



**Institución Universitaria**

**Metodología para la selección automática de  
características de señales EEG utilizando  
algoritmos de aprendizaje de máquina  
aplicado al reconocimiento del procesamiento  
emocional en excombatientes.**

**Daniel Alexis Nieto Mora**

Instituto Tecnológico Metropolitano  
Facultad de Ingenierías  
Medellín, Colombia  
2020

**Metodología para la selección automática de características de señales EEG utilizando algoritmos de aprendizaje de máquina aplicado al reconocimiento del procesamiento emocional en excombatientes.**

**Daniel Alexis Nieto Mora**

Tesis presentada como requisito parcial para optar al título de:  
**Magister en Automatización y Control Industrial**

Director:

Ph.D. Juan David Martínez Vargas

Ph.D. Leonardo Duque Muñoz

Grupo de Investigación:

Máquinas Inteligentes y Reconocimiento de Patrones

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2020



**(Dedicatoria)**

A mis padres Alexander Nieto y Yancelli Mora, mis hermanas Valentina y Stefanía y a mi abuela Nohemí Ramirez, quienes desde el inicio de mi formación académica apoyaron de innumerables formas mis deseos por afrontar la vida desde el conocimiento y el saber.



## Agradecimientos.

Quisiera agradecer inicialmente a mis asesores de tesis Juan David Martínez Vargas y Leonardo Duque Muñoz quienes acompañaron el desarrollo de este trabajo de principio a fin, brindándome los conocimientos requeridos para realizar una investigación de calidad.

También quiero agradecer a los investigadores de los grupos GISAME y SISTEMIC de la Universidad de Antioquia quienes amablemente nos facilitaron los datos utilizados, y quienes siempre estuvieron dispuestos a contribuir en el buen desarrollo de la investigación aportando sus conceptos y saberes.

Agradezco a la agencia de educación superior de medellín (SAPIENCIA) quienes financiaron parte de mis estudios, y a la Universidad Noruega de Ciencia y Tecnología (NTNU), especialmente a la doctora Marta Molinas Cabrera y el doctorando Andrés Soler Guevara por permitirme realizar una estancia de investigación en su reconocido laboratorio.

Por último quiero agradecer al Instituto Tecnológico Metropolitano por brindar a nosotros los estudiantes de posgrados la posibilidad de iniciarnos en el mundo de la docencia, a través de las cátedras especializadas y directas, y por el programa de pasantías que financió mi instancia de investigación en Noruega.



# Resumen

Los diferentes procesos de desmovilización y reincorporación a la vida en sociedad han conseguido que miles de excombatientes de diferentes grupos armados busquen retornar a la vida civil. Sin embargo, se ha reportado en la literatura que la experiencia de guerra causa en estas personas trastornos y desordenes psicológicos que les impiden completar su proceso de reintegración. Se ha encontrado en la literatura distintas alternativas para estudiar el comportamiento de personas que han participado en el conflicto armado, algunos de estos métodos abordan el problema desde la psicología, haciendo entrevistas y encuestas asistidas por expertos. En los últimos años estos estudios han sido apoyados cada vez más con técnicas de aprendizaje de máquina, haciendo análisis de registros electroencefalográficos (EEG), ya que el uso de los sensores para la adquisición de estas señales tiene un costo reducido y la prueba es no invasiva, lo cual facilita poner en práctica esta técnica. Además, los registros EEG tienen una muy buena resolución temporal (milisegundos), y mediante su análisis se ha mostrado una mejoría considerable en el rendimiento de la tarea de clasificación entre las clases (controles y excombatientes).

La metodología desarrollada fue probada en dos bases de datos que evalúan el procesamiento emocional de controles y sujetos expuesto al conflicto. El primer conjunto de datos tiene como objetivo discriminar entre las clases utilizando una tarea de valencia contextual, y el segundo utiliza estímulos con imágenes flanqueadas para distinguir entre sujetos que han recibido alta exposición y sujetos con baja exposición al conflicto armado colombiano.

En esta tesis se plantea una metodología que utiliza dos formas de caracterización de registros EEG utilizando combinación de la representación de estas señales en tiempo, frecuencia y espacio. El primero de los métodos utiliza caracterización en tiempo-frecuencia empleando la transformada Wavelet en su forma discreta para descomponer las señales EEG. Después se extrajeron datos estadísticos sobre los coeficientes de detalle y aproximación, los cuales fueron utilizados como características. Por otro lado, se utilizó también información en frecuencia-espacio, haciendo análisis de conectividad funcional y aplicando la teoría de grafos a las conexiones encontradas en diferentes escalas de conectividad. Adicionalmente, se realizó un análisis de relevancia con tres métodos que permiten brindar mayor interpretabilidad a los resultados obtenidos y obtener una mayor tasa de clasificación al utilizar las características más relevantes. Los métodos utilizados son búsqueda exhaustiva, aprendizaje multi kernel (MKL), y selección de características con ANOVA. Finalmente, se realiza la clasificación de las características con una máquina de vectores de soporte, obteniendo el puntaje F1 como medida de evaluación.

Los resultados sugieren que existe diferencia entre las clases de la tarea denominada como

*flanker*, consiguiendo hasta 94% de puntaje F1 en la tarea de clasificación. Para el caso de valencia contextual se tiene hasta un 85% en el puntaje F1 combinando la información espectral con MKL. En general, se obtuvo que el análisis por bandas de frecuencia obtiene a lo largo de las pruebas los resultados más altos, aunque el análisis de relevancia con MKL es también consistente, y se observó que la banda en donde se dieron los mejores resultados fue en los rangos de frecuencia altos de  $\beta$ . Esto sugiere que los controles y pacientes expuestos al conflicto presentan una diferencia en los niveles de concentración y atención.

**Palabras clave:** Aprendizaje de Máquina, Bandas de Frecuencia, Conectividad de EEG, Kernels, MKL, Procesamiento Emocional, Señales EEG, SVM, Wavelets.

# Abstract

The different demobilization process have bring thousands of colombian excombatants in searching for return to the civil life. However, it is reported that the war experience produces psychological disorders that prevent completing their reintegration process. The literature shows several alternatives to study the behavior of people with war experiences, some of these methods address the problem using psychology, i.e., making interviews by experts. In the last years, the studies have been helped by artificial intelligence using electroencephalographic (EEG) signals, due to EEG is a non-invasive and low-cost study, which facilitates put into practice this technique. Also, EEG signals have an adequate time resolution (milliseconds), and with its analysis the classification task between excombatants and controls have improved.

The developed methodology was evaluated in two different datasets, both assess the emotion processing in controls and subjects with high exposure to the armed conflict. The first dataset aims to discriminate between classes using contextual valence. The second dataset uses stimuli with flanker images to distinguish between subjects that have been highly exposed to the conflict and subjects with low exposure.

In this thesis it is developed a methodology that uses two ways of EEG characterization making combinations of the representations of these signals in different domains as time, frequency, and space. The first approach uses features in time-frequency domain employing decomposition with multiple discrete wavelets, then, statistics features are extracted from the decomposition coefficients. On the other hand, it is used frequency-space information making a functional connectivity analysis and applying graph theory over the connections found on the connectivity. Also, it was made a feature relevance analysis through three methods that give better interpretability of the data. The relevance analysis methods used are: Exhaustive search with frequency bands, weights assignment with MKL, and ANOVA feature selection technique. Finally, the classification was made using SVM, and evaluated with the F1 score metric.

Results suggest that there is a difference between the classes in the flanker dataset, reaching a 94% of F1 score. For the contextual valence dataset, the F1 score achieves an 85% by combining the spectral information with MKL. In general the exhaustive search method showed the best scores among several tests, nevertheless the relevance analysis with MKL is the most regular method. Finally, it is shown that higher frequencies in the beta band are the most relevant ones, suggesting that the controls and subjects present differences in the concentration and attention level.

**Keywords:** EEG Connectivity, EEG Signals, Emotion Processing, Frequency Bands,

**Kernels, Machine Learning, SVM, Wavelets.**



# Contenido

<b>Agradecimientos</b>	<b>v</b>
<b>Resumen</b>	<b>vii</b>
<b>Abstract</b>	<b>ix</b>
<b>1 Antecedentes</b>	<b>6</b>
1.1 Introducción.	6
1.2 Planteamiento del Problema.	8
1.3 Hipótesis.	10
1.4 Objetivos.	11
1.4.1 Objetivo Principal:	11
1.4.2 Objetivos Específicos:	11
1.5 Publicaciones y Productos de Investigación.	11
<b>2 Marco Teórico.</b>	<b>12</b>
2.1 Electroencefalografía (EEG).	12
2.1.1 Las Neuronas y el Potencial de Acción.	12
2.1.2 Señales Electroencefalográficas.	14
2.1.3 Ritmos del EEG.	15
2.1.4 EEG en el Diagnóstico de Trastornos y Enfermedades de Origen Neurológico.	17
2.1.5 Reconocimiento de Emociones.	18
2.2 Aprendizaje De Máquina.	19
2.2.1 Definición.	19
2.2.2 Aprendizaje Supervisado.	19
2.2.3 Aprendizaje de Máquina Aplicado al Procesamiento de Señales EEG.	20
2.3 Sumario.	21
<b>3 Descripción de la Base de Datos de Controles y Excombatientes, y Metodología de Preprocesamiento</b>	<b>22</b>
3.1 Base de Datos.	22
3.1.1 Valencia Contextual.	22
3.1.2 <i>Flanker</i> .	24

3.2	Preprocesamiento. . . . .	27
3.2.1	Referenciación y Filtrado de las Señales EEG. . . . .	27
3.2.2	Análisis de Componentes Independientes ICA. . . . .	31
3.2.3	Selección de Componentes Ruidosos. . . . .	33
3.2.4	Reparación de Épocas Defectuosas. . . . .	35
3.3	Sumario. . . . .	37
<b>4</b>	<b>Caracterización de Registros Electroencefalográficos</b>	<b>38</b>
4.1	Introducción. . . . .	38
4.2	Wavelets. . . . .	39
4.3	Análisis de Conectividad. . . . .	42
4.3.1	Coficiente de la Coherencia. . . . .	43
4.3.2	Parte Imaginaria de la Coherencia. . . . .	44
4.3.3	Valor de Bloqueo de Fase. . . . .	44
4.4	Teoría de Grafos. . . . .	44
4.4.1	Métricas Globales. . . . .	45
4.4.2	Métricas Locales. . . . .	45
4.5	Sumario. . . . .	46
<b>5</b>	<b>Clasificación y Análisis de Relevancia</b>	<b>47</b>
5.1	Introducción. . . . .	47
5.2	Teoría de Kernels. . . . .	48
5.2.1	Definición. . . . .	48
5.2.2	Kernel Definido Positivo. . . . .	48
5.2.3	Alineación de Kernels. . . . .	49
5.2.4	Centrado de Kernels. . . . .	49
5.2.5	Aprendizaje Multi Kernel. . . . .	49
5.3	Máquinas de Vectores de Soporte. . . . .	52
5.4	Métricas de Evaluación. . . . .	55
5.5	Sumario. . . . .	57
<b>6</b>	<b>Desarrollo Metodológico.</b>	<b>58</b>
6.1	Introducción. . . . .	58
6.2	Preproceso. . . . .	60
6.3	Caracterización. . . . .	61
6.3.1	Características Estadísticas del EEG Utilizando Wavelets. . . . .	62
6.3.2	Caracterización Utilizando Conectividad y Grafos. . . . .	65
6.4	Relevancia y Clasificación. . . . .	67
6.4.1	Búsqueda exhaustiva. . . . .	68
6.4.2	Asignación de Pesos a Través de MKL. . . . .	69
6.4.3	Selección de Características. . . . .	70

---

6.4.4	Clasificación. . . . .	71
6.5	Sumario. . . . .	73
<b>7</b>	<b>Resultados.</b>	<b>74</b>
7.1	Introducción. . . . .	74
7.2	Resultados de la Clasificación Utilizando Caracterización con Wavelets. . . . .	74
7.3	Resultados de la Clasificación Utilizando Medidas de Conectividad. . . . .	81
7.4	Sumario. . . . .	86
<b>8</b>	<b>Conclusiones y Trabajo Futuro.</b>	<b>90</b>
	<b>Bibliografía</b>	<b>92</b>

# Lista de Figuras

1-1	Cifras de Desmovilizados Resportadas por la ARN en 2019. . . . .	7
2-1	Representación de la Estructura Básica de la Neurona. Editado de <a href="https://www.freepik.com/vectors/">https://www.freepik.com/vectors/</a>	
2-2	Señal Electroencefalográfica en el Dominio del Tiempo Grabado por 20 Electro- trodos. . . . .	16
2-3	ritmos del EEG y su Relación con el Estado de Concentración o Vigilia. . . .	17
2-4	Estructura Metodológica del Estudio de Señales EEG Utilizando Aprendizaje de Máquina. . . . .	20
3-1	Tarea Diseñada Para la Adquisición de las Señales EEG en la Tarea de Va- lencia Contextual Mediante la Presentación de Imágenes IAPS. . . . .	23
3-2	Electrodos Utilizados por el Equipo NeuroScan EEG SynAmps2 y su Ubica- ción. . . . .	24
3-3	Prueba Diseñada Bajo el Paradigma de Presentación de Estímulos Visuales con Imágenes Flanqueadas. . . . .	25
3-4	Representación del contenido y posición en cada uno de los tipos de imágenes presentados durante el estímulo. . . . .	26
3-5	Re-referenciación en el Potencial de los Canales EEG Utilizando Como Nueva Referencia el Valor Medio de Todos los Canales. . . . .	28
3-6	Firma EEG Procesada en 20 Canales Utilizando un Filtro Pasa Bandas Tipo FIR. . . . .	30
3-7	Correlación de Componentes Independientes y Canales HEO Y VEO. . . . .	34
3-8	Fuentes de los Componentes Altamente Correlacionados con los Canales de Referencia de Artefactos EOG. . . . .	35
3-9	Efecto de la Reparación de Épocas en los Canales Frontales de un Sujeto. . .	36
4-1	a) Señal Sinusoidal Multi Espectral, b) Espectrograma de la Señal en a) Trans- formada por la Wavelet <i>Mexican Hat</i> . . . . .	40
4-2	Descomposición del EEG en sus Coeficientes de Aproximación y Detalle. . .	41
4-3	Representación en Coordenadas Polares de una Señal en el Dominio de la Frecuencia. . . . .	43
5-1	Separación de Clases Utilizando Máquinas de Vectores de Soporte. . . . .	53
5-2	Matriz de Confusión Para Clasificación Binaria. . . . .	55

---

<b>6-1</b>	Mapa Conceptual del Desarrollo Metodológico de la Tesis. . . . .	59
<b>6-2</b>	Regiones de Interés Utilizadas en: a) Valencia Contextual, b) <i>Flanker</i> . . . . .	62
<b>6-3</b>	Descomposición por Niveles Utilizando la Transformada Discreta de Wavelet. . . . .	63
<b>6-4</b>	Potencial Evocado de las Señales EEG en: a) Un Control de la Base de Datos de <i>Flanker</i> , b) Un Caso de la Base de Datos de <i>Flanker</i> . . . . .	64
<b>6-5</b>	Gráficos de conectividad para un caso de los datos de valencia contextual con umbral de binarización en 0.7. . . . .	66
<b>6-6</b>	Kernels Generados a Partir de la Caracterización en Bandas de Frecuencia. . . . .	68
<b>6-7</b>	Diagrama de Cajas y Bigotes Sobre la Asignación de Pesos a los Kernel Creados por Banda de Frecuencia. . . . .	69
<b>6-8</b>	Combinación de los Kernels por Bandas de Frecuencia Utilizando MKL. . . . .	70
<b>6-9</b>	Entrenamiento del Clasificador Utilizando Validación Cruzada. . . . .	72
<b>7-1</b>	Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Aplicando Búsqueda exhaustiva. . . . .	75
<b>7-2</b>	Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Aplicando Selección de Características. . . . .	76
<b>7-3</b>	Comparación del Puntaje F1 Alcanzado por los Diferentes Métodos de Relevancia Utilizando Wavelets en Datos de Valencia Contextual. . . . .	77
<b>7-4</b>	Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de <i>Flanker</i> Aplicando Búsqueda exhaustiva. . . . .	78
<b>7-5</b>	Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de <i>Flanker</i> Aplicando Selección de Características. . . . .	79
<b>7-6</b>	Comparación del Puntaje F1 Alcanzado por los Diferentes Métodos de Relevancia Utilizando Wavelets en Datos de <i>Flanker</i> . . . . .	80
<b>7-7</b>	Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de Valencia Contextual Utilizando Búsqueda exhaustiva. . . . .	81
<b>7-8</b>	Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Utilizando Selección de Características. . . . .	82
<b>7-9</b>	Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Comparando los Métodos de Relevancia Utilizados. . . . .	83
<b>7-10</b>	Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de <i>Flanker</i> Comparando los Métodos de Relevancia Utilizados. . . . .	84
<b>7-11</b>	Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de <i>Flanker</i> Comparando los Métodos de Relevancia Utilizados. . . . .	85
<b>7-12</b>	Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de <i>Flanker</i> Comparando los Métodos de Relevancia Utilizados. . . . .	86
<b>7-13</b>	Resultados Comparativos Entre Wavelets y Conectividad Para los Datos de Valencia Contextual Utilizando MKL Como Mejor Método de Relevancia. . . . .	88

<b>7-14</b> Resultados Comparativos Entre Wavelets y Conectividad Para los Datos de <i>Flanker</i> Utilizando MKL Como Mejor Método de Relevancia. . . . .	89
--	----

# Lista de Tablas

<b>2-1</b>	Capas Entre el Cerebro y el Cuero Cabelludo, Sus Tamaños y Resistividades.	15
<b>3-1</b>	Descripción Demográfica Y Análisis Estadístico de las Clases Asignadas a los Sujetos de Estudio. . . . .	23
<b>3-2</b>	Artefactos Internos y Externos del EEG. . . . .	27
<b>3-3</b>	Criterios Para la Selección de Componentes Ruidosos . . . . .	34
<b>6-1</b>	Total de Características Utilizadas en Cada Método de Caracterización . . .	71

# 1 Antecedentes

## 1.1. Introducción.

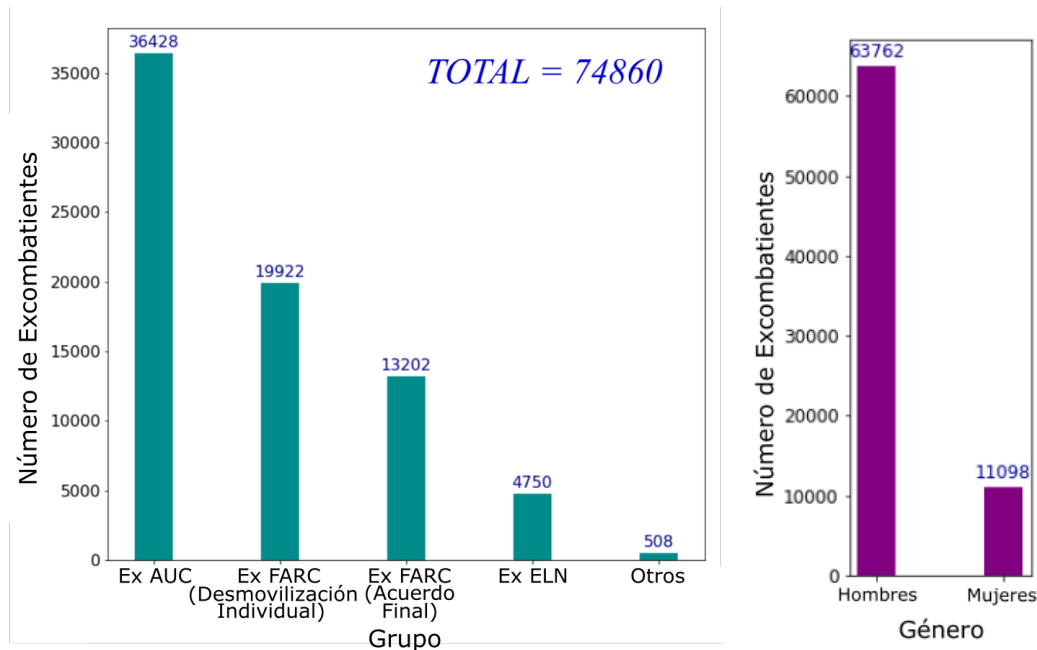
El conflicto armado en Colombia es una problemática que tiene más de 50 años. Durante este período se han hecho partícipes diferentes grupos y organizaciones criminales con fines de diferente índole, entre estos se hacen puntuales los fines políticos, el narcotráfico, control de territorios y enriquecimiento ilícito a través de múltiples prácticas ilícitas [99]. En este conflicto se exhibe además el grupo armado ilegal más antiguo de la historia, las FARC, que a 2015 contaba con 6230 combatientes [22]. Al finalizar el proceso de paz que concluyó en 2016, muchos de estos combatientes se acogieron a los procesos de reinserción a la vida civil.

Según la Agencia Colombiana para la Reintegración (ACR), en su guía de aplicación denominada Política Nacional de Reintegración Social y Económica PRSE, se estimó que al finalizar el primer trimestre del 2014 se tenían 5296 personas en el proceso de reintegración, y se especifica que desde el 2003 más de 56400 personas han dejado las armas, no todos de los mismos grupos protagonistas del conflicto, ni de la misma rama ideológica, lo cual es un punto crítico a evaluar en los planes de reintegración social.

La Agencia Nacional Para la Reinserción y Normalización (ARN) estima que hacia el 2014 en Colombia hubo una cifra significativa de desmovilizados con respecto a los años anteriores, de los 56171 individuos que se acogieron al proceso de paz y que dejaron las armas, 46896 iniciaron la reintegración [101], lo que da una idea de la magnitud del proceso de desmovilización y reintegración, en donde las estadísticas reflejan que el 83 % de los actores involucrados están dispuestos a iniciar el proceso. También se debe tener en cuenta que los grupos de post desmovilización aportan un gran número de personas a nuevos grupos ilegales como las bandas criminales, articulaciones delictivas que operan principalmente desde regiones rurales como el Urabá antioqueño, dedicadas al narcotráfico, extorsión a empresas y negocios, y que son resultado de un mal proceso de reinserción, dado que del total de ex combatientes en proceso de reincorporación, 12186 abandonaron el programa por ausentismo, pérdida de beneficios o por solicitud propia [101].

Los últimos documentos revelados por la ARN en 2019 muestran la cantidad de desmovilizados luego de la finalización del proceso de paz. En la Figura 1-1 se pueden ver estas cifras discriminadas por grupo y género.





**Figura 1-1:** Cifras de Desmovilizados Reportadas por la ARN en 2019.

Las cifras exponen que hay una gran población que ha abandonado la vía armada y está dispuesta a retomar labores en sociedad, esto gracias a los múltiples acuerdos que se han logrado entre grupos armados y el gobierno, y con ello, se ha hecho indispensable un plan de reincorporación y aprovechamiento de las personas que vuelven a la sociedad, para lo cual se han implementado diferentes programas como el DDR, siglas del proceso de Desarme, Desmovilización y Reintegración a la vida civil de excombatientes, proceso inicializado en el país hace varios años con algunos grupos, y que la Organización de Naciones Unidas (ONU) describe como *remoción de armas de las manos de los combatientes, el retiro de los combatientes de estructuras militares, y la asistencia a estos para reintegrarse social y económicamente en la sociedad mediante formas de vida civiles* [82]. La justicia transicional y el PRSE son también mecanismos diseñados por el gobierno que pretenden motivar a que las personas vuelvan a la vida civil de forma exitosa, brindándoles las mínimas garantías de supervivencia como la vivienda y vinculación a trabajos dignos. Con este fin, se han realizado actualmente alianzas con algunas compañías en pro de incentivar la integración de estas personas a la vida laboral.

Sin embargo, como resultado de investigaciones acerca de los excombatientes y sus condiciones de salud física y mental luego de volver de la guerra, se ha mostrado que uno de los principales factores que interviene en la reincorporación, son sus cambios en el procesamiento de emociones, lo cual interviene directamente en el comportamiento de los individuos, ya que como se describe en [96], existe una relación entre el procesamiento emocional y el desempeño en la cognición social que aborda facultades como la empatía, las cuales son de vital importancia para un reacondicionamiento satisfactorio. Dada esta problemática, esta

investigación pretende abordar el proceso de diagnóstico de patrones en el procesamiento de emociones de los excombatientes en Colombia desde un enfoque ingenieril, poniendo a disposición herramientas que trabajen de forma conjunta con las labores sociales y procesos de reacondicionamiento psicológico de los actores involucrados, para de esta forma hallar una calibración en el diagnóstico de dificultades de procesamiento emocional en desmovilizados.

En este trabajo, los algoritmos de aprendizaje de máquina basados en señales electroencefalográficas son utilizados para identificar características determinantes en la forma de procesar emociones de los individuos. Estos algoritmos han sido ampliamente utilizados en el estado del arte en múltiples tareas y han mostrado excelentes desempeños [76].

El aprendizaje de máquina es una disciplina científica que se deriva de la inteligencia artificial (AI por sus siglas en inglés), la cual se encarga de predecir comportamientos en un conjunto de datos basado en modelos estadísticos, extrayendo de dichos datos información que sería muy compleja obtener por cálculos humanos debido a la dificultad computacional y el volumen de datos que usualmente se requiere.

Algunos de los temas con mayor investigación en los últimos años visto desde el aprendizaje de máquina giran en torno a resolución de problemas como detección eficiente del habla [38, 79, 69], incluso extrayendo características para poder determinar el estado emocional de un individuo por medio de su voz [75], clasificación entre estados emocionales como disgusto, ansiedad o felicidad [45], así como también se investiga en el reconocimiento de textos escritos a mano [17, 51], y se trabaja profundamente en algunas ramas vanguardistas y de aplicación recurrente en la vida cotidiana como la seguridad informática, la minería de datos [9], e interfaces de interacción entre hombre y máquina a través de conectividad cerebral BCI [92, 132].

## 1.2. Planteamiento del Problema.

En la literatura se han encontrado diversas alternativas para analizar el procesamiento emocional de los seres humanos. Algunas de estas metodologías abordan la problemática desde un punto de vista netamente psicológico, en donde se han desarrollado procedimientos como las entrevistas de diagnóstico estandarizadas, las cuales requieren personal que previamente ha recibido capacitaciones intensivas durante tiempos medios o prolongados y que cuenta con experiencia para llevar a cabo el procedimiento [107], entre ellas las entrevistas clínicas estructuradas y la escala de trastorno de estrés postraumático supervisada por personal médico (CAPS) [133]. Recientemente se han ido introduciendo nuevos procedimientos haciendo uso del análisis a partir de las señales electroencefalográficas de los pacientes, algunas de ellas apoyadas en algoritmos de aprendizaje de máquina [100, 99] y otras en técnicas alternativas como el modelo lineal multinivel [40]. Los trabajos que recurren a la electroencefalografía

han mostrado una mejoría en el rendimiento de la tarea comparado con las entrevistas estructuradas. Por otra parte, los registros EEG resultan ser una técnica efectiva, dado que es una prueba no invasiva y de bajo costo, lo que la convierte en una alternativa viable desde el punto de vista médico. Adicional a esto, tiene una alta resolución en el tiempo (en escala de milisegundos), lo que la vuelve factible para realizar procesamiento y análisis en el ámbito ingenieril.

La adquisición de los registros EEG se diversifica según las condiciones del paciente y repetitividad de la misma. Uno de los procedimientos ampliamente utilizados es el de los potenciales evocados o potenciales relacionados a eventos (ERP). Este método consiste en tomar el sujeto de estudio y someterlo a condiciones específicas en un entorno cerrado, con poco ruido, en un asiento confortable, de tal forma que se disminuyan al máximo las perturbaciones inmersas en el ambiente, para posteriormente tomar los registros mientras se le presentan estímulos que se espera sean percibidos en forma de impulsos eléctricos en las mediciones que luego son tratadas y estudiadas. Normalmente estos estímulos corresponden a imágenes [90, 16], sonidos [61] e incluso la percepción del dolor [115].

Existe gran cantidad de trabajos dedicados al tratamiento del EEG en sus diversas etapas y con objetivo en la caracterización, en donde los autores se han esforzado por establecer métodos óptimos y con desempeños superiores a los paradigmas actuales, incluyendo la mejor forma de adquirir los datos evitando perturbaciones debido a estímulos involuntarios como el parpadeo o tensión de músculos [61] y el filtrado de las señales de forma que se elimine el ruido sin sacrificar la adquisición de datos relacionados con la tarea [104, 118]. En la caracterización sobresalen técnicas en el dominio del tiempo, como se hace en [41, 115, 57], frecuencia utilizando modelos matemáticos como la transformada de wavelet [27, 49], transformada de Fourier [2], y adicionalmente se tiene el análisis espacial [50].

Sin importar el dominio en el que se trabajen las señales, es contundente que el éxito del proceso de clasificación se vincula a la selección adecuada de las características que maximizan la frontera de decisión entre las etiquetas de clase. Esto se debe a lo que comúnmente se conoce como la maldición de la dimensión, i.e., donde demasiadas características pueden no aportar información discriminante para la tarea de estudio, dificultando crear una frontera de decisión óptima. Para resolver esta tarea, existen varios métodos de selección de características tanto supervisados basados en entropías utilizando información mutua [68], o en subespacios [32], como no supervisados buscando las características con mayor variabilidad. Sin embargo, aunque dichos métodos permiten seleccionar las características que maximizan la clasificación, estas son seleccionadas de forma individual, haciendo que la evaluación de la relevancia de dichas características una a una por un especialista, se puede tornar en un proceso extenuante, dificultando además la integración del sistema propuesto en un ámbito interdisciplinar, i.e., integrado por psicólogos, sociólogos, ingenieros; entre otros. Para la

tarea en cuestión, es importante que el método de selección propuesto permita interpretar grupos de características, con el fin de generar un biomarcador que sirva para diferenciar entre sujetos control y excombatientes. Para solucionar este problema, surgen métodos como *Multiple Kernel Learning*, que entregan un peso indicando qué tan relevante para la tarea de estudio es cada forma de caracterización, la cual agrupa criterios similares como bandas, características específicas, dominios, etc. Así, estos pesos podrán ser utilizados por psicólogos expertos en procesamiento emocional, para indicar con qué rasgos de los excombatientes se relacionan.

### **1.3. Hipótesis.**

Los trabajos y experiencia de diferentes autores encontrados en la literatura relacionados con la clasificación y extracción de características del EEG, evidencian una gran capacidad de los algoritmos de aprendizaje para la separación y asignación de etiquetas a diferentes conjuntos de individuos relacionados con una tarea específica. Basados en dicha experiencia, se espera que utilizando algoritmos de aprendizaje de máquina, y tomando como información las diferentes caracterizaciones de los registros EEG, es posible desarrollar una metodología que entregue como resultado el método de caracterización que maximiza la discriminación entre sujetos de control y excombatientes, de tal forma que las características extraídas conserven una alta interpretabilidad de los datos obtenidos, y de esta forma contribuir con profesionales de otras disciplinas a determinar las causas y consecuencias de las afectaciones en individuos expuestos a la guerra.

## 1.4. Objetivos.

### 1.4.1. Objetivo Principal:

Desarrollar una metodología basada en algoritmos de aprendizaje de máquina que permita identificar qué tipo de caracterización de los registros EEG maximiza la clasificación entre sujetos de control y excombatientes.

### 1.4.2. Objetivos Específicos:

- Desarrollar una metodología de caracterización de registros EEG utilizando análisis de conectividad en espacio, tiempo y frecuencia, de tal manera que se puedan identificar patrones relacionados con el procesamiento emocional.
- Proponer una metodología de análisis de relevancia utilizando algoritmos de aprendizaje supervisado, que permita relacionar grupos de características de los registros EEG con patrones discriminatorios entre los diferentes sujetos de estudio.
- Evaluar el rendimiento de la caracterización propuesta, con el fin de cuantificar la mejoría en la tarea de discriminación de los grupos de estudio después del análisis de relevancia.

## 1.5. Publicaciones y Productos de Investigación.

A continuación, se muestran los productos de investigación obtenidos con el desarrollo de esta tesis, estos son: 1 artículo publicado en revista Q2, 1 artículo aprobado en revista Q2, y 1 conferencia en evento internacional, los títulos de estos trabajos se listan en el orden mencionado.

- J.D. Martínez-Vargas, D.A. Nieto-Mora, P.A. Muñoz-Gutiérrez, Y.R. Céspedes-Villar, E. Giraldo, G. C.-D. Assessment of Source Connectivity for Emotional States Discrimination. Lecture Notes in Computer Science.
- Nieto Mora, D. A., Giraldo, A., Acosta, J. C., Trujillo, L. C., Céspedes, Y. R., & Martínez Vargaz, J. D. Using Hidden Markov Models for Profiling Driver Behavior Patterns. International Journal of Computer Science.
- Nieto Mora, D. A., Martínez Vargaz, J. D., & Duque Muñoz, L. Emotional States Discrimination Using EEG Based on Channels Connectivity and Multiple Kernel Learning.

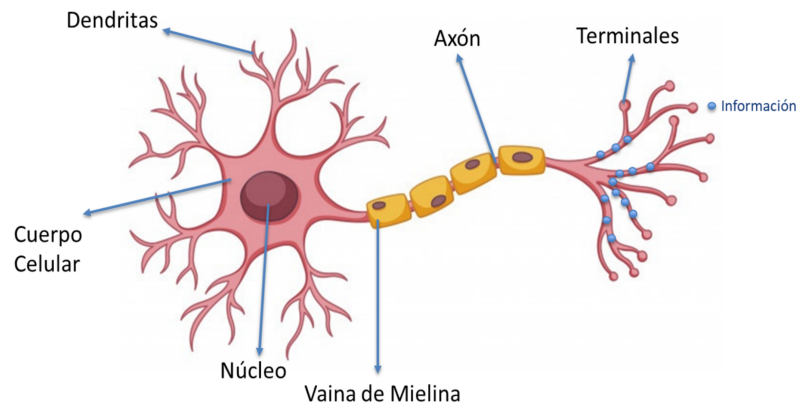
## 2 Marco Teórico.

### 2.1. Electroencefalografía (EEG).

#### 2.1.1. Las Neuronas y el Potencial de Acción.

El cuerpo humano es un sistema complejo compuesto por diferentes procesos y subsistemas que son esenciales para su correcto funcionamiento, mas aún, existe un órgano encargado que centraliza, organiza y distribuye todas las tareas a través de señales biológicas, dicho órgano es el cerebro. El cerebro es la unidad central de procesamiento en los animales y humanos, es el responsable de coordinar otros sistemas como el digestivo, tegumentario, cardiovascular y respiratorio, además, es responsable de los movimientos voluntarios e involuntarios. Una de las funciones más importantes del cerebro es adquirir y procesar toda la información que los humanos reciben a través de los diferentes sentidos, que usualmente son descritos como la visión, el gusto, audición, olfato y tacto [89]. Utilizando los sentidos, el ser humano puede interactuar e interpretar el mundo que lo rodea basado en experiencia, razonamiento, y habilidades físicas y mentales. Por esta razón, el cerebro es considerado la parte más sorprendente y complicada del cuerpo humano [103].

Como sucede en todo el cuerpo, la información en el cerebro es recibida y transmitida a través de células, en este caso, existen unas células especiales llamadas neuronas o células nerviosas (debido a que son las relacionadas con el sistema nervioso), en donde son producidos los Potenciales de Acción o AP (por sus siglas en inglés). Los AP son producidos cuando hay un cambio en la carga eléctrica y polaridad al interior de las células, en este caso las neuronas. Estos AP son producidos en el axón a través de la membrana celular. A continuación, la Figura 2-1 muestra la estructura principal de la neurona.



**Figura 2-1:** Representación de la Estructura Básica de la Neurona. Editado de <https://www.freepik.com/vectors/background>

Para producir un potencial de acción es necesario que las neuronas reciban un estímulo lo suficientemente fuerte para evocarlos, luego el proceso continúa con el intercambio de iones de potasio, calcio, cloruro, sodio y otros iones orgánicos, los cuales causan una variación en el potencial de la membrana dependiendo de la cantidad de cationes (iones positivos) y aniones (iones negativos) en el interior y exterior de esta, sacando a la neurona del estado de reposo, el cual representa una carga negativa de 70 milivoltios (mV) en la membrana celular. Es necesario un estímulo suficientemente fuerte debido a que el potencial producido debe superar el voltaje umbral o voltaje mínimo del límite de reposo en la neurona; luego de alcanzar este valor, normalmente fijado 15 mV por encima del potencial de reposo, es decir en -55 mV, el potencial cambia de negativo a positivo. Para retornar al potencial normal, hay diferentes fases que experimenta la membrana celular, donde se permite la entrada y salida tanto de aniones como de cationes. El sodio, potasio y cloruro son los iones que están involucrados esencialmente en el proceso sináptico, cada uno de estos cuenta con un canal especial, estos canales son poros acuosos cerrados cuyos cambios composicionales son dirigidos por el campo eléctrico en la membrana [52], regulando y controlando de esta manera el ingreso de partículas. De igual manera, cada canal iónico cuenta con compuertas que definen el estado en que se encuentra el canal, los estados pueden ser: activo (abierto o cerrado), inactivo o bloqueado [14]

Las fases del potencial de acción para llegar al estado de reposo se definen como:

- **Depolarización:** esta fase ocurre cuando el potencial en el cuerpo de la neurona comienza a ser menos negativo y se eleva de -70 mV hasta el voltaje de umbral localizado en -55 mV, durante esta fase el canal de sodio pasa a activo y las compuertas se abren, por lo tanto, el sodio fuera de la membrana comienza a fluir hacia el interior. Por esta

razón, la membrana adquiere una carga menos negativa, considerando que el sodio es un ion de carga positiva. Si el estímulo no es lo suficientemente fuerte para producir el potencial de acción, se le llama potencial graduado y la neurona permanece en estado de reposo.

- **Sobre impulso:** en la fase de depolarización, una vez el estímulo consigue alcanzar el umbral de reposo, el potencial siempre aumenta hasta 30 mV, produciendo el sobre impulso, donde la membrana alcanza el máximo potencial positivo. Luego las compuertas de sodio se cierran y el canal pasa a estado inactivo. Esto interrumpe el flujo de los iones de sodio al interior de la célula [103].
- **Repolarización:** en la repolarización la neurona busca recuperar el estado de reposo, para este propósito es esencial la salida de cationes de la membrana celular, por esto, en esta fase las compuertas del canal de potasio pasan a posición abierta para iniciar el flujo de estos cationes al exterior y las de sodio permanecen cerradas. Es necesario tener en cuenta que los canales de potasio abren y cierran a menor velocidad que los de sodio, lo cual provoca la fase de hiperpolarización, previa a la recuperación del estado de reposo.
- **Hiperpolarización:** debido a que los canales de potasio trabajan lentamente, la membrana alcanza nuevamente su potencial negativo, pero sobrepasa el voltaje normal de reposo, impidiendo alcanzar el equilibrio electroquímico, ya que el flujo de carga negativa no es interrumpido inmediatamente. Para alcanzar el potencial de reposo las bombas de sodio y potasio trabajan extrayendo sodio y permitiendo la entrada de potasio.
- **Estado de Reposo:** luego de la hiperpolarización, la membrana alcanza el equilibrio electroquímico y la neurona no puede recibir un nuevo estímulo hasta después de 2 milisegundos. Durante esta fase los canales permanecen cerrados y las bombas mantienen el desequilibrio iónico intercambiando sodio y potasio [114].

### 2.1.2. Señales Electroencefalográficas.

El proceso secuencial de apertura y cierre de los canales iónicos es reflejado en el cambio del potencial sobre cada vaina de mielina a través del axón, el cual finalmente alcanza las terminales sinápticas donde otras neuronas son conectadas [7]. Este grupo de neuronas crean redes en el cerebro, y las señales eléctricas son generadas por la creación masiva y el intercambio de potenciales de acción que producen un voltaje medible, el cual es grabado utilizando electrodos distribuidos sobre el cuero cabelludo, a este estudio se le conoce como electroencefalografía.



Las señales electroencefalograficas, comúnmente conocidas como EEG por su abreviación, son consecuencia de la información transmitida y recibida en el cerebro a través de las células nerviosas. El proceso sináptico genera un campo eléctrico medible utilizando EEG, los electrodos toman medidas extracelularmente con una resolución temporal de milisegundos, permitiendo hacer interpretaciones sobre las faces de la comunicación neuronal [24]. A pesar de que las señales de los AP están en el rango de los milivoltios, las medidas captadas por los electrodos son de microvoltios, esto se debe a que entre la superficie craneal y el punto de origen de los AP existen diferentes capas que reducen la intensidad del campo eléctrico. Algunas de estas capas, su espesor y resistividad se muestran en la Tabla 2-1:

Capa	Espesor (cm)	Resistividad( $\Omega$ )
Cuero Cabelludo	0.3-0.5	0.3-0.4
Cráneo	0.3-0.7	10-25
Corteza	0.1-0.3	0.05-0.150

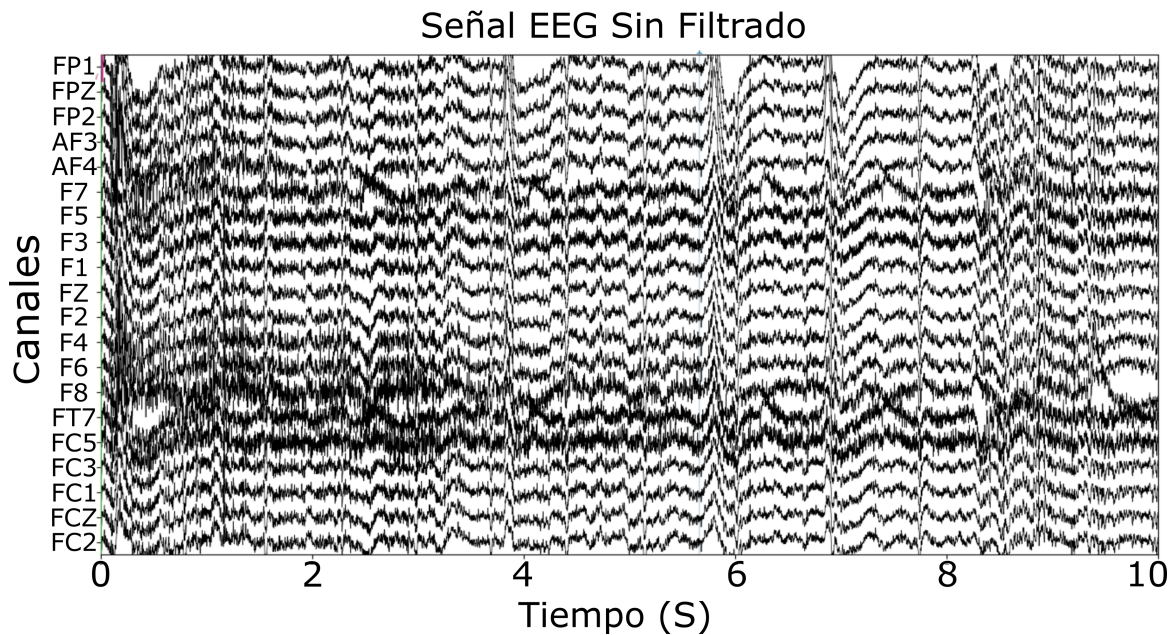
**Tabla 2-1:** Capas Entre el Cerebro y el Cuero Cabelludo, Sus Tamaños y Resistividades.

Es importante reconocer que los registros de EEG son tomados en un espacio unidimensional; sin embargo, corresponden a un estudio multi dimensional, debido a que diferentes electrodos toman medidas en los mismos instantes de tiempo, adquiriendo así múltiples señales en un lapso de tiempo determinado, como se puede observar en la Figura 2-2.

### 2.1.3. Ritmos del EEG.

A lo largo de los años, científicos e investigadores interesados en el EEG han encontrado diversas ondas, las cuales se caracterizan por tener una determinada morfología y que son frecuentes en las grabaciones, estas ondas son conocidas como los ritmos cerebrales o ritmos del EEG, y como se menciona en [86], los ritmos EEG están definidos como perfiles de onda regularmente recurrentes, con forma y duración similar. Algunas de las más importantes características que pueden definir un ritmo son la frecuencia y amplitud, e incluso las regiones del cerebro donde se producen se ven implicadas. En [86] se especifica que el mayor tipo de neuronas implicadas en la generación, sincronización, y activación de los ritmos cerebrales están localizadas en la corteza cerebral, el tálamo y diversos sistemas modulatorios generalizados que surgen del núcleo del tallo cerebral, hipotalamo posterior y el prosencéfalo basal.

A continuación se muestra una lista de los ritmos cerebrales que habitualmente se describen en el estado del arte y que componen todo el espectro de frecuencia de las señales electroencefalográficas. Es necesario tener en cuenta que el rango de frecuencia de cada banda puede




**Figura 2-2:** Señal Electroencefalográfica en el Dominio del Tiempo Grabado por 20 Electrodo.

cambiar según el autor y sus propósitos.

- **Delta 0-4 Hz ( $\delta$ ):** delta es la banda que cubre las frecuencias más bajas, en este rango se encuentra la información relacionada con el sueño profundo, funciones inconscientes del cuerpo, discapacidades en el aprendizaje y en la empatía [27].
- **Theta 4-8 Hz ( $\theta$ ):** es la señal sincrona extracelular más grande que se puede registrar desde el cerebro de los mamíferos y está relacionada con la meditación, el sueño REM y la memoria [116].
- **Alfa 8-13 Hz ( $\alpha$ ):** el ritmo alfa es en donde se ubica la información relacionada con el estado de vigilia, este aparece en la solución de problemas, concentración y es influenciado por los estados anímicos.
- **Beta 13-30 Hz ( $\beta$ ):** relacionado con el estrés, alta concentración y enfoque, la ansiedad y alta excitación.
- **Gamma > 30 Hz ( $\gamma$ ):** las ondas gamma son ondas de mayor frecuencia que mantienen perfiles visuales abstractos en la memoria a corto plazo y se presentan en estímulos enfocados [116].

Se puede notar que las bandas de frecuencia en los seres humanos están ampliamente relacionadas con el estado de vigilia o somnolencia, de tal forma que, la frecuencia aumenta a medida que el estado de concentración también incrementa. La Figura 2-3 muestra cómo se relacionan los ritmos del EEG y el estado de vigilia o somnolencia.



**Figura 2-3:** ritmos del EEG y su Relación con el Estado de Concentración o Vigilia.

#### 2.1.4. EEG en el Diagnóstico de Trastornos y Enfermedades de Origen Neurológico.

Una de las aplicaciones que se le ha dado a través de los años a los estudios del EEG, es el diagnóstico de enfermedades que provienen de afectaciones cerebrales o psicológicas, un ejemplo puntual es el caso del Alzheimer, donde varios análisis espectrales y no lineales del EEG han sido utilizados para detectar cambios funcionales en el cerebro. Los investigadores han extraído características cuantitativas del EEG, que podrían determinar cada etapa de esta enfermedad [78].

Otro caso puntual de EEG aplicado al diagnóstico de enfermedades del cerebro es la detección de ataques de epilepsia. Para esta enfermedad se hacen esfuerzos especialmente en extraer las regiones del cerebro que son afectadas, para luego remover las porciones del cerebro que conducen a los ataques epilépticos [10]. En este caso, las señales pueden ser focales o no focales dependiendo del área afectada. Si las señales EEG son extraídas de áreas donde

el primer ataque fue detectado, se le llama EEG focal, y si estas son tomadas de áreas del cerebro que no están involucradas con los ataques, se le llama EEG no focal.

Adicionalmente, estas bioseñales se extienden hacia otros trastornos y diagnósticos como son la depresión, derrames cerebrales [126], parálisis bulbar progresiva [86], atrofia muscular espinal (AME) [55], enfermedades degenerativas del cerebro, disfunciones motoras a causa de enfermedades en el nervio craneal [62], autismo [88], entre otras. Los estudios mencionados han mostrado que las señales EEG apoyadas en el aprendizaje de máquina como herramienta para la identificación de patrones y características en sujetos que padecen estas enfermedades, han obtenido resultados sobresalientes, por lo cual, este tipo de metodologías basadas en algoritmos de inteligencia artificial tienen un alto potencial en la resolución de problemáticas de origen neurológico.

### **2.1.5. Reconocimiento de Emociones.**

El reconocimiento de emociones es una capacidad humana esencial para la coexistencia exitosa entre las personas y el entorno que los rodea, en donde día a día, los seres humanos se ven involucrados en diferentes escenarios y circunstancias que los obligan a tener una percepción clara acerca del estado anímico de los demás, permitiéndoles tener una comunicación e interacción asertiva, y además, obtener aprendizaje durante el proceso [124].

Diferentes autores involucrados en la salud mental y psicológica, han encontrado relaciones entre el procesamiento de emociones y enfermedades mentales, como es el caso de la esquizofrenia, donde se ha detectado déficit en la percepción de expresiones faciales y vocales en personas que la padecen [26]. Pacientes con la enfermedad de Huntington muestran un cambio en la banda alfa [93], también personas con parkinson son evaluadas según su comportamiento y procesamiento emocional [8], y la caracterización de alteraciones de procesos cognitivo-emocionales en convulsiones psicógenas no epilépticas ha ayudado en el tratamiento de esta misma [102].

Dada la importancia de las emociones en los seres humanos, investigadores han invertido tiempo en estudiar este fenómeno y definir sus consecuencias y efectos. Paul Maclean en sus estudios pudo identificar la región del cerebro donde las emociones son procesadas y se refirió a esta como el sistema límbico, compuesto por el hipotálamo, hipocampo y la corteza cingulada junto con una estructura importante llamada amígdala [131]. Esta información ha conducido a que otros trabajos se centren en identificar las regiones del cerebro afectadas. En este sentido, experimentos utilizando electroencefalografía, magnetoencefalografía (MEG), e imágenes por resonancia magnética funcional (fMRI), son de gran ayuda para detectar regiones y patrones con funcionalidad anormal.

## 2.2. Aprendizaje De Máquina.

### 2.2.1. Definición.

El aprendizaje de máquina (ML por sus siglas en inglés de *Machine Learning*) es una disciplina científica que se deriva de la inteligencia artificial y de las ciencias de la computación. Adicionalmente, es considerada una de las áreas con mayor crecimiento en la computación. Los científicos de datos, estos son, personas que se especializan en el manejo de los datos y la información a través de técnicas estadísticas y de aprendizaje de máquina, definen el ML como la profesión más atractiva del siglo XXI debido a su amplio rango de aplicaciones en diferentes campos y su potencial para resolver problemas complejos. Esta disciplina se trata de un grupo de algoritmos y códigos que tienen la capacidad de resolver tareas a través del aprendizaje y “experiencia” que adquieren de los resultados evaluados en una función de costo, la cual le indica al algoritmo qué tan alejado está su resultado del objetivo. De esta forma, el aprendizaje de máquina realiza predicciones basado en los datos e información previa que no ha sido explícitamente programada [97].

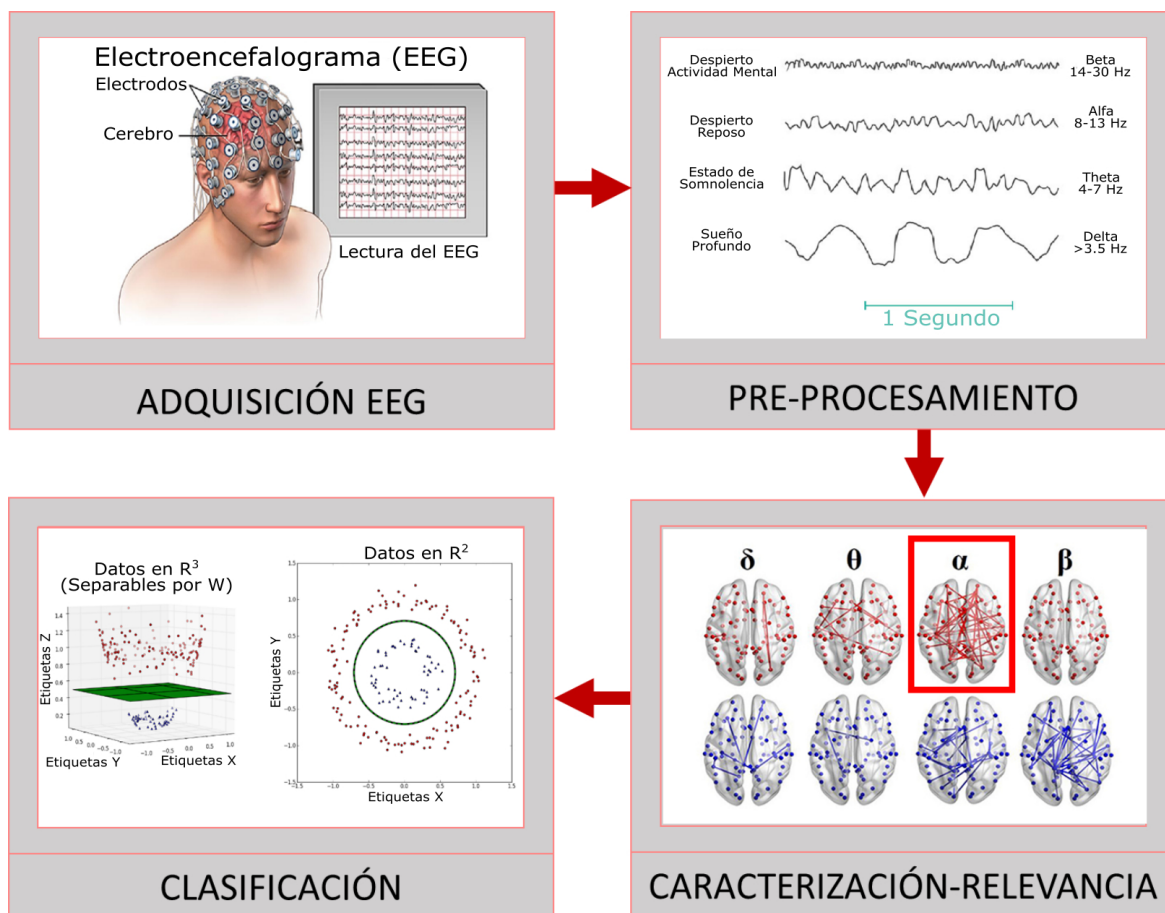
Normalmente las tareas de ML se dividen en 4 categorías: aprendizaje supervisado, aprendizaje no supervisado o agrupamiento de datos, aprendizaje semi-supervisado y más recientemente un enfoque llamado aprendizaje por refuerzo.

### 2.2.2. Aprendizaje Supervisado.

En los algoritmos de aprendizaje supervisado los modelos son entrenados analizando una serie de observaciones e incluyendo las respuestas reales que estas ocasionan, llamadas etiquetas de clase [44]. Esto permite en el entrenamiento obtener información de un resultado validado y etiquetar nuevas instancias en la epata de prueba en base a las etiquetas de entrenamiento. En esta categoría se pueden encontrar tareas de clasificación que están orientadas a construir fronteras de decisión entre las clases y asignar a una nueva entrada la clase que le pertenece basado en sus características (e.g., categorización de frutas, personas sanas vs personas enfermas, identificación de caracteres escritos a mano). También se tienen las tareas de regresión en donde se encuentran valores numéricos según las características del conjunto de datos (e.g., el precio de una casa teniendo en cuenta su ubicación, número de habitaciones y pisos, etc), y por último está la previsión de datos, en donde se trata de predecir el valor futuro de una variable basado en su comportamiento actualmente conocido y la relación con otras variables, manteniendo similitud con la regresión, no obstante, la predicción se centra solamente en valores futuros como la estimación de la tasa representativa del dólar cierto número de días a partir de la fecha actual, probabilidad de lluvia en próximos días, etc.

### 2.2.3. Aprendizaje de Máquina Aplicado al Procesamiento de Señales EEG.

Los estudios de EEG han sido direccionados por el aprendizaje de máquina en sus diferentes etapas haciendo uso de metodologías y teorías matemáticas aplicadas a algoritmos de procesamiento. El estado del arte reporta una tendencia marcada en los pasos que regularmente son realizados por los investigadores. Esta tendencia se puede ver representada por la Figura 2-4.



**Figura 2-4:** Estructura Metodológica del Estudio de Señales EEG Utilizando Aprendizaje de Máquina.

Inicialmente se adquieren las firmas de EEG, para lo que se han propuesto diferentes paradigmas en torno a la recolección de datos, dependiendo del trastorno, enfermedad o tarea (en el caso de las interfaces cerebro computadora), como identificación de fuentes epilépticas [109], procesamiento de emociones [13, 6], identificación de movimientos imaginados [95, 21], etc. Posteriormente se preprocesan los datos adquiridos para eliminar el ruido y la información no relacionada proveniente de estímulos visuales, auditivos, etc. Luego se extraen y

seleccionan grupos de características determinantes, y finalmente se clasifican los datos en las clases de interés.

### **2.3. Sumario.**

En este capítulo fueron definidos los conceptos fundamentales acerca de las señales electroencefalográficas y el aprendizaje de máquina. Inicialmente se expone cómo la interacción entre neuronas desemboca en pequeños potenciales que se sincronizan y dan origen a un campo eléctrico que se propaga a través de las diferentes capas del cerebro y cráneo, generando así una señal EEG. Luego se habla sobre el aprovechamiento de estos registros para realizar diagnósticos de patologías y trastornos de origen neuronal. Finalmente se introduce el direccionamiento que han recibido estos estudios por parte del aprendizaje de máquina debido a su excelente desempeño y capacidad para encontrar relaciones en amplios volúmenes de datos, mostrando el esquema básico de procesamiento.

# 3 Descripción de la Base de Datos de Controles y Excombatientes, y Metodología de Preprocesamiento

## 3.1. Base de Datos.

Los datos utilizados en esta tesis sobre conflicto armado colombiano fueron tomados y facilitados por los grupos de investigación en salud mental GISAME y el grupo de sistemas embebidos e inteligencia computacional SISTEMIC de la Universidad de Antioquia. La primera de las bases de datos consta de una tarea de valencia contextual y la segunda base de datos es una tarea denominada *flanker*.

### 3.1.1. Valencia Contextual.

La base de datos de valencia contextual contiene la información de 31 excombatientes en proceso de reintegración de la Agencia para la reincorporación y la normalización (ARN<sup>1</sup>), y de 19 colombianos que no han tenido experiencia de combate como grupo de control. Los grupos fueron pareados en escolaridad, edad y género, además se realizaron tres pruebas estadísticas que muestran que no hay diferencia significativa entre las clases (excombatiente o control) con base en las variables mencionadas, la Tabla **3-1** muestra la media de la edad y escolaridad de ambas clases, la cantidad de personas pertenecientes a cada una de ellas, discriminando además por género, y los resultados de las pruebas estadísticas.

Los sujetos realizaron una tarea de reconocimiento de valencia contextual sincronizada con un registro electroencefalográfico. Esta metodología permite tomar múltiples y simultáneas mediciones de: polaridad (potencial negativo o positivo), amplitud, latencia y distribución en la superficie craneal de señales EEG, de esta forma, puede ser evaluada la actividad eléctrica cerebral asociada a procesos psicológicos y neurológicos, en respuesta a los estímulos presentados a lo largo de diferentes pruebas. En este experimento los sujetos fueron expuestos a una serie de imágenes estandarizadas por el Sistema Internacional de Imágenes Afectivas, en inglés *International Affective Pictures System (IAPS)* y validadas por la Universidad de

---

<sup>1</sup>Antes agencia colombiana para la reintegración (ACR)



		Faltantes	Controles	Excombatientes	P Valor	Prueba
Cantidad			19	31		
Género	F	0	2	2	0.629	<i>Fisher</i>
	M		17	29		
Edad Media ( $\sigma$ )		0	36.7 (9.0)	37.2 (8.3)	0.869	<i>T-test</i>
Escolaridad Media ( $\sigma$ )		1	11.1 (2.2)	10.2 (3.0)	0.279	<i>T-test</i>

$\sigma$  = **Desviación estándar**   **F** = **Femenino**   **M** = **Masculino**

**Tabla 3-1:** Descripción Demográfica Y Análisis Estadístico de las Clases Asignadas a los Sujetos de Estudio.


Antioquia para el contexto de la población Colombiana [43].

Los investigadores de los grupos GISAME y SISTEMIC adaptaron un paradigma para la evaluación del Procesamiento Emocional (PE) de excombatientes. Para ello se utilizó la escala de valencia positiva y negativa, utilizada en otros estudios de PE [65, 50, 129, 39]. Adicional a esto, se hizo una modificación incorporando una valencia neutra [94]. En la Figura 3-1 se muestra el paradigma y la tarea que fue utilizada en la adquisición de las señales, las imágenes fueron ajustadas en términos de color, brillo e intensidad y se presentaron en un monitor de 17 pulgadas a 60 centímetros del participante [100].



**Figura 3-1:** Tarea Diseñada Para la Adquisición de las Señales EEG en la Tarea de Valencia Contextual Mediante la Presentación de Imágenes IAPS.

Los electrodos fueron ubicados según el sistema 10-20. El equipo utilizado para la recolección fue el *NeuroScan EEG SynAmps2* con 64 electrodos. La impedancia de estos se mantuvo por debajo de los 10 k $\Omega$ , la frecuencia de muestreo se fijó en 1000 Hz, y como referencia se utilizaron los mastoides. A continuación, la Figura 3-2 muestra los electrodos utilizados y su ubicación.




**Figura 3-2:** Electrodo Utilizados por el Equipo NeuroScan EEG SynAmps2 y su Ubicación.

### 3.1.2. Flanker.

Esta base de datos fue adquirida basando la tarea en el estudio de [91], en el cual se define que el punto clave de análisis con imágenes flaqueadas (*flanker*) está en el contenido y la posición de estímulos emocionales relevantes. Formas y dibujos definidos como objetos son introducidos en la tarea y categorizados en vivos y no vivos. El objetivo de utilizar objetos es atraer aún más la atención del espectador sin interferir en la dimensión emocional que se está evaluando [5].

En total fueron seleccionadas 60 imágenes de valencia negativa y neutra tomadas del sistema IAPS tal como en el apartado 3.1.1 y 60 sobre objetos (30 para vivos y 30 para no vivos) del repositorio *International Picture Naming Project Database* [71]. El experimento se dividió en 4 bloques en los que se presentaron 60 imágenes para un total de 240 pruebas, en cada una de estas pruebas el estímulo presentado contenía una imagen central y 4 periféricas. En caso de ser presentada una imagen de valencia (negativa o neutra) en el centro, las periféricas debían ser objetos y en caso de presentarse un objeto en el centro, las periféricas debían ser sobre valencia. En la Figura 3-3 se muestra un ejemplo de una prueba individual y la estructura del estímulo.



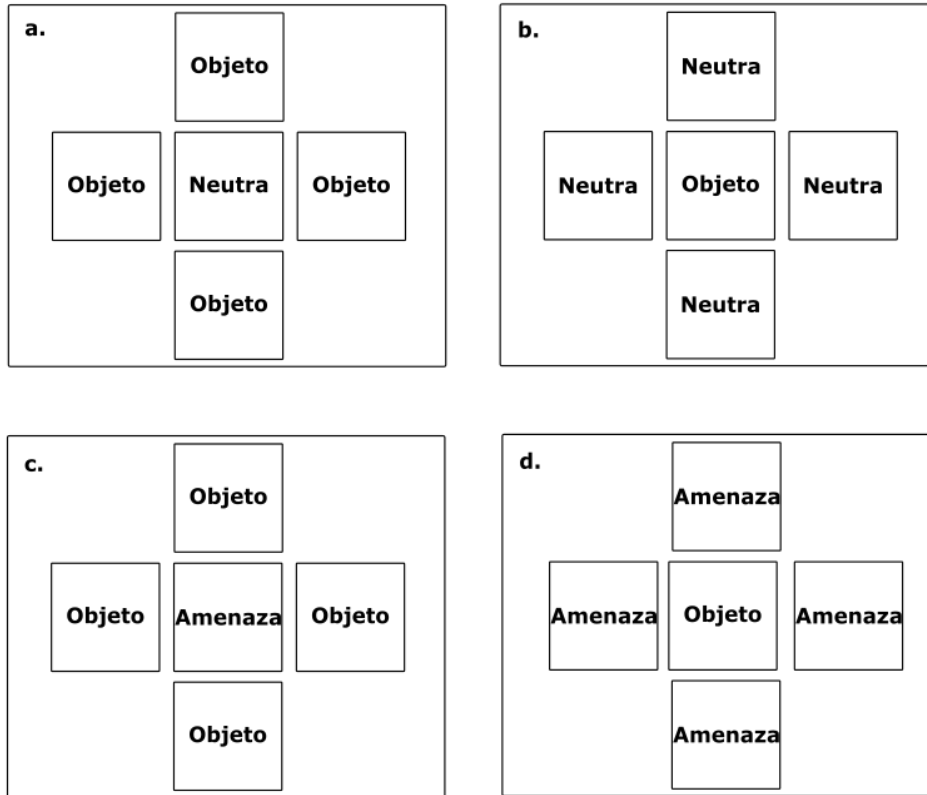
**Figura 3-3:** Prueba Diseñada Bajo el Paradigma de Presentación de Estímulos Visuales con Imágenes Flanqueadas.

En el tiempo de presentación del estímulo fueron mostrados 4 tipos de combinaciones de imágenes entre el objetivo (imagen central) y los distractores periféricos. Estas combinaciones fueron:

- **a) Neutra Central:** valencia neutra en el cuadro central y objetos en los cuadros periféricos
- **b) Neutra Periférica:** objeto en el cuadro central y valencia neutra en los cuadros periféricos.
- **c) Amenaza Central:** valencia negativa en el cuadro central y objetos en los cuadros periféricos.
- **d) Amenaza Periférica:** objeto en el cuadro central y valencia negativa en los cuadros periféricos.

Un ejemplo representativo de los tipos de imágenes utilizadas en el experimento se puede ver en la Figura 3-4:

### Posicionamiento de las Emociones



**Figura 3-4:** Representación del contenido y posición en cada uno de los tipos de imágenes presentados durante el estímulo.

Al igual que en la tarea de valencia contextual, *flanker* fue sincronizado con un sistema de adquisición de EEG de 64 canales. Para esto se utilizó un equipo *NeuroScan Ltd.* configurado bajo el estándar 10-10 del sistema internacional. Las señales fueron tomadas a 1000 Hz de frecuencia base y la impedancia de los electrodos se mantuvo por debajo de los 10 k $\Omega$ , los participantes fueron ubicados a 60 centímetros de una pantalla de 17 pulgadas en donde se proyectaron los estímulos. La duración total de cada sesión fue de aproximadamente 1 hora. En total se seleccionaron 57 sujetos marcados con alta exposición al conflicto armado y 20 con baja exposición.

## 3.2. Preprocesamiento.

El preprocesamiento de las señales EEG es la etapa en donde se realiza la eliminación del ruido y el proceso de filtrado, dado que las medidas del EEG están contaminadas por diversos artefactos [125]. Los artefactos son considerados señales o interferencia en los registros, estos usualmente se dividen en dos clases principales, externos e internos, también conocidos como biológicos y no biológicos [106]. Los artefactos internos son producidos cuando hay distorsión o alteración en las señales por procesos biológicos como el parpadeo o movimiento ocular, latidos del corazón, movimientos musculares e incluso información procesada acerca de tareas no relacionados cómo los estímulos visuales y auditivos durante las grabaciones. Por otro lado, los artefactos externos están asociados con condiciones del entorno y ajustes del experimento, esto puede ser, interferencia a causa de la red eléctrica, desconexión de los electrodos, energía estática, y tecnología no satisfactoria. En la Tabla 3-2 se muestran algunos artefactos categorizados.

Artefactos Externos	Artefactos Internos
Frecuencia principal	Potencial visual evocado
Falla en los electrodos	Potencial miogénico
Fallas en el equipo de adquisición	Artefactos del EEG
Presión de los electrodos	Pulsaciones
Ventilación	Resistencia de la piel
Vibración	Movimientos del paciente

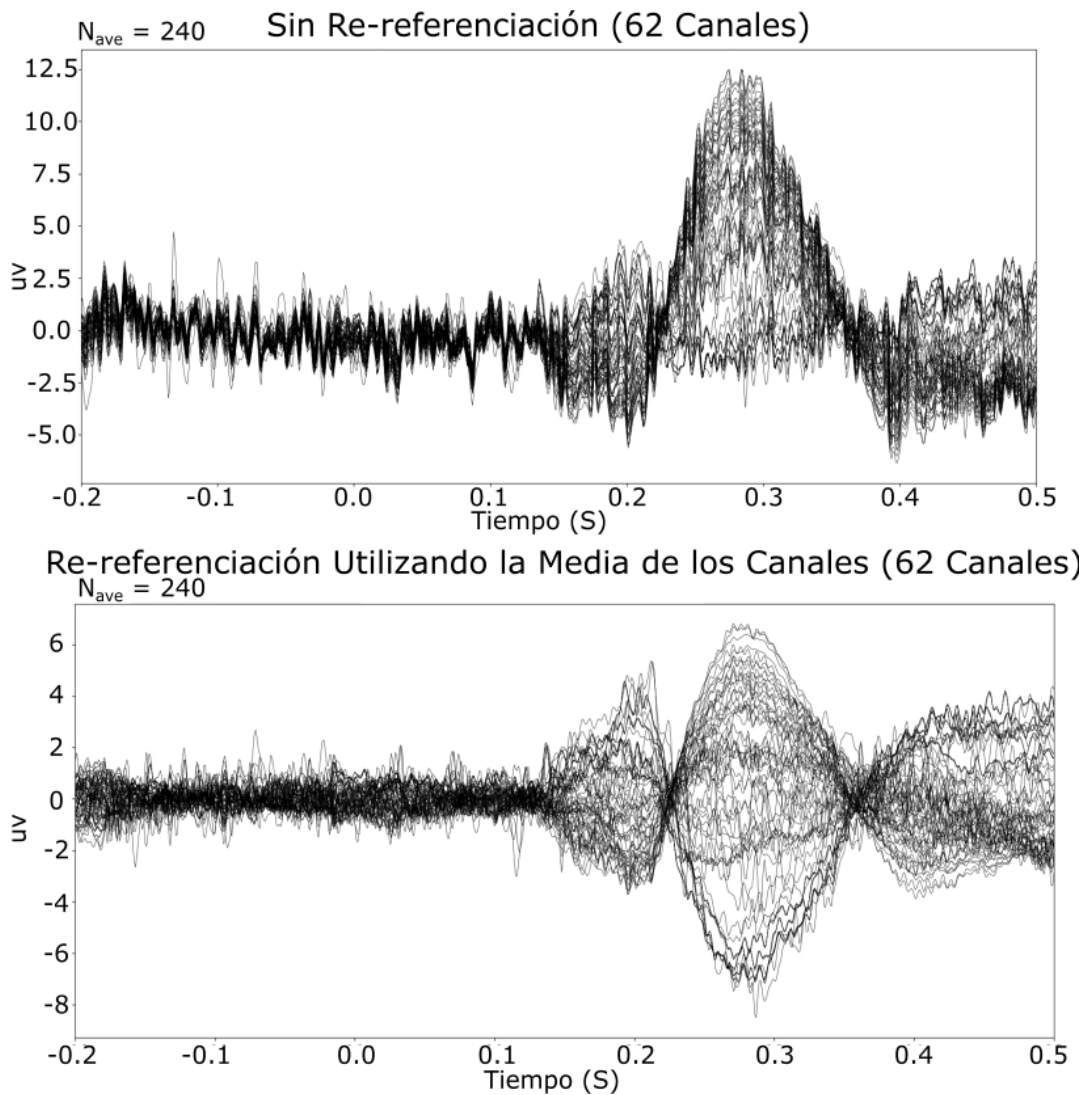
**Tabla 3-2:** Artefactos Internos y Externos del EEG.

Distintas técnicas y algoritmos han sido utilizados en la búsqueda de remover los más significativos y mayor cantidad de artefactos posibles. En primera instancia, aquellos relacionados con frecuencias atípicas como la red eléctrica y frecuencias de equipos cercanos pueden ser removidos utilizando filtros pasa bandas o pasa bajas, dado que la mayor actividad cerebral oscila por debajo de los 50 Hz [95], y sobre esta frecuencia están las redes eléctricas.

### 3.2.1. Referenciación y Filtrado de las Señales EEG.

Con el fin de remover el mayor número de artefactos EEG, se utilizaron diferentes técnicas en cadena que han mostrado en el estado del arte ser robustas y efectivas en la eliminación de diversas fuentes de ruido. Todo el proceso que se describe a continuación fue desarrollado utilizando el módulo MNE de Python 3.6 para el procesamiento de señales EEG. Inicialmente se realizó una re-referenciación de las señales, tomando como nueva referencia la media de la totalidad de los electrodos que perciben actividad cerebral (descartando canales de

movimiento ocular). La re-referenciación tiene gran importancia en los resultados, ya que diferentes estudios han mostrado que hay cambios drásticos en la amplitud, la latencia y la localización de la señal al utilizar como referencia los mastoides, la nariz, el canal CZ o el promedio de los canales como es el caso [60], afectando las medidas de conectividad. Sin embargo, se ha mostrado que al utilizar el promedio de los canales como nueva referencia se disminuye el error relativo en los potenciales comparado con la referencia en mastoides y CZ, e incluso ayuda a resaltar patrones de conexión entre canales [30].



**Figura 3-5:** Re-referenciación en el Potencial de los Canales EEG Utilizando Como Nueva Referencia el Valor Medio de Todos los Canales.

En la Figura 3-5 se observa el resultado del cambio de referencia, en donde sobresale una

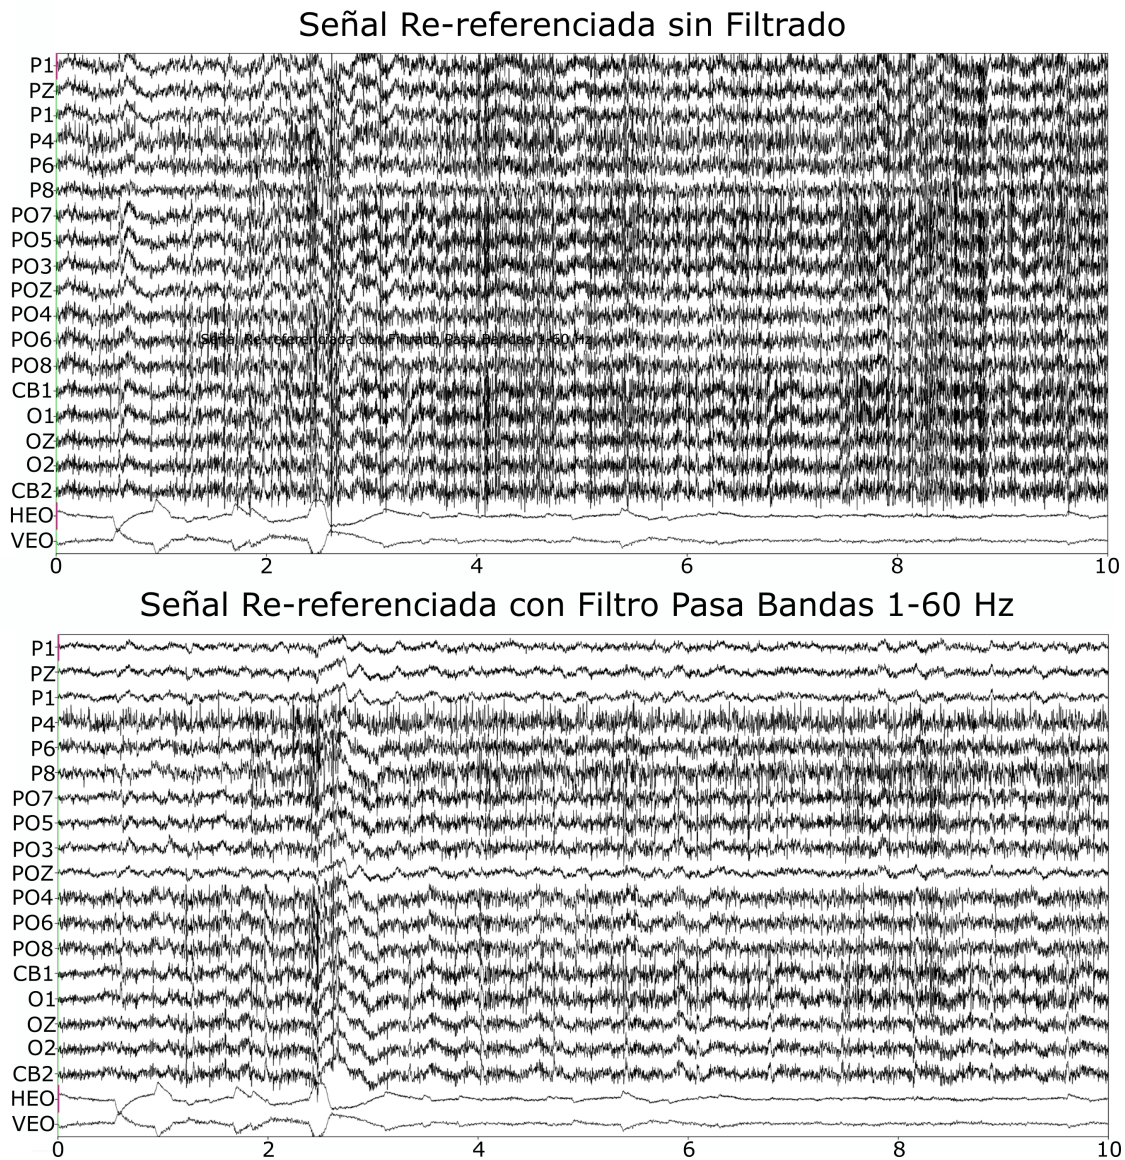
diferencia en la polaridad del potencial en múltiples canales y alteración en el voltaje máximo positivo, así como en el mínimo negativo en el intervalo de 0.2 a 0.5 segundos que es la respuesta al estímulo, garantizando así mayor diferenciación en las medidas de cada canal, condición que es aprovechada en el análisis de conectividad.

Al tener una nueva referencia se continuó con la identificación de los canales ruidosos, para esto se utilizaron diferentes criterios sugeridos en [15]. El primero de ellos utiliza el puntaje  $Z$  robusto (puntaje estandarizado robusto) que normaliza la desviación estándar de las amplitudes en los canales y selecciona como canales defectuosos aquellos que superan 5 veces la desviación normalizada. Para el cálculo del puntaje  $Z$  robusto la media es reemplazada por la mediana  $\mu$  de las señales  $Y$  y la desviación estándar por la desviación absoluta media  $D$ , expresado en la ecuación (3-1).

$$Z_n = \frac{Y - \mu}{D} \quad (3-1)$$

Como segundo criterio se encontró la correlación en frecuencias inferiores a 50 Hz partiendo las señales en ventanas de 1 segundo, y evaluando cada canal contra los demás por ventana. Paso seguido se calculó la correlación máxima absoluta como el percentil 98 de los valores absolutos de dichas correlaciones y se marcaron como canales defectuosos aquellos que tenían una correlación inferior al 40 %. En búsqueda de reparar los canales defectuosos, se hizo interpolación con las medidas de los canales vecinos y se eliminó la etiqueta de canales defectuosos para hacer uso de ellos en el resto del procesamiento. Este procedimiento contribuyó a reducir actividad no relacionada como el pulso basal registrado en algunas ocasiones a causa de la presión ejercida por el electrodo, actividad ocular y medidas atípicas.

Para la remoción de ruido originado por equipos electrónicos y potencia eléctrica se utilizó un filtro pasa bandas de respuesta finita al impulso (FIR por sus siglas en inglés de *Finite Impulse Response*) eliminando las frecuencias mayores a 60 Hz (ya que los datos fueron adquiridos en Colombia donde la red eléctrica está fijada a esta frecuencia), y se estableció una banda inferior de 1 Hz, este último es utilizado para remover artefactos que provienen de movimientos musculares. Estos filtros utilizados son de fase lineal, lo cual permite que no haya afectaciones en la fase de la señal original. En la Figura 3-6 se muestra una firma EEG antes y después de pasar por el filtro utilizado; los últimos dos canales (HEO Y VEO) corresponden a electrodos de referencia ocular.



**Figura 3-6:** Firma EEG Procesada en 20 Canales Utilizando un Filtro Pasa Bandas Tipo FIR.

Posterior al filtrado se hizo la extracción de épocas, lo cual corresponde a la selección de las señales en los intervalos de tiempo donde cada sujeto de estudio fue expuesto al estímulo de la tarea, es decir, las imágenes de valencias negativa, neutra y positiva, marcados en la adquisición de los datos con las etiquetas 10, 11 y 12 respectivamente. Todos los periodos marcados con estas etiquetas fueron unidos uno tras otro por canal, tomando las medidas desde 200 milisegundos antes hasta 800 milisegundos después de presentado el estímulo, ya que este se considera que es el tiempo de reacción en la firmas EEG para estímulos visuales, obteniendo como resultado 1 firma de 64 canales (62 de EEG y 2 de referencia ocular). En



esta firma se encuentra depositada la información de los estímulos de interés, obviando intervalos como descansos, cruz de fijación, pantalla sin contenido, etc.

En la Figura **3-6**, la señal anterior al filtrado muestra componentes de alta frecuencia que no se asocian con actividad cerebral. Luego de pasar las firmas de EEG por el filtro FIR, se puede detallar que las ondulaciones y picos de alta repetitividad desaparecen en todos los canales, no obstante, aún se perciben ondas atípicas que pertenecen a artefactos como el parpadeo y movimiento ocular (conocidos como EOG), los cuales se caracterizan por tener una alta amplitud y frecuencia baja, tardando entre 200 ms y 400 ms [103], condiciones que hacen visualmente identificable las regiones donde han quedado registrados.

En el estado del arte se ha encontrado que la remoción de señales oculares está direccionada por el Análisis de Componentes Independientes (ICA por sus siglas en inglés de *Independent Component Analysis*), Análisis de Componentes Principales (PCA por sus siglas en inglés de *Principal Component Analysis*) y filtros adaptativos, de los cuales ICA ha mostrado ser el más robusto a pesar de no ser rápido procesando los componentes, y los filtros adaptativos han mostrado ser los más adecuados en tareas que requieran procesamiento en tiempo real dada su velocidad, aunque poseen un bajo rendimiento [66]. Para suprimir las señales provenientes de EOG se utilizó ICA por su robustez, obviando el tiempo de computación ya que esta aplicación no requiere un procesamiento en línea.

### 3.2.2. Análisis de Componentes Independientes ICA.

El Análisis de Componentes Independientes es una técnica de separación ciega de fuentes que busca independencia utilizando un análisis estadístico de orden superior [42]. ICA parte de suponer que las fuentes originales son no Gaussianas, mutuamente independientes y las observaciones son una transformación lineal de las fuentes de origen [66].

La técnica de ICA resuelve el problema de mezcla de señales que define que una señal  $\mathbf{S}$ , descrita como  $\mathbf{S} = \mathbf{S}_{i1}, \mathbf{S}_{i2}, \mathbf{S}_{i3}, \dots, \mathbf{S}_{iN}$ , donde  $N$  representa los instantes de tiempo u observaciones de la señal, y  $\mathbf{S}_{ij}$  representa la amplitud de  $\mathbf{S}_i$  en el instante  $j$ , tiene componentes  $\mathbf{S}_1, \mathbf{S}_2, \mathbf{S}_3, \dots, \mathbf{S}_M$ , siendo  $M$  el número de fuentes independientes [117], y se puede expresar como lo muestra la ecuación (3-2).

$$\mathbf{S} = \begin{pmatrix} \mathbf{S}_1 \\ \mathbf{S}_2 \\ \mathbf{S}_3 \\ \vdots \\ \mathbf{S}_M \end{pmatrix} = \begin{pmatrix} (\mathbf{S}_{11} & \mathbf{S}_{12} & \mathbf{S}_{13} & \cdots & \mathbf{S}_{1N}) \\ (\mathbf{S}_{21} & \mathbf{S}_{22} & \mathbf{S}_{23} & \cdots & \mathbf{S}_{2N}) \\ (\mathbf{S}_{31} & \mathbf{S}_{32} & \mathbf{S}_{33} & \cdots & \mathbf{S}_{3N}) \\ \vdots & & & & \\ (\mathbf{S}_{M1} & \mathbf{S}_{M2} & \mathbf{S}_{M3}, \cdots & \mathbf{S}_{MN}) \end{pmatrix} \quad (3-2)$$

A partir de  $\mathbf{S}_1, \mathbf{S}_2, \dots, \mathbf{S}_M$  se pueden obtener las señales  $\mathbf{X}$  que son combinación lineal de  $\mathbf{S}$ .

$$\mathbf{X} = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \mathbf{X}_3 \\ \vdots \\ \mathbf{X}_M \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & a_{13} & \cdots & a_{1K} \\ a_{21} & a_{22} & a_{23} & \cdots & a_{2K} \\ a_{31} & a_{32} & a_{33} & \cdots & a_{3K} \\ \vdots & & & & \\ a_{M1} & a_{M2} & a_{M3} & \cdots & a_{MK} \end{pmatrix} \begin{pmatrix} \mathbf{S}_1 \\ \mathbf{S}_2 \\ \mathbf{S}_3 \\ \vdots \\ \mathbf{S}_M \end{pmatrix} = \mathbf{AS} \quad (3-3)$$

La matriz  $\mathbf{A}$  representa los coeficientes de mezcla que forman la combinación lineal entre las fuentes para obtener  $\mathbf{X}$ .

El algoritmo de ICA obtiene una matriz de separación de fuentes, de tal manera que al ser multiplicada por el vector de señales mezcladas  $\mathbf{X}$ , sean obtenidos los componentes independientes (IC) representados por  $\mathbf{y}$ , como lo expone la ecuación (3-4)

$$\mathbf{y} = \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \mathbf{y}_3 \\ \vdots \\ \mathbf{y}_K \end{pmatrix} = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \alpha_{13} & \cdots & \alpha_{1K} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} & \cdots & \alpha_{2K} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} & \cdots & \alpha_{3K} \\ \vdots & & & & \\ \alpha_{K1} & \alpha_{K2} & \alpha_{K3} & \cdots & \alpha_{KK} \end{pmatrix} \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \mathbf{X}_3 \\ \vdots \\ \mathbf{X}_K \end{pmatrix} \quad (3-4)$$

Los valores  $\alpha_{ij}$  son los coeficientes utilizados para la separación de fuentes y son representados por la matriz  $W$ , por lo cual, se puede decir que el objetivo de ICA es específicamente encontrar los coeficientes en  $W$ , para lo cual se realizan los siguientes pasos fundamentales [117]:

- **Centrado:** El objetivo en este paso es extraer la media de todas las señales como en la ecuación (3-5).

$$\mathbf{D} = \mathbf{X} - \mu = \begin{pmatrix} \mathbf{D1} \\ \mathbf{D2} \\ \vdots \\ \mathbf{Dn} \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1 - \mu \\ \mathbf{x}_2 - \mu \\ \vdots \\ \mathbf{x}_n - \mu \end{pmatrix} \quad (3-5)$$

Donde  $\mathbf{D}$  es la mezcla de las señales después del centrado.

- **Blanqueo de los Datos:** Este paso corresponde a eliminar la correlación de los datos y luego hacer una escalización de varianza unitaria. Para eliminar la correlación de dos variables  $(x_i, x_j)$  se evalúan las covarianzas como:

$$\sum_i j = E[(x_i - \mu_i)(x_j - \mu_j)] = E[\mathbf{D}\mathbf{D}^T] \quad (3-6)$$

la matriz de covarianza es resuelta al hallar los eigenvectores ( $\mathbf{V}$ ) y eigenvalores ( $\lambda$ ) como  $\mathbf{V}\Sigma = \lambda\mathbf{V}$ , siendo los eigenvectores la representación de los componentes principales y su dirección en el espacio de PCA, y los eigenvalores la magnitud. Luego el escalado se hace considerando un vector  $\mathbf{U}$  de longitud unitaria y es reescalado para obtener una varianza unitaria como,  $\mathbf{Z} = \lambda^{\frac{1}{2}}\mathbf{U} = \lambda^{\frac{1}{2}}\mathbf{V}\mathbf{D}$  donde  $\mathbf{Z}$  son los datos blanqueados y  $\lambda^{\frac{1}{2}}$  se obtiene como,  $\lambda^{\frac{1}{2}} = \{\lambda_1^{\frac{1}{2}}, \lambda_2^{\frac{1}{2}}, \dots, \lambda_n^{\frac{1}{2}}\}$

En este trabajo fue utilizado el algoritmo *extended infomax* de ICA utilizado por el módulo MNE de procesamiento [72].

Las señales que se llevaron al análisis de componentes independientes fueron las firmas correspondientes a las épocas, evitando así, llevar datos no relacionados con la tarea al procesamiento.

### 3.2.3. Selección de Componentes Ruidosos.

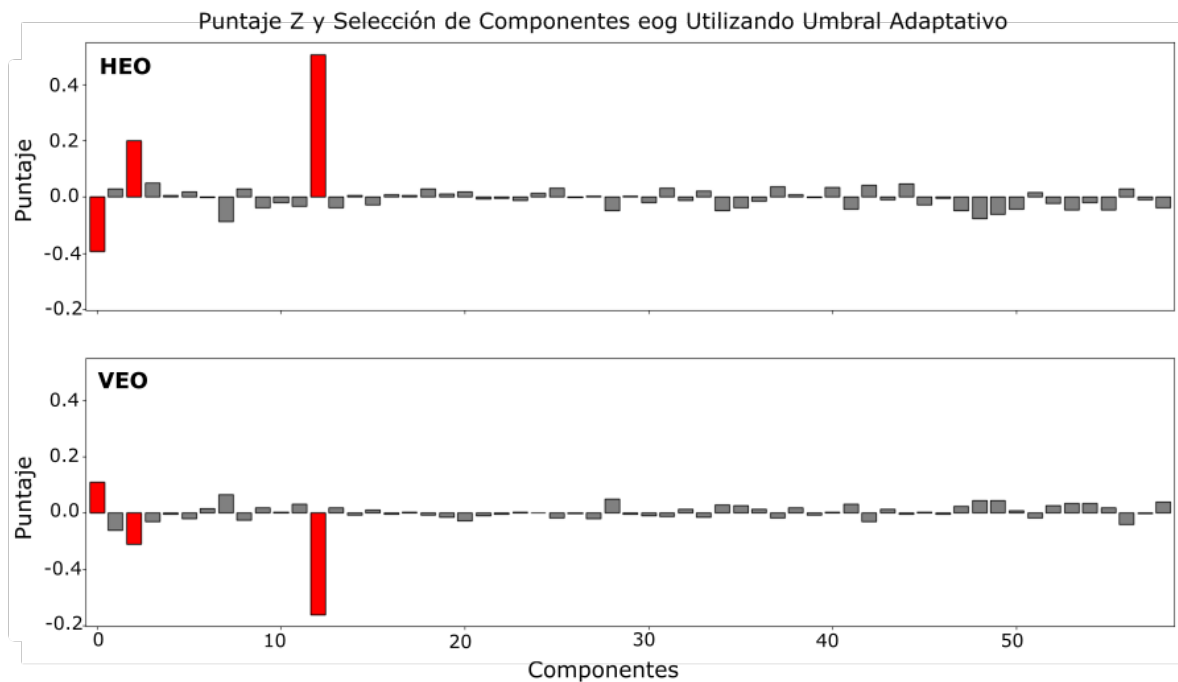
Luego de ser encontrados los componentes independientes, fue necesario hacer un análisis para seleccionar los componentes que contienen algún tipo de ruido, para la selección se utilizó como criterio los momentos centrales estadísticos de diferente orden consignados en la Tabla 3-3. Para cada momento estadístico se establecieron umbrales que al ser superados asignan el componente como ruidoso, almacenándolo en un vector que contiene los índices

de componentes a excluir en la reconstrucción de las señales. De esta forma fueron obtenidas nuevas firmas limpias de artefactos. Adicional a los momentos centrales se aprovecharon las señales de los canales HEO y VEO ubicados en el área superior y lateral circundante a uno de los párpados como referencia de actividad ocular para calcular la correlación de estos canales con los componentes de ICA, incluyendo como criterio un umbral de correlación con la referencia ocular. Los valores asignados para dichos límites son los que se sugieren en la literatura.

Criterio	Umbral Asignado
Correlación con Canales EOG	0.4
Oblicuidad Estadística	2
Curtosis	2
Varianza	2

**Tabla 3-3:** Criterios Para la Selección de Componentes Ruidosos


En la Figura 3-7 se marcan en rojo los componentes asociados a algún tipo de ruido. Estos componentes son excluidos de la reconstrucción.



**Figura 3-7:** Correlación de Componentes Independientes y Canales HEO Y VEO.

Con el propósito de tener una idea de la procedencia del ruido de los componentes marcados, se graficaron las fuentes de estos mismos y el potencial evocado, esto se muestra en la

Figura 3-8, la cual resalta que los potenciales de mayor intensidad están localizados en la parte posterior y frontal, zonas de procesamiento visual y cercana (en el caso de los frontales) a músculos faciales.




**Figura 3-8:** Fuentes de los Componentes Altamente Correlacionados con los Canales de Referencia de Artefactos EOG.

### 3.2.4. Reparación de Épocas Defectuosas.

Como última estrategia en la remoción de artefactos, se utilizó la técnica de reparación de épocas propuesta en [58, 59]. Este proceso se hace necesario debido a que a lo largo de las pruebas, usualmente aparecen altos potenciales que interfieren con el rendimiento de las metodologías [59], donde generalmente se suelen descartar estas pruebas, perdiendo información valiosa y volumen de datos. La metodología selecciona un umbral por canal EEG y selecciona como ruidosos aquellos que sobrepasan dicho valor, si el número de canales defectuosos es inferior a cierto monto  $k$  se procede a hacer la reparación de los canales época por época utilizando los canales vecinos para interpolar. Si el número de canales defectuosos supera a  $k$ , entonces no es posible realizar la reparación.

Finalmente, después de todo el procedimiento descrito anteriormente se obtienen las épocas limpias con las que se procede a realizar la metodología de caracterización. Un ejemplo de una firma limpia se ve en la Figura 3-9.



**Figura 3-9:** Efecto de la Reparación de Épocas en los Canales Frontales de un Sujeto.

Como se puede observar en la Figura 3-9, se destaca en rojo algunos potenciales atípicos que la técnica es capaz de remover y ajustar, en la época 3 previa, a la aplicación de la reparación se observa claramente un artefacto producido por el parpadeo de los ojos que luego es corregido, obteniendo una firma libre de los principales artefactos que ocasionan dificultades e interfieren en el procesamiento, de tal manera que se da paso a la etapa de caracterización, teniendo la certeza de que las épocas extraídas contienen en su mayor parte información relacionada con la tarea.

### **3.3. Sumario.**

En este capítulo es explicado el proceso de adquisición de las señales electroencefalográficas de los excombatientes y controles en ambas bases de datos utilizadas en este trabajo. Se destacan puntos como el equipo y número de canales utilizados, y la tarea diseñada a la que se expusieron los sujetos de estudio.

En la segunda parte se expone la metodología de preprocesamiento que se utilizó para poder eliminar gran parte de los artefactos que suelen estar inmersos en el EEG, con este propósito, se hizo re-referenciación, filtrado, análisis y reparación de épocas defectuosas, y análisis de componentes independientes, seleccionando automáticamente aquellos que están más relacionados con algún tipo de ruido, destacando la proyección con respecto a los canales de referencia ocular.

Como resultado se obtuvieron las épocas pertenecientes a los estímulos de valencias positiva, negativa y neutra sin artefactos como EOG, potencial eléctrico de equipos, movimientos musculares y actividad no relacionada con la tarea.

# 4 Caracterización de Registros Electroencefalográficos

## 4.1. Introducción.

La caracterización es la etapa del procesamiento que se encarga de extraer la información más relevante que compone una firma EEG, en base a sus representaciones en tiempo, frecuencia y espacio. La frecuencia es la unidad básica para determinar el comportamiento normal o anormal de una señal EEG [67], para esto se suelen evaluar los ritmos cerebrales ligados a estados mentales como somnolencia, sueño profundo, alta concentración, y meditación [23].

La caracterización de las señales de EEG supone un gran reto debido a su complejidad y variaciones correspondientes a la forma en que cada ser humano percibe el mundo y procesa la información que recibe de este. Estas circunstancias hacen que surjan metodologías que son ajustadas a problemas específicos, perdiendo en ocasiones capacidad de generalización, además, la extracción de características juega un papel crucial en el éxito de la clasificación. Algunos de los métodos que se suelen usar son la transformada de Fourier [2, 74], la transformada Wavelet [49, 13], medidas estadísticas y espectrales de las señales [31], filtros espaciales [112, 62], y análisis de conectividad [50, 20, 12].

El análisis de conectividad es uno de los métodos más utilizados para caracterizar EEG. En algunos estudios se ha evidenciado que la conectividad tiene un gran potencial para identificar enfermedades psicofisiológicas como la esquizofrenia, autismo y trastornos depresivos, debido a que los pacientes que sufren de estas enfermedades han mostrado una disminución en la conectividad funcional entre regiones corticales [127], del mismo modo, otros estudios han utilizado la conectividad funcional en tareas de procesamiento emocional [6, 77, 3].



## 4.2. Wavelets.

Las Wavelets ( $\psi(t)$ ) son funciones oscilantes que se encuentran tanto en el dominio del tiempo como en la frecuencia y están limitadas en un cierto intervalo (tienen una extensión limitada) [105]. La función  $\psi(t)$  debe satisfacer:

- La función debe ser normalizada  $||\psi(t)|| = 1$ .
- La función al cuadrado debe tener energía finita, esto es satisfacer la ecuación (4-1).

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (4-1)$$

- La integral de la función  $\psi(t)$  debe ser igual a 0 como se muestra en la ecuación (4-2).

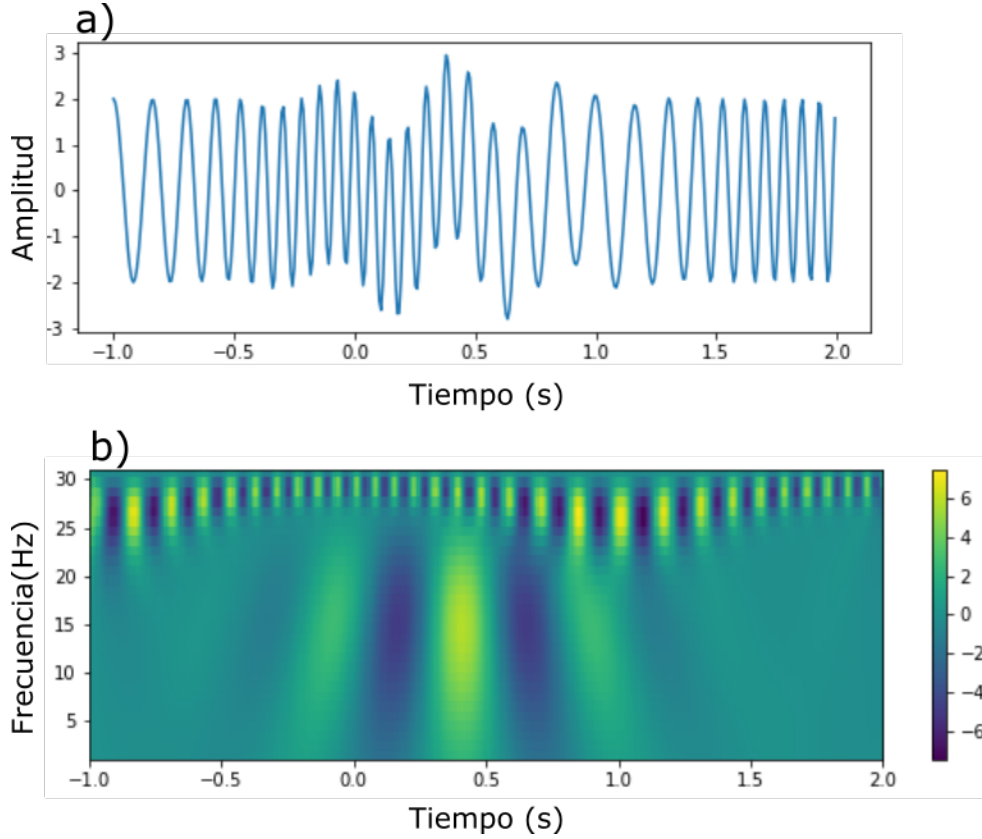
$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (4-2)$$

En el análisis de tiempo continuo, una señal se descompone en versiones escaladas y trasladadas  $\psi_{a,b}(t)$  de la función  $\psi(t)$ , conocida también como la Wavelet madre [56].

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (4-3)$$

Donde  $a$  es la dilatación (inversamente proporcional a la frecuencia) y  $b$  la traslación o desplazamiento referente a la localización en el tiempo, con  $a, b \in \mathbb{R}$ , y  $a \neq 0$ .

La Figura 4-1 muestra el espectrograma de una señal luego de pasar por la transformada Wavelet conocida como sombrero mexicano o *mexican hat*. En esta se puede ver cómo las diferentes amplitudes pueden ser localizadas tanto en tiempo como en frecuencia.



**Figura 4-1:** a) Señal Sinusoidal Multi Espectral, b) Espectrograma de la Señal en a) Transformada por la Wavelet *Mexican Hat*.

La versión discreta de la transformada Wavelet (DWT) se obtiene al discretizar los parámetros  $a$  y  $b$ , y generalmente suele ser utilizada la Wavelet diádica, la cual se produce al emplear potencias de 2 para los parámetros  $a$  y  $b$ , siendo  $a = 2^j$  y  $b = k2^j$ , con  $j, k \in \mathbb{N}$ .

$$\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j}t - k) \quad (4-4)$$

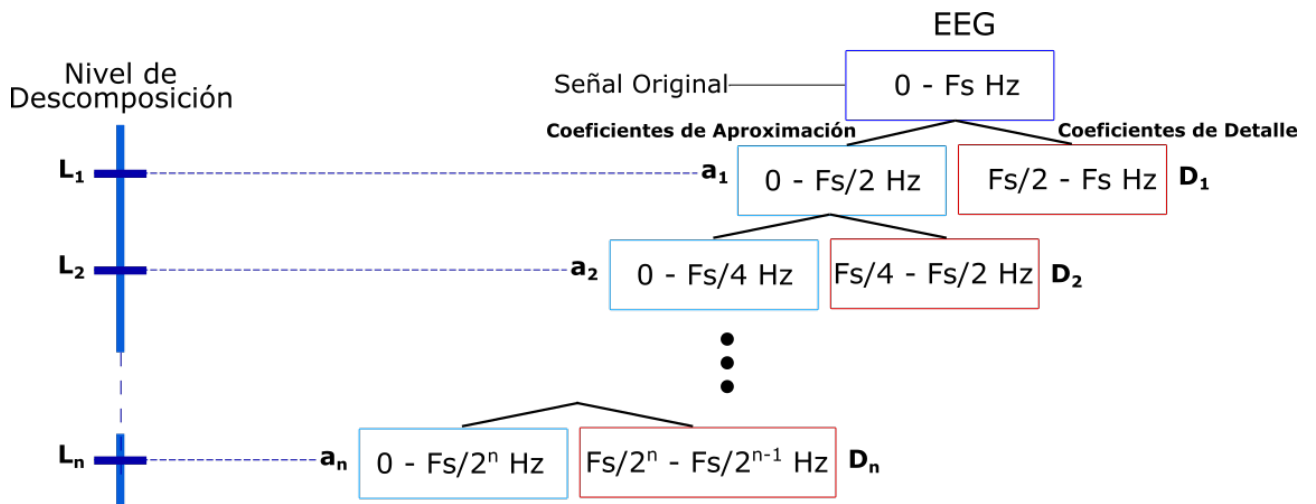
De forma general la transformada Wavelet de una función  $f(n)$  discretizada puede ser escrita como en la ecuación (4-5).

$$W(j, k) = C_{j,k} = \frac{1}{\sqrt{j}} \sum_{-\infty}^{\infty} f(n) \psi_{j,k}(n) \quad (4-5)$$

Siendo  $W(j, k)$  valores conocidos como los coeficientes Wavelet que permiten hacer una reconstrucción perfecta de la señal original. Para esto se suman las funciones base Wavelet  $\psi(n)$  ponderadas por los coeficientes  $C_{j,k}$  [105], de la siguiente forma:

$$f(n) = \sum_j \sum_k C_{j,k} \psi_{j,k}(n) \quad (4-6)$$

A menudo la transformada de Wavelet discreta es utilizada como filtro para el análisis en múltiples resoluciones, para ellos se ajusta el parámetro de nivel de descomposición  $L$ . Cada uno de los niveles de descomposición corresponde a una banda de frecuencia determinada [31], y para cada banda se obtienen coeficientes de detalle y coeficientes de aproximación. Los primeros describen la señal en las frecuencias comprendidas entre la frecuencia de muestreo original y la frecuencia del nivel de descomposición, mientras que los coeficientes de detalle representan la señal desde 0 Hz hasta la frecuencia del nivel  $L$ , lo anterior puede ser visto en la Figura 4-2.



**Figura 4-2:** Descomposición del EEG en sus Coeficientes de Aproximación y Detalle.

Esta descomposición en niveles de frecuencia es ampliamente utilizada en señales EEG, dado que se puede filtrar la señal en los ritmos del EEG ( $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ , y  $\gamma$ ) para analizar de forma independiente la información de cada banda. Adicionalmente, los coeficientes de detalle y aproximación son utilizados para hacer caracterización de los segmentos EEG, construyendo vectores de características que almacenan los coeficientes obtenidos al emplear determinada Wavelet [31]. Por otro lado, en algunos estudios se calculan características estadísticas de diferente orden sobre los coeficientes de Wavelet, estos pueden ser el valor máximo y mínimo de los coeficientes, la media, la mediana, moda, curtosis, y oblicuidad.


A continuación se listan algunas de las Wavelets más utilizadas en el estudio del EEG:

- Biortogonal
- Symlet
- Coiflet
- Daubechies
- Meyer Discreta
- Haar

### 4.3. Análisis de Conectividad.

La habilidad de las neuronas de establecer uniones e interacciones oscilatorias a grandes escalas debido a patrones complejos de conectividad, deriva en dos conceptos que son fundamentales para el análisis de la interacción de grupos neuronales que están distribuidos en el cerebro, estos son la conectividad anatómica y conectividad funcional. El primero de ellos se refiere a la disposición específica de las fibras neuronales que conectan las diferentes regiones del cerebro, y el segundo es un término fundamentalmente estadístico que determina la existencia de patrones sincronizados en la activación temporal de regiones neuronales usualmente remotas [46].

Generalmente, las medidas de conectividad son calculadas en el dominio de la frecuencia, utilizando pares de señales que almacenan información a través de diferentes épocas, y una serie de frecuencias específicas, estimando así la fase y amplitud de las oscilaciones. Esta estimación puede ser representada como un complejo  $Ae^{i\phi}$  [12], que puede ser ubicado en un plano cartesiano como un punto  $P$  de dos dimensiones, la distancia del vector que une el origen con dicho punto representa la amplitud  $A$ , y el ángulo  $\phi$  que este forma con el eje  $X$  es la fase, esto se puede ver representado en la Figura 4-3.



**Figura 4-3:** Representación en Coordenadas Polares de una Señal en el Dominio de la Frecuencia.

### 4.3.1. Coeficiente de la Coherencia.

Una de las formas más utilizadas para calcular la conectividad entre señales es la coherencia. La coherencia indica la cantidad de varianza en una de las señales que puede ser explicada por la otra señal, y viceversa, además es una medida normalizada entre 0 y 1 y matemáticamente se describe como:

$$Coh_{xy}(w) = \frac{|\frac{1}{n} \sum_{k=1}^n A_x(w, k) A_y(w, k) e^{i(\phi_x(w, k) - \phi_y(w, k))}|}{\sqrt{(\frac{1}{n} \sum_{k=1}^n A_x^2(w, k)) (\frac{1}{n} \sum_{k=1}^n A_y^2(w, k))}} \quad (4-7)$$

En la ecuación (4-7) el numerador representa la densidad espectral de potencia cruzada entre las señales  $x$  e  $y$  en una frecuencia  $w$  en promedio de las épocas  $n$  y el denominador es el producto de las densidades espectrales individuales de cada señal en el promedio de las épocas. La ecuación (4-7) puede reescribirse omitiendo los componentes complejos, como se ve en la ecuación (4-8).

$$Coh_{xy}(w) = \frac{|S_{xy}(w)|}{\sqrt{S_{xx}(w) S_{yy}(w)}} \quad (4-8)$$

Adicionalmente, la matriz de densidad espectral viene dada por:

$$\mathbf{S} = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{yx} & S_{yy} \end{bmatrix} \quad (4-9)$$

La diagonal principal de la matriz de la ecuación (4-9) representa la potencia individual de las señales  $x$  e  $y$  y los elementos que están fuera de esta son la potencia cruzada de ambas señales.

### 4.3.2. Parte Imaginaria de la Coherencia.

La parte imaginaria de la coherencia (ICOH) se obtiene al proyectar el valor complejo de la coherencia en un eje imaginario. Se utiliza para describir la sincronización de fase entre dos señales  $x(t)$  e  $y(t)$ . La ecuación para esto es, al igual que en la coherencia, la ecuación (4-7), teniendo en cuenta que la parte imaginaria de la coherencia es extraída previo al cálculo de la magnitud. La ICOH es mínima cuando el espectro cruzado entre  $x(t)$  e  $y(t)$  tienen fase 0 o  $180^\circ$ , y máxima en  $\pm 90^\circ$  [119].

### 4.3.3. Valor de Bloqueo de Fase.

El valor de bloqueo de fase, más conocido como PLV (por sus siglas en inglés de *Phase Locking Value*), es el valor absoluto del promedio de la diferencia entre fases de dos señales  $x$  e  $y$  [123]. Este es el resultado de aplicar la ecuación (4-7) a señales normalizadas que pasaron por la transformada de Fourier (ver ecuación (4-10)), y se ha encontrado en la literatura que el PLV logra separar los componentes de fase de los de amplitud aún mejor que la coherencia [123, 12].

$$PLV_{xy}(w) = \frac{\left| \frac{1}{n} \sum_{k=1}^n 1_x(w, k) 1_y(w, k) e^{i(\phi_x(w, k) - \phi_y(w, k))} \right|}{\sqrt{\left( \frac{1}{n} \sum_{k=1}^n 1_x^2(w, k) \right) \left( \frac{1}{n} \sum_{k=1}^n 1_y^2(w, k) \right)}} \quad (4-10)$$

De esta manera, la ecuación (4-11) expresa la forma reducida de PLV:

$$PLV_{xy}(w) = \left| \frac{1}{n} \sum_{k=1}^n e^{i(\phi_x(w, k) - \phi_y(w, k))} \right| \quad (4-11)$$

## 4.4. Teoría de Grafos.

Un grafo puede ser definido como  $G = (V, E, \mathbf{W})$ , donde  $V$ ,  $E$  son el conjunto de vértices y aristas del grafo, y  $\mathbf{W}$  es la matriz de adyacencia que describe la conexión entre cada par

de vértices o nodos en  $V$ , de tal manera que  $\mathbf{W}_{pq}$  representa la importancia de la conexión existente entre el nodo  $p$  y el nodo  $q$  [123]. En el contexto del análisis de EEG, los nodos hacen referencia a los electrodos y la conexión entre estos es hallada haciendo uso de las medidas de conectividad.

Los grafos formados por la conectividad funcional del EEG son grafos indirectos, esto se debe a que el grafo se mueve entre sus nodos en diferentes direcciones, a diferencia de los grafos directos que se mueven en una sola dirección.

Con el fin de establecer un filtro entre los valores que realmente representan una conexión entre nodos, y aquellos espurios o que son originados por ruido, se crea un grafo binario  $\Gamma$ , de  $N$  nodos y  $K$  aristas, su matriz de adyacencia  $\mathbf{A}_{ij}$  es una matriz cuadrada de  $N \times N$  [50]. El elemento  $i, j$  corresponde al valor de conectividad entre el electrodo  $i$  y  $j$ , el cual es llevado a 0 si este es inferior al umbral establecido  $\tau$ , o 1 si es mayor, formando así el grafo binario [113].

Los grafos contienen características estructurales que se describen por algunas métricas, las cuales pueden ser globales o locales.

#### 4.4.1. Métricas Globales.

Estas métricas se relacionan directamente con el nivel de integración de las redes, en este caso, la integración que existe entre los electrodos de diferentes regiones. Una de las medidas más utilizadas es la distancia promedio de las rutas entre dos nodos  $L$ , se calcula como en la ecuación (4-12).

$$L = \frac{1}{N(N-1)} \sum_{i \neq j} d_{ij} \quad (4-12)$$

La distancia  $L$  da noción del flujo de información que existe al interior de la red, además se puede calcular la eficiencia global del grafo  $E_g$ , que determina el número de conexiones existentes entre todos los nodos, por tanto, un grafo con  $E_g = 0$  indica que no hay conexiones o es vacío, y uno con  $E_g = 1$  está totalmente conectado. La ecuación (4-13) describe el cálculo de la eficiencia global, expresándose como la media del inverso de las distancias para todos los pares de nodos  $i, j$  [20].

$$E_g = \frac{1}{N(N-1)} \sum_{i \neq j} \frac{1}{d_{ij}} \quad (4-13)$$

#### 4.4.2. Métricas Locales.

Las métricas locales indican el nivel de segregación que existe en los grafos, esto puede ser visto como los subgrafos  $S_i$  que pueden ser generados a partir de  $\Gamma$ . El coeficiente de

agrupamiento  $C$  es uno de los más utilizados en medidas locales, puede ser calculado a partir de los coeficientes  $C_i$ , que corresponden al número de aristas restantes en cada  $S_i$  al ser removido el nodo  $i$ . Para calcular  $C$  se calcula la media de todos los  $C_i$  como se ve en la ecuación (4-14).

$$C = \frac{1}{N} \sum_i C_i \quad (4-14)$$

Al igual que en las métricas globales, la eficiencia local  $E_l$  es calculada (ver ecuación (4-15)), y evalúa las propiedades locales y su tendencia para generar agrupaciones. Esta medida cuantifica la transferencia de información en regiones específicas del cerebro [50].

$$E_l = \frac{1}{N} \sum_{i=1}^n E_g(S_i) \quad (4-15)$$

Dependiendo de la eficiencia global y local, los grafos pueden ser catalogados en regulares, aleatorios y de mundo pequeño. Los primeros se caracterizan por tener una alta eficiencia local y baja eficiencia global, contrario a las redes aleatorias que poseen alta eficiencia global y baja local y por último las redes de mundo pequeño poseen una alta eficiencia global y local. Para el caso de los grafos construidos a partir de EEG, [20] sugiere que las redes mantienen un balance entre segregación e integración de la información, lo cual indica que estas redes son de mundo pequeño. Para tener certeza de la categoría de la red, se puede evaluar el coeficiente  $C$  y la longitud  $L$  normalizadas por un grafo aleatorio del mismo número de nodos, aristas y grados de distribución que en el original, por tanto un coeficiente de mundo pequeño  $S$  puede ser calculado como:

$$S = \frac{\frac{C}{C_{ale}}}{\frac{L}{L_{ale}}} \quad (4-16)$$

Donde  $C_{ale}$  y  $L_{ale}$  de la ecuación (4-16) son el coeficiente de agrupamiento y la longitud del grafo aleatorio.

## 4.5. Sumario.

En este capítulo se introducen las bases teóricas y formulación matemática, utilizada en el estado del arte en relación a las metodologías de caracterización en el análisis de señales electroencefalográficas. Usualmente son planteados análisis que combinan información en tiempo, frecuencia y espacio, por lo cual se expone el análisis de conectividad que combina espacio y frecuencia, ayudado de la teoría de grafos para determinar características estructurales y de segregación en las redes generadas entre electrodos, y análisis tiempo-frecuencia empleando la transformada Wavelet, especialmente en su forma discreta.



# 5 Clasificación y Análisis de Relevancia

## 5.1. Introducción.

La clasificación es la etapa del aprendizaje de máquina en donde se evalúan las características que describen a una muestra  $n$  del conjunto de datos  $N$  y con base en el entrenamiento que recibió previamente el clasificador asociando características con etiquetas, se le asigna a la muestra  $n$  la clase correspondiente. Los algoritmos de clasificación crean fronteras de decisión en un espacio de dimensionalidad  $N$  generado por las propias características, de esta forma, se logra ver la gran importancia de la caracterización para obtener una clasificación exitosa.

En el estado del arte se han utilizado numerosos métodos de clasificación para tareas de electroencefalografía, los cuales han mostrado un rendimiento sobresaliente. Usualmente estas tareas buscan identificar regiones cerebrales afectadas, desordenes mentales, identificación de movimientos imaginados y ejecutados, mayor precisión en interfaces cerebro computadora, análisis del procesamiento emocional, entre otras. Algunos de los algoritmos más utilizados para hacer clasificación son: árboles de decisión [47, 18, 2], redes neuronales artificiales (ANN) [83, 73, 124],  $k$ -vecinos más cercanos (KNN) [84], y máquinas de vectores de soporte (SVM) [29, 111]. Estudios comparativos han mostrado que las SVM obtienen mejores resultados que los demás métodos mencionados [57, 13, 48] para tareas como procesamiento emocional, lo cual las ubica como una técnica confiable para el estudio de EEG.

Publicaciones recientes han conseguido mejorar el rendimiento de las SVM utilizando algoritmos híbridos, como en [49], donde utilizan Cadenas Ocultas de Markov a la salida de la SVM para encontrar información que no es percibida en la etapa anterior, también se han realizado modificaciones a las bases matemáticas de las SVM para solucionar problemas como lo hacen en [98], al implementar una técnica denominada *Universum Support Vector Machine* que reduce el efecto de valores atípicos en la clasificación. Este tipo de investigaciones muestra que las máquinas de vectores de soporte tienen un amplio potencial por explorar, en búsqueda de perfeccionar los parámetros que discriminan las etiquetas de clase.

## 5.2. Teoría de Kernels.

### 5.2.1. Definición.

Los kernel son medidas de similitud halladas entre un par de muestras  $\mathbf{x}_i, \mathbf{x}_j$  en el espacio de características proyectado por la función  $\phi$ . La similitud es medida por productos punto en algún espacio de dimensionalidad  $F$ , la cual dependiendo del kernel puede ser una dimensión infinita [108]. Para evitar trabajar en dimensiones de alta complejidad se busca una representación en la cual se puedan utilizar modelos en el espacio de entrada; esto se puede obtener a través del truco kernel. El truco kernel permite realizar el calculo de la similitud entre muestras en el espacio de las características, sin necesidad de calcular las coordenadas de dichas muestras en un espacio de alta dimensionalidad, disminuyendo así el costo computacional.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \quad (5-1)$$

Algunos de los kernels más conocidos y utilizados son:

Kernel	Ecuación	Descripción
Lineal	$K_{lin} = \langle \mathbf{x}_i, \mathbf{x}_j \rangle$	Producto punto simple entre los valores de entrada.
Polinómico	$K_{pol} = (\langle \mathbf{x}_i, \mathbf{x}_j \rangle + 1)^p$	Producto punto elevado a la potencia $p$ .
Exponencial	$K_{exp} = exp(-\ \mathbf{x}_i - \mathbf{x}_j\ _2 / \sigma^2)$	Calcula la distancia euclidiana entre las entradas y las divide por un parámetro asociado a la distribución de los datos, con $\sigma \in \{R_{++}\}$ .
Gaussiano	$K_{gau} = exp(-\ \mathbf{x}_i - \mathbf{x}_j\ _2^2 / \sigma^2)$	Calcula la distancia euclidiana cuadrada entre las entradas y las divide por un parámetro asociado a la distribución de los datos, con $\sigma \in \{R_{++}\}$ .

### 5.2.2. Kernel Definido Positivo.

Para que una función  $K$  pueda generar un kernel en un espacio de dimensión  $F$  que separe linealmente las clases del conjunto de datos  $D$ , debe cumplir ser definido positivo, de esta forma,  $K : \mathbf{X} \times \mathbf{X} \rightarrow \mathbb{R}$  para todo  $m \in \mathbb{N}$ ,  $\mathbf{x}_i \in \mathbb{X}$  da lugar a una matriz de Gram definida positiva, por lo cual para toda las constantes  $c_i, c_j$  se tiene que [108]:

$$\sum_{i,j=1}^m c_i c_j \mathbf{K}_{ij} \geq 0 \quad (5-2)$$

### 5.2.3. Alineación de Kernels.

En la clasificación binaria se tienen  $n$  pares de muestras de entrenamiento  $D = (\mathbf{x}_i, \mathbf{y}_i)_{i=1}^n$ , donde  $\mathbf{x}_i \in \mathbb{X} \in \mathbb{R}^D$ , cada  $\mathbf{x}$  llevado al espacio  $F$  por  $\phi(\mathbf{x})$  ( $\phi : \mathbb{X} \rightarrow F$ ) determinado por una función kernel  $K$ . La matriz de Gram  $\mathbf{K}$  del kernel  $K$  se define como  $[\mathbf{K}]_{i,j} = K(\mathbf{x}_i, \mathbf{x}_j)$ , de este modo, para calcular la alineación  $A$  de dos kernels  $\mathbf{K}_1$  y  $\mathbf{K}_2$  que determina la similitud de las matrices de Gram asociadas a estos se utiliza la ecuación (5-3) [122].

$$A(\mathbf{K}_1, \mathbf{K}_2) = \frac{\langle \mathbf{K}_1, \mathbf{K}_2 \rangle_F}{\sqrt{\langle \mathbf{K}_1, \mathbf{K}_1 \rangle_F \langle \mathbf{K}_2, \mathbf{K}_2 \rangle_F}} \quad (5-3)$$

La función  $\langle \mathbf{K}_1, \mathbf{K}_2 \rangle_F$  denota el producto Frobenius entre  $\mathbf{K}_1$  y  $\mathbf{K}_2$  que realiza la siguiente operación:

$$\langle \mathbf{K}_1, \mathbf{K}_2 \rangle_F = \sum_{i=1}^n \sum_{j=1}^n \mathbf{K}_1(\mathbf{x}_i, \mathbf{x}_j) \mathbf{K}_2(\mathbf{x}_i, \mathbf{x}_j) \quad (5-4)$$

Aplicando el concepto de alineación de kernel a la clasificación, se puede encontrar la similitud existente entre el kernel  $\mathbf{K}$  formado por las características, y uno creado a partir de las etiquetas de clase  $\mathbf{K}^* = \mathbf{y}\mathbf{y}^T$ , así [36]:

$$A(\mathbf{K}, \mathbf{K}^*) = \frac{\langle \mathbf{K}, \mathbf{K}^* \rangle_F}{\sqrt{\langle \mathbf{K}, \mathbf{K} \rangle_F \langle \mathbf{K}^*, \mathbf{K}^* \rangle_F}} = \frac{\mathbf{y}^T \mathbf{K} \mathbf{y}}{\|\mathbf{K}\|_F} \quad (5-5)$$

### 5.2.4. Centrado de Kernels.

Si  $P$  es la distribución que representa los puntos de entrenamiento y test del conjunto de datos  $D$ , el centrado de kernels se produce al hacer  $\phi - E_x[\phi]$ , esto es, substrar el valor esperado  $E_x[\phi]$  de la función  $\phi$ . El centrado de un kernel definido positivo  $\mathbf{K}$  implica centrar todo  $\phi$  asociado a  $\mathbf{K}$  [33], de tal manera que el kernel centrado  $\mathbf{K}_c$  asociado a  $\mathbf{K}$  es definido para todo  $\mathbf{x}_i, \mathbf{x}_j \in \mathbb{X}$  como:

$$\begin{aligned} K_c(\mathbf{x}_i, \mathbf{x}_j) &= (\phi(\mathbf{x}_i) - E_{\mathbf{x}_i}[\phi])^T (\phi(\mathbf{x}_j) - E_{\mathbf{x}_j}[\phi])^T \\ &= K(\mathbf{x}_i, \mathbf{x}_j) - E_{\mathbf{x}_i}[K(\mathbf{x}_i, \mathbf{x}_j)] - E_{\mathbf{x}_j}[K(\mathbf{x}_i, \mathbf{x}_j)] + E_{\mathbf{x}_i, \mathbf{x}_j}[K(\mathbf{x}_i, \mathbf{x}_j)] \end{aligned} \quad (5-6)$$

### 5.2.5. Aprendizaje Multi Kernel.

El aprendizaje multi kernel (conocido generalmente como MKL por sus siglas en inglés de *Multiple Kernel Learning*), es un grupo de métodos matemáticos y algoritmos que se utilizan para combinar la información de diferentes kernels, cuya formulación está basada

en la alineación mostrada anteriormente como se explica en [81, 33]. El objetivo principal es poder optimizar la información contenida en los kernels haciendo una combinación lineal o no lineal de estos.

$$k_{\boldsymbol{\eta}}(\mathbf{x}_i, \mathbf{x}_j) = f_{\boldsymbol{\eta}}(k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)_{m=1}^p) \quad (5-7)$$

Donde  $f_{\boldsymbol{\eta}} : \mathbb{R}^p \rightarrow \mathbb{R}$  es la función de combinación y puede ser lineal o no lineal. Los kernels  $k_m : \mathbb{R}^D \times \mathbb{R}^D \rightarrow \mathbb{R}$  realizan  $p$  representaciones basadas en características de las instancias  $\mathbf{x}_i = \mathbf{x}_i^m_{m=1}$ , e  $\boldsymbol{\eta}$  parametriza la función de combinación, siendo la más común la que se muestra en la ecuación (5-8) [81].

$$k_{\boldsymbol{\eta}}(\mathbf{x}_i, \mathbf{x}_j) = f_{\boldsymbol{\eta}}(k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)_{m=1}^p | \boldsymbol{\eta}) \quad (5-8)$$

Si los parámetros de la combinación son conocidos previamente, lo anterior se puede expresar como:

$$k_{\boldsymbol{\eta}}(\mathbf{x}_i, \mathbf{x}_j) = f_{\boldsymbol{\eta}}(k_m(\mathbf{x}_i^m, \mathbf{x}_j^m | \boldsymbol{\eta})_{m=1}^p) \quad (5-9)$$

El aprendizaje multi kernel puede ser usado de dos formas dependiendo el origen de la información de los kernel individuales. La primera de ella es utilizando kernels que tienen entre sí diferentes medidas de similitud, de tal modo que en vez de buscar cual es la mejor, se le permite al algoritmo hacer selección de la que considere sobresaliente, o encontrar una nueva utilizando una combinación. La segunda forma de utilizar MKL es tomando kernels que provienen de diferentes representaciones, lo cual puede darse al venir de diferentes fuentes o modalidades [81]. Adicionalmente, en [81] se taxonomizan los algoritmos de MKL según diferentes criterios, de los cuales utilizamos los siguientes en este documento de tesis.

- Método de aprendizaje: este criterio hace referencia a la forma en que se calcula la función de combinación de kernels, sobre todo en el enfoque que se da para encontrar la parametrización de los algoritmos, estos métodos de aprendizaje pueden ser: heurísticos, de reglas fijas, optimizados (deterministas), bayesianos, y de aprendizaje impulsado.
- Forma funcional: como se mencionó anteriormente, la función de combinación  $f_{\boldsymbol{\eta}}$  puede ser tanto lineal como no lineal, este criterio hace referencia precisamente a esta condición, para la que se tiene que de forma lineal  $f_{\boldsymbol{\eta}}$  esta dada por:

$$k_{\boldsymbol{\eta}}(\mathbf{x}_i, \mathbf{x}_j) = f_{\boldsymbol{\eta}}(k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)_{m=1}^p | \boldsymbol{\eta}) = \sum_{m=1}^p \eta_m k_m(\mathbf{x}_i^m, \mathbf{x}_j^m) \quad (5-10)$$

- Función objetivo: aquí se agrupan las funciones a optimizar en tres categorías: basado en similitud, funciones de riesgo estructural, y bayesianas.

De la ecuación (5-10) surgen diferentes proposiciones para hallar los pesos  $\boldsymbol{\eta}$  óptimos. En este trabajo se asumen pesos positivos normalizados resolviendo el siguiente problema de optimización propuesto en [81] para la alineación centrada entre el kernel de combinación  $\mathbf{K}_\eta$  y el kernel de etiquetas  $\mathbf{y}\mathbf{y}^T$ :

$$\max_{\mathbf{a}, \boldsymbol{\eta} \in \mathbb{M}} A_c(\mathbf{K}_\eta, \mathbf{y}\mathbf{y}^T) \quad (5-11)$$

Donde  $\mathbb{M} = \boldsymbol{\eta} : \|\boldsymbol{\eta}\|_2 = 1, \boldsymbol{\eta} \in \mathbb{R}_+^P$ , lo anterior se obtiene resolviendo el problema de optimización cuadrática que sigue:

$$\min_{\mathbf{a}, \mathbf{v} \in \mathbb{R}_+^P} \mathbf{v}^T \mathbf{M} \mathbf{v} - 2\mathbf{v}^T \mathbf{a} \quad (5-12)$$

Con  $\mathbf{M} = \{\langle \mathbf{K}_m^c, \mathbf{K}_h^c \rangle_F\}_{m,h=1}^P$ , y  $\mathbf{a} = \{\langle \mathbf{K}_m^c, \mathbf{y}\mathbf{y}^T \rangle_F\}_{m=1}^P$ . Finalmente se tiene que:

$$\boldsymbol{\eta} = \mathbf{v} / \|\mathbf{v}\|_2 \quad (5-13)$$

En [4] se expone otro método para encontrar  $\boldsymbol{\eta}$ , en este se utiliza el algoritmo KOMD que trata de minimizar la siguiente expresión.

$$\min_{\gamma \in \hat{\Gamma}} D(\gamma) := \gamma^T \hat{\mathbf{Y}} \hat{\mathbf{K}} \hat{\mathbf{Y}} \gamma \quad (5-14)$$

Siendo  $\hat{\Gamma}$  la distribución de probabilidad  $\gamma \in \mathbb{R}_+^M$  definidas sobre el conjunto de muestras de ambas clases. Luego se tiene que el problema de optimización para encontrar los pesos de cada kernel  $K$  es:

$$\max_{\|\boldsymbol{\eta}\|=1} \min_{\gamma \in \Gamma} (1 - \lambda) \gamma^T \hat{\mathbf{Y}} \left( \sum_r \boldsymbol{\eta}_r \hat{\mathbf{K}}_r \right) \hat{\mathbf{Y}} \gamma + \lambda \|\gamma\|^2 = \max_{\|\boldsymbol{\eta}\|=1} \min_{\gamma \in \Gamma} Q(\boldsymbol{\eta}, \gamma) \quad (5-15)$$

Donde  $Q(\boldsymbol{\eta}, \gamma) = (1 - \lambda) \boldsymbol{\eta}^T \mathbf{d}(\gamma) + \lambda \|\gamma\|^2$ , y la entrada  $r$  de  $d(\gamma)$  es  $d(\gamma) = \gamma^T \hat{\mathbf{Y}} \hat{\mathbf{K}} \hat{\mathbf{Y}} \gamma$ . Por tanto los pesos quedan definidos como:

$$\boldsymbol{\eta} = \frac{\mathbf{d}(\gamma)}{\|\mathbf{d}(\gamma)\|} \quad (5-16)$$

### 5.3. Máquinas de Vectores de Soporte.

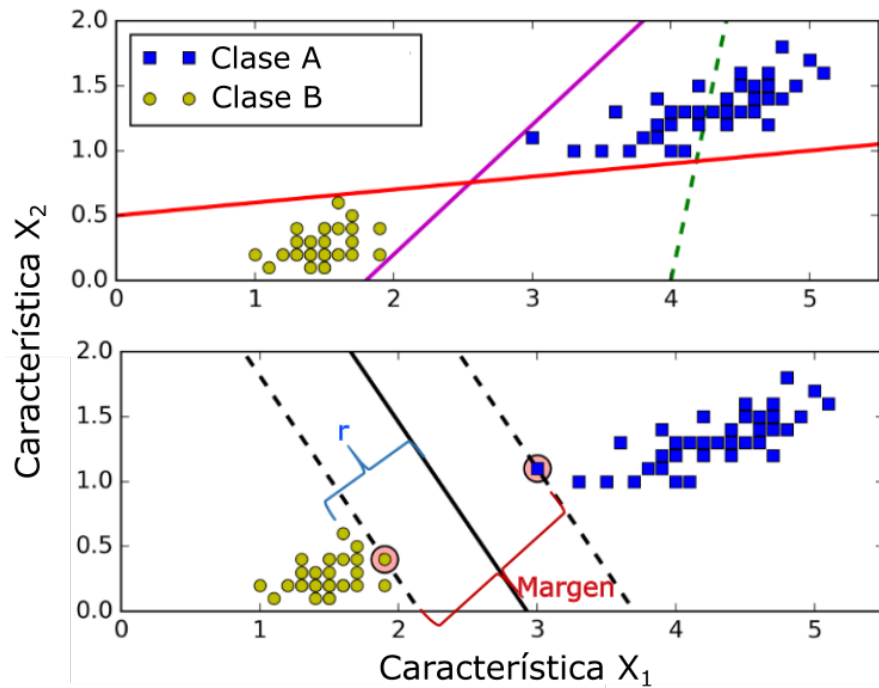
Las máquinas de vectores de soporte (también conocidas como máquinas de soporte vectorial) son uno de los modelos más conocidos y utilizados en el aprendizaje de máquina, suponen una herramienta muy versátil, siendo utilizadas para clasificación lineal y no lineal, regresión, y detección de valores atípicos [44]. Este modelo surge de la teoría de aprendizaje estadístico de Vladimir Vapnik [34] establecida alrededor de los años noventa.

El problema general de clasificación binaria dicta que dado un conjunto de datos  $D = (\mathbf{x}_i, \mathbf{y}_i | i = 1, 2, \dots, n)$ , donde  $\mathbf{x}_i \in \mathbb{R}^D$  y  $\mathbf{y}_i \in \pm 1$  es la etiqueta de clase correspondiente a cada  $\mathbf{x}_i$ , el objetivo es obtener una función  $f(\mathbf{x})$  que minimice la función de costo  $l(\mathbf{y}_i, f(\mathbf{x}_i))$  que evalúa el error promedio entre todas las pruebas  $i \in n$ . En el caso de las SVM, la función de costo dependerá del tipo de margen que se utilice, esta puede ser dura (también conocida como rígida) o blanda.

La ecuación (5-17) representa la función  $f(\mathbf{x})$  para una margen rígida, asumiendo que los datos de entrada son separables, en donde  $\mathbf{w}$  es un vector unitario normal al hiperplano de separación,  $(\mathbf{x}, \mathbf{w}) = \mathbf{x}^T \mathbf{w}$  es el producto punto entre  $\mathbf{w}$  y  $\mathbf{x}$ , y  $b$  es una constante de parcialidad [130].

$$f(\mathbf{x}) = (\mathbf{w}, \mathbf{x}) + b = 0 \quad (5-17)$$

La márgen en las SVM representan la distancia que hay entre los vectores de soporte de ambas clases, siendo los vectores de soporte las muestras que tienen la menor distancia hacia el hiperplano de separación o frontera de decisión [44]. Lo anterior se representa gráficamente como en la Figura 5-1, en donde las muestras o instancias de las clases A y B son representadas en un espacio  $\mathbb{R}^2$  formado por las características  $X_1$  y  $X_2$ . En este, las muestras son separadas por múltiples hiperplanos (para el caso de  $\mathbb{R}^2$  una línea recta). En el cuadro superior se muestra como los planos en morado y rojo logran separar perfectamente ambas clases; sin embargo, en el cuadro inferior se puede ver que el plano generado separa las clases y además mantiene la máxima distancia entre los vectores de soporte y el hiperplano, siendo esta la solución óptima al problema [34].



**Figura 5-1:** Separación de Clases Utilizando Máquinas de Vectores de Soporte.

Dado que es posible que existan instancias que violen la margen, lo cual se puede dar al quedar dentro de la margen o en la frontera de decisión equivocada, se incorporó una forma suave o blanda como extensión al modelo de margen dura que permitiera ser flexible con la solución final. La formulación matemática para esto se ve en la ecuación (5-18).

$$f(\mathbf{x}) = (\mathbf{w}, \mathbf{x}) + b \geq 1 \text{ si } y_i = 1 \quad (5-18)$$

$$f(\mathbf{x}) = (\mathbf{w}, \mathbf{x}) + b \leq -1 \text{ si } y_i = -1$$

De forma generalizada se tiene [121]:

$$\mathbf{y}_i[(\mathbf{w}, \mathbf{x}_i) - b] \geq 1, \quad i \in n \quad (5-19)$$

La distancia entre una muestra  $\mathbf{x}_i$  y el hiperplano de separación puede ser calculada con la ecuación (5-20).

$$r_i = \frac{\mathbf{w}^T \mathbf{x}_i + b}{\|\mathbf{w}\|} \quad (5-20)$$

Las variables  $\mathbf{w}$  y  $b$  son calculadas minimizando la siguiente función objetivo o función de

regularización.

$$R(\mathbf{w}, b) = C \sum_{i=1}^n l(\mathbf{y}_i, f(\mathbf{x}_i)) + \frac{1}{2} \|\mathbf{w}\|_2^2 \quad (5-21)$$

En la ecuación (5-21)  $C$  es un parámetro de regularización que juega un papel fundamental en la asignación de etiquetas, ya que controla la tasa de aprendizaje de la SVM realizando una penalización en el entrenamiento, provocando así que la curva se ajuste más a las instancias conocidas, por tanto a medida que el parámetro  $C$  crece, incrementa la posibilidad de sobre entrenar el algoritmo, perdiendo generalización en el modelo final. La solución de la ecuación anterior lleva a lo que se conoce como el problema primario [28]:

$$\begin{aligned} & \min_{\mathbf{w}, b, \xi} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \xi_i \\ & s.t \ \mathbf{y}_i (\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, \\ & \quad \xi_i \geq 0, i = 1, \dots, n \end{aligned} \quad (5-22)$$

Siendo  $\phi(\mathbf{x}_i)$  una función que mapea  $\mathbf{x}_i$  a una espacio de mayor dimensión, y  $\xi$  es una variable de holgura. Por lo general este problema se resuelve empleando multiplicadores de Lagrange  $\alpha$  de la siguiente forma.

$$\begin{aligned} & \min_{\alpha} \frac{1}{2} \alpha^t \mathbf{Q} \alpha - \mathbf{e}^T \alpha \\ & s.t \ \mathbf{y}^T \alpha = 0, \end{aligned} \quad (5-23)$$

$$0 \leq \alpha_i \leq C, \ i = 1, \dots, n$$

A la ecuación (5-23) se le conoce como el problema dual, donde  $\mathbf{e} = [1, \dots, 1]^T$  es un vector de unos,  $\mathbf{Q}$  es un matriz cuadrada definida semipositiva de tamaño  $n \times n$ ,  $\mathbf{Q}_{ij} \equiv \mathbf{y}_i \mathbf{y}_j K(\mathbf{x}_i, \mathbf{x}_j)$ , y  $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$  es la función kernel [28]. Luego de ser resuelto el problema dual, se tiene que  $\mathbf{w}$  satisface:

$$\mathbf{w} = \sum_{i=1}^n \mathbf{y}_i \alpha_i \phi(\mathbf{x}_i) \quad (5-24)$$

Se obtiene entonces que la función de decisión esta dada por la ecuación (5-25).

$$\text{sgn}(\mathbf{w}^T \phi(\mathbf{x}) + b) = \text{sgn}\left(\sum_{i=1}^n \mathbf{y}_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + b\right) \quad (5-25)$$



Es importante resaltar la importancia de la función kernel en este abordaje, dado que es la que permite un análisis no lineal en el conjunto de entrada, esto sucede al calcular la similitud de los datos en un espacio de mayor dimensión donde se supone son linealmente separables, y luego al volver al espacio original se espera obtener una discriminación entre clases no necesariamente lineal.

## 5.4. Métricas de Evaluación.

Las métricas de evaluación, son un conjunto de herramientas matemáticas que dan cuenta del rendimiento o desempeño de la clasificación a través del análisis estadístico, diferentes métricas evalúan ciertas características que son inducidas por el algoritmo de clasificación [53].

Asumiendo que se tienen las clases positiva (P) y negativa (N) en un problema de clasificación binaria, se busca que una muestra desconocida sea clasificada correctamente con la etiqueta P o N [117], sin embargo, el clasificador puede etiquetar incorrectamente las muestras, asumiendo uno de los casos representados por la matriz de confusión expuestos en la Figura 5-2.

		Clase Real	
		Positivo	Negativo
Clase Asignada	Positivo	Verdadero Positivo	Falso Positivo
	Negativo	Falso Negativo	Verdadero Negativo

**Figura 5-2:** Matriz de Confusión Para Clasificación Binaria.

A continuación, se muestran las métricas más utilizadas para describir el rendimiento de un clasificador con base a la matriz de confusión.

- **Exactitud:** la exactitud se define como el radio entre las muestras correctamente

clasificadas y el total de muestras [117]. Se calcula como:

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (5-26)$$

Con  $VP$  verdaderos positivos,  $VN$  verdaderos negativos,  $FP$  falsos positivos, y  $FN$  falsos negativos.

- **Sensibilidad:** la sensibilidad, también conocida como tasa de positividad verdadera (TPR por sus siglas en inglés) hace referencia a las clases etiquetadas correctamente como positivas con respecto al número total de etiquetas positivas reales. La ecuación (5-27) muestra la forma de calcular la sensibilidad.

$$Sensibilidad = \frac{VP}{VP + FN} = \frac{VP}{P} \quad (5-27)$$

- **Especificidad:** a diferencia de la sensibilidad, esta medida hace referencia a las clases etiquetadas correctamente como negativas con respecto al número total de etiquetas negativas reales. Se calcula como:

$$Especificidad = \frac{VN}{VN + FP} = \frac{VN}{N} \quad (5-28)$$

- **Precisión:** también conocido como el valor predictivo positivo ( $VPP$ ), relaciona el número de etiquetas correctamente clasificadas como positivas sobre el número total de etiquetas asignadas como positivas, así:

$$VPP = \frac{VP}{FP + VP} \quad (5-29)$$

- **Puntaje F1:** Es la media armónica entre la precisión y la sensibilidad. La forma de calcularla se muestra en la ecuación (5-30).

$$F1 = \frac{2 * VPP * TPR}{PPV + TPR} \quad (5-30)$$

## 5.5. Sumario.

En este capítulo se muestra la teoría y matemática de la clasificación basada en máquinas de vectores de soporte y kernels. Las SVM son una de las herramientas más versátiles en el aprendizaje de máquina, siendo la clasificación uno de los campos en donde mejor se desempeña según la literatura, incluyendo estudios a lo largo de varios años en donde se utilizan señales EEG. Por otro lado, gracias al concepto de los kernels, las máquinas de vectores de soporte tienen la posibilidad de abordar problemas lineales y no lineales, siendo esta una de las principales razones de su popularidad y buen desempeño.

La formulación del aprendizaje multi kernel también es presentada en este capítulo, mostrando sus características fundamentales, condiciones, y algoritmos desarrollados para la combinación de información basada en kernels que pueden provenir de diferentes fuentes, o medidas del kernel base. Finalizando el capítulo se habla sobre el puntaje F1 utilizado como métrica de evaluación para las SVM.

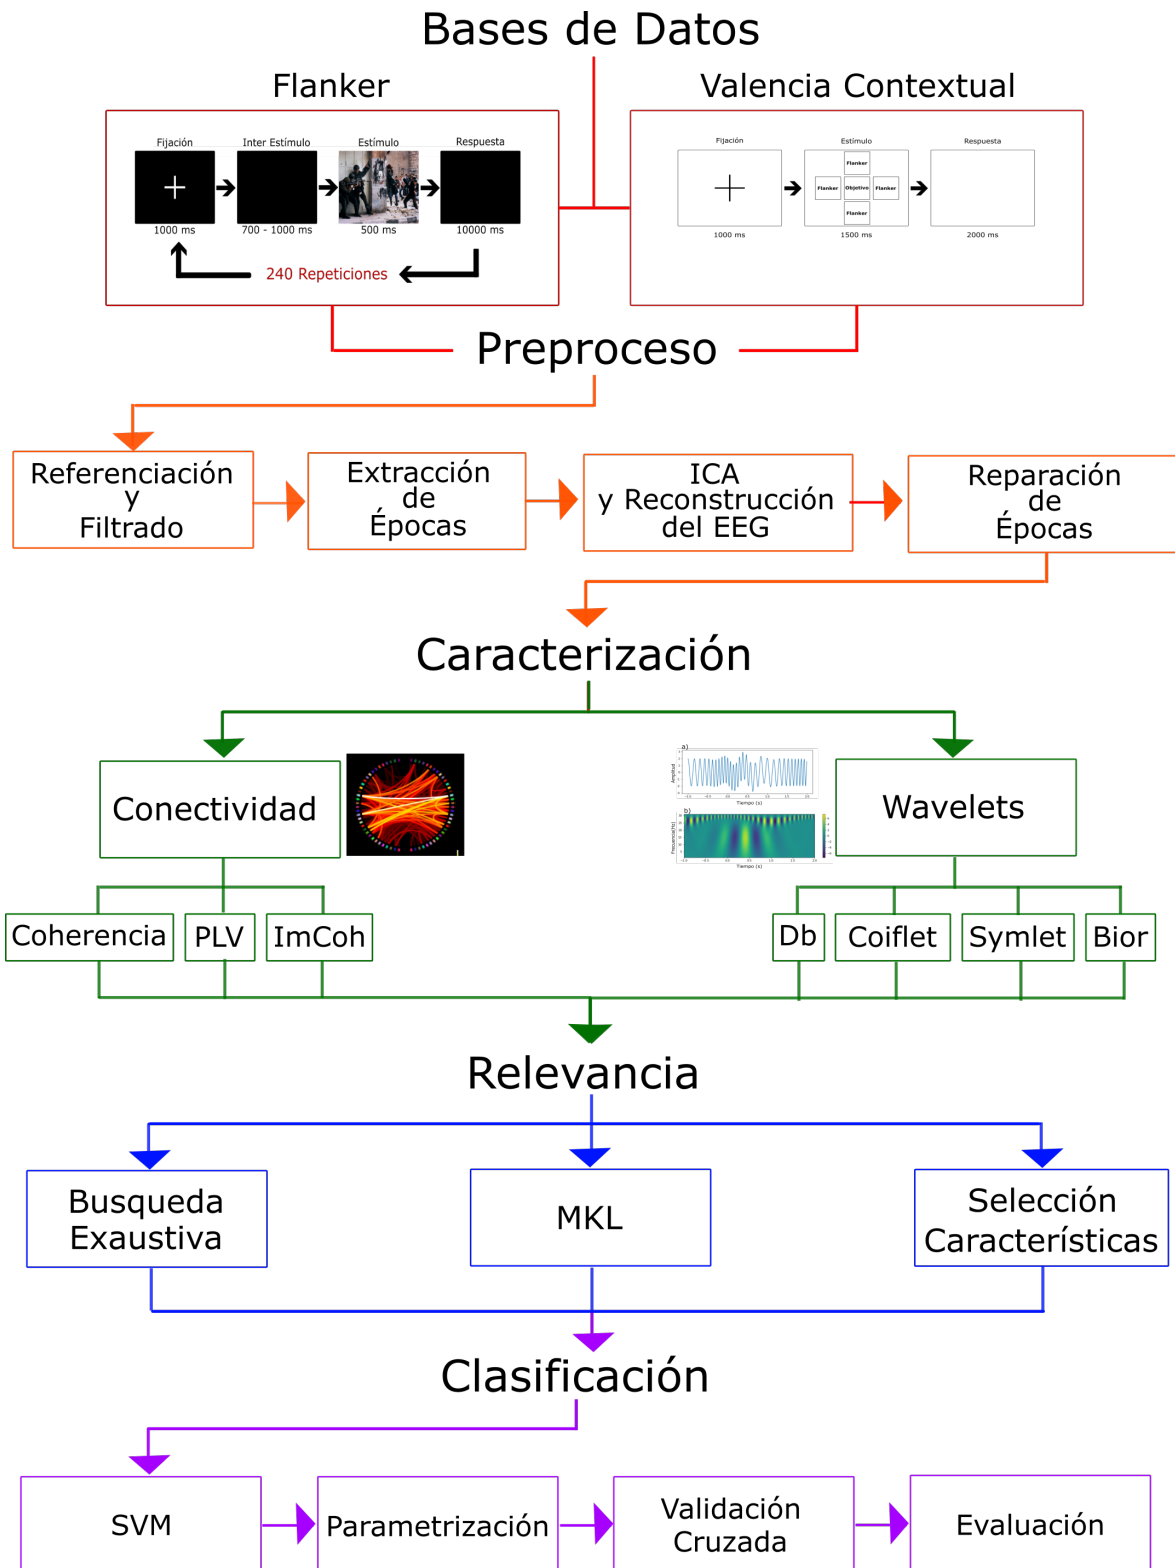
# 6 Desarrollo Metodológico.

## 6.1. Introducción.

La revisión bibliográfica acerca del estudio de las señales EEG desde el punto de vista de la automatización y la inteligencia artificial, ha mostrado numerosas metodologías y formas de abordar gran variedad de problemas como enfermedades neurológicas, traumas y trastornos cerebrales, y análisis del procesamiento emocional (ver apartado 2.1.4). Como se ha mencionado anteriormente, este es un proceso extenuante debido a las diversas etapas que se deben considerar desde el procesamiento hasta obtener un resultado final, bien sea en ejercicios de clasificación o regresión.

En esta tesis se introduce una metodología que sigue la línea trazada por investigaciones recientes [12, 50], realizando un preprocesamiento que ha mostrado ser efectivo en la eliminación de ruido y datos espurios, caracterizando las señales resultantes en diferentes dominios (tiempo, espacio y frecuencia), de los cuales se han generado características para el análisis de la estructura de los datos, tales como sus propiedades estadísticas, y finalmente elaborando una búsqueda de aquellas características que representan con mayor precisión las etiquetas de clase de los conjuntos de datos. Lo anteriormente dicho es evaluado utilizando un clasificador de máquinas de vectores de soporte para comparar los resultados alcanzados entre las diferentes formas de búsqueda y análisis de relevancia que han sido propuestas, utilizando como métrica el puntaje F1 que permite conocer el rendimiento de la clasificación en términos de exactitud y sensibilidad.

La metodología que se muestra a continuación fue creada a partir de las bases de datos de ex-combatientes expuestas anteriormente y pensada para tener generalización en demás trabajos que utilicen registros de EEG. Uno de los aspectos más importantes de esta es el análisis de relevancia, el cual permite brindar mayor interpretabilidad a los resultados, de tal manera que la información pueda ser estudiada en otros ámbitos.



**Figura 6-1:** Mapa Conceptual del Desarrollo Metodológico de la Tesis.

## 6.2. Preproceso.

La Figura 6-1 muestra el flujo del trabajo realizado, cada módulo es resaltado en un color diferente y representa cada uno de los pasos concernientes al reconocimiento de patrones en señales de EEG. El primer paso de la metodología es el preproceso.

En general se realizó una re-referenciación basada en el promedio de las señales en cada prueba realizada y luego se utilizó un filtro pasa bandas para eliminar principalmente el ruido ocasionado por frecuencias de equipos electrónicos. Posterior al filtrado inicial de todas las firmas, se procedió a extraer las épocas de interés, en el caso de valencia contextual se tomaron los tramos marcados como 10, 11, y 12, los cuales corresponden a las valencias negativa, neutra y positiva respectivamente; para *flanker* se utilizaron las marcas 64, 65, 66, y 67 que hacen alusión a amenaza central, amenaza periférica, neutra central y neutra periférica respectivamente. Es importante tener en cuenta que las marcas tienen una duración de un segundo o más, por tanto, buscando obtener la mayor información relevante a la prueba, se consideró desde -0.2 a 0.7 segundos de iniciada la sección estimulante.

Una vez calculadas las épocas de las señales, se realizó un proceso de identificación de fuentes ruidosas, para ello se descompuso cada firma utilizando ICA como se muestra en apartado 3.2.2. Cada componente fue evaluado estadísticamente utilizando la varianza, curtosis, oblicuidad y correlación con canales de referencia ocular para el caso de valencia contextual, esto con el fin de hacer una reconstrucción de las épocas sin considerar componentes ruidosos, obteniendo así una señal más limpia. Finalmente se utilizó la técnica propuesta en [58, 59] para seleccionar en cada época aquellos canales con valores atípicos (altos picos en el voltaje) que no pudieron ser filtrados, estos canales fueron reparados al realizar una interpolación con los demás más cercanos.

### 6.3. Caracterización.

Para la etapa de caracterización y en general en este trabajo se realizó el análisis sobre los canales ubicados sobre el cuero cabelludo de los sujetos, ya que esta técnica como bien se ha mencionado, mantiene una excelente resolución temporal. Esta metodología frente a otras como el análisis por fuentes (problema inverso) es más vulnerable ante fenómenos como el efecto de volumen de conducción, donde un canal capta intensidades de regiones vecinas generando medidas o datos espurios, además, el análisis en fuentes es un modelo más aproximado a la interacción neuronal, generando un mejor enfoque cuando se desea conocer con gran profundidad la interacción entre regiones, lo cual no es el caso. Sin embargo, el análisis por canales evita ahondar en problemas complejos como la selección de dipolos o estimación de fuentes y delimitación de regiones, lo cual tiene un costo computacional considerable, y existen aún imprecisiones en los modelos [19]. La decisión de trabajar sobre los canales del EEG se tomó teniendo presente estudios que han mostrado como evitar o minimizar los efectos de problemas como el de volumen de conducción [25, 37], y presentan la relación existente entre el análisis en canales y fuentes [70].

Adicional a las implicaciones del análisis por canales, se tomó en consideración la variación de las características de las señales EEG en el tiempo debido a su no-estacionariedad y no-linealidad [64], de este modo, fueron seleccionadas técnicas que consideraran información no solo espectral si no también temporal por ejemplo, esto con el fin de dar importancia a los instantes de tiempo donde ocurren los cambios en la fase y amplitud de la señal [35].

La caracterización fue realizada de dos formas diferentes, la idea está fundamentada en explorar la información presente en los diferentes dominios (tiempo, espacio, frecuencia y combinación de estos), por tanto, la caracterización utilizando conectividad de señales busca la información contenida combinando espacio y frecuencia, mientras que la caracterización mediante Wavelets se centra en el dominio tiempo-frecuencia. Ambos métodos han sido ampliamente utilizados en estudios de electroencefalografía [50, 31, 100].

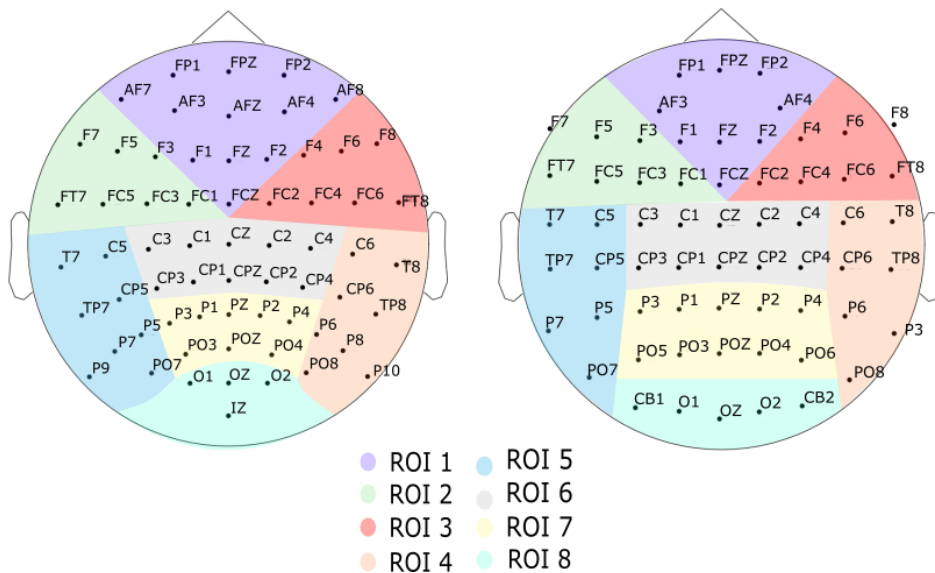
A continuación se detalla individualmente cada método de caracterización, todo este procedimiento que se describirá fue ejecutado de forma homogénea tanto para los datos de valencia contextual como para *flanker*.

### 6.3.1. Características Estadísticas del EEG Utilizando Wavelets.

Este método consiste en hacer un filtrado y a la vez una transformación de las señales EEG utilizando la transformada discreta Wavelet (DWT), el objetivo es tener información tanto temporal como espectral. Las Wavelets fueron seleccionadas siguiendo la literatura, donde se recurre a las Wavelet madre Daubechies, Symlet, Coiflet y Biortogonal para tareas de EEG [27, 31, 84, 49], específicamente para cada tipo de Wavelet se utilizó.

- **Biortogonal:** Bior3.6, Bior6.8
- **Symlet:** Sym2, Sym5, Sym8
- **Coiflet:** Coif1, Coif5
- **Daubechies:** Db4, Db10, Db15

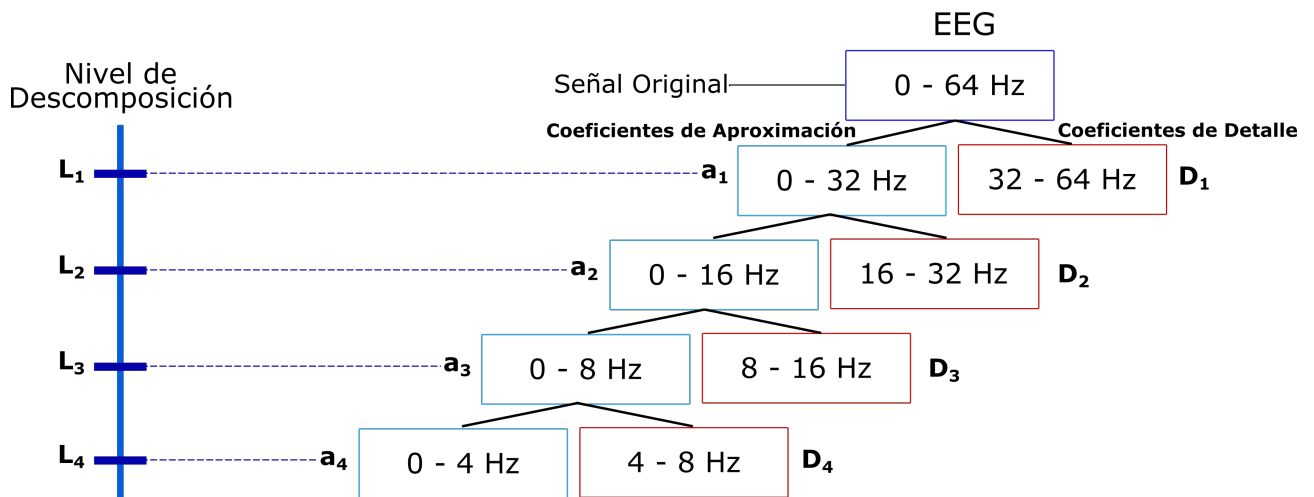
Previo al proceso de filtrado, se decidió trabajar por regiones de interés (ROI), al hacer esto, se pudo extraer características para cada una de ellas. Las regiones fueron marcadas siguiendo la metodología de [80, 110], en la cual se separa por regiones: frontal, temporal, central, parietal y occipital. Las regiones se pueden ver en la Figura 6-2.



**Figura 6-2:** Regiones de Interés Utilizadas en: a) Valencia Contextual, b) *Flanker*.

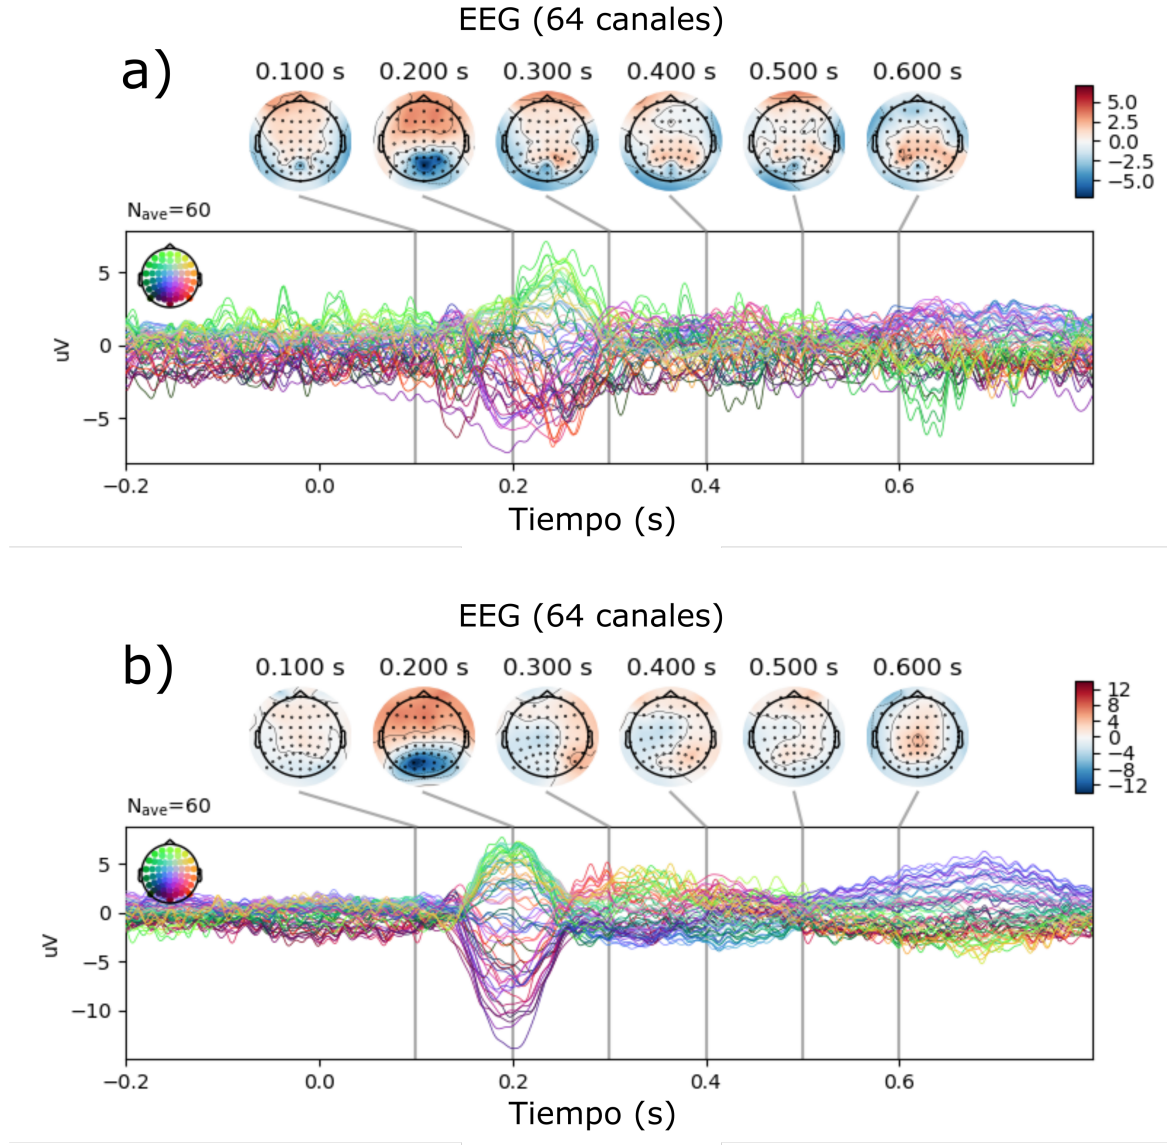


Para cada sujeto se tomaron individualmente las ROI y se aplicó en cada canal la transformación con las Wavelet listadas anteriormente, para esto se tomaron 4 niveles de descomposición y se almacenaron los coeficientes de detalle, adicionalmente, en el último nivel de descomposición se tomaron los coeficientes de aproximación, por tanto se contó con 4 coeficientes de detalle y 1 de aproximación como bandas independientes. La Figura 6-3 muestra cómo se descompuso el EEG en cada nivel y los rangos espectrales de cada uno de ellos.



**Figura 6-3:** Descomposición por Niveles Utilizando la Transformada Discreta de Wavelet.

Las firmas de EEG utilizadas en la descomposición fueron los potenciales evocados de cada sujeto, esto es, el promedio en cada canal a lo largo de las épocas. De lo anterior se obtienen firmas como las presentadas en la Figura 6-4, donde es mostrado el potencial evocado resultante en cada canal, también se evidencia una diferencia en las firmas entre un caso y un sujeto de control, siendo las señales de este último más uniformes y respondiendo simultáneamente a cada instante de tiempo, además, las ROI que sufren activación ante el estímulo varían en algunos instantes registrados, principalmente a los 0.3, 0.5 y 0.6 segundos. Estos comportamientos son los que se esperan sean repetitivos a lo largo de todos los sujetos, tanto en controles como en casos, y de este modo obtener diferencias que son realizadas luego del filtrado con Wavelets.



**Figura 6-4:** Potencial Evocado de las Señales EEG en: a) Un Control de la Base de Datos de *Flanker*, b) Un Caso de la Base de Datos de *Flanker*.

Los coeficientes de detalle y aproximación fueron promediados utilizando los canales de cada ROI en cada nivel de descomposición, por tanto se obtuvieron por cada ROI 5 grupos de coeficientes en diferentes frecuencias. Las características son finalmente resultado de un análisis estadístico, siguiendo algunos trabajos como [31], se decidió extraer el valor máximo, valor mínimo, media, mediana, varianza, desviación estandar, oblicuidad, y curtosis de los coeficientes.

Para cada sujeto el tamaño de la matriz de características es de  $N_b \times N_f$ , con  $N_b$  número

de bandas, y  $N_f = N_r \times N_e$  el número de características al realizar una vectorización de la matriz de  $N_r \times N_e$ , ubicando de esta forma todas las medidas estadísticas de todas las ROI una tras otra en la dimensión de características. Para estas bases de datos se tiene que  $N_b = 5$ ,  $N_r = 8$ , y  $N_e = 8$  correspondiente a las características estadísticas.

### 6.3.2. Caracterización Utilizando Conectividad y Grafos.

En el análisis de conectividad, inicialmente se independizaron y trataron las épocas de cada valencia (para valencia contextual) y estímulo (para *flanker*), luego se calculó la conectividad espectral en 6 bandas de frecuencia, estas bandas fueron seleccionadas según los ritmos del EEG:  $\delta$  (0 - 4 Hz),  $\theta$  (4 - 8 Hz),  $\alpha$  (8 - 12 Hz),  $\beta_{bajo}$  (12 - 16 Hz),  $\beta_{alto}$  (16 - 32 Hz),  $\gamma$  (32 - 50 Hz). La conectividad fue calculada utilizando la coherencia, la parte imaginaria de la coherencia y el valor de bloqueo de fase como se especifica en apartado 4.3 y se almacenaron en matrices de  $N_c \times N_c \times N_b$ , siendo  $N_c$  el número de canales y  $N_b$  el número de bandas, dado que el resultado del cálculo es una matriz simétrica cuadrada que contiene la conectividad entre canales de a pares en una escala de 0 a 1, por tanto el elemento  $(i, j, k)$  es la conectividad entre el canal  $i$  y el canal  $j$  para una banda  $k$ .

Las medidas de conectividad utilizadas representan una ventaja al tratar con problemas como el volumen de conducción, puntualmente se tienen estudios que exponen como la parte imaginaria de la coherencia es menos vulnerable a este efecto y como se detectan interacciones reales en el cerebro desde el EEG [87, 11], adicionalmente se ha visto que la coherencia también es ligeramente menos afectada comparada con métodos como la correlación de la envolvente de la amplitud (AEC), y el índice de retardo de fase (PLI) [25]. Por otro lado se descartaron medidas como la correlación (COR), y correlación cruzada (XCOR), ya que detectan únicamente relaciones lineales de la amplitud, o no detectan relaciones cuando hay retrasos entre las señales.

Luego de ser obtenidas las diferentes medidas de conectividad, se procedió a realizar un proceso de binarización para extraer características mediante la teoría de grafos. Generalmente se utilizan umbrales muy bajos (e.g.  $< 0.1$ ) pero dado que el análisis por canales se ve influenciado por el volumen de conducción, se evaluán otros umbrales, sin embargo, umbrales muy altos posiblemente entregarían grafos sin conexiones [50], por lo cual se utilizaron valores entre 0.3 y 0.7 en incrementos de 0.1 como se recomienda en la literatura [85], obteniendo 5 umbrales diferentes con un rango considerable de conexiones. De este modo, si la conectividad superaba el umbral esta era marcada como 1, si el valor era menor al umbral se marcó como 0. Dichos valores fueron almacenados en matrices de igual tamaño a la de conectividad, generando así las matrices de adyacencia. A continuación, en la Figura 6-5 se muestran los mapas de conectividad y el grafo para cada banda de frecuencia cuando se aplica un umbral de 0.7.

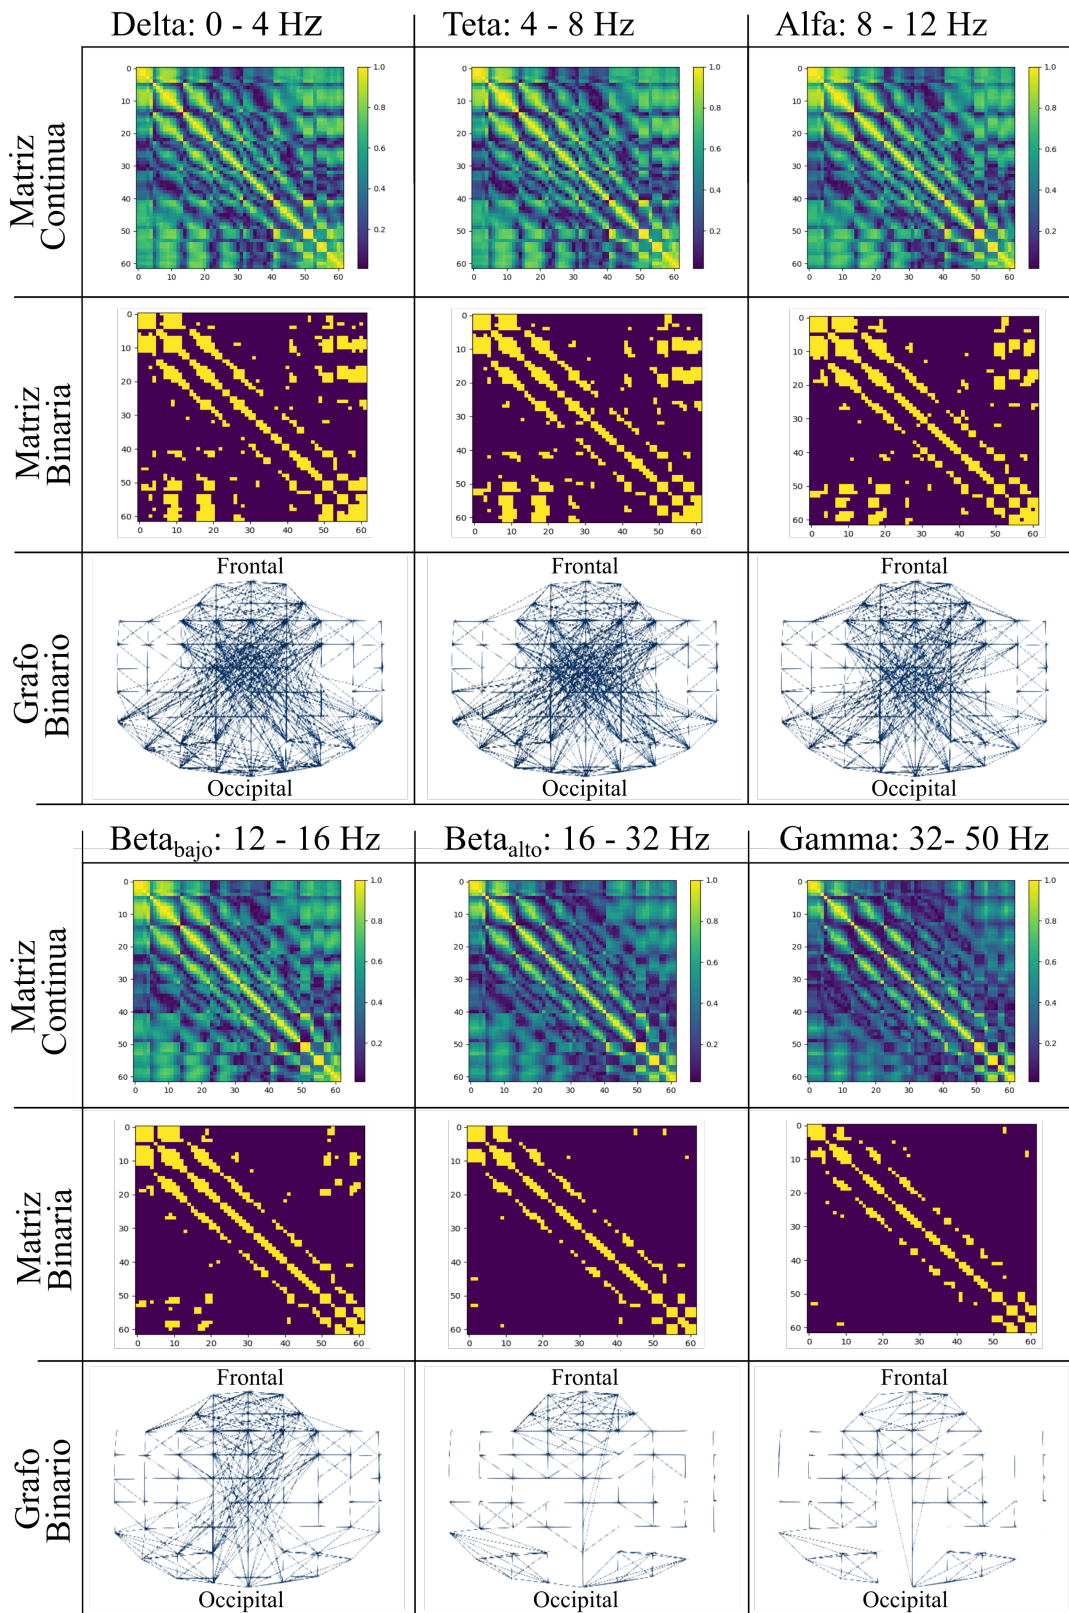


Figura 6-5: Gráficos de conectividad para un caso de los datos de valencia contextual con umbral de binarización en 0.7.

A pesar de que este trabajo tiene como finalidad proporcionar una metodología que de cuenta de las características más relevantes en estudios de EEG, evaluadas por el rendimiento en la clasificación, se pueden hacer algunas evaluaciones preliminares y acercamientos al comportamiento fisiológico, como en este caso, en el que se puede ver en la Figura 6-5 que la conectividad va disminuyendo conforme se exploran frecuencias más altas, esto puede deberse a que las operaciones normales del ser humano se centran en bandas medias en estado de alerta, y las bandas altas requieren un mayor estado de concentración. También se encontró que las conexiones con mayor remanencia a lo largo de todos los ritmos son las ubicadas en la región frontal y occipital.

Teniendo como base las matrices de adyacencia se extrajo la eficiencia global ( $E_g$ ), eficiencia local ( $E_l$ ), longitud máxima del grafo ( $L$ ), coeficiente de agrupación ( $C$ ) y la relación entre la agrupación global y local del grafo ( $S$ ), tal como se describe en el apartado 4.4. Estos coeficientes y métricas son las que conformaron el conjunto de características para este método, y se hace para cada banda de frecuencia y cada umbral, de este modo, al tener 5 umbrales preseleccionados y 5 medidas de grafos, se tiene como resultado un total de 25 características.

El tamaño de la matriz de características para cada forma de conectividad es entonces de  $N_b \times N_f$ , donde  $N_f$  es el número de características. Puntualmente, para ambas bases de datos, se tiene que el tamaño es de  $6 \times 25$ . Posteriormente, con el fin de optimizar el modo en que se cargan y almacenan los datos, se añadió una dimensión de forma de conectividad para tener una matriz con toda la información contenida. Finalmente se tiene que el tamaño es de  $N_m \times N_b \times N_f$ , siendo  $N_m$  el número de métodos de conectividad, de forma puntual sería  $3 \times 6 \times 25$ .

## 6.4. Relevancia y Clasificación.

Previo a la clasificación se utilizaron tres estrategias de análisis de relevancia con el fin de extraer del conjunto de características aquellas que contienen información crucial, que al ser llevadas al clasificador logran obtener una mejor frontera de decisión, discriminando con mayor precisión las etiquetas de clase. Para el caso de valencia contextual fueron controles o excombatientes, y para *flanker*, sujetos con alta o baja exposición al conflicto armado en Colombia.

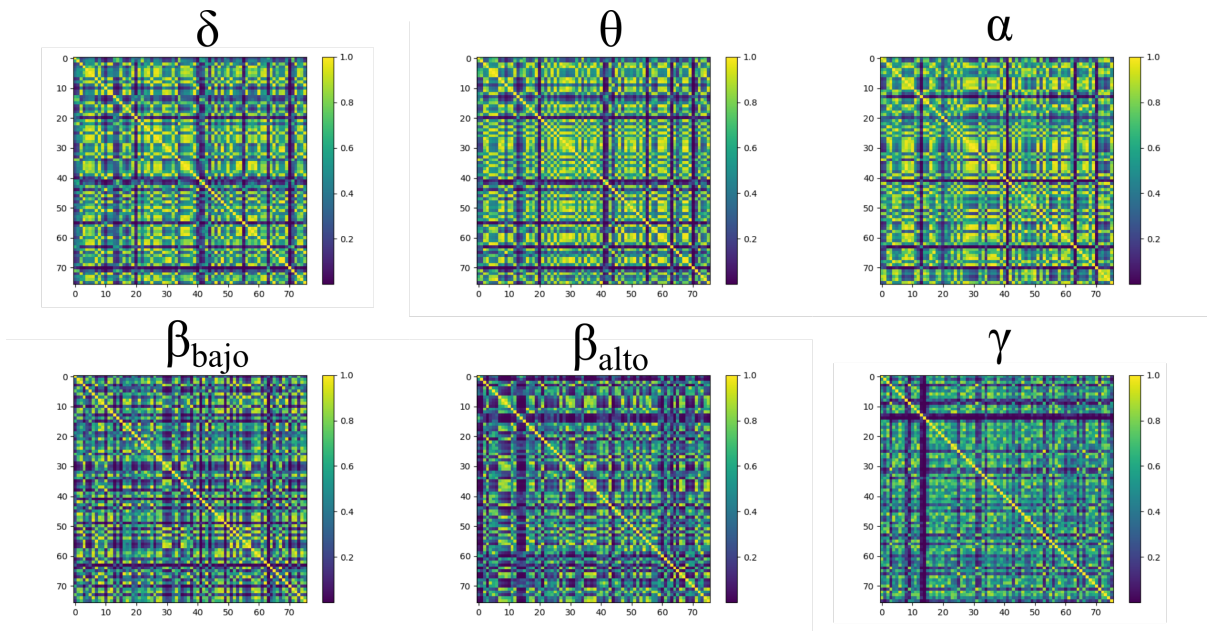
Las características tanto de conectividad como de Wavelets fueron tomadas y se mapearon utilizando un kernel Gaussiano, específicamente de base radial o RBF, este kernel fue seleccionado para hacer la clasificación de forma homogénea para todas las formas de relevancia. La utilización de este kernel se debe a su capacidad de generalización en problemas no lineales como es el caso, lo cual no poseen otros como el lineal, adicionalmente el kernel RBF tiene la capacidad de aproximación universal ya que es representado como un polinomio de grado in-

finito en las series de Taylor, lo cual lo hace preferible frente a otros kernels. Por otra parte, la correcta selección de la margen logra mantener las principales relaciones entre los datos [128].

Los métodos de análisis de relevancia utilizados fueron: búsqueda exhaustiva a través del espectro de frecuencias, asignación de pesos utilizando MKL, y selección de características con análisis de varianza (ANOVA).

### 6.4.1. Búsqueda exhaustiva.

En la búsqueda exhaustiva se utilizaron las características expuestas anteriormente, pero para esta metodología se hizo el cálculo de las mismas por cada rango de frecuencias, de tal modo que se obtuvo  $N_b$  kernels, con  $N_b$  el número de bandas dependiendo del método de caracterización. Luego los kernels se llevaron al clasificador y se evaluó el desempeño por cada banda analizada. En [100] utilizan este análisis para hacer clasificación en la misma base de datos de valencia contextual. La Figura 6-6 muestra un ejemplo de algunos kernels creados en base a la caracterización de conectividad para un sujeto de la base de datos *flanker*.



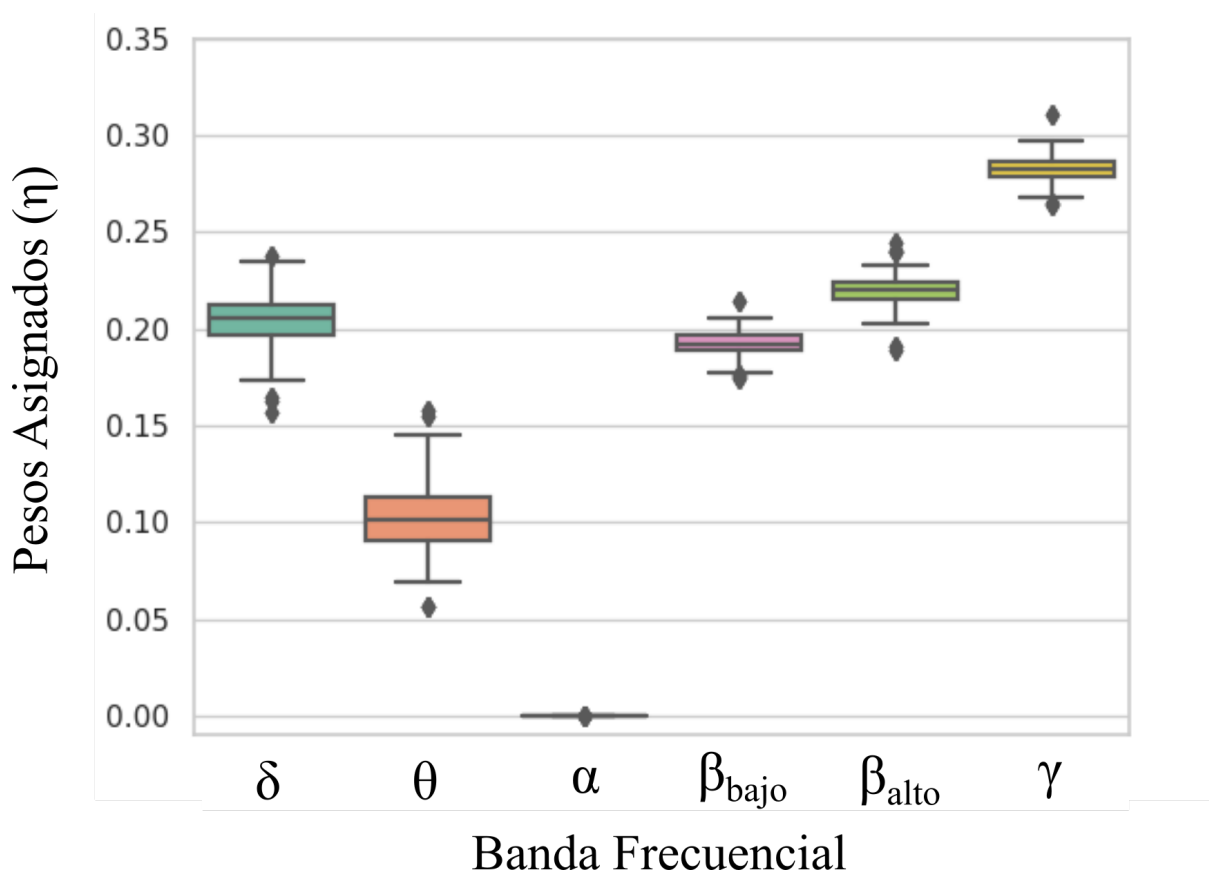
**Figura 6-6:** Kernels Generados a Partir de la Caracterización en Bandas de Frecuencia.

Como se puede ver en el gráfico anterior, cada uno de los kernels tienen información diferente acerca del sujeto analizado, por lo cual se hace el siguiente análisis con ayuda de la teoría de kernels.

### 6.4.2. Asignación de Pesos a Través de MKL.

Dado que la representación en bandas de frecuencia arroja información diferente para cada kernel formado, se utilizó el aprendizaje multi kernel para combinar la información total contenida en las bandas, de acuerdo a su capacidad para discriminar entre las etiquetas de clase. Por lo tanto, se utilizaron 2 modos para hallar los pesos ( $\eta$ ) con MKL denominados: *MKL sparse* y *MKL easy* que emplean la ecuación (5-12) y ecuación (5-15) respectivamente.

Estos pesos son asignados de tal forma que el kernel más discriminatorio reciba un peso alto y los que menos aportan a la solución del problema reciban uno más bajo. En la Figura 6-7 se muestra un diagrama de cajas y bigotes que da cuenta de la asignación de pesos a través de los diferentes muestras (sujetos de estudio) de la base de datos de *flanker*, en esta se muestra entonces el valor de la mediana en cada banda de frecuencia y los rangos intercuartiles a lo largo de los diferentes sujetos evaluados (77 en total).



**Figura 6-7:** Diagrama de Cajas y Bigotes Sobre la Asignación de Pesos a los Kernel Creados por Banda de Frecuencia.

Se puede observar que los pesos son dados a las bandas de más alta frecuencia y la banda



delta, por tanto la información más relevante se ubica en los extremos del espectro y decae conforme se acerca a frecuencias centrales. Este tipo de información es la que se espera será aprovechada por profesionales en otras áreas para dar una interpretación fisiológica y psicológica de lo que sucede con el individuo.

Los pesos fueron tomados y multiplicados por los kernels, obteniendo así uno que contiene la información más relevante, luego este kernel se llevó al clasificador. Esto se ilustra en la Figura 6-8.

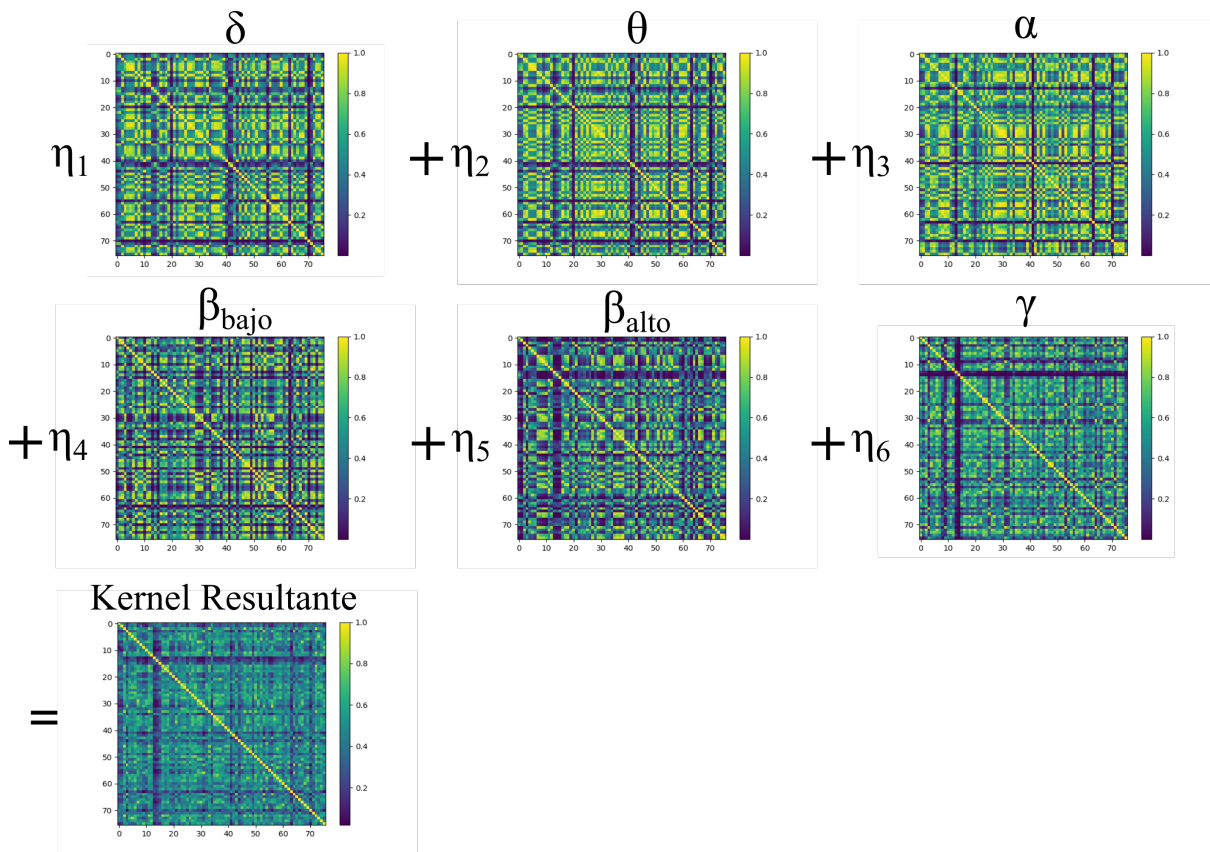


Figura 6-8: Combinación de los Kernels por Bandas de Frecuencia Utilizando MKL.

### 6.4.3. Selección de Características.

La selección de características es un método ampliamente utilizado para extraer información relevante de los datos, principalmente se utiliza para reducir la dimensión a la cual son mapeados los datos y reducir la complejidad del problema.

El procedimiento de selección se ejecutó con todas las características en todas las bandas de frecuencia, esto es, concatenando las características extraídas en cada rango espectral, por



lo tanto el número de características total fue:

			Total Características
Método	Conectividad	Coh/PLV	150
		ImCoh	30
	Tiempo-Frecuencia	Wavelets	320

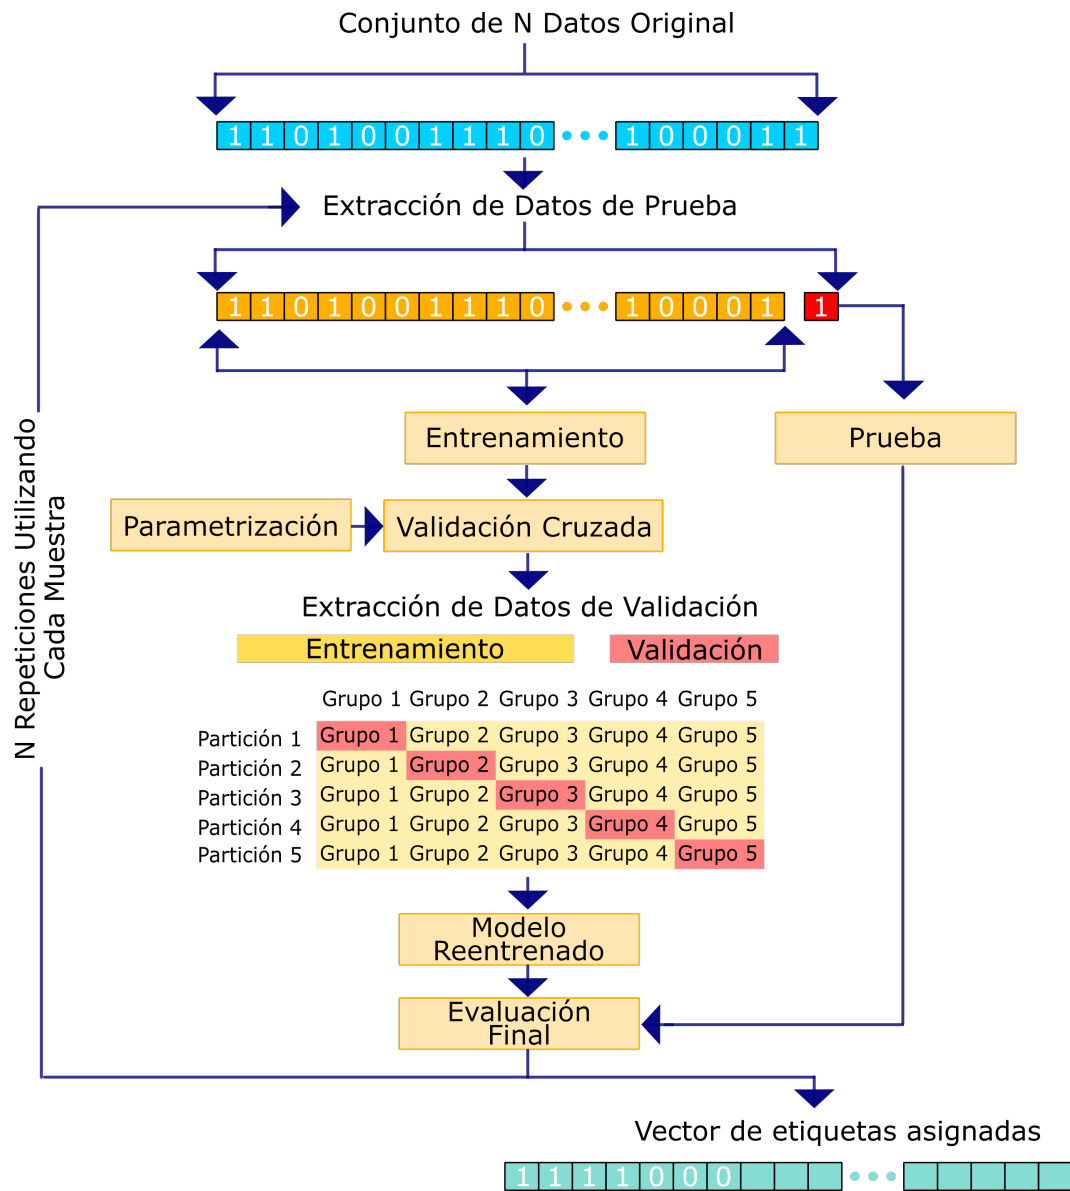
**Tabla 6-1:** Total de Características Utilizadas en Cada Método de Caracterización

Mediante la técnica ANOVA fueron organizadas todas las características en orden de mayor a menor relevancia para luego en la clasificación seleccionar el conjunto que mayor desempeño obtiene en términos de exactitud.

#### 6.4.4. Clasificación.

Cada método de relevancia fue llevada a una máquina de soporte vectorial, esta fue ajustada para recibir un kernel precalculado, al cual se llevaron los kernel RBF creados en la sección anterior. Los parámetros  $\gamma$  y  $c$  fueron sintonizados para lograr un rendimiento óptimo basado en la distribución de los datos y el estado del arte, en donde se recomienda utilizar una búsqueda por rejilla tanto para  $\gamma$ , como para  $c$ . Para el parámetro  $c$  la rejilla fue:  $2^n$ , con  $n = [-8, -7, \dots, 6, 7, 8]$  las potencias de 2 con exponente entero desde -8 hasta 8. En el caso de  $\gamma$  se tuvo una rejilla en donde se incluyeron valores de 10 en 10 hasta el número total de sujetos en la base de datos, y un valor fijo dado por:  $\gamma = \frac{1}{n_f * \sigma^2}$  siendo  $n_f$  el número de características y  $\sigma$  la varianza del conjunto de datos de entrenamiento.

La clasificación se llevó acabo utilizando validación cruzada tanto para el entrenamiento como para las pruebas. Inicialmente se tomo el conjunto de datos total y se dejó por fuera una observación junto con su etiqueta de clase, correspondientes a la prueba, siguiendo la metodología de validación cruzada dejando uno afuera (LOO por sus siglas en inglés). Los datos restantes de la selección anterior se definieron como las muestras de entrenamiento, y entre ellas se realizó una nueva validación cruzada utilizando 5 grupos y 5 particiones, dejando uno de los grupos para probar el desempeño del clasificador con los parámetros mencionados, para finalmente seleccionar los mejores y utilizarlos en el modelo final, el cual clasifica la muestra que se había excluido desde el inicio. Las etiquetas asignadas a la muestra de pruebas se almacenaron para luego ser evaluadas. En la Figura 6-9 se ilustra este proceso.



**Figura 6-9:** Entrenamiento del Clasificador Utilizando Validación Cruzada.

Es importante mencionar que para el caso de valencia contextual el objetivo es clasificar entre sujetos de control y excombatientes, específicamente se tienen 19 controles y 31 excombatientes a discriminar y el experimento de *flanker* tiene como fin discriminar entre sujetos altamente expuestos a situaciones de conflicto y sujetos que han tenido una baja exposición, de la primera clase se tienen 57 muestras y de la segunda 20. Se evidencia entonces que en ambas tareas hay una gran diferencia entre el número de muestras de una clase con respecto a la otra, por esta razón se utilizó balance de clases durante la clasificación, de tal manera que la SVM diera un mayor peso a las muestras de la clase con menos instancias. Para este balance se utilizó la librería *Class weight* de *sklearn*, la cual emplea máxima verosimilitud

ponderada para el cálculo de los pesos de las observaciones  $(\mathbf{x}, \mathbf{Y})$  [63], esto se expone en la ecuación (6-1).

$$\begin{aligned} \ln L_w(B|\mathbf{Y}) &= w_1 \sum_{\mathbf{Y}_i=1} \ln(\boldsymbol{\pi}_i) + w_0 \sum_{\mathbf{Y}_i=0} \ln(1 - \boldsymbol{\pi}_i) \\ &= - \sum_{i=1}^n w_i \ln(1 + e^{(1-2\mathbf{Y}_i)\mathbf{x}_i B}) \end{aligned} \quad (6-1)$$

Con  $B$  la variable a optimizar para elevar el valor de la función,  $w_1 = \frac{\tau}{\bar{y}}$ ,  $w_0 = (\frac{1-\tau}{1-\bar{y}})$ ,  $\bar{y}$  la muestra,  $\tau$  la población, y  $\boldsymbol{\pi}_i$  como:

$$\boldsymbol{\pi}_i = \frac{1}{1 + e^{-\mathbf{x}_i B}} \quad (6-2)$$

Se tienen entonces los pesos:

$$w_i = w_1 \mathbf{Y}_i + w_0 (1 - \mathbf{Y}_i) \quad (6-3)$$

Finalmente se evaluó el desempeño de la clasificación con el valor F1, esto con el fin de ver la sensibilidad del clasificador ante las clases que se están evaluando.

## 6.5. Sumario.

En este capítulo se describe todo el desarrollo metodológico de este trabajo de investigación, inicialmente se repasa el preprocesamiento explicado en apartado 3.2, para después hablar de los métodos de caracterización utilizados, teniendo en cuenta la información en tiempo-frecuencia con Wavelets, y espacio-frecuencia con conectividad funcional.

Al final de este capítulo se detallan las formas de análisis de relevancia y selección de características utilizadas, y la forma de realizar el entrenamiento y evaluación del clasificador, así como su sintonización.

# 7 Resultados.

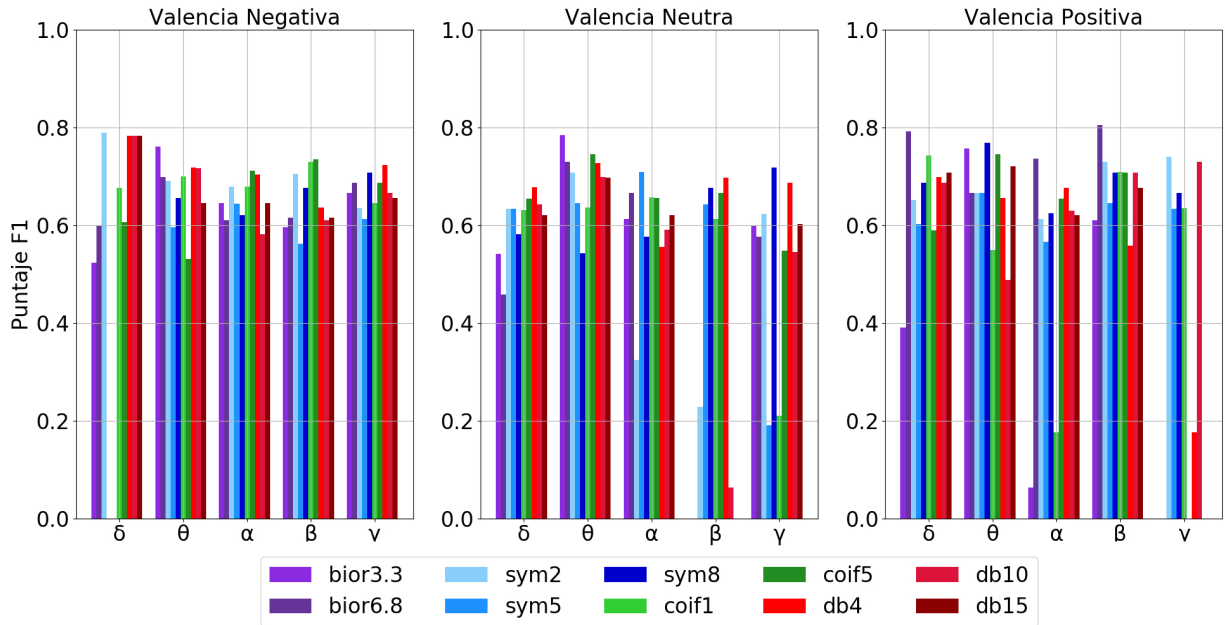
## 7.1. Introducción.

En este capítulo se muestran los resultados obtenidos durante el desarrollo de la tesis en cumplimiento de los objetivos específicos y objetivo general. La experimentación consistió en tomar las bases de datos y clasificar los sujetos de estudio, tal y como se mencionó en el capítulo anterior. Para ello se hizo el entrenamiento y evaluación de la clasificación extrayendo inicialmente 1 sujeto de los datos, dejando por fuera sus señales y etiqueta de clase para la evaluación, en lo que se conoce como validación con *Leave one out*. Para entrenar la SVM se tomó el conjunto de entrenamiento y se realizaron 5 validaciones cruzadas para hacer la sintonía de parámetros, escogiendo entonces aquellos que tuvieron mejor desempeño. Los parámetros encontrados en la etapa de validación fueron los que se usaron en la parametrización para la asignación de la etiqueta correspondiente al sujeto de evaluación.

Los resultados son presentados por cada base de datos, forma de caracterización y análisis de relevancia estudiado.

## 7.2. Resultados de la Clasificación Utilizando Caracterización con Wavelets.

Inicialmente se realizó para las bases de datos la caracterización utilizando Wavelets y búsqueda exhaustiva, con el fin de evaluar el comportamiento de la clasificación a lo largo de los diferentes tipos de Wavelets madre y bandas de frecuencia, en cada valencia. El objetivo es entonces encontrar si existe alguna banda de frecuencia que logra contener una diferenciación clara entre controles y excombatientes.



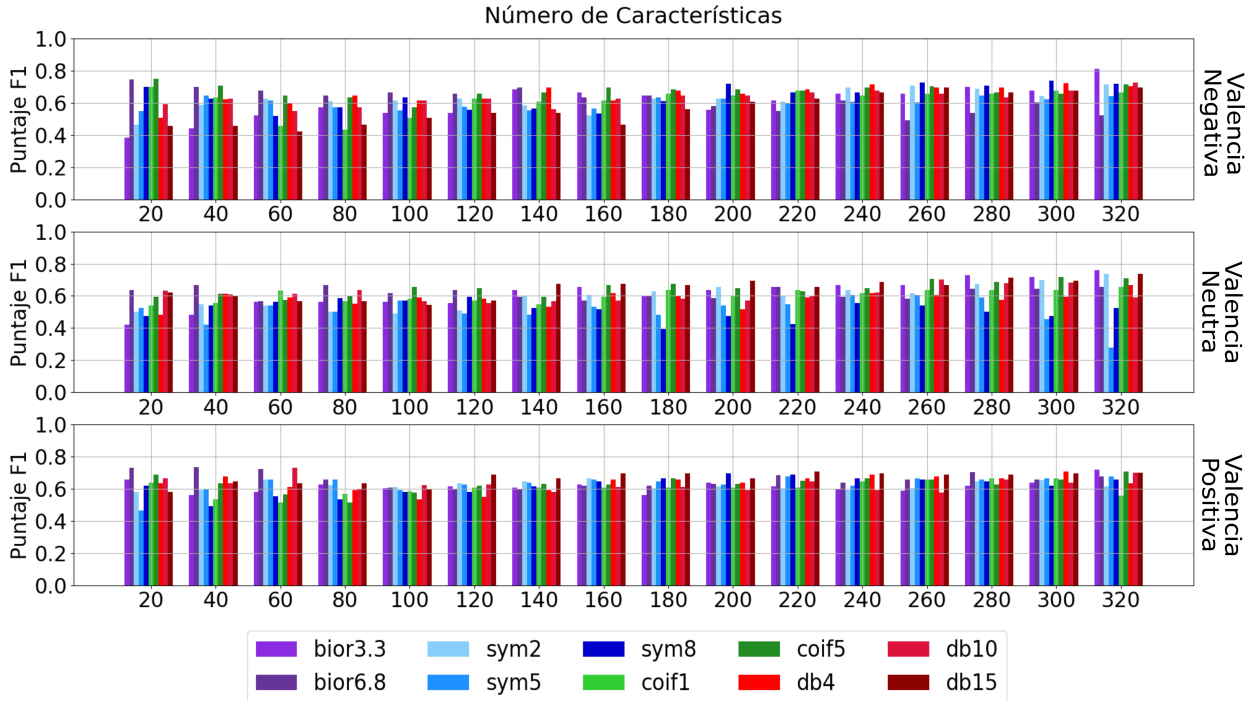
**Figura 7-1:** Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Aplicando Búsqueda exhaustiva.

Como se puede ver en la Figura 7-1 el resultado máximo obtenido se ubica sobre la banda  $\beta$  que abarca las frecuencias de 16 a 32 Hz según los niveles de descomposición que se aplicaron, este valor corresponde a **80.52 %** de exactitud en la clasificación, seguido por tres valores en la banda  $\delta$  que corresponde a los coeficientes de aproximación, estos valores son: **79.37 %**, **79.24 %**, y **78.94 %**. Al centrarse en el análisis por Wavelets a lo largo de todas las bandas y valencias se tiene que de mayor a menor exactitud las Wavelets con mejores puntajes fueron respectivamente: **Bior6.8** para los 2 mejores resultados, **Sym2**, y los tres tipos de **Db** compartiendo el mismo valor (**78.94 %**). Como lo ha reportado el estado del arte, la Wavelet Daubechies muestra ser una buena alternativa para filtrar EEG dado su rendimiento promedio ( $\mu_{Db4} = 64 \%$ ) que se evidencia a lo largo de las bandas, y también se destaca la Biortogonal con menor rendimiento promedio ( $\mu_{Bior6,8} = 57 \%$ ) pero con valores pico en todas las valencias.

Uno de los hallazgos obtenidos en este experimento, es el hecho de que al hacer análisis por valencias, se tiene que la valencia positiva da lugar al valor F1 máximo alcanzado (**80.52 %**), seguido por la valencia negativa (**79.37 %**). y por último valencia neutra (**78.43 %**), aunque no existe gran diferencia entre los valores pico alcanzados, la valencia positiva realza la diferencia entre las características de ambas clases.

Luego de ser realizado el análisis de búsqueda exhaustiva, se procedió a clasificar utilizando

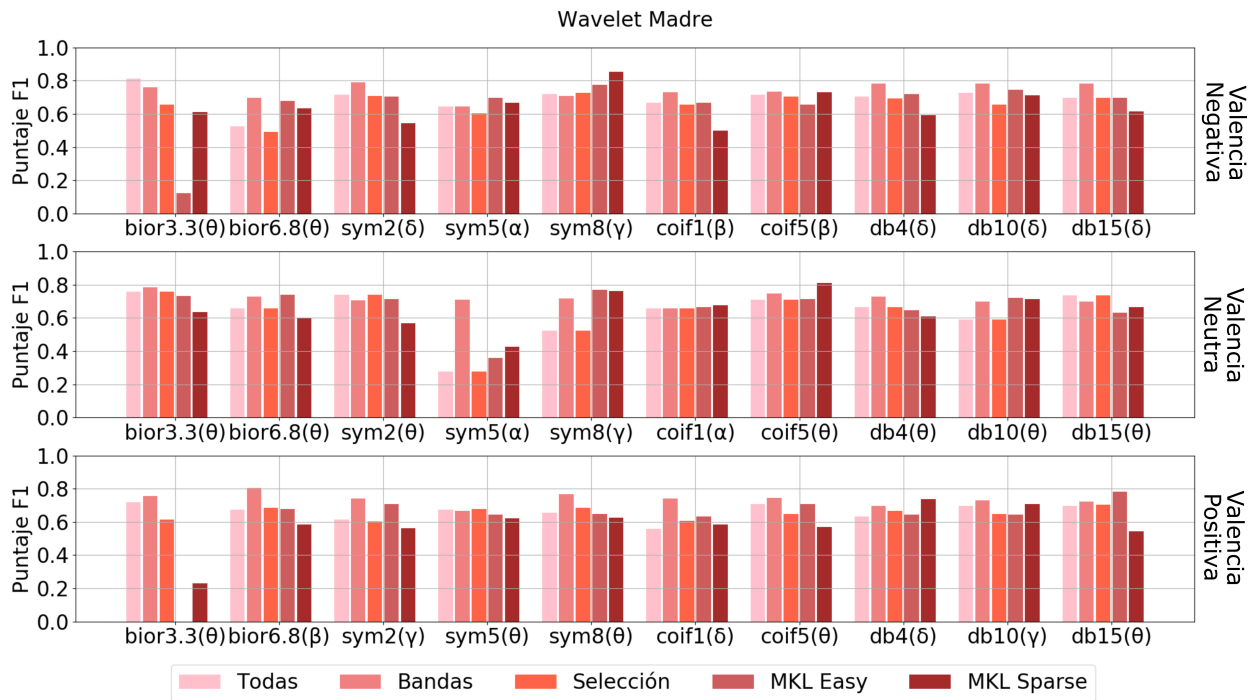
selección de características. Como se mencionó en el capítulo anterior, las características fueron ordenadas de mayor a menor relevancia usando la técnica ANOVA, paso siguiente se hizo clasificación escogiendo de 20 en 20 las mejores características. El resultado de este experimento se muestra en la Figura 7-2.



**Figura 7-2:** Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Aplicando Selección de Características.

En general la clasificación mejora conforme se aumenta el número de características, lo cual sugiere que existe información discriminatoria en las diferentes bandas y medidas estadísticas que describen el comportamiento de las señales. De este experimento se seleccionó el mejor número de características, para esto se identificó el número de características que da lugar al F1 más alto por cada valencia entre todas las Wavelets y este fue elegido. Los grupos de características escogidos son: 260 para valencia negativa, 320 para neutra y 60 para positiva.

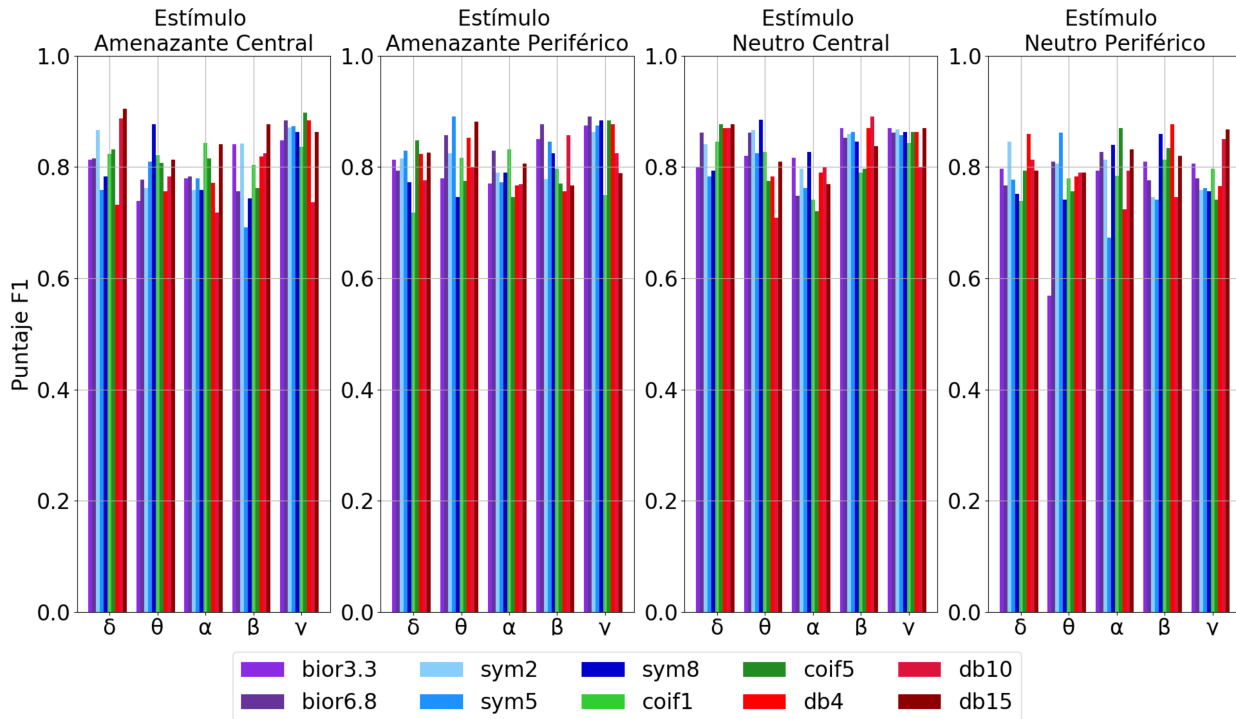
Después se implementaron los algoritmos de MKL como método de relevancia y combinación de la información. En la Figura 7-3 se comparan los métodos de relevancia realizados por cada Wavelet y valencia. En la parte inferior de las gráficas se muestran las Wavelet y la banda de frecuencia donde se obtuvo el mayor puntaje durante la búsqueda exhaustiva o por bandas, adicionalmente se muestra el resultado de clasificar utilizando la totalidad de las características.



**Figura 7-3:** Comparación del Puntaje F1 Alcanzado por los Diferentes Métodos de Relevancia Utilizando Wavelets en Datos de Valencia Contextual.

Los mejores resultados son alcanzados por MKL sparse en las valencias negativa (**85.29%**) y neutra (**81.15%**), y por búsqueda exhaustiva para valencia positiva (**80.52%**). Este estudio muestra que MKL logra combinar información contenida en los diferentes rangos frecuenciales, superando el mejor resultado alcanzado individualmente por bandas, que tiene el rendimiento más consistente a lo largo de todas las pruebas.

Al igual que en valencia contextual, se muestran los resultados de la búsqueda exhaustiva para *flanker*.

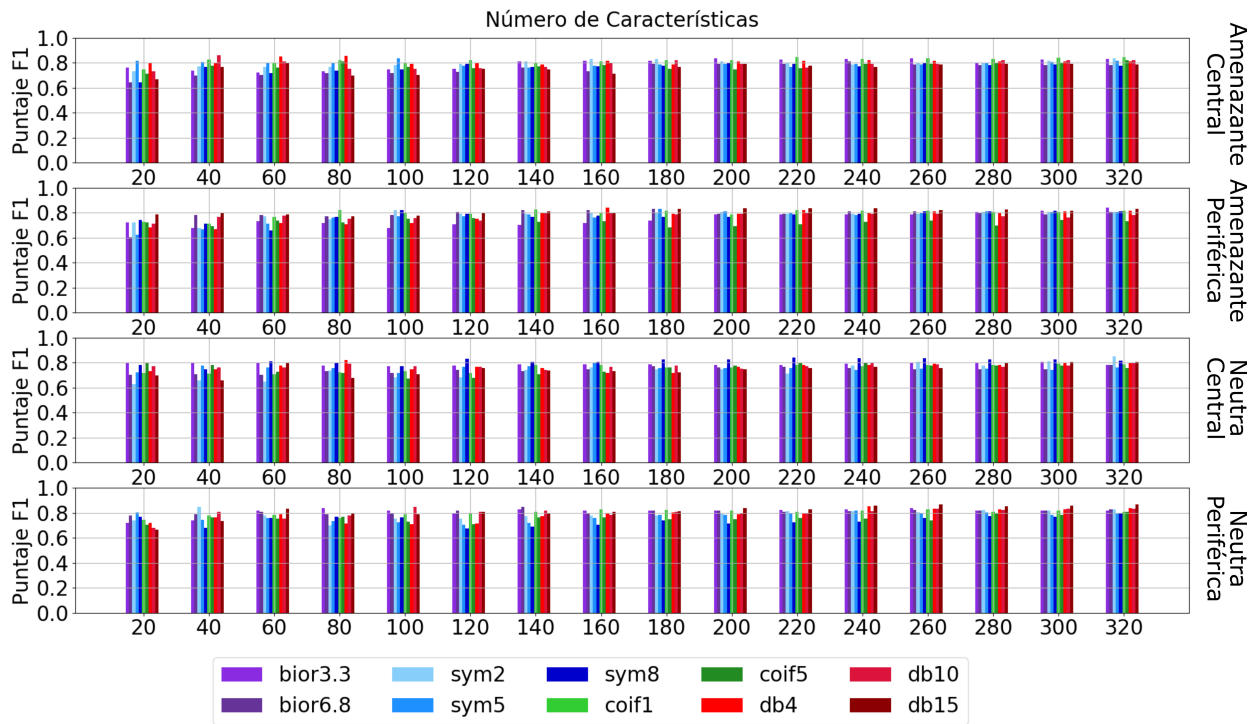


**Figura 7-4:** Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de *Flanker* Aplicando Búsqueda exhaustiva.

El estudio mostró que el mejor puntaje es alcanzado por la Wavelet **Db15** con **90.47%**, seguido por **Coif5** con **89.76%**, y **89.06%** por **Db10**, **Bior6.8** y **Sym5**. En este caso las bandas muestran en general altos puntajes, por lo que no es posible determinar con certeza alguna relación entre las bandas y la tarea, aunque se observa que en estímulos centrales las bandas  $\delta$  y  $\gamma$  tienen altos puntajes, y en la banda  $\alpha$  el puntaje de la clasificación decrece, además la banda  $\beta$  obtiene en los estímulos neutros el resultado más alto.



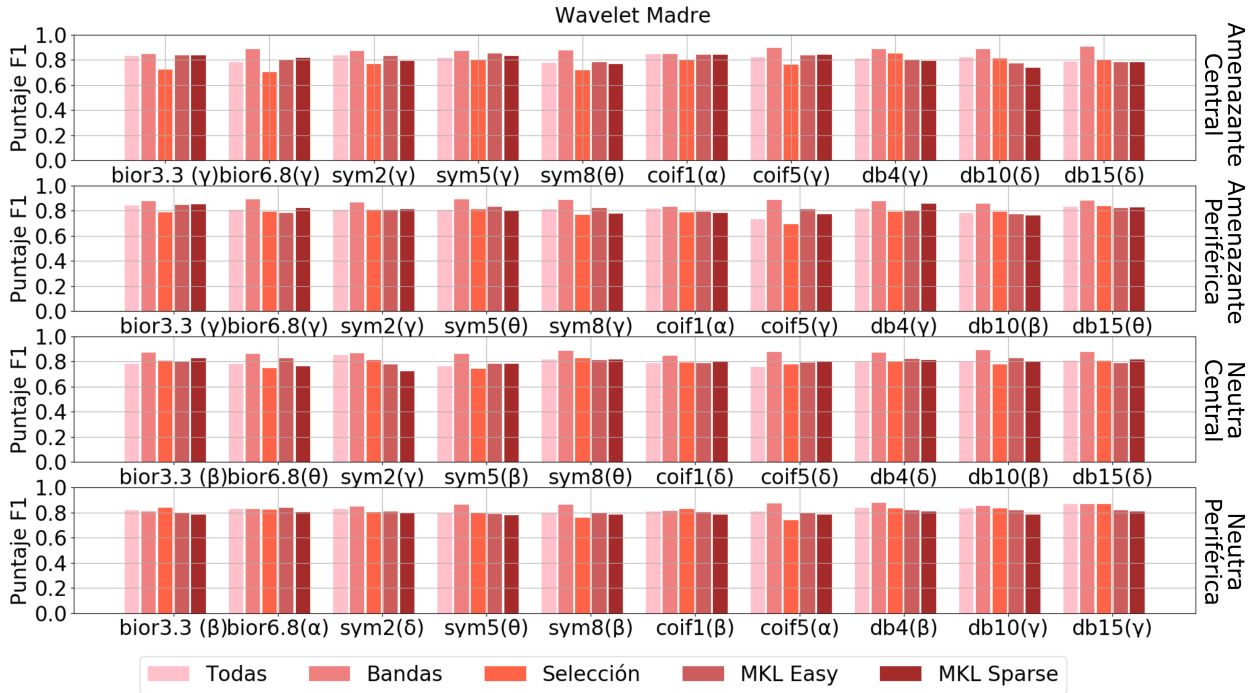
Para la selección de características se obtuvo los resultados de la Figura 7-5



**Figura 7-5:** Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de *Flanker* Aplicando Selección de Características.

De aquí se seleccionaron como mejores grupos: 60 características para estímulo amenazante central, 200 para amenazante periférico, 300 para neutro central y 260 para neutro periférico.

Los resultados de la comparación entre métodos son:




**Figura 7-6:** Comparación del Puntaje F1 Alcanzado por los Diferentes Métodos de Relevancia Utilizando Wavelets en Datos de *Flanker*.

Es claro que el análisis por bandas de frecuencia se encuentra información altamente discriminante entre las clases, siendo el mejor resultado para 35 de las 40 pruebas y siendo inferior en sólo 4. Luego se tiene que MKL supera la selección de características al ser superior en alguna de las formas de calcular los pesos en 27 de las 40 pruebas y a pesar de que no logra superar para esta base de datos el análisis por bandas, se mantienen en todas las pruebas al rededor del 80% de exactitud. De cualquier forma, los métodos reportados muestran que las clases tienen características distintivas, especialmente en la banda  $\gamma$  que fue seleccionada como la mejor en 15 pruebas, seguido por  $\beta$  en 8, y  $\delta$  en 7.

Como resultado general del análisis por Wavelets se tiene que en ambas bases de datos la Wavelet Daubechies representa las señales con mayor diferencia que ayudan al clasificador a etiquetar correctamente, también se tiene que las bandas  $\delta$  y  $\gamma$  son las que mayor puntaje alcanzan, lo cual puede indicar que la diferencia entre este tipo de sujetos de estudio (altamente expuestos y con baja exposición) podrían tener una diferencia en el nivel de concentración que los sujetos realizan la tarea, ya que en ambos casos bandas de alta concentración ( $\gamma$  y  $\beta$ ) han ayudado a encontrar mejores fronteras de desición comparadas con las demás, lo que concuerda con estudios ya realizados [96].

### 7.3. Resultados de la Clasificación Utilizando Medidas de Conectividad.

Del mismo modo que para la caracterización con Wavelets, se hizo la experimentación en ambas bases de datos aplicando la caracterización basada en conectividad funcional, al igual que en Wavelets se implementó el análisis exhaustivo para cada una de las 6 bandas de frecuencia, obteniendo los resultados de la Figura 7-7.




**Figura 7-7:** Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de Valencia Contextual Utilizando Búsqueda exhaustiva.

Es notorio que la mejor medida de conectividad para esta tarea es la coherencia (Coh), dado que solo en 1 prueba es sobrepasada por el valor de bloqueo de fase (PLV), y también se evidencia que la parte imaginaria de la coherencia está por debajo de las demás medidas en todas las pruebas.

Uno de los resultados a resaltar es que al igual que con Wavelets se tiene que el resultado de clasificación más alto se da en la valencia positiva y es de **79.54 %** en la banda  $\delta$ , seguido por la valencia neutra de **78.94 %** en la banda  $\beta_b$ , e igualmente **78.94 %** para la negativa en  $\beta_a$ . De igual forma la máxima diferencia es alcanzada en la valencia positiva y se repiten las bandas  $\delta$  y  $\gamma$  como bandas más relevantes.

En la Figura 7-8 se muestran los resultados de la selección de características. Para esta forma de caracterización se seleccionaron de 20 en 20 y el último intervalo de 30 hasta 150

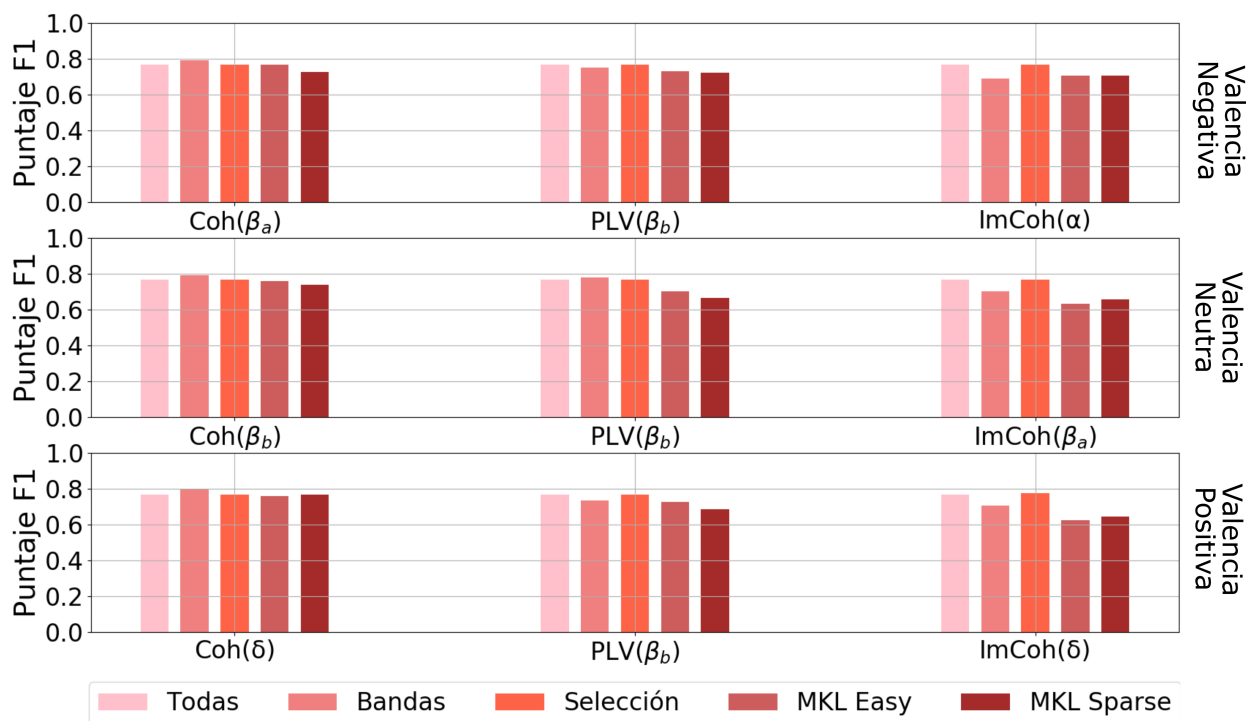
para coherencia y valor de bloque de fase, y de 5 en 5 hasta 30 para la parte imaginaria de la coherencia.



**Figura 7-8:** Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Utilizando Selección de Características.

Los métodos fueron comparados y también se resaltaron las bandas más votadas por el método de búsqueda exhaustiva.

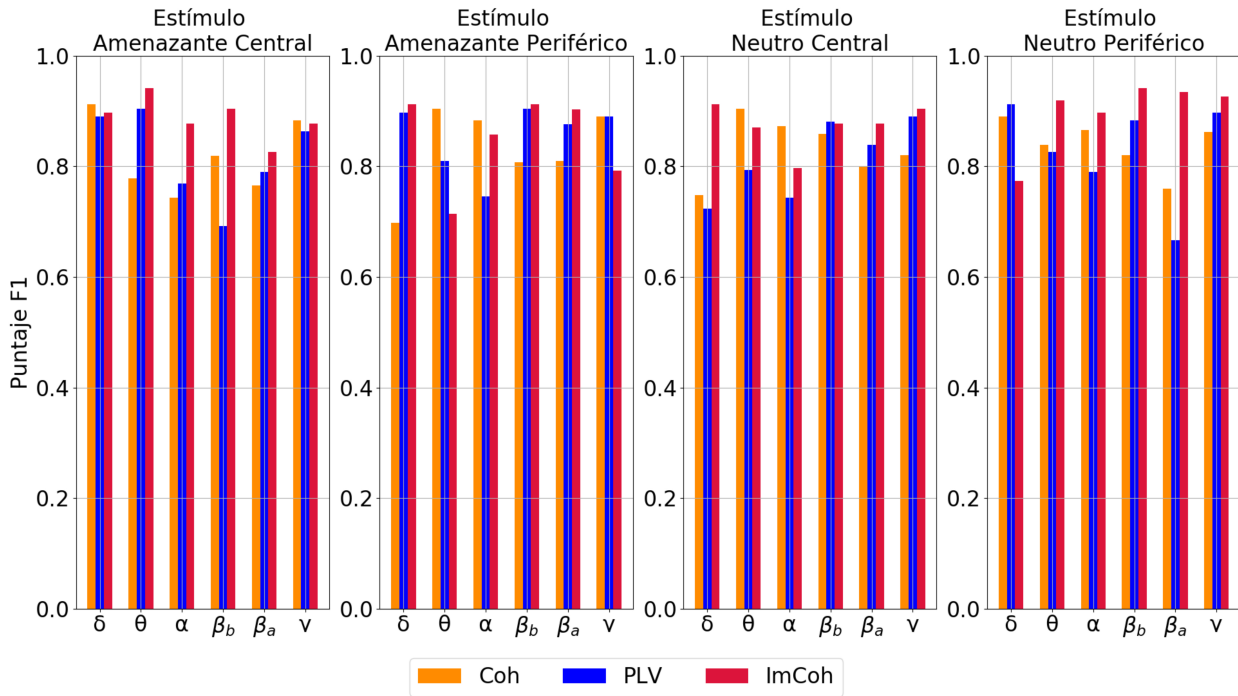
### 7.3 Resultados de la Clasificación Utilizando Medidas de Conectividad. 83



**Figura 7-9:** Puntaje F1 de la Clasificación Utilizando Wavelets Para Datos de Valencia Contextual Comparando los Métodos de Relevancia Utilizados.

En la figura 7-9, se puede observar que los métodos de análisis de relevancia entregan un valor más alto a las bandas  $\beta_b$  y  $\beta_a$ , teorizamos que esto se debe dado que la diferencia entre las clases radica en el nivel de atención prestado durante los estímulos, ya que estas bandas están asociadas a altos niveles de concentración y actividad cerebral.

A continuación se muestran los resultados obtenidos para la base de datos *flanker* caracterizada con conectividad funcional, iniciando por la búsqueda exhaustiva.

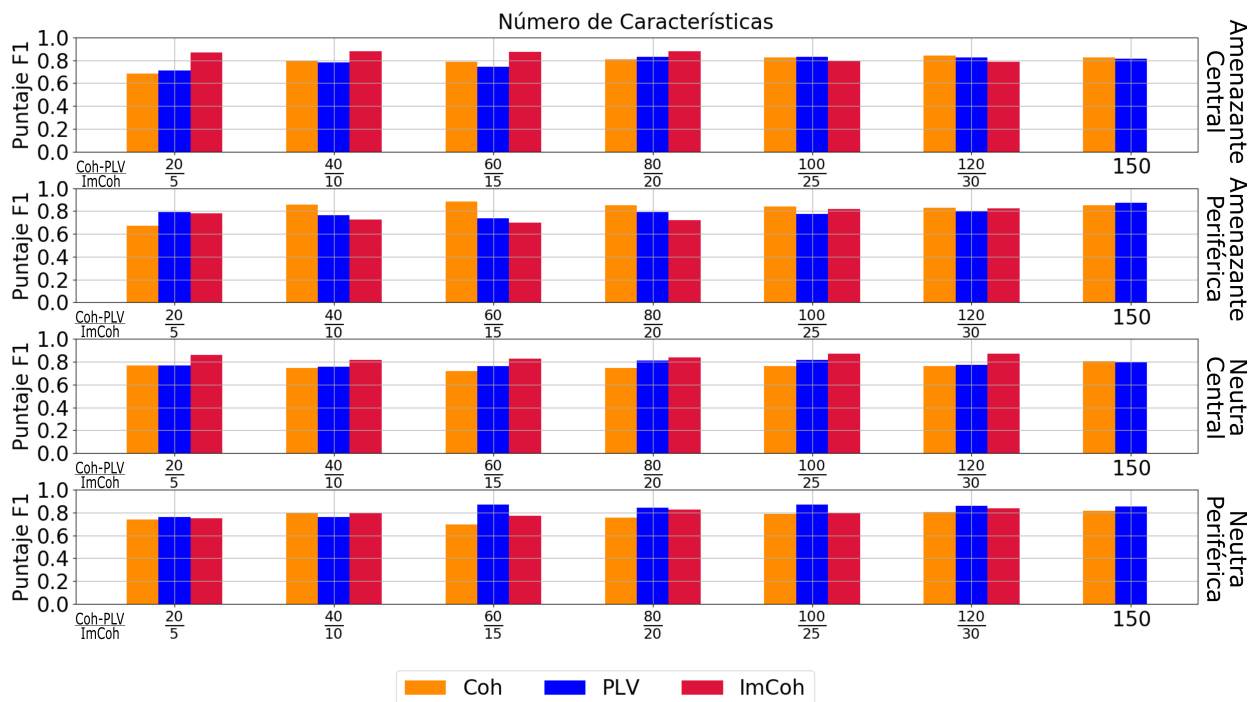


**Figura 7-10:** Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de *Flanker* Comparando los Métodos de Relevancia Utilizados.

Los resultados de *flanker* utilizando Wavelets y características estadísticas mostraron excelentes resultados sobrepasando el 90% de puntaje F1; sin embargo, la experimentación con conectividad muestra mejores resultados en todas los estímulos. El mejor de estos es de **94.28%** en las bandas  $\beta_b$  y  $\theta$ , luego está la banda  $\beta_a$  con **93.44%**, y  $\gamma$  con **92.68%**, al igual que en las pruebas anteriores la banda  $\beta$  es la que contiene la información que mejor discrimina entre las clases.

### 7.3 Resultados de la Clasificación Utilizando Medidas de Conectividad. 85


La selección de características dio como resultado:



**Figura 7-11:** Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de *Flanker* Comparando los Métodos de Relevancia Utilizados.

El conjunto de características óptimo se localiza en general para todos los métodos de conectividad al seleccionar la mitad de las características, aunque puede variar dependiendo de la valencia y método. Los conjuntos seleccionados fueron: 80 y 20 para estímulo amenazante central, 120 y 25 para amenazante periférico, 120 y 30 para neutro central, y 100 y 25 para neutro periférico.

A continuación se muestra entonces el resultado de la comparación de los métodos en la Figura 7-14.



**Figura 7-12:** Puntaje F1 de la Clasificación Utilizando Conectividad Para Datos de *Flanker* Comparando los Métodos de Relevancia Utilizados.

Para este experimento y datos la banda más votada fue  $\delta$ , por tanto, si se consideran los demás experimentos, se tiene que en  $\delta$  al igual que en  $\beta$  hay componentes que contribuyen a una mejor clasificación, esto sugiere que la atención y concentración son factores fundamentales en ambas tareas.

Se puede ver que a lo largo de todos los experimentos la búsqueda exhaustiva alcanzó por lo general los mejores resultados, sobrepasada en un experimento por la combinación de información usando MKL, que en esta ocasión también se mantiene en altos valores, mejorando incluso la selección de características y la prueba usando todas las características, esto quiere decir que MKL no sólo usa toda la información si no que logra crear una representación que mejora la clasificación comparado con el conjunto de todas las características sin ningún proceso.

## 7.4. Sumario.

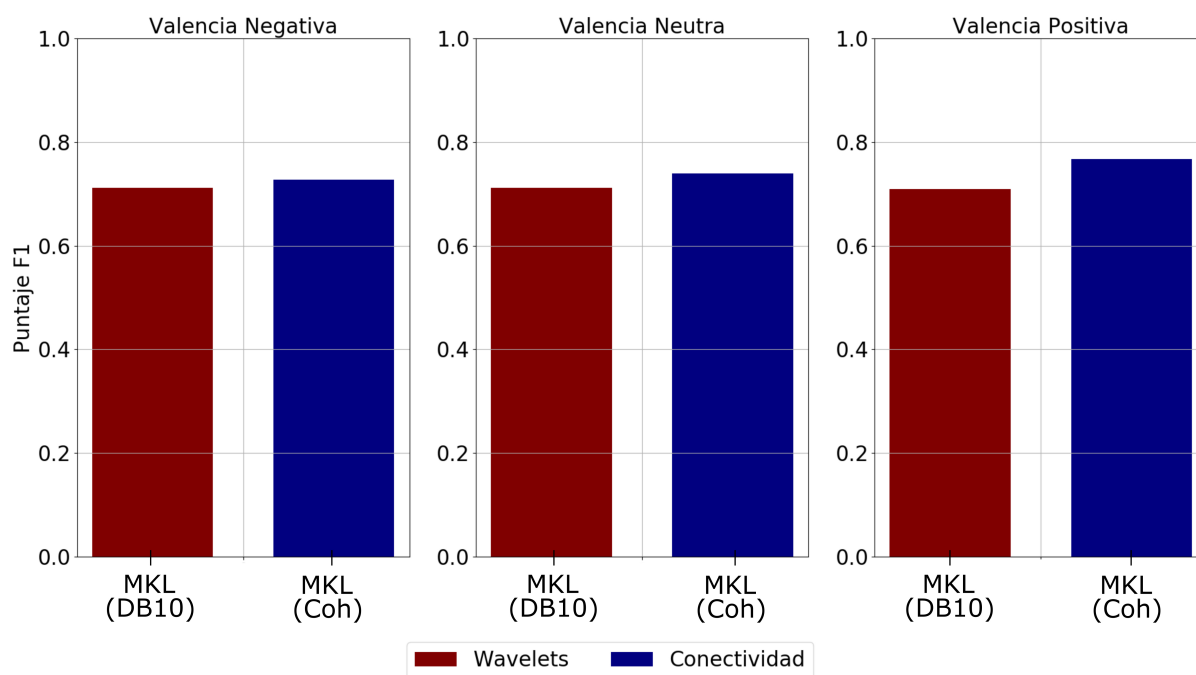
Los resultados para cada método de caracterización y análisis de relevancia son presentados en este capítulo. En general, se mostraron para ambas bases de datos los resultados de clasificación con máquinas de vectores de soporte, inicialmente utilizando la transformación Wavelet y características estadísticas, luego se utilizó conectividad funcional con grafos. Adicionalmente se realizó un análisis de relevancia con tres métodos: búsqueda exhaustiva por bandas



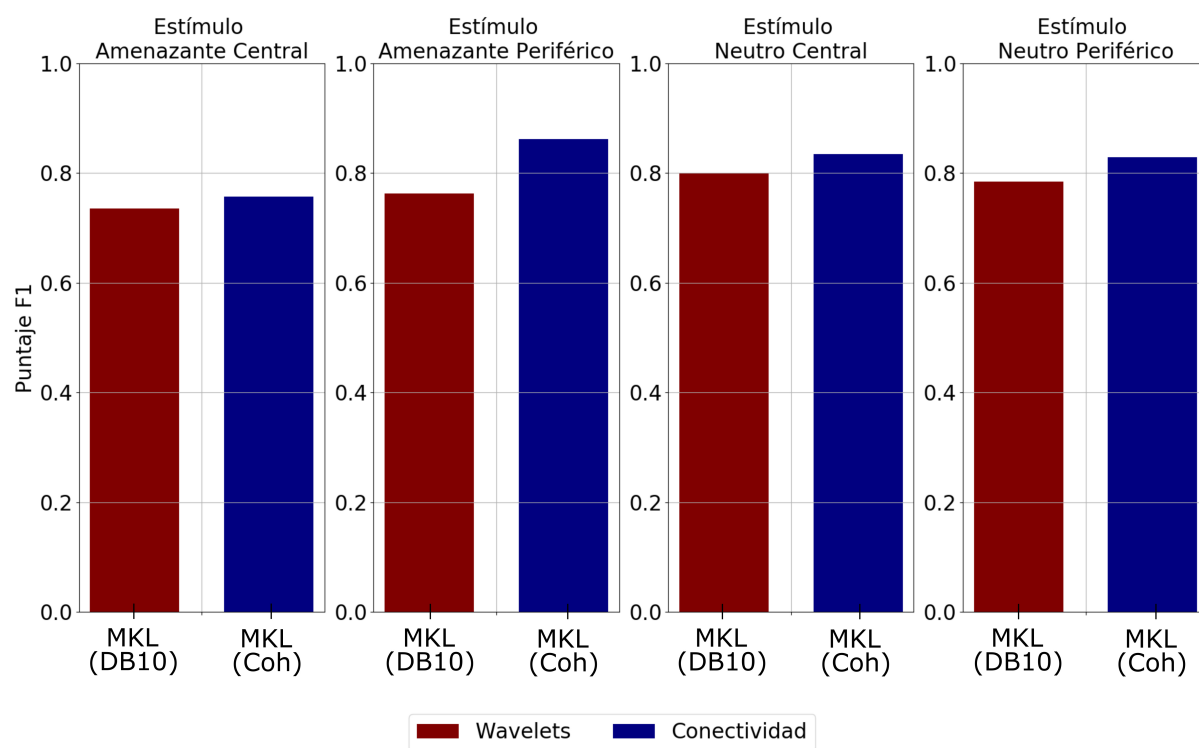
de frecuencia, asignación de pesos con aprendizaje multi kernel y selección de características.

Se observó que a lo largo de las pruebas realizadas con búsqueda exhaustiva la banda con mejores resultados y más votada es  $\beta$ , seguida por  $\delta$ . Dichas bandas se relacionan con la atención, con lo que hipotetizamos que los excombatientes y los controles tienen un nivel de atención diferente a los estímulos.

A continuación, se muestra un resumen de los resultados alcanzados por MKL sparse tanto en wavelets como en conectividad, a pesar de que el análisis usando búsqueda exhaustiva logró obtener los resultados más altos en la mayoría de pruebas y es altamente consistente a lo largo de los experimentos, se hace especial referencia a MKL debido a que alcanza valores comparables con la búsqueda exhaustiva, y principalmente por su capacidad de asignar de forma automática pesos a las características más relevantes, lo cual es un avance substancial en las metodologías tradicionales que requieren una inspección manual de los resultados, además es de resaltar que en la base de datos de valencia contextual, se superaron los mejores resultados obtenidos por la búsqueda exhaustiva, lo cual muestra que MKL es una alternativa viable para este tipo de estudios. De este modo, se muestra en la caracterización con Wavelets los resultados al seleccionar Db10 como Wavelet madre, y en el caso de conectividad se escogió la coherencia.



**Figura 7-13:** Resultados Comparativos Entre Wavelets y Conectividad Para los Datos de Valencia Contextual Utilizando MKL Como Mejor Método de Relevancia.



**Figura 7-14:** Resultados Comparativos Entre Wavelets y Conectividad Para los Datos de *Flanker* Utilizando MKL Como Mejor Método de Relevancia.

En general se puede observar que las medidas de conectividad con MKL tienen buenos resultados en ambas bases de datos, lo que quiere decir que los pesos asignados corresponden a las bandas más relevantes, haciendo este trabajo de forma automática sin necesidad de hacer la valoración por bandas.

## 8 Conclusiones y Trabajo Futuro.

En el presente trabajo de tesis se desarrolló una metodología de caracterización, análisis de relevancia y clasificación de registros de electroencefalografía para discriminar sujetos con alta exposición al conflicto armado de pacientes control.

Los métodos exploratorios de características en combinación de los dominios tiempo, espacio, y frecuencia fueron fundamentales para hallar diferencias entre la forma en que procesan las emociones los sujetos de estudio y los controles, evidenciando que las bandas de frecuencia que presentan la mayor relevancia son las bandas  $\delta$  y  $\beta$ . Esto se pudo observar para las dos bases de datos, lo cual sugiere que la diferencia entre los grupos de estudio se centra en patrones de atención y alta concentración.

Uno de los hallazgos más importantes obtenidos en este trabajo radica en la forma como el aprendizaje multi kernel logra mantener en promedio una buena separabilidad de clases, incluso alcanzando mayor discriminación que la mejor banda en datos de valencia contextual, esto indica que MKL realiza una combinación efectiva de la información y genera en algunos casos mejores fronteras de decisión en el conjunto de datos mapeado al plano de características.

Evaluando individualmente cada base de datos y método de caracterización, se encontró que para valencia contextual al tener mejores resultados en wavelets que en conectividad, no hay una diferencia clara entre las regiones del cerebro que procesan la información entre controles y excombatientes, mientras que para datos con imágenes flanqueadas, se encuentra que hay modificaciones en la conectividad funcional de los sujetos con alta exposición al conflicto comparado con los controles. Esto se puede observar especialmente en el experimento de clasificación utilizando la medida de conectividad que representa la parte imaginaria de la coherencia.

La forma de evaluación planteada permitió observar de forma homogénea las fronteras de decisión generadas por los métodos de caracterización y relevancia. La clasificación con SVM mostró luego de ser evaluado por el puntaje F1 que la tasa de aprendizaje obtenida de los datos de entrada, tanto para wavelets como para conectividad, alcanzaron resultados satisfactorios, siendo las características de conectividad las que lograron una mejor tasa de clasificación.

Ya que la intención de este trabajo fue desarrollar una completa forma de caracterización y análisis de relevancia, el proceso de clasificación no fue explorado a profundidad. Uno de los trabajos futuros en búsqueda de mejorar la separación de clases es evaluar otras metodologías de clasificación, teniendo como base algoritmos como redes neuronales convolucionales, árboles de decisión, y bosques aleatorios. Adicionalmente se puede hacer un estudio más exhaustivo de la forma en que se calculan los pesos del aprendizaje multi kernel, y la relación que existe entre los de datos de entrada y el éxito en la combinación, ya que como se pudo ver, en determinados casos lograba sobrepasar el mejor resultado del análisis individual por bandas y en otros no, este comportamiento abre diferentes interrogantes sobre los datos que se están evaluando.

Al trabajo futuro se suma la utilización de otras medidas de grafos como las que se mencionan en [120], donde se utilizan descriptores de imágenes en las matrices de adyacencia basados en la estructura de grafos locales, por otro lado en [1] se muestran algunas formas alternativas para la selección de los umbrales en la binarización de la matriz adyacencia, lo cual es factor determinante y no se ha estudiado a profundidad. Adicionalmente, sería totalmente adecuada la incorporación de otras medidas de conectividad que en el estado del arte han mostrado reducción el efecto del volumen de conducción en canales, como el índice de retardo de fase ponderado (wPLI) e información mutua simbólica ponderada (wSMI) [54].

# Bibliografía

- [1] ABDULLA, Shahab ; DIYKH, Mohammed ; LUAIBI, Raid ; SALEH, Khalid: Sleep EEG signal analysis based on correlation graph similarity coupled with an ensemble extreme machine learning algorithm. En: *Expert Systems With Applications* 138 (2019), p. 112790. – ISSN 0957–4174
- [2] ACKERMANN, Pascal ; KOHLSCHHEIN, Christian ; BITSCH, Jó Ágila ; WEHRLE, Klaus ; JESCHKE, Sabina: EEG-based automatic emotion recognition: Feature extraction, selection and classification methods. En: *2016 IEEE 18th International Conference on e-Health Networking, Applications and Services, Healthcom 2016* (2016). ISBN 9781509033706
- [3] AHIRWAL, M. K. ; KUMAR, A. ; LONDHE, N. D. ; BIKROL, H.: Scalp connectivity networks for analysis of EEG signal during emotional stimulation. En: *International Conference on Communication and Signal Processing, ICCSP 2016* (2016), p. 592–596. ISBN 9781509003969
- [4] AIOLLI, Fabio ; DONINI, Michele: Easy Multiple Kernel Learning. En: *22nd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2014 - Proceedings* (2014), Nr. April, p. 289–294. ISBN 9782874190957
- [5] TRUJILLO ET AL., submitted: Cambios en el EEG en reposo de exparticipantes en el conflicto armado colombiano con trastorno de personalidad antisocial. En: *Revista Colombiana de Psiquiatría* 47 (2018), Nr. 2, p. 90–97. – ISSN 00347450
- [6] AL-SHARGIE, Fares ; TARIQ, Usman ; ALEX, Meera ; MIR, Hasan ; AL-NASHASH, Hasan: Emotion Recognition Based on Fusion of Local Cortical Activations and Dynamic Functional Networks Connectivity: An EEG Study. En: *IEEE Access* 7 (2019), p. 143550–143562. – ISSN 21693536
- [7] ALCAMI, Pepe ; EL HADY, Ahmed: Axonal Computations. En: *Frontiers in Cellular Neuroscience* 13 (2019), Nr. September, p. 1–19. – ISSN 16625102
- [8] ALSHUAIB, M Murugappan Waleed B.: Emotion Classification in Parkinson ' s Disease EEG using RQA and ELM. En: *International Colloquium on Signal Processing & its Applications (CSPA 2020)* (2020), Nr. Cspa, p. 28–29. ISBN 9781728153100

- [9] ARIAFAR, Elham: Intrusion Detection System Using an Optimized Framework Based on Datamining Techniques. (2017), p. 785–791. ISBN 9781538626405
- [10] ARUNKUMAR, A. ; RAMKUMAR, R. K. ; VENKATRAMAN, V. V. ; ABDULHAY, Enas ; LAWRENCE FERNANDES, Steven ; KADRY, Seifedine ; SEGAL, Sophia: Classification of focal and non focal EEG using entropies. En: *Pattern Recognition Letters* 94 (2017), p. 112–117. – ISSN 01678655
- [11] BASELICE, Fabio ; SORRISO, Antonietta ; RUCCO, Rosaria ; SORRENTINO, Pierpaolo: Phase Linearity Measurement : A Novel Index for Brain Functional Connectivity. En: *IEEE Transactions on Medical Imaging* 38 (2019), Nr. 4, p. 873–882
- [12] BASTOS, André M ; SCHOFFELEN, Jan-mathijs: A Tutorial Review of Functional Connectivity Analysis Methods and Their Interpretational Pitfalls. En: *Frontiers in Systems Neuroscience* 9 (2016), Nr. January, p. 1–23
- [13] BAZGIR, Omid ; MOHAMMADI, Zeynab ; HABIBI, Seyed Amir H.: Emotion Recognition with Machine Learning Using EEG Signals. En: *2018 25th Iranian Conference on Biomedical Engineering and 2018 3rd International Iranian Conference on Biomedical Engineering, ICBME 2018* (2018), Nr. June. ISBN 9781538679524
- [14] BEN-ABU, Yuval ; ZHOU, Yufeng ; ZILBERBERG, Noam ; YIFRACH, Ofer: Inverse coupling in leak and voltage-activated K + channel gates underlies distinct roles in electrical signaling. 16 (2009), Nr. 1, p. 71–79
- [15] BIGDELY-SHAMLO, Nima ; MULLEN, Tim ; KOTHE, Christian ; SU, Kyung M. ; ROBINS, Kay A.: The PREP pipeline: Standardized preprocessing for large-scale EEG analysis. En: *Frontiers in Neuroinformatics* 9 (2015), Nr. JUNE, p. 1–19. – ISSN 16625196
- [16] BONO, Valentina ; BISWAS, Dwaipayan ; DAS, Saptarshi ; MAHARATNA, Koushik: Classifying human emotional states using wireless EEG based ERP and functional connectivity measures. En: *3rd IEEE EMBS International Conference on Biomedical and Health Informatics, BHI 2016* (2016), p. 200–203. ISBN 9781509024551
- [17] BOUFENAR, Chaouki ; BATOUCHE, Mohamed: Investigation on deep learning for off-line handwritten Arabic Character Recognition using Theano research platform. En: *2017 Intelligent Systems and Computer Vision, ISCV 2017* (2017). ISBN 9781509040629
- [18] BREIMAN, Leo: ST4\_Method\_Random\_Forest. En: *Machine Learning* 45 (2001), Nr. 1, p. 5–32. – ISBN 9788578110796

- [19] BRUNO, P ; VATTA, F ; MININEL, S ; INCHINGOLO, P: Referenced EEG and head volume conductor model: geometry and parametrical setting. En: *International Conference of the IEEE EMBS C* (2004), p. 833–836. ISBN 0780384393
- [20] BULLMORE, Ed ; SPORNS, Olaf: The economy of brain network organization. 13 (2012), Nr. April, p. 336–349
- [21] BURIANOVÁ, Hana ; MARSTALLER, Lars ; SOWMAN, Paul ; TESAN, Graciela ; RICH, Anina N. ; WILLIAMS, Mark ; SAVAGE, Greg ; JOHNSON, Blake W.: NeuroImage Multimodal functional imaging of motor imagery using a novel paradigm. En: *NeuroImage* 71 (2013), p. 50–58. – ISSN 1053–8119
- [22] BUSTAMANTE, Valentina J.: Conflicto armado en Colombia, el proceso de paz y la Corte Penal Internacional: Un estudio sobre la internacionalización del conflicto armado en Colombia y su búsqueda por encontrar la paz duradera. En: *Journal of International Law* 6 (2015), Nr. 6, p. 6–34. – ISSN 2216–0965
- [23] BUZSÁKI, György: *Rhythms of the Brain*. 2006. – ISBN 9780195301069
- [24] BUZSÁKI, György ; ANASTASSIOU, Costas A. ; KOCH, Christof: The origin of extracellular fields and currents EEG, ECoG, LFP and spikes. En: *Nature Reviews Neuroscience* 13 (2012), Nr. 6, p. 407–420. – ISSN 1471–0048
- [25] CARLOS, G ; MIGUEL, A ; HORNERO, Roberto ; MEMBER, Ieee S.: Analysis of Volume Conduction Effects on Different Functional Connectivity Metrics : Application to Alzheimer ' s Disease EEG Signals. C (2019), p. 6434–6437. ISBN 9781538613115
- [26] CHAKRABORTY, Debsubhra ; YANG, Zixu ; TAHIR, Yasir ; MASZCZYK, Tomasz ; DAUWELS, Justin ; THALMANN, Nadia ; ZHENG, Jianmin ; MANIAM, Yogeswary ; AMIRAH, Nur ; TAN, Bhing L. ; LEE, Jimmy: PREDICTION OF NEGATIVE SYMPTOMS OF SCHIZOPHRENIA FROM EMOTION RELATED LOW-LEVEL SPEECH SIGNALS. (2018), p. 6024–6028. ISBN 9781538646588
- [27] CHAMANDEEP, Kaur: DESIGN OF WAVELET THRESHOLDING MODEL FOR EPILEPTIC EEG SIGNAL. 9 (2017), Nr. 2, p. 29505–29514
- [28] CHANG, Chih-chung ; LIN, Chih-jen: LIBSVM : A Library for Support Vector Machines. (2013), p. 1–39
- [29] CHATTERJEE, Rajdeep ; BANDYOPADHYAY, Tathagata: EEG Based Motor Imagery Classification Using SVM and MLP. En: *2016 2nd International Conference on Computational Intelligence and Networks (CINE)* (2016), p. 84–89. ISBN 978–1–5090–0451–5



- [30] CHELLA, Federico ; PIZZELLA, Vittorio ; ZAPPASODI, Filippo: Impact of the reference choice on scalp EEG connectivity estimation. En: *Journal of Neural Engineering* 13, Nr. 3, p. 1–21. – ISSN 1741–2552
- [31] CHEN, Duo ; WAN, Suiren ; XIANG, Jing ; BAO, Forrest S.: A high-performance seizure detection algorithm based on Discrete Wavelet Transform ( DWT ) and EEG. (2017), p. 1–21. ISBN 1111111111
- [32] CHEN, Mo ; HAN, Junwei ; GUO, Lei ; WANG, Jiahui ; PATRAS, Ioannis: Identifying valence and arousal levels via connectivity between EEG channels. En: *2015 International Conference on Affective Computing and Intelligent Interaction, ACII 2015* (2015), p. 63–69. ISBN 9781479999538
- [33] CORTES, Corinna ; MOHRI, Mehryar ; ROSTAMIZADEH, Afshin: Algorithms for Learning Kernels Based on Centered Alignment. 13 (2012), p. 795–828
- [34] CORTES, Corinna ; VAPNIK, Vladimir: Support-Vector Networks. 297 (1995), p. 273–297
- [35] CORTES, Jimmy A. ; CHAVES OSORIO, José Andrés: Del análisis de Fourier a las wavelets análisis de Fourier Scientia Et Technica Universidad Tecnológica de Pereira. En: *Scientia Et Technica* (2015), Nr. May 2007
- [36] CRISTIANINI, Nello ; SHAWE-TAYLOR, John ; ELISSEEFF, Andre ; SHAWE-TAYLOR, John: On Kernel-Target Alignment.
- [37] DELGADO, Marisel ; AVIYENTE, Selin: A Time-Frequency Based Bivariate Synchrony Measure for Reducing Volume Conduction Effects in EEG. En: *Symposium on Singular Processing Challenges in Human Brain Connectomics* (2015), p. 825–828. ISBN 9781479975914
- [38] DESPOTOVIC, Vladimir ; WALTER, Oliver ; HAEB-UMBACH, Reinhold: Machine learning techniques for semantic analysis of dysarthric speech: An experimental study. En: *Speech Communication* 99 (2018), may, p. 242–251. – ISSN 0167–6393
- [39] DING, Rui ; LI, Ping ; WANG, Wei ; LUO, Wenbo: Emotion Processing by ERP Combined with Development and Plasticity. En: *Neural Plasticity* 2017 (2017). – ISSN 16875443
- [40] FITZGERALD, Jacklynn M. ; GORKA, Stephanie M. ; KUJAWA, Autumn ; DIGANGI, Julia A. ; PROESCHER, Eric ; GREENSTEIN, Justin E. ; AASE, Darrin M. ; SCHROTH, Christopher ; AFSHAR, Kaveh ; KENNEDY, Amy E. ; HAJCAK, Greg ; PHAN, K. L.: Neural indices of emotional reactivity and regulation predict course of PTSD symptoms in combat-exposed veterans. En: *Progress in Neuro-Psychopharmacology and Biological Psychiatry* 82 (2018), Nr. August 2017, p. 255–262. – ISSN 18784216

- [41] FRID, Alex ; BREZNITZ, Zvia: An SVM based algorithm for analysis and discrimination of dyslexic readers from regular readers using ERPs. En: *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel, IEEEI 2012* (2012), p. 1–4. ISBN 9781467346801
- [42] FRØLICH, Laura ; DOWDING, Irene: Removal of muscular artifacts in EEG signals: a comparison of linear decomposition methods. En: *Brain Informatics* 5 (2018), Nr. 1, p. 13–22. – ISBN 0123456789
- [43] GANTIVA DÍAS, Carlos Andres (Universidad De San B. ; GUERRA MUÑOZ, Pedro (Universidad de G. ; VILLA CASTELLAR, Jaime (Universidad de G.: COLOMBIAN VALIDATION OF THE INTERNATIONAL AFFECTIVE PICTURE. 14 (2011), Nr. 2, p. 103–111
- [44] GÉRON, Aurélien: *Hands-on Machine Learning with Scikit-Learn, Keras, and Tensor-Flow, 2nd Edition*. 2019. – 838 p.. – ISBN 9781492032649
- [45] GHAI, Mohan ; LAL, Shamit ; DUGGA, Shivam ; MANIK, Shrey: Emotion Recognition On Speech Signals Using Machine Learning. (2017), p. 34–39. ISBN 9781509063994
- [46] GOMEZ-HERRERO, G: *Brain Connectivity Analysis with EEG*. 2010 ( MARCH 2010). – 159 p.. – ISBN 9789521523427
- [47] GRAJSKI, Kamil A. ; BREIMAN, Leo ; DI PRISCO, Gonzalo V. ; FREEMAN, Walter J.: Classification of EEG Spatial Patterns with a Tree-Structured Methodology: CART. En: *IEEE Transactions on Biomedical Engineering* BME-33 (1986), Nr. 12, p. 1076–1086. – ISSN 15582531
- [48] GÜLER, Inan ; ÜBEYLI, Elif D.: Multiclass support vector machines for EEG-signals classification. En: *IEEE Transactions on Information Technology in Biomedicine* 11 (2007), Nr. 2, p. 117–126. – ISSN 10897771
- [49] GUO, Kairui ; CANDRA, Henry ; YU, Hairong ; LI, Huiqi ; NGUYEN, Hung T. ; SU, Steven W.: EEG-based emotion classification using innovative features and combined SVM and HMM classifier. En: *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* (2017), p. 489–492. – ISBN 9781509028092
- [50] GUPTA, Rashmi ; HUR, Young J. ; LAVIE, Nilli: Distracted by pleasure: Effects of positive versus negative valence on emotional capture under load. En: *Emotion* 16 (2016), Nr. 3, p. 328–337. – ISSN 19311516
- [51] HANDHAYANI, Teny: Hand Signature and Handwriting Recognition as Identification of the Writer using Gray Level Co- Occurrence Matrix and Bootstrap. (2017), Nr. September, p. 1103–1110. ISBN 9781509064359

- [52] HILL, Bertil: IONIC CHANNELS IN EXCITABLE MEMBRANES CURRENT PROBLEMS AND BIOPHYSICAL APPROACHES. (1978), Nr. February 1977, p. 283–294
- [53] HOSSIN, M ; M.N, Sulaiman: A REVIEW ON EVALUATION METRICS FOR DATA CLASSIFICATION EVALUATIONS. En: *International Journal of Data Mining & Knowledge Process* 5 (2015), Nr. 2, p. 1–11
- [54] IMPERATORI, Laura S. ; BETTA, Monica ; CECCHETTI, Luca ; CANALES, Andrés ; RICCIARDI, Emiliano ; SICLARI, Francesca ; PIETRINI, Pietro ; CHENNU, Srivas: EEG functional connectivity metrics wPLI and wSMI account for distinct types of brain functional interactions. (2019), Nr. June, p. 1–15
- [55] ITO, Yasushi ; KUMADA, Satoko ; UCHIYAMA, Akira ; SAITO, Kayoko ; OSAWA, Makiko ; YAGISHITA, Akira ; KURATA, Kiyoko ; HAYASHI, Masaharu: Thalamic lesions in a long-surviving child with spinal muscular atrophy type I: MRI and EEG findings. En: *Brain and Development* 26 (2004), Nr. 1, p. 53–56. – ISSN 0387–7604
- [56] IZQUIERDO, Juan A P.: Contribución al análisis multiescala de señales . Aplicación a imágenes de suelos agrícolas y series nancieras. (2016)
- [57] JADIDI, A.F. ; ZARGAR, B.S. ; MORADI, M.H.: Categorizing visual objects; Using ERP components. En: *2016 23rd Iranian Conference on Biomedical Engineering and 2016 1st International Iranian Conference on Biomedical Engineering, ICBME 2016* (2017), Nr. November, p. 23–25. ISBN 9781509034529
- [58] JAS, Mainak ; ENGEMANN, Denis A. ; BEKHTI, Yousra ; RAIMONDO, Federico ; GRAMFORT, Alexandre: Autoreject: Automated artifact rejection for MEG and EEG data. En: *NeuroImage* 159 (2017), Nr. December 2016, p. 417–429. – ISSN 10959572
- [59] JAS, Mainak ; ENGEMANN, Denis A. ; RAIMONDO, Federico ; BEKHTI, Yousra ; GRAMFORT, Alexandre: Automated rejection and repair of bad trials in To cite this version : Automated rejection and repair of bad trials in MEG / EEG. En: *6th International Workshop on Pattern Recognition in Neuroimaging (PRNI)* (2016)
- [60] KAISER, Jurgen ; TENKE, Craig: Issues and considerations for using the scalp surface Laplacian in EEG/ERP research: A tutorial review Jürgen. 97 (2016), Nr. 3, p. 189–209
- [61] KAKKOS, I. ; GKIATIS, K. ; BROMIS, K. ; ASVESTAS, P. A. ; KARANASIOU, I. S. ; VENTOURAS, E. M. ; MATSOPOULOS, G. K.: Classification of Error Related Brain Activity in an Auditory Identification Task with Conditions of Varying Complexity. En: *Journal of Physics: Conference Series* 931 (2017), Nr. 1. – ISSN 17426596
- [62] KIM, Sun-hee ; ANH, Ngoc ; THI, Nguyen: Feature Extraction of Emotional States for EEG-based Rage Control. En: *2016 39th International Conference on Telecommunications and Signal Processing (TSP)* (2016), p. 361–364. ISBN 9781509012886

- [63] KING, Gary ; ZENG, Langche: Logistic Regression in Rare. (2001)
- [64] KLONOWSKI, Wlodzimierz: Everything you wanted to ask about EEG but were afraid to get the right answer. En: *Nonlinear Biomedical Physics* 5 (2009), p. 1–5
- [65] KOELSTRA, Sander ; MEMBER, Student ; MEMBER, Student ; LEE, Jong-seok ; YAZDANI, Ashkan ; EBRAHIMI, Touradj ; PUN, Thierry ; NIJHOLT, Anton ; PATRAS, Ioannis: DEAP : A Database for Emotion Analysis using Physiological Signals. , p. 1–15
- [66] KROUPI, Eleni ; YAZDANI, Ashkan ; VESIN, Jean M. ; EBRAHIMI, Touradj: Ocular artifact removal from EEG: A comparison of subspace projection and adaptive filtering methods. En: *European Signal Processing Conference* (2011), Nr. Eusipco, p. 1395–1399. – ISSN 22195491
- [67] KUMAR, J. S. ; BHUVANESWARI, P.: Analysis of electroencephalography (EEG) signals and its categorization - A study. En: *Procedia Engineering* 38 (2012), p. 2525–2536. – ISSN 18777058
- [68] KUNCHEVA, Ludmila I. ; RODRÍGUEZ, Juan J.: Interval feature extraction for classification of event-related potentials (ERP) in EEG data analysis. En: *Progress in Artificial Intelligence* 2 (2013), Nr. 1, p. 65–72. – ISSN 2192–6352
- [69] LABRUNIE, M. ; BADIN, P. ; VOIT, D. ; JOSEPH, A.A. ; FRAHM, J. ; LAMALLE, L. ; VILAIN, C. ; BOË, L.-J.: Automatic segmentation of speech articulators from real-time midsagittal MRI based on supervised learning. En: *Speech Communication* 99 (2018), p. 27–46
- [70] LAI, Margherita ; DEMURU, Matteo ; HILLEBRAND, Arjan ; FRASCHINI, Matteo: A comparison between scalp- and source-reconstructed EEG networks. En: *Scientific Reports* 8 (2018), Nr. 1, p. 1–8. – ISBN 4159801830869
- [71] LANG, J M.: A new on-line resource for psycholinguistic studies. 51 (2012), Nr. 2, p. 247–250
- [72] LEE, Te-won ; SEJNOWSKI, Terrence J.: Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Subgaussian and Supergaussian Sources. 441 (1999), p. 417–441
- [73] LI, J. ; YU, Z.L. ; GU, Z. ; WU, W. ; LI, Y. ; JIN, L.: A Hybrid Network for ERP Detection and Analysis Based on Restricted Boltzmann Machine. En: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 26 (2018), Nr. 3, p. 563–572. – ISSN 15344320

- [74] LI, Junhua ; WANG, Yijun ; ZHANG, Liqing ; JUNG, Tzyy P.: Combining ERPs and EEG spectral features for decoding intended movement direction. En: *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* (2012), p. 1769–1772. – ISBN 9781424441198
- [75] LI, Ruru ; YANG, Dali ; LI, Xinxing ; WANG, Renyu ; XU, Mingxing ; ZHENG, Thomas F.: Relative Entropy Normalized Gaussian Supervector for Speech Emotion Recognition using Kernel Extreme Learning Machine.
- [76] LIN, Yuan P. ; WANG, Chi H. ; JUNG, Tzyy P. ; WU, Tien L. ; JENG, Shyh K. ; DUANN, Jeng R. ; CHEN, Jyh H.: EEG-based emotion recognition in music listening. En: *IEEE Transactions on Biomedical Engineering* 57 (2010), Nr. 7, p. 1798–1806. – ISSN 00189294
- [77] LIU, Xucheng ; LI, Ting ; TANG, Cong ; XU, Tao ; CHEN, Peng ; BEZERIANOS, Anastasios ; WANG, Hongtao: Emotion Recognition and Dynamic Functional Connectivity Analysis Based on EEG. En: *IEEE Access* 7 (2019), p. 143293–143302. – ISSN 21693536
- [78] LODHA, Priyanka ; TALELE, Ajay: Diagnosis of Alzheimer ' s Disease using Machine Learning. En: *Fourth International conference on Computer Communication Control and Automation (ICCUBEA)* (2018), p. 2018–2021. ISBN 9781538652572
- [79] LORENZO-TRUEBA, Jaime ; EJE HENTER, Gustav ; TAKAKI, Shinji ; YAMAGISHI, Junichi ; MORINO, Yosuke ; OCHIAI, Yuta: Investigating different representations for modeling and controlling multiple emotions in DNN-based speech synthesis. En: *Speech Communication* 99 (2018), p. 135–143. – ISSN 01676393
- [80] MCBRIDE, Joseph ; ZHAO, Xiaopeng ; MUNRO, Nancy ; SMITH, Charles ; JICHA, Gregory ; JIANG, Yang: Resting EEG Discrimination of Early Stage Alzheimers Disease from Normal Aging Using Inter-Channel Coherence Network Graphs. En: *Annals of biomedical engineering* 41 (2013), 03
- [81] MEHMET, G ; ALPAYDIN, Ethem: Multiple Kernel Learning Algorithms. 12 (2011), p. 2211–2268
- [82] MÉNDEZ, Alvaro ; CORTINA, Andrés ; GRAZIANI, Jimmy ; SEQUERA, Natalia: *Desarme, Desmovilización y Reintegración, DDR: Una Introducción para Colombia*. 2013. – 1–88 p.. – ISBN 958975189X
- [83] MINSKY, Marvin L. ; PAPERT, Seymour A.: *Perceptrons An Introduction to Computational Geometry*. (1988). ISBN 9780262534772

- [84] NASEHI, Saadat ; POURGHASSEM, Hossein: A novel effective feature selection algorithm based on S-PCA and wavelet transform features in EEG signal classification. En: *2011 IEEE 3rd International Conference on Communication Software and Networks, ICCSN 2011* (2011), p. 114–117. ISBN 9781612844855
- [85] NGUYEN, Thien ; BABAWALE, Olajide ; KIM, Tae ; JO, Hang J. ; LIU, Hanli ; KIM, Jae G.: Exploring brain functional connectivity in rest and sleep states : a fNIRS study. En: *Scientific Reports* (2018), Nr. September, p. 1–10. – ISSN 2045–2322
- [86] NIEDERMEYER, Ernst ; LOPES, Fernando: *Electroencephalography Basic Principles, Clinical Applications, and Related Fields*. Philadelphia, USA : LIPPINCOTT WILLIAMS & WILKINS, 2005. – 267–282 p.. – ISBN 0781751268
- [87] NOLTE, Guido ; BAI, Ou ; WHEATON, Lewis ; MARI, Zoltan ; VORBACH, Sherry ; HALLETT, Mark: Identifying true brain interaction from EEG data using the imaginary part of coherency. 115 (2004), p. 2292–2307
- [88] OBERMAN, Lindsay M. ; HUBBARD, Edward M. ; MCCLEERY, Joseph P. ; ALTSCHULER, Eric L. ; RAMACHANDRAN, Vilayanur S. ; PINEDA, Jaime A.: EEG evidence for mirror neuron dysfunction in autism spectrum disorders. En: *Cognitive Brain Research* 24 (2005), Nr. 2, p. 190–198. – ISSN 0926–6410
- [89] OBRIST, Marianna ; VELASCO, Carlos ; VI, Chi T. ; RANASINGHE, Nimesha ; ISRAR, Ali ; CHEOK, Adrian D. ; SPENCE, Charles ; GOPALAKRISHNAKONE, Ponnampalam: Touch, Taste, & Smell User Interfaces: The Future of Multisensory HCI. En: *Proceedings of the 2016 CHI Conference Extended Abstracts on Human Factors in Computing Systems*. New York, NY, USA : ACM, 2016 (CHI EA '16). – ISBN 978–1–4503–4082–3, p. 3285–3292
- [90] ÖZBEYAZ, Abdurrahman ; ARICA, Sami: Familiar/Unfamiliar Face Classification from EEG Signals by Utilizing Pairwise Distant Channels and Distinctive Time Interval. En: *Signal, Image and Video Processing* (2018), Nr. March. – ISSN 18631711
- [91] PARRA, Mario A. ; SÁNCHEZ, Manuel G. ; VALENCIA, Stella ; TRUJILLO, Natalia ; PARRA, Mario A. ; SÁNCHEZ, Manuel G. ; VALENCIA, Stella ; TRUJILLO, Natalia: Attentional bias during emotional processing : evidence from an emotional flanker task using IAPS. 9931 (2017), Nr. November
- [92] PICHILIANI, Mauro C. ; HIRATA, Celso M. ; FRAGA, Tania: Exploring a brain controlled interface for emotional awareness. En: *Proceedings - 9th Brazilian Symposium on Collaborative Systems, SBSC 2012* (2012), p. 49–52. ISBN 9780769548906

- [93] PLEROU, Antonia ; BOBORI, Catherine: Molecular Basis of Huntington ' s Disease and Brain Imaging Evidence. En: *International Symposium on Signal Processing and Information Technology (ISSPIT) Molecular* (2015), p. 387–391
- [94] QUINTERO-ZEA, Andres ; SEPÚLVEDA CANO, Lina ; RODRÍGUEZ-CALVACH, Mónica V. ; ÁNGEL-LÓPEZ, Juan P. ; ARZOLA DE LA PEÑA, Nelson: Characterization Framework for Ex-combatants Based on EEG and Behavioral Features. En: *IFMBE Proceedings* 60 (2017), p. 520–523. ISBN 978–981–10–4085–6
- [95] RAHMAN, M. M. ; CHOWDHURY, M. A. ; FATTAH, S. A.: An efficient scheme for mental task classification utilizing reflection coefficients obtained from autocorrelation function of EEG signal. En: *Brain Informatics* 5 (2018), Nr. 1, p. 1–12. – ISSN 21984026
- [96] RAMOS, Claudia ; DUQUE-GRAJALES, Jon ; RENDÓN, Jorge ; MONTOYA-BETANCUR, Alejandro ; BAENA, Ana ; PINEDA, David ; TOBÓN, Carlos: Cambios en el EEG en reposo de exparticipantes en el conflicto armado colombiano con trastorno de personalidad antisocial. En: *Revista Colombiana de Psiquiatría* 47 (2018), Nr. 2, p. 90–97. – ISSN 00347450
- [97] RAY, Susmita: A Quick Review of Machine Learning Algorithms. En: *Proceedings of the International Conference on Machine Learning, Big Data, Cloud and Parallel Computing: Trends, Perspectives and Prospects, COMITCon 2019* (2019), p. 35–39. ISBN 9781728102115
- [98] RICHHARIYA, B. ; TANVEER, M.: EEG signal classification using universum support vector machine. En: *Expert Systems with Applications* 106 (2018), p. 169–182. – ISSN 09574174
- [99] RODRIGUEZ, Viviana: Methodology to recognize atypical functioning in emotional processing of Colombian ex-combatants using EEG brain connectivity. (2017), p. 90
- [100] RODRÍGUEZ-CALVACH, Mónica V. ; QUINTERO-ZEA, Andrés ; TRUJILLO-ORREGO, Sandra P. ; TRUJILLO-ORREGO, Natalia ; LÓPEZ-HINCAPIÉ, José D.: Detecting atypical functioning of emotional processing in Colombian ex-combatants. En: *TecnoLógicas* 20 (2017), Nr. 40, p. 83–96. – ISSN 0123–7799
- [101] ROJAS, Gabriel ; HURTADO, Paola: Grupos posdesmovilización y desplazamiento forzado en Colombia: una aproximación cuantitativa. (2014), Nr. Imdc
- [102] ROSALES, Rachael ; DWORETZKY, Barbara ; BASLET, Gaston: Cognitive-emotion processing in psychogenic nonepileptic seizures. En: *Epilepsy and Behavior* 102 (2020), p. 106639. – ISSN 15255069

- [103] SAEID SANEI: *ADAPTIVE PROCESSING OF BRAIN SIGNALS*. 24 May 201. 2013 John Wiley & Sons, Ltd, 2013. – 470 p.. – ISBN 9780470686133
- [104] SAI, Chong Y. ; MOKHTAR, Norrima ; AROF, Hamzah ; CUMMING, Paul ; IWAHASHI, Masahiro: Automated Classification and Removal of EEG Artifacts with SVM and Wavelet-ICA. En: *IEEE Journal of Biomedical and Health Informatics* 2194 (2017), Nr. c, p. 1–7. – ISSN 21682194
- [105] SARRÍA, Alfonso F.: ESTUDIO DE TÉCNICAS BASADAS EN LA TRANSFORMADA WAVELET Y OPTIMIZACIÓN. (2007)
- [106] SAVELAINEN, Antti: An introduction to EEG artifacts. En: *Perception* (2010), Nr. February, p. 1–67. ISBN 9781597492812
- [107] SCHAAL, Susanne ; KOEBACH, Anke ; HINKEL, Harald ; ELBERT, Thomas: Posttraumatic stress disorder according to DSM-5 and DSM-IV diagnostic criteria: A comparison in a sample of congolese ex-combatants. En: *European Journal of Psychotraumatology* 6 (2015), p. 1–8. – ISSN 20008066
- [108] SCHÖLKOPF, Bernhard: The kernel trick for distances. En: *Advances in Neural Information Processing Systems* (2001). – ISBN 0262122413
- [109] SEECK, M. ; LAZEYRAS, F. ; MICHEL, C. M. ; BLANKE, O. ; GERICKE, C. A. ; IVES, J. ; DELAVELLE, J. ; GOLAY, X. ; HAENGGELI, C. A. ; DE TRIBOLET, N. ; LANDIS, T.: Non-invasive epileptic focus localization using EEG-triggered functional MRI and electromagnetic tomography. En: *Electroencephalography and Clinical Neurophysiology* 106 (1998), Nr. 6, p. 508–512. – ISSN 00134694
- [110] SHIRK, Steven D. ; MCLAREN, Donald G. ; BLOOMFIELD, Jessica S. ; POWERS, Alex ; DUFFY, Alec ; MITCHELL, Meghan B. ; EZZATI, Ali ; ALLY, Brandon A. ; ATRI, Alireza: Inter-Rater Reliability of Preprocessing EEG Data: Impact of Subjective Artifact Removal on Associative Memory Task ERP Results. En: *Frontiers in Neuroscience* 11 (2017), p. 322. – ISSN 1662–453X
- [111] SIMBOLON, Artha I. ; TURNIP, Arjon ; HUTAHAEAN, Jeperson ; SIAGIAN, Yessica ; IRAWATI, Novica: An experiment of lie detection based EEG-P300 classified by SVM algorithm. En: *Proceedings of the 2015 International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology, ICACOMIT 2015* (2016), p. 68–71. ISBN 9781467374088
- [112] SOMAN, Sumit ; JAYADEVA: High performance EEG signal classification using classifiability and the Twin SVM. En: *Applied Soft Computing Journal* 30 (2015), p. 305–318. – ISBN 15684946 (ISSN)



- [113] SPORNS, O. ; TONONI ; EDELMAN, G.M: Theoretical Neuroanatomy : Relating Anatomical and Functional Connectivity in Graphs and Cortical Connection Matrices. (2000), p. 127–141
- [114] STEVENS, Charles F.: The Neuron Author ( s ): Charles F . Stevens Source : Scientific American , Vol . 241 , No . 3 ( September 1979 ), pp . 54-65 Published by : Scientific American , a division of Nature America , Inc . Stable URL : <https://www.jstor.org/stable/10.2307/24965>. 241 (1979), Nr. 3, p. 54–65
- [115] SUN, Ya B. ; LIN, Xiao X. ; YE, Wen ; WANG, Ning ; WANG, Jin Y. ; LUO, Fei: A Screening Mechanism Differentiating True from False Pain during Empathy. En: *Scientific Reports* 7 (2017), Nr. 1, p. 1–13. – ISSN 20452322
- [116] TAKASE, Ryoken ; BOASEN, Jared ; YOKOSAWA, Koichi: Different roles for theta- and alpha-band brain rhythms during sequential memory. (2019), p. 1713–1716. ISBN 9781538613115
- [117] THARWAT, Alaa: Independent component analysis: An introduction. En: *Applied Computing and Informatics* (2018), p. 1–15. – ISSN 22108327
- [118] TIAN, Jinhua ; WANG, Jian ; XIA, Tao ; ZHAO, Wenshuang ; XU, Qianru ; HE, Weiqi: The influence of spatial frequency content on facial expression processing: An ERP study using rapid serial visual presentation. En: *Scientific Reports* 8 (2018), Nr. 1, p. 1–8. – ISSN 20452322
- [119] TRUJILLO-ORREGO, Sandra P. ; TRUJILLO-ORREGO, Natalia ; RODRIGUEZ, Monica ; QUINTERO, Andrés ; LÓPEZ, José: Detecting atypical functioning of emotional processing in Colombian. 20 (2017), Nr. 40, p. 83–96
- [120] TUNCER, Turker ; DOGAN, Sengul ; ERTAM, Fatih ; SUBASI, Abdulhamit: A novel ensemble local graph structure based feature extraction network for EEG signal analysis. En: *Biomedical Signal Processing and Control* 61 (2020), p. 102006. – ISSN 1746–8094
- [121] VAPNIK, Vladimir N.: An overview of statistical learning theory. En: *IEEE Transactions on Neural Networks* 10 (1999), Nr. 5, p. 988–999. – ISSN 10459227
- [122] WANG, Tinghua ; ZHAO, Dongyan ; TIAN, Shengfeng: An overview of kernel alignment and its applications. (2012)
- [123] WANG, Zhongmin ; TONG, Yue ; HENG, Xia: Phase-Locking Value Based Graph Convolutional Neural Networks for Emotion Recognition. En: *IEEE Access* 7 (2019), p. 93711–93722. – ISSN 21693536

- [124] WEI, Chen ; LAN CHEN, Lan ; ZHEN SONG, Zhen ; GUANG LOU, Xiao ; DONG LI, Dong: EEG-based emotion recognition using simple recurrent units network and ensemble learning. En: *Biomedical Signal Processing and Control* 58 (2020), p. 101756. – ISSN 17468108
- [125] WINKLER, Irene ; DEBENER, Stefan ; MULLER, Klaus R. ; TANGERMANN, Michael: On the influence of high-pass filtering on ICA-based artifact reduction in EEG-ERP. En: *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* 2015-Novem (2015), p. 4101–4105. – ISBN 9781424492718
- [126] WU, Jennifer ; SRINIVASAN, Ramesh ; QUINLAN, Erin B. ; SOLODKIN, Ana ; SMALL, Steven L. ; CRAMER, Steven C.: Utility of EEG measures of brain function in patients with acute stroke. En: *Journal of Neurophysiology* 115 (2016), Nr. 5, p. 2399–2405. – ISSN 15221598
- [127] WU, Xun ; ZHENG, Wei L. ; LU, Bao L.: Identifying Functional Brain Connectivity Patterns for EEG-Based Emotion Recognition. En: *International IEEE/EMBS Conference on Neural Engineering, NER* 2019-March (2019), p. 235–238. – ISBN 9781538679210
- [128] WU, Yue ; WANG, Hui ; ZHANG, Biaobiao ; DU, K: Using Radial Basis Function Networks for Function Approximation and Classification. 2012 (2012)
- [129] YANG, Minglong ; AI, Qingsong ; LIU, Quan: Design of a high-performance EEG acquisition system for unshielded environment. En: *Proceedings of 2012 8th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications, MESA 2012* (2012), p. 202–206. ISBN 9781467323475
- [130] YE, Jieping ; XIONG, Tao: SVM versus Least Squares SVM.
- [131] YUVARAJ, R. ; MURUGAPPAN, M. ; SUNDARAJ, Kenneth: Methods and approaches on emotions recognition in neurodegenerative disorders: A review. En: *ISIEA 2012 - 2012 IEEE Symposium on Industrial Electronics and Applications* (2012), p. 287–292. ISBN 9781467330046
- [132] ZHANG, Yu ; WANG, Yu ; ZHOU, Guoxu ; JIN, Jing ; WANG, Bei ; WANG, Xingyu ; CICHOCKI, Andrzej: Multi-kernel extreme learning machine for EEG classification in brain-computer interfaces. En: *Expert Systems with Applications* 96 (2018), p. 302–310. – ISBN 0957–4174
- [133] ZHUANG, Xiaodan ; ROZGIC, Victor ; CRYSTAL, Michael ; MARX, Brian: IMPROVING SPEECH-BASED PTSD DETECTION VIA MULTI-VIEW LEARNING Xiaodan Zhuang , Viktor Rozgi Ć c , Michael Crystal Raytheon BBN Technologies Speech

, Language and Multimedia Business Unit Brian P . Marx National Center for PTSD at VA Boston Healthcare Syst. (2014), p. 260–265. ISBN 9781479971299