



INAOE

“Extracción de características sobre señales EEG para detección de actividades mentales motoras en sistemas BCI”

Por:

Gerardo Rosas Cholula

Tesis sometida como requisito parcial para obtener el grado de

DOCTORADO EN CIENCIAS EN LA ESPECIALIDAD DE ELECTRÓNICA.

En el

Instituto Nacional de Astrofísica, Óptica y Electrónica.

Junio 2014

Tonantzintla, Puebla

Supervisada por:

Dr. Juan Manuel Ramírez Cortés

Dr. Vicente Alarcón Aquino

©INAOE 2014

Derechos Reservados

El autor otorga al INAOE el permiso de reproducir y distribuir copias de esta tesis en su totalidad o en partes mencionando la fuente.



“Extracción de características sobre señales EEG para detección de actividades mental-motoras en sistemas BCI”

Por:

Gerardo Rosas Cholula

Tesis sometida como requisito parcial para obtener el grado de

DOCTORADO EN CIENCIAS EN LA ESPECIALIDAD DE ELECTRÓNICA.

En el

Instituto Nacional de Astrofísica, Óptica y Electrónica.

Junio 2014

Tonantzintla, Puebla

Supervisada por:

Dr. Juan Manuel Ramírez Cortés

Dr. Vicente Alarcón Aquino

©INAOE 2014

Derechos Reservados

El autor otorga al INAOE el permiso de reproducir y distribuir copias de esta tesis en su totalidad o en partes.

Resumen.

Los sistemas denominados interfaces-cerebro-computadora, BCI por sus siglas en inglés, han tenido un gran desarrollo en años recientes, debido a su potencial aplicación como herramientas de apoyo a personas con limitaciones motrices severas para que éstas puedan comunicarse o controlar algunos dispositivos en su vida diaria. Entre las técnicas no invasivas se destaca el uso de señales de EEG (electroencefalografía) obtenidas por medio de equipos de bajo costo como base para la construcción de sistemas BCI.

El presente trabajo de tesis se centra en el estudio e investigación de técnicas de procesamiento de señales para la detección de la actividad cerebral en los siguientes paradigmas neurofisiológicos: el fenómeno ERD/ERS (*Event Related Desynchronization/Synchronization*) incluyendo el caso de imaginación motora y la detección de eventos tipo P300. Para tal efecto, se desarrollaron dos protocolos experimentales propios basados en los paradigmas mencionados, y se realizaron experimentos y comparaciones con la base de datos PhysioBank, disponible a la comunidad internacional para propósitos educativos y de investigación.

En la detección de la onda P300 se reporta el uso de sistemas adaptivos neurodifusos (ANFIS). Para el análisis de las señales se investigaron técnicas espectrales y pseudo-espectrales tales como la transformada Wavelet y la Descomposición Modal Empírica (EMD). Esta última entregó resultados interesantes que condujeron al desarrollo de una técnica original para el tratamiento de ruido correlacionado a los movimientos en la interface electrodo-piel cercano a la corteza cerebral superficial. Este tipo de ruido se presenta típicamente en situaciones con el sujeto en movimiento, como sería el caso de un sistema de control en una silla de ruedas.

La separación de bandas involucrada en la detección del fenómeno ERD/ERS se hizo en base a las técnicas de descomposición EMD y MEMD (EMD multivariada). En esta última se propuso una variante original incorporando conjuntos difusos.

Los resultados obtenidos indican un nivel competitivo de desempeño de los sistemas desarrollados, orientándose a aplicaciones en condiciones de operación por parte del usuario en ambientes naturales de ubicación y desplazamiento en un espacio cerrado.

Abstract.

BCI - Brain Computer Interfaces have become, in recent years, in one of the most important systems used as tool by persons with severe muscular disabilities. BCI enable them to communicate or to control common devices in daily life. BCI systems based on EEG – electroencephalography is counted among the non-invasive techniques and it is possible to be used by low cost equipment.

The main objective for this work is to study and investigate digital signal processing techniques for detecting brain activity following two of the most remarkable paradigms: ERD/ERS – Event Related Desynchronization/Event Related Synchronization including motor imagery and P300 wave. In consequence, two experiment protocols have been developed according these paradigms. Applying these experiments is possible to compare with other techniques and databases such as PhysioBank which is available as public to the research community for educational purposes.

P300 events detection by means of ANFIS – Adaptive Neuro-Fuzzy Inference Systems – was explored with excellent results. Also for signal analysis decomposition, spectral and pseudo-spectral techniques such as WT – Wavelet Transform and EMD – Empirical Mode Decomposition were investigated as adequately feature selection solution. EMD results allow developing an original technique for noise reduction correlated to the skull-electrode interface movements. This type of noise is present when the subject moves constantly, e.g., an automatic control system for wheel chair.

Bands decomposition, useful for ERD/ERS events detection, is based on EMD and MEMD – Multivariate EMD. For the last one, an original decomposition variation is proposed based on fuzzy inference systems.

The developed system shows a competitive performance and fulfills the needs of applications in conditions of daily life interior locations and natural subject movements.

Índice.

Capítulo 1.....	1
1 Introducción.....	1
1.1 Fundamentos del problema.....	2
1.2 Descripción del problema.....	3
1.3 Objetivo general.....	3
1.4 Objetivos particulares.....	4
1.5 Metodología.....	4
1.5.1 EEG señal no-estacionaria.....	4
1.5.2 Ruido y artefactos.....	5
1.6 Organización de la tesis.....	7
Capítulo 2.....	8
2 Fundamentos.....	8
2.1 Conceptos básicos de las señales EEG.....	8
2.2 Distribución espacial de los electrodos.....	9
2.3 Diferencias interindividuales e intraindividuales.....	10
2.4 Tipos de eventos cerebrales usados en interfaces cerebro-computadora.....	10
2.4.1 Potenciales evocados: P300.....	11
2.4.2 Actividades motoras: ERD/ERS.....	11
2.5 Trabajo relacionado: Métodos y algoritmos para procesamiento del EEG.....	13
2.6 Discusión: Comparación general de esta propuesta contra el típico procesamiento EEG.....	18
Capítulo 3.....	20
3 Procesamiento de señales EEG.....	20
3.1 EMD. Descomposición en modo empírico.....	20
3.2 Filtro Kalman.....	24
3.3 Lógica difusa.....	26
3.4 ANFIS.....	28
3.5 Discusión.....	30
Capítulo 4.....	31
4 Modelo propuesto de procesamiento, eliminación de ruido y artefactos para los eventos ERD/ERS.....	31
4.1 Descomposición de la señal EEG.....	31

4.2	Eliminación de ruido y artefactos.....	32
4.3	Línea base ERD/ERS.....	35
4.4	Clasificación.....	35
4.5	Evaluación y discusión.....	39
4.6	Descomposición multivariada mediante sistemas difusos.....	41
Capítulo 5.....		44
5	Módulo propuesto para la detección, eliminación de ruido y artefactos en los eventos ERD/ERS.....	44
5.1	Experimentos.....	44
5.2	Antecedentes.....	44
5.3	Montaje para estimulación y adquisición de la señal EEG.....	48
5.4	Protocolo experimental para eventos ERD/ERS.....	49
5.4.1	Primera etapa del experimento ERD/ERS.....	50
5.4.2	Segunda etapa del experimento ERD/ERS.....	51
5.4.3	Tercera etapa del experimento ERD/ERS.....	52
5.5	ERD/ERS Imaginario.....	53
5.6	Base de datos EEG PhysioBank para eventos ERD/ERS.....	55
5.6.1	Montaje de PhysioBank para estimulación y adquisición de la señal EEG.....	55
5.6.2	Protocolo experimental de PhysioBank para eventos ERD/ERS.....	55
5.7	Descomposición EMD/MEMD.....	56
5.8	Reducción de ruido.....	59
5.9	Discusión.....	61
5.10	Línea base.....	62
5.11	Discusión.....	64
5.12	Clasificación.....	66
5.13	Discusión y evaluación.....	70
5.14	Evaluación de descomposición MEMD difusa.....	72
5.15	Discusión.....	75
Capítulo 6.....		77
6.1	Conclusiones.....	77
6.2	Trabajo a futuro.....	78
6.3	Publicaciones realizadas a partir del presente trabajo de tesis doctoral.....	78

Referencias 80

Lista de Figuras.

<i>Figura 2.1 Esquema general BCI.....</i>	<i>9</i>
<i>Figura 2.2 Sistema 10-20 internacional (tomado de la referencia [14]).....</i>	<i>10</i>
<i>Figura 2.3 Onda P300 tomado de [13].....</i>	<i>11</i>
<i>Figura 2.4. Eventos ERD/ERS tomado de [13].....</i>	<i>12</i>
<i>Figura 3.1 Descomposición EMD: a) señal original, b) EMD aplicado a esta señal.....</i>	<i>23</i>
<i>Figura 3.2 Etapas y componentes de un sistema de control difuso.....</i>	<i>28</i>
<i>Figura 3.3. Arquitectura ANFIS para dos variables de entrada [49].....</i>	<i>30</i>
<i>Figura 4.1 Eliminación de ruido mediante EMD y correlación.....</i>	<i>32</i>
<i>Figura 4.2 Eliminación de ruido mediante MEMD y correlación.....</i>	<i>33</i>
<i>Figura 4.3. Vista general del sistema de inferencia detectando la desincronización de las bandas ERD.....</i>	<i>37</i>
<i>Figura 4.4. Vista general del sistema de inferencia detectando la sincronización de las bandas ERD.....</i>	<i>38</i>
<i>Figura 4.5. Esquema general propuesto.....</i>	<i>39</i>
<i>Figura 5.1. Estímulo para la activación de la onda P300.....</i>	<i>45</i>
<i>Figura 5.2. Detección de eventos P300.....</i>	<i>45</i>
<i>Figura 5.3. Entrenamiento de ANFIS como clasificador.....</i>	<i>47</i>
<i>Figura 5.4. Salida de ANFIS después de entrenamiento.....</i>	<i>47</i>
<i>Figura 5.5. Experimento P300.....</i>	<i>48</i>
<i>Figura 5.6 Electrodo disponibles en el sistema Emotiv (marcados en rojo).....</i>	<i>48</i>
<i>Figura 5.7. Componentes del sistema para generar eventos ERD/ERS.....</i>	<i>49</i>
<i>Figura 5.8. Interruptor de pie para envío de marcadores al equipo EEG.....</i>	<i>50</i>
<i>Figura 5.9. Ejemplo de comando y retroalimentación al usuario.....</i>	<i>50</i>
<i>Figura 5.10 Comandos derecha, izquierda y pie para generar eventos motrices.....</i>	<i>51</i>
<i>Figura 5.11. Movimiento mano derecha.....</i>	<i>51</i>
<i>Figura 5.12. Movimiento mano izquierda, segunda etapa del experimento.....</i>	<i>52</i>
<i>Figura 5.13. Movimiento sostenido de mano derecha con retroalimentación a los 4 segundos....</i>	<i>52</i>
<i>Figura 5.14. Movimiento sostenido de mano izquierda con retroalimentación a los 4 segundos.</i>	<i>53</i>
<i>Figura 5.15. Movimiento sostenido de pie con retroalimentación a los 4 segundos.....</i>	<i>53</i>
<i>Figura 5.16. Sujeto de prueba durante el experimento ERD/ERS.....</i>	<i>54</i>
<i>Figura 5.17. PhysioNet - Interface para el manejo de la base de datos PhysioBank.....</i>	<i>55</i>
<i>Figura 5.18. Electrodo disponibles en el equipo de PhysioBank.....</i>	<i>56</i>

<i>Figura 5.19</i>	<i>Descomposición EMD para FC6.....</i>	<i>57</i>
<i>Figura 5.20</i>	<i>Descomposición EMD para F4.....</i>	<i>57</i>
<i>Figura 5.21</i>	<i>Descomposición EMD para F8.....</i>	<i>58</i>
<i>Figura 5.22</i>	<i>Descomposición EMD para FC6.....</i>	<i>58</i>
<i>Figura 5.23</i>	<i>Descomposición MEMD para F4.....</i>	<i>59</i>
<i>Figura 5.24.</i>	<i>Descomposición MEMD para F8.....</i>	<i>59</i>
<i>Figura 5.25.</i>	<i>Descomposiciones MEMD (a-c) y EMD (d-f) para la secuencia de [6].....</i>	<i>60</i>
<i>Figura 5.26.</i>	<i>Descomposición MEMD incluyendo evento ERD/ERS.....</i>	<i>62</i>
<i>Figura 5.27.</i>	<i>Envolvente ejemplo obtenida mediante spline cúbica.....</i>	<i>63</i>
<i>Figura 5.28.</i>	<i>Variación de la potencia para las IMFs 1 a la 5.....</i>	<i>63</i>
<i>Figura 5.29.</i>	<i>Desincronización relativa a evento motriz.....</i>	<i>64</i>
<i>Figura 5.30.</i>	<i>Evento ERD/ERS ocurriendo en la muestra 350. Línea verde es la variación de la potencia. Línea azul es la salida del filtro Kalman para cada banda.....</i>	<i>65</i>
<i>Figura 5.31.</i>	<i>Gráfica de las reglas difusas para detección de desincronización.....</i>	<i>66</i>
<i>Figura 5.32.</i>	<i>Gráfica de gamma vs beta en la etapa de desincronización.....</i>	<i>67</i>
<i>Figura 5.33.</i>	<i>Gráfica de gamma vs alfa en la etapa de desincronización.....</i>	<i>67</i>
<i>Figura 5.34.</i>	<i>Gráfica de las reglas difusas para detección de sincronización.....</i>	<i>68</i>
<i>Figura 5.35.</i>	<i>Gráfica de desync vs gamma en la etapa de desincronización.....</i>	<i>68</i>
<i>Figura 5.36.</i>	<i>Gráfica de desync vs beta en la etapa de desincronización.....</i>	<i>69</i>
<i>Figura 5.37.</i>	<i>Gráfica de desync vs alfa en la etapa de desincronización.....</i>	<i>69</i>
<i>Figura 5.38.</i>	<i>Gráfica ROC de MEMD (en línea roja) y transformada wavelet (azul).....</i>	<i>70</i>
<i>Figura 5.39.</i>	<i>Sistema de inferencia difuso para descomposiciones multivariadas.....</i>	<i>72</i>
<i>Figura 5.40.</i>	<i>Salida del sistema difuso para las 3 entradas artificiales.....</i>	<i>73</i>
<i>Figura 5.41.</i>	<i>Envolventes para máximos (izquierda) y mínimos (derecha) de la señal.....</i>	<i>73</i>
<i>Figura 5.42.</i>	<i>Primer intento fallido de obtención de IMF mediante sifting por lo que se necesitará un ciclo adicional.....</i>	<i>73</i>
<i>Figura 5.43.</i>	<i>IMF 1 para la señal de entrada 3.....</i>	<i>74</i>
<i>Figura 5.44.</i>	<i>MEMD basado en sistema difuso propuesto (izquierda) y en proyecciones sobre hiperesferas (derecha).....</i>	<i>75</i>

Lista de Tablas.

<i>Tabla 2.1. Métodos comúnmente usados para pre-procesamiento.....</i>	<i>15</i>
<i>Tabla 2.2. Métodos comúnmente usados para selección/reducción de características.....</i>	<i>16</i>
<i>Tabla 2.3. Métodos comúnmente usados para clasificación.....</i>	<i>17</i>
<i>Tabla 4.1 Reglas para el sistema de inferencia 1, donde, L = low, A=average, H=high, XH=extra-high, x=dont care.....</i>	<i>38</i>
<i>Tabla 4.2 Reglas para el sistema de inferencia 2, donde, L = low, A=average, H=high, XH=extra-high, x=dont care.....</i>	<i>38</i>
<i>Tabla 4.3 Reglas para el sistema de inferencia MEMD, donde, L = low, A=average, H=high.</i>	<i>44</i>
<i>Tabla 5.1 Valores de correlación para elección de wavelet madre.....</i>	<i>46</i>
<i>Tabla 5.2 Valores de correlación y el aumento en detección de ruido usando MEMD.....</i>	<i>60</i>
<i>Tabla 5.3 La primera columna contiene el número de sujeto en la base de datos de PhysioBank. La segunda columna contiene el desempeño de [88] y la tercera columna contiene el desempeño de esta propuesta.....</i>	<i>71</i>
<i>Tabla 5.4 Comparación entre MEMD por hiperesferas y MEMD difuso.....</i>	<i>74</i>

Capítulo 1.

1 Introducción.

El concepto interface-cerebro-computadora o BCI por sus siglas en inglés, se refiere genéricamente a aquellas aplicaciones orientadas a la realización de alguna determinada actividad en una unidad de cómputo, accionada por la voluntad del usuario y detectada desde sus señales cerebrales. En décadas recientes, a la par con la disponibilidad de nuevos recursos computacionales y tecnológicos en general, se han estado realizando en diversas partes del mundo, estudios e investigaciones sobre sistemas BCI, orientadas al desarrollo de tecnología, técnicas de procesamiento de señales, metodologías adecuadas, etc., con base en el análisis de las señales de electroencefalografía (EEG) generadas por un individuo. Dichas señales son capturadas en forma no-invasiva por medio de electrodos colocados en la superficie exterior de la corteza cerebral. Si bien existen alternativas adicionales de tipo invasivo, tal como las señales de ElectroCortigrafía ECoG [1], o electrodos implantados en zonas específicas del cerebro como en el caso de experimentos con visión por medio de electrodos insertados en la corteza visual primaria [2], resulta evidente el nivel de complicaciones inherentes a estudios de este tipo [3]. Por tal motivo, la investigación descrita en la presente propuesta de tesis doctoral, se centra en el análisis de señales EEG obtenidas por medio de electrodos superficiales con técnicas no invasivas.

En la actualidad los sistemas basados en BCI constituyen un área abierta en materia de investigación y desarrollo tecnológico, y no resulta difícil anticipar una gran variedad de aplicaciones que redunden en una mejora en la calidad de vida del ser humano. De manera específica, se puede enfatizar el nivel de relevancia que estos sistemas adquieren, por ejemplo, al incidir positivamente en la vida de personas con trastornos motores severos producto de enfermedades graves tales como la Esclerosis Múltiple, Esclerosis Lateral Amiotrófica (ALS), y otras distrofias neuromusculares, para quienes las formas de contacto hacia el mundo exterior se ven drásticamente reducidas [4].

El presente trabajo de tesis se centra en el estudio e investigación de técnicas de procesamiento de señales para la extracción de características y clasificación de la actividad cerebral en la modalidad de potenciales evocados asociados con actividad motora, específicamente: detección del fenómeno ERD/ERS (Event Related Desynchronization/ Synchronization) y detección de la onda P300 [5]. El análisis de las señales está basado en técnicas espectrales que utilizan a la transformada wavelet [5] y descomposición modal empírico (EMD) [6], así como sistemas adaptivos neurodifusos [5] y filtrado Kalman [6]. Se incorporan técnicas relacionadas con el tratamiento de ruido por diversos artefactos, y se presenta un esquema original de

removimiento de ruido correlacionado originado por movimiento de electrodos basado en descomposición modal empírica. Para los experimentos de reconocimiento se utilizan técnicas de clasificación basadas en distancias y modelos adaptivos neurodifusos (ANFIS) [5].

1.1 Fundamentos del problema.

La electroencefalografía consiste en el registro de las señales eléctricas producidas por el cerebro. Estas señales cerebrales se obtienen mediante electrodos colocados sobre el cuero cabelludo. Dependiendo del tipo de electrodos podría ser necesario el uso de gel o solución salina para mejorar la conducción en la interface electrodo-piel. La obtención de las señales EEG es mediante medición, amplificación y registro de las diferentes fluctuaciones eléctricas como función del tiempo y debido a esto las señales registradas tienen cierto ancho de banda. Para la mayoría de los dispositivos se requiere una respuesta en frecuencia de 0.16Hz hasta 100Hz. En algunos casos se requiere una respuesta en frecuencias muy bajas llegando a DC. La actividad eléctrica generada por la corteza cerebral no transita solamente por el área cercana de la superficie de la cabeza en una forma altamente enfocada sino que la corriente eléctrica que fluye desde la corteza se distribuye conforme va recorriendo las diferentes capas de resistencia eléctrica. El sistema de adquisición EEG debe proveer de una representación de la distribución espacial de los potenciales sobre la superficie y debe estar compuesto de varios canales con características similares (típicamente 8-256 electrodos). Aún cuando las señales cerebrales tienen un contenido espectral con energía distribuida, es decir, las ondas no se emiten en una sola banda de frecuencia, se ha encontrado que determinadas funciones provocan reacciones o activaciones más pronunciadas en un determinado rango [7]. De esta manera, se encuentra en la literatura la siguiente clasificación:

Beta. Su frecuencia se encuentra entre 13 Hz y 30 Hz y usualmente tiene un voltaje entre 5 y 30 μ V. La onda beta está asociada con el pensamiento activo, atención o enfoque en el mundo externo o para resolver problemas. Con actividad mental intensa se pueden alcanzar hasta cerca de los 50 Hz.

Alfa. Esta banda está localizada entre 8 Hz y 13 Hz con una amplitud típica entre 30 y 50 μ V. Estas ondas indican desde atención relajada hasta desatención y son prominentes sobre el área occipital y frontal. Alfa es una de las bandas más prominentes en toda la actividad cerebral e indica ausencia de pensamiento. La amplitud de esta onda es disminuida o eliminada abriendo los ojos, por ansiedad, concentración mental o sonidos no familiares.

Theta. Localizada entre los 4 Hz a 7 Hz con amplitud mayor a $20\mu\text{V}$. Es producto de estrés emocional especialmente frustración o decepción. También está asociada a la inspiración creativa y meditación.

Delta. Se encuentra en el rango de 0.5 Hz a 4 Hz con una amplitud variable. delta está asociada con el sueño profundo o en el estado de despertar. Se confunde fácilmente con artefactos provenientes de los músculos del cuello y mandíbula aunque delta es de mucha menor amplitud y adicionalmente es atenuado al pasar a través del cráneo.

Gamma. Esta banda está formada por señales de los 35Hz hasta los 200Hz-400Hz. Se ha concluido que esta banda refleja el mecanismo de conciencia.

Mu. Esta banda está en el rango de 8 Hz a 12 Hz y está asociada con actividades motoras y por lo tanto su amplitud pico es mayor sobre la corteza motora. Disminuye con el movimiento o la intención de movimiento. La diferencia con la onda alfa es que ésta se registra sobre la corteza occipital. Una característica importante es que las personas pueden aprender a cambiar la amplitud de estas ondas mediante entrenamiento, nivel de atención o esfuerzo mental.

Infrabaja. Las oscilaciones de muy baja frecuencia se encuentran en el rango de 0.02 Hz a 0.2 Hz con una amplitud de decenas de microvolts. Se observa durante el sueño durante los movimientos REM y en neonatos pretérmino relacionados con falta de maduración cerebral.

Ultrarápida. Se encuentra en el rango de 400 Hz hasta 1000 Hz. Relacionada con potenciales evocados sensoriales.

Las bandas alfa, mu y gamma son la principal fuente de información para la detección de eventos musculares y/o musculares-imaginarios.

1.2 Descripción del problema.

El enfoque principal es la detección de eventos musculares mediante técnicas no invasivas, lo cual incrementa la cantidad de ruido en la adquisición de las señales EEG debido a que se realiza mediante electrodos en contacto con el cuero cabelludo. El ruido provocado por el movimiento de la cabeza podría enmascarar completamente las señales cerebrales. En términos generales las señales EEG son consideradas como no-estacionarias, lo cual podría dificultar o limitar su procesamiento adecuado con herramientas como las transformadas a frecuencia/escala.

1.3 Objetivo general

El objetivo primordial es la detección de eventos musculares o musculares imaginarios de acuerdo al fenómeno que produce: ERD/ERS. Por lo tanto, el fenómeno de

desincronización/sincronización es la base del sistema BCI propuesto aún para equipos de bajo costo.

1.4 Objetivos particulares.

- Procesamiento de las señales EEG tomando en cuenta que estas señales son consideradas como no-estacionarias en la mayoría de los casos.
- Como elemento primordial se propone la reducción de ruido provocado por el movimiento de la cabeza.
- Detección del fenómeno ERD/ERS producto de eventos motrices como base para un sistema BCI.
- Detección de eventos P300 producto de eventos sorprendidos.
- Diseño de experimentos y protocolos adecuados para producir fenómenos ERD/ERS y P300.

1.5 Metodología.

Se ha encontrado que el uso de bases de datos fisiológicas es bastante común como medio de obtención de datos EEG. Se tiene que tomar en cuenta la descripción del experimento, condiciones en las cuales fueron tomados los datos y características de los sujetos bajo prueba. Adicional a estas bases de datos, el diseño y aplicación de experimentos propios aplicados a sujetos determinados es otra fuente principal para la obtención de datos EEG. Con estos datos es posible el procesamiento para la detección de movimientos musculares o imaginarios-musculares. El uso de datos propios y de bases de datos permite establecer hipótesis y conclusiones con mayor generalidad del método propuesto.

Se han identificado dos problemas principales para el uso del EEG como base las interfaces cerebro-computadora: la característica no-estacionaria de las señales EEG y el ruido provocado por el movimiento del usuario y por lo tanto del movimiento en la interfaz electrodo-piel.

1.5.1 EEG señal no-estacionaria.

La característica no-estacionaria de las señales EEG es bien conocida ya que sus parámetros estadísticos varían en el tiempo. Se considera que existen segmentos quasi-estacionarios de aproximadamente 0.25s o de intervalos de hasta 2 segundos [7]. La causa principal de que las señales EEG sean no estacionarias se debe a la influencia de

diversas estructuras cerebrales ubicadas en cada una de las capas que conforman el cerebro. Estas estructuras se activan de acuerdo al funcionamiento interno del cerebro y cada una transmite con diferente intensidad y variación. Por lo tanto, si la fuente que produce una señal cambia con el tiempo, la señal producida es considerada como no-estacionaria. En el estudio del EEG se debe definir los valores tiempo-escala en todo el proceso de análisis pero para el caso del EEG estos valores cambian dinámicamente en el tiempo. La característica no-estacionaria del EEG no siempre se puede percibir fácilmente pero en ocasiones se observan transientes, picos abruptos, etc.

Comentarios y evaluación.

Para resolver el problema de que el EEG es no-estacionario se han propuesto varias soluciones que en términos generales es la segmentación de la señal EEG en ventanas de análisis. Estas ventanas garantizan que durante ese intervalo el EEG se comportará como una señal de características estacionarias. El tamaño de la ventana puede ser fijo o variable de acuerdo a ciertos parámetros dependientes del algoritmo o procesamiento que se utilice.

En la mayoría de los casos la señal EEG es segmentada en ventanas individuales del mismo tamaño. Para cada una de las ventanas se obtiene un conjunto de características como valores espectrales, por ejemplo, considerando la señal como estacionaria. Posteriormente esta información se usa como entrada a módulos de clasificación. Por último, posiblemente sea necesario eliminar segmentos pertenecientes a la misma clase que se encuentren adyacentes debido a semejanzas en los valores característicos de estas ventanas. Para el caso en el cual se varíe el tamaño de la ventana se seguirán los mismos pasos que para ventana fija. En cuanto a la definición del tamaño de ventana se usan diversos parámetros auto-regresivos, estadísticos, etc. [7]. Algunos de estos métodos cometen el error de que los parámetros utilizados para definición de tamaño de ventana se calculan como si la señal fuera estacionaria cayendo en una contradicción.

Para resolver el problema de la propiedad no-estacionaria de las señales EEG, la cual restringe el tamaño de la ventana de análisis o requiere de cálculos adicionales para definir este tamaño, se propone el uso de descomposiciones de tipo empírico. Estas descomposiciones son consideradas de alguna forma adaptivas y en la mayoría de veces no se requiere conocimiento a priori de la señal de entrada, que en este caso, es el EEG.

1.5.2 Ruido y artefactos.

Existen diversas fuentes de contaminación que se presentan en el momento en que el sistema de adquisición registra las señales EEG. Entre las principales fuentes de contaminación se encuentran señales bioeléctricas como las electro-oculares,

mioeléctricas, cardíacas; ruido electromagnético; ruido en el amplificador; ruido en la conversión digital; artefactos en el electrodo. Cuando un electrodo es colocado en una solución conductora y no hay corriente fluyendo existe una diferencia de potencial entre el electrodo y la solución. Este potencial es provocado por la diferencia entre la carga eléctrica producto del flujo de iones desde la superficie metálica del electrodo hacia la solución y la carga producto del flujo de iones metálicos desde la solución hacia la superficie metálica de los electrodos. Un exceso de carga en la solución causa la formación de una doble capa eléctrica y de esta forma se establece un equilibrio. El valor del potencial del electrodo está en función del material del electrodo y la temperatura, en el rango de mili-volts. Este potencial generado en los electrodos, el cual no puede ser eliminado, provoca un offset de voltaje en DC a la entrada del amplificador para las señales EEG y puede ser tan grande o más en comparación a la magnitud de la actividad eléctrica proveniente del cerebro.

El movimiento de un electrodo en relación a la superficie de la cabeza causa cambios en la interface entre el metal y la solución lo que altera el offset de voltaje en DC y por lo tanto produce un artefacto en las señales EEG. En la mayoría de los sistemas basados en EEG y aún en el análisis clínico, el ruido y los artefactos producidos por el movimiento del cuerpo y cabeza del sujeto bajo prueba son algunos de los problemas que más afectan la correcta adquisición, procesamiento y detección de eventos cerebrales de interés.

Comentarios y evaluación.

Existen muchos métodos para la eliminación del ruido y artefactos de la señal EEG. Entre las más exitosas se encuentran ICA (Independent Component Analysis), basadas en análisis mediante wavelet, transformada Hilbert-Huang. El análisis de componentes independientes ha sido ampliamente usado para la eliminación de artefactos de la señal EEG, mejoramiento de la relación señal a ruido y/o selección óptima de electrodos [7][8]. ICA tiene algunas desventajas como la posible corrupción del espectro [9], la localización de componentes no necesariamente en orden específico por lo que dificulta su implementación en sistemas de tiempo real [10]. La transformada discreta wavelet (DWT) y la transformada Hilbert-Huang (HHT) ofrecen una extracción eficiente de características de la señal EEG. Sin embargo, se ha reportado que la HHT ofrece una representación tiempo-frecuencia más precisa debido a su base adaptable a los datos de entrada [11][12]. Además, antes del procesamiento con DWT se debe elegir una wavelet adecuada y valores límite como tamaño de ventana de acuerdo a los datos de entrada.

Adicional al uso de una descomposición del tipo EMD (Empirical Mode Decomposition), se propone un método para eliminación de ruido y artefactos provocado por el movimiento de cuerpo y cabeza mediante la comparación de información proveniente de diferentes electrodos ubicados lo más lejano entre sí en la medida que el sistema de adquisición lo permita. La forma más común de detección de cambios en cada una de las bandas de frecuencia es mediante promediado por ventanas

[3]. Esto puede ser mejorado mediante la implementación de un filtro Kalman de primer orden. Esto permite mejorar la detección de cambios en la potencia para cada una de las bandas y además de proveer un elemento adicional de eliminación de ruido no proveniente de los cambios propios de los eventos musculares o musculares-imaginarios.

1.6 Organización de la tesis.

El trabajo reportado en esta tesis está organizado de la siguiente manera: Capítulo 1 contiene una breve explicación de las señales EEG, su aplicación y la importancia de su correcto procesamiento como base para construir una interfaz cerebro-computadora. Algunos fundamentos de EEG son descritos en el capítulo 2, así como los eventos musculares como base para las interfaces cerebro-computadora. En el capítulo 3 se proporciona la teoría que servirá como soporte para entender algunos conceptos y términos que se manejarán posteriormente en el presente documento. El capítulo 4 presenta el método propuesto para la detección de eventos musculares o mental-imaginarios como base para las interfaces cerebro-computadora. Se incluyen las soluciones propuestas a la característica no-estacionaria de las señales EEG, eliminación de ruido y artefactos y obtención de la variación en la potencia en cada una de las bandas de frecuencia de interés. El capítulo 5 muestra los resultados de la aplicación del método propuesto sobre datos provenientes de experimentos propios y de base de datos fisiológicas. Por último en el capítulo 6 se presentan las conclusiones y trabajo a futuro.

Capítulo 2

2 Fundamentos.

2.1 Conceptos básicos de las señales EEG.

Las señales EEG consisten de la suma de la actividad eléctrica de un conjunto de neuronas. Las neuronas son células excitables con propiedades de característica intrínsecamente eléctrica y su actividad produce campos eléctricos y magnéticos. Estos campos pueden ser registrados por medio de electrodos a relativamente corta distancias de las fuentes (EEG local o potenciales de campo locales LFP) o de la superficie cortical (electrocorticograma ECoG) o a larga distancia aún sobre el cuero cabelludo, es decir, el EEG.

La actividad eléctrica generada por la corteza cerebral no transita solamente por el área cercana de la superficie de la cabeza en una forma altamente enfocada sino que la corriente eléctrica que fluye desde la corteza se distribuye conforme va recorriendo las diferentes capas de resistencia eléctrica. Estas capas son parénquima cerebral, fluido cerebro-espinal CSF, dura, cráneo y cuero cabelludo.

Las afirmaciones del párrafo anterior dan como resultado una de las reglas fundamentales en la interpretación del EEG: *la amplitud de la señal EEG es directamente proporcional a la distribución de corriente en la superficie de la cabeza y por lo tanto una forma de onda que es solamente detectada por un solo electrodo es tomada, inmediatamente, como artefacto hasta que se pruebe lo contrario.*

De manera muy general, el problema por resolver en aplicaciones de interfaz cerebro-computadora consiste en obtener un conjunto de señales de EEG obtenidas a partir de mediciones en el cuero cabelludo con electrodos especiales, y a partir de dicho conjunto realizar una serie de operaciones numéricas orientadas a reconocer o clasificar las señales hasta obtener una respuesta que represente la acción deseada por la persona. En el proceso involucrado en las interfaces cerebro-computadora se pueden distinguir varias etapas, que listadas en orden son: sensado, amplificación y filtrado de las señales, pre-procesado, extracción de características, selección de estas características o reducción de la dimensionalidad en su caso, reconocimiento o clasificación de características y procesamiento final, el cual incluye la traducción de la respuesta obtenida hacia señales eléctricas adecuadas a las interfaces de control de determinado dispositivo, como puede ser una silla de ruedas eléctrica o dispositivos de interacción con la computadora como el 'mouse'. En la figura 2.1 se muestra los diferentes bloques de un sistema BCI basado en EEG.

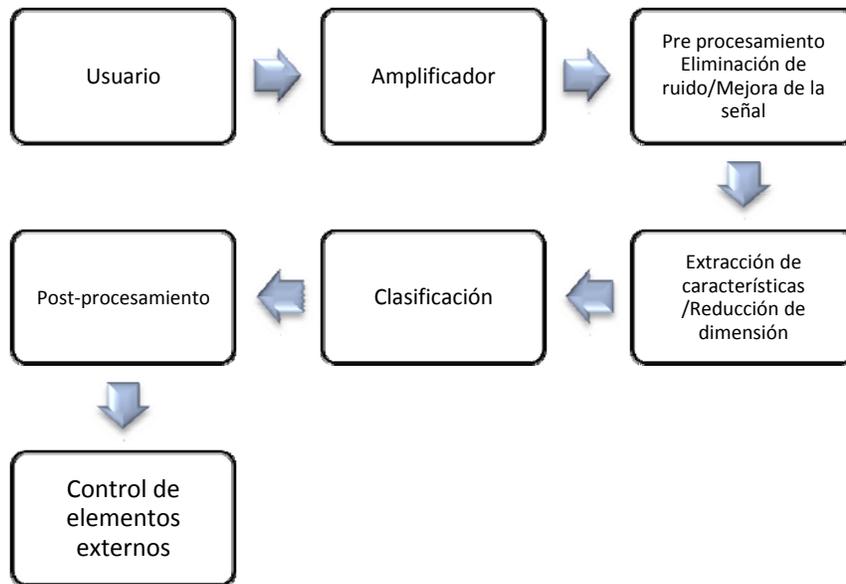


Figura 2.1 Esquema general BCI.

2.2 Distribución espacial de los electrodos.

Está documentado que es necesario asegurar al menos una área cortical de 6 cm^2 para obtener un potencial bien definido en la superficie de la cabeza [13], como en el caso de las señales producto de la epilepsia que ocupan un área de 10 a 20 cm^2 de superficie. Se estima que para el sistema 10-20 internacional, con distancia entre electrodos de aproximadamente 4.5 cm , exista un error de muestreo de cerca de 6% . En el caso del sistema expandido 10-20 internacional, con una distancia inter-electrodo de aproximadamente 2.5 cm , se considera que el error no afecta la práctica clínica. Sin embargo, existe una actualización a esta versión con distancias entre electrodos de 2 cm . No es necesario utilizar todos los electrodos siempre que se respete la distribución en el área de interés. La figura 2.2 muestra la distribución de electrodos correspondiente al sistema extendido internacional 10-20, que es el más frecuentemente utilizado en el contexto de sistemas BCI. Las letras F, T, P, O, etiquetando a cada uno de los electrodos se refieren respectivamente a los lóbulos frontal, temporal, parietal y occipital. La letra C se utiliza para indicar los electrodos ubicados en la parte central del cráneo siguiendo la orientación de los lóbulos. Los números pares designan a los electrodos colocados sobre el hemisferio derecho y los números impares sobre el hemisferio izquierdo. La letra z indica la línea media del cráneo de acuerdo a la orientación numérica. Con la letra A se identifican los electrodos sobre el lóbulo de la oreja. La letra Fp designa los electrodos cercanos a la frente en el polar izquierdo y derecho. Pg se utiliza para etiquetar a los electrodos en el área nasofaríngea.

- Respuesta a actividades mentales complejas produciendo distribuciones de patrones EEG sobre varias partes del cerebro.
- Respuesta a actividades motoras. Se presentan sincronizaciones/desincronizaciones en varias bandas de frecuencia como producto de esta actividad. Este tipo de fenómenos serán usados para la interfaz cerebro-computadora propuesta. Por lo tanto, se describe en forma más detallada en la sección 2.4.2.

2.4.1 Potenciales evocados: P300.

La onda P300 presenta un pico típico en aproximadamente 300ms después de haber recibido un estímulo externo aunque dependiendo principalmente de la edad puede llegar hasta los 1000ms (figura 2.3). P300 se mide con mayor amplitud cerca de la zona central alrededor del electrodo Cz. La duración común de este pico cuasi-triangular es de aproximadamente 150 ms a 200 ms con amplitud máxima menor a $10\mu\text{V}$. La onda P300 presenta una baja razón señal a ruido por lo que deberá ser pre-procesada mediante promedio por ventanas durante múltiples respuestas o mediante el uso de algoritmos como ICA [5]. Debido a la naturaleza propia del P300, los estímulos deberán presentarse en una secuencia aleatoria en el tiempo y de manera poco frecuente o sorpresiva al usuario. Por esta razón P300 es considerado dentro del grupo ERP (Event Related Potencial) Potencial Relacionado a Evento.

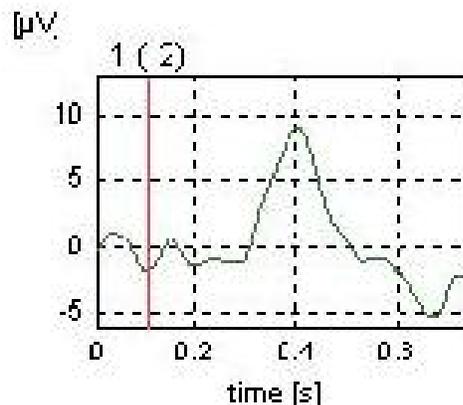


Figura 2.3 Onda P300 tomado de [13]

2.4.2 Actividades motoras: ERD/ERS.

La desincronización EEG o, inicialmente conocida por bloqueo de banda alfa resultado del procesamiento sensorial o acciones motoras, fue reportada por primera vez por Berger (1930), Jasper y Andrew (1938), and Jasper y Penfield (1949) [13]. Esta desincronización se refleja en el decrecimiento de la actividad oscilatoria relacionada internamente o externamente a un evento no sorpresa (paced event) y es conocida como desincronización relacionada a evento (ERD Event Related Desynchronization).

El fenómeno opuesto, es decir, aumento en la actividad oscilatoria es conocido como sincronización relacionada a evento (ERS Event Related Synchronization).

Adicionalmente a las oscilaciones en la banda alfa, se presentan variaciones en la banda beta inferior y en la banda gamma (alrededor de 40 Hz). Las ERD y ERS se encuentran localizadas en áreas bien definidas, con comportamiento fásico y con composición espectral muy conocida. Por ejemplo, la existencia de al menos tres bandas de frecuencia en el mismo electrodo sobre el área sensor-motora de la mano durante el movimiento de un dedo puede ser observada en la figura 2.4.

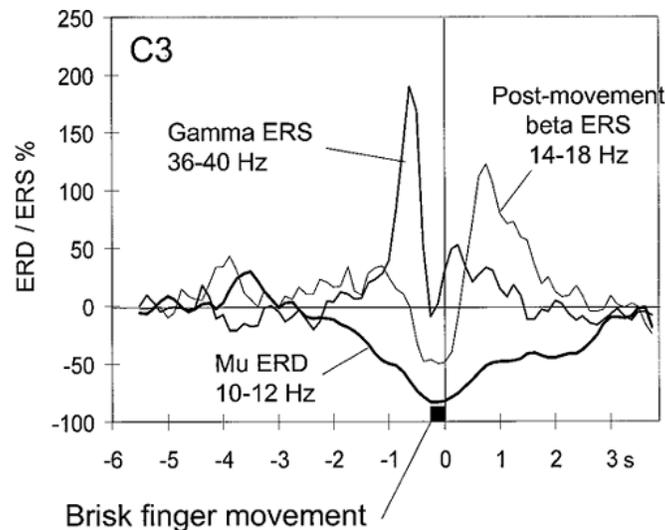


Figura 2.4. Eventos ERD/ERS tomado de [13]

Además de la desincronización mu (10 Hz – 12 Hz) y una desincronización posterior al movimiento en la banda beta (14 Hz – 18 hz), se presenta una oscilación en la banda gamma (36 Hz – 40 Hz). La banda gamma alcanza un máximo poco antes de que el movimiento suceda, mientras que la sincronización en beta tiene su máximo después del movimiento muscular. En contraste a la banda alfa, la banda gamma es representativa de una etapa de procesamiento de información. Un prerequisite para que se presente el pico en gamma es, en la mayoría de los casos, la desincronización de la banda alfa.

La cuantificación del ERD/ERS se basa en la repetición del mismo experimento consistiendo en un evento que dispare el EEG, tomando en cuenta una fracción de segundo antes y algunos segundos después del evento. El evento puede incluir estimulación no sorpresiva (acústica, visual o sensorial). De acuerdo a Da Silva [13] se deben seguir las etapas de a) filtrado pasabanda de cada evento, b) calcular la potencia de las señales, c) promediar todos los intentos y d) promediar sobre un número pequeño de valores de potencia para reducir la varianza. La potencia absoluta es convertida en porcentaje de la potencia definiendo la potencia dentro de un intervalo de

referencia como el 100%. Por convención, un decremento en potencia corresponde a un ERD y un incremento en potencia a un ERS.

2.5 Trabajo relacionado: Métodos y algoritmos para procesamiento del EEG.

Existe en la literatura una gran cantidad de enfoques que buscan obtener una representación adecuada de las señales cerebrales y que permitan realizar su análisis, detección o clasificación. En dicho conjunto de enfoques y técnicas se pueden distinguir tres grandes grupos [13][15][16]: Métodos no paramétricos, paramétricos y una combinación de los anteriores.

- Métodos no paramétricos. Consideran las propiedades estadísticas de la señal EEG como producto de un proceso aleatorio. Caracteriza las señales mediante distribuciones de probabilidad y sus momentos, por la función de auto-correlación o por su espectro en potencia, o mediante la distribución de intervalos entre niveles de cruce. En todos los casos, el EEG es considerado como un proceso estocástico y en la mayoría de los casos sin una generación de modelo. Entre estos métodos se encuentran las funciones de correlación, basados en potencia por descomposición espectral, etc.
- Métodos paramétricos. Igualmente usados para analizar señales EEG pero en este caso la señal EEG es generada por un modelo específico. Por ejemplo, asume que el EEG es la salida de un filtro lineal, además, suponiendo que a la entrada se tiene ruido blanco es posible la caracterización del filtro por un conjunto de coeficientes o parámetros. Algunos de importancia mencionar son los filtros AR/ARMA y filtrado Kalman.

Existe una gran variedad de algoritmos y métodos aplicados en literatura, buscando que se cumplan las condiciones para cada uno de los módulos de la figura 2.1. En las tabla 2.1-2.3 se enlistan estos métodos que son comúnmente usados en los bloques de pre-procesamiento, selección/reducción de características y clasificación.

Tabla 2.1. Métodos comúnmente usados para pre-procesamiento

Common average referencing (CAR).	Subtrae la señal promedio de todos los canales adyacentes sobre cada electrodo. No es útil si no se usa una distribución uniforme de electrodos [17][18].
Surface Laplacian (SL).	Aumenta la resolución espacial del EEG usando los electrodos disponibles. Pobre respuesta al incrementarse el ruido [17][19][20].
Independent	Encuentra las fuentes independientes usando las señales de los

component analysis (ICA).	electrodos. Es necesario tener una buena resolución espacial de lo contrario resulta de poca utilidad [17][21].
Common spatial patterns (CSP).	Filtro espacial que construye un nuevo espacio que minimiza la varianza de las señales en los electrodos. Es muy sensible a los outliers [17][22][23].
Principal component analysis (PCA).	Encuentra las componentes principales o no correlacionadas de un conjunto de datos usando una transformación ortogonal. Utilizado para reducir la dimensionalidad de los datos [17][24].
CSP/PCA.	Usa una combinación de CSP y PCA [17].
Singular value decomposition (SVD).	Consiste en la factorización o descomposición de una matriz de datos usado para reducción de dimensionalidad [17].
Common spatio-spatial patterns (CSSP).	Método similar a CSP pero se construye un filtro para cada canal con un retraso establecido entre si [17][25].
Frequency normalization (Freq-Norm).	Se normaliza la frecuencia de las amplitudes de acuerdo a valores estadísticos de la señal como la varianza [26][17].
Local averaging technique (LAT).	Usa el promedio de todos los canales adyacentes para filtrar ruido sobre la señal de un electrodo. No es útil si no se usa una distribución uniforme de electrodos [17].
Robust Kalman filtering.	El filtro está diseñado para eliminar cambios en la varianza del ruido del proceso y del ruido en la medición [27].
Common spatial subspace decomposition.	Diseña filtros espaciales que llevan a la estimación de las fuentes independientes relacionadas a cierto evento mental eliminando el ruido común [17][28][29].
Wiener filtering.	Filtro para eliminación de ruido mediante la autocorrelación y la correlación cruzada de la señal y el ruido [17].
Sparse component analysis.	Utiliza elementos de PCA pero cambiando la fórmula para el cálculo de la varianza total de los datos [30].

Maximum noise fraction (MNF).	Básicamente consiste de dos transformaciones PCA en cascada para eliminación de ruido y reducción de dimensionalidad [31].
Spike detection methods.	Consiste en aplicar un pre-énfasis a la señal, como el valor absoluto, para después aplicar un umbral de activación [17][32].
Neuron ranking methods.	Elimina la mayor cantidad de nodos en la red neural propuesta mediante análisis de sensibilidad [17].

Tabla 2.2. Métodos comúnmente usados para selección/reducción de características

Genetic algorithm (GA)	Es básicamente una búsqueda heurística que intenta imitar el proceso de evolución natural. En general, este método consiste de una inicialización, selección, reproducción y terminación [31][33]
Principal component analysis (PCA)	Encuentra las componentes principales o no correlacionadas de un conjunto de datos usando una transformación ortogonal. Utilizado para la selección de características [27][26].
Distinctive sensitive learning vector quantization (DSLQ)	Se basa en una función de distancia pero empleando pesos adaptivos donde la influencia de características que contribuyen a un error en la etapa de clasificación es reducida [34][17].
Sequential forward feature selection (SFFS)	Comenzando desde el conjunto vacío agrega secuencialmente la característica que maximiza alguna función objetivo tomando en cuenta las características que ya ha seleccionado [17][35].
Grid search method	Considera n puntos de búsqueda sobre una función de optimización para formar una malla donde se encuentra un punto óptimo o de interés [36].
Relief method	Asigna un peso a cada característica mediante iteraciones usando un valor umbral o criterio establecido [17].
Recursive feature/channel elimination	De acuerdo a la variación de una función de costo de un conjunto de entrenamiento se pueden ir eliminando características o asignándole un peso de cero [17][37].

(RFE)	
Linear discriminant analysis (LDA)	Su objetivo es llevar a cabo reducción de dimensionalidad tratando de preservar lo más posible la información para establecer el discriminante de clase o clases mediante la proyección de un punto multidimensional sobre un vector de pesos [17].
Fisher discriminant analysis (dimensionality reduction/feature selection)	Método similar a LDA, maximiza una función de la diferencia entre las medias normalizada por una medida de dispersión intraclase [17][38][39].
Zero-norm optimization	Intenta resolver el problema de la combinación de elementos no cero en el vector de pesos proyectado en los datos de entrada y así seleccionar las características más importantes de la señal de entrada [17].
Orthogonal least square	Utiliza el método de mínimos cuadrados para la identificación del sistema pero con un proceso de ortogonalización tipo Gram-Schmidt [40].
Spectral transformations	Se obtiene el vector de características mediante transformación en frecuencia o escala: FFT, STFT, DWT, Windowed DCT [41][42][43][44].

Tabla 2.3. Métodos comúnmente usados para clasificación.

Gaussian SVM	Usa un hiperplano como discriminante, tratando de maximizar la distancia al punto de entrenamiento más cercano. El límite de decisión entre clases puede ser una recta o crear límites no lineales mapeando a otro espacio de dimensión más alta usando un kernel. En este caso el kernel es una función gaussiana o RBF [45][46].
LDA	Básicamente maximiza la función de la diferencia entre las medias. Usa hiperplanos para separar las clases considerando con distribución normal y matriz de covarianza igual a la identidad [45][46][47].

HMM	Se dice que el modelo oculto de Markov es un autómata que calcula la probabilidad de observar una secuencia determinada de vectores de características. Método muy adecuado para modelado de series de tiempo [45][48].
MLP / Boosting with MLPs	Red neuronal tipo perceptrón formada de varias capas generalmente: capa de entrada, una o varias escondidas y capa de salida. Existen múltiples conexiones entre estas capas. La capa de salida determina la clase a la que pertenece el vector de características de entrada [49][50][51].
FIR NN	Las conexiones a los nodos de la red neuronal son modelados como si fuera un filtro FIR, por la misma razón no tiene retropropagación [45].
Bayes quadratic integrated	Este método aplica la regla de máximo a posteriori de Bayes para conocer la probabilidad de que determinado vector característico pertenezca a una determinada clase. Asume una distribución normal de los datos por lo que el umbral de decisión es una función cuadrática [52][53].
Mahalanobis distance	Generalización de la distancia euclidiana pero tomando en consideración la dispersión de los datos mediante el uso de la matriz de covarianza [45][54].
K-Nearest Neighbour	Técnica donde una instancia es clasificada basada en la muestra más cercana de las muestras de entrenamiento presentes en los vectores de características [55].
Fuzzy Sets	Toma valores difusos o imprecisos en la entrada y entrega valores precisos en la salida [55].

Se puede notar en las tablas 2.1-2.3 que en algunos casos los mismos métodos son usados para diferentes etapas del procesamiento del EEG dependiendo de la intención del investigador. Se pueden presentar variaciones de un mismo método o combinaciones entre ellos. Igualmente existen combinación de clasificadores usando diferentes tipos de estrategias [45] como *boosting* (clasificadores en cascada), *voting* (la mayoría de los clasificadores deciden la clase), *stacking* (parecido a *voting* pero con un clasificador adicional a la salida).

2.6 Discusión: Comparación general de esta propuesta contra el típico procesamiento EEG.

El procesamiento de la señal EEG se lleva a cabo mediante la construcción de módulos con forma general establecida en la figura 2.1. Se le dará más importancia al pre-procesamiento y selección de características a diferencia de la mayoría de las propuestas debido a que el ruido y artefactos pueden tener las mismas propiedades, como la misma banda de frecuencia, que los cambios producidos por los eventos motrices y/o motrices imaginarios. Al tener, en muchas ocasiones, las mismas características el ruido y artefactos que los eventos de interés, la complejidad del clasificador aumenta si es que llega a detectar correctamente la mayoría de estos eventos durante la secuencia de datos EEG a menos de que se cumplan con condiciones muy específicas, como tamaño de ventana, promediado de la señal, entre otros.

El objetivo es que la persona pueda llevar a cabo movimientos naturales y con un ancho de banda en frecuencia menores a 500Hz aunque la mayoría de los equipos de adquisición de datos eliminan frecuencias mayores a los 60Hz. Este objetivo no se maneja comúnmente en los sistemas BCI por lo que se propone el uso de uno de los fenómenos en la adquisición del EEG: el ruido producido por el movimiento de cabeza y/o cuerpo aparecerá en todos los electrodos del sistema con pequeñas variaciones. El uso de un arreglo como en [6] permite la eliminación de este tipo de ruido eficientemente.

Cabe mencionar a ICA como uno de los métodos más adecuados para separar la actividad cerebral del ruido y artefactos [56][57][58]. En términos generales el análisis de componentes independientes consiste en encontrar una matriz de mezcla para obtener las fuentes originales mediante la observación únicamente de la mezcla de sus componentes. Los resultados y observaciones en [57] muestran algunas desventajas de ICA como los problemas que se presentan en las bandas superiores de frecuencia (beta y gamma), el tamaño de la ventana de análisis y el número mínimo de electrodos involucrados. Estos resultados deberán ser interpretados con mucha precaución particularmente la información proveniente de electrodos en la vecindad de músculos como los de la mandíbula. En algunos casos [58] se agrega información temporal basada en correlación e incrementan aun más la complejidad computacional de ICA.

El problema de la característica no-estacionaria del EEG es resuelta comúnmente mediante el uso de ventanas ya sea de tamaño fijo o adaptable de acuerdo a los datos de entrada para después ser procesadas con descomposiciones tipo espectral en la mayoría de los casos. Una de las más mejores opciones actualmente es el uso de la transformada wavelet [56, 59, 60, 61]. La transformada de Fourier obtiene el contenido espectral de la señal pero elimina la información temporal. La STFT (Short Time Fourier Transform) es una transformada de Fourier con tamaño de ventana fijo. Mientras más grande sea la ventana existe una mayor

pérdida en resolución temporal y una ventana corta perderá resolución espectral. Al contrario, la transformada Wavelet (DWT) entrega una representación tiempo-frecuencia más completa de la señal mediante el uso de un tamaño variable de ventana de análisis. Normalmente la DWT provee de una información más precisa en frecuencia a bajas frecuencias e información temporal más precisa en altas frecuencias. Esta propiedad es importante en medicina porque la mayoría de las señales contienen información en alta frecuencia con una duración corta en tiempo e información en baja frecuencia de más larga duración. A pesar de las grandes ventajas del uso de DWT se presentan algunas desventajas referentes a la característica de la señal EEG, la cual es compleja y no-estacionaria. Estas desventajas son que se debe tener conocimiento previo de la señal de entrada para definir la wavelet madre y el tamaño de ventana adecuadas. Existen otras opciones que se exploran en esta investigación. Se procesará mediante el uso de descomposiciones de la familia EMD (Empirical Mode Decomposition). La descomposición EMD es capaz de descomponer una señal con característica no-estacionaria. Como resultado nos entrega un determinado número de niveles de descomposición con características estacionarias y por lo tanto puede ser procesado adecuadamente por los módulos posteriores de acuerdo a los pasos de la figura 2.1. Lo más importante es que no es necesario tener un conocimiento previo de la señal de entrada.

En el caso de la detección de eventos ERD/ERS propios de los eventos motrices es necesario promediar la potencia por banda para conocer la línea base propia de cada una de estas bandas. Este valor base cambia entre personas y aún entre mediciones provenientes de la misma persona, lo que se conoce como diferencias intra-personales e inter-personales. Además, este valor base deberá ser conocido preferentemente antes del procesamiento de determinada secuencia EEG, lo que equivale en ocasiones, a un entrenamiento del sujeto bajo prueba. Se propone el uso del filtro Kalman en sustitución del simple promediado de la potencia en las bandas. Esto permitirá encontrar el valor base automáticamente y a su vez eliminara cambios bruscos en las bandas de frecuencia a consecuencia de otros fenómenos cerebrales diferentes al ERD/ERS.

Adicionalmente, se analiza el uso de ANFIS como elemento clasificador utilizando como entradas valores de potencia provenientes de la descomposición espectral de la onda P300. La onda P300 fue producto de una adecuada estimulación del usuario usando el experimento propuesto en el capítulo 5.

Capítulo 3

3 Procesamiento de señales EEG.

Se describirán en este capítulo los elementos base de la presente propuesta para el procesamiento del EEG y la eliminación de ruido y artefactos. Además se establecerán algunos conceptos y abreviaturas útiles para la lectura de los capítulos posteriores.

3.1 EMD. Descomposición en modo empírico.

La descomposición EMD es un método completo para obtener estimaciones o representaciones tiempo-frecuencia altamente localizadas para señales no-estacionarias. El objetivo general de EMD es encontrar o identificar los modos oscilatorios o intrínsecos (IMF – Intrinsic Mode Function) tomando como base la señal de entrada en una forma adaptiva. Estas funciones modo intrínseco cumplen con dos condiciones: el número de máximos y mínimos es igual al número de cruces por cero o con diferencia de uno, la media de las curvas envolventes conectando los máximos y mínimos locales es aproximadamente cero. Existe una modificación a la primera condición de tal forma que solo puede haber un cruce por cero entre un máximo y un mínimo, por lo que variaciones locales en la señal y asimetrías son eliminadas. Por lo tanto, cada IMF puede ser considerada como una señal de banda limitada y representando una escala temporal intrínseca a los datos de entrada. EMD fue propuesta inicialmente por Huang [40] como una herramienta de análisis espectral para series de tiempo no lineales y no estacionarias. Para la obtención de frecuencia instantánea se aplica la transformada Hilbert a estas señales limitadas en banda, dando como resultado la HHT (Hilbert Huang Transform).

Una señal puede ser descompuesta en sus IMFs tras un conjunto de operaciones iterativas:

Sea

$$\tilde{v}(t) = v(t) \quad (3.1)$$

donde $v(t)$ es la señal original.

Se identifican los máximos y mínimos locales de $\tilde{v}(t)$. Es necesario generar una onda envolvente usando estos puntos máximos mediante interpolación. La más común es la interpolación spline cúbica. De esta forma se obtiene $e_l(t)$. De la misma manera se procede para los puntos mínimos del cual se obtendrá $e_u(t)$.

Se calcula la curva media local mediante la ecuación 3.2.

$$\bar{m}(t) = \frac{e_l(t)+e_u(t)}{2} \quad (3.2)$$

Se subtrae la media local de $\tilde{v}(t)$, de acuerdo a la ecuación 3.3.

$$c_i(t) = \tilde{v}(t) - \bar{m}(t) \quad (3.3)$$

donde i es el orden de la IMF. Ahora $\tilde{v}(t) = c_i(t)$. Se verifica si $c_i(t)$ cumple los requisitos de una IMF, de lo contrario se repite el proceso para $\tilde{v}(t)$. La primera IMF se resta de los datos originales, de acuerdo a la ecuación 4.

$$r(t) = v(t) - c_i(t) \quad (3.4)$$

El procedimiento se repite iterativamente sobre el residuo $r(t)$ hasta que sea constante o no contenga más oscilaciones aunque existen otros criterios de paro. A este proceso se le llama sifting. Estos criterios de paro pueden ser diversos como por ejemplo, que se cumpla cierto número de siftings, que se alcancen ciertos umbrales o mínima amplitud residual. Este proceso permite establecer algunas propiedades importantes de la descomposición EMD:

Completa. Se refiere al grado de precisión con la cual una señal puede ser representada, es decir, de que es posible reconstruir la señal original mediante sus descomposiciones o IMFs.

Ortogonal. Garantiza la reconstrucción de la señal y evita la fuga entre descomposiciones.

Local. Significa que todos los eventos pueden ser localizados con una función del tiempo, tanto en amplitud como en frecuencia.

Adaptiva. Es decir que cambia su resolución (número de descomposiciones) dependiendo de la variación de los datos.

Las descomposiciones o IMFs son localmente ortogonales entre si, como lo expresa la ecuación 3.5, aunque en ocasiones se pueden presentar desviaciones menores por la naturaleza iterativa del algoritmo.

$$\overline{(x(t) - \overline{x(t)}) \cdot \overline{x(t)}} = 0 \quad (3.5)$$

Si es necesario conocer o analizar estas desviaciones es posible usar la ecuación 3.6. La ecuación 3.6 es un índice de ortogonalidad donde X es la señal original, $j \neq k$, n es el número de descomposiciones y T es el número de muestras dentro de la ventana de análisis.

$$I_O = \sum_{t=0}^T \left(\frac{\sum_{j=1}^{n+1} \sum_{k=1}^{n+1} IMF_j(t) IMF_k(t)}{\chi^2(t)} \right) \quad (3.6)$$

En ocasiones es necesario contar con una aproximación local sobre ciertas zonas de la secuencia de entrada o iterar solo en zonas donde el error es de valor considerable. Una EMD local puede ser obtenida mediante una función de peso $w(t)$ que describa una curva de decaimiento suave fuera de la zona problemática. De esta forma la ecuación (3.3) puede ser modificada a la ecuación (3.7).

$$d(t) = x(t) - w(t)m(t) \quad (3.7)$$

La figura 3.1 muestra la descomposición EMD proveniente de una señal artificial, se puede notar las 5 primeras descomposiciones (tomado de [6]).

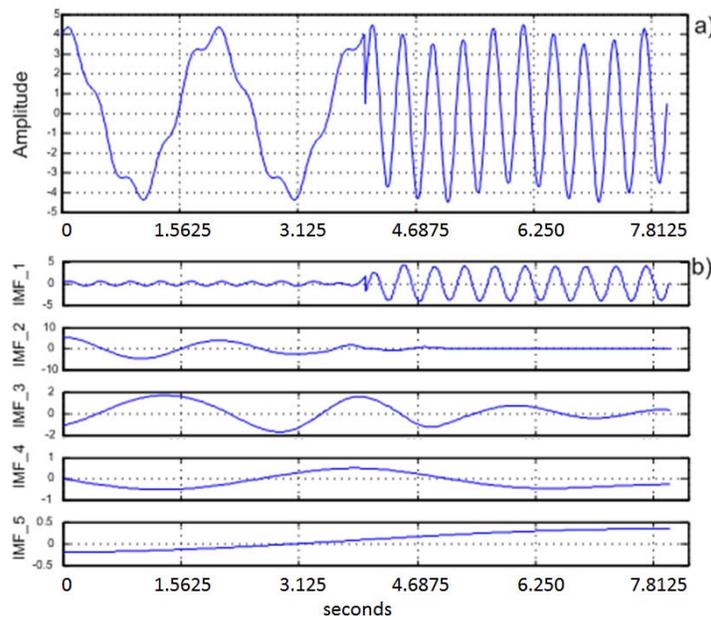


Figura 3.1 Descomposición EMD: a) señal original, b) EMD aplicado a esta señal

En el caso del EEG, que comúnmente se analiza información de múltiples electrodos, es necesario incluir una descomposición acorde a este análisis multivariado. Cuando se aplica EMD a cada uno de los canales, sin tomar en cuenta las variaciones en conjunto, se presentan algunas dificultades en el análisis del EEG. El problema de la unicidad, es decir, la variación del número de IMFs para diferentes canales, es causado por la naturaleza empírica del algoritmo y principalmente por el cálculo de la curva media en forma local. Además se presentan cambios en frecuencia (mode mixing), escala y fase de la curva IMF. Para resolver estos problemas se han desarrollado extensiones a la descomposición EMD. Tales como la EMD bivariada/compleja [62, 63], trivariada [64] y n-variada [65]. En términos generales consisten en el mapeo de señales multivariadas en múltiples señales reales o complejas para general envolventes multidimensionales.

En el caso de la EMD, la media local es calculada por medio del promedio de la envolvente superior e inferior. En contraste, en el caso de las señales multicanal, los máximos y mínimos locales no se pueden definir directamente y en consecuencia de la definición de las envolventes. La MEMD (Multivariate EMD) [65] genera un conjunto de envolventes de n-dimensión producto de la proyección sobre espacios n-dimensionales. Se considera que es una generalización de [64] y [65]. La elección de un adecuado espacio o vectores de dirección para de ahí generar las proyecciones es propuesto como una esfera n-dimensional en [65] con muestreo distribuido o mediante secuencias de baja discrepancia como la secuencia de Halton o Hammersley. Estas secuencias proveen una mejor distribución o muestreo, en este caso, de vectores de dirección en la esfera n-dimensional [66] y en consecuencia una mejor media local mediante el uso de las múltiples envolventes. Tomando en cuenta estas consideraciones se agregan pasos adicionales al algoritmo de EMD para obtener la MEMD. Considerando una secuencia de vectores n-dimensional, comúnmente designada por $\mathbf{v}(t)$ de acuerdo a la ecuación (3.8).

$$\{\mathbf{v}(t)\}_{t=1}^T = \{v_1(t), v_2(t), \dots, v_n(t)\} \quad (3.8)$$

Primero se generan los vectores de dirección sobre la hiper-esfera, designados por \mathbf{x}^{θ^k} , con ángulos definidos por θ^k sobre una $(n-1)$ esfera, acorde a la ecuación (3.9) y (3.10).

$$\mathbf{x}^{\theta^k} = \{x_1^k, x_2^k, \dots, x_n^k\} \quad (3.9)$$

$$\theta^k = \{\theta_1^k, \theta_2^k, \dots, \theta_{(n-1)}^k\} \quad (3.10)$$

Se calculan las proyecciones $p^{\theta^k}(t)$ de $t=1$ a T , de la señal de entrada $\mathbf{v}(t)$ a lo largo de la dirección de los vectores definidos por \mathbf{x}^{θ^k} para $\forall k$.

Se encuentran los tiempos $\{t_i^{\theta^k}\}$ correspondientes a los puntos máximos y mínimos del conjunto de proyecciones.

Se interpola usando $[t_i^{\theta^k}, \mathbf{v}(t_i^{\theta^k})]$ para obtener las envolventes multivariadas designadas por $e^{\theta^k}(t)$ de $k=1$ a K .

Para el conjunto K de vectores, la media $\mathbf{m}(t)$ de las curvas envolventes se calcula mediante la ecuación (3.11).

$$\mathbf{m}(t) = \frac{1}{K} \sum_{k=1}^K e^{\theta^k}(t) \quad (3.11)$$

En este punto se vuelve a realizar el mismo proceso que describe la ecuación (3.3). Si se cumple el criterio para las IMFs se ha encontrado la primera IMF, de lo contrario se continúa iterando para c_i . Este método es computacionalmente eficiente para un número

conocido, previamente, de canales o variables de entrada, debido a la propia naturaleza de las secuencias de Hammerslay.

3.2 Filtro Kalman.

El filtro Kalman es una herramienta para la estimación de variables expresadas en estados de un sistema lineal de un amplio rango de procesos [67]. En particular, el filtro Kalman es uno de los pocos filtros que minimiza la varianza del error de estimación. El modelo del mundo real descrito por el filtrado Kalman es descrito por medio de ecuaciones diferenciales. Estas ecuaciones deben estar en forma de matriz, es decir, en variables de estado (3.12):

$$\dot{x} = Fx + Gu + w \quad (3.12)$$

donde x es una variable aleatoria (en este caso expresado en forma de vector) con los estados del sistema, F es la matriz del sistema dinámico, u es un vector desconocido llamado vector de control y w es el ruido del proceso, el cual es expresado igualmente como vector. Se define convenientemente la matriz de ruido en el proceso, relacionado con el vector de ruido en el proceso de acuerdo a (3.13)

$$Q = E[ww^T] \quad (3.13)$$

Se requiere que las mediciones estén linealmente relacionadas a los estados de acuerdo a la ecuación (3.14).

$$z = Hx + v \quad (3.14)$$

donde z es el vector de medición, H es la matriz de medición y v es el ruido en la medición, el cual también es expresado en forma de vector. De igual manera se define la matriz de ruido en la medición R en relación al vector de ruido v

$$R = E[vv^T] \quad (3.15)$$

Las ecuaciones (3.12-3.15) deben ser discretizadas para que el filtro Kalman pueda ser construido. Si se toman muestras cada T_s segundos, es necesario encontrar primero una matriz fundamental Φ . Para un sistema invariante en el tiempo la matriz fundamental puede ser encontrada de una matriz de sistema dinámico de acuerdo a

$$\Phi(t) = \mathcal{L}^{-1}[(sI - F)^{-1}] \quad (3.16)$$

donde I es la matriz identidad y F es la matriz del sistema. La ecuación (3.17) es usada para propagar un estado hacia adelante o expresado matemáticamente

$$x(t) = \Phi(t - t_0)x(t_0) \quad (3.17)$$

Adicionalmente ϕ puede ser obtenida utilizando la expansión por series de Taylor (3.18), una vez encontrada $\Phi(t)$ se reemplaza t por $t - t_0$ en ϕ

$$\Phi(t) = e^{Ft} = I + Ft + \frac{(Ft)^2}{2!} + \dots + \frac{(Ft)^n}{n!} + \dots \quad (3.18)$$

Por lo tanto, la matriz fundamental discreta o matriz de transición puede ser obtenida por la evaluación de la matriz fundamental en el periodo de muestreo T_s , es decir (3.19),

$$\Phi_k = \Phi(T_s) \quad (3.19)$$

entonces la forma discreta del filtrado Kalman para la ecuación de mediciones se convierte en (3.20)

$$z_k = Hx_k + v_k \quad (3.20)$$

y (3.21)

$$R_k = E[v_k v_k^T] \quad (3.21)$$

Se puede observar que la matriz R_k consiste de las varianzas de todas las fuentes de ruido en la medición. La resultante ecuación para el filtro Kalman está definida por (3.22)

$$\hat{x}_k = \Phi_k \hat{x}_{k-1} + G_k u_{k-1} + K_k (z_k - H \Phi_k \hat{x}_{k-1} - H G_k u_{k-1}) \quad (3.22)$$

donde

K_k es la matriz de ganancia

G_k está definido por (3.23)

$$G_k = \int_0^{T_s} \Phi(\tau) G d\tau \quad (3.23)$$

De igual manera la matriz de ruido del proceso discreta se obtiene a través de la matriz fundamental (3.24)

$$Q_k = \int_0^{T_s} \Phi(\tau) Q \Phi^T(\tau) d\tau \quad (3.24)$$

La ganancia de Kalman es calculada mientras el filtro está operando utilizando las ecuaciones de Ricatti. Las ecuaciones de Ricatti son un conjunto de ecuaciones matriciales recursivas definidas por (3.25-3.27)

$$M_k = \Phi_k P_{k-1} \Phi_k^T + Q_k \quad (3.25)$$

$$K_k = M_k H^T (H M_k H^T + R_k)^{-1} \quad (3.26)$$

$$P_k = (I - K_k H) M_k \quad (3.27)$$

donde la matriz de covarianza P_k representa errores en los estados estimados, es decir, una varianza entre el valor real menos el estimado después de una actualización y M_k es la matriz de covarianza representando errores en los estados estimados antes de una actualización. Para comenzar la iteración en las ecuaciones de Ricatti es necesario iniciar la matriz de covarianza P con una P_0 .

Este valor de P es muy importante para obtener la variación correcta en la potencia para cada una de las bandas involucradas en los eventos ERD/ERS. El filtro está basado en la definición del sistema usando variables de estado y un algoritmo recursivo de minimización [67]. El filtro consiste de dos etapas predicción y corrección. La predicción o estado anterior resuelve las ecuaciones diferenciales que describen el modelo dinámico (ecuación 9), donde x es el vector de estados, F la matriz dinámica del sistema y w es ruido de proceso. Las medidas están linealmente relacionadas a los estados de acuerdo a la ecuación (3.10). La ecuación (3.10) es conocida como modelo de observación, donde z es el vector de medición, H es la matriz de medición y v es el ruido de medición. La solución de las ecuaciones diferenciales es una combinación lineal del estado inicial x según lo expresa la ecuación (3.17). En esta propuesta se considera un modelo expresado por las ecuaciones (3.28-3.30).

$$x = Fx + w \quad (3.28)$$

$$z = Hx + v \quad (3.29)$$

$$x(t) = \Phi(t - t_0)x(t_0) \quad (3.30)$$

3.3 Lógica difusa.

La lógica difusa es una extensión de la lógica tradicional que utiliza conceptos de pertenencia de conjuntos más parecidos a la manera de pensar humana. El concepto de conjunto difuso fue introducido por L.A. Zadeh en 1965 como una generalización de un conjunto exacto o nítido (conocido como crisp) tradicional. Los conjuntos tradicionales hacen uso de lógica booleana con valores exactos como en la lógica binaria. La lógica difusa además de incluir los valores 0 y 1, toma en cuenta valores intermedios por lo que se considera como un súper-conjunto incluyendo a la lógica tradicional. Si X es una colección

de objetos en el cual $x \in X$, un conjunto difuso es un mapa $\mu_F(x) : X \rightarrow [0, \alpha]$, en el cual a cada valor de x la función $\mu_F(x)$ le asigna un número entre los valores 0 a α . Por lo tanto, el conjunto difuso es el conjunto de pares ordenados definidos por la ecuación (3.31).

$$A = \{(x, \mu_A(x)) \mid x \in X\} \quad (3.31)$$

El valor asignado por $\mu_F(x)$ corresponde al grado en el cual el valor x tiene el atributo F , es decir, su grado de pertenencia por lo que a $\mu_F(x)$ se le llama función de pertenencia. Esta función es un grado de ambigüedad sobre la característica de la variable. Se usan variables lingüísticas para el análisis y modelado de sistemas. Un ejemplo de ello es la variable temperatura que puede definirse como fría, tibia, caliente. En la figura 3.2 se muestran los componentes de un sistema difuso. A continuación se enumeran estos componentes con una breve definición.

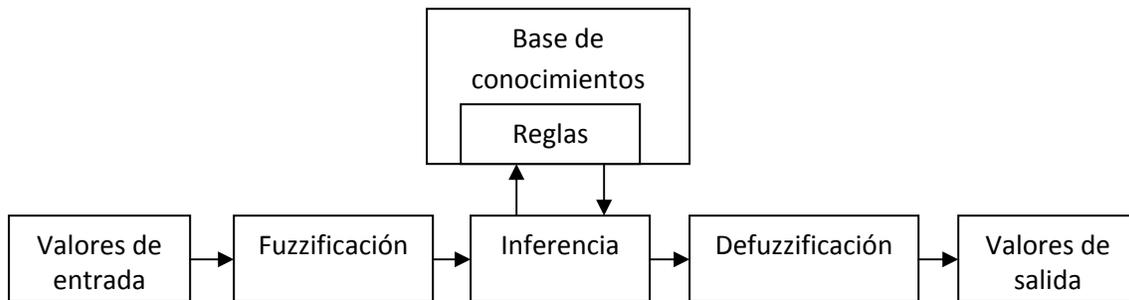


Figura 3.2 Etapas y componentes de un sistema de control difuso.

- Valores de entrada. Son valores nítidos, por ejemplo, valores provenientes de sensores (presión, temperatura, velocidad, etc.)
- Etapa de fuzzificación. Convierte los valores nítidos en grados de membresía.
- Inferencia. Mediante evaluación de reglas mapea el o los conjuntos difusos de entrada a la salida. Este proceso de inferencia se basa en una base de conocimientos provenientes de un experto o mediante una base de datos de mediciones de la planta.
- Defuzzificación. Convierte el conjunto o conjuntos difusos a valores nítidos (crisp) mediante métodos de defuzzificación como el cálculo del centroide.

Mediante el uso de las variables lingüísticas, reglas y las funciones de membresía es posible el modelado completo de sistemas. Las reglas difusas son de la forma *IF x es A THEN y es B*, en la cual A y B son variables lingüísticas definidas por conjuntos difusos en los universos X y Y. La parte, *IF x es A*, es llamada antecedente o premisa y la parte *THEN y es B* es el consecuente o conclusión.

Una vez definidas las partes de un controlador difuso se pueden hacer variaciones de este, lo que resulta en la definición de sistemas tipo Mamdani y Sugeno. El modelo Sugeno no

necesita la defuzzificación porque cada regla cuenta con un valor de salida exacto debido a que usa una función como consecuente. Mamdani fue uno de los primeros modelos a seguir ya que es más fácil aplicar la experiencia de operadores humanos. Para este tipo de modelos es necesario asignar un operador. Estos operadores puede ser AND, OR, T-norm, T-conorm y defuzzificación. Los métodos de defuzzificación usados en el control tipo Mamdani puede ser centroide, biselector de un área, el más pequeño, medio, máximo de un máximo, etc. Para esta propuesta se usará un controlador difuso tipo Mamdani para aprovechar el conocimiento médico de los eventos motrices expresados en las señales EEG.

3.4 ANFIS.

ANFIS (*Adaptive Neuro-Fuzzy Inference System*) combina la ventaja de los sistemas difusos de poder usar expresiones lingüísticas para generar modelos y también la capacidad de las redes neuronales de poder ser entrenadas. En otras palabras el sistema usa la inferencia difusa para representar conocimiento en una manera interpretable y también tiene la habilidad de poder ajustar los parámetros de sus funciones de membresía y reglas lingüísticas directamente de los datos para mejorar el desempeño del sistema. La figura 3.3 muestra la arquitectura ANFIS, la cual puede ser vista como una red neuronal que contiene cinco capas que se propagan hacia adelante. ANFIS utiliza un sistema de inferencia tipo Sugeno generando reglas difusas tomando como referencia un conjunto de datos de entrada y de salida. Considerando los componentes de un sistema difuso descritos en la sección 3.2, ANFIS ajusta los parámetros de las funciones de membresía tanto en la premisa y en el consecuente. Este ajuste se realiza mediante un algoritmo de aprendizaje en dos pasos: hacia adelante (*forward pass*) y en retroalimentación o hacia atrás (*backward pass*).

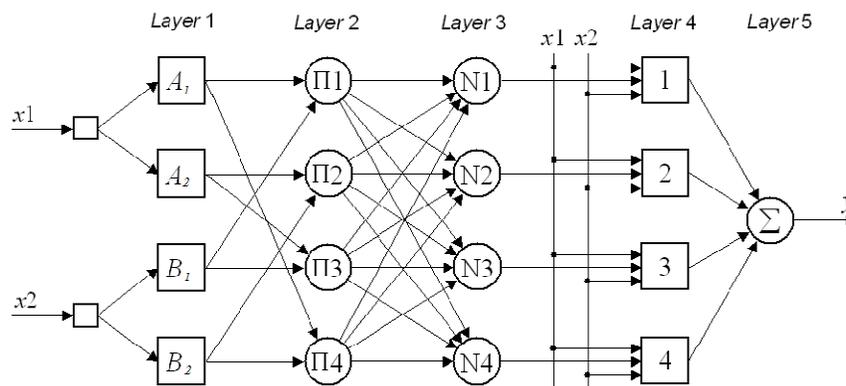


Figura 3.3. Arquitectura ANFIS para dos variables de entrada [49].

Dado un conjunto de entrada y salida, ANFIS construye un sistema de inferencia cuyos parámetros en la función de membresía son ajustados usando ya sea mediante retro-

propagación solamente o una combinación con estimación de mínimos cuadrados. El ajuste de estos parámetros en la retro-propagación es utilizando, comúnmente, gradiente descendiente.

La propagación hacia adelante se realiza mediante el cálculo de la salida en cada una de las capas de la figura 3.3 y los parámetros en el consecuente se obtienen mediante estimación de mínimos cuadrados. En la capa 1 o capa de fuzzificación, se definen los grados de membresía para cada valor de entrada dependiendo de la función de membresía elegida. En muchas ocasiones la función de membresía es gaussiana o normal por lo que la salida está definida por la ecuación 3.32.

$$O_{1,i} = \mu_{A_i}(x) = e^{\left(-\frac{1}{2}\left(\frac{x_1 - c_i}{\sigma_i}\right)^2\right)} \quad (3.32)$$

donde $O_{1,i}$ es la salida del i -ésimo nodo con c_i y σ_i como el centro y la desviación estándar del conjunto difuso normal A_i respectivamente. Este es el primer conjunto de parámetros en la premisa comúnmente designados por S1. La salida de la capa 2 es calculada mediante el producto II_i de los grados de membresía de acuerdo a la ecuación 3.33.

$$O_{2,i} = w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2) \quad (3.33)$$

La capa 3 es un proceso de normalización N_i tomando en cuenta la salida de todos los nodos de la capa anterior. Es una razón entre la i -ésima regla respecto a la suma de todas las reglas (ecuación 3.34).

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2 + \dots + w_i + \dots + w_n} \quad (3.34)$$

En la capa 4 se considera el peso de cada entrada sobre una función lineal de acuerdo a la ecuación 3.35.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i + r_i) \quad (3.35)$$

Donde p, q, r es el conjunto de parámetros en el consecuente los cuales pueden ser encontrados usando la estimación por mínimos cuadrados y comúnmente designados por S2. Finalmente la capa 5 calcula la salida como la sumatoria de todos los nodos de la capa anterior usando la ecuación 3.36.

$$O_{5,i} = \sum_i^n \bar{w}_i f_i \quad (3.36)$$

La estimación minimiza el error de $\|AX - B\|^2$ aproximando a X con X^* , donde B son los datos de salida conocidos previamente, A son los pesos obtenidos de la capa 3 y X es el conjunto de parámetros que sea desea estimar de la capa 4.

Como se había mencionado anteriormente ANFIS se entrena mediante ciclos de dos pasos: hacia adelante y en retroalimentación. Para realizar este entrenamiento es necesario encontrar los parámetros S1 y S2 definidos anteriormente. En el paso hacia adelante se considera el conjunto S1 como fijo y el conjunto de parámetros S2 es calculado mediante estimación por mínimos cuadrados. En el paso en retroalimentación el conjunto S2 es considerado como fijo y el conjunto de parámetros S1 se encuentra comúnmente mediante gradiente descendiente. ANFIS es uno de los mejores métodos en entregar un compromiso entre sistemas difusos y redes neuronales lo cual le permite obtener salida suavizada y con alta adaptabilidad. Sin embargo ANFIS tiene algunas restricciones desde el punto de vista de su tiempo de entrenamiento.

3.5 Discusión.

Se establecieron los métodos que servirán como base para la propuesta del capítulo 5. Además de su notación se describió su modo de funcionamiento y las operaciones involucradas en cada uno de ellos.

Capítulo 4

4 Modelo propuesto de procesamiento, eliminación de ruido y artefactos para los eventos ERD/ERS.

En este capítulo se describe cada una de las partes de las cuales consta esta propuesta, describiendo sus ventajas respecto a otros métodos conocidos.

4.1 Descomposición de la señal EEG.

El uso de la transformada Wavelet [68][69] y EMD [70] para el manejo de señales no-estacionarias se ha incrementado en los últimos años y en el caso del EEG no ha sido la excepción. Se establecen ciertas limitantes para el análisis usando transformada Wavelet como el tamaño de la ventana. Se ha hecho notar en los capítulos anteriores las ventajas de EMD sobre la transformada Wavelet, tales como su adaptabilidad y su mejor desempeño en localización temporal. EMD en el análisis multicanal puede, en algunos casos, presentar problemas en la cantidad de descomposiciones resultantes por canal. Esto tiene como consecuencia, desde el punto de vista multivariable, en que no se exista banda limitada en cada IMF. Este problema puede ser evitado mediante un promediado por ventanas antes de realizar la descomposición pero perdería una de las grandes ventajas sobre otras transformadas y en algunos casos pérdida de información. MEMD evita los problemas de la EMD para análisis multicanal como el permitir definir una IMF_i en la cual se detectarán los cambios característicos de los eventos motrices: alfa, beta, gamma, además de eliminar el problema de defase, escala y el promediado necesario antes de la descomposición. Un punto fuerte es que las ventanas de análisis no se limitan a la duración propia del evento y algo muy importante, no es necesario considerar que el EEG es estacionario durante la duración de la ventana. Aún más se elimina la necesidad de agregar procesamiento adicional en el caso de tamaño de ventana adaptiva.

La descomposición del EEG mediante MEMD se lleva a cabo en esta propuesta en cualquier situación, ya sea en condiciones controladas de laboratorio o no. La siguiente sección describe el caso en la cual las condiciones de ruido y artefactos son provocados por movimiento de cabeza o cuerpo. En algunos casos es posible la eliminación de contaminación de naturaleza EOG (Electro-Oculografía) sólo mediante la descomposición MEMD [71].

4.2 Eliminación de ruido y artefactos.

En la mayoría de los sistemas de adquisición de datos EEG, se encuentran disponible un número determinado de electrodos que van desde 14 (Emotiv headset, por ejemplo) hasta en número mayor a 100 electrodos. En todos estos sistemas se cuenta con los datos de varios electrodos simultáneamente. Una ventaja de tener múltiples fuentes es la posibilidad de reducir el ruido drásticamente mediante un procesamiento basado en correlación. Cualquier movimiento de cabeza producirá ruido en los electrodos del sistema de adquisición EEG debido a pequeños movimientos entre el electrodo y el cuero cabelludo del sujeto bajo prueba. Mientras más drástico sea el movimiento de la cabeza el ruido se incrementara sobre cada uno de los electrodos reduciendo el desempeño de la detección [72]. Este ruido puede ser eliminado o reducido tomando en cuenta una las principales reglas en la interpretación y análisis del EEG: *una señal que se presenta en todos los electrodos (con ligeras variaciones en amplitud) es muy probablemente ruido para personas saludables*. Este tipo de ruido presente en todos los electrodos es producido por diferentes fuentes tales, como en este caso, por movimientos musculares de cabeza/cuello o respiratorios, por ruido electromagnético, etc. En conclusión, el objetivo a seguir es encontrar señales comunes en todos los electrodos o en un subconjunto de *electrodos lejanos entre sí*. La figura 4.1 muestra el proceso general para obtener las componentes comunes a los electrodos. Este proceso consiste en la descomposición de la señal proveniente del electrodo por medio de MEMD. Esta descomposición se repite para todos los electrodos o al menos 3, involucrando al electrodo del cual se requiera analizar su información y 2 electrodos los más alejados entre sí y que se tengan disponibles en el sistema de adquisición. El siguiente paso es tomar la descomposición i de cada electrodo (i -ésima IMF) y se le aplica una función basada en correlación para encontrar un índice de semejanza. Finalmente un módulo de integración es necesario para descartar descomposiciones comunes a los electrodos.

Como se ha mencionado anteriormente, el ruido producido por movimientos de cabeza aparecerán en todos los electrodos del sistema con pequeñas variaciones, lo que lleva a concluir que es posible establecer una dependencia de estas señales o al menos en las componentes (IMFs) de la señal de cada electrodo. Funciones basadas en correlación, tal como el coeficiente de Pearson miden o establecen un valor de dependencia entre dos variables aleatorias. La ecuación (4.1) define la correlación de Pearson con valores esperados de μ_X y μ_Y con desviaciones estándar σ_X y σ_Y .

$$\rho_{X,Y} = \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X\sigma_Y} \quad (4.1)$$

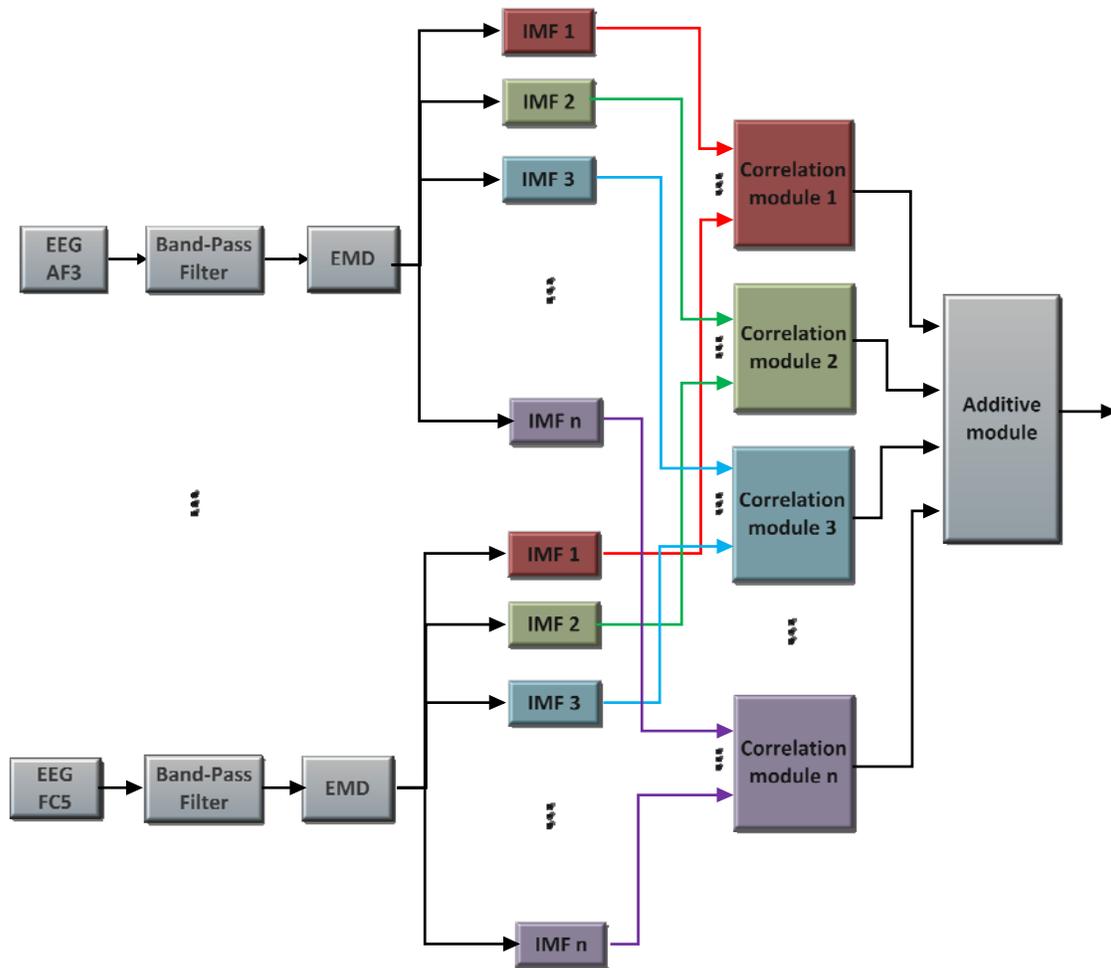


Figura 4.1 Eliminación de ruido mediante EMD y correlación.

Si se aplica la función de correlación directamente a las señales de entrada de cada electrodo podría arrojar similitud entre esos canales. Esto significa que las señales tendrían que ser removidas en esa ventana de análisis, sin embargo, la eliminación de estas secuencias causará la pérdida de información relevante. Por lo tanto, descomponer la señal de entrada de cada electrodo reducirá la pérdida de información, permitiendo que el sistema pueda remover los artefactos producidos por movimientos de la interfaz electrodo-piel. Este proceso se ha aplicado con éxito en experimentos propios en [6] mediante descomposición EMD y siguiendo el flujo de la figura 4.1. Además de esta propuesta inicial con EMD, se aprovecharán las ventajas de MEMD sobre EMD para señales multicanal. En conclusión el sistema cambiará al descrito en la figura 4.2.

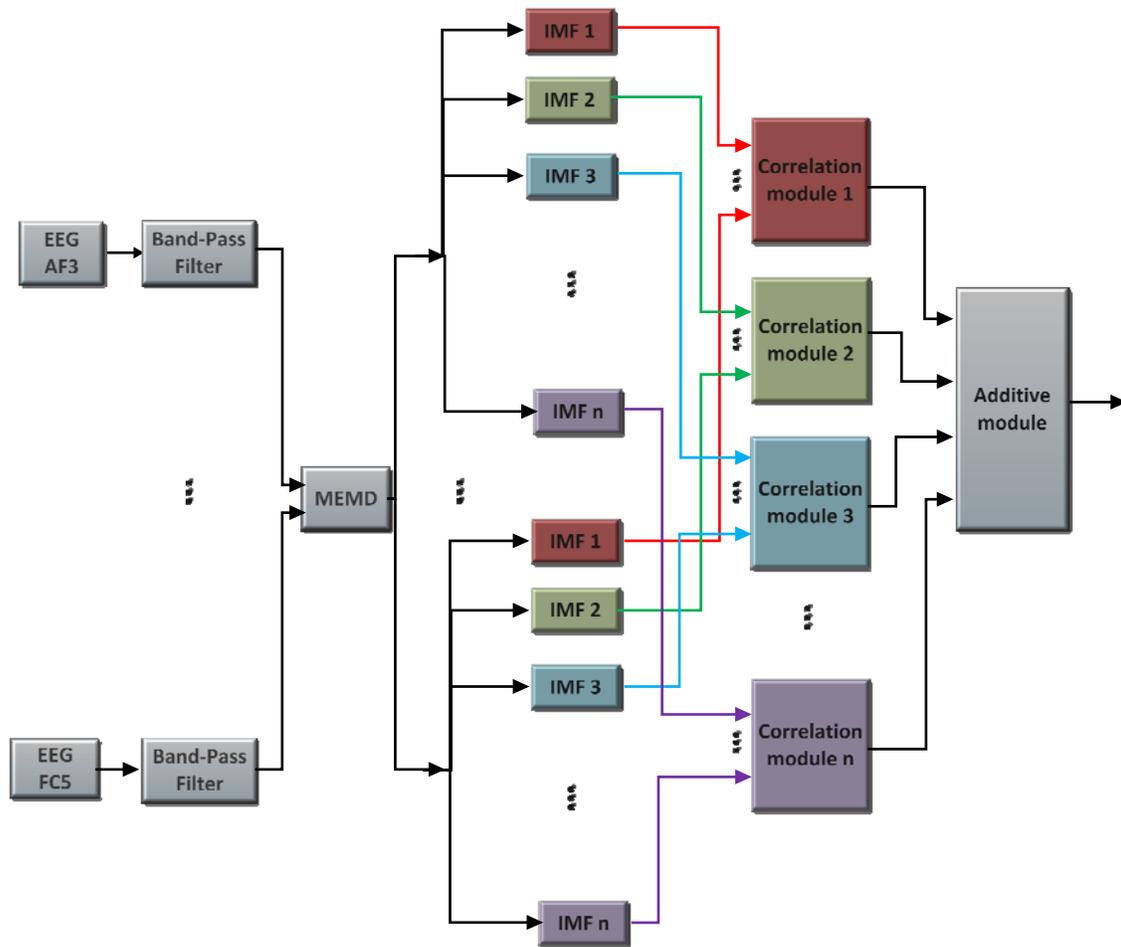


Figura 4.2 Modelo propuesto para eliminación de ruido mediante MEMD y correlación.

Este proceso descrito en la figura 4.2 se aplicará en los casos de que hay información de 3 o más electrodos disponibles y que no existan condiciones controladas de laboratorio. Ejemplo de estas condiciones controladas pueden ser jaula de Faraday y/o instrucciones al sujeto bajo prueba de no moverse a menos de que sea necesario. Se han diseñado experimentos propios para la adquisición de EEG enfocándose en los eventos ERD/ERS con énfasis de no instruir al usuario de que evite cualquier movimiento. Estos experimentos se describirán más a fondo en el capítulo 5.

Por medio de la correlación de Pearson, descrita por la ecuación (4.1), se encuentra la similitud entre estas IMFs producto de la MEMD. Este valor de correlación se usa como entrada para calcular un p-valor por medio de una transformación del valor de correlación al valor obtenido de una distribución t estadística con $n-2$ grados de libertad, donde n es el número de datos en la secuencia de entrada. Si el valor resultante es cercano a cero en la mayoría de los electrodos en comparación respecto al electrodo de análisis significa que esta descomposición (IMF), en esa ventana, será considerada como ruido y por lo tanto, no se considerada en el módulo de adición.

4.3 Línea base ERD/ERS.

Típicamente se debe conocer con anterioridad a la detección de eventos, el valor de la potencia para cada una de las bandas involucradas en el fenómeno ERD/ERS que corresponde al sujeto de prueba. Este valor base o línea base se establece durante el reposo o descanso, sin dormir o somnolencia, de la persona que usará el sistema. Lo anterior implica cierto entrenamiento previo al uso del sistema tanto para el módulo de procesamiento como para el usuario. Se propone la implementación de un filtro Kalman lineal para evitar el uso de la línea base para cada banda. Se considera al filtro Kalman como un filtro predictivo recursivo que minimiza la covarianza del error convirtiéndolo en un estimador óptimo. Esto permite usar el filtro para actividades como seguimiento, eliminación de jitter para estabilización de imágenes [73], seguimiento en tiempo real de rostros [74]. En esta propuesta las matrices de Kalman (ecuaciones 3.28 y 3.29) pueden ser definidas en forma similar a una partícula en movimiento en un plano a velocidad constante sujeto a perturbaciones aleatorias en su trayecto. Es decir, que la variación de la potencia para cada una de las ventanas será sometida a “seguimiento” por el filtro. De esta forma se establecería la línea base automáticamente y no permitiría cambios bruscos, los cuales no son típicos en los eventos ERD/ERS por lo que eliminaría otros fenómenos mentales que se presenten. Por lo tanto, el modelo del sistema queda definido de acuerdo a las ecuaciones 4.2 y 4.3 en su forma discreta, donde T_s es el periodo de muestreo.

$$\begin{bmatrix} x_1 \\ x_2 \\ \bar{x}_1 \\ \bar{x}_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 & T_s & 0 \\ 0 & 1 & 0 & T_s \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} x + w \quad (4.2)$$

$$\begin{bmatrix} z_1 \\ z_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} x + v \quad (4.3)$$

Los valores de los vectores de ruido de proceso y de medición pueden ser definidos mediante la varianza de la señal para cada una de las bandas. Una vez que se han obtenido las IMFs mediante el uso de MEMD es correcto considerar que la señal es estacionaria con ruido gaussiano con media de cero de acuerdo a [] y por lo tanto, se cumplen las condiciones de funcionamiento para filtro Kalman.

4.4 Clasificación.

Se propone el uso de un sistema difuso para la detección de eventos ERD/ERS ya que se ha aplicado exitosamente el uso de los sistemas de inferencia difuso para detección de eventos

mentales [75]. Una vez que se ha procesado la señal EEG mediante los módulos descritos en las secciones anteriores es posible en forma directa construir un sistema difuso con 3 variables de entrada correspondientes a cada una de las bandas involucradas, es decir, alfa, beta y gamma. Se tiene que tomar en cuenta para la construcción del sistema difuso, a pesar de que se tenga un sistema con ruido y artefactos reducidos, la variación natural en amplitud y fase para cada una de las bandas. A continuación se describirá las razones por las cuales existe una variación en la amplitud y el atraso/adelanto para las bandas alfa, beta y gamma. Estas variaciones son del tipo intra-personal e inter-personal.

Variación en fase y amplitud en las bandas del fenómeno ERD/ERS.

Se toman como válidos ciertos rangos en fase y de amplitud en cada banda (gamma, beta, alfa) dentro de la ventana del ERD/ERS debido a que no en todas las personas se presentan de la misma manera y es dependiente de la edad, inteligencia y estado de ánimo. Aquí los modificadores en la fase y la amplitud dependiendo de la banda:

- Alfa.

Su variación es mayor, en este caso disminución de potencia, cuando es un movimiento nuevo o que requiere de cierto entrenamiento. Por esta razón, siempre la variación disminuye en la etapa final de cualquier experimento.

Su variación es menor cuando se usa la mano o región dominante: diestro, zurdo.

La variación es mayor cuando implica el uso de características mentales tales como la percepción, el juicio y/o la memoria.

- Beta.

Indica la terminación del movimiento, por lo que persistirá su variación, en este caso como disminución de potencia, durante movimientos sostenidos.

Representa en general una desactivación o inhibición del movimiento.

Se presenta también cuando se observa a otra persona realizar movimiento (empatía).

- Gamma.

Indica la preparación para el inicio de una actividad cognitiva.

Igualmente que alfa disminuirá su variación al realizar movimientos aprendidos o monótonos.

De la misma manera que alfa, aumenta la variación pero con un incremento en la potencia, cuando implica el uso de características mentales tales como la percepción, el juicio y/o la memoria.

El conjunto de reglas difusas puede ser definido siguiendo el comportamiento propio de los eventos ERD/ERS explicado en los capítulos anteriores. Las tablas 4.1 y 4.2 muestran las reglas difusas para este sistema.

Retraso en los cambios de potencia.

Se ha comentado anteriormente que el punto de referencia para detectar un posible evento ERD/ERS es el aumento considerable relativo en la banda gamma. A partir del punto donde se detecta un incremento en la potencia de gamma se medirá la fase o retraso de cambio para las bandas beta y alfa.

Retraso gamma-beta. Típicamente deberá haber un cambio en beta (incremento en la potencia) al momento de la restauración o re-sincronización de gamma (ver figura 2.3). Recordando que beta indica la terminación del movimiento, su disminución persistirá durante movimientos sostenidos y aumentará al terminar esta persistencia.

Dado que este retraso es modificado voluntariamente por el sujeto bajo prueba deberá ser acordado previamente y mantener esta duración t_β como fase válida como parámetro para el clasificador. El rango de duración voluntaria del movimiento es considerado $t_\beta \pm 20\%$ [13] como parámetro válido para la mayoría de las personas.

Retraso gamma-alfa. El tiempo de retraso entre el incremento en la banda gamma t_α y el punto mínimo en alfa es de considerarse como cero. En su defecto sólo se debe considerar como condición obligatoria es que alfa deberá estar disminuyendo.

Todo este conocimiento de variaciones en potencia y retraso en tiempo para cada una de las bandas alfa, beta y gamma puede ser utilizado directamente por el sistema de inferencia propuesto. Por lo tanto, definiendo alfa, beta y gamma como variables lingüísticas como entrada al sistema de inferencia se usa una matriz tipo Toeplitz (ecuación 4.4) formada con la secuencia de datos de entrada, que en este caso es la variación de cada una de las bandas, donde n es el número de entradas.

$$X = \begin{bmatrix} x(0) & x(1) & x(2) & x(3) & \cdots & x(n) & \cdots \\ 0 & x(0) & x(1) & x(2) & \cdots & x(n-1) & \cdots \\ 0 & 0 & x(0) & x(1) & \cdots & x(n-2) & \cdots \\ 0 & 0 & 0 & x(0) & \cdots & x(n-3) & \cdots \\ \vdots & \vdots & \vdots & \vdots & \cdots & \vdots & \cdots \\ 0 & 0 & 0 & 0 & \cdots & x(0) & \cdots \end{bmatrix} \quad (4.4)$$

Es necesario definir las reglas difusas para estas variables lingüísticas tomando en consideración los diagramas de la figura 4.3 y 4.4. El primer sistema de inferencia funciona como un habilitador del segundo sistema al detectar la desincronización de las bandas,

inicio propio de los eventos motrices. La salida Desync funciona como una entrada al segundo sistema que detectará la sincronización de las bandas marcando la terminación del evento motriz.

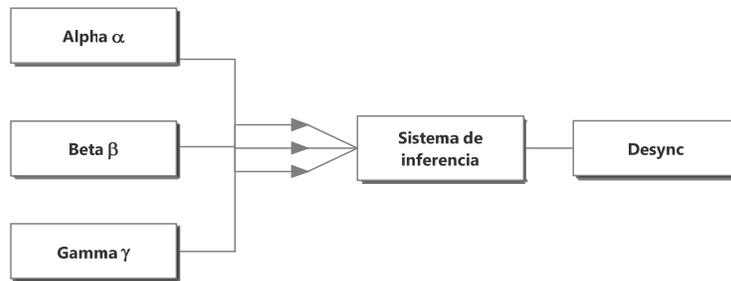


Figura 4.3. Vista general del sistema de inferencia detectando la desincronización de las bandas ERD.

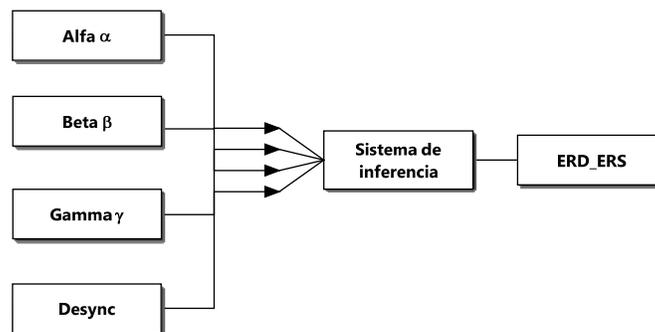


Figura 4.4. Vista general del sistema de inferencia detectando la sincronización de las bandas ERD.

Las reglas difusas se definen directamente de la observación del comportamiento del ERD/ERS. La tabla 4.1 enlista las reglas para el primer y la tabla 4.2 para el segundo sistema de inferencia considerando operadores AND. El conjunto difuso es de tipo gaussiano siendo uno de los más comunes y arrojando mejores resultados que el tipo triangular. Los conjuntos difusos de entrada cubren el rango de entrada dividiéndolo en 3 areas: low, average y high. Las tablas 4.1 y 4.2 describen reglas que se usarán en el sistema difuso. Como ejemplo tenemos para el primer renglón de la tabla 4.1: “Si gamma (γ) es alto y beta (β) es bajo y... entonces Desync es Extra-Alto”.

Tabla 4.1 Reglas para el sistema de inferencia 1, donde, L = low, A=average, H=high, XH=extra-high, x=dont care.

IF-THEN	<i>Sistema de inferencia: Desincronización</i>					
γ	$\gamma(1)$	β	$\beta(1)$	α	$\alpha(1)$	<i>Desync</i>
<i>H</i>	<i>x</i>	<i>L</i>	<i>x</i>	<i>L</i>	<i>L</i>	<i>XH</i>
<i>H</i>	<i>x</i>	<i>A</i>	<i>x</i>	<i>L</i>	<i>L</i>	<i>XH</i>

<i>H</i>	<i>x</i>	<i>L</i>	<i>x</i>	<i>A</i>	<i>H</i>	<i>A</i>
<i>H</i>	<i>x</i>	<i>A</i>	<i>x</i>	<i>A</i>	<i>H</i>	<i>A</i>
<i>H</i>	<i>x</i>	<i>L</i>	<i>x</i>	<i>L</i>	<i>A</i>	<i>H</i>
<i>H</i>	<i>x</i>	<i>A</i>	<i>x</i>	<i>L</i>	<i>A</i>	<i>H</i>
<i>A</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>L</i>
<i>L</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>L</i>

Tabla 4.2 Reglas para el sistema de inferencia 2, donde, L = low, A=average, H=high, XH=extra-high, x=dont care.

IF-THEN	<i>Sistema de inferencia: Sincronización</i>						
γ	$\gamma(1)$	β	$\beta(1)$	α	$\alpha(1)$	<i>Desync</i>	<i>ERD_ERS</i>
<i>A</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>L</i>	<i>x</i>	<i>XH</i>	<i>XH</i>
<i>A</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>A</i>	<i>x</i>	<i>XH</i>	<i>XH</i>
<i>A</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>XH</i>	<i>H</i>
<i>L</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>L</i>	<i>x</i>	<i>XH</i>	<i>XH</i>
<i>L</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>A</i>	<i>x</i>	<i>XH</i>	<i>XH</i>
<i>L</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>H</i>	<i>x</i>	<i>XH</i>	<i>H</i>
<i>A</i>	<i>x</i>	<i>A</i>	<i>L</i>	<i>L</i>	<i>x</i>	<i>XH</i>	<i>H</i>
<i>A</i>	<i>x</i>	<i>A</i>	<i>L</i>	<i>A</i>	<i>x</i>	<i>XH</i>	<i>A</i>
<i>A</i>	<i>x</i>	<i>A</i>	<i>L</i>	<i>H</i>	<i>x</i>	<i>XH</i>	<i>L</i>
<i>L</i>	<i>x</i>	<i>A</i>	<i>L</i>	<i>L</i>	<i>x</i>	<i>XH</i>	<i>A</i>
<i>L</i>	<i>x</i>	<i>A</i>	<i>L</i>	<i>A</i>	<i>x</i>	<i>XH</i>	<i>A</i>
<i>L</i>	<i>x</i>	<i>A</i>	<i>L</i>	<i>H</i>	<i>x</i>	<i>XH</i>	<i>L</i>
<i>x</i>	<i>x</i>	<i>L</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>L</i>
<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>L</i>	<i>L</i>
<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>A</i>	<i>L</i>
<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>x</i>	<i>H</i>	<i>L</i>

4.5 Evaluación y discusión.

Se ha propuesto un método de detección de eventos ERD/ERS incluyendo reducción de ruido para condiciones no controladas de laboratorio. Estas modificaciones no implican que el sistema forzosamente tenga que ser usado con eliminación de ruido o con el filtro Kalman. El sistema se ha propuesto con alta modularidad, es decir, el bloque de reducción de ruido y la obtención de línea base puede ser eliminados de la línea de procesamiento para los casos de ambientes controlados. El esquema general de la propuesta se muestra en la figura 4.5.

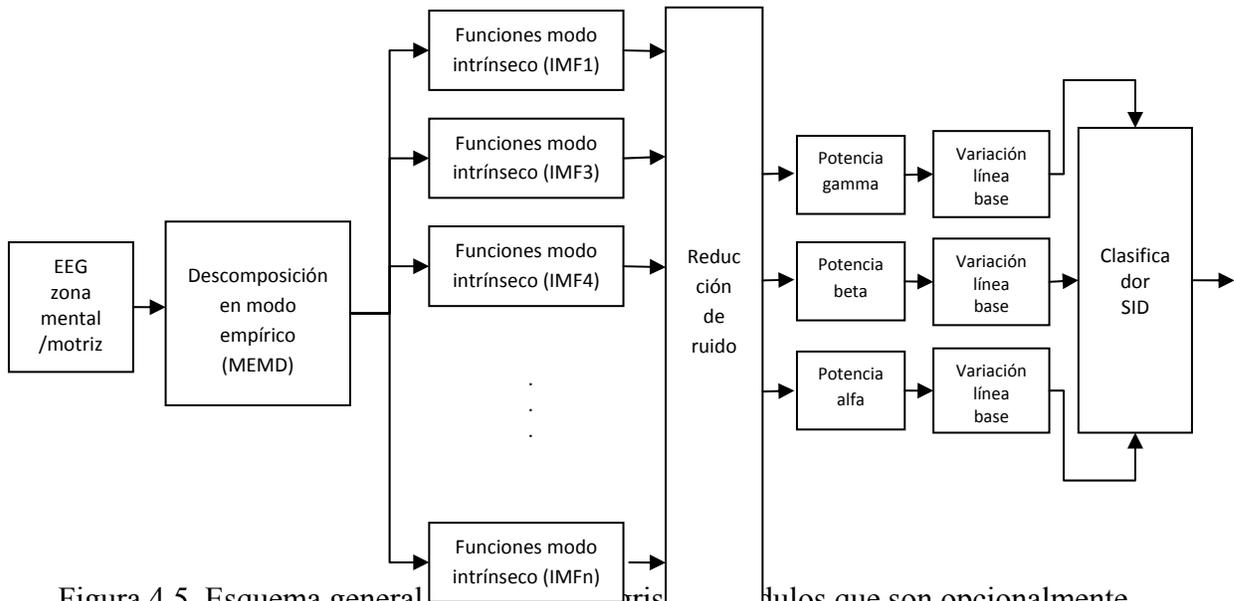


Figura 4.5. Esquema general propuesto. En gris los módulos que son opcionalmente utilizados.

La mayoría de señales EEG disponibles provenientes de base de datos no consideran el ruido provocado por el movimiento del usuario ya que se encuentra bajo la instrucción de no moverse en la mayor medida posible. Por lo tanto, la estimación de la reducción de ruido es evaluado mediante el procesamiento de señales EEG provenientes de experimentos propios. En el capítulo 5 se describe la aplicación de este método y se demuestra la posibilidad de reducir la complejidad del clasificador a un conjunto simple de reglas difusas. La forma en la que se evalúa el sistema propuesto es mediante los siguientes elementos:

Diseño propio de experimentos mediante apoyo visual a los usuarios.

Se aplica a personas sanas entre 18 y 50 años.

Se les instruye al sujeto de la cantidad y protocolo de cada una de las pruebas.

Se conoce el momento en que un evento ERD/ERS deberá presentarse.

Los valores de desempeño se presentan primordialmente mediante la matriz de confusión en su forma de gráficas ROC con lo cual se establece fácilmente una comparación.

Para la reducción de ruido se evalúa mediante valores de correlación que son la referencia principal para habilitar el módulo de integración para la reducción del ruido y artefactos. Adicionalmente se procesa la información EEG para el fenómeno ERD/ERS de información proveniente de una base de datos reconocida siguiendo el proceso de evaluación de esta propuesta. Se deberá tomar en cuenta que la información de la base de

datos es bajo ambiente controlado de ruido y movimiento. Esta se evalúa igualmente mediante gráficas ROC.

4.6 Descomposición multivariada mediante sistemas difusos.

Se propone un método alternativo a [65] para la obtención de las descomposiciones IMFs para sistemas multivariados pero conservando las mismas ventajas de la MEMD como el correcto procesamiento de señales no estacionarias y la eliminación de los problemas que surgen al aplicar EMD a sistemas multivariados como el modo mezclado (mode-mixing). En términos generales se obtiene la descomposición en modo empírico para múltiples señales de entrada mediante un sistema de inferencia difuso en substitución a la proyección en hiper-esferas. Uno de las aproximaciones más conocidas es la de D. Looney y N. Rehman [65], la cual mediante proyección a esferas multidimensionales se obtiene la descomposición en modo empírico para sistemas multivariados, eliminando los problemas anteriormente mencionados. Como un sustituto de estas hiper-esferas se propone el uso de conjuntos difusos para la obtención de una señal con características comunes a las variaciones de las señales de entrada y en consecuencia de la señal envolvente que se usará como base para la descomposición.

Como se había descrito en el capítulo 3 se debe elegir un espacio adecuado para la generación de las proyecciones. Este espacio es propuesto en [65] como una esfera n -dimensional muestreada mediante el uso de secuencias de baja discrepancia como las secuencias de Hammersley.

Considerando nuevamente la secuencia de vectores n -dimensional designada por $\mathbf{v}(t)$ de acuerdo a la ecuación (3.8). La generación de vectores de dirección descritos por la hiper-esfera y su proyección sobre estos vectores será sustituida por el sistema de inferencia difuso. Se representa la regla de control difuso de la forma r_j : if(\mathbf{v}_i es \mathbf{A}^j) then (\mathbf{z} es \mathbf{C}^j), a través de una relación difusa cuya función de membresía definida en el espacio producto $A_1 \times A_2 \times \dots \times A_n \times B$ está dado por la ecuación (4.5).

$$\mu_{r_j}(\mathbf{v}_i, \mathbf{z}) = t(\mu_{A^j}(\mathbf{v}_i), \mu_{C^j}(\mathbf{z})) \quad (4.5)$$

donde t es la T-norma, la cual comúnmente es el producto o, en este caso, el mínimo. Dado que existen un conjunto de reglas que mapean \mathbf{v} en \mathbf{z} entonces existen n relaciones que pueden conectarse mediante la operación OR. Esto permite formar una base de conocimiento, de acuerdo a la ecuación (4.6).

$$\mu_{BR}(\mathbf{v}_i, \mathbf{z}) = \cup_j \mu_{r_j}(\mathbf{x}, \mathbf{z}) \quad (4.6)$$

La ecuación 4.6 se puede definir utilizando la s-norma (ecuación 4.7), la cual puede ser definida como una suma o, en este caso, máximo.

$$\mu_{BR}(\mathbf{v}_i, z) = s(\mu_{r1}(\mathbf{x}, z), \mu_{r2}(\mathbf{x}, z), \dots, \mu_{rn}(\mathbf{x}, z)) \quad (4.7)$$

Empleando la composición como operador se puede inferir la función de membresía de salida de acuerdo a un conjunto de entradas \mathbf{v} . Considerando a cada uno de los vectores de la secuencia n-dimensional \mathbf{v} como variables lingüísticas de entrada y una variable de salida z como la función de membresía que, después de defuzzificación, reemplazara a las proyecciones $p^{\theta_k}(t)$ sobre la hiper-esfera. La función de membresía del conjunto difuso de salida \mathbf{C}' está definido por la ecuación 4.8.

$$\mu_{C'}(z) = \sum_{i=1}^n w_i \wedge \mu_{C_i}(z) = (w_1 \wedge C_1) \vee (w_2 \wedge C_2) \vee \dots \vee (w_n \wedge C_n) \quad (4.8)$$

donde $\mu_{C_i}(z)$ es la función de membresía de la conclusión difusa C_i , w_i indica el grado de activación de la regla R_i y n el número de reglas.

Para la obtención de la señal que substituirá a las proyecciones es necesario la defuzzification de la conclusión difusa (ecuación 4.8) en un valor nítido mediante el método de centroide como lo especifica la ecuación (4.9).

$$\mathbf{z}_o = \frac{\int_z \mu_{C'}(z) z dz}{\int_z \mu_{C'}(z) dz} \quad (4.9)$$

donde $\mu_{C_i}(z)$ está definido por la ecuación 4.8 y \mathbf{z}_o son los centros de gravedad de las funciones de membresía resultantes y los cuales funcionan como valor nítidos. Se encuentran los tiempo $\{ t_i^{\mu_k} \}$ correspondientes a los puntos máximos y mínimos de la salida del sistema de inferencia difuso \mathbf{z}_o .

Se interpola usando $[t_i^{\mu_k}, \mathbf{v}(t_i^{\mu_k})]$ para obtener las envolventes multivariadas designadas por $e^{\mu_k}(t)$ de $k=1$ a K .

Para el conjunto K de vectores, la media $\mathbf{m}(t)$ de las curvas envolventes se calcula mediante la ecuación 4.10 en forma similar a la ecuación 3.11.

$$\mathbf{m}(t) = \frac{1}{K} \sum_{k=1}^K e^{\mu_k}(t) \quad (4.10)$$

Se sigue el mismo proceso que describe la ecuación (3.3). Si se cumple el criterio para las IMFs se ha encontrado la primera IMF, de lo contrario se continúa iterando para c_i . El conjunto de reglas a usar se muestran en la tabla 4.3 para $n=3$. Se representa la regla de control difuso de la forma r_j : if(\mathbf{v}_i es \mathbf{A}^j) then (z es \mathbf{C}^j) para cada una de las entradas i .

IF-THEN	<i>Sistema de inferencia Multivariado con n=3</i>		
v_1	v_2	v_3	z
L	L	L	L
L	L	A	L
L	L	H	A
L	A	L	L
L	A	A	A
...
H	H	A	H
H	H	H	H

Tabla 4.3 Reglas para el sistema de inferencia MEMD, donde, L = low, A=average, H=high.

En el capítulo 5 se evalúa el proceso de descomposición propuesto mediante valores promedio de amplitud y valores de potencia en un intervalo determinado de tiempo.

Capítulo 5

En este capítulo se presenta el diseño de experimentos para la obtención del EEG distinguiendo el fenómeno ERD/ERS. Además se presentan los resultados de la detección de eventos musculares, reducción de ruido y artefactos y la obtención de la línea base.

5 Modelo propuesto para la detección, eliminación de ruido y artefactos en los eventos ERD/ERS.

5.1 Experimentos.

Se han diseñado experimentos para la obtención de ciertos eventos mentales y musculares con buenos resultados siguiendo un protocolo sencillo de adquisición [6][56][75][5][76]. El protocolo que se siguió para la obtención del ERD/ERS es un poco más relajado que para el fenómeno P300 [56][75][5]. En el experimento de [75], el sujeto debería estar aislado en cuarto cerrado eliminando la mayor cantidad de estimulaciones visuales, auditivas y sensitivas, adicionalmente se le instruyó que estuviera completamente inmóvil en sus posibilidades. Para la obtención del ERD/ERS, en este experimento, el individuo no está aislado, con otras personas en el mismo cuarto y no se le instruye el permanecer completamente inmóvil.

5.2 Antecedentes.

Se han diseñado experimentos en busca de la activación de eventos cerebrales como el P300. Como se ha mencionado anteriormente P300 es el resultado de la activación de la zona central cerebral aproximadamente a los 300ms de ocurrido el elemento causante. Este elemento es un evento sorpresa al usuario. Tomando como ventaja la naturaleza del fenómeno P300 se aplicó un experimento que busca activarlo mediante una aplicación parecida a un juego de video que es mostrado al usuario. Esta aplicación consiste en una nave espacial a punto de destruir un poblado. Mediante la tecla de entrada se destruye esta nave de ataque. Los tiempos y la posición en los cuales aparece la nave no son conocidos por el usuario de tal manera que se estimule la aparición de la onda P300. Es necesario que el usuario se encuentre en un cuarto sin otras personas y aislado de estímulos visuales y auditivos. También se le instruye al usuario no moverse en todo lo posible. En la figura 5.1 se puede observar el momento en que el usuario recibe el estímulo y la forma en que la aplicación proporciona el elemento de retroalimentación al usuario y se ‘destruye’ la nave.

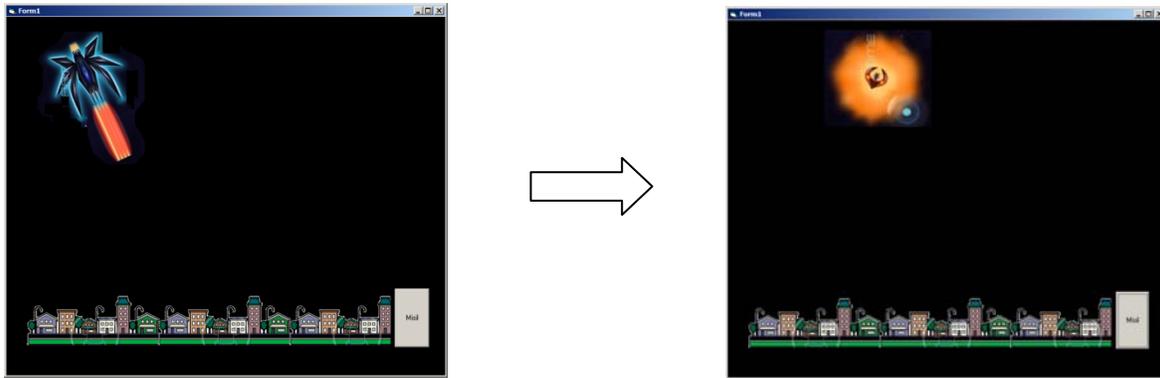


Figura 5.1. Estímulo para la activación de la onda P300.

El diagrama contenido en la figura 5.2 muestra la forma en que se procesó la señal EEG. Se considera que la señal es estacionaria mediante el uso de una ventana deslizante de 2 segundos de duración que cubre la máxima duración de este tipo de eventos P300. Al aplicar ICA (Independent Component Analysis) se considera la señal EEG como la suma de un conjunto de fuentes independientes dentro de la zona central de la cabeza [75]. El equipo de Emotiv (se explicará las características de este equipo en la siguiente sección) no incluye electrodos sobre el área central cerebral. Sin embargo, existen electrodos en la cercanía del área central: AF3, AF4, F3 y F4. A pesar de controlar el experimento aislando al usuario, la señal EEG se encuentra contaminada con ruido y artefactos. Se usará la información proveniente de los 14 electrodos disponibles como entrada al algoritmo de ICA. Típicamente la señal P300 aparece en el canal 2 a la salida de ICA.

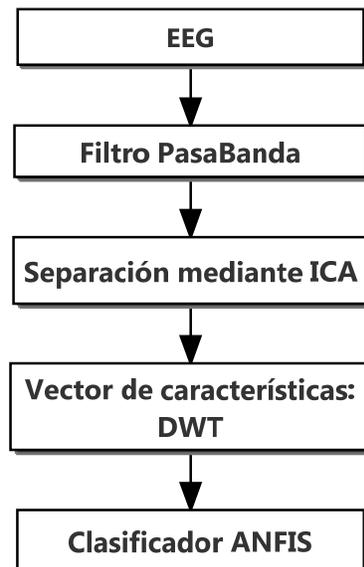


Figura 5.2. Detección de eventos P300.

Un análisis mediante transformada discreta wavelet es usado para localizar los picos de energía correspondientes al patrón de la onda P300. Se encontró adecuada el uso de la wavelet madre tipo Daubechies-4 [75] mediante valores de correlación entre la wavelet madre y la onda P300 dentro de la ventana de análisis. Se tomo en consideración dos puntos importantes en la elección de la wavelet madre: señales complejas requieren de wavelet madre compleja y la wavelet madre adecuada tendrá una forma parecida a la señal a analizar. La tabla 5.1 muestra una tabla comparativa incluyendo valores de correlación entre wavelets madre representativas de acuerdo a los dos puntos anteriores.

Tabla 5.1 Valores de correlación para elección de wavelet madre.

Ventana	DB4	Coif 4	Sym 4
1	0.85	0.76	0.81
2	0.9	0.66	0.83
3	0.75	0.64	0.77
4	0.96	0.83	0.9
5	0.9	0.81	0.88
6	0.91	0.87	0.92
7	0.86	0.83	0.84
8	0.63	0.58	0.61
9	0.95	0.82	0.87
10	0.77	0.78	0.75
11	0.67	0.55	0.74
12	0.86	0.72	0.83
13	0.59	0.54	0.56
14	0.93	0.77	0.89
15	0.78	0.81	0.83
16	0.97	0.88	0.93
17	0.71	0.77	0.74
18	0.82	0.66	0.71
19	0.56	0.79	0.72

La onda P300 muestra un patrón conformado por energía proveniente de las bandas 8-4, 4-2, 2-1 y 1-0.5 Hz por lo que se requerirán 11 niveles de descomposición tomando en cuenta una frecuencia de muestreo de 128 muestras por segundo. Estas cuatro bandas se han etiquetado como variables lingüísticas B1, B2, B3 y B4 respectivamente (ver figura 5.3). ANFIS es usado para mapear la composición de la señal P300 a un conjunto de pulsos triangulares cuyo pico ocurre al mismo tiempo que se envía el estímulo al usuario. Se aplicó el experimento a un conjunto de 8 usuarios en segmentos de 10 eventos con duración de 16 segundos.

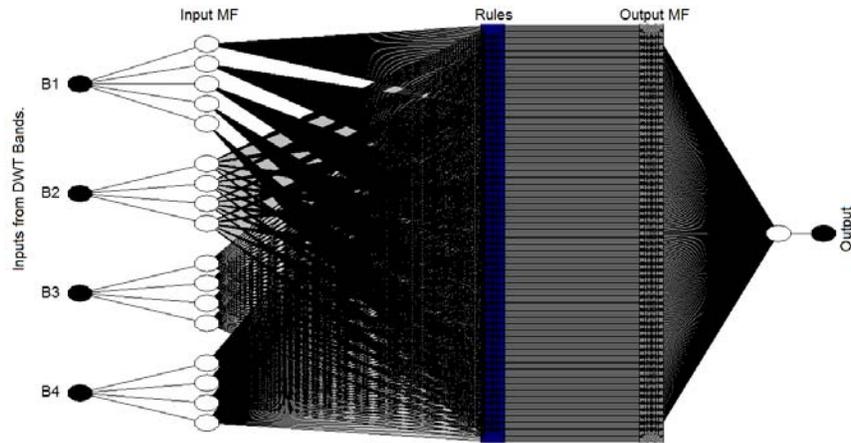


Figura 5.3. Entrenamiento de ANFIS como clasificador [75].

La figura 5.4 muestra la salida de ANFIS después del entrenamiento, obsérvese el incremento de la amplitud cuando un evento P300 está ocurriendo. El pico de la onda triangular indica el momento en que el estímulo es mostrado al usuario. En este caso, existen estímulos en las muestras 384, 768, 1152 y 1920.

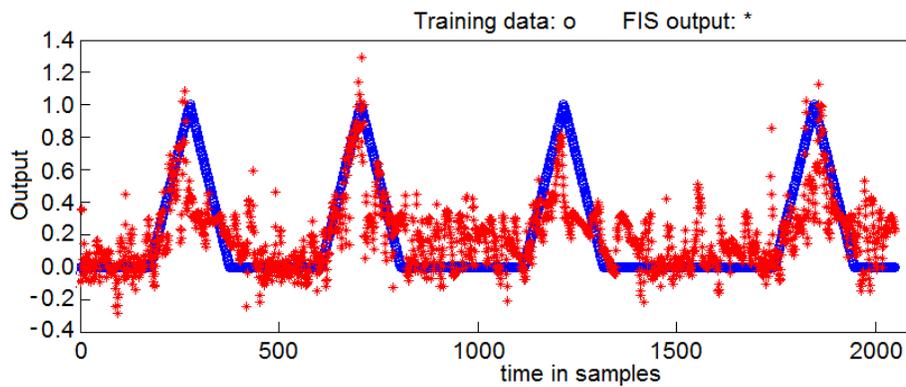


Figura 5.4. Salida de ANFIS después de entrenamiento [75].

La figura 5.5 muestra la forma y los elementos involucrados durante la aplicación del experimento. Se obtuvo un desempeño de hasta el 85% en la detección de eventos P300.



Figura 5.5. Experimento P300.

5.3 Montaje para estimulación y adquisición de la señal EEG.

El equipo de adquisición de datos es el casco de Emotiv [77] que cuenta con 14 electrodos distribuidos de acuerdo a la figura 5.6 tomando como referencia el sistema 10-20 extendido.

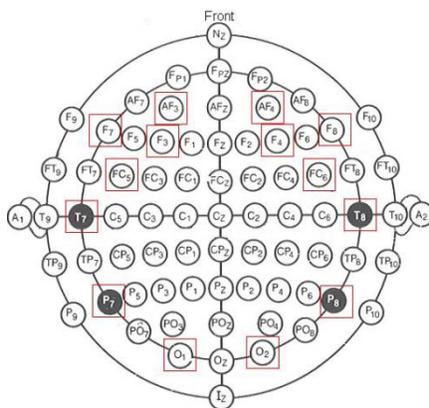


Figura 5.6 Electrodo disponibles en el sistema Emotiv (remarcados en cuadros).

Este equipo representa una alternativa práctica y económica para el desarrollo de aplicaciones basadas en EEG en comparación a equipos médicos de más de 100 electrodos. Tiene algunos inconvenientes como que, en algunas ocasiones, se tenga contacto pobre entre el electrodo y la piel, además de que está basado en electrodos húmedos. El diagrama de la figura 5.7 muestra los elementos necesarios para la adquisición del EEG para el experimento de generación de ERD/ERS así como el flujo de información.

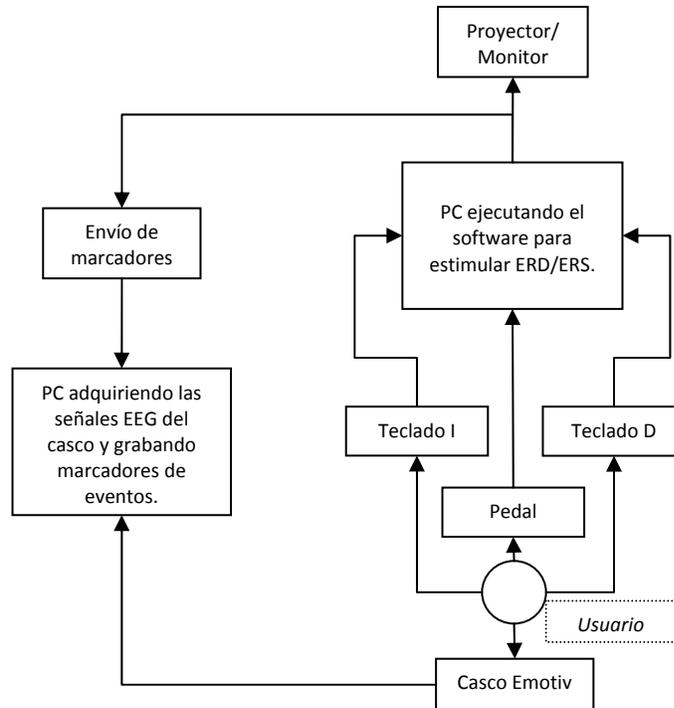


Figura 5.7. Componentes del sistema para generar eventos ERD/ERS.

5.4 Protocolo experimental para eventos ERD/ERS.

El experimento consiste de tres etapas, las cuales consisten en presentar una serie de comandos que el usuario bajo prueba deberá seguir. La persona deberá estar calmada y en una posición cómoda tratando de no realizar movimientos musculares diferentes a los que se le presentan en la pantalla pero con comportamiento natural. Los comandos son eventos muy sencillos de tres tipos:

- Movimiento dedo izquierdo
- Movimiento dedo derecho
- Movimiento pie

El elemento sensor para detección de movimiento en la mano derecha e izquierda es un teclado simplificado con interfaz USB. El usuario será instruido para que presione la tecla de entrada como señalización del evento muscular. Para la detección de movimiento de pie se construyó un interruptor con base inclinada para el descanso del pie. Este interruptor se conecta a una tarjeta con interfaz USB (ver figura 5.8).

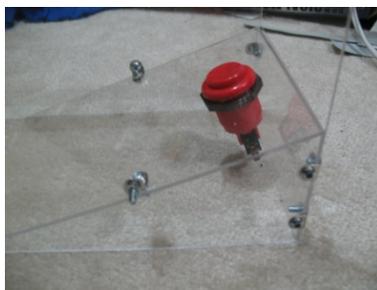


Figura 5.8. Interruptor de pie para envío de marcadores al equipo EEG.

5.4.1 Primera etapa del experimento ERD/ERS.

La base para la generación de eventos ERD/ERS es una aplicación de software que va instruyendo al usuario si debe accionar el teclado de la mano derecha, el teclado de la mano izquierda o el interruptor de pie (cue). En la primera etapa la aplicación presentará al usuario el comando a realizar clara y gráficamente esperando la respuesta del usuario mediante la activación del teclado o del interruptor según sea el caso. Uno de los puntos importantes es la presentación al usuario de la retroalimentación que indica que ha realizado con éxito el movimiento. Esta es una de las principales condiciones que de acuerdo a [78] permite construir interfaces cerebro-computadora sin requerir, o con muy poco, entrenamiento por parte del usuario.



Figura 5.9. Ejemplo de comando y retroalimentación al usuario.

Una vez que el usuario realizó el movimiento y la computadora lo ha detectado, la aplicación presentará un mensaje de retroalimentación 500ms después para dar a conocer que se ha grabado el evento (figura 5.9). En la figura 5.10 se muestran los 3 comandos para generar eventos motrices. Ninguno de los 3 es del tipo sostenido, es decir, se espera que la respuesta de la banda beta sea inmediata a la terminación de gamma.

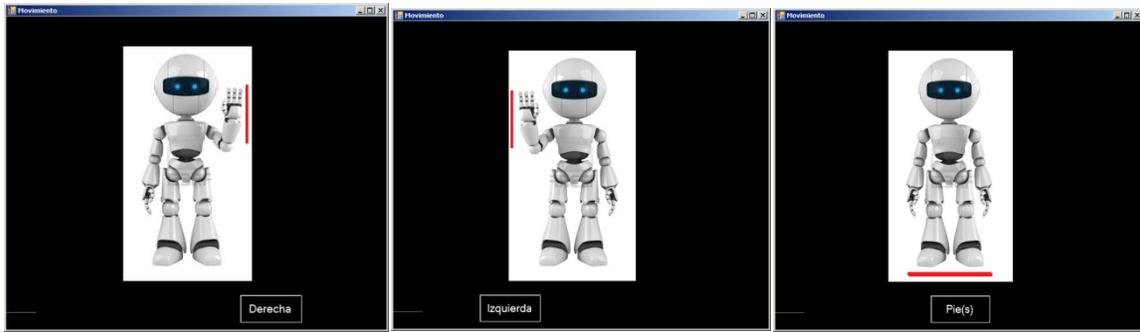


Figura 5.10 Comandos derecha, izquierda y pie para generar eventos motrices.

5.4.2 Segunda etapa del experimento ERD/ERS.

En la segunda parte del experimento, utilizando los mismos elementos de hardware, se usará mano izquierda o mano derecha dependiendo del evento en la secuencia presentada por la aplicación. Esta tiene como objetivo reforzar aún más los cambios en las bandas en comparación con la primera parte del experimento. Para llevar a cabo este reforzamiento se provoca en el usuario un aumento en el razonamiento en el momento de realizar el movimiento. La elaboración de la aplicación de software incluye dos tipos de naves que deben ser destruidas de acuerdo a su tamaño. Se tienen dos posibles armas láser y misil que corresponde a la nave azul pequeña o a la nave roja grande. Si se presenta una nave azul pequeña se deberá usar el láser para destruirla, es decir, realizar un movimiento con la mano derecha (figura 5.11).

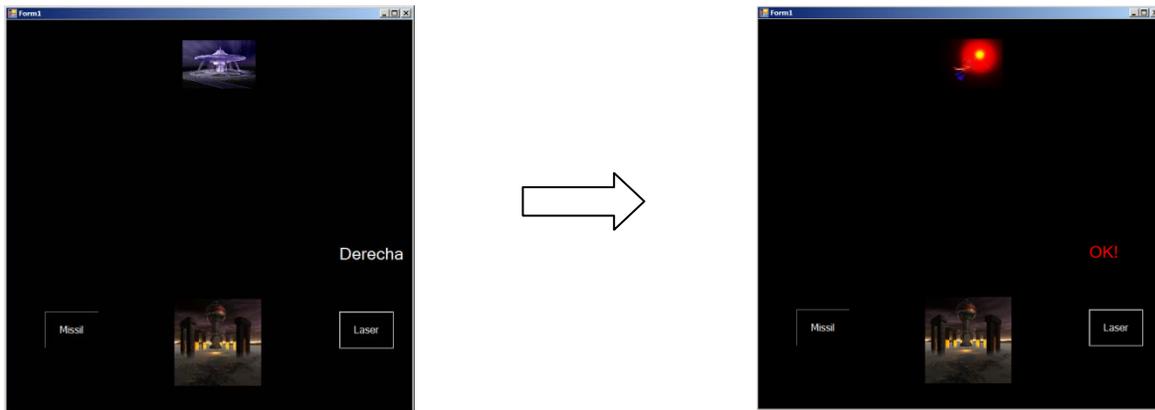


Figura 5.11. Movimiento mano derecha.

Una caja de texto aparece especificando que mano debe usar para mayor claridad. De la misma manera que la aplicación anterior, a los 500ms se le presentará al usuario un mensaje de retroalimentación. Igualmente que para la mano derecha, se presenta una nave de mayor tamaño de color naranja, la cual deberá ser destruida con un misil lo que corresponde a realizar un movimiento de mano izquierda (figura 5.12).

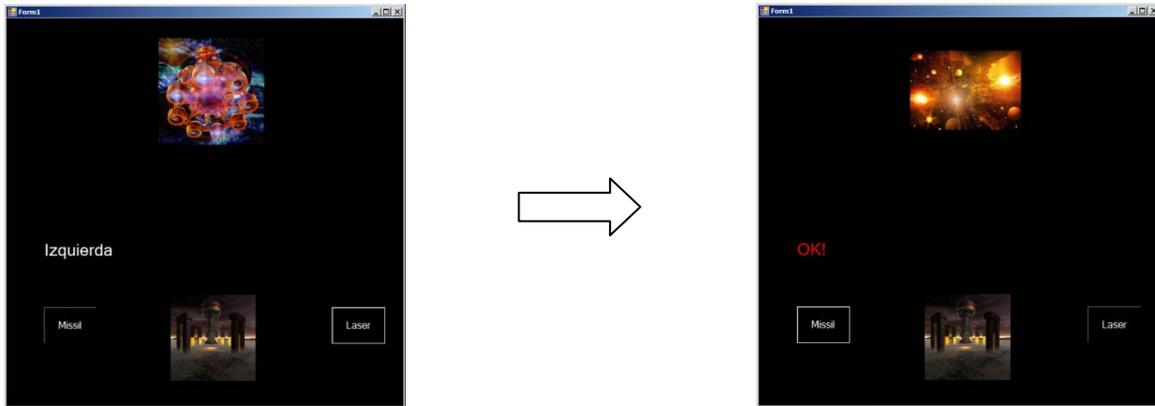


Figura 5.12. Movimiento mano izquierda, segunda etapa del experimento.

5.4.3 Tercera etapa del experimento ERD/ERS.

El motivo de la tercera etapa es el análisis de movimientos sostenidos. Se esperaba una desincronización normal pero con la terminación de movimiento retrasada, lo que implica un retraso en el aumento de la banda beta. De la misma manera se le instruye al usuario de mantener su mano derecha o izquierda cerrada o flexionar su pie durante un lapso de 4 segundos los cuales serán remarcados por la aplicación hasta que se le pida abrir su mano. En la figura 5.13-5-15 se muestra el procedimiento, de la misma manera se envía retroalimentación al usuario en cada paso del proceso.



Figura 5.13. Movimiento sostenido de mano derecha con retroalimentación a los 4 segundos.



Figura 5.14. Movimiento sostenido de mano izquierda con retroalimentación a los 4 segundos.



Figura 5.15. Movimiento sostenido de pie con retroalimentación a los 4 segundos.

5.5 ERD/ERS Imaginario.

El experimento incluye un ciclo adicional incluyendo las tres etapas del experimento pero ahora se enfocará en el fenómeno muscular imaginario. Este fenómeno como se había explicado anteriormente, implica, el imaginar que se está realizando el movimiento. Cada una de las bandas reaccionará de la misma manera pero se espera una disminución en el cambio de cada una de sus potencias. De la misma manera se enviará un marcador al sistema de adquisición que se tomará sólo como referencia temporal debido a que es muy difícil saber el momento en que el usuario imaginará realizar el movimiento. Los eventos imaginarios-musculares dependen de la imaginación del usuario por lo que será más complicado que desencadene el fenómeno ERD/ERS.

El casco de Emotiv sólo cuenta con 2 electrodos sobre el área motriz por lo que usando el mismo equipo se colocará el casco en desfase con el estándar 10-20. Este desfase sería del 10% girado hacia arriba para que, por ejemplo, los electrodos AF3 y AF4 coincidan con F3 y F4. De esta forma se puede analizar el cambio de potencia en el área motriz y en específico la zona que corresponde o controlan los pies. En la figura 5.16 se muestra el

sistema completo para llevar a cabo el experimento y el ambiente en el cual se tomaron alguna de las muestras EEG.

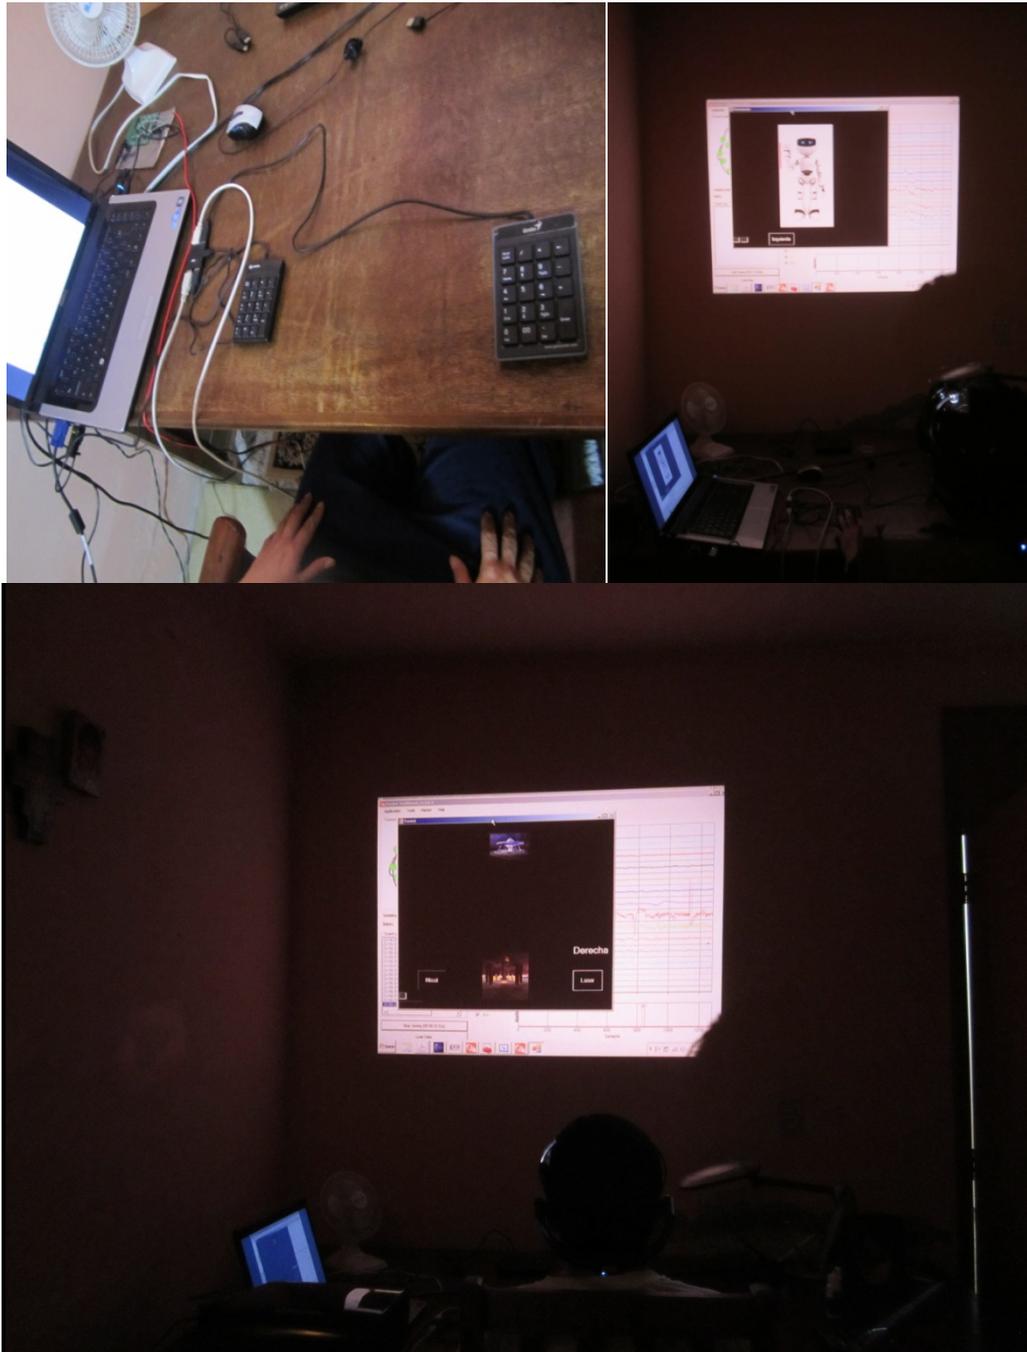


Figura 5.16. Sujeto de prueba durante el experimento ERD/ERS.

5.6 Base de datos EEG PhysioBank para eventos ERD/ERS.

Una de las más grandes bases de datos fisiológicas disponibles y siempre en constante crecimiento es PhysioBank [83]. Esta base de datos contiene un conjunto de archivos digitales de señales fisiológicas tales como neurales, cardíacas, pulmonares, miográficas, etc., provenientes de personas saludables y de pacientes con ciertos padecimientos como epilepsia, apnea del sueño, enfermedades cardíacas. PhysioBank posee datos EEG de eventos musculares y musculares imaginarios usando el sistema BCI2000 [84] con 64 canales disponibles (figura 5.17). Por los anteriores argumentos se usará esta base de datos en las siguientes secciones para establecer adecuadamente un punto de comparación para el sistema propuesto.

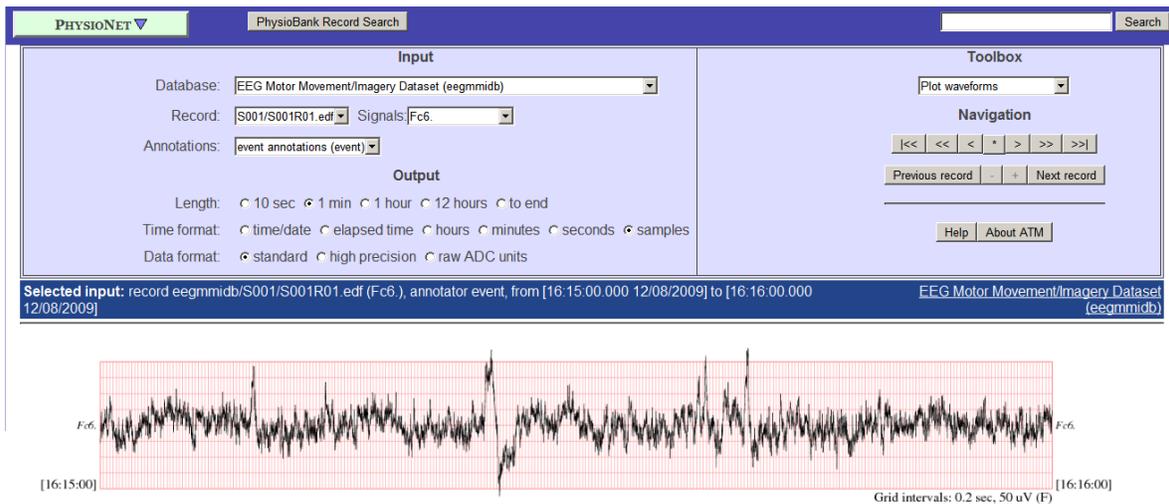


Figura 5.17. PhysioNet - Interfaz para el manejo de la base de datos PhysioBank

5.6.1 Montaje de PhysioBank para estimulación y adquisición de la señal EEG.

El equipo de adquisición de EEG cuenta con 64 electrodos siguiendo el sistema internacional 10-10 (sin los electrodos Nz, F9, F10, FT9, FT10, A1, A2, TP9, TP10, P9 y P10) de acuerdo a la figura 5.18. La frecuencia de muestreo disponible al usuario para este equipo es de 160 muestras por segundo.

5.6.2 Protocolo experimental de PhysioBank para eventos ERD/ERS.

Cada sujeto es sometido a 14 secuencias de eventos en paquetes de dos y tres minutos:

Dos minutos para línea base, incluyendo, ojos abiertos y ojos cerrados.

Tres minutos para 4 diferentes actividades:

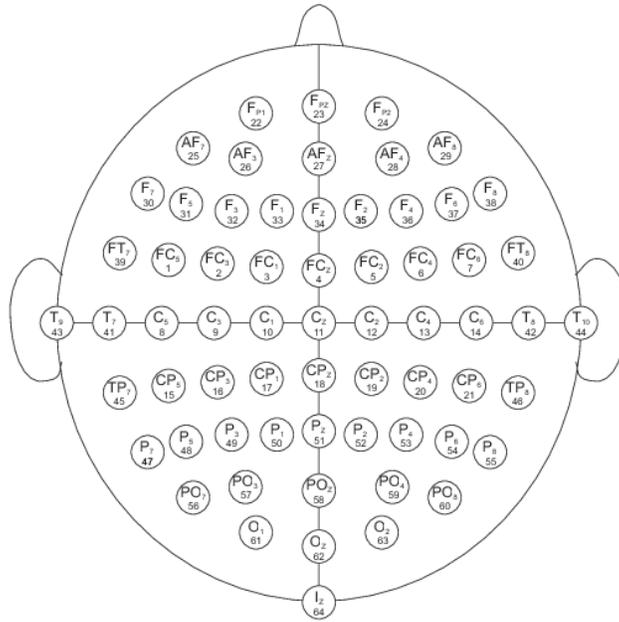


Figura 5.18. Electrodo disponible en el equipo de PhysioBank.

- Actividad 1 – 2. Un objeto aparece, ya sea del lado derecho o izquierdo de la pantalla. El sujeto abre y cierra la mano hasta que el objeto desaparece para después permanecer en descanso.
- Actividad 3. Un objeto aparece en la parte de arriba o baja de la pantalla. El sujeto abre y cierra ambas manos, si el objeto está en la parte de arriba, o ambos pies, si se encuentra en la parte de abajo, hasta que el objeto desaparece. Después permanece en descanso.
- Actividad 4. Un objeto aparece ya sea en la parte de arriba o baja de la pantalla. El sujeto imagina abrir y cerrar ambas manos, si el objeto está en la parte de arriba, o ambos pies, si se encuentra en la parte de abajo, hasta que el objeto desaparece. Después permanece en descanso.

5.7 Descomposición EMD/MEMD.

A pesar de las múltiples ventajas de la descomposición EMD, en el caso de sistemas multivariable surgen algunos problemas en su análisis como el modo mezclado y diferente número de escalas. En la figuras 5.19-5.21 se muestran las 5 primeras descomposiciones EMD para la información de los electrodos FC6, F4 y F8 respectivamente. Esta secuencia contiene información de un evento ERD/ERS provenientes de la base de datos. Como es de esperarse se obtienen diferente número de escalas (IMF) 8, 8 y 7 para los electrodos FC6,

F4 y F8. También se observa desfaseamiento en los modos oscilatorios así como un filtrado relativo entre canales de la información de una escala a otra.

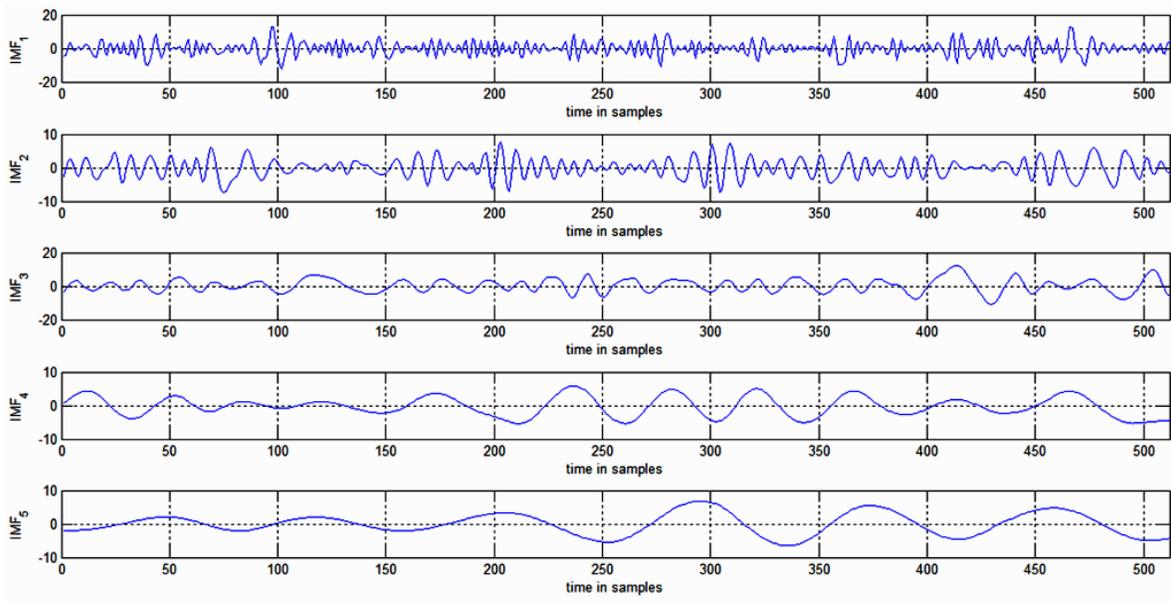


Figura 5.19 Descomposición EMD para FC6.

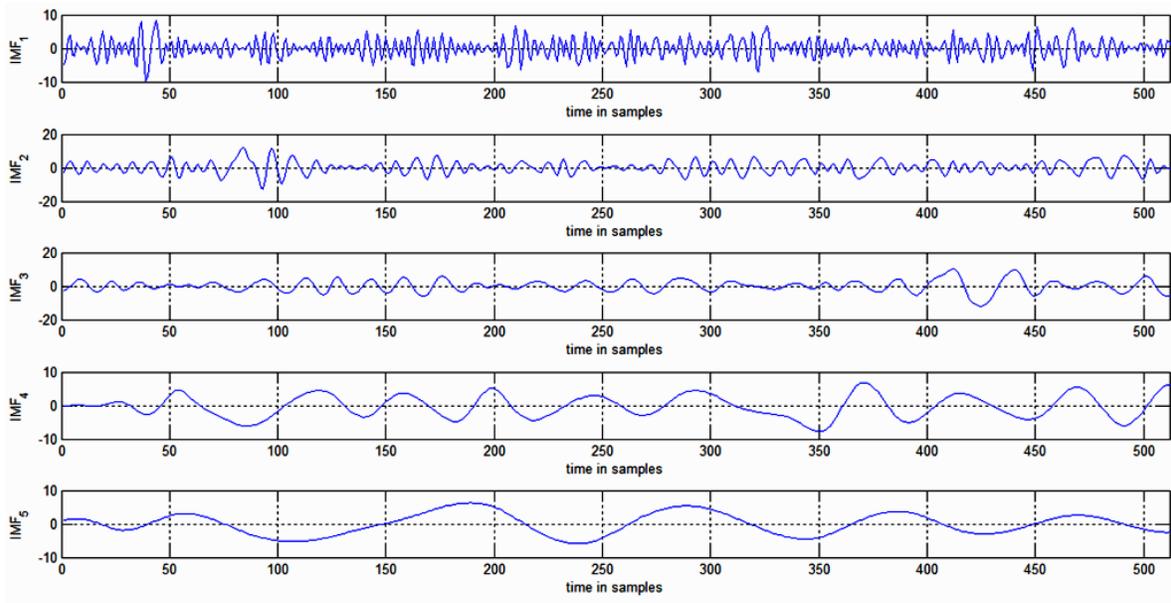


Figura 5.20 Descomposición EMD para F4.

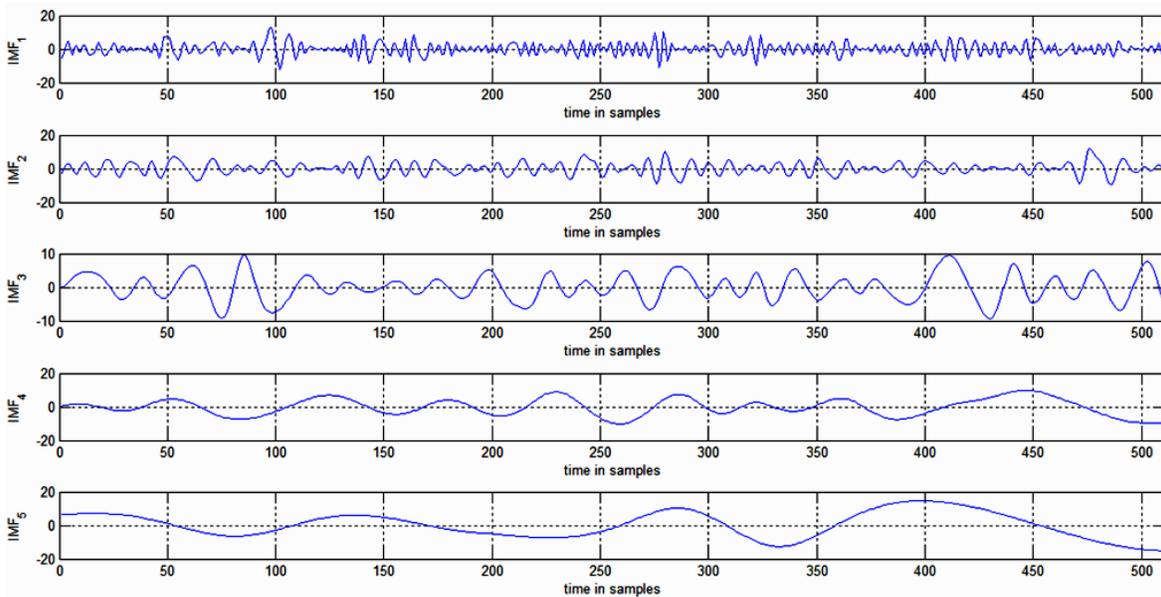


Figura 5.21 Descomposición EMD para F8.

Por motivos de comparación se realizará la descomposición de la misma secuencia EEG conteniendo el mismo evento ERD/ERS de la base de datos pero en esta ocasión mediante MEMD. La MEMD usa las series de Hammersley muestreando sobre una hipersfera unitaria [65]. En las figuras 5.22 a la 5.24 se puede notar que no existe modo mezclado, sin filtrado de información entre escalas, sin desfaseamiento y con el mismo número de escalas 9, 9 y 9 para FC6, F4 Y F8 respectivamente.

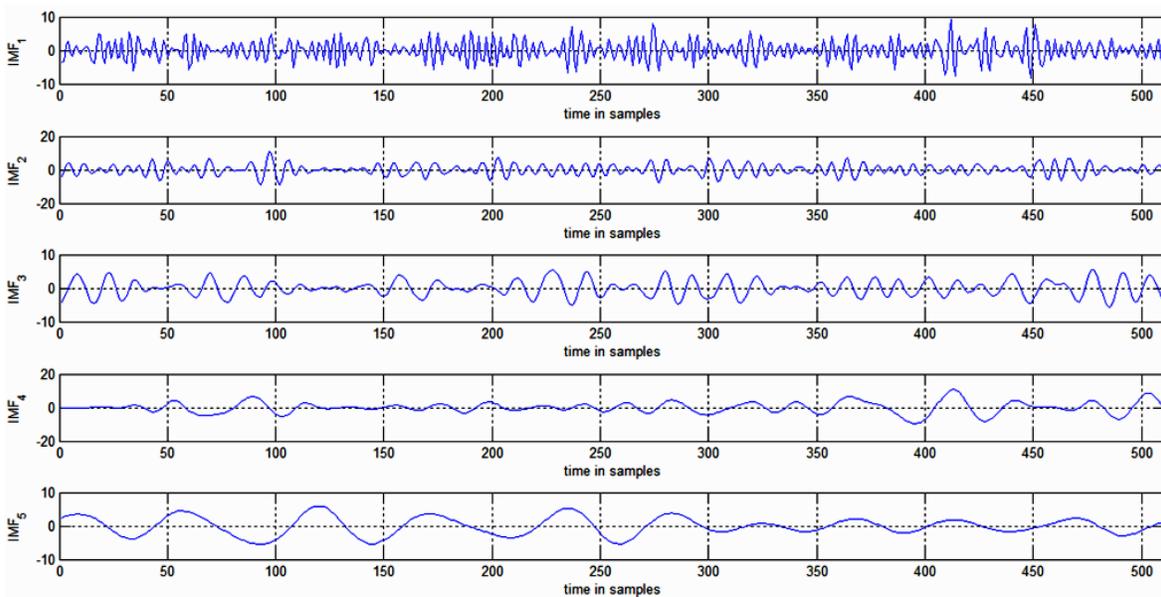


Figura 5.22 Descomposición EMD para FC6.

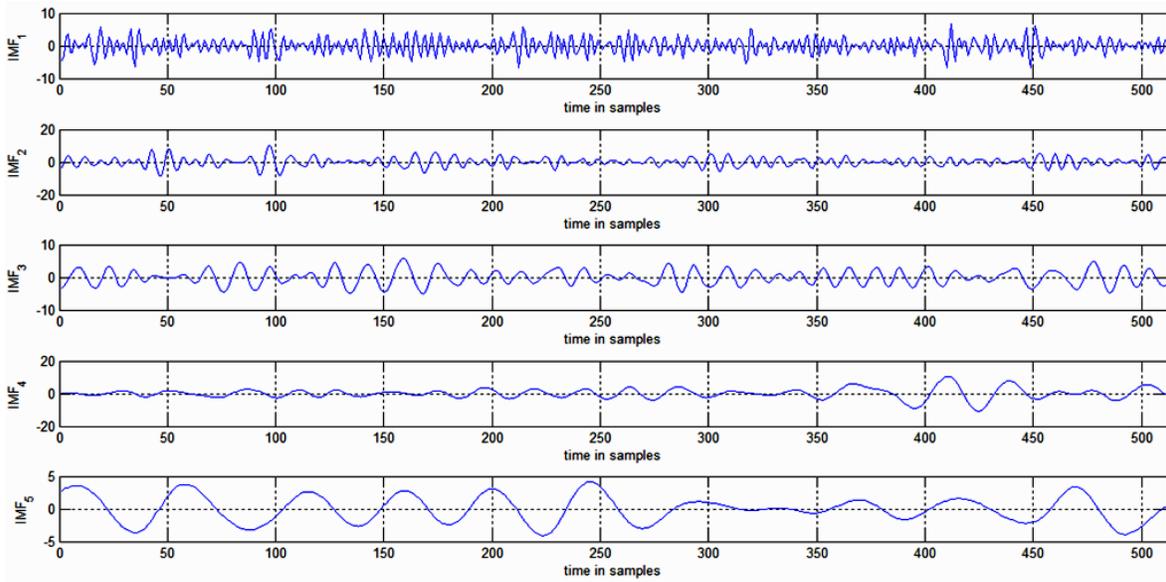


Figura 5.23 Descomposición MEMD para F4.

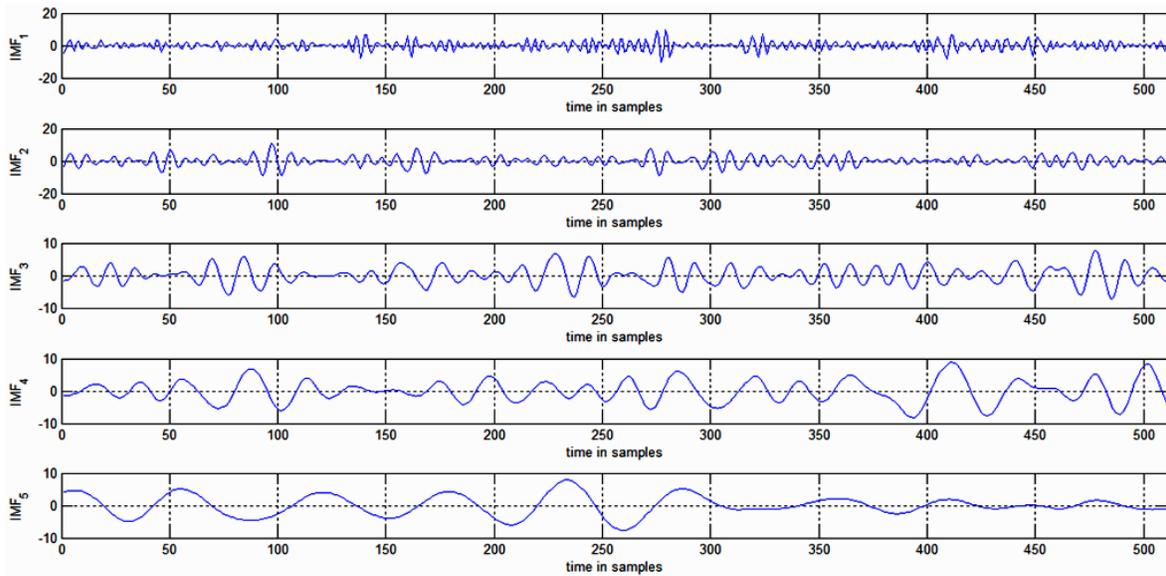


Figura 5.24. Descomposición MEMD para F8.

Con las mismas ventajas para el manejo de señales no-estacionarias, la MEMD resuelve el problema del análisis multivariado con la EMD simple. Esto permite mejorar el algoritmo de reducción de ruido propuesto en [6].

5.8 Reducción de ruido.

El algoritmo de reducción de ruido y artefactos propuesto y descrito en la sección 4.2 ha sido exitosamente aplicado en [6] tomando como base la descomposición EMD. Es posible realizar una comparación usando el mismo algoritmo de reducción de ruido pero con la

diferencia de que las descomposiciones provendrán de la MEMD aplicado a los mismos datos de entrada de [6] y bajo las mismas condiciones. La figura 5.25 a-c muestra la descomposición MEMD y la descomposición EMD 5.25 d-f para los mismos 3 electrodos alejados entre sí, a saber, FC5, P7 y P8, tomando como referencia AF3. Existe una considerable cantidad de ruido producto del movimiento de la cabeza especialmente alrededor de la muestra 200. El evento de interés está ocurriendo en la muestra 1200. Visualmente se puede apreciar que el algoritmo de reducción de ruido presentará problemas en la IMF2 ya que a pesar de ser semejantes para todos los electrodos, la correlación será mínima y el módulo de integración tomará una decisión incorrecta. Se establece una comparación numérica usando los valores de correlación de 5 sujetos bajo prueba en la tabla 5.1. Sólo se muestran los valores promedios para fines de ilustración incluyendo los valores para la EMD y MEMD. La primera columna W_i designa el número de ventana bajo análisis. La tercera columna muestra la diferencia total en detección correcta de IMFs consideradas ruido entre la EMD y MEMD. Esta diferencia determinará el aumento en rendimiento tomando como base de descomposición la MEMD.

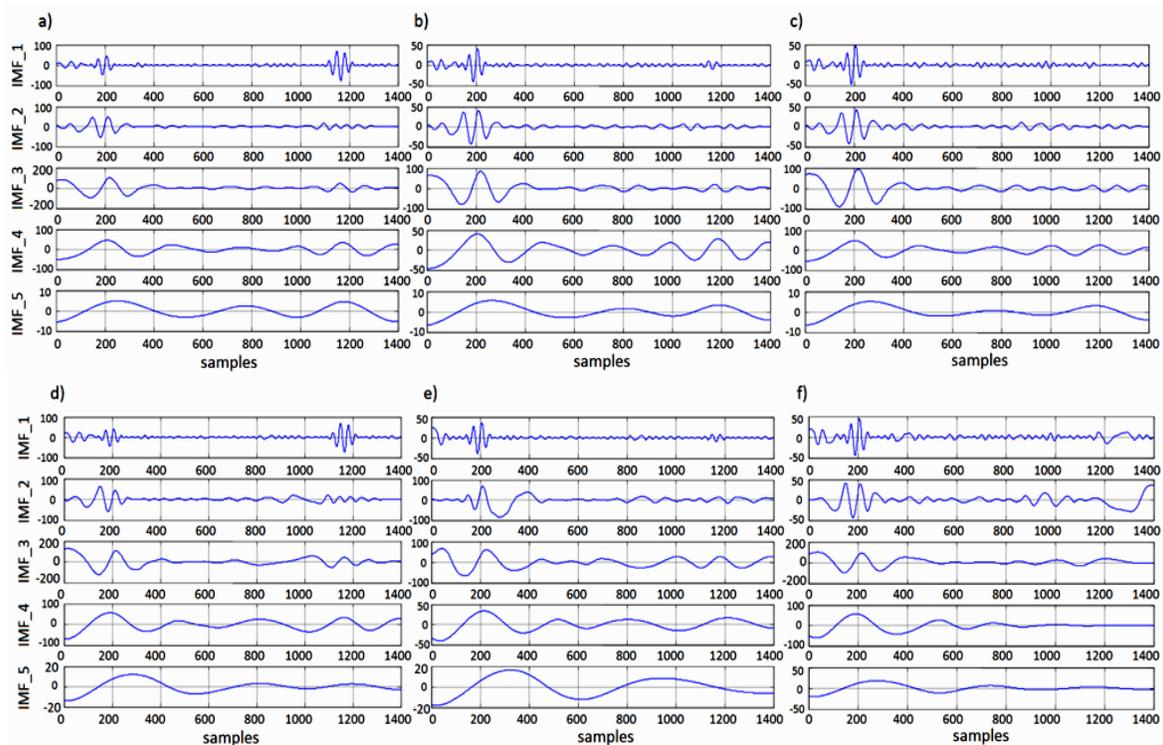


Figura 5.25. Descomposiciones MEMD (a-c) y EMD (d-f) para la secuencia de [6].

Tabla 5.2 Valores de correlación y el aumento en detección de ruido usando MEMD.

	<i>MEMD</i>	<i>EMD</i>	<i>Diferencia en detección</i>
W1	0.968166667	0.9244	0

W2	0.702333333	0.497066667	0
W3	0.566133333	0.556233333	0
W4	0.754766667	0.753986667	0
W5	0.586333333	0.430566667	0
W6	0.539866667	0.472833333	0
W7	0.978766667	0.7537	0
W8	0.809666667	0.4215	1
W9	0.784933333	0.5146	1
W10	0.63242	0.550353333	0
W11	0.6492	0.193033333	0
W12	0.8048	0.431333333	1
W13	0.9951	0.957533333	0
W14	0.995533333	0.386166667	2
W15	0.956633333	0.695266667	2
W16	0.8152	0.580393333	2
W17	0.891066667	0.467066667	2
W18	0.952233333	0.557566667	2
W19	0.997066667	0.971566667	0
W20	0.994433333	0.810966667	0
W21	0.972033333	0.883133333	0
W22	0.818986667	0.49436	1
W23	0.811133333	0.596533333	1
W24	0.976833333	0.948566667	0
W25	0.9995	0.9973	0
W26	0.998066667	0.971266667	0
W27	0.986466667	0.712033333	0
W28	0.830753333	0.712606667	0
W29	0.979866667	0.575333333	1
W30	0.999533333	0.9929	0
Total			16

5.9 Discusión.

Se tiene una mejora de 16 eventos correctamente detectados como ruido. Considerando un conjunto de 108 eventos totales se tiene una mejora del aproximadamente 14.81% en la razón señal a ruido ponderando en forma unitaria cada uno de los segmentos. Esta propuesta provee de una mejora significativa a métodos basados puramente en niveles de confianza de la amplitud de la señal [71]; separar el ruido de las señales EEG por bandas de frecuencia [79] mediante transformada wavelet que podría eliminar una cantidad

importante de información de los eventos que se desea detectar; con transformada wavelet pero agregando información muscular con electrodos adicionales [80]; con algoritmos como ICA que, además de su complejidad, se deben cumplir tamaños de ventana adecuados y con una gran cantidad de electrodos involucrados [81]. ANFIS ha probado ser una buena elección para eliminar ruido [5] pero involucra un tiempo considerable de entrenamiento [82]. En muchas ocasiones se consideran condiciones de laboratorio por lo que no es necesario realizar este tipo de pre-procesamiento para eliminación de ruido y artefactos.

5.10 Línea base.

Como parte de esta propuesta se incluye el uso del filtro Kalman como un elemento importante que nos permitirá analizar con mayor facilidad el cambio en la potencia para cada banda. La gráfica de la figura 5.26 muestra la descomposición MEMD de datos provenientes de una secuencia de la señal EEG del experimento descrito en este capítulo, después de la eliminación de ruido, específicamente de los electrodos FC6, F4 y F8, tomando a FC6 como referencia. El movimiento es de la mano izquierda no sostenido.

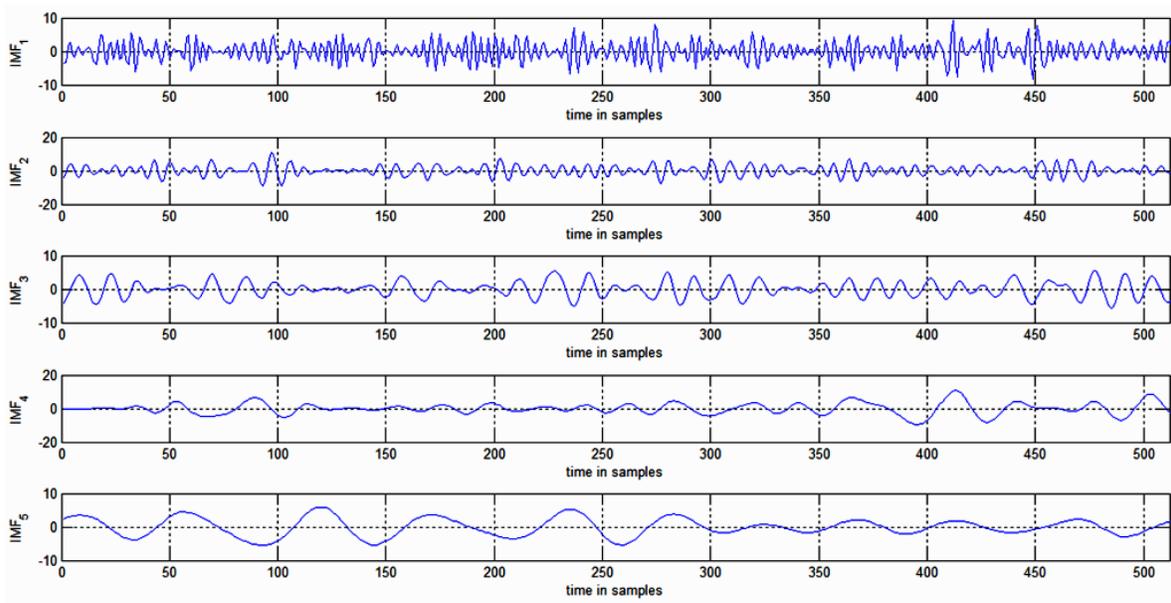


Figura 5.26. Descomposición MEMD incluyendo evento ERD/ERS.

Después de la descomposición podemos considerar a cada una de las IMFs como lineales y estacionarias que son unas de las principales condiciones de operación para el filtro Kalman. Las matrices de covarianza de ruido de proceso \mathbf{Q} y de covarianza de ruido de medición \mathbf{R} se asumirán constantes durante todo el experimento. Bajo las condiciones de que \mathbf{R} y \mathbf{Q} son constantes entonces la covarianza estimada del error \mathbf{P}_k y la ganancia de Kalman \mathbf{K}_k , se estabilizarán rápido y permanecerán constantes. Se considera que los ruidos de proceso y de medición son independientes entre sí y de distribución normal. Los valores de covarianza en la medición, muchas veces establecidos mediante prueba y error, se

encontraron mediante un procedimiento similar a la descomposición EMD. Se encuentran los puntos máximos de la señal de potencia. Tomando estos puntos como señal de referencia se traza una envolvente que será considerada como la media en los cambios de potencia para los eventos ERD/ERS. La figura 5.27 muestra una envolvente que será utilizada como valor medio para la obtención de las matrices de ruido de referencia.

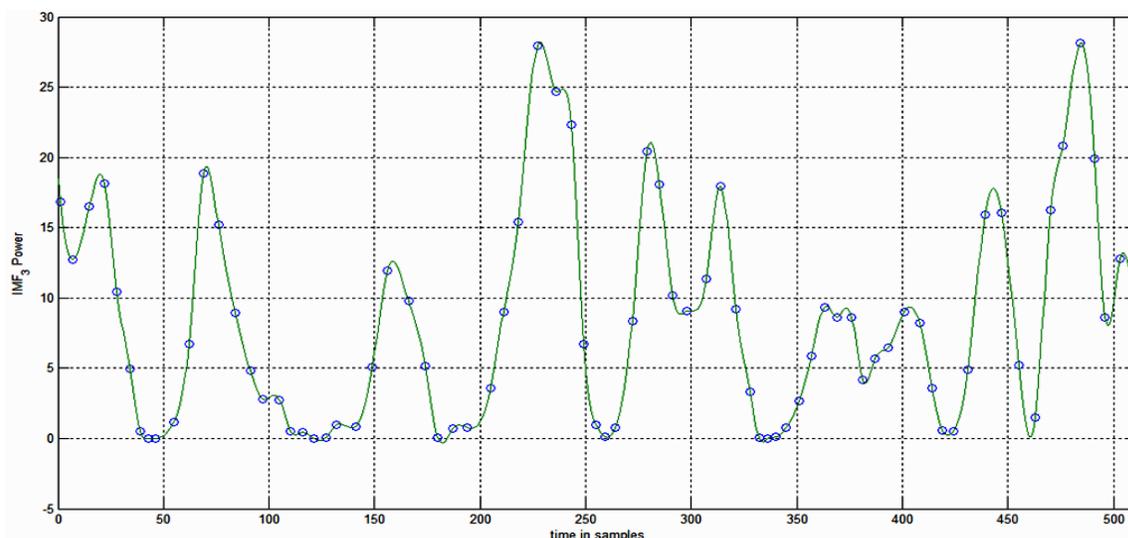


Figura 5.27. Envolvente ejemplo obtenida mediante spline cúbica.

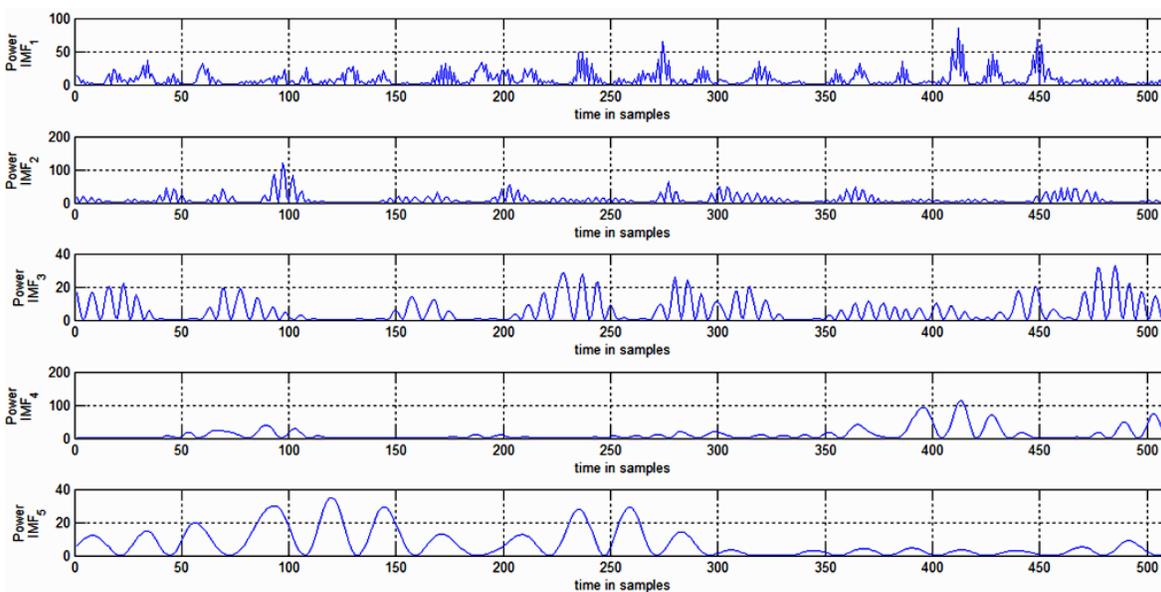


Figura 5.28. Variación de la potencia para las IMFs 1 a la 5.

Ya que se han definido todos los valores del modelo Kalman se procede a aplicar a cada una de las bandas. MEMD provee de una gran ventaja al no haber modo mezclado y entregar el mismo número de IMFs en su análisis multicanal. Este permite distinguir los

cambios gamma, beta y alfa en las IMFs 3, 4 y 5 respectivamente. En la figura 5.28 se pueden observar la variación de la potencia para las IMF 1 a la 5. En la figura 5.29 se puede notar visualmente la característica del fenómeno motriz: la desincronización implica una disminución de energía en todas las bandas (remarcado en rojo). Después de que el movimiento ha ocurrido se vuelven a resincronizar la potencias en las bandas.

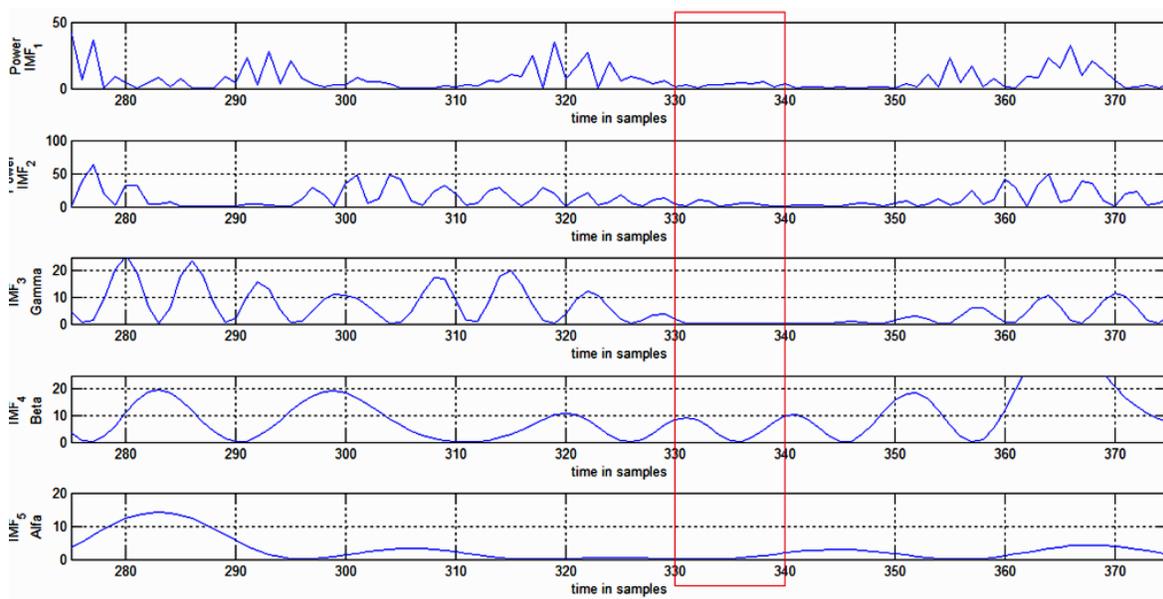


Figura 5.29. Desincronización relativa a evento motriz.

La figura 5.30 muestra el efecto del filtro Kalman sobre la variación para cada una de las bandas. Se puede observar que el evento ERD/ERS producto del movimiento de mano izquierda puede ser detectado aún visualmente.

5.11 Discusión.

Siguiendo la tendencia en esta propuesta del uso de algoritmos adaptables a los datos de entrada, con la aplicación del filtro Kalman ya no es necesario conocer el valor o rango de variación de la línea o valor base, reduce artefactos de otros procesos mentales y elimina la necesidad del promediado por ventana deslizante. El promediado por ventana deslizante es uno de los métodos más usados para la obtención de la variación de potencias o amplitudes de los fenómenos cerebrales. Con el tiempo se han venido usando otras opciones como filtro Kalman para eventos ERP como el P300 [85, 86, 87]. En [86] se demuestra claramente la ventaja de Kalman sobre promediado por ventana deslizante. Aunque en [85][86] se usa Kalman aún para señales no-estacionarias y por la misma razón queda confinado a tamaño de ventanas determinados, por ejemplo, por la duración del evento P300. Otra desventaja de [86][87] es que es necesario el modelado del P300, es decir, modelarlo como si fuese una planta a controlar.

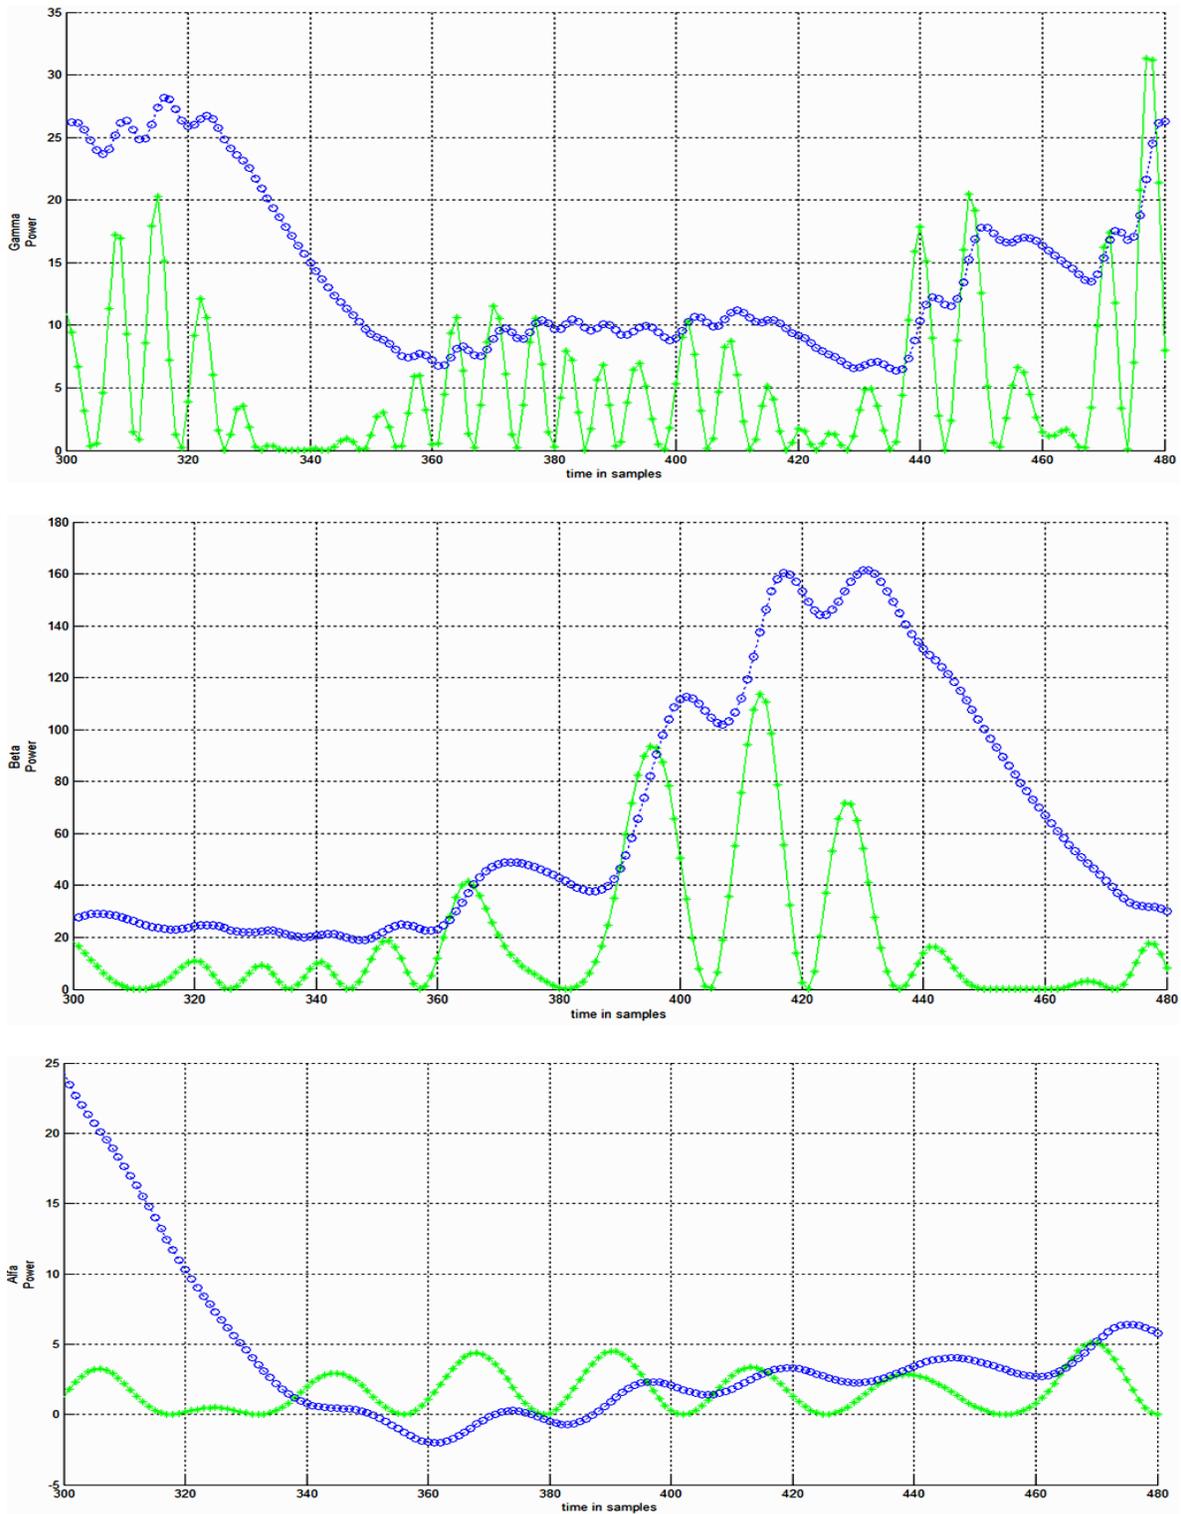


Figura 5.30. Evento ERD/ERS ocurriendo en la muestra 350. Línea verde es la variación de la potencia. Línea azul es la salida del filtro Kalman para cada banda.

Para eliminar la desventaja de los tamaños limitados de ventana en [88] se propone el uso del filtro partícula para el manejo adecuado de la característica no-estacionaria de la señal EEG, lo que implica un aumento considerable en la complejidad del algoritmo.

5.12 Clasificación.

Aprovechando el conocimiento médico como base de conocimientos y de que las variaciones que ocurren en el fenómeno ERD/ERS puedan ser descritas en lenguaje común, los sistemas de inferencia difusos pueden ser utilizados en forma casi directa como clasificadores de este tipo de eventos. En el capítulo anterior se describió el sistema de inferencia que se usará como clasificador definiendo la matriz tipo Toeplitz con $n=2$. De acuerdo a las tablas 4.1 y 4.2 que enlistan las reglas difusas, se construyen los sistemas de inferencia para la detección de los eventos ERD/ERS. Cabe recordar que es un sistema a dos pasos. El primer paso detecta la desincronización de acuerdo a la variación de las bandas. El segundo paso detectará la vuelta a sincronización de las bandas. Las reglas difusas y las curvas de relación para la detección de la desincronización se muestran gráficamente de la figura 5.31 a la 5.33 y para la sincronización de la 5.34 a 5.37.

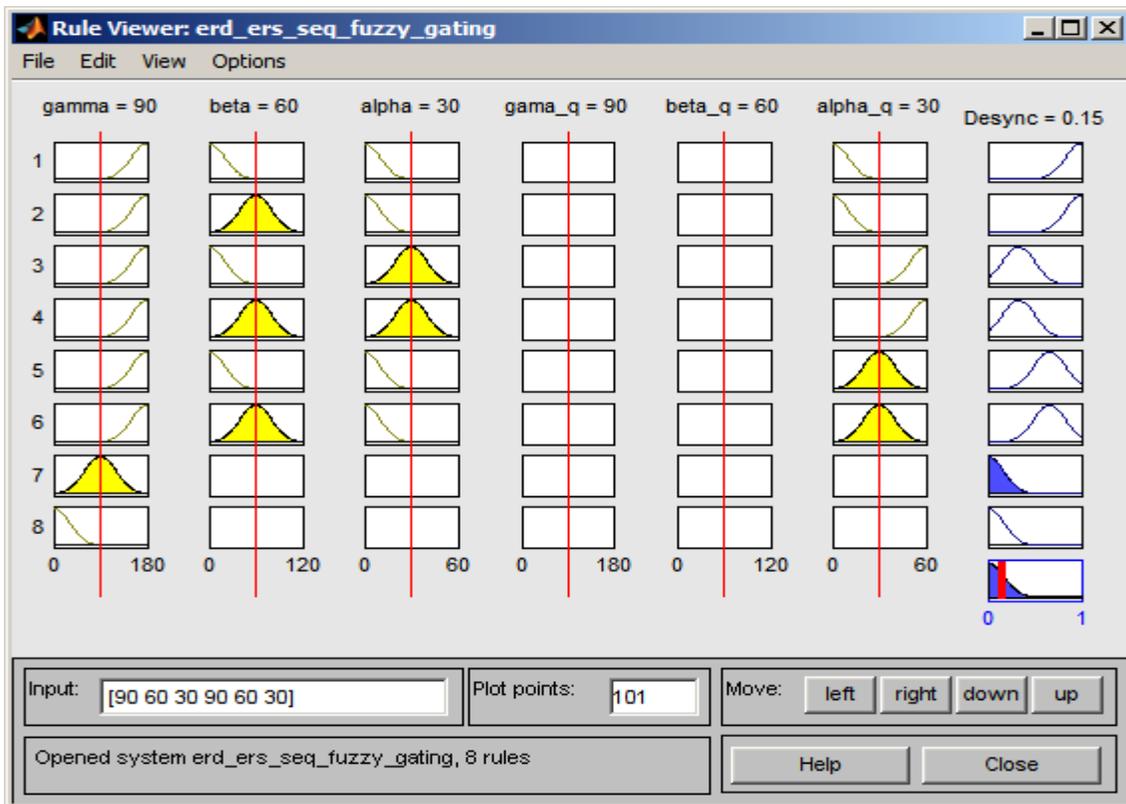


Figura 5.31. Gráfica de las reglas difusas para detección de desincronización.

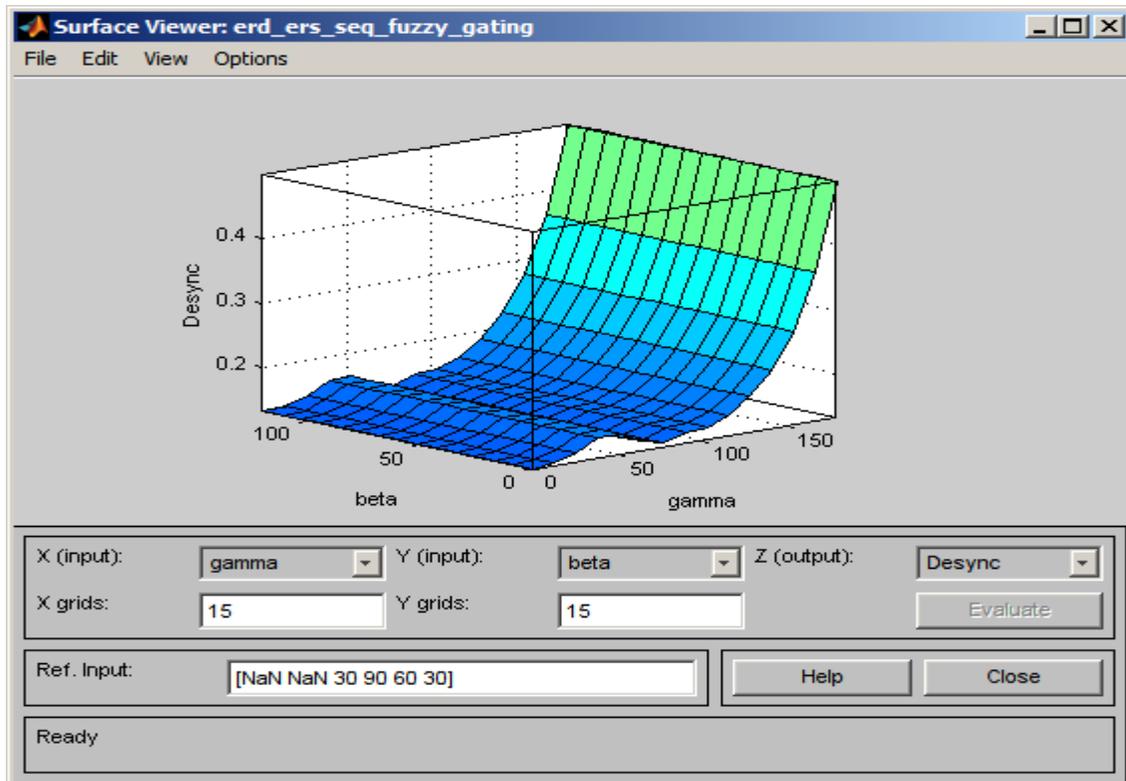


Figura 5.32. Gráfica de gamma vs beta en la etapa de desincronización.

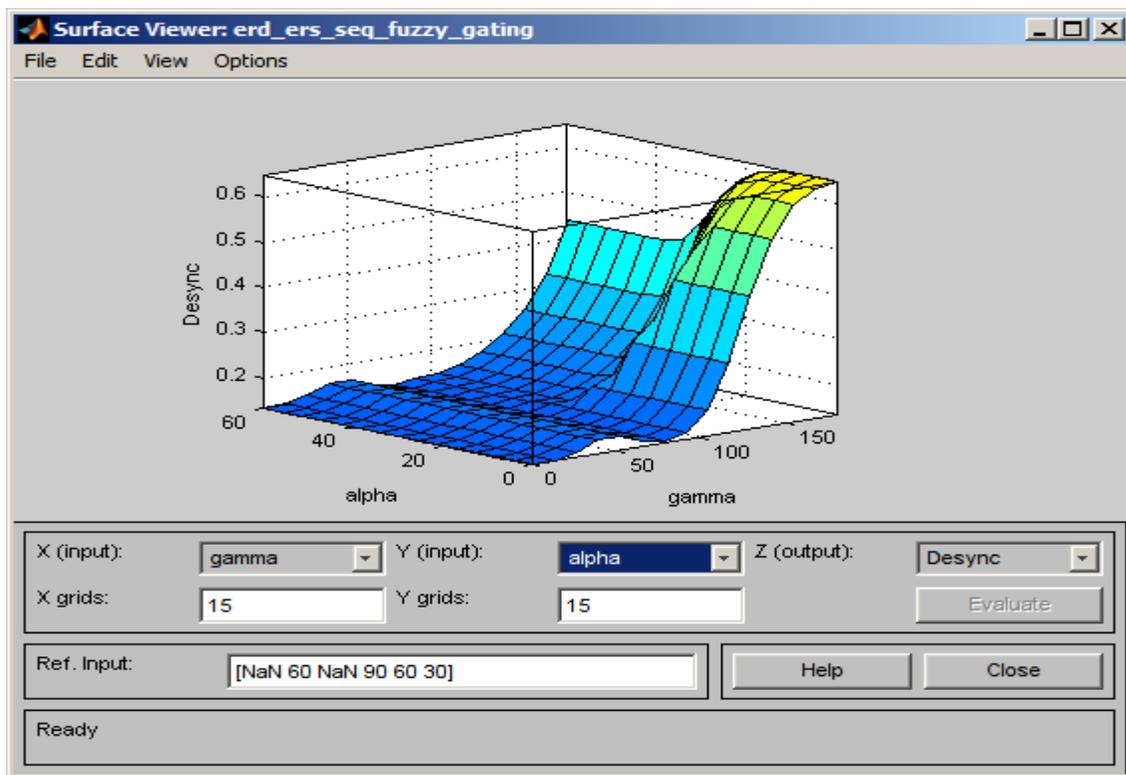


Figura 5.33. Gráfica de gamma vs alfa en la etapa de desincronización.

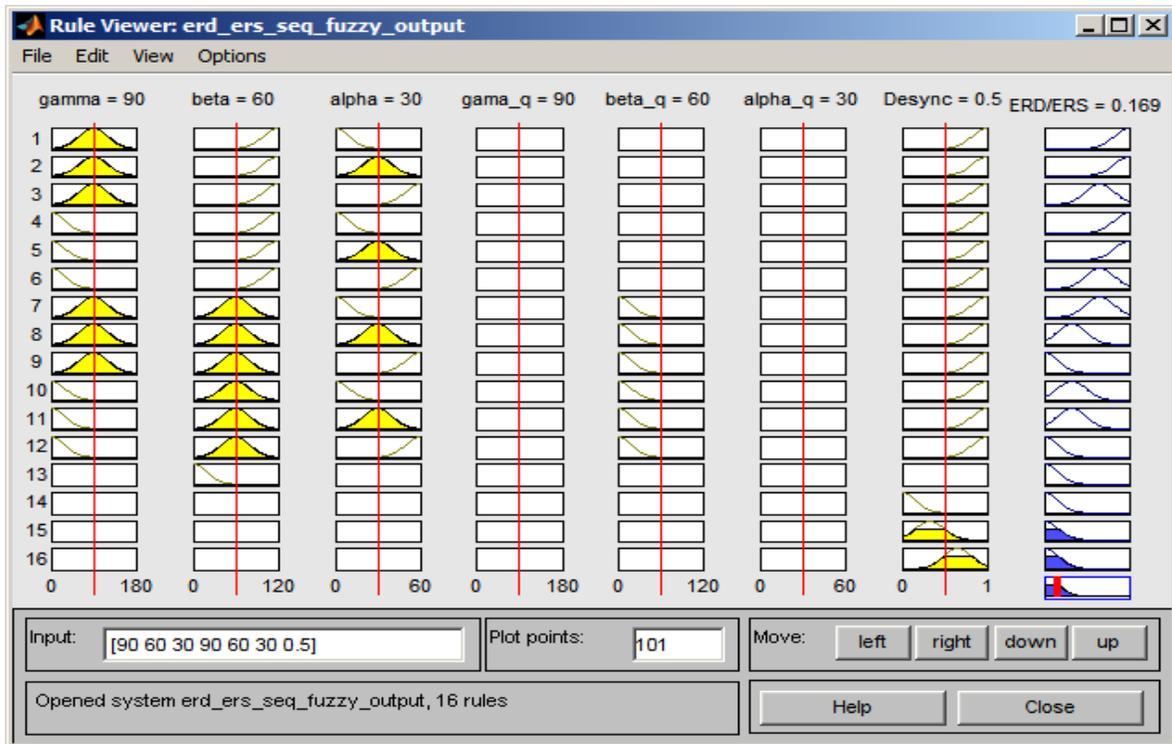


Figura 5.34. Gráfica de las reglas difusas para detección de sincronización.

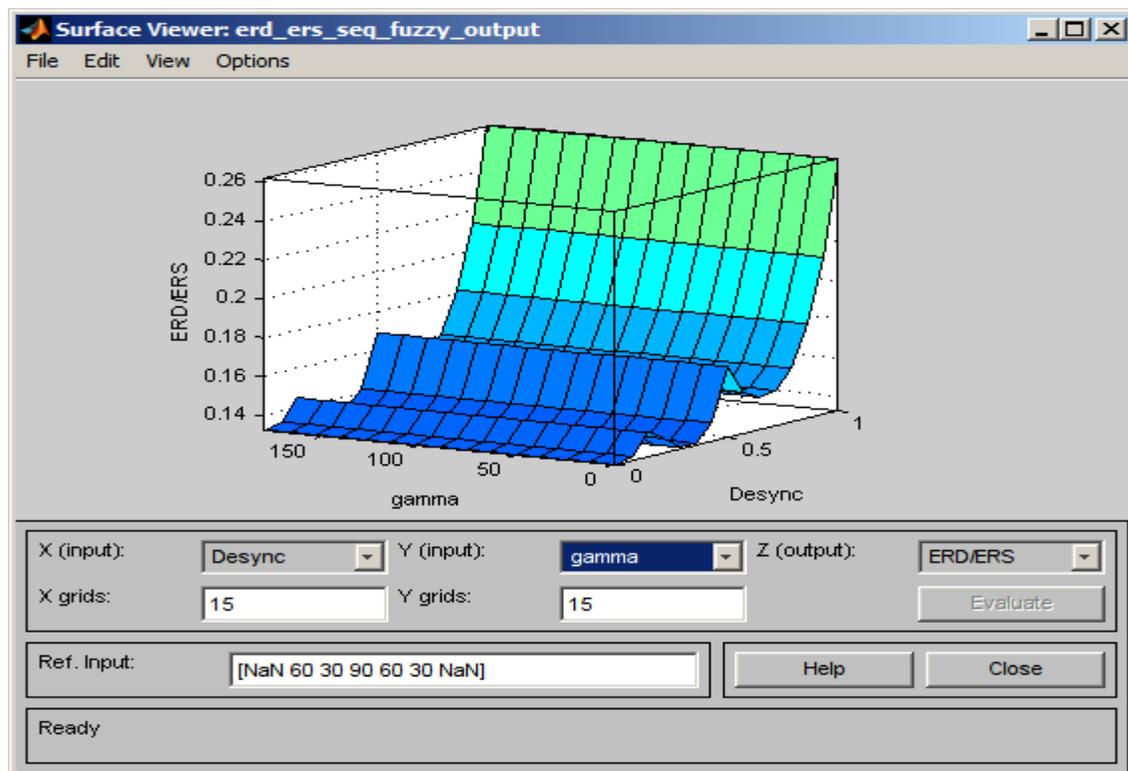


Figura 5.35. Gráfica de desync vs gamma en la etapa de desincronización.

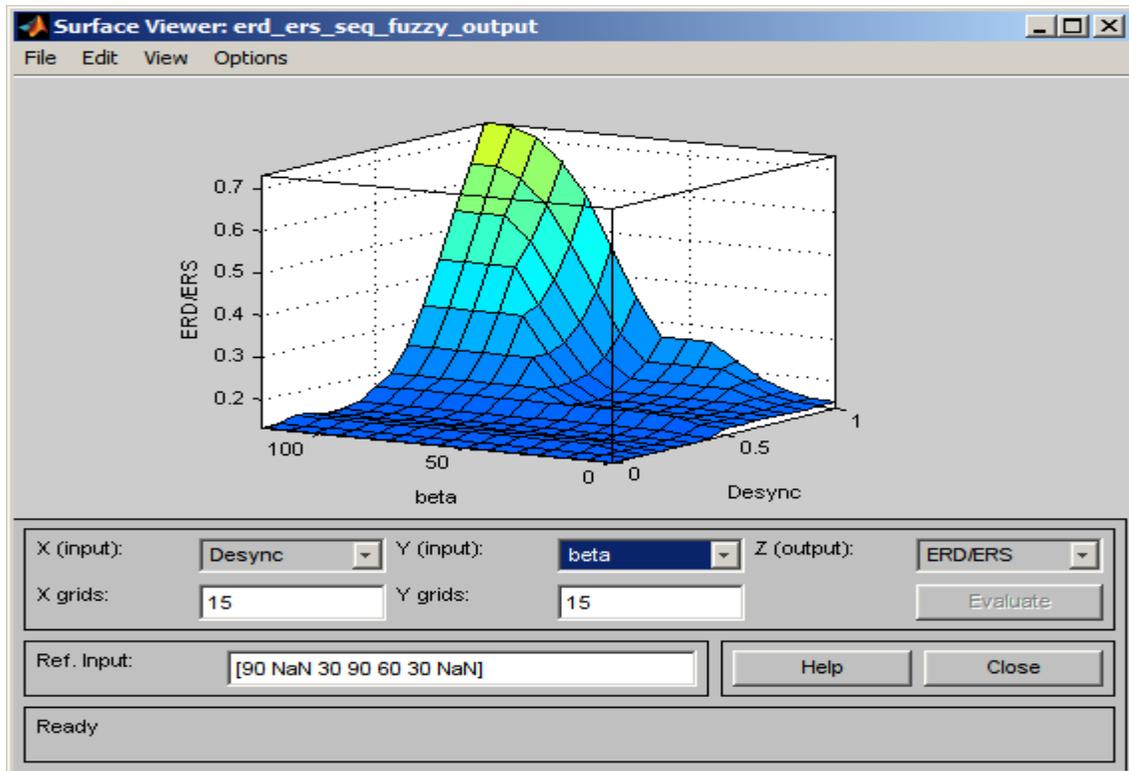


Figura 5.36. Gráfica de desync vs beta en la etapa de desincronización.

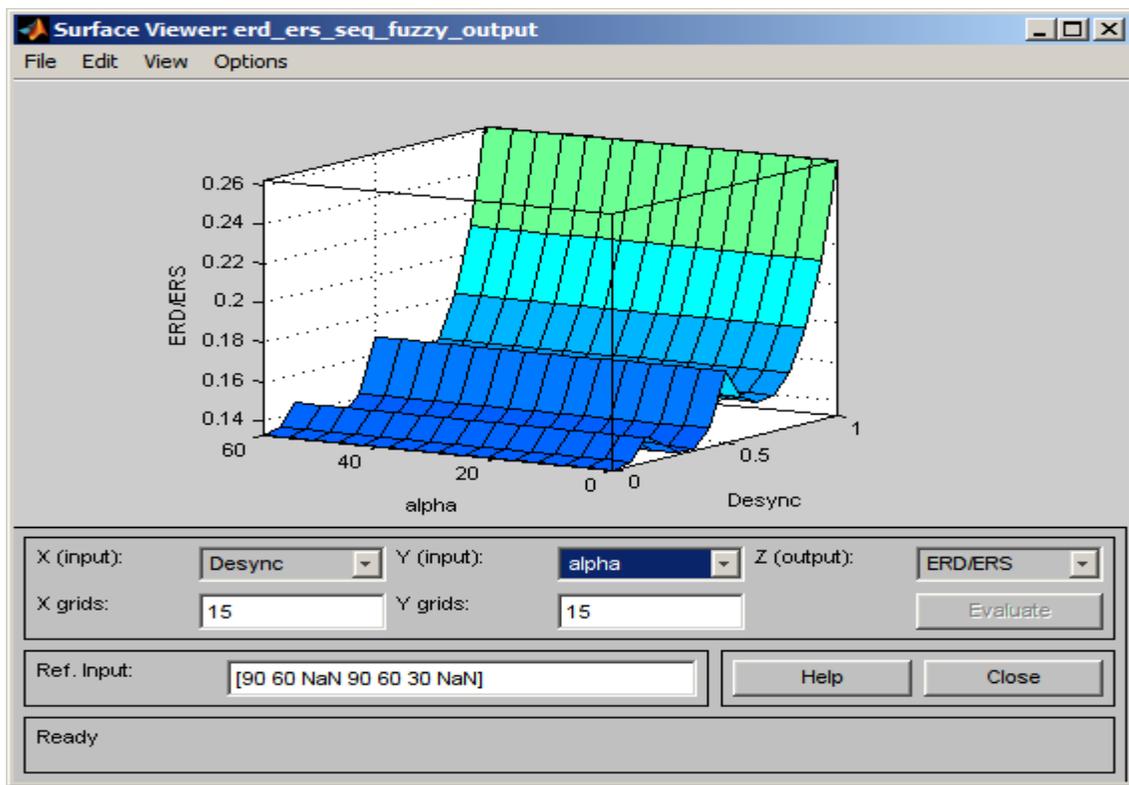


Figura 5.37. Gráfica de desync vs alfa en la etapa de desincronización.

5.13 Discusión y evaluación.

Tomando en consideración las secuencias provenientes (etapas 1 y 2) del experimento realizado para provocar el fenómeno ERD/ERS, se ha sometido a una comparación entre la obtención de la descomposición mediante MEMD y mediante transformada wavelet. El clasificador es el sistema de inferencia propuesto en el capítulo 4 con filtrado Kalman en ambas descomposiciones. La transformada discreta wavelet está usando como wavelet madre una tipo Daubechies-2. La figura 5.38 muestra la gráfica ROC como medio de comparación adecuada para establecer el desempeño de la MEMD y la transformada wavelet. MEMD se desempeña mejor que la transformada wavelet, en concordancia con otras comparaciones realizadas en [89] pero ambas presentan un aceptable método de descomposición.

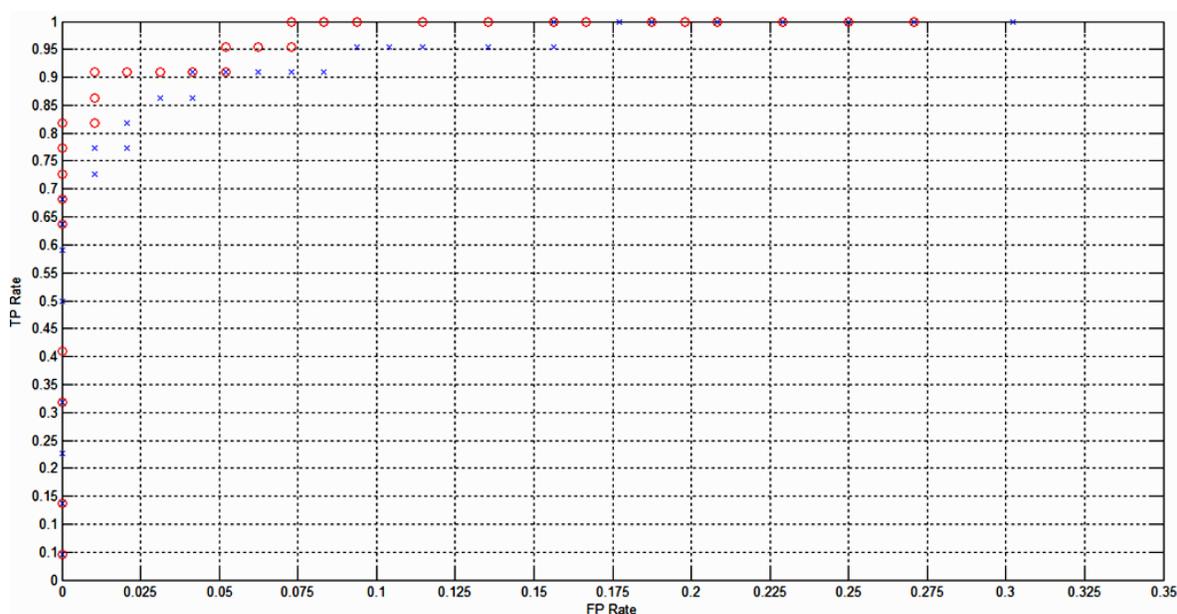


Figura 5.38. Gráfica ROC de MEMD ('o' rojos) y transformada wavelet ('x' azul).

Es difícil establecer una comparación clara entre los sistemas de detección de eventos musculares debido a que desde la adquisición de la señal EEG existen una gran cantidad de parámetros que varían en cada investigación. Sin embargo, el uso de bases de datos, permite una comparación más acertada entre el universo de métodos y algoritmos de detección del ERD/ERS. La base de datos PhysioBank es una excelente opción dado que se han registrado los datos EEG siguiendo un protocolo bien establecido además de que es ampliamente reconocida. Se analizarán los datos de un subconjunto de los 109 usuarios disponibles, en concordancia con [89]. Se eligen los bloques en donde los sujetos imaginan el movimiento de mano derecha e izquierda. La tabla 5.2 muestra que la comparación será de los sujetos bajo prueba 1, 2, 4, 7, 12, 13, 15, 25, 26, 29. En total son 45 eventos

seleccionando hasta 11 posibles canales FC3, FC4, Cz, C3, C4, C5, C6, T7, T8, CP3 y CP4. Adicionalmente se muestra sobre que números de IMFs se llevará a cabo el procesamiento y los valores de desempeño. El sistema que se usará para detectar eventos ERD/ERS es el propuesto en esta tesis. En contraste, en [89] se usará MEMD como método de descomposición, CSP (Common Spatial Patterns) para el vector de características y como clasificador una maquina de soporte vectorial (SVM) con kernel gaussiano.

Tabla 5.3 La primera columna contiene el número de sujeto en la base de datos de PhysioBank. La segunda columna contiene el desempeño de [89] y la tercera columna contiene el desempeño de esta propuesta.

Sujeto	IMF _{4<11}	IMF _{3-5<11}
1	81.7	80.2
2	84.8	83.7
4	72.1	75.3
7	81.4	81.2
12	72.2	73.6
13	64.9	67.1
15	79.6	78.2
25	69.0	70.4
26	71.5	72.1
29	75.9	78.3
Promedio	75.31	76.01

Comentarios sobre complejidad computacional.

El esquema propuesto, que incluye una descomposición mediante MEMD, puede ser aplicado confiablemente independientemente del tamaño de ventana aunque deberá ser tomada en consideración la complejidad computacional. Para ventanas menores de 2 segundos y que se conozcan previamente las características de la señal a analizar la transformada wavelet deberá ser considerada por su menor complejidad computacional. En cuanto a la obtención de la línea base mediante filtro Kalman se aconseja siempre ser aplicada a menos de que se tenga algún obstáculo en cuanto a la cantidad de procesamiento o que se considere una situación controlada de laboratorio para el uso del sistema.

La complejidad computacional puede ser definida para cada uno de los algoritmos utilizados en esta propuesta siguiendo la notación big O. Para cada una de las siguientes definiciones siguiendo la notación big O, n el tamaño de la secuencia de entrada, k es el número de variables de entrada, p el número de vectores de muestreo y p_d es el número de conjuntos difusos. La complejidad del filtro Kalman se reduce a $O(n^2)$ [67]. En el caso de la MEMD su complejidad se puede descomponer en el conjunto de operaciones que se realizan para su obtención. Uno de los puntos en los cuales se presenta mayor complejidad es en la interpolación cúbica que se requiere para el cálculo de las envolventes. De esta

forma la complejidad de la EMD se encuentra definida por su interpolación cúbica $O(n + \log(n))$ [90], la búsqueda de puntos extremos $O(n)$, mapeo a hiper-esferas $O(n \cdot k \cdot p)$ o mapeo por conjunto difuso $O(n \cdot p_d)$ y adicionalmente la construcción de las secuencias de Hammersley para el mapeo a hiper-esferas $O(\log(n))$ [91]. El modelo de eliminación de ruido requiere de una complejidad computacional de $O(n)$. Como puede ser observado este modelo puede ser implementado en tiempo real fácilmente con el desempeño en procesamiento de las computadoras actuales.

5.14 Evaluación de descomposición MEMD difusa.

De acuerdo a la base de conocimiento de la tabla 4.1 se genera el sistema de inferencia tipo Mamdani con conjuntos difusos tipo triangular (figura 5.39).

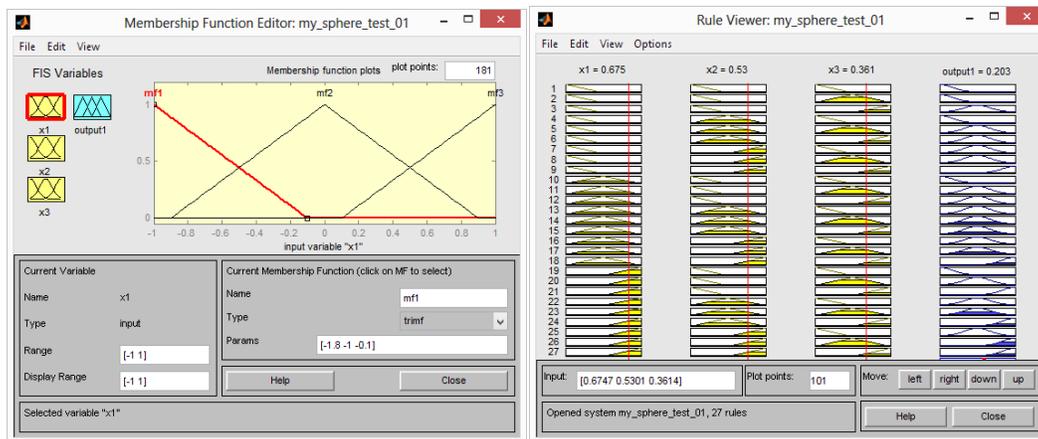


Figura 5.39. Sistema de inferencia difuso para descomposiciones multivariadas.

Para comprobar el funcionamiento del sistema propuesto se usaran como entrada una señal senoidal con amplitud máxima de 0.9 contaminada con frecuencias 4 y 8 veces más alta con amplitud máxima de 0.1, en consecuencia se tienen 3 señales de entrada. En la figura 5.40 se observa la salida del sistema difuso tomando como entrada las 3 señales artificiales. Esta salida se tomará como base para el trazado de las envolventes. Posteriormente el proceso es semejante para obtener la descomposición en modo empírico (figura 5.41-5.43). Es decir, búsqueda de máximos y mínimos (figura 5.41); trazar envolventes mediante spline cúbica (figura 5.42); cálculo de la variación promedio, el cual se restará a la señal original (figura 5.43). Si se cumplen los requisitos que distinguen a una IMF se detiene el proceso de lo contrario de vuelve a repetir el ciclo. Se usará como criterio de paro, para que la señal se considere como IMF, que tenga un cruce por cero entre un máximo y un mínimo.

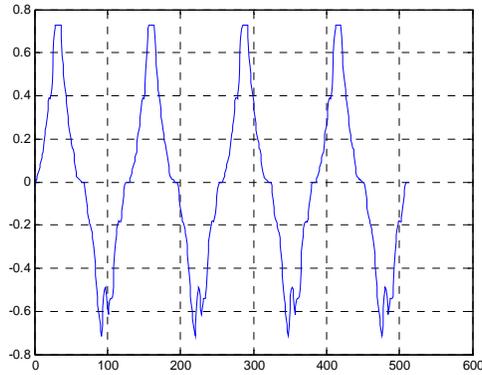


Figura 5.40. Salida del sistema difuso para las 3 entradas artificiales.

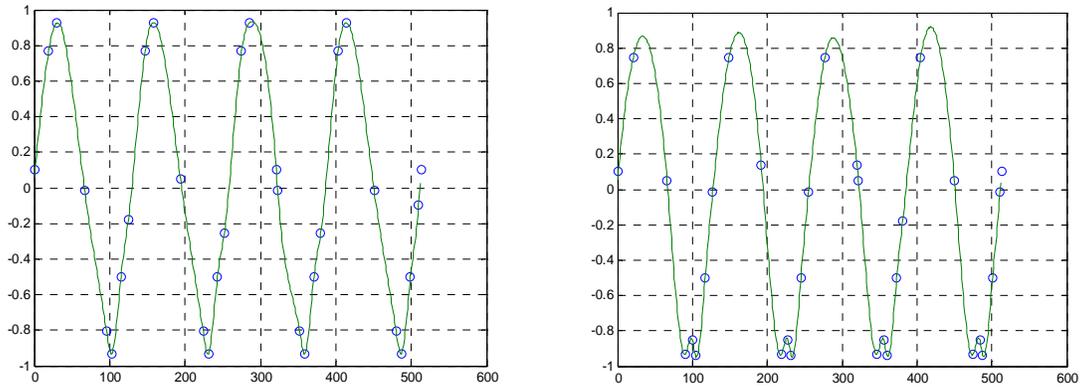


Figura 5.41. Envolturas para máximos (izquierda) y mínimos (derecha) de la señal.

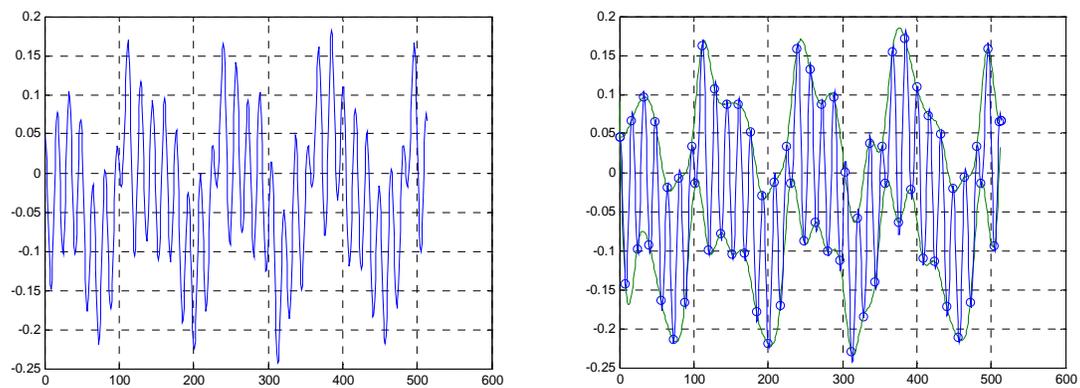


Figura 5.42. Primer intento fallido de obtención de IMF mediante sifting por lo que se necesitará un ciclo adicional.

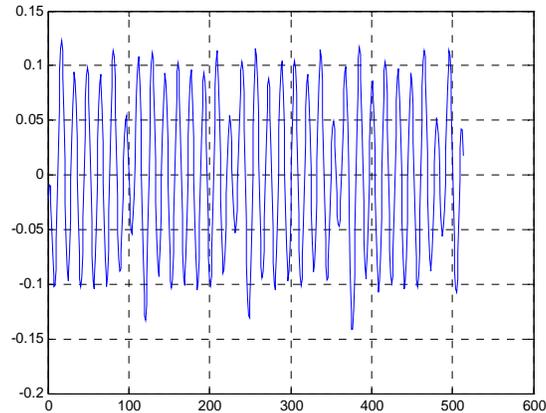


Figura 5.43. IMF 1 para la señal de entrada 3.

A la salida se deberá observar la frecuencia predominante combinada con las frecuencias contaminantes ya separadas en diferentes IMFs. Adicionalmente se compara con la salida de la descomposición multivariable propuesta por Looney y Rehman[65]. En la figura 5.44 en la parte izquierda se puede observar la descomposición obtenida mediante el sistema difuso y a la derecha mediante hiper-esferas. El primero punto de comparación numérica entre el método propuesto mediante el uso de un sistema de inferencia difuso y mediante proyecciones a hiper-esferas es la cantidad de descomposiciones IMF resultantes. En este caso ambos métodos obtienen 3 IMF como se esperaba. La tabla 5.3 resume algunos valores numéricos de interés para cada IMF. La columna de “Potencia esperada” es el valor absolutamente correcto de potencia para cada descomposición. Las columnas de error es la diferencia entre la IMF y la señal senoidal original expresando valores promedios. El error deberá tener siempre un valor de 0.

Tabla 5.4 Comparación entre MEMD por hiperesferas y MEMD difuso.

	MEMD hiperesferas		MEMD Difuso		Potencia esperada
	Potencia	Error	Potencia	Error	
1 IMF 1	0.003	0.02	0.004	0.08	0
1 IMF 2	0.002	0.03	0.03	0.09	0
1 IMF 3	0.63	0.01	0.63	0.03	0.63
2 IMF 1	0.003	0.07	0.004	0.07	0
2 IMF 2	0.08	0.02	0.095	0.09	0.07
2 IMF 3	0.63	0.01	0.62	0.03	0.63
3 IMF 1	0.08	0.02	0.093	0.03	0.07
3 IMF 2	0.003	0.04	0.005	0.05	0
3 IMF 3	0.63	0.02	0.61	0.03	0.63

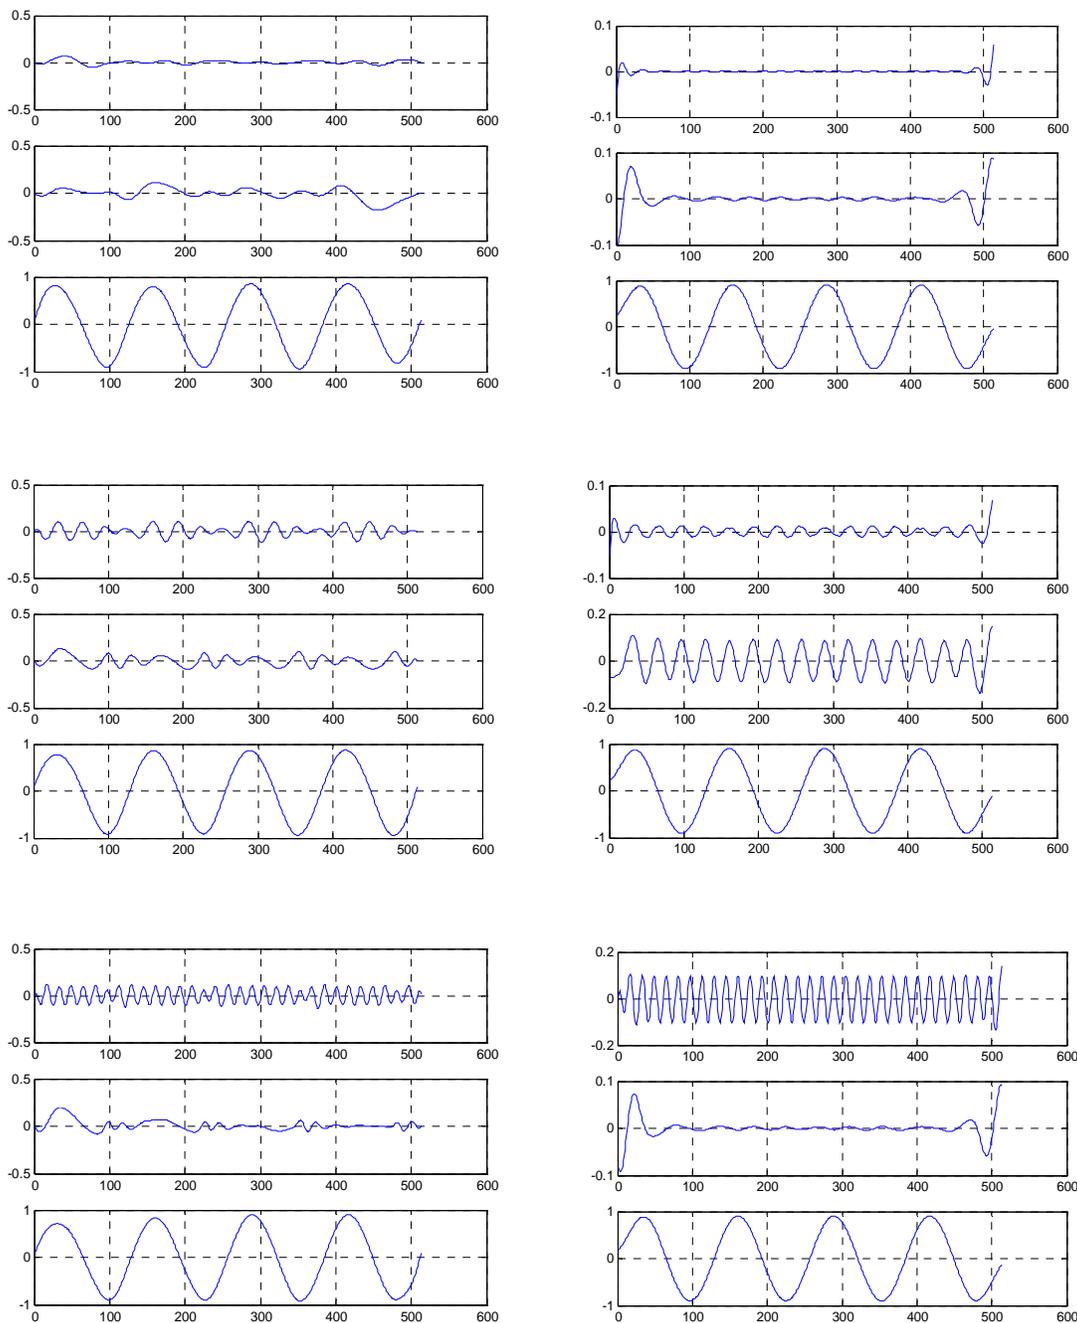


Figura 5.44. MEMD basado en sistema difuso propuesto (izquierda) y en proyecciones sobre hiperesferas (derecha).

5.15 Discusión.

La MEMD difusa obtiene valores aceptables para el caso de que se use la potencia como valor característico pero entrega una pequeña distorsión desde el punto de vista de la

amplitud instantánea de las señales de entrada de acuerdo a los datos numéricos de la tabla 5.3. Sin embargo, la MEMD difusa propuesta tiene las mismas propiedades y por la misma razón las mismas ventajas que la MEMD: completa, ortogonal, local, adaptiva. Además de eliminar el modo mezclado y defase en la señal entre el mismo nivel de descomposición para cada una de las variables de entrada. Adicionalmente, se elimina la necesidad del cálculo previo de las secuencias de baja discrepancia y de sus respectivos ángulos dentro de cada hiper-esfera. En el caso de la MEMD difusa, como en la MEMD por hiper-esferas, no es necesario conocer previamente el tamaño de la secuencia de entrada.

Capítulo 6

En este capítulo se presentan las principales contribuciones de la tesis además se incluye una discusión de la tendencia a futuro de esta propuesta.

6.1 Conclusiones.

La investigación descrita en el presente documento reporta el uso de modelos y algoritmos siempre teniendo en cuenta la naturaleza no-estacionaria de la señal EEG. La reducción de ruido en los sistemas BCI es un punto muy importante para el análisis/detección de eventos mentales por lo que se ha propuesto un sistema sencillo de aplicar basado en las propiedades del EEG, con un aumento de la razón señal a ruido de al menos 15%. Además esta propuesta cuenta con bloques de procesamiento que fácilmente pueden ser agregados o eliminados para los casos en que se encuentre en condiciones no controladas o en experimentos de laboratorio. Por lo tanto la propuesta es altamente modular.

Adicionalmente se explora el uso de algoritmos considerados como adaptivos a los datos de entrada por lo que, en muchas ocasiones, no es necesario conocer de antemano los parámetros o características de la señal. Permitiendo alcanzar desempeños del orden de hasta el 90%.

Los resultados de esta investigación pueden ser usados para mejorar los sistemas basados en EEG fuera y dentro de laboratorio. Las contribuciones del presente trabajo de tesis doctoral al área de interfaces cerebro-computadora se resumen a continuación:

- El diseño de experimentos propios que han permitido la estimulación a las áreas, formas y tiempo correctos del cerebro.
- La creación y uso de algoritmos adecuados para la descomposición de la señal EEG, ya sea para señales uni-variable o multicanal, considerando su característica no-estacionaria. Además, estos algoritmos no necesitan conocimiento previo de la señal a descomponer. La mayoría de los algoritmos propuestos en otras investigaciones incluyen tamaños de ventana limitados establecidos experimentalmente en el orden de máximo 2 segundos de análisis. En este intervalo de tiempo la señal EEG se le considera como estacionaria o cuasi-estacionaria.
- La eliminación de ruido provocado por movimientos de la cabeza y al fin de cuentas en la interfaz electrodo-piel. Este proceso de eliminación de ruido y artefactos se basa en las características propias de la adquisición de datos EEG. Por lo tanto, no necesita capacidades especiales del sistema de adquisición de datos o electrodos adicionales que registren información mio-eléctrica.

- Mediante un filtrado adaptivo es posible conocer la línea base y eliminar cambios abruptos en la variación de la potencia de la señal. No es necesario que la línea base sea conocida previo al inicio de la detección de eventos mentales.
- El diseño de clasificadores que puedan aprovechar la amplia base de conocimiento médico en forma directa y así evitar tiempos de entrenamiento y ser fácil de depurar y modificar.
- Este sistema propuesto puede ser fácilmente implementado aún en equipo de adquisición de bajo costo.

6.2 Trabajo a futuro.

El principal punto a continuar trabajando es la investigación en descomposiciones que mejoren el desempeño computacional de esta propuesta y que tengan las mismas ventajas. En esta propuesta se hace uso de una descomposición que necesita la creación de secuencias que maximicen la uniformidad de muestreo sobre hiper-esferas. Posteriormente se tienen que calcular las proyecciones sobre los vectores que describen estas hiper-esferas y generar envolventes multidimensionales que permitirán el cálculo de la media. Es posible encontrar esta curva promedio mediante métodos como los sistemas de inferencia difusos y así reducir el número de operaciones numéricas.

Otro punto importante es la creación de nuevos experimentos mentales de tal manera que permitan que no exista el entrenamiento al usuario del sistema o se mantenga en lo mínimo. En general se deberá procurar entrenar al sistema no al usuario [72].

6.3 Publicaciones realizadas a partir del presente trabajo de tesis doctoral.

Rosas-Cholula, G., Ramirez, J., Alarcon, V., Gomez, P., Rangel-Magdaleno, J., Gyroscope-driven mouse pointer with an EMOTIV EEG headset and data analysis based on Empirical Mode Decomposition, *Sensors*, Vol. 13, No. 8, pp. 10561-10583, 2013. (JCR and SCI indexed journal with impact factor 1.953; ISSN 1424-8220)

Ramírez-Cortés, J.M., Alarcon-Aquino, V., Rosas-Cholula, G., Gomez-Gil, P., Escamilla-Ambrosio, P. J. “ANFIS-based P300 rhythm detection using wavelet feature extraction on blind source separated EEG signals”, Book Chapter, *Intelligent Automation and Systems Engineering*, Springer, Vol. 103, pp. 353-365, 2011.

Rosas-Cholula, G., Ramirez, J.M., Alarcón, V., Martinez, J., Gomez, P, “On signal P-300 detection for BCI applications based on wavelet analysis and ICA preprocessing”, Electronics, Robotics and Automotive Mechanics Conference (CERMA), Morelos, Mexico, pp.360-365, 2010.

Ramirez-Cortés J.M., Alarcon V, Rosas-Cholula, G., Gomez, P., Escamilla, P., “P-300 rhythm detection using ANFIS algorithm and wavelet feature extraction in EEG signals”, International Conference on Signal Processing and Image Engineering ICSPIE 2010, Best Paper Award; World Congress on Engineering and Computer Science, San Francisco, Cal., USA, pp. 963-968, 2010.

Rosas-Cholula, G., Ramirez, J.M., Escamilla, J., Alarcon, V., “On the development of a simple EOG-based mouse with BCI technology applying Empirical Mode Decomposition and DWT”, International Graphonomics Society Conference (IGS), Cancun, Mexico, pp.70-73, 2011.

Rosas-Cholula, G., Ramirez, J.M., Rangel-Magdaleno, J., Gomez, P, Alarcon V, "Head movement artifact removal in EEG signals using Empirical Mode Decomposition and Pearson correlation", International Conference in Artificial Intelligence ICAI 2013, CSREA Press, Las Vegas, Nevada, July, 2013.

(Estas publicaciones han recibido en total 29 citas internacionales de acuerdo con Google Scholar)

Referencias.

- 1 Leuthardt, E.C., G. Schalk, J.R. Wolpaw, J.G. Ojemann, and D.W. Moran. "A brain-computer interface using electrocorticographic signals in humans". *Journal of Neural Engineering*, Vol 1,2004,pp.63–71.
- 2 Yoshor, D., Bosking, W., Ghose, G., Maunsell, J., "Receptive Fields in Human Visual Cortex Mapped with Surface Electrodes", *Oxford Journal*, Vol. 17, Issue 10, 2006
- 3 Fisch, MD., *Fundamentals of EEG interpretation*, New Orleans, LA, Medical Report, 2003.
- 4 Wolpaw, J.R., H. Ramoser, D.J. McFarland, and G. Pfurtscheller. "EEG-based communication: improved accuracy by response verification". *IEEE Transactions Rehabilitation Engineering*, Vol.6,1998,pp.326–333.
- 5 Ramírez-Cortés, J.M., Alarcon-Aquino, V., Rosas-Cholula, G., Gomez-Gil, P., Escamilla-Ambrosio, P. J. "ANFIS-based P300 rhythm detection using wavelet feature extraction on blind source separated EEG signals", *Book Chapter, Intelligent Automation and Systems Engineering, Springer, Lecture Notes in Electrical Engineering, Volume 103, 2011, pp. 353-365.*
- 6 Rosas, G., Ramirez, J., Alarcon, V., Gomez, P., Rangel-Magdaleno, J., "Gyroscope-driven mouse pointer with an EMOTIV® EEG headset and data analysis based on Empirical Mode Decomposition", *Sensors*, Vol 13(8), 2013, pp.10561-10583.
- 7 Nicolas-Alonso L.F, Gomez-Gil J., "Brain Computer Interfaces, a Review", *Sensors* 12, 2012, pp.1211-1279.
- 8 McMenamin, B. W., Shackman A.J., Maxwell, J. S., Bachhuber D.R.W., Koppenhaver A.M., Greischar L.L., Davidson R. J., "Validation of ICA-Based Myogenic Artifact Correction for Scalp and Source-Localized EEG", *Neuroimage* 49, 3, 2010, pp. 2416-2432.
- 9 Plochl M., Ossandón J.P., Konig P., "Combining EEG and eye tracking: identification, characterization and correction of eye movement artifacts in electroencephalographic data", *Frontiers in Human Neuroscience* 6, 278, 2012, pp. 1-23.
- 10 Gwin, J.T., Gramann K., Makeig S., Ferris D.P., "Removal of Movement Artifact From High-Density EEG Recorded During Walking and Running", *Journal of Neurophysiology* 103, 2010, pp.3526–3534.

- 11 Huang M., Wu P., Liu Y., Bi L., Chen H., “Application and Contrast in Brain-Computer Interface between Hilbert-Huang Transform and Wavelet Transform”, 9th International Conference for Young Computer Scientists, Hunan, China, November 18-21, 2008, pp.1706-1710.
- 12 Bulling A., Ward J. A., Gellersen H., Troster G., “Eye Movement Analysis for Activity Recognition Using Electrooculography”, IEEE Transactions on Pattern Analysis and Machine Intelligence 33, 2011, 4, 741-753.
- 13 Schomer, D., Lopes da Silva, F., “Niedermayer's Electroencephalography, Basic Principles, Clinical Applications and Related Fields”, Lippincot Williams & Williams, 2011
- 14 Fisch, MD., “Fundamentals of EEG interpretation”, New Orleans, LA, 2003.
- 15 Krusienski, D.J., Grosse-Wentrup, M., Galán, F., Coyle, D, Miller, K.J., Forney, E., Anderson, C., “Critical issues in state-of-the-art brain–computer interface signal processing”, Journal of Neural Engineering, 8, 025002, 2011.
- 16 Brunner, P., Bianchi, L., Guger, C., Cincotti, F., Schalk, G., “Current trends in hardware and software for brain–computer interfaces (BCIs)”, Journal of Neural Engineering, 8, 025001, 2011
- 17 Bashashati, M. Fatourehchi, “A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals”, Journal of Neural Engineering, 2007, R32-R57.
- 18 Fabiani, G., McFarland D., Wolpaw, J., Pfurtscheller G., “Conversion of EEG activity into cursor movement by a brain–computer interface (BCI)”, IEEE Transactions on Neural Systems and Rehabilitation, Eng. 12, 2004, pp.331–338.
- 19 Qin, L., He, B., “A wavelet-based time-frequency analysis approach for classification of motor imagery for brain–computer interface applications”, J. Neural Eng.2, 2005, pp.65–72.
- 20 Qin, L., Kamousi, B., Liu, M., Ding, L., He, B., “Classification of motor imagery tasks by means of time-frequency-spatial analysis for brain–computer interface applications”, Proc. IEEE-EMBS Conf. on Neural Engineering (Arlington, VA), 2005, pp.374–376.
- 21 Peterson D., Knight J., Kirby M., Anderson C., Thaut, M., “Feature selection and blind source separation in an EEG-based brain–computer interface”, EURASIP J. Appl. Signal Processing, 19, 2005, pp.3128–3140.

- 22 Dornhege G., Blankertz, B., Curio, G., “Speeding up classification of multi-channel brain–computer interfaces: common spatial patterns for slow cortical potentials”, Proceedings 2nd IEEE-EMBS Conference on Neural Engineering, pp 595–598, 2003
- 23 Dornhege, G., Blankertz, B., Curio, G., Muller, K., “Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms”, IEEE Transaction Biomedicine, 2004, Eng. 51, pp. 993–1002.
- 24 Yoon, H., Yang, K., Shahabi, C., “Feature subset selection and feature ranking for multivariate time series”, IEEE Transactions on Knowledge Data, Eng. 17, 2005, pp.1186–98.
- 25 Lemm, S., Blankertz, B., Curio, G., Muller, K., “Spatio-spectral filters for improving the classification of single trial EEG”, IEEE Transactions on Biomedicine, Eng., 2005, pp. 52 1541–8.
- 26 Fatourechi, M., Bashashati, A., Ward, R., Birch, G., “A hybrid genetic algorithm approach for improving the performance of the LF-ASD brain–computer interface”, Proceedings IEEE International Conference on Acoustics, Speech and Signal Processing, Vol. 5, 2005, pp. v/345 - v/348.
- 27 Bayliss, J., Ballard, D., “Recognizing evoked potentials in a virtual environment Advances in Neural Information”, Processing Systems, Vol. 12, Ed. S A Solla, T K Leen, K R Müller (Cambridge, MA: MIT Press), 2000a
- 28 Wang, Y., Zhang, Z., Li, Y., Gao, X., Gao, S., Yang, F., “BCI competition 2003–data set IV: an algorithm based on CSSD and FDA for classifying single-trial EEG”, IEEE Transactions on Biomedicine and Engineering, 2004d, Vol. 51, pp. 1081–1086.
- 29 Cheng, M., Jia, W., Gao, X., Gao, S., Yang F, “Mu rhythm-based cursor control: an offline analysis”, Clinical Neurophysiology, Vol.115, 2004, pp.745–51
- 30 Li, Y., Cichocki, A., Guan, C., Qin, J., “Sparse factorization preprocessing-based offline analysis for a cursor control experiment”, Proc. IEEE Int. Workshop on Biomedical Circuits and Systems (Singapore), 2006a, pp.S3/5/INV-S3/5/5–8.
- 31 Peterson, A., Knight, J., Kirby, M., Anderson, C., Thaut, M., “Feature selection and blind source separation in an EEG-based brain–computer interface” EURASIP Journal Applied Signal Processing, Vol. 19, 2005, 3128–40
- 32 Gibson, S., Judy, J., Markovi’c, D., “Comparison of Spike-Sorting Algorithms for Future Hardware Implementation”, 30th Annual International IEEE EMBS Conference Vancouver, British Columbia, Canada, 2008, pp. 5015 – 5020.

- 33 Tavakolian, K., Nasrabadi, A., Rezaei, S., “Selecting better EEG channels for classification of mental tasks”, Proceedings IEEE International Symposium on Circuits and Systems, 2004, pp. 537–540.
- 34 Neuper, C., Scherer, R., Reiner, M., Pfurtscheller, G., “Imagery of motor actions: differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG”, Cognitive Brain Research, Elsevier, Vol. 25, Issue 3, 2005, pp. 668–77
- 35 Fabiani, G., McFarland, D., Wolpaw, J., Pfurtscheller, G., “Conversion of EEG activity into cursor movement by a brain–computer interface (BCI)”, IEEE Transactions on Neural Systems and Rehabilitation, Eng. 12, 2004, pp. 331–338.
- 36 Glassman, E., “A wavelet-like filter based on neuron action potentials for analysis of human scalp electroencephalographs”, IEEE Transaction Biomedics Eng. , Vol. 52, 2005, pp.1851–62
- 37 Schröder, M., Lal, T., Hinterberger, T., Bogdan, M., Hill, N., Birbaumer, N., Rosenstiel, W., Schölkopf, B., “Robust EEG channel selection across subjects for brain–computer interfaces”, EURASIP Journal on Applied Signal Process, Vol. 19, 2005, pp.3103–12.
- 38 Wang Y, Zhang Z, Li Y, Gao X, Gao S, Yang F, “BCI competition 2003–data set IV: an algorithm based on CSSD and FDA for classifying single-trial EEG”, IEEE Transactions on Biomedicine Eng, Vol. 51, 2004d, 1081–1086.
- 39 Cheng M, Jia W, Gao X, Gao S, Yang F, “Mu rhythm-based cursor control: an offline analysis”, Clinical Neurophysiology, Vol. 115, 2005, pp.745–51.
- 40 Xu, W., Guan, C., Siong, C., Ranganatha, S., Thulasidas, M., Wu, J., “High accuracy classification of EEG signal”, Proceedings 17th International Conference on Pattern Recognition, Vol.2, 2004, pp.391-394.
- 41 Firat, N., Arica, S., Tewfik, A., “Classification of single trial motor imagery EEG recordings with subject adapted non-dyadic arbitrary time–frequency tilings”, Journal of Neural Engineering, Vol. 3, 2006, pp. 235-244.
- 42 Huang, D., Lin, P., Fei, DY., Chen, X., Ou, B., “Decoding human motor activity from EEG single trials for a discrete two-dimensional cursor control”, Journal of Neural Engineering, Vol. 6, 2009, Num. 046005.
- 43 McFarland, D., Krusienski, D., Sarnacki, W., Wolpaw, J., “Emulation of computer mouse control with a noninvasive brain–computer interface”, Journal of Neural Engineering, Vol. 6, 2008, Num. 046005.

- 44 Qin, L., He, B., "A wavelet-based time–frequency analysis approach for classification of motor imagery for brain–computer interface applications", *Journal of Neural Engineering*, 2005, pp. 65-72.
- 45 Lotte, F., Congedo, M., Lecuyer, A., Lamarche, F., Arnaldi, B., "A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces", *Journal of Neural Engineering*, Vol. 4, 2007, pp. R1-R13.
- 46 Garrett, D., Peterson, D., Anderson, C., Thaut, M., "Comparison of linear, nonlinear, and feature selection methods for EEG signal classification", *IEEE Transactions on Neural System and Rehabilitation Engineering*, Vol. 11, 2003, pp.141-144.
- 47 Scherer, R., Muller, G., Neuper, C., Graimann, B., Pfurtscheller, G., "An asynchronously controlled EEG-based virtual keyboard: Improvement of the spelling rate", *IEEE Transactions on Biomedical Engineering*, Vol. 51(6), 2004, pp. 979-984.
- 48 Cincotti, F., Scipione, F., Tiniperi, A., Mattia, D., Marciani, M., Millan, J., Salinari, S., Bianchi, L., Babiloni, F., "Comparison of different feature classifiers for brain computer interfaces", *Proceedings of the 1st International IEEE EMBS Conference on Neural Engineering*, 2003, pp.645-647.
- 49 Bishop, C., "Neural Networks for Pattern Recognition". Oxford University Press, 1996.
- 50 Palaniappan, R., "Brain computer interface design using band powers extracted during mental tasks", *Proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering*, 2005, pp.321-324.
- 51 Boostani, R., Moradi, M., "A new approach in the bci research based on fractal dimension as feature and adaboost as classifier", *Journal of Neural Engineering*, Vol. 1(4), 2004, pp.212-217.
- 52 Solhjoo, S., Moradi, M., "Mental task recognition: A comparison between some of classification methods", *BIOSIGNAL International EURASIP Conference*, 2004, pp. 24-26.
- 53 Barreto, G., Frota, R., de Medeiros, F., "On the classification of mental tasks: a performance comparison of neural and statistical approaches", *Proceedings of the IEEE Workshop on Machine Learning for Signal Processing*, 2004, pp. 529-538.
- 54 Schlogl, A., Lee, F., Bischof, H., Pfurtscheller, G., "Characterization of four-class motor imagery EEG data for the BCI-competition 2005", *Journal of Neural Engineering*, 2005, pp. L14-L22.

- 55 R. Acharyaa, F. Molinarib, V. Sreec, S. Chattopadhyayd, N. Kwan-Hoong, J. Suri, “Automated diagnosis of epileptic EEG using entropies”, Elsevier, Biomedical Signal Processing and Control 7, 2012, pp. 401– 408.
- 56 Rosas, G., Ramirez, J.M., Alarcón, V., Martinez, J., Gomez, P, “On signal P-300 detection for BCI applications based on wavelet analysis and ICA preprocessing”, Conference on Electronics, Robotics and Automotive Mechanics Conference (CERMA), 2010, pp.360-365.
- 57 McMenamin B., Shackman, A., Greischar, L., Davidson, R., “Electromyogenic artifacts and electroencephalographic inferences revisited”, Elsevier, NeuroImage, Vol. 54, 2011, pp. 4-9.
- 58 Winkler I., Haufe, S., Tangermann, M., “Automatic Classification of Artifactual ICA Components for Artifact Removal in EEG Signals”, Behavioral and Brain Functions, 2001, pp. R7:30.
- 59 Ramirez J.M., Alarcon V, Rosas, Gomez, P., Escamilla, P., “P-300 rhythm detection using ANFIS algorithm and wavelet feature extraction in EEG signals”, World Congress on Engineering and Computer Science, Vol. 1, 2010.
- 60 Krishnaveni V., Jayaraman S., Aravind S., Hariharasudhan V., Ramadoss K., “Automatic identification and Removal of ocular artifacts from EEG using Wavelet transform”, Measurement Science Review 6, Vol. 4, 2006, pp.45-57.
- 61 Salinas R., Schachter E., Miranda M., “Recognition and Real-Time Detection of Blinking Eyes on Electroencephalographic Signals Using Wavelet Transform”, Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications, Springer Berlin Heidelberg, 2012, pp. 682-690.
- 62 Altaf, M., Gautama, T., Tanaka, T., Mandic, P., “Rotation Invariant Complex Empirical Mode Decomposition”, ICASSP, III, 2007, pp.1009-1012.
- 63 Rilling, G., Flandrin, P., Goncalves, P., Lilly, J. M., “Bivariate empirical mode decomposition”, IEEE Signal Processing Letters, Vol. 14, 2007, pp.936–939.
- 64 Rehman, N. & Mandic, D. P. In press. “Empirical mode decomposition for trivariate signals”, IEEE Transactions on Signal Processing, Volume 58, Issue:3, 2010, pp.1059 – 1068.
- 65 Rehman, N., Mandic, D. P., “Multivariate empirical mode decomposition”, Proceedings Real Society. A, 466, 2010, pp. 1291–1302.
- 66 Niederreiter, H., “Random number generation and quasi-Monte Carlo methods”. Philadelphia, PA: Society for Industrial and Applied Mathematics, 1992

- 67 Zarchan P., Mussoff H., “Fundamentals of Kalman Filtering”, 3rd ed, American Institute of Aeronautics and Astronautics, 2009
- 68 Kumar, P., Arumuganathan, R., Sivakumar, K., Vimal, C., “Removal of Artifacts from EEG Signals using Adaptive Filter through Wavelet Transform”, ICSP2008 Proceedings, Journal of Physics: Conference Series 90, 2007
- 69 Guo, L., Rivero, D., Dorado, J., Rabunal, J., Pazos, A., “Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks”, Journal of Neuroscience Methods 191, 2010, pp.101–109.
- 70 Rutkowski, T., Mandic, D., Cichocki, A., Przybyszewski, A., “EMD Approach to Multichannel EEG Data”, Journal of Circuits, Systems, and Computers, Vol. 19, No. 1, 2010, pp.215-229.
- 71 Molla, M., Tanaka, T., Rutkowski, T., “Multivariate EMD based approach to EOG artifacts separation from EEG”, ICASSP Acoustics, Speech and Signal Processing, 2012, pp. 653-656.
- 72 Lotte, F., Larrue, F., Hachet, M., “BCI Research at Inria Bordeaux: making BCI designs usable outside the lab”, International BCI meeting, hal-00802403, 2013.
- 73 Hu, H., Ma J., and Tian J., “A New Electronic Image Stabilization Technology Based on Random Ferns for Fixed Scene”, Network Computing and Information Security, Springer Berlin Heidelberg, 2012, pp. 501-508.
- 74 Tsai, C. Y., Dutoit X., Song K.T., Van Brussel H., Nuttin M., “Robust face tracking control of a mobile robot using self-tuning Kalman filter and echo state network”, Asian Journal of Control 12, 2010, Vol. 4, pp. 488-509.
- 75 Ramirez J.M., Alarcon V, Rosas, Gomez, P., Escamilla, P., “P-300 rhythm detection using ANFIS algorithm and wavelet feature extraction in EEG signals”, World Congress on Engineering and Computer Science, 2010
- 76 Rosas, G., Ramirez, J.M., Escamilla, J., Alarcon, V., “On the development of a simple EOG-based mouse with BCI technology applying Empirical Mode Decomposition and DWT”, International Graphonomics Society (IGS), 2011
- 77 Emotiv - Brain Computer Interface Technology. Available online: <http://www.emotiv.com> (accessed on Feb-2014).
- 78 Lotte, F., Larrue, F., Hachet, M., “BCI Research at Inria Bordeaux: making BCI designs usable outside the lab”, International BCI meeting, hal-00802403, 2013

- 79 Araghi, L., "A New Method for Artifact Removing in EEG Signals", Proceedings of the International MultiConference of Engineers and Computer Scientists, Vol 1, IMECS, 2010, pp. 420-423.
- 80 Hsu, W., Lin, C., Hsu, H., Chen, P., Chen, I., "Wavelet-based envelope features with automatic EOG artifact removal: Application to single-trial EEG data", Elsevier, International Journal Expert Systems with Applications, Vol. 39, 2012, pp. 2743–2749.
- 81 McMenamin, B. W., Shackman A.J., Maxwell, J. S., Bachhuber D.R.W., Koppenhaver A.M., Greischar L.L., Davidson R. J., "Validation of ICA-Based Myogenic Artifact Correction for Scalp and Source-Localized EEG", Neuroimage Vol. 49, Issue 3, 2010, pp.2416-2432.
- 82 Balaiah, P., "Comparative Evaluation of Adaptive Filter and Neuro-Fuzzy Filter in Artifacts Removal From Electroencephalogram Signal", American Journal of Applied Sciences, Vol. 9, Issue 10, pp. 1583-1593, 2012
- 83 Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. Circulation 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>].
- 84 Schalk, G., McFarland, D., Hinterberger, T., Birbaumer, N., Wolpaw, J., "BCI2000: A general-purpose brain-computer interface (BCI) system", IEEE Transactions on Biomedical Engineering, Vol. 51, Issue 6, 2004, pp.1034-1043.
- 85 Daubigny, L., Pietquin, O., "Single-trial P300 detection with Kalman Filtering and SVMs", ESANN 2011 proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, Belgium, 2011
- 86 Vedel-Larsen, E., Fuglo, J., Channir, F., Thomsen, C., Sorensen, H., "A comparative study between a simplified Kalman filter and sliding window averaging for single trial dynamical estimation of event-related potentials". Computer Methods and Programs in Biomedicine, 99(3):252-260, 2010.
- 87 Georgiadis, S., Ranta-aho, P., Tarvainen, M., Karjalainen, P., "Single-trial dynamical estimation of event-related potentials: a Kalman filter-based approach", IEEE Transactions on Biomedical Engineering, Vol. 52(8), 2005, pp.1397-1406.
- 88 Ting C., Salleh S., Zainuddin Z., Bahar, A., "Spectral estimation of nonstationary EEG using particle filtering with application to event-related desynchronization (ERD)", Biomedical Engineering, IEEE Transactions on Vol. 58, Issue 2, 2011, pp.321-331.

89 Park, C., Looney, D., Rehman, D., Ahrabian, A., Mandic, D., “Classification of Motor Imagery BCI Using Multivariate Empirical Mode Decomposition”, IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 21, No. 1, 2013, pp. 10-22.

90 Lee W., Dean, J., Dean Riess, R., “Numerical Analysis”. Third Ed., Addison-Wesley, 1982.

91 Dobkin, D.P., Eppstein, D., Mitchell, Don P. “Computing the discrepancy with applications to super-sampling patterns”. ACM Transactions on Graphics, Vol. 15, No. 4, pp. 354–376, 1996.