-07	1.91E-11	0.004888126	3.48E-05
91	2.35E-06	0.204661237	0.056810036	2.17E-10	3.03E-07
92	1.77E-08	0.712089774	0.002189741	1.68E-11	2.72E-09
93	1.22E-06	0.832914358	1.49E-05	1.79E-11	1.81E-12
94	3.53E-05	0.504091646	4.57E-07	1.45E-12	4.90E-15
95	8.24E-07	3.65E-12	1.03E-31	0.017855373	0.906118205
96	0.216763807	1.18E-05	3.07E-09	1.26E-12	2.93E-07
97	0.331418655	0.13347998	0.657371314	1.36E-14	1.38E-09
98	5.23E-06	0.081676453	0.043295997	1.84E-12	3.00E-10
99	1.55E-16	2.82E-11	1.26E-06	9.32E-11	1.46E-12
100	0.075992711	0.017558971	1.40E-05	1.67E-06	7.90E-06
101	5.81E-12	0.002641969	0.379064353	0.0017110834	1.30E-08
102	5.86E-13	0.003960048	0.000677062	0.024918752	4.38E-11
103	8.16E-13	0.100527281	8.13E-08	0.142867092	4.00E-16
104	9.27E-09	0.803276703	9.40E-12	0.150301759	1.62E-18
105	7.73E-07	0.857987187	4.92E-09	0.004544907	4.00E-18
106	4.12E-05	0.193639917	1.11E-07	3.08E-08	8.69E-20
107	0.000168122	0.00020227	3.68E-12	5.38E-11	2.20E-14
108	2.47E-10	0.818801269	0.027417717	1.14E-19	2.40E-12
109	0.04525505	4.63E-17	7.40E-22	8.25E-08	0.000440773
110	0.509183855	2.77E-07	1.35E-13	4.54E-08	3.18E-05
111	6.06E-05	0.473618131	0.000639293	7.26E-12	2.10E-07
112	6.75E-17	1.22E-05	0.022176083	8.50E-19	4.33E-12
113	0.975920903	0.00329654	4.78E-24	6.31E-16	1.61E-06
114	0.73002491	9.65E-05	1.65E-11	1.04E-15	6.03E-10
115	0.000127378	0.25855907	0.196559451	2.04E-14	4.96E-14
116	7.76E-07	7.30E-05	0.229772967	9.25E-10	6.06E-14
117	4.08E-16	1.10E-16	5.16E-05	3.18E-07	1.47E-14
118	0.153009146	0.0359766	1.20E-07	0.00015451	0.000481189
119	1.33E-09	7.59E-05	0.190455531	0.17096687	2.53E-05
120	5.50E-11	9.87E-05	0.005264869	0.395764476	3.62E-06
121	2.90E-12	0.003977993	3.62E-10	0.451041863	9.78E-13
122	1.18E-09	0.161561219	9.28E-16	0.06920431	1.11E-20
123	1.93E-08	0.076183808	1.36E-09	9.68E-05	2.36E-23
124	9.85E-08	0.579638526	2.22E-07	1.33E-09	3.06E-26
125	1.83E-07	0.198880241	9.49E-11	9.31E-14	2.44E-20
126	1.97E-13	0.012975816	0.000515938	8.26E-17	4.02E-20
127	0.214705145	2.18E-09	4.33E-23	6.01E-10	4.03E-06

128	0.000702469	0.003495073	1.85E-10	6.42E-13	3.35E-06
129	2.41E-07	0.543277024	7.26E-07	3.19E-17	4.25E-08
130	2.95E-18	6.84E-08	0.072535949	3.59E-24	1.74E-17
131	0.003464697	0.297894332	7.91E-07	6.57E-20	4.63E-06
132	0.000482534	0.383535518	0.01590354	5.62E-12	3.48E-10
133	2.42E-06	0.010624287	0.156451453	1.11E-05	8.94E-09
134	1.36E-11	1.28E-10	0.271880883	0.000432199	3.83E-08
135	2.44E-17	7.21E-22	0.034808748	0.008988216	0.000111968
136	0.821979218	1.47E-06	3.45E-18	0.01733647	0.318508241
137	8.42E-10	5.59E-05	0.000512676	0.9414563	0.442459386
138	1.22E-12	2.28E-09	0.002950867	0.814793855	0.202910902
139	4.47E-17	1.33E-08	1.11E-05	0.285410218	2.51E-08
140	6.33E-19	1.08E-06	1.86E-08	0.000811817	6.33E-20
141	6.54E-18	3.26E-08	0.000194003	4.62E-07	2.88E-26
142	1.07E-15	0.000676389	1.24E-07	4.00E-12	5.41E-26
143	6.23E-15	0.046877622	2.67E-07	4.24E-14	1.06E-19
144	9.97E-27	9.14E-27	0.650059857	3.72E-16	2.95E-22
145	0.000101998	0.000458054	9.31E-11	7.71E-06	8.32E-11
146	0.000172314	0.009810919	4.34E-08	3.28E-20	5.75E-11
147	1.48E-07	0.543296096	4.74E-07	2.31E-15	6.79E-13

Dirección General de Bibliotecas UAQ

MOVILIDAD					
	Alpha	Betha	Gamma	Delta	Theta
Sensor	Probabilidad	Probabilidad	Probabilidad	Probabilidad	Probabilidad
2	0.406245607	3.12E-14	0.057703119	2.13E-05	0.723808654
3	7.43E-01	0.17413854	0.822151841	7.87E-05	6.27E-01
4	0.555177518	6.57E-16	0.12531232	3.69E-07	0.537641465
5	0.160797985	3.41E-07	0.549071641	4.55E-05	0.383936849
6	0.010823509	5.38E-06	0.420774798	0.000453349	0.585275985
7	0.135501179	0.001283164	0.038404302	2.29E-05	0.456747795
8	0.233903525	0.016250258	0.030293986	2.85E-05	0.145029721
9	0.052607342	0.070961145	0.112836225	2.21E-06	0.422020048
10	0.097647955	0.043487514	0.061989956	2.26E-07	0.753042872
11	0.108098634	3.48E-07	0.588331895	2.24E-07	0.982040616
12	0.461858958	8.24E-11	0.843089284	5.42E-05	0.993537766
13	0.466259318	1.26E-08	0.829811854	5.31E-05	0.861237785
14	0.131595948	1.97E-06	0.518589203	0.000184753	0.64190731
15	0.472159328	4.03E-07	0.589370535	0.005086699	0.461137461
16	0.606448004	1.61E-07	0.966855493	0.00050434	0.503054581
17	0.101850139	8.37E-06	0.390063719	0.038071761	0.027061632
18	0.002276036	0.000172893	0.355016681	0.004014766	0.71175592
19	0.034611723	0.000975007	0.001361472	0.001456166	0.663439977
20	0.006922979	0.072135425	0.009040926	7.86E-05	0.618044719
21	0.008735106	0.317656327	0.043138865	6.76E-05	0.613081164
22	0.000988425	0.284495727	0.694150383	0.004900141	0.069191317
23	0.006931357	0.923703167	0.882508891	7.44E-06	0.340930638
24	0.868267009	0.80805853	0.353623695	3.39E-05	0.469959831
25	0.090083497	0.329683219	0.193668575	2.88E-09	0.724156425
26	0.003122503	0.002852962	0.811694961	2.70E-08	0.79159791
27	0.005818334	0.000367013	0.407609808	4.54E-07	0.249587291
28	0.020906744	2.37E-05	0.535728612	0.000241108	0.640118991
29	0.032143008	4.29E-06	0.573875675	0.000607825	0.410436881
30	0.137197995	3.94E-05	0.57673895	0.003068318	0.238638578
31	0.14799597	4.56E-07	0.240515508	0.010866394	0.864182324
32	0.550098445	0.000544774	0.4850856	0.000894214	0.811106899
33	0.434004024	8.11E-05	0.653041521	0.00607916	0.275494012
34	0.146154855	0.008074863	0.964378858	0.078275945	0.24031269
35	0.002637359	0.032432628	0.090004695	0.008871019	0.546791469
36	0.000257569	0.116980586	2.35E-05	0.034361653	0.741706851
37	0.001954769	0.105412865	0.000712422	0.006698948	0.567505324
38	0.000442212	0.102237032	0.000422929	8.91E-06	0.243271902
39	0.006610827	0.890013047	8.75E-06	1.02E-05	0.112715024

40	0.001042692	0.787302053	0.002079725	0.010749221	0.775950521
41	0.002448588	0.163858369	0.00208064	0.000199557	0.99458727
42	0.021602594	0.317924887	0.359955247	1.73E-08	0.498983682
43	0.040299825	0.733593328	0.048833798	2.44E-08	0.242801521
44	0.007698763	0.677403718	0.466725547	2.69E-10	0.691801932
45	0.001343818	0.103123522	0.381365175	1.31E-05	0.959558909
46	0.000259694	0.016709942	0.031683238	0.000409989	0.949314098
47	0.008462273	0.000174217	0.00270692	0.001204434	0.576000649
48	0.000819853	7.08E-06	0.099444275	0.017932277	0.456373983
49	0.002855387	4.71E-05	0.150511731	0.030543201	0.517336617
50	0.045182671	0.002982097	0.779844394	0.019129876	0.651614759
51	0.237144309	0.000129835	0.006897359	0.002915565	0.994519674
52	0.455333642	0.000170087	0.035939275	0.029442131	0.836118482
53	0.126163471	0.016735445	0.065065716	0.029781328	0.780674313
54	0.0064744	0.171162445	0.127593469	0.130901797	0.200249821
55	8.32E-06	0.999745725	6.06E-05	0.108480669	0.871930843
56	9.81E-06	0.714622081	1.37E-06	0.020754245	0.500596158
57	2.25E-05	0.699494735	2.48E-05	0.003538367	0.309406838
58	0.000802003	0.408604768	5.31E-08	1.26E-05	0.434508991
59	6.75E-05	0.699061118	8.41E-07	5.01E-06	0.49010946
60	1.48E-07	0.470702025	8.68E-11	0.000463697	0.463809541
61	0.000245477	0.383281568	3.97E-07	0.000769539	0.9171027
62	5.70E-05	0.328266865	0.001052595	1.38E-07	0.216713765
63	0.014231615	0.100664413	0.372839808	1.15E-08	0.138499946
64	0.00100165	0.630151694	0.729186262	6.75E-07	0.158603191
65	0.002286048	0.529411818	0.791398053	5.98E-09	0.580934353
66	0.000235602	0.309069196	0.254639413	4.67E-06	0.688150084
67	7.25E-05	0.011627737	0.005766703	0.007755598	0.936960891
68	0.00041845	7.05E-06	0.001991962	5.89E-05	0.483825682
69	6.24E-05	3.02E-06	0.017023455	0.000834168	0.629879441
70	0.000139175	6.05E-05	0.399884427	0.004418312	0.267595741
71	0.010634036	0.00239267	0.056930307	0.049598203	0.609281452
72	0.141926049	0.000708284	0.043983548	0.001883685	0.809180975
73	0.051171162	0.003114993	0.000651965	0.013688336	0.227508121
74	0.033331209	0.008905974	0.002775134	0.03687796	0.363654935
75	0.008765662	0.158882452	0.077581412	0.019003464	0.444841432
76	1.37E-05	0.591857256	0.017441978	0.113251891	0.300700509
77	2.57E-07	0.071216817	1.84E-06	0.17191238	0.943928436
78	1.64E-06	0.163693938	1.71E-10	0.019603062	0.836400126
79	3.60E-05	0.635983927	4.60E-09	0.000157395	0.541044173
80	2.19E-05	0.987774463	9.76E-10	4.47E-06	0.167251449

81	0.001663215	0.475178553	1.56E-13	5.13E-06	0.231912842
82	0.002493346	0.117687649	1.67E-13	0.000463446	0.891164083
83	0.00038286	0.119859752	6.35E-11	0.003074917	0.889319496
84	2.25E-05	0.15263317	9.30E-09	9.19E-05	0.313714592
85	0.000558917	0.96504311	1.22E-06	1.44E-07	0.143716806
86	0.001835347	0.353151993	0.043851225	7.79E-08	0.095886327
87	0.001159891	0.725306193	0.424531651	2.10E-06	0.456977804
88	0.001368491	0.476180491	0.492781227	4.31E-06	0.620785217
89	0.000556711	0.106275724	0.280080889	4.49E-05	0.104130346
90	0.000105537	0.000119757	0.061701079	0.000868558	0.116001477
91	0.000201783	2.46E-09	0.011828218	0.000464871	0.771156159
92	5.91E-07	2.86E-09	0.084621784	3.57E-05	0.912566273
93	1.73E-05	1.95E-06	0.038512802	4.26E-05	0.493394554
94	0.005411629	4.25E-05	0.005448438	0.000712174	0.290494259
95	0.317707895	0.593748105	3.85E-06	0.005603746	0.218309952
96	6.63E-07	0.526858219	5.98E-07	0.016470215	0.384596852
97	1.52E-10	0.007205468	9.44E-10	0.363463973	0.496793759
98	3.10E-07	0.081720367	2.06E-09	0.057233439	0.926470479
99	0.000443566	0.563359217	3.98E-12	0.000335864	0.718161109
100	0.001688508	0.823119257	6.68E-09	4.17E-07	0.292794107
101	0.000689306	0.383232924	3.46E-14	5.67E-06	0.317839876
102	0.003701369	0.008511666	4.47E-15	4.29E-05	0.726542172
103	0.002640013	0.00013321	7.29E-14	0.000826723	0.944398732
104	0.000289847	0.000534334	4.55E-11	0.008450556	0.275615096
105	0.006233814	0.025050461	1.39E-09	0.004275553	0.025271456
106	0.024155172	0.079508429	3.98E-05	6.65E-05	0.027707521
107	0.006488573	0.041056787	0.02881224	7.07E-05	0.105726263
108	0.014060173	0.020509284	0.775825656	0.000115355	0.387900483
109	0.000267425	0.02010014	0.393247476	2.19E-05	0.003762749
110	0.000363019	1.64E-05	0.339515108	7.07E-05	0.001584451
111	0.000850999	7.56E-09	0.861656338	4.13E-05	0.090654923
112	3.21E-10	8.24E-09	0.0017569	0.000368328	0.855930505
113	0.000338804	0.014250491	2.47E-09	1.89E-05	0.28765926
114	3.54E-06	0.457886065	3.54E-15	0.001213579	0.787359373
115	4.23E-08	0.160399823	1.32E-16	0.019815999	0.758014285
116	1.27E-05	0.201169676	1.09E-13	0.005099535	0.651485213
117	0.075421995	0.385513012	1.60E-10	8.53E-05	0.735086553
118	0.067649573	0.215226701	3.39E-11	2.20E-07	0.660943521
119	0.22239278	0.007807664	1.97E-18	1.06E-05	0.505664079
120	0.309972859	1.21E-05	1.20E-20	0.000222584	0.608315557
121	0.078178584	1.43E-07	4.09E-15	0.005936636	0.390025519

122	0.023843906	5.25E-07	1.95E-11	0.04071467	0.064585468
123	0.031007269	0.000463033	2.84E-08	0.012619441	0.003038742
124	0.010279561	0.001164382	4.47E-06	0.000874544	0.000470769
125	0.015938808	0.000245839	0.010310128	0.000428235	0.068487317
126	0.006187574	7.98E-05	0.625304528	1.99E-05	0.065664123
127	0.003447196	0.007496497	0.69200285	2.26E-05	0.000665509
128	0.006484977	3.23E-06	0.838957411	1.51E-05	0.00354358
129	0.000456087	2.65E-09	0.705102099	1.03E-05	0.033080872
130	1.17E-07	1.20E-05	0.166481955	5.57E-06	0.098943657
131	0.034413236	0.009977192	8.31E-07	1.18E-05	0.001506504
132	0.074733942	0.188842367	1.65E-12	0.000754708	0.067646759
133	0.035705294	0.336606702	9.65E-15	0.001883205	0.648956064
134	0.449068342	0.065081549	2.08E-10	0.000162909	0.505029322
135	0.922578616	0.001840355	8.30E-11	2.09E-06	0.330860614
136	0.620749683	0.000271981	1.04E-09	2.32E-07	0.433978536
137	0.014953129	1.33E-07	6.95E-20	0.000190484	0.737114408
138	0.002022902	2.88E-10	1.37E-17	0.002223896	0.477324471
139	0.234971423	5.34E-11	3.23E-15	0.054991965	0.534911416
140	0.224093961	1.32E-10	1.70E-11	0.24480415	0.017850141
141	0.212905424	6.87E-08	2.58E-11	0.068465259	0.000964617
142	0.006113092	9.77E-08	2.94E-08	0.00445505	0.033916215
143	0.002738608	1.40E-09	0.070219902	0.001943634	0.091961511
144	0.019235085	1.93E-09	0.393289528	5.34E-05	0.575726223
145	0.021558819	0.000388649	0.65726826	0.002163352	0.029086839
146	0.049278045	0.000439057	0.266899777	3.78E-16	0.001971136
147	0.005700421	3.10E-05	9.73E-06	5.89E-06	0.001334797

COMPLEJIDAD					
	alpha	betha	gamma	delta	Theta
Sensor	probabilidad	probabilidad	probabilidad	probabilidad	probabilidad
2	0.117034239	0.505015094	0.237590457	5.49E-07	0.633516846
3	7.01E-01	0.460426275	7.32E-02	1.01E-05	8.06E-01
4	0.108707879	0.046651387	8.11E-08	1.76E-08	0.729836795
5	0.690972964	0.841683646	0.006171727	0.002371093	0.741497839
6	0.127006861	0.336057371	0.000784068	0.002343005	0.537405115
7	0.590382703	0.15023744	0.006314538	1.19E-07	0.911321809
8	0.582948848	0.804070955	0.006043821	4.65E-07	0.809934219
9	0.066531001	0.49458076	2.14E-05	2.20E-06	0.52911179
10	0.18164761	0.257268257	1.16E-05	4.53E-08	0.361539804
11	0.754443462	0.527887914	0.003938848	2.48E-10	0.162210228
12	0.925972719	0.748680703	0.000300062	4.39E-07	0.427687694
13	0.307802671	0.35378726	0.084394818	0.000260354	0.883751006
14	0.889675985	0.23352052	0.060620214	0.003971281	0.533082629
15	0.873858703	0.402917233	0.005400414	0.013849926	0.200699855
16	0.678244923	0.957652302	0.010235578	0.020445121	0.982940219
17	0.263479209	0.764823374	0.000261682	0.131745883	0.223977474
18	0.015978058	0.528426332	0.00078419	0.008765757	0.876839144
19	0.331791504	0.524499256	0.000702858	0.000257937	0.809707599
20	0.221897937	0.188965911	0.06463816	3.02E-06	0.558757769
21	0.089009319	0.389657391	0.0027097	6.44E-06	0.683655699
22	0.047619634	0.809881886	3.49E-05	0.021356134	0.0367913
23	0.226392445	0.300372307	5.48E-06	0.000871666	0.047045609
24	0.072087763	0.324137636	0.07556711	0.048262078	0.950025409
25	0.34971655	0.091092279	0.001705785	5.81E-08	0.371018019
26	0.557214877	0.015512175	0.258552791	3.28E-08	0.086917637
27	0.888326857	0.006200295	0.022063531	3.46E-07	0.271016378
28	0.58862263	0.022419475	0.130474469	0.000195773	0.446486167
29	0.230829828	0.201278116	0.00757657	0.000510682	0.222936629
30	0.562593636	0.121043352	0.002128231	0.007070489	0.04517219
31	0.518943815	0.240019077	0.363560041	0.001644703	0.904254446
32	0.285444727	0.779380173	0.245057047	0.001672047	0.744944907
33	0.355626367	0.222838337	0.003490173	0.032127157	0.789219724
34	0.616012354	0.295476091	5.78E-07	0.070025717	0.698001429
35	0.016755628	0.381786639	2.19E-07	0.009892153	0.901652302
36	0.039298938	0.094563228	0.002056148	0.004915399	0.464268414
37	0.62454887	0.460715369	0.010639434	4.06E-05	0.17716935
38	0.687184263	0.433794194	0.019661919	6.24E-07	0.877137321
39	0.594919639	0.436219767	0.009144473	4.83E-05	0.281261451

40	0.254258997	0.395984796	0.004325438	0.073371021	0.242015691
41	0.100965987	0.054562463	1.34E-08	0.014651806	0.438977169
42	0.058149288	0.003911997	3.02E-08	0.000203164	0.49014928
43	0.289571376	0.101126679	9.04E-05	4.25E-05	0.92381556
44	0.377618921	0.05576134	0.126365525	1.05E-07	0.322428047
45	0.371873042	0.022775077	0.050001026	0.000192274	0.357890259
46	0.32693694	0.104678282	0.01749907	0.002621439	0.209345576
47	0.278546134	0.247727962	0.098844246	0.00178995	0.229627633
48	0.489662349	0.263842725	0.132454917	0.037383811	0.063348559
49	0.358858096	0.002034765	0.050541139	0.029560561	0.030173546
50	0.789750425	0.037920012	0.000219795	0.032171265	0.235172475
51	0.681993834	0.111698995	0.042731955	2.91E-05	0.340310435
52	0.080231857	0.326999077	0.044709337	0.00035596	0.960821966
53	0.260482476	0.506968888	0.000863299	0.01858861	0.817956763
54	0.839262589	0.710854615	1.77E-07	0.069818986	0.956011785
55	0.079584561	0.409126717	0.000384004	0.373271058	0.425416118
56	0.05851792	0.074021701	1.73E-05	0.009891284	0.30300682
57	0.671991303	0.406210758	0.004033745	0.000176227	0.246499594
58	0.801497019	0.095974596	0.001296506	8.11E-07	0.157729405
59	0.281384686	0.526269207	0.000602875	0.000154618	0.841661207
60	0.155869799	0.378617411	0.030721017	0.054035458	0.031317876
61	0.554998252	0.173751112	4.78E-07	0.082863138	0.901641988
62	0.04942081	0.02648257	1.84E-09	0.00795526	0.702057192
63	0.019771211	0.020542166	5.69E-07	7.75E-05	0.726442412
64	0.060498075	0.144311337	0.005035594	6.04E-05	0.328694509
65	0.243556776	0.196088968	0.048396197	1.95E-09	0.651810402
66	0.039647806	0.274856054	0.001411247	9.16E-07	0.544912177
67	0.205562224	0.23212098	0.000844912	0.001900413	0.347152284
68	0.885143412	0.94815122	0.000446864	5.09E-05	0.149384533
69	0.241334889	0.149613674	0.038296489	0.000982296	0.005337399
70	0.075761193	0.008753139	0.000169966	0.002957353	0.013305526
71	0.42003016	0.004173567	0.18911671	0.033335561	0.100061123
72	0.919643632	0.334980531	0.097233181	4.29E-06	0.427218508
73	0.454872129	0.346135929	0.011500046	4.25E-05	0.520470412
74	0.152606568	0.104636382	0.001018567	0.001202308	0.327422798
75	0.871982784	0.352170762	3.98E-07	0.008512179	0.727618211
76	0.451144173	0.261841765	8.75E-07	0.043538543	0.738115637
77	0.093333604	0.198296388	8.84E-05	0.317468197	0.522571514
78	0.041579673	0.406938544	0.004204657	0.018281162	0.109407445
79	0.60366789	0.298291509	3.25E-05	0.000320389	0.036334794
80	0.723422871	0.258394033	3.02E-06	8.72E-05	0.698717971

81	0.958260418	0.277489804	1.56E-09	0.000801071	0.933477348
82	0.923095931	0.351440945	0.000186858	0.034424612	0.843174658
83	0.241760882	0.831009265	0.362300719	0.262646125	0.369810637
84	0.122196552	0.190780637	0.008286037	0.047841391	0.87239486
85	0.052996254	0.180496644	0.003615852	0.003840387	0.942239749
86	0.245526324	0.192484763	0.001063557	8.37E-05	0.353428502
87	0.202563545	0.5723396	0.330287316	1.67E-06	0.718510808
88	0.360284264	0.636445792	0.018473387	1.90E-06	0.864077253
89	0.034389179	0.557278609	0.000911412	1.08E-05	0.704442222
90	0.028278561	0.241803916	6.31E-06	5.52E-05	0.665400307
91	0.414519244	0.976644172	7.43E-06	0.000124581	0.525372518
92	0.439663115	0.515283241	2.37E-05	2.98E-05	0.018012122
93	0.073479812	0.041778533	1.66E-06	4.76E-05	0.009590018
94	0.048208609	0.037222312	0.000285315	0.000671421	0.006711033
95	0.795721001	0.003289768	0.194210935	3.10E-05	0.233074224
96	0.282396952	0.001003919	6.26E-10	0.001073666	0.783270001
97	0.184435689	0.035352829	2.58E-05	0.213305256	0.875346529
98	0.191699045	0.454215307	0.009898486	0.067586712	0.276215987
99	0.188863116	0.948625775	0.023554525	0.000517171	0.057543329
100	0.988806218	0.981368588	0.000127797	3.46E-06	0.212281997
101	0.640169605	0.643926935	1.55E-07	0.001006097	0.171480138
102	0.408567565	0.377123768	2.38E-07	0.020111171	0.428410402
103	0.883698427	0.84752233	0.00299375	0.558435032	0.948640816
104	0.348669174	0.833052492	0.4866686	0.750191705	0.531477229
105	0.283625912	0.750638555	0.135191576	0.581294321	0.849559798
106	0.315217731	0.366519681	3.12E-05	0.003930721	0.62268423
107	0.536146557	0.379380108	0.007184763	0.000698435	0.708065479
108	0.58968141	0.429487716	0.017653038	1.25E-06	0.996426951
109	0.060559886	0.781271659	0.003917488	2.65E-07	0.018879797
110	0.000971249	0.141081011	0.000156002	1.52E-05	0.034816866
111	0.059136313	0.927848294	1.18E-05	7.39E-05	0.343447641
112	0.329553592	0.629611675	0.000279883	0.000283914	0.563698143
113	0.243725114	0.007239246	0.048090374	1.17E-05	0.698753117
114	0.212047352	0.003794872	0.000357161	7.44E-05	0.985459594
115	0.159261655	0.005736107	0.017501504	0.003709252	0.714098639
116	0.230311598	0.031445468	0.03605724	0.000536706	0.352923673
117	0.122909041	0.928700695	0.024738539	1.27E-05	0.232426428
118	0.994985486	0.141961279	0.022226537	8.19E-07	0.422169312
119	0.729786255	0.962733528	4.83E-07	0.002431879	0.179824368
120	0.389500904	0.329232197	7.89E-07	0.123249315	0.204168467
121	0.60659734	0.402014349	0.000421002	0.867673814	0.531195288

122	0.642693205	0.786616613	0.014614421	0.631508686	0.52028315
123	0.424305985	0.474140593	1.67E-05	0.615235882	0.341166093
124	0.243927003	0.124744078	8.20E-06	0.050653884	0.063894527
125	0.289297694	0.224488275	0.010971883	0.001142911	0.127730235
126	0.218043735	0.336094649	0.157679536	2.07E-05	0.602868452
127	0.06712711	0.883411154	0.00504889	7.25E-06	0.003464405
128	0.103987566	0.916208886	5.57E-05	6.69E-06	0.001487891
129	0.208600273	0.562404704	7.49E-08	4.00E-06	0.005515358
130	0.591434465	0.363882921	1.06E-08	1.51E-05	0.070602113
131	0.959588463	0.142038746	4.34E-06	1.61E-06	0.367094786
132	0.272143928	0.005978591	0.012719387	5.42E-06	0.816926295
133	0.250966648	0.006458601	0.144196917	9.87E-05	0.835100605
134	0.336827258	0.145761766	0.005597821	9.24E-06	0.366885101
135	0.300385373	0.947460709	0.053434226	6.66E-06	0.013020122
136	0.881950197	0.502153475	0.001976872	2.87E-06	0.254749588
137	0.280540414	0.608176879	3.97E-08	0.005290724	0.092232658
138	0.895801787	0.307505837	8.80E-08	0.460263916	0.205695475
139	0.971512395	0.682676232	0.001090161	0.512459719	0.414949528
140	0.665742602	0.588454084	0.066354167	0.20490852	0.150804733
141	0.706745624	0.655208512	0.230639454	0.947606707	0.321619232
142	0.168617176	0.307084251	0.016131747	0.049841822	0.149222495
143	0.128171559	0.219896693	0.120787052	0.010120108	0.185022366
144	0.073261975	0.667288746	0.653286942	0.000638537	0.976734216
145	0.226108931	0.435639387	0.001756887	0.020173751	0.01673797
146	0.324460868	0.974278786	6.47E-05	2.80E-14	0.001393257
147	0.624387473	0.712733047	0.07793179	2.33E-06	0.001825513