


(TFPFD) TRABAJO FINAL PERIODO FORMATIVO
DOCTORADO



Universidad
Politécnica
de Cartagena

EVALUACIÓN DE TÉCNICAS COMPUTACIONALES
PARA EL ANÁLISIS LINEAL DE SEÑALES
ELECTROENCEFALOGRÁFICAS



Programa de Doctorado: Tecnologías Industriales

Autor: Francisco José Martínez Albaladejo

Director: D. Juan Luis García Guirao

Septiembre 2013

CONTENIDO

Capítulo 1. Introducción y objetivos.	1
1.1 Introducción	1
1.2 Objetivos	2
1.3 Resumen.....	3
1.4 Etapas del TFDPF	5
1.4.1 Descripción de las etapas del TFDPF	6
Capítulo 2. Bioseñales.	7
2.1 Descripción de bioseñal	7
2.2 Neurona como precursora de la bioseñal	7
2.3 Electroencefalograma (EEG).....	8
2.3.1 Rango de frecuencia Beta (β)	11
2.3.2 Rango de frecuencia Alfa (α)	11
2.3.3 Rango de frecuencia Theta (θ)	12
2.3.4 Rango de frecuencia Delta (δ)	12
2.3.5 Rango de frecuencia Gamma (γ)	13
2.3.6 Ritmo Mu (μ)	13
Capítulo 3. Electroencefalografía.	15
3.1 Técnicas actuales.....	15
3.1.1 Electroencefalografía (EEG).....	16
3.1.2 Magneto encefalografía (MEG)	17
3.1.3 Imagen por resonancia magnética funcional (fMRI)	18
3.1.4 Tomografía de emisión de positrones (PET)	19
3.1.5 Resonancia magnética espectroscópica (MRS)	19
3.1.6 Imagen por ultrasonidos 2D (2D- Ultrasound Imaging)	20
3.1.7 Tomografía cerebral por computación activa de microondas (EMIT)	20
3.1.8 Espectroscopía de Infrarrojo Cercano (NIRS o fNIR)	21

3.1.9 Tomografía computerizada de emisión mono fotónica (SPECT).....	21
3.2 Disposición espacial de electrodos en EEG	22
3.3 Principios básicos de diagnóstico EEG.	25
Capítulo 4. Formatos de archivo para el intercambio de bioseñales.....	26
4.1 Experiencias internacionales para la normalización	28
4.2 El formato GDF	28
4.2.1 Introducción	29
4.2.2 Estructura	30
4.2.3 Especificaciones.....	30
Capítulo 5. Sistemas Brain Computer Interface	32
5.1 Definición de sistema BCI.....	32
5.2 Descripción de un sistema BCI	32
5.3 Tipos de BCI	33
5.3.1 Imagen motora.....	34
5.3.2 P300.....	35
5.3.3 Potenciales Visuales Evocados Fijos o Estacionarios (SSVEP)	35
5.2 Imaginando el movimiento	35
5.3 Competiciones en BCI	37
Capítulo 6. Extracción de las características.	39
6.1. Densidad Espectral de Potencia (PSD).	41
6.2 Parámetros de Hjörth.....	42
6.3 Modelo adaptativo autorregresivo (AAR)	43
Capítulo 7. Clasificación de características.	45
7.1 FLD (Discriminante lineal de Fisher).....	45
7.2 SVM (Máquina de soporte vectorial)	48
Capítulo 8. Sistema BCI utilizado.....	49
8.1 Hardware g.USBamp.....	49

8.1.1 Casco gEEGcap.....	51
8.1.2 Electrodo Ag/AgCl (Plata/Cloruro de Plata).....	51
8.2 Software Simulink (MATLAB)	53
8.3 Paradigma utilizado.....	54
8.4 Esquema de extracción y clasificación	56
8.5 Resultados	57
8.5.1 Sujetos de estudio.....	57
8.4.1 Sujeto 1:	58
8.4.2 Sujeto 2:	59
8.4.3 Sujeto 3:	61
8.4.4 Sujeto 4:	62
8.4.5 Sujeto 5:	64
8.5 Conclusiones y trabajo futuro	66
Referencias bibliográficas	67
ANEXO (datos obtenidos en experimentos)	74

Índice de ilustraciones

Ilustración 1. Sistema BCI basado en la señal de EEG.....	3
Ilustración 2. Datos y Diagrama de Gantt del TDFPF.....	5
Ilustración 3. Representación de las partes de una neurona.....	7
Ilustración 4. Espectro en frecuencia de una señal EEG.....	9
Ilustración 5. Algunos ejemplos de señales EEG.....	10
Ilustración 6. Representación temporal bioseñal Beta.....	11
Ilustración 7. Representación temporal bioseñal Alfa.....	11
Ilustración 8. Representación temporal bioseñal Theta.....	12
Ilustración 9. Representación temporal bioseñal Delta.....	12
Ilustración 10. Representación temporal bioseñal Gamma.....	13
Ilustración 11. Representación temporal bioseñal ritmo Mu.....	13
Ilustración 12. Se observan las características principales de estas desde el punto de vista de resolución temporal y espacial de algunas de las técnicas citadas anteriormente.....	15
Ilustración 13. Equipos usados en EGG.....	16
Ilustración 14. Equipos usados en MEG.....	17
Ilustración 15. Equipos usados en fMRI.....	18
Ilustración 16. Equipos usados en PET.....	19
Ilustración 17. Equipos usados en MRS.....	19
Ilustración 18. Equipos usados en 2D.....	20
Ilustración 19. Equipos usados en EMIT.....	20
Ilustración 20. Equipos usados en fNIR.....	21
Ilustración 21. Equipos usados en SPECT.....	21
Ilustración 22. El sistema internacional 10-20 visto a partir de (A) a la izquierda y (B) por encima de la cabeza.....	22
Ilustración 23. Ubicación y nomenclatura de los 10% electrodos intermedios, estandarizadas por la Sociedad Americana electroencefalográfica.....	23
Ilustración 24. (A) Medición bipolar y (B) Mediciones unipolares.....	24
Ilustración 25. La actividad del EEG es dependiente del nivel de consciencia..	25
Ilustración 26. Logotipo del Proyecto BioSig.....	28
Ilustración 27. Ejemplo de un sistema BCI completo.....	33
Ilustración 28. Regiones sensitivas motoras cerebrales.....	36
Ilustración 29. Esquema temporal de las pruebas. Pruebas con realimentación (a) y sin realimentación (b).....	38
Ilustración 30. Extracción de características a partir de señales EEG.....	39
Ilustración 31. Clasificador lineal.....	46
Ilustración 32. g.USBamp.....	50
Ilustración 33. Casco g.EEGcap utilizado.....	51
Ilustración 34. Imagen de electrodo utilizado.....	51
Ilustración 35. Disposición de los electrodos para la adquisición de las bioseñales.....	52
Ilustración 36. Ejemplo de uso de Simulink.....	53
Ilustración 37. Esquema temporal del paradigma utilizado.....	55
Ilustración 38. Esquema extracción y clasificación.....	56
Ilustración 39. Imagen Sujeto 1.....	58
Ilustración 40. Clasificación FLD sujeto 1.....	58
Ilustración 41. Clasificación SVM sujeto 1.....	59
Ilustración 42. Imagen Sujeto 2.....	59

Ilustración 43. Clasificación FLD sujeto 2.....	60
Ilustración 44. Clasificación SVM sujeto 2.....	60
Ilustración 45. Imagen Sujeto 3.....	61
Ilustración 46. Clasificación FLD sujeto 3.....	61
Ilustración 47. Clasificación SVM sujeto 3.....	62
Ilustración 48. Imagen Sujeto 4.....	62
Ilustración 49. Clasificación FLD sujeto 4.....	63
Ilustración 50. Clasificación SVM sujeto 4.....	63
Ilustración 51. Imagen Sujeto 5.....	64
Ilustración 52. Clasificación FLD sujeto 5.....	64
Ilustración 53. Clasificación SVM sujeto 5.....	65

Índice de tablas

Tabla 1. Resumen de ritmos cerebrales describiendo la situación donde se producen.	14
Tabla 2. Distintos formatos de representación de señales e imágenes usados con bioseñales para su almacenamiento sobre ficheros de intercambio de datos.	27
Tabla 3. Estructura de un archivo de GDF.	31
Tabla 4. Sujetos y edad.	57

PALABRAS CLAVE: Bioseñal, Electroencefalograma (EEG), Brain Computer Interface (BCI), Extracción y Clasificación de Características, SVM, FLD, PSD, Hjorth, AAR.

Capítulo 1. Introducción y objetivos.

1.1 Introducción

“Coger un objeto o poder moverlo de un lugar a otro, no es que no quiera levantarme para hacerlo, es que mis limitaciones físicas me lo impiden”.

Es lo que diría cualquier persona con sus capacidades físicas limitadas. Es un grado de libertad que no tienen y es fundamental para una calidad de vida llamémosla digna.

Los sistemas de interfaz cerebro/ordenador (o BCI, del inglés Brain Computer Interface) permiten la implementación de sistemas de comunicación a partir del análisis de la actividad cerebral. El éxito de estos sistemas depende tanto del sistema implementado como de la habilidad del usuario a la hora de manejarlo. Por ello para obtener un mejor rendimiento debe haber una adaptación mutua entre el hombre y la máquina. La adaptación de la máquina se suele realizar al inicio de cada sesión de trabajo, para ello se capturan las primeras muestras de señal a través de un electroencefalograma (EEG) mientras el usuario realiza las tareas mentales que se le van indicando y seguidamente se realiza el ajuste de los pesos de los clasificadores para adaptarlo lo máximo posible al usuario. Sin embargo la adaptación de los usuarios al sistema es bastante más compleja. Se ha observado que cuando un grupo suficientemente grande de sujetos trata de interactuar con estos sistemas por primera vez mediante paradigmas de imaginación de movimiento, de forma natural hay algunos de estos sujetos que obtienen mejor resultado; siendo estos sensiblemente mayores que la media del grupo, y sin embargo, hay algunos sujetos que aunque se sometan a un proceso de entrenamiento sistemático nunca llegará controlar el sistema de forma satisfactoria. De hecho, se estima que casi un 20% de la población tiene serias dificultades para interactuar con sistemas BCI basados en este tipo de paradigmas.

1.2 Objetivos

En los últimos veinte años, el análisis y procesado de señales electroencefalográficas (EEG) ha despertado un gran interés en la comunidad científica gracias al amplio abanico de aplicaciones que ofrece, desde contextos clínicos hasta lúdicos e industriales [1-3]. Para problemas de discriminación de señales EEG, el procesado de las misma habitualmente se realiza en dos etapas fundamentales: extracción de información relevante y a continuación su clasificación.

El objetivo de este TFPD es la implementación y evaluación comparativa de distintas técnicas computacionales para el análisis de señales EEG. En concreto, se pretenden validar las técnicas lineales más utilizadas para la extracción de características y su clasificación [4] [5], con el fin de poder observar si se produce un incremento en el rendimiento del sistema si se asigna de forma particularizada a cada sujeto el clasificador y el método de extracción de características, en función del binomio que consiga un mejor resultado.

Además como aplicación práctica está observar que sucede al evaluar señales EEG obtenidas de cinco usuarios que no tenían experiencia previa en el manejo de estos sistemas. En particular, estos usuarios imaginaban el movimiento de su mano derecha o izquierda según le iba indicando el sistema, y realizaron una única sesión para entrenar al sistema y otra sesión para evaluar el rendimiento.

1.3 Resumen

La investigación y desarrollo de sistemas basados en el análisis de señales EEG es una actividad multidisciplinar en la que la técnica tiene un papel fundamental. A pesar de los años que se lleva investigando el cerebro, todavía no se conoce en profundidad su funcionamiento.

Las señales EEG generadas por nuestro cerebro están compuestas por estas ondas a diferentes frecuencias y su contribución varía de manera continua con el tiempo en función de la actividad mental realizada.

En general, tal y como muestra la ilustración 1, un Sistema BCI basado en la señal EEG consta de cuatro etapas principales:

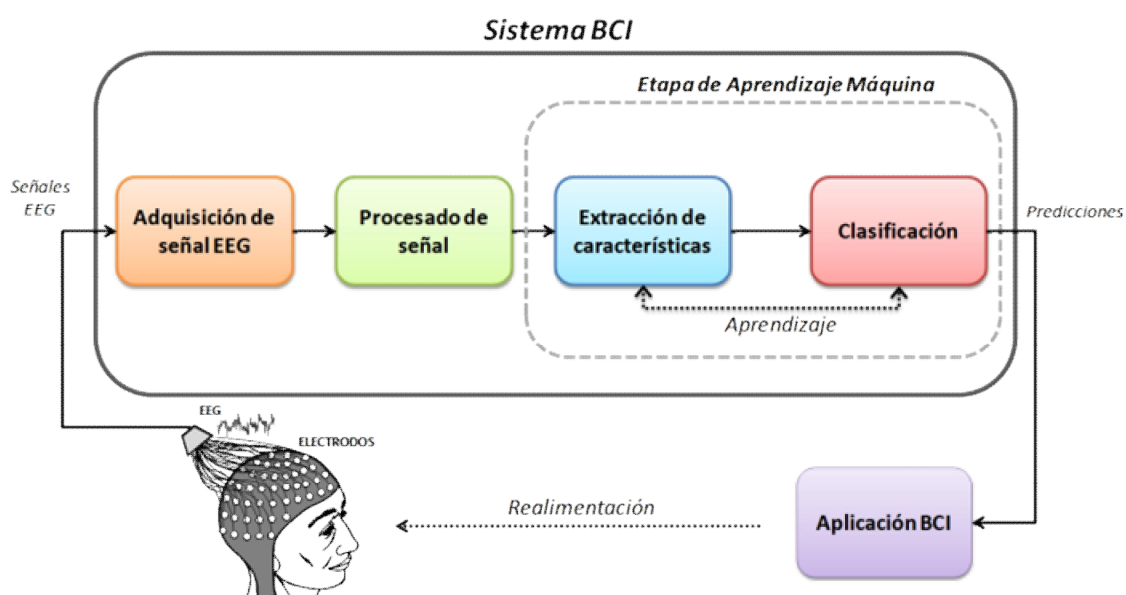


Ilustración 1. Sistema BCI basado en la señal de EEG

1) Adquisición de señal EEG. Las señales eléctricas generadas por el cerebro del sujeto, durante la realización de una actividad mental controlada, son registradas a través de métodos invasivos o no-invasivos. En esta fase, las señales EEG son digitalizadas y amplificadas.

2) Pre-procesado de señal. *Una vez que las señales han sido adquiridas, es necesario filtrar las señales y eliminar artefactos (señales que se encuentran superpuestas a la señal de interés), de tal forma que únicamente contengan la información discriminante asociada a la actividad mental realizada por el sujeto.*

3) Extracción de características. *En esta fase, a partir de las señales EEG pre-procesadas se extrae un conjunto variables numéricas (características) que contienen información discriminante para predecir el pensamiento del sujeto. Para ello se utilizan diferentes técnicas de extracción de características, como por ejemplo, características basadas en la densidad espectral de potencia, los parámetros de Hjorth y el análisis autorregresivo.*

4) Clasificación. *Tras la extracción de características, un clasificador es utilizado para encontrar el tipo de tarea mental que se realiza. El clasificador determina el tipo de la tarea mental a partir de la información discriminante contenida en las características extraídas de las señales EEG.*

De estas cuatro etapas, gran parte de los esfuerzos de la comunidad científica están centrados en la dos últimas. En concreto, para cada una de estas dos etapas se implementarán y evaluarán las siguientes técnicas:

A. Extracción de características:

- A.1. Densidad Espectral de Potencia (PSD, Power Spectral Density).
- A.2. Parámetros de Hjorth.
- A.3. Procesado adaptativo autorregresivo (AAR, Adaptive Auto Regressive).

B. Clasificación:

- B.1. Discriminante Lineal de Fisher (Fisher Linear Discriminant).
- B.2. Máquinas de Soporte Vectorial (Support Vector Machine).

Los resultados experimentales se obtendrán empleando distintos conjuntos de señales EEG. La implementación software se realizará en MATLAB.

Para llegar a todo lo explicado anteriormente se van a proceder a definir desde un principio los conceptos básicos para entender el funcionamiento de un proceso de este tipo, es decir, qué tipo de señales se estudian, en donde se producen, qué determina su presencia y cómo podemos utilizarlas para fines científicos.

1.4 Etapas del TDFPF

Mediante el siguiente diagrama de Gantt se clarifican las fases del trabajo realizado:

Etapas del TDFPF	Fecha de Inicio	Duración	Fecha Final
Etapa 1	01/10/2012	60	30/11/2012
Etapa 2	01/12/2012	15	16/12/2012
Etapa 3	01/01/2013	90	01/04/2013
Etapa 4	02/04/2013	60	01/06/2013
Etapa 5	02/06/2013	30	02/07/2013
Etapa 6	03/07/2013	60	01/09/2013




Ilustración 2. Datos y Diagrama de Gantt del TDFPF.

Capítulo 2. Bioseñales.

Se procede a describir el origen de las señales objeto de estudio.

2.1 Descripción de bioseñal

Se conoce como bioseñal a aquel indicador que un ser vivo produce, y que puede ser capturado utilizando determinadas técnicas y analizado posteriormente.

BIOSEÑAL	DEFINICIÓN	RANGO DE AMPLITUD (μV)	RANGO DE FRECUENCIA (Hz)
Electroencefalograma (EEG)	Actividad eléctrica cerebral	De 5 a $300\mu\text{V}$	DC-150Hz

2.2 Neurona como precursora de la bioseñal

La unidad básica del sistema nervioso tiene la capacidad de comunicarse eléctricamente con otras células, sean éstas nerviosas o no. La información viaja entre neuronas por medio de impulsos eléctricos que se transmiten de unas neuronas a otras. Estos impulsos, se reciben de otras neuronas en las dendritas y pasan a través de la neurona hasta ser conducidas por el axón a los terminales de salida, los cuales pueden conectarse con otra neurona, fibras musculares o glándulas (ver ilustración 3).




Ilustración 3. Representación de las partes de una neurona.

Cuando se produce un estímulo externo, el sistema nervioso actúa de la siguiente forma; cuando dicho estímulo es recibido en alguna región sensorial capturando alguna información, se transporta por el sistema nervioso (a través de las neuronas) hasta una componente integradora en donde se analiza. Esta componente elabora la respuesta, que es conducida a través de las neuronas hacia fibras musculares (respuesta motora) o hacia glándulas (secreción glandular). Hay que tener en cuenta que la actividad cerebral es producida por un número muy elevado de neuronas (aproximadamente cien mil millones en un cuerpo humano medio) y cada una de las tareas que nuestro cuerpo puede realizar provoca una actividad cerebral con forma e intensidad diferentes, además de localizarse en distintas zonas del sistema nervioso.

2.3 Electroencefalograma (EEG)

La primera grabación del campo eléctrico del cerebro humano fue realizada por el psiquiatra alemán Hans Berger en 1924 [6], otorgando a esta grabación el nombre de electroencefalograma (EEG). De 1929 a 1938 se publicaron 20 artículos científicos sobre el EEG con el mismo título "Über das Elektroencephalogramm des Menschen" que significa "Sobre el Electroencefalograma de personas".

Lo que se puede observar utilizando la técnica de EEG es lo siguiente:

- i Actividad espontánea.
- ii Potenciales evocados.
- iii Eventos bioeléctricos producidos por neuronas individuales.

La actividad espontánea se mide sobre el cuero cabelludo utilizando técnicas no invasivas o sobre la superficie del cerebro utilizando otras técnicas denominadas invasivas que requieren cirugía.

La amplitud del EEG es de aproximadamente $100 \mu\text{V}$ cuando se mide en el cuero cabelludo y alrededor de 1 a 2 mV cuando se mide en la superficie del cerebro. El ancho de banda de esta señal se puede definir desde por debajo de 1 Hz hasta aproximadamente los 50 Hz, como se describe en la ilustración 4.

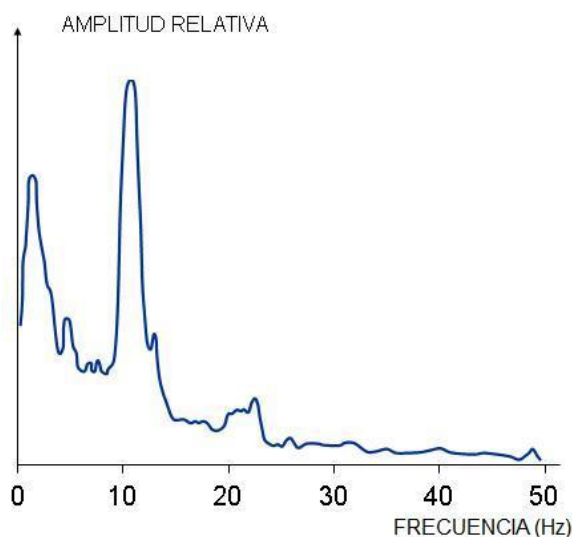


Ilustración 4. Espectro en frecuencia de una señal EEG.

Como indica la frase "actividad espontánea", esta actividad ocurre aleatoriamente y de manera continua en el individuo vivo.

Los potenciales evocados son los componentes del EEG que surgen en respuesta a un estímulo (que puede ser eléctrico, auditivo, visual). Dichas señales están, en general, por debajo del nivel de ruido y por lo tanto no se distinguen fácilmente por lo que hay que utilizar un tren de estímulos y promediar la señal para mejorar la relación señal/ruido.

La señal EEG es, por tanto, un tipo de bioseñal y contiene ciertas señales superpuestas que clasificaremos de acuerdo a su frecuencia y a su distribución en el cerebro, explicando a su vez su significado biológico y su posible uso en sistemas BCI.

Estas bandas de frecuencia son, en orden de menor a mayor frecuencia son; delta (δ), theta (θ), alfa (α), beta (β), y gamma (γ). A continuación, se detallarán algunas de las características más importantes de cada una de ellas.




Ilustración 5. Algunos ejemplos de señales EEG.

Mediante el EGG se realiza el registro eléctrico de dichas bioseñales en el cerebro y se va a realizar su descripción desde el punto de vista de la actividad eléctrica describiéndolas de mayor a menor actividad como sigue a continuación.

2.3.1 Rango de frecuencia Beta (β)

Queda definido entre los 13 Hz hasta los 30 Hz localizándose en las partes frontal y parietal del cerebro. Está asociado con un elevado nivel de concentración, atención y con la resolución de problemas. Se caracteriza por tener una distribución simétrica cuando no se está realizando ninguna actividad motora. Sin embargo, en el caso de realizar un movimiento se atenúa de manera que se rompe la distribución simétrica y esta acción de atenuación puede servir de base de estudio para este tipo de bioseñales.




Ilustración 6. Representación temporal bioseñal Beta.

2.3.2 Rango de frecuencia Alfa (α)

También llamadas Ondas de Berger, son detectadas mediante EEG y MEG. Se encuentran en la región occipital del cerebro y su frecuencia varía entre los 8 y 13 Hz. La amplitud de estos ritmos se incrementa al cerrar los ojos o estar en un estado de relajación, y se atenúa al abrir los ojos o hacer un esfuerzo mental. La frecuencia de los ritmos alfa puede ser inferior a 8 Hz en los niños jóvenes lo que puede hacer que se confundan con los ritmos theta. Los ritmos alfa pueden ser útiles para determinar el grado de cansancio mental ya que están relacionados con el esfuerzo mental. Dentro del mismo rango de frecuencias que los ritmos alfa, se puede encontrar también los ritmos mu. Aunque están localizados en el mismo rango de frecuencia existen importantes diferencias fisiológicas entre ellos. Al contrario que los ritmos alfa, los ritmos mu están muy relacionados con las actividades motrices.




Ilustración 7. Representación temporal bioseñal Alfa.

2.3.3 Rango de frecuencia Theta (θ)

Se extiende de los 4 a los 8 Hz. Este rango de frecuencia se ha asociado con actividades como la meditación o la creación. Normalmente, los ritmos theta se observan solamente en niños jóvenes pero también es posible encontrarlos en niños más mayores o adultos en estado de somnolencia o meditación. Se generan tras la interacción entre los lóbulos temporal y frontal.




Ilustración 8. Representación temporal bioseñal Theta.

2.3.4 Rango de frecuencia Delta (δ)

Se sitúan entre los 0.5 y los 4 Hz y la amplitud de las señales que se encuentran en esta banda decrece con la edad. Los ritmos delta sólo pueden ser observados en adultos cuando se encuentran en estado de sueño profundo y son totalmente inusuales en estado de vigilia. Debido a su baja frecuencia, es fácil confundir este tipo de señales con artefactos producidos por el movimiento de los músculos del cuello o la mandíbula.




Ilustración 9. Representación temporal bioseñal Delta.

2.3.5 Rango de frecuencia Gamma (γ)

Pertenecen al rango de frecuencias entre los 30 y 100 Hz. La presencia de ritmos gamma en la actividad cerebral de un adulto sano está relacionada con ciertas funciones motoras o percepciones. Se ha demostrado científicamente una relación en los seres humanos entre las actividades motoras y las ondas gamma durante la contracción muscular [7], lo que sugiere que existe una correlación entre la actividad gamma o beta y la fuerza ejercida por los músculos [8]. De la misma forma hay evidencias sobre el papel de la actividad gamma en la percepción de estímulos, tanto visuales como auditivos [9] [10]. En el diseño de BCI basados en EEG, los ritmos gamma se usan con menos frecuencia ya que los artefactos como la electromiografía (EMG) o electro-oculograma (EOG) afectan en mayor medida a este tipo de ritmos. No obstante, este rango de frecuencias está atrayendo una atención creciente porque, en comparación a las señales beta y alfa tradicionales, la actividad gamma podría aumentar la tasa de transferencia de información [11].




Ilustración 10. Representación temporal bioseñal Gamma.

2.3.6 Ritmo Mu (μ)

Es un tipo de onda similar a la alfa (de 8- 13Hz) que aparece sobre la corteza cerebral y que se atenúa con el movimiento e incluso con la sola intención de moverse.




Ilustración 11. Representación temporal bioseñal ritmo Mu.

Ritmos	Situación mental a la que corresponde la onda cerebral
Delta	Con una frecuencia de 0.5-4 Hz, surgen principalmente en el sueño profundo y muy raras veces se pueden experimentar estando despierto. No suelen ser de interés en los BCI's.
Theta	Con una frecuencia de 4-8 Hz, se producen durante el sueño o en meditación profunda, entrenamiento autógeno, por la práctica del yoga o cualquier otra actividad que trabaje la relajación físico-mental. Las características de este estado son: memoria plástica, mayor capacidad de aprendizaje, fantasía, imaginación e inspiración creativa. Se localiza en zona parietal-temporal.
Alfa	Tienen una frecuencia de 8–13 Hz y están asociadas con estados de relajación. Se registran especialmente momentos antes de dormirse. Está situado sobre las regiones posteriores de la cabeza y sobre las zonas occipitales. La amplitud es variable pero generalmente no es mayor de 50 micro-voltios. En adultos se observa al cerrar los ojos o en estados de relajación y poca actividad mental. La amplitud disminuye durante la atención, especialmente visual, y durante el esfuerzo mental.
Beta	Originan un campo electromagnético con una frecuencia comprendida entre 13 y 30 Hz. Se registran cuando los sentidos se hallan volcados hacia el exterior y en plena actividad mental. Su amplitud es algo menor que las de ritmo alfa, localizándose en zona parietal y Frontal. Son más acusadas cuando tenemos el estado alfa bloqueado o en actividad mental intensa como estados de máxima alerta. A veces va asociada con el ritmo mu.
Mu	De frecuencia y amplitud similar al ritmo alfa. Generado por el área sensorio-motriz, situado en la zona central superior (posiciones C3, Cz y C4 del Sistema Internacional 10-20 descrito en la página 20). Está presente en estados de reposo o concentración y su amplitud disminuye durante la realización de movimientos o su imaginación motora.

Tabla 1. Resumen de ritmos cerebrales describiendo la situación donde se producen.

Capítulo 3. Electroencefalografía.

Aquí se describen las principales técnicas *no invasivas* para la obtención de las bioseñales descritas en el apartado anterior.

3.1 Técnicas actuales

En los estudios de la conectividad funcional cerebral existen distintas técnicas no invasivas entre las que destacan:

- Electroencefalografía (EEG).
- Magneto encefalografía (MEG).
- Imagen por resonancia magnética funcional (fMRI).
- Tomografía de emisión de positrones (PET).
- Resonancia magnética espectroscópica (MRS).
- Imagen por ultrasonidos 2D (2D-Ultrasound-Imaging).
- Tomografía cerebral por computación activa de microondas (EMIT).
- Tomografía óptica (NIRS).
- Tomografía computerizada de emisión mono-fotónica (SPECT).




Ilustración 12. Se observan las características principales de estas desde el punto de vista de resolución temporal y espacial de algunas de las técnicas citadas anteriormente.

*sEEG se refiere a la estéreo electroencefalografía, pero se considera técnica invasiva por tanto no se describió anteriormente.

3.1.1 Electroencefalografía (EEG)

La electroencefalografía (EEG) es una de las técnicas de la neurociencia que se utiliza con mayor frecuencia, especialmente por su reducido coste frente a los sistemas de imagen cerebral.

La actividad coordinada de miles de neuronas produce diferencias de potencial en el cuero cabelludo que pueden ser registradas utilizando electrodos en conjunción con amplificadores de señal. Es decir, colocando una serie de electrodos repartidos por la cabeza podemos hacernos una idea de en qué zonas de nuestro cerebro se está produciendo mayor actividad.

La EEG que toma datos del cuero cabelludo es una técnica no invasiva y silenciosa que es sensible a la actividad neuronal. Su resolución temporal está determinada por el *hardware* pero típicamente mide el voltaje entre 1 y 3 milisegundos. Esto supone una buena resolución temporal.

Sin embargo, la EEG tiene una resolución espacial muy limitada (debido al número de electrodos) y no ofrece datos fiables de las partes más internas del cerebro.

La principal ventaja de la EEG es que es una técnica con un coste moderado y que puede utilizarse con relativa facilidad. Por otra parte, la EEG ofrece libertad de movimientos al sujeto, ya que éste puede moverse en una estancia e interactuar (cosa que no podría hacer con una fMRI, por ejemplo).



Ilustración 13. Equipos usados en EEG.

3.1.2 Magneto encefalografía (MEG)

La MEG ofrece una calidad de señal superior y una resolución temporal muy alta. Sin embargo, sus costes son mucho mayores, lo que la hace una técnica no tan popular como la anterior. Un equipo de magneto encefalografía, que requiere una sala aislada de campos magnéticos para poder medir las débiles señales del cerebro, tiene un alto coste.

El cerebro humano tiene una dinámica interesante y relevante en todas las escalas espaciales, extendiéndose desde unas pocas neuronas a la corteza entera.

La resolución espacial de una técnica de medida particular selecciona ciertos procesos fisiológicos sobre otros. Investigaciones realizadas en animales se han centrado en las capacidades de información de unas pocas neuronas, usando medidas directas con electrodos implantados. Aunque las medidas de EEG integren sobre la actividad de 10-100 millones de neuronas, hay prueba más que suficiente que la información relevante está representada en estas largas escalas. De hecho, interacciones entre las áreas alejadas del cerebro debe implicar escalas espaciales grandes. Además, varias técnicas se han desarrollado para mejorar la resolución espacial del EEG registrado a nivel del cuero cabelludo para poder estimar tal comportamiento dinámico.



Ilustración 14. Equipos usados en MEG.

3.1.3 Imagen por resonancia magnética funcional (fMRI)

La imagen por resonancia magnética funcional (fMRI, del inglés funcional Magnetic Resonance Imaging) es una técnica de neuroimagen que detecta cambios en el volumen, flujo y nivel de oxigenación de la sangre a través de campos electromagnéticos.

Uno de los principales usos de fMRI es localizar áreas especialmente activas en el interior del cerebro gracias a que puede proporcionar una alta resolución espacial [12]. Por esto, fMRI no parece ser adecuada para aplicaciones BCI que requieran una comunicación rápida. La introducción de fMRI en el diseño de sistemas BCI es relativamente reciente. Tradicionalmente, la adquisición de señales cerebrales a través de fMRI requiere mucho tiempo. Antes de que surgieran sistemas fMRI de tiempo real, los datos adquiridos mediante fMRI tenían que ser procesados posteriormente y los resultados no llegaban a estar disponibles hasta después de horas o incluso días. Gracias a la creación de fMRI de tiempo real, ha sido posible diseñar BCI basados en esta modalidad de adquisición [12-15]. No obstante, no se espera que la aplicación de fMRI en sistemas BCI llegue más allá de los experimentos clínicos en un laboratorio porque requiere dispositivos que son demasiado voluminosos y con un coste elevado.



Ilustración 15. Equipos usados en fMRI.

3.1.4 Tomografía de emisión de positrones (PET)

Esta técnica permite observar el flujo sanguíneo o el metabolismo en una parte del cerebro. Al sujeto se le inyecta glucosa radiactiva que seguidamente es detectada en las áreas más activas del cerebro.



Ilustración 16. Equipos usados en PET.

3.1.5 Resonancia magnética espectroscópica (MRS)

Espectroscopia por resonancia magnética (MRS) es una técnica diagnóstica que ofrece una valoración bioquímica, metabólica y funcional seriadas en enfermedades del sistema nervioso central que complementan los estudios convencionales.

Imágenes por resonancia magnética (fMRI) y MRS son básicamente la misma técnica que difieren solo en la forma como se procesan y se presentan los datos. Ambas son gobernadas por los mismos principios físicos.



Ilustración 17. Equipos usados en MRS.

3.1.6 Imagen por ultrasonidos 2D (2D- Ultrasound Imaging)

Las imágenes por ultrasonido, también denominadas exploración por ultrasonido o ecografía, involucran la exposición del cuerpo a ondas acústicas de alta frecuencia para producir imágenes del interior del organismo.

Al ser en tiempo real se pueden medir y estudiar diferencias en imágenes consecutivas en lugares del cerebro localizados.



Ilustración 18. Equipos usados en 2D.

3.1.7 Tomografía cerebral por computación activa de microondas (EMIT)

Permite medir las propiedades fisiológicas de los tejidos en tiempo real, basado en la diferenciación de las propiedades dieléctricas de los mismos.



Ilustración 19. Equipos usados en EMIT.

3.1.8 Espectroscopía de Infrarrojo Cercano (NIRS o fNIR)

Es un tipo de topografía óptica basado en emisores y receptores de infrarrojos repartidos por el cuero cabelludo. Se realiza la medición de longitud de onda e intensidad de la absorción de luz infrarroja cercana realizada por la muestra. La luz infrarroja cercana se extiende en un rango de 800 nm - 2.5 μm y tiene energía suficiente para excitar sobretonos y combinaciones de vibraciones moleculares a altos niveles de energía.



Ilustración 20. Equipos usados en fNIR.

3.1.9 Tomografía computerizada de emisión mono fotónica (SPECT)

Es una técnica muy parecida a una radiografía, pero utiliza una cámara sensible a los rayos gamma y no a los rayos X. Como en una radiografía, cada una de las imágenes que se obtienen es bidimensional, pero pueden combinarse muchas imágenes tomadas desde distintas posiciones alrededor del paciente para obtener una imagen tridimensional. Esta imagen tridimensional puede después manipularse mediante software para obtener secciones dimensionales del cerebro en cualquier orientación.



Ilustración 21. Equipos usados en SPECT.

3.2 Disposición espacial de electrodos en EEG

El sistema internacional 10-20 se emplea generalmente para registrar el EEG espontáneo [16]. En este sistema, 21 electrodos se encuentran en la superficie del cuero cabelludo, como se muestra en la ilustración 22 A y B. Las posiciones se determinan como sigue: Los puntos de referencia son nasión, que es el hueco que se encuentra en la parte superior de la nariz a nivel de los ojos e inión, que es el bulto óseo en la base del cráneo en la línea media de la parte posterior de la cabeza. A partir de estos puntos, los perímetros del cráneo se miden en los planos transversal y meridiano. Las localizaciones de los electrodos se determinan dividiendo estos perímetros en intervalos de 10% y 20%.

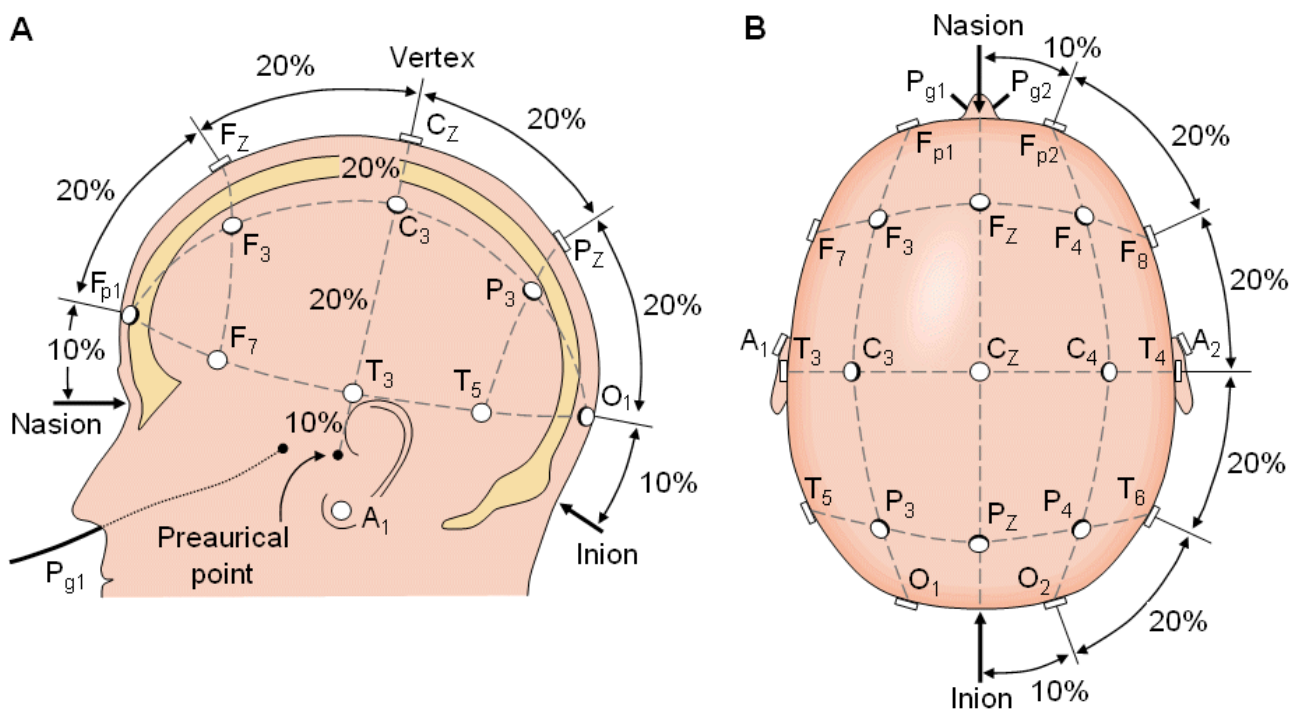


Ilustración 22. El sistema internacional 10-20 visto a partir de (A) a la izquierda y (B) por encima de la cabeza.

A = lóbulo de la oreja, C = centro, Pg = nasofaríngeo, P = parietal, F = frontal, Fp = frontal polar, O = occipital.

Además de los 21 electrodos del sistema internacional 10-20, también se utilizan intermedios 10% posiciones de los electrodos. Las ubicaciones y la nomenclatura de estos electrodos están estandarizados por la Sociedad Americana electroencefalográfica (Sharbrough, 1991; ver Ilustración 23).

En esta recomendación, cuatro electrodos tienen nombres diferentes en comparación con el sistema de 10 a 20, que son T7, T8, P7 y P8. Estos electrodos se dibujan negro con texto en blanco en la figura.




Ilustración 23. Ubicación y nomenclatura de los 10% electrodos intermedios, estandarizadas por la Sociedad Americana electroencefalográfica.

A parte del sistema internacional 10-20, existen muchos otros sistemas que utilizan electrodos para el registro de los potenciales eléctricos en el cuero cabelludo. El sistema cuadrado de la reina de colocación de los electrodos se ha propuesto como un estándar en grabar el patrón de los potenciales evocados en ensayos clínicos.

La medición bipolar o de electrodos unipolares son también técnicas utilizadas en la medición de EEG. En el primer método se mide la diferencia de potencial entre un par de electrodos. En el segundo método, el potencial de cada electrodo se compara, ya sea con un electrodo neutro o con la media de todos los electrodos (véase la ilustración 24).

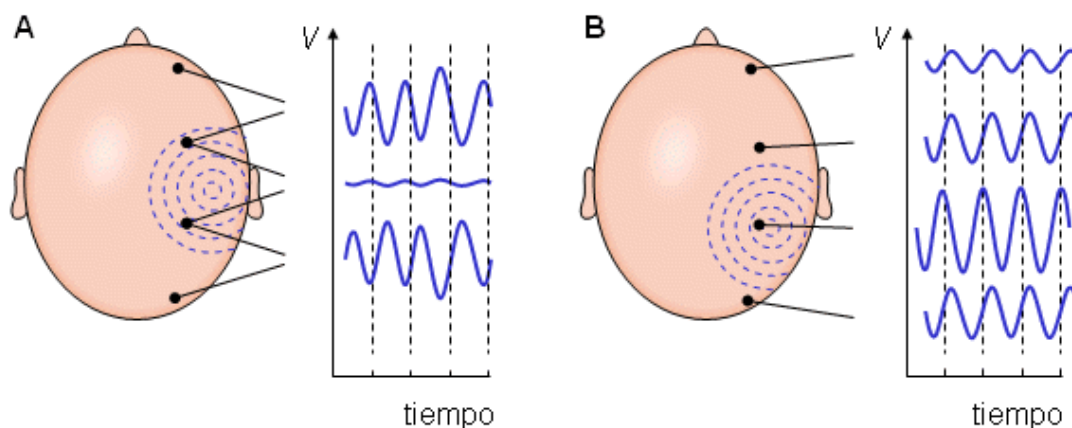


Ilustración 24. (A) Medición bipolar y (B) Mediciones unipolares.

. Hay que tener en cuenta que la forma de onda del EEG depende de la ubicación de los electrodos en la medición.

3.3 Principios básicos de diagnóstico EEG.

La señal del EEG está estrechamente relacionada con el nivel de consciencia de la persona. A medida que aumenta la actividad cerebral, los cambios en EEG se producen a mayores frecuencias y a su vez disminuyen las señales en amplitud. Cuando los ojos están cerrados, las ondas alfa empiezan a dominar el EEG. Cuando la persona se duerme, la frecuencia EEG dominante disminuye. En una cierta fase de sueño con movimientos oculares rápidos llamado (REM) puede ser adquirida como una señal de EEG característica. En el sueño profundo, el EEG tiene variaciones de señal de gran amplitud y alta frecuencia que son las citadas anteriormente como ondas delta. Cuando no hay actividad cerebral se puede determinar la muerte cerebral completa de un paciente. Los ejemplos de las formas de onda antes mencionados se dan en la ilustración siguiente.




Ilustración 25. La actividad del EEG es dependiente del nivel de consciencia.

Capítulo 4. Formatos de archivo para el intercambio de bioseñales.

Una vez conocida la forma de obtener las bioseñales se estudia el tipo de formato óptimo para el intercambio de los archivos que contienen la información.

Hay diversos formatos de archivo con los que trabajan herramientas como BioSig, para su tratamiento con programas como Matlab u Octave.

También son diversos los argumentos para la elección de un estándar de intercambio de señales u otro, algunos de los mismos se definen a continuación.

- En la evolución temporal de una enfermedad que requiere el almacenaje de exámenes hechos durante largos periodos. El almacenamiento digital de la información facilita y acelera la comparación entre distintos exámenes. Por otro lado, la evolución tecnológica constante y el uso de la compatibilidad, así como también el desarrollo de formatos abiertos para los archivos de señales, son esenciales para garantizar la correcta recuperación de datos en el futuro.
- En telemedicina para facilitar la distribución de datos de pacientes entre hospitales en tiempo real y es necesario que haya un acuerdo para que disponer de un formato común de datos.
- En investigación con el fin de analizar los efectos de una nueva medicina o diagnosticar una enfermedad en donde por lo general es necesario analizar y comparar grandes volúmenes de registros médicos y exámenes de varios grupos de pacientes. En la mayoría de las pruebas a gran escala de este tipo, los exámenes se realizan en diferentes lugares, posiblemente con diferentes marcas de equipos. Para poder procesar los datos de los exámenes procedentes de diferentes lugares, es conveniente un formato de almacenamiento único en todos los lugares.

- En estudios en ingeniería para ayudar al propio diagnóstico médico, mediante la caracterización de señales, su procesado o el análisis sobre registros reales de bioseñales. El formato estandarizado permite una lectura eficaz de los registros y una interacción con los datos, como puede ser el marcado de eventos tras su procesado para que este sea fácilmente interpretado a su vez por otros investigadores, siguiendo las indicaciones de un estándar.

<i>Bioseñal</i>	<i>Definición</i>	<i>Rango amplitud</i>	<i>Rango frecuencia</i>
<i>Electrocardiograma (ECG)</i>	Actividad eléctrica cardíaca	0.5 - 4 mV	0.01-250 Hz
<i>Electroencefalograma (EEG)</i>	Actividad eléctrica cerebral	5 - 300 μ V	DC-150 Hz
<i>Electrogastrograma (EGG)</i>	Actividad eléctrica gástrica	10 μ V - 1 mV	DC-1 Hz
<i>Electromiograma (EMG)</i>	Actividad eléctrica muscular	0.1 - 5 mV	DC-10 kHz
<i>Electroneurograma (ENG)</i>	Actividad eléctrica nerviosa	0.01 - 3 mV	DC-1 kHz
<i>Electrooculograma (EOG)</i>	Potencial retina-córnea	50 - 3500 μ V	DC-50 Hz
<i>Electrorretinograma (ERG)</i>	Actividad eléctrica de la retina	0 - 900 μ V	DC-50 Hz
<i>Fonocardiograma (PCG)</i>	Sonidos cardíacos	80 dB (rango dinámico) 100 μ Pa (umbral)	5-2000 Hz
<i>Flujo sanguíneo</i>	Flujo sanguíneo	1 - 300 ml/s	DC - 20 Hz
<i>Gasto cardíaco</i>	Cantidad de sangre bombeada por el corazón en unidad de	4 - 25 litros/minuto	DC - 20 Hz
<i>pH sanguíneo</i>	Medida del pH en sangre	6.8 - 7.8 unid. pH	DC - 2 Hz
<i>Plestimografía</i>	Medida de cambios de volumen	Depende del órgano medido	DC-30 Hz
<i>Pneumotacografía</i>	Medida del flujo respiratorio	0-600 litros/minuto	DC-40 Hz
<i>Potencial acción</i>	Potencial característico de diferentes tipos de células	100 mV	2 kHz
<i>Potenciales evocados (EP)</i>	Respuestas cerebrales evocadas por estímulos sensoriales	0.1 - 10 μ V	0.5 - 3 kHz
<i>Presión arterial</i>	Presión sanguínea arterial	10 - 400 mm Hg	DC - 50 Hz
<i>Presión venosa</i>	Presión sanguínea venosa	0 - 50 mm Hg	DC - 50 Hz
<i>Respuesta galvánica de la piel (GSR)</i>	Potencial generado por la	1 - 500 k Ω	0.01 -1 Hz

Tabla 2. Distintos formatos de representación de señales e imágenes usados con bioseñales para su almacenamiento sobre ficheros de intercambio de datos.

4.1 Experiencias internacionales para la normalización

En los últimos quince a veinte años, ha habido una creciente actividad relacionada con los esfuerzos para la normalización del formato de almacenamiento e intercambio de bioseñales por algunas instituciones internacionales, principalmente en EE.UU. y Europa. El Comité Europeo de Normalización (CEN), posee un Comité Técnico (TC) 251, éste es un grupo de trabajo dentro de la Unión Europea que se ocupa de la normalización en el ámbito de las tecnologías de la Información y las Comunicaciones (TIC) en la salud.

4.2 El formato GDF

Las señales biomédicas son guardadas en muchos formatos de datos diferentes. La mayoría de los formatos han sido desarrollados para un propósito específico de una comunidad especializada para la investigación del electrocardiograma, el análisis de EEG, investigación del sueño, etcétera. Hasta ahora ninguno de los formatos existentes pueden ser considerados un formato de datos universal para señales biomédicas. Para solucionar este problema y unificar las necesidades de los campos de procesamiento de señal biomédicas, se desarrolla el formato de datos general para señales biomédicas o GDF. Este formato está descrito completamente y especificado. El software para leer y escribir los datos GDF es implementado en Octave, Matlab y C / C + + y suministrado a través de BioSig [17] (una biblioteca de software de fuente gratis y abierta para el procesamiento de señal biomédico). BioSig también provee conversores de varios formatos de datos a GDF.



Ilustración 26. Logotipo del Proyecto BioSig.

4.2.1 Introducción

Las bioseñales se almacenan actualmente en una gran variedad de formatos diferentes. BioSig soporta aproximadamente 50 formatos de datos diferentes [17]. Muchos formatos de datos han sido desarrollados por compañías comerciales, por grupos de investigación y por organizaciones de normalización

La mayoría de los formatos de datos generaban sólo algunas necesidades específicas, pero no lo suficientemente flexibles en el campo de grabaciones de EEG e investigación en interfaz de cerebro/computadora o BCI. Por lo tanto, la primera versión del formato de datos general (GDF) que se desarrolló fue implementada con éxito y usada en investigación de BCI.

Suministra un esquema de codificación común para los eventos que se producen y respalda muchas características útiles (tasas de muestras diferentes, valores de calibración para canales diferentes utilizados, una detección de exceso automático, la codificación de ajustes de filtro etc.). En la actualidad hay nuevos requisitos que se pusieron en evidencia por parte de la comunidad investigadora y en esta descripción del formato GDF en su versión 2 se abordan necesidades como por ejemplo:

- La información específica en cuestión del paciente (el sexo, la edad, el deterioro, etc.).
- La ubicación de grabación, la identificación del software de grabación.
- Las posibilidades para guardar los puestos de electrodo en coordenadas espaciales, impedancias de electrodo, etc.
- La codificación más eficiente de la fecha y el tiempo las dimensiones físicas, la información de filtro.

4.2.2 Estructura

La estructura de GDF v2.0 tiene una cabecera fija con 256 octetos y una cabecera con la variable de 256 veces "number_of_channels" (número de canales). Por otra parte, GDF v2.0 soporta el almacenamiento de eventos (anotaciones y marcadores) y datos no equidistantes (de baja densidad) en la muestra. Con respecto al campo de identificación de la versión (primeros 8 bytes), es fácil escribir software que soporte todos los formatos de forma simultánea. BioSig proporciona la implementación prototipo para Octave / Matlab, así como C / C ++, como se mencionó anteriormente. El soporte para otros lenguajes de programación (como Python y Java) está bajo consideración.

4.2.3 Especificaciones

La estructura general de datos se define en la Tabla 9 (véase el anexo correspondiente). Un archivo de GDF se compone de los siguientes cinco componentes: la cabecera fija o cabecera 1 (con 256 bytes) que es obligatoria, la cabecera variable o cabecera 2 que contiene información específica del canal (número-de-canales 256 bytes), el encabezado TLV encabezado 3 contiene información opcional, la sección de datos y la tabla de eventos. El encabezado 2 puede estar vacío, en caso de que no se almacene la información del canal (por ejemplo, en los archivos de eventos puros).

	Description	size [bytes]	
1	Fixed header, (header1)	256	1
2	variable header, channel-specific information (header 2)	256*NS	1
3	optional header, tag-length-value structure, (header 3)	$\geq 4*NT + \text{length of each value field}$ $\leq \text{Length of header} - 256*(NS+1)$	$0 \leq NT < 256$
4	data section	number_of_records times bytes per record	≤ 1
5	event table	$8 + NEV*6$ {mode 1} or $8 + NEV*12$ {mode 3}	≤ 1

Tabla 3. Estructura de un archivo de GDF.

NS, NT, y NEV indican el número de canales, el número de elementos de TLV, y el número de eventos, respectivamente.

Capítulo 5. Sistemas Brain Computer Interface.

Se describe a continuación un sistema BCI completo como el que se ha utilizado para realizar la adquisición de bioseñales y se describen los tres tipos de sistemas BCI actuales desde el punto de vista de la actividad mental a realizar por el usuario.

5.1 Definición de sistema BCI

Una interfaz cerebro-ordenador (BCI) ofrece un nuevo canal de comunicación entre el cerebro humano y un ordenador. La actividad mental implica la actividad eléctrica y estas señales electrofisiológicas se pueden detectar con técnicas como el electroencefalograma EEG o el ECOG. El sistema BCI detecta esos cambios y los transforma en señales de control, que pueden ser utilizados para objetos en movimiento, escribir cartas, abrir puertas, cambiar canales de televisión y otras actividades de uso cotidiano. Esta tecnología ayuda a las personas con movilidad reducida aumentar su independencia. Uno de los principales objetivos es permitir que los pacientes completamente paralizados (síndrome locked-in, [18]) puedan comunicarse con su entorno.

5.2 Descripción de un sistema BCI

La investigación mediante sistemas BCI, como se comentó en la anterior definición, permite al sujeto o paciente aumentar su capacidad para interactuar con el exterior, ya que este permanece aislado sin poder comunicarse debido a discapacidades motoras causadas por trastornos tanto neurológicos como neuromusculares. Las distintas etapas en la que se pueden dividir un sistema de este tipo serían: la adquisición de la señal cerebral, el pre-procesamiento donde se lleva a cabo un filtrado, la mejora de la calidad de la señal, la extracción de sus características, su clasificación y el interfaz de control. En anteriores capítulos se han descrito los tipos de bioseñales y algunos métodos técnicos para su obtención, este apartado describe un sistema BCI desde el punto de vista de la extracción de esas características y su clasificación.

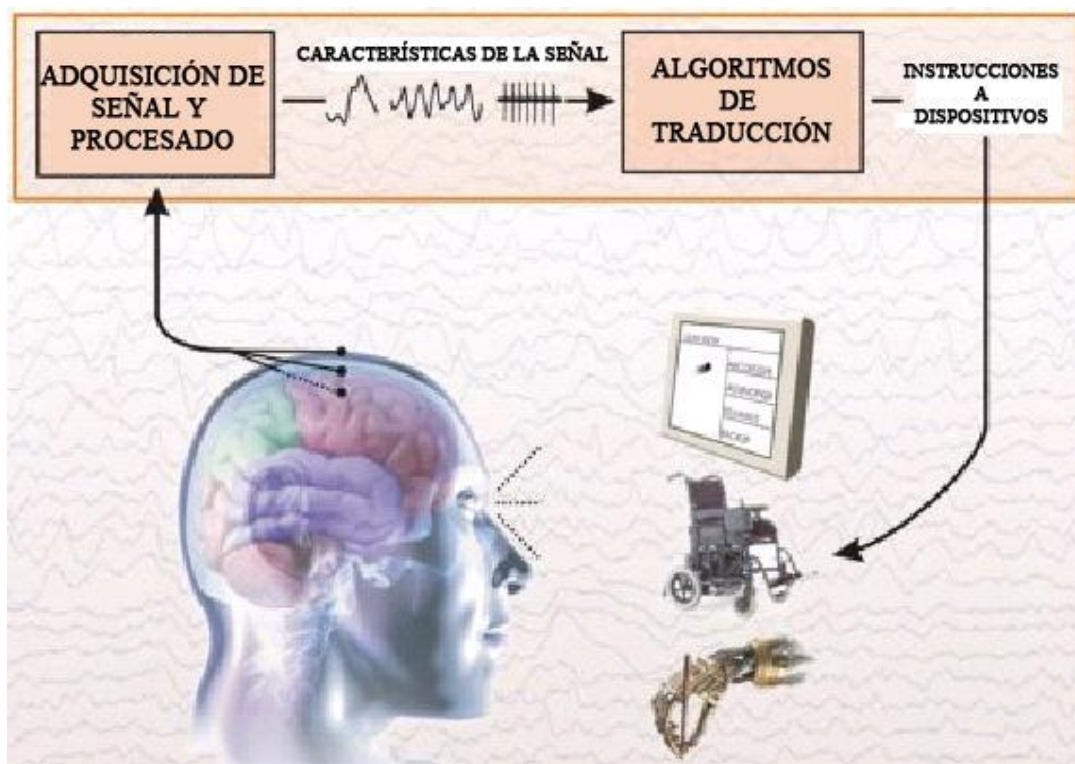


Ilustración 27. Ejemplo de un sistema BCI completo.

5.3 Tipos de BCI

Los BCI a menudo se clasifican de acuerdo al tipo de actividad mental que los usuarios tienen que realizar para enviar mensajes o comandos. La mayoría de BCI's se basan en uno de los tres tipos de actividades mentales:

- Imágenes del motor
- P300
- Potenciales Visuales Evocados fijos o estacionarios (SSVEP)

A continuación se describen detalladamente.

5.3.1 Imagen motora

El sujeto imagina realizar una acción, como apretar una pelota. Los datos del EEG se extraen y clasifican, para mostrar el resultado gráficamente al sujeto como una barra horizontal en la pantalla que se mueve bien hacia la derecha o izquierda correspondiéndose así con la imagen motora. La realimentación ayuda al sujeto a 'entrenar' dicha imagen motora, lo que conduce a una clasificación correcta. Para mejorar el rendimiento, el clasificador debe ser actualizado después de algunas sesiones de éxito. El análisis posterior de los datos registrados apoya la optimización de las características.

Ejemplos de aplicaciones: rehabilitación motriz de alguna extremidad dañada.

Recientemente los sistemas BCI también se utilizaron con fines de rehabilitación de motor para los pacientes con derrame cerebral. El sistema BCI se utiliza para medir la activación de la corteza sensitivo-motora de control externo dando apoyo a dispositivos robóticos como exoesqueletos o aparatos ortopédicos. El dispositivo robótico tiene el propósito de mover las extremidades del paciente y este volverá a activar la corteza sensitivo-motora. La activación puede ser vista como cambios ERD/ERS (Event Related Desynchronization/Event Related Synchronization) o eventos sincronizados o desincronizados en las señales de EEG [19].

Un motor a base de imágenes del sistema BCI es capaz de medir este cambio ERD / ERS y se puede utilizar como señal de control. Los patrones comunes de superposición espacial de la corteza sensitivo-motora ayudan a ganar rapidez y un control más preciso y peso de cada electrodo de acuerdo a su importancia. En lugar de dispositivos robóticos reales también las representaciones virtuales de las extremidades del cuerpo pueden ser utilizados para activar las neuronas espejo.

5.3.2 P300

La P300 es otro tipo de actividad cerebral que se pueden detectar con el EEG. Fue descubierto por primera vez por Sutton [20]. La P300 es un componente cerebral que se produce después de un estímulo y que en la señal del EEG se presenta como una onda positiva de 300 ms. después del inicio del estímulo. Los electrodos se colocan sobre el cuero cabelludo posterior.

Ejemplo de aplicaciones: Dispositivos de ortografía y dispositivos de casa inteligente.

5.3.3 Potenciales Visuales Evocados Fijos o Estacionarios (SSVEP)

Los Potenciales Visuales Evocados fijos o estacionarios (SSVEP) con base BCI utilizan varias fuentes de luz estacionaria oscilante como por ejemplo con LED parpadeantes donde cada uno de ellos oscila con una frecuencia única. Cuando una persona mira una de estas luces e incluso centra la atención en ella, la actividad EEG en el lóbulo occipital mostrará un aumento en el poder de la frecuencia correspondiente.

5.2 Imaginando el movimiento

Imaginar el movimiento es un proceso mental que se ha utilizado ampliamente en la investigación BCI. Esto conduce a la activación de aproximadamente las mismas áreas cerebrales que están involucradas en el movimiento real realizado [21]. Imaginar el movimiento de la mano derecha o de la izquierda activará las cortezas motoras primarias hacia la izquierda o la derecha, respectivamente. Esto se puede medir por la atenuación de los ritmos en curso en la señal del EEG. En secciones anteriores se han mencionado en detalles acerca de los patrones de activación cerebral y su uso en BCI.

La imaginación del movimiento físico produce cambios en la corteza sensorio-motriz. Por ejemplo, imaginar que se muestra una flecha de izquierda a derecha produce cambios de sincronización en las posiciones de los electrodos alrededor de C3 y C4 (en la ilustración 22 de la página 22). Estos cambios se observan alrededor de los 10 Hz y 20 Hz.




Ilustración 28. Regiones sensitivas motoras cerebrales.

5.3 Competiciones en BCI

Desde el año 2001, se ha llevado a cabo cada dos años una serie de competiciones en BCI en las que cualquier investigador podía demostrar la eficiencia de su sistema BCI empleando una serie de señales cerebrales proporcionadas por algunos de los más importantes grupos de investigación sobre BCI. Hasta ahora se han celebrado cuatro ediciones de esta competición BCI I, II (también llamada 2003), III y IV. Se ofrecen varios conjuntos de señales recogidas de algunos usuarios que están separadas en dos partes. Por un lado, se encuentra un subconjunto de señales etiquetadas en las que se conoce el estado mental del usuario, que sirven para como señales de entrenamiento. Por otro lado, se tiene señales sin etiquetar, que sirven para conocer el rendimiento del método propuesto una vez que la competición ha terminado.

Las competiciones BCI son un mecanismo que impulsa la investigación en BCI. Se ofrecen diferentes tipos de señales: potenciales P300 o también llamados potenciales cognitivos, SCP o potenciales corticales lentos y ritmos μ y β , señales relacionadas con la realización de movimientos y explicadas en el capítulo 2. Las competiciones proporcionan un conjunto de señales que pueden ser utilizadas por todos los investigadores de la comunidad científica. Esto hace mucho más sencilla la comparación de los diferentes métodos presentados por los investigadores. Además facilita la replicación de los estudios.

La forma de las señales que se recogen en estas competiciones, están asociadas a dos factores fundamentales:

- El estado mental en el que se encuentra el sujeto
- La actividad sensorial que se experimenta en el momento de la toma de los datos.

Estas competiciones poseen a su vez un paradigma o modelo para la realización de las pruebas donde se describe la forma de adquirir los datos por parte de los participantes, como ejemplo se muestra la ilustración siguiente:

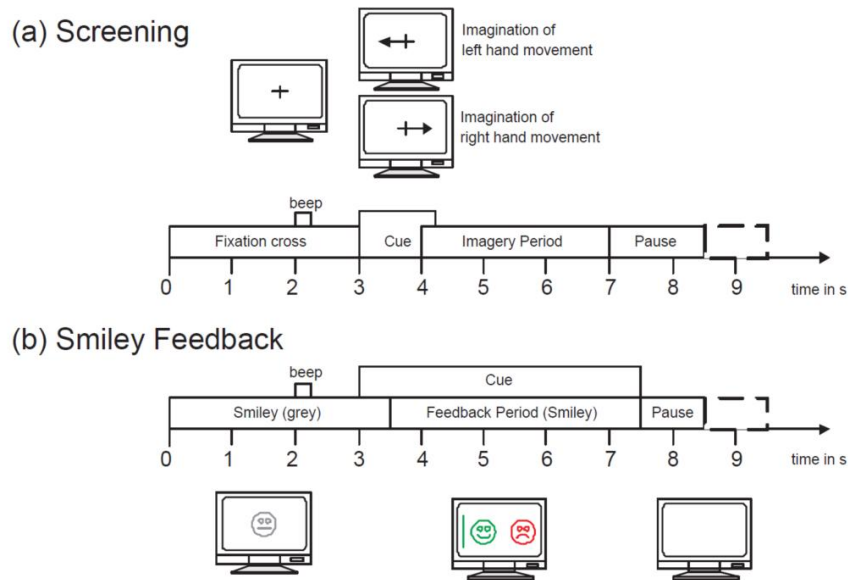


Ilustración 29. Esquema temporal de las pruebas. Pruebas con realimentación (a) y sin realimentación (b).

Capítulo 6. Extracción de las características.

Se describen los modelos matemáticos utilizados para analizar las bioseñales obtenidas.

La extracción de características intenta cuantificar de manera numérica los atributos de interés de las señales EEG. En otras palabras, durante la extracción de características se calculan un conjunto de variables numéricas a partir de las señales EEG, previamente adquiridas, y estas variables son recogidas un vector de datos o patrón. Así, se puede considerar la extracción de características como la compresión de datos que elimina la información irrelevante y conserva la información relevante de los datos en bruto. En el esquema de la ilustración 30 es posible utilizar diferentes métodos de extracción de características para aprovechar la información complementaria que pueda aportarnos cada método [22] [23] y no uno solo como hacen la mayoría de las publicaciones en BCI. Seguidamente, suele ser habitual incorporar una etapa de selección de características para obtener las más apropiadas para la clasificación. A modo ilustrativo se muestra un esquema general correspondiente a las etapas de extracción y selección de características. Como se puede ver, se consideran L técnicas distintas de extracción.

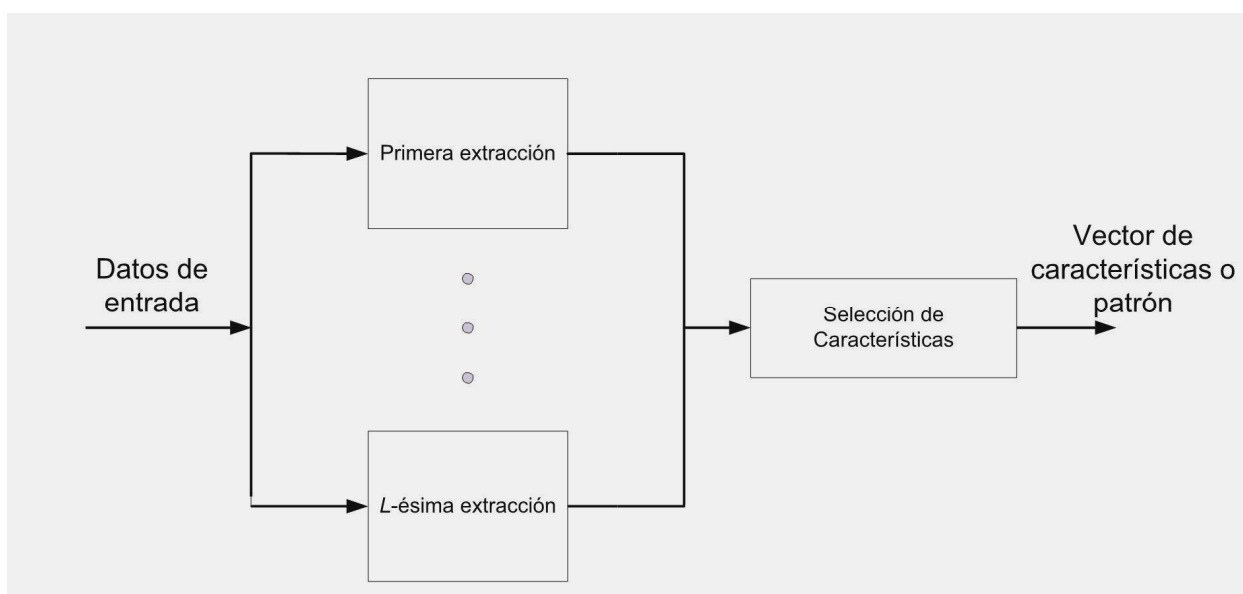


Ilustración 30. Extracción de características a partir de señales EEG.

Pensar en diferentes tareas tiene como resultado que se produzcan diferentes patrones en las señales cerebrales. Para clasificar cada uno de estos patrones en la clase a la que corresponde, se necesita extraer algunas de las características de las señales que reflejen sus similitudes con una clase determinada así como sus diferencias con el resto de las clases. De ahí que la extracción de un conjunto adecuado de características sea crucial para el funcionamiento preciso de un sistema BCI. Unas buenas características que discriminen de manera efectiva las señales son esenciales para el éxito de cualquier sistema de reconocimiento de patrones y su posterior clasificación.

Para conseguir unas tasas de reconocimiento elevadas en la posterior etapa de clasificación, hay una serie de aspectos que se deben considerar para un método de extracción de características:

- El tipo de señal que se captura, es decir, que paradigma es el que tiene que realizar el usuario y, por lo tanto, que “tarea” provoca su generación.
- Ofrecer una buena capacidad de discriminación (lo ideal, es un número reducido de clases y una gran separación entre ellas).
- Ser insensible a las variables externas (como el ruido y la interferencia).
- Ser relativamente rápido si la aplicación es en tiempo real.

Siguiendo la bibliografía de referencia en sistemas BCI, en este trabajo se trabaja con los siguientes métodos de extracción por su relevancia para paradigmas de imaginación de movimiento:

- i. Densidad Espectral de Potencia (PSD, Power Spectral Density).
- ii. Parámetros de Hjorth.
- iii. Procesado adaptativo autorregresivo (AAR, Adaptive Auto Regressive).

6.1. Densidad Espectral de Potencia (PSD).

La función de densidad espectral de potencia o PSD, es una función matemática que nos muestra como está distribuida la potencia o la energía sobre las distintas frecuencias de las que está formada su espectro [24]. En otras palabras, muestra en qué frecuencias las variaciones son fuertes y en qué frecuencias las variaciones son débiles. El cálculo de las características espectrales mediante la función PSD se realiza directamente con la transformada rápida de Fourier o FFT, (del inglés Fast Fourier Transform.) trabajando en las bandas α (8-13 Hz) y β (13-30 Hz). Así en las bandas α y β vienen dadas por:

$$P_{\alpha} = \frac{FFT^{*}(EEG_{\alpha}) \times FFT(EEG_{\alpha})}{p^2} \quad (6.1)$$

$$P_{\beta} = \frac{FFT^{*}(EEG_{\beta}) \times FFT(EEG_{\beta})}{p^2} \quad (6.2)$$

Donde p es el número de muestras de la ventana temporal, $FFT(EEG_{\alpha})$ denota la transformada rápida de Fourier en la banda α y $FFT^{*}(EEG_{\beta})$ es el complejo conjugado. La misma notación es empleada para la banda β de la señal EEG, (EEG_{β}) .

6.2 Parámetros de Hjörth

Los parámetros desarrollados por B. Hjörth, originalmente denominados descriptores normalizados de pendiente (NSD, del inglés Normalized Slope Descriptors), se aplican fundamentalmente a señales del tipo EEG. Los parámetros de Hjörth más utilizados son: la actividad, la movilidad y la complejidad [25]. Estos tres parámetros se definen a partir de diversos momentos estadísticos de la densidad espectral de potencia, que en el caso de los momentos de orden 0, 2 y 4 se obtienen con:

$$m_0 = \frac{1}{p} \sum_{i=1}^p x_i, \quad (6.3)$$

$$m_2 = \frac{1}{p} \sum_{i=1}^p d_i = \frac{1}{p} \sum_{i=1}^p (x_i - x_{i-1}), \quad (6.4)$$

$$m_4 = \frac{1}{p} \sum_{i=1}^p (d_i - d_{i-1})^2 = \frac{1}{p} \sum_{i=1}^p (x_i - 2x_{i-1} + x_{i-2})^2 \quad (6.5)$$

donde x_i es la muestra i -ésima de la señal EEG obtenida tras la adquisición y el preprocesado, considerando que la región de interés de la señal EEG está compuesta por p muestras.

La actividad h_0 , se define como el momento de orden 0:

$$h_0 = m_0 \quad (6.6)$$

la movilidad h_1 , se define como:

$$h_1 = \sqrt{\frac{m_2}{m_0}} \quad (6.7)$$

La complejidad h_2 , se define como:

$$h_2 = \sqrt{\frac{m_4}{m_2} - \frac{m_2}{m_0}} \quad (6.8)$$

6.3 Modelo adaptativo autorregresivo (AAR)

Un modelo autorregresivo (AR) es una técnica de modelado paramétrico que describe la muestra actual de la señal como una combinación lineal de las m muestras anteriores más un término de error. Los parámetros AR se calculan bajo la suposición de que la señal es estacionaria en cada segmento. Cuando los coeficientes de la combinación lineal varían con el tiempo se habla de modelos AR adaptativos [26], (AAR, del inglés Adaptive AutoRegressive).

De manera general, y considerando una señal EEG denotada por $s(t)$ en el dominio temporal, su modelo AR de orden m se puede expresar con la siguiente ecuación:

$$s(t) \approx s(t) + a_1 s(t-1) + \dots + a_m s(t-m), \quad (6.9)$$

donde m es el orden del modelo y $[1, a_1, \dots, a_m]$ es el vector de coeficientes del modelo lineal. Por lo tanto, tal y como vemos en (6.9), cada muestra de la señal de entrada es predicha por la suma ponderada de las m muestras anteriores, según el vector de coeficientes del modelo AR.

Durante la etapa de diseño de un modelo AR es necesario determinar dos parámetros: la longitud de la ventana de datos (es decir, duración de la señal sobre la que se ajustan los coeficientes del modelo p) y el orden del modelo (es decir, el número de coeficientes m). Actualmente, en la literatura no existe un único criterio ampliamente aceptado para la selección de estos dos parámetros, que deben ser seleccionados en función de la experiencia previa del investigador y los datos EEG analizados [27]. Así, por ejemplo, Schlögl considera un modelo con $m=3$ [28], Ince utiliza $m=6$ [29], y McFarland y Wolpaw emplean $m=16$ [30].

En realidad, los modelos AR pueden proporcionar estimaciones espectrales para los segmentos de cualquier duración. Sin embargo, esto no significa que las señales se puedan resolver con precisión infinita, es decir que la predicción sea exacta aumentando el orden del modelo. Adicionalmente, el modelado AR se acompaña de una serie de restricciones conectadas con importantes hipótesis analíticas:

- El proceso no debe ser anticipante (hipótesis de recursividad temporal); lo que quiere decir que los valores de una variable en un momento t no dependerán de los que ésta misma tome en $t + n$.
- La magnitud de los coeficientes está limitada en valor absoluto, así, por ejemplo, en el caso de un AR con $m = 1$, el coeficiente autorregresivo de un proceso estocástico estacionario ha de ser inferior a 1 en valor absoluto, en el caso de un AR con $m = 2$ es la suma de los dos coeficientes la que no puede exceder la unidad.

Por último, cabe destacar una evolución del modelado AR: el modelado adaptativo autorregresivo (AAR). La principal diferencia es que en el modelado AAR los parámetros (valores del vector de coeficientes del modelo) no son constantes y varían con el tiempo de forma adaptativa, por lo que estos parámetros describen el comportamiento temporal de la señal y la nueva ecuación queda tal y como se presenta a continuación:

$$s(t) \approx s(t) + a_1(t)s(t-1) + \dots + a_m(t)s(t-m), \quad (6.10)$$

En esta ecuación, m sigue siendo el orden del modelo y $[1, a_1(t), \dots, a_m(t)]$ son los parámetros variables del modelado AAR. Los algoritmos de estimación de los parámetros AAR tienen la ventaja de realizar una estimación temporal de alta resolución con un bajo coste computacional, y son por lo tanto válidos para aplicaciones en tiempo real, además son especialmente útiles cuando no se aplica un promediado temporal de la señal [26]. Algunos de estos algoritmos son: Least-Mean-Squares 'LMS' [31] [32], the Recursive-Least-Squares (RLS) [33], Recursive AR (RAR) [34] así como filtrado de Kalman

[35]. Un filtro de Kalman realiza la propagación de la densidad de probabilidad para problemas en los que el sistema puede ser descrito mediante un modelo lineal y los ruidos en las mediciones son gaussianos.

Capítulo 7. Clasificación de características.

Se describen los modelos matemáticos para analizar los resultados obtenidos del proceso anterior de extracción.

El objetivo de la etapa de clasificación de un sistema BCI es el reconocimiento de las intenciones del usuario en base a un vector de características que representa las propiedades de la señal recogida a partir de la actividad cerebral. Este vector como se ha explicado en secciones anteriores es generado por la etapa de extracción de características. Para lograr clasificar los vectores de características con el fin de clasificar las señales cerebrales se han propuesto varios algoritmos tales como clasificadores basados en el vecino más cercano o clasificadores lineales.

7.1 FLD (Discriminante lineal de Fisher)

El discriminante lineal de Fisher (FLD) es un clasificador bastante simple que proporciona una precisión bastante aceptable sin requisitos computacionales elevados. Este método de clasificación es muy común en la comunidad BCI y es una muy buena opción para el diseño de sistemas BCI online que requieran una respuesta rápida con recursos computacionales limitados. FLD se suele aplicar para clasificar los patrones encontrados en las señales cerebrales en dos clases. No obstante es posible extender el método a múltiples clases [36]. FLD ofrece una precisión relativamente aceptable y se han utilizado con éxito en numerosos sistemas BCI como dispositivos de escritura basados en respuestas P300 [37], BCI multiclase [36] o BCI síncronos [38]. Sin embargo, puede suceder que este clasificador lleve a conclusiones totalmente equivocadas cuando, entre los vectores de propiedades de entrenamiento que se emplean para construir el clasificador, existan valores atípicos o que hayan sido afectados severamente por el ruido [39].

Para un problema de dos clases, FLD supone que las dos clases son linealmente separables. Según esta hipótesis, se define una función lineal que representa un plano en el espacio de características para distinguir la clase a la que pertenece el vector de características a clasificar. La clase a la que el vector de propiedades pertenece se decide en función del lado del plano en el que se encuentra el vector de la siguiente ilustración.




Ilustración 31. Clasificador lineal.

La frontera de decisión es la línea continua. El margen del clasificador lineal es la mínima distancia de cualquier punto a la frontera de decisión. En este caso, el margen es la distancia entre las líneas punteadas y la línea continua.

El plano de decisión se puede representar matemáticamente como

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 \quad (7.1)$$

donde \mathbf{w} es conocido como el vector de pesos, \mathbf{x} es el vector de características de entrada y w_0 es un umbral. El vector de propiedades de entrada \mathbf{x} se asigna a una clase u otra en función del signo de $g(\mathbf{x})$.

Existen varios métodos para calcular \mathbf{w} . Por ejemplo, se puede calcular \mathbf{w} como [40]:

$$\mathbf{w} = \sum_c^{-1} (\mu_2 - \mu_1) \quad (7.2)$$

Donde μ_i es la media de clase i y $\sum_c = \frac{1}{2}(\sum_1 + \sum_2)$ es la matriz de covarianza común, que se calcula como la media de las matrices de covarianza de las dos clases.

La estimación de la media y la covarianza se hace según

$$\Sigma = \frac{1}{\mathbf{n}-1} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (7.3)$$

$$\mu = \frac{1}{\mathbf{n}} \sum_{i=1}^n x_i \quad (7.4)$$

Siendo x una matriz que contiene los \mathbf{n} vectores de propiedades $x_1, x_2, \dots, x_n \in \mathbb{R}^d$ utilizados para construir el clasificador lineal.

Como mejoras de este clasificador, se han propuesto algunos algoritmos como Bayesian FLD (BFLD) [41], que se puede ver como una extensión del algoritmo FLD. BFLD resuelve el problema del pequeño tamaño de la muestra introduciendo un método estadístico conocido como regularización. La regularización es realizada a través del análisis bayesiano de los datos de entrenamiento y se emplea para prevenir un sobre-entrenamiento del clasificador a datos de dimensión alta y posiblemente algunos ruidosos. El sobre-entrenamiento no es deseable en un clasificador porque pierde generalidad. Cuando un clasificador está sobre-entrenado solo es capaz de clasificar los datos que se proporcionaron como entrenamiento o aquéllos que se parezcan en gran medida a ellos. El algoritmo BFLD clasifica con mayor precisión y más rápidamente que FLD, especialmente en aquellos casos en los que el número de propiedades es grande [41]. Además, BFLD no consume mucho más tiempo de cálculo, que es un requisito esencial en sistemas BCI de tiempo real.

7.2 SVM (Máquina de soporte vectorial)

Una máquina de soporte vectorial (SVM, del inglés Support Vector Machine) es un clasificador que, de manera similar que FLD, construye un hiperplano o conjunto de hiperplanos, con el fin de separar los vectores de características en varias clases. Sin embargo, a diferencia del discriminante lineal, SVM selecciona los hiperplanos que maximizan los márgenes, es decir, la distancia de los vectores de propiedades a los hiperplanos [42]. Los vectores que se encuentran más cerca de estos hiperplanos se denominan vectores soporte.

Es muy habitual mapear los vectores de propiedades en un espacio multidimensional con dimensión más alta que el número de propiedades [43]. El teorema de Cover [44] afirma que un problema de clasificación complejo puede solucionarse con un clasificador lineal si se mapean los datos a un espacio de dimensión mayor. También, como para sucede en el caso de clasificación mediante FLD, SVM utiliza la regularización con el fin de evitar el clasificador de acomodar conjuntos de datos posiblemente ruidosos.

SVM se ha utilizado para clasificar vectores de características en problemas de dos clases [45-47] y multiclase [48] [49]. También se ha utilizado con éxito para el diseño de un gran número de BCI síncronos [47] [50].

SVM es considerado como un clasificador lineal, ya que para llevar a cabo la clasificación utiliza uno o varios hiperplanos. No obstante, es posible crear SVM que empleen límites de decisión no lineales por medio de un núcleo función $K(x, y)$. SVM no lineales proporcionan un límite de decisión más flexible lo que puede aumentar la precisión de clasificación. El kernel que se utiliza generalmente en el campo de los BCI es la función de base de Gauss o radial (RBF):

$$K(x, y) = \exp\left(\frac{-\|x - y\|^2}{2\sigma^2}\right) \quad (7.5)$$

El SVM con núcleo gaussiano se ha aplicado en el BCI para clasificar a los potenciales evocados P300 [51-53].

Capítulo 8. Sistema BCI utilizado.

8.1 Hardware g.USBamp

El g.USBamp es un amplificador de bioseñales de alto rendimiento y precisión a la vez que un sistema de adquisición y procesamiento de señales. Permite la investigación de las actividades cerebral, cardíaca y muscular, los movimientos oculares, la respiración, la respuesta galvánica de la piel y muchos otros parámetros fisiológicos y físicos. Debido a sus especificaciones técnicas y diversas opciones en el software, este instrumento se ha convertido en un estándar para muchos campos distintos de investigación, incluyendo la neuropsicología, la investigación médica y por supuesto la investigación en BCI.

El g.USBamp se compone de 16 canales de adquisición de bioseñales muestreadas simultáneamente con 24 bits y un total de 4 tierras independientes que garantizan que las señales adquiridas no interfieran entre ellas.

Es posible ensamblar un sistema multi-canal con más de 16 canales a través de múltiples dispositivos g.USBamp. Un cable de sincronización garantiza que todos los dispositivos sean muestreados con la misma frecuencia.

El amplificador tiene un rango de entrada de ± 250 mV, lo que permite la grabación de señales de DC sin saturación.

Además posee entradas y salidas digitales que permiten la grabación de canales de disparo junto con los canales de bioseñales para compartir de manera sencilla los resultados del análisis.

Los aspectos a destacar del uso de este hardware para sistemas BCI son los siguientes:

- 16 canales de alto rango por unidad (DC-Coupled), 4 tierras independientes, grabación de cualquier tipo de señal (EEG / ECoG / ECG...), conexión de varios sensores, ampliación de unidades hasta 32/48/64 canales.
- Resolución de 24 bits con muestreo simultáneo de todos los canales con un máximo de 38,4 kHz, filtración de señales digitales y procesamiento previo.
- Trabaja con electrodos pasivos y activos, 8 entradas de disparo digitales, 4 salidas digitales.
- Filtros de corte (Notch), filtros pasabanda digitales internos, unidad de calibración integrada y medición de impedancias.
- Fácil configuración y puesta en marcha a través del software y alta velocidad en el procesamiento de datos en línea disponibles para SIMULINK y para LabVIEW.



Ilustración 32. g.USBamp.

8.1.1 Casco gEEGcap.

Es un casco de goma donde se sitúan los electrodos en los huecos que se observan en la ilustración 32 dependiendo del tipo de disposición requerida para el estudio.



Ilustración 33. Casco g.EEGcap utilizado.

8.1.2 Electrodo Ag/AgCl (Plata/Cloruro de Plata)

El electrodo standard de plata/ploruro de plata está diseñado para medidas de alta fiabilidad en potenciales superficiales(requiere de un gel en contacto con el cuero cabelludo).



Ilustración 34. Imagen de electrodo utilizado.

Cinco electrodos estarán fijados en el casco según indica la ilustración 35. Los electrodos 1 y 3 registran la señal del hemisferio izquierdo y los electrodos en posiciones 2 y 4 la señal del hemisferio derecho. El electrodo situado en la posición 5 es para la señal de referencia.




Ilustración 35. Disposición de los electrodos para la adquisición de las bioseñales.

8.2 Software Simulink (MATLAB)

Simulink es un entorno de diagramas de bloque para la simulación. Ofrece un editor gráfico, bibliotecas de bloques personalizables y solvers para modelar y simular sistemas dinámicos.

Se integra con MATLAB, lo que permite incorporar algoritmos de MATLAB en los modelos y exportar los resultados de la simulación a MATLAB para llevar a cabo más análisis.

Además de sus conocidas prestaciones para el desarrollo y la implementación de algoritmos y modelos computacionales, en este trabajo se ha empleado MATLAB-Simulink debido a que la mayoría de los algoritmos de referencia están inicialmente desarrollados en esta plataforma.

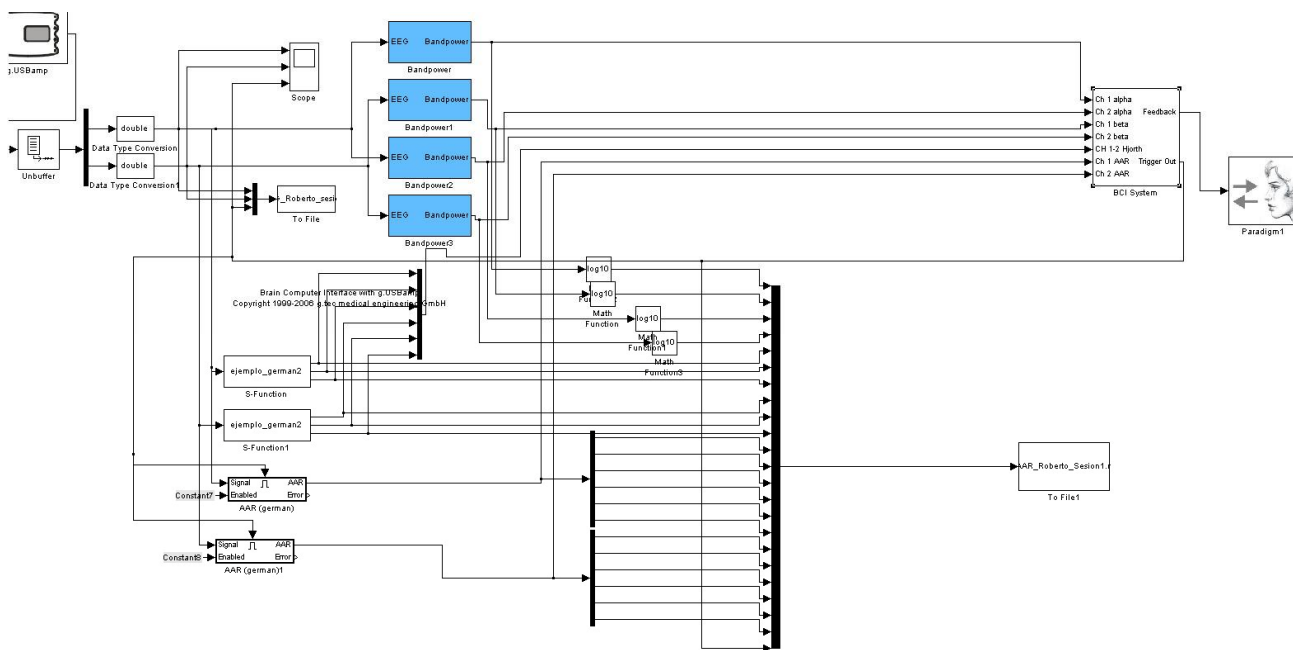


Ilustración 36. Ejemplo de uso de Simulink.

8.3 Paradigma utilizado

La salida del sistema de BCI está conectado al bloque paradigma, que es una función en MATLAB que controla el paradigma experimental.

La ilustración 30 muestra el momento en un ensayo del experimento. El sujeto se encuentra sentado a 1,5 m por delante de un monitor de PC y se le pide que no se mueva para intentar mantener los brazos y los pies relajados a la vez se le pide que mire fijamente al centro de la pantalla.

Los distintos pasos del experimento se describen a continuación:

El experimento comienza con una cruz fija que se muestra en el centro del monitor.

Después de dos segundos se reproduce una señal auditiva de advertencia en forma de un "beep" y una señal de disparo se fija en la salida del bloque paradigma.

Desde el segundo 3 hasta hasta el 4,25 segundos una flecha (estímulo), apuntando hacia abajo o hacia la derecha se muestra en el monitor.

En el experimento, al sujeto se le pide que imagine un movimiento de la mano o del pie derecho, dependiendo de la dirección de la flecha hasta 8 segundos.

Si el experimento se realizó con realimentación, una barra horizontal indica el resultado de la clasificación. La barra se extiende hacia el lado derecho si se imaginó la mano derecha y hacia abajo si se imaginó en esa dirección.

El experimento dura 8 segundos y el tiempo entre dos experimentos es aleatorio en un rango de 0,5 a 2,5 segundos para evitar la adaptación. El sujeto realiza 4 sesiones, con 40 experimentos por sesión.

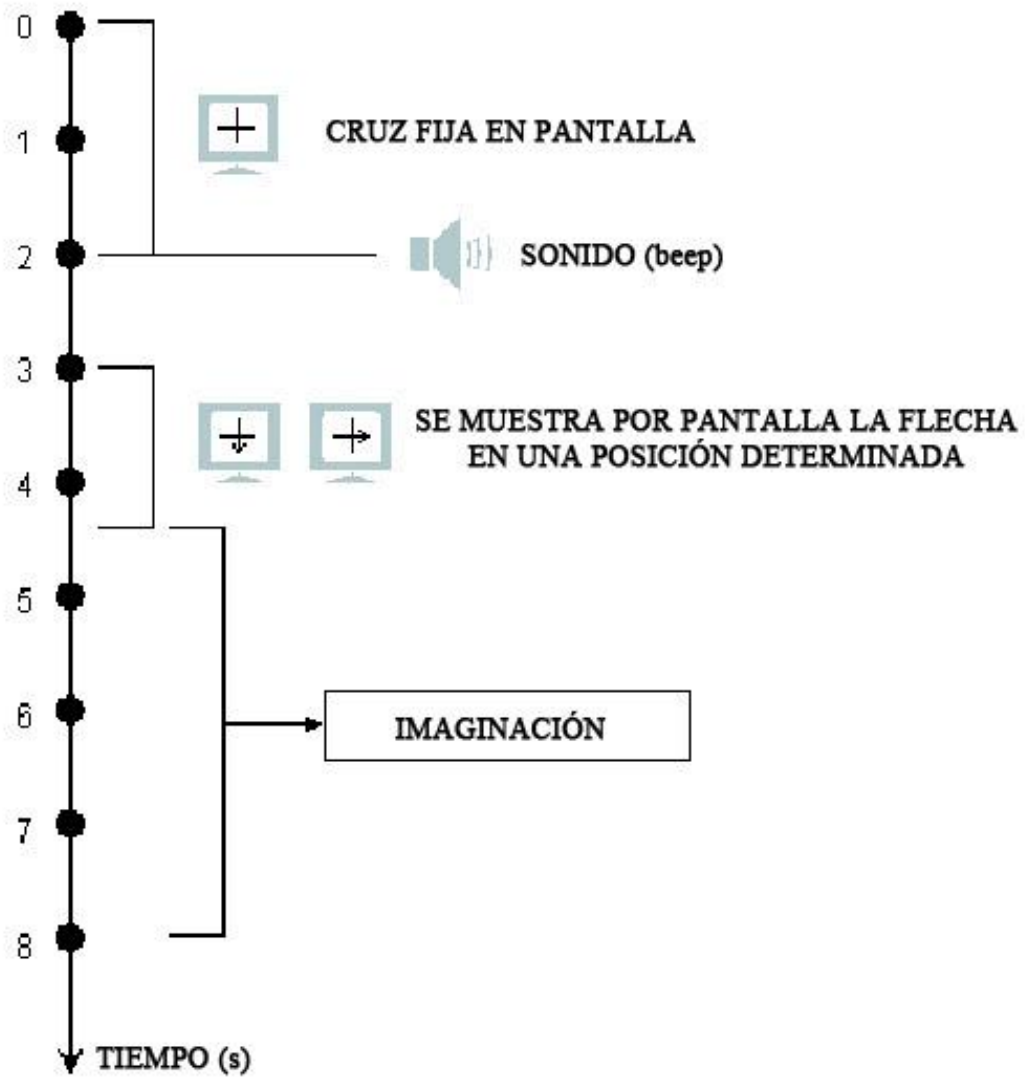


Ilustración 37. Esquema temporal del paradigma utilizado.

8.4 Esquema de extracción y clasificación

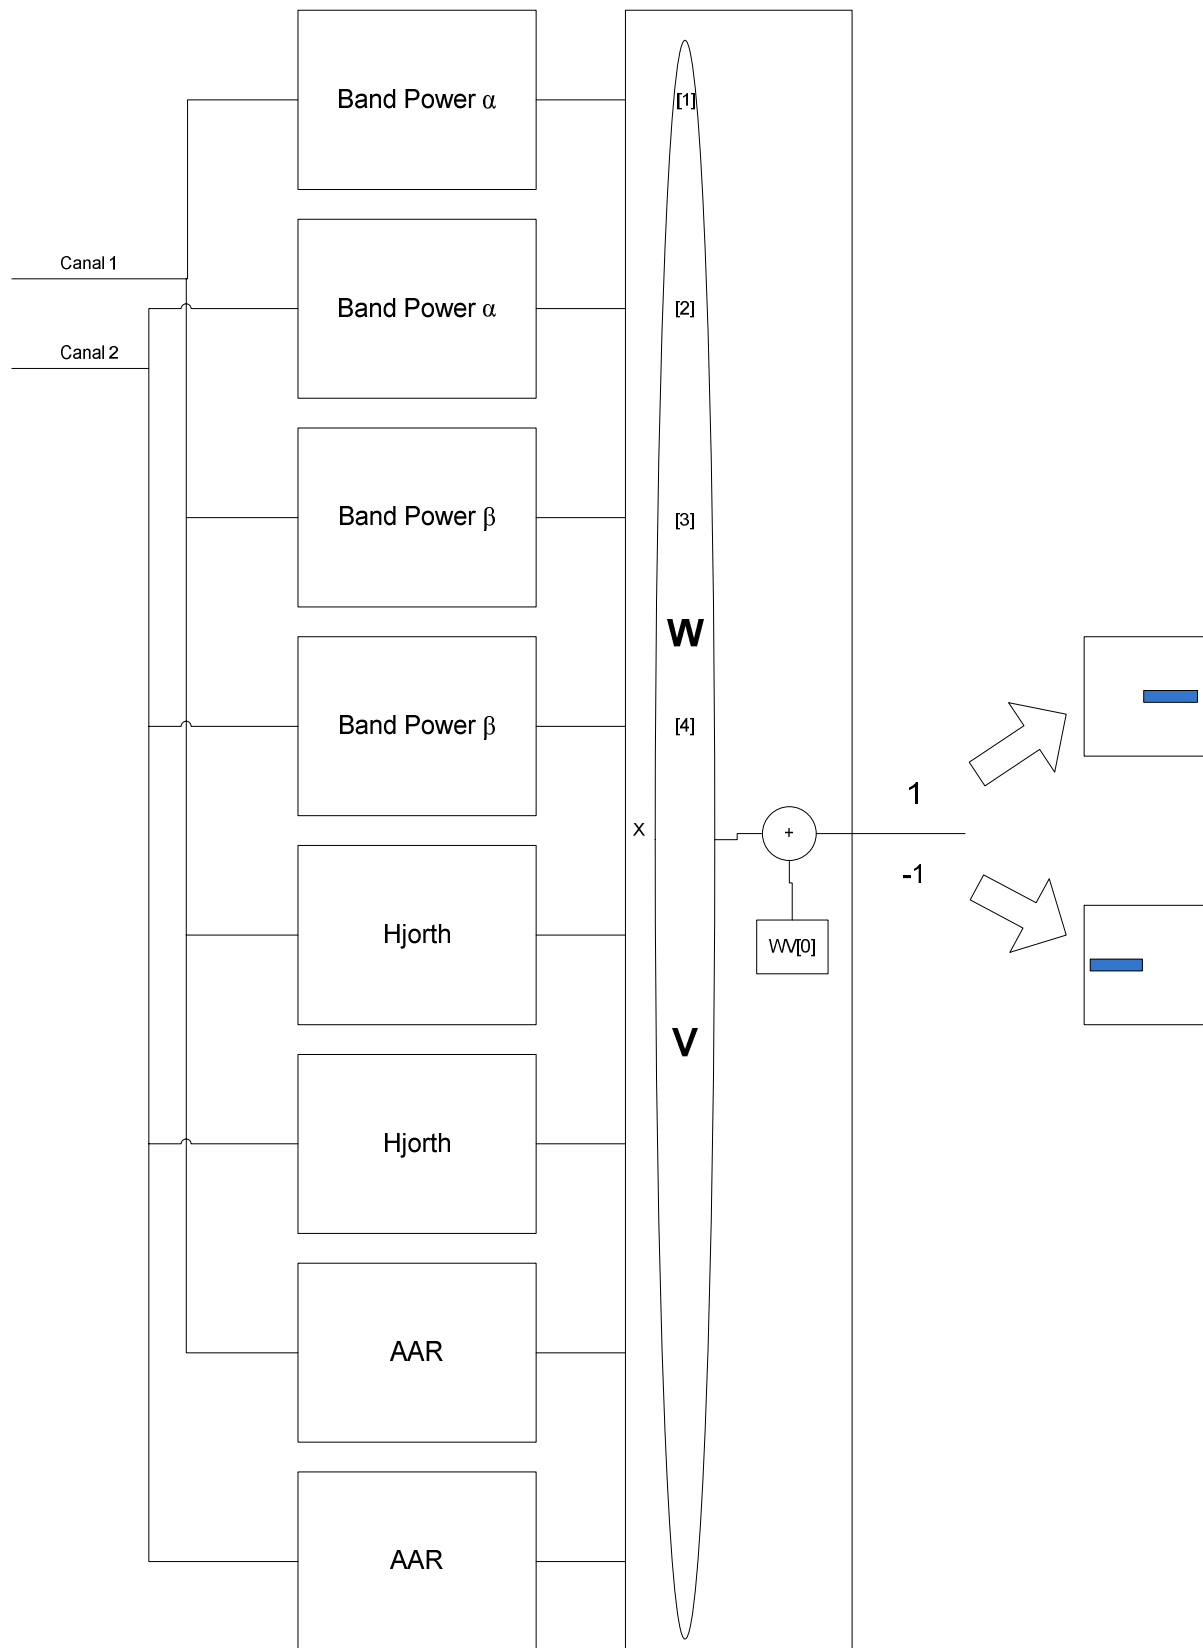


Ilustración 38. Esquema extracción y clasificación.

8.5 Resultados

A continuación se detallan los resultados de clasificación de señal EEG obtenida bajo el paradigma del apartado anterior, con imaginación de movimiento (mano derecha e izquierda). Se ha implementado un discriminante lineal de fisher y un SVM para clasificar y tres extracciones de características distintas PSD, Hjorth y AAR.

Solo se utilizan los datos del experimento marcado en amarillo de cada sujeto. Estos resultados se han obtenido empleando los datos de una sesión de 40 iteraciones de imaginación de movimiento (20 a derecha y 20 a izquierda) para entrenar los clasificadores y otra sesión de 40 iteraciones de imaginación de movimiento imaginando el movimiento de ambas manos para testear el sistema una vez ha sido entrenado. Ambas sesiones carecían de feedback, es decir, que no había señal de realimentación que informara al usuario de su rendimiento en tiempo real.

8.5.1 Sujetos de estudio

La siguiente tabla muestra las 5 personas que participaron en la experiencia donde se indica su edad:

	EDAD
Sujeto 1	34
Sujeto 2	30
Sujeto 3	22
Sujeto 4	31
Sujeto 5	22

Tabla 4. Sujetos y edad.

8.4.1 Sujeto 1:



Ilustración 39. Imagen Sujeto 1.

SESIÓN 1 (Entrenamiento) y SESIÓN 2 (Test)

Datos Clasificación FLD:

PSD.....0.8
Hjorth.....0.7
AAR.....0.55
All.....0.6

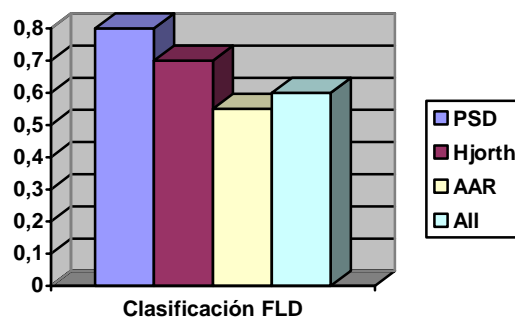


Ilustración 40. Clasificación FLD sujeto 1.

Datos Clasificación SVM:

PSD.....0.8

Hjorth.....0.625
AAR.....0.5
All.....0.725

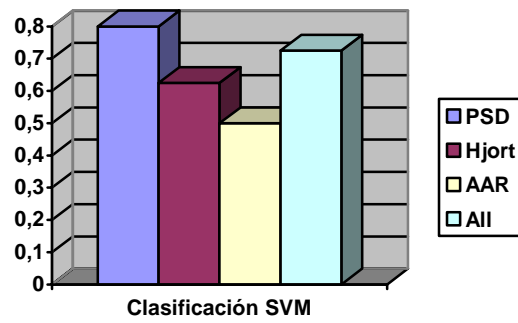


Ilustración 41. Clasificación SVM sujeto 1.

8.4.2 Sujeto 2:



Ilustración 42. Imagen Sujeto 2.

SESIÓN 1 (Entrenamiento) y SESIÓN 2 (Test)

Datos Clasificación FLD:

PSD.....0.5
Hjorth.....0.525
AAR.....0.375
All.....0.375




Ilustración 43. Clasificación FLD sujeto 2.

Datos Clasificación SVM:

PSD.....0.475
Hjorth.....0.55
AAR.....0.425
All.....0.4

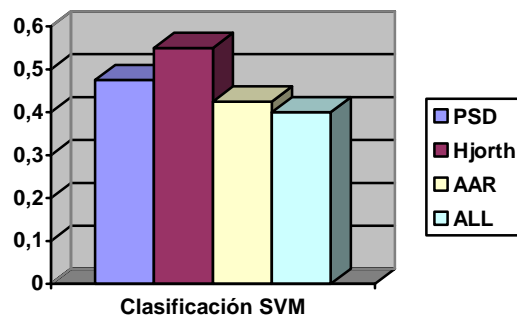


Ilustración 44. Clasificación SVM sujeto 2.

8.4.3 Sujeto 3:



Ilustración 45. Imagen Sujeto 3.

SESIÓN 1 (Entrenamiento) y SESIÓN 2 (Test)

Datos Clasificación FLD:

PSD.....0.5
Hjorth.....0.55
AAR.....0.475
All.....0.5




Ilustración 46. Clasificación FLD sujeto 3.

Datos Clasificación SVM:

PSD.....0.525
Hjorth.....0.55
AAR.....0.5
All.....0.475




Ilustración 47. Clasificación SVM sujeto 3.

8.4.4 Sujeto 4:



Ilustración 48. Imagen Sujeto 4.

SESIÓN 1 (Entrenamiento) y SESIÓN 2 (Test)

Datos Clasificación FLD:

PSD.....0.65
Hjorth.....0.4
AAR.....0.6
All.....0.675




Ilustración 49. Clasificación FLD sujeto 4.

Datos Clasificación SVM:

PSD.....0.675

Hjorth.....0.475

AAR.....0.575

All.....0.65

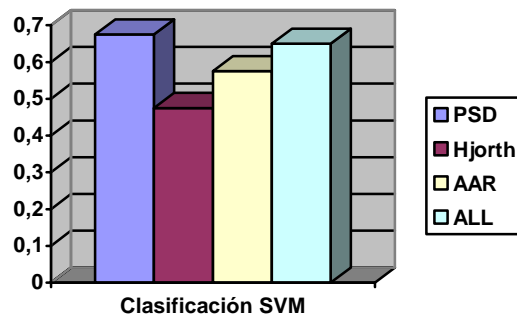


Ilustración 50. Clasificación SVM sujeto 4.

8.4.5 Sujeto 5:



Ilustración 51. Imagen Sujeto 5.

SESIÓN 1 (Entrenamiento) y SESIÓN 2 (Test)

Datos de Clasificación FLD:

PSD.....0.45
Hjorth.....0.475
AAR.....0.525
All.....0.5




Ilustración 52. Clasificación FLD sujeto 5.

Datos Clasificación SVM:

PSD.....0.475
Hjorth.....0.5
AAR.....0.5
All.....0.475




Ilustración 53. Clasificación SVM sujeto 5.

8.5 Conclusiones y trabajo futuro

Los objetivos establecidos en este TFPFD se han cumplido:

1. Análisis lineal de señales EEG. Para ello, se han implementado tres técnicas lineales de extracción de características (PSD, Hjorth, AAR); así como, dos clasificadores lineales (FLD y SVM). Todos estos métodos son ampliamente utilizados en la literatura de referencia para procesamiento de señales EEG.

2. Evaluación de prestaciones en distintos sujetos. Empleando señales procedentes de usuarios inexpertos que se enfrentaban por primera vez al manejo de un sistema BCI basado en imaginación de movimiento, se ha verificado que, como era de esperar, el rendimiento obtenido por el sistema para la mayoría de ellos (tres de los cinco sujetos) es más bajo de lo deseable. Así mismo, es conocido que hay personas que aún siendo novatas consiguen resultados mucho mejores que los demás independientemente del método empleado para su extracción de características y clasificación [54] (en nuestro caso, dos de los cinco sujetos). Todo ello confirma las hipótesis inicialmente planteadas en el Capítulo 1.

A partir de este planteamiento, una posible hipótesis para desarrollar el trabajo de Tesis Doctoral sería la de realizar una comparativa de la evolución de los resultados a lo largo de un entrenamiento sistemático de los sujetos tanto 'buenos' como 'malos' y proponer eficientes procedimientos de mejora de los sistemas de entrenamiento adaptados a cada usuario.

Referencias bibliográficas

- [1] J. J. Vidal, *Toward direct Brain-Computer communication*, Annual Review Biophysisc and Bioengineering, 1973, vol. 2, pp. 157-180.
- [2] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller y T. M. Vaughan, *Brain-computer interfaces for communication and control*, Clinical neurophysiology, 2002, vol. 113, nº 6, pp. 767-791.
- [3] B. Kleber y N. Birbauer, *Direct brain communication: neuroelectric and metabolic approaches at Tübingen*, Cognitive Processing, 2005, vol. 6, nº 1, pp. 65-74.
- [4] A. Bashashati, M. Fatourechí, R. K. Ward y G. E. Birch, *A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals*, J. Neural Eng. ,2007,pp. 32–57.
- [5] Bishop C. M., *Pattern Recognition and Machine Learning*, Springer, USA, 2006.
- [6] Berger H.: *Über das Elektroenkephalogram des Menschen*. Arch. F. Psychiat. 1929, 87: 527-70.
- [7] Brown, P.; Salenius, S.; Rothwell, J.C. y Hari, R., *Cortical Correlate of the Piper Rhythm in Humans*. J. Neurophysiol. 1998, 80, 2911-2917.
- [8] Mima, T.; Simpkins, N.; Oluwatimilehin, T. y Hallett, M., *Force level modulates human cortical oscillatory activities*, Neurosci. Lett. 1999, 275, 77-80.

[9] Lee, K.-H.; Williams, L.M.; Breakspear, M. y Gordon, E., *Synchronous Gamma activity: a review and contribution to an integrative neuroscience model of schizophrenia*, Brain Res. Rev. 2003, 41, 57-78.

[10] Lutzenberger, W.; Pulvermüller, F.; Elbert, T. y Birbaumer, N., *Visual stimulation alters local 40-Hz responses in humans: an EEG-study*, Neurosci. Lett. 1995, 183, 39-42.

[11] Darvas, F.; Scherer, R.; Ojemann, J.G.; Rao, R.P.; Miller, K.J. y Sorensen, L.B. , *High gamma mapping using EEG* , Neuroimage 2010, 49, 930-938.

[12] deCharms, R.C.; Christoff, K.; Glover, G.H.; Pauly, J.M.; Whitfield, S. y Gabrieli, J.D.E. , *Learned regulation of spatially localized brain activation using real-time fMRI* , Neuroimage 2004, 21, 436-443.

[13] Weiskopf, N.; Mathiak, K.; Bock, S.W.; Scharnowski, F.; Veit, R.; Grodd, W.; Goebel, R. y Birbaumer, N. , *Principles of a brain-computer interface (BCI) based on real-time functional magnetic resonance imaging (fMRI)*, IEEE Trans. Biomed. Eng., 2004, 51, 966-970.

[14] Christopher deCharms, R., *Applications of real-time fMRI*. Nat. Rev. Neurosci. 2008, 9,720-729.

[15] Moench, T.; Hollmann, M.; Grzeschik, R.; Mueller, C.; Luetzkendorf, R.; Baecke, S.; Luchtman, M.; Wagegg, D. y Bernarding, J. , *Real-time Classification of Activated Brain Areas for fMRI-based Human-Brain-Interfaces*, Society of Photo-Optical Instrumentation Engineers: Bellingham, WA, USA, 2008.

[16] Jasper, H.H. *The ten-twenty electrode system of the International Federation*, Electroencephalogr. Clin. Neurophysiol. 1958, 371-375.

- [17] A. Schlögl, *The BioSig project*. 2003-2013.
- [18] León Carrión J, Van Eeckhout P y Dominguez Morales, M.R., *The locked-in syndrome: a syndrome looking for a therapy*, 2002, 69.
- [19] Pfurtscheller, G. y Lopes da Silva, F. H., *Event-related EEG/MEG synchronization and desynchronization: basic principles*, Clin Neurophysiol, 1999,110 (11):1842–1857.
- [20] S. Sutton, M. Braren, J. Zubin, y E. R. John, *Evoked-potential correlates of stimulus uncertainty*, 1965, Science, vol. 150, pp. 1187–1188.
- [21] Lin, C.-J. y Hsieh, M.-H., *Classification of mental task from EEG data using neural networks based on particle swarm optimization*. 2009, nº 72, pp. 1121-1130.
- [22] J. Vanerp, F. Lotte y M. Tangermann, *Brain-Computer Interfaces: Beyond Medical Applications*, Computer, vol. 45, nº 4, pp. 26-34, 2012.
- [23] Bishop C. M., *Pattern Recognition and Machine Learning*. Springer, New York, USA, 2006.
- [24] B. Schack y G. Witte, *Parametrische Methoden der dynamischen Spektralanalyse und ihre Anwendung in der Biosignalanalyse*, Biomedizinische Technik, nº 38, pp. 79-80, 1993.
- [25] B. Hjorth, *EEG analysis based on time domain properties*, Electroencephalography and Clinical Neurophysiology, vol. 29, nº 3, pp. 306-310, 1970.
- [26] A. Schlögl, *The electroencephalogram and the adaptive autoregressive model: Theory and applications*, 2000.

[27] G. Rodriguez Bermudez, J. Roca-Gonzalez, F. Martinez Gonzalez, L. Peña- Mora, J. L. Roca-González y J. Roca-Dorda, *Performance analysis of different feature-classifier binomials in motor-imagery BCIs: Preliminary results*, International Symposium on Applied Sciences, Italy, 2010.

[28] A. Schlogl, F. Lee, H. Bischof y G. Pfurtscheller, *Characterization of four- class motor imagery EEG data*, Journal of Neural Engineering, nº 2, pp. 14-22, 2005.

[29] N. Ince, S. Arica y A. Tewfik, *Classification of single trial motor imagery EEG recordings with subject adapted non-dyadic arbitrary time-frequency tilings*, Journal of Neural Engineering, nº 3, pp. 235-244, 2006.

[30] D. McFarland y J. Wolpaw, *Sensorimotor rhythm-based brain-computer interface (BCI): Feature selection by regression improves performance*, IEEE Transactions on Neural Systems and Rehabilitation Engineering, nº 13, pp. 372-379, 2005.

[31] S. Haykin, *Adaptive Filter Theory*, Englewood Cliffs, NJ. Prentice Hall, 1996.

[32] L. Patomaki, J. Kaipio, P. Karjalainen y M. Juntunen, *King of nonstationary EEG with the polynomial root perturbation*, Proceedings of the 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, New York, 1995.

[33] A. Bianchi, L. Mainardi, C. Meloni, S. Chierchia y S. Cerutti, *Continuous monitoring of the Sympatho-Vagal Balance through spectral analysis*, IEEE Engineering in Medicine and Biology, vol. 16, nº 5, pp. 64-73, 1997.

[34] B. Jansen, J. Bourne y J. Ward, *Autoregressive estimation of short segment spectra for computerized EEG analysis*, IEEE Transaction Biomedical Engineering, vol. 28, nº 9, 1981.

[35] A. Isaksson, *A sparsely updated Kalman filter with application to EEG signals*, Department of Telecommunication Theory, Royal Institute of Technology, Stockholm, 1975.

[36] Garrett, D., Peterson, D.A., Anderson, C.W. y Thaut, M.H., *Comparison of linear, nonlinear, and feature selection methods for EEG signal classification*. 2003, 11, 141-144.6.

[37] Bostanov, V. *BCI competition 2003-data sets Ib and IIb: feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram*, 2004, 51, 1057-1061.

[38] Scherer, R.; Muller, G.R.; Neuper, C.; Graitmann, B. y Pfurtscheller, G., *An asynchronously controlled EEG-based virtual keyboard: improvement of the spelling rate*, 2004, 51, 979-984.

[39] Muller, K.R.; Anderson, C.W. y Birch, G.E. ,*Linear and nonlinear methods for brain-computer interfaces*, 2003, 11, 165-169.

[40] Blankertz, B.; Lemm, S.; Treder, M.; Haufe, S. y Müller, K.-R. ,*Single-trial analysis and classification of ERP components- A tutorial*. 2010.

[41] Hoffmann, U.; Vesin, J.-M.; Ebrahimi, T. y Diserens, K. , *An efficient P300-based brain-computer interface for disabled subjects* ,2008, 167, 115-125.

[42] Burges, C.J.C. *A Tutorial on Support Vector Machines for Pattern Recognition*, 1998, 2, 121-167.

[43] Xiang, L., Dezhong, Y., Wu, D. y Chaoyi, L. , *Combining Spatial Filters for the Classification of Single-Trial EEG in a Finger Movement Task*, IEEE Trans. Biomed. Eng. 2007, 54, 821-831.

[44] Cover, T.M. *Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition*, IEEE Trans. Electron. Comput. 1965, EC-14, 326- 334.

[45] Kayikcioglu, T. y Aydemir, O., *A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data*, 2010, 31, 1207-1215.

[46] Garcia, G.N.; Ebrahimi, T. y Vesin, J.M. ,*Support vector EEG classification in the Fourier and time-frequency correlation domains* ,First International IEEE EMBS Conference on Neural Engineering (NER'03), Capri Island, Italy, March 2003; pp. 591-594.

[47] Blankertz, B.; Curio, G. y Müller, K. *Classifying Single Trial EEG: Towards Brain Computer Interfacing*, Advances in Neural Information Processing Systems (ANPS'02), Vancouver, BC, Canada, December 2002; pp. 157-164.

[48] Garrett, D.; Peterson, D.A.; Anderson, C.W. y Thaut, M.H., *Comparison of linear, nonlinear, and feature selection methods for EEG signal classification*, 2003, 11, 141- 144.

[49] Schlögl, A.; Lee, F.; Bischof, H. y Pfurtscheller, G. ,*Characterization of four-class motor imagery EEG data for the BCI-competition 2005*,J. Neural Eng. 2005, 2, L14.

[50] Rakotomamonjy, A.; Guigue, V, *BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller*, IEEE Trans. Biomed. Eng. 2008, 55, 1147-1154.

- [51] Haihong, Z., Cuntai, G. y Chuanchu, W., *Asynchronous P300-Based Brain-Computer Interfaces: A Computational Approach With Statistical Models*, IEEE Trans. Biomed. Eng. 2008, 55, 1754-1763.
- [52] Kaper, M., Meinicke, P., Grossekaehler, U., Lingner, T. y Ritter, H., *BCI competition 2003-data set IIb: support vector machines for the P300 speller paradigm*, IEEE Trans. Biomed. Eng. 2004, 51, 1073-1076.
- [53] Meinicke, P., Kaper, M., Hoppe, F., Heumann, M. y Ritter, H., *Improving Transfer Rates in Brain Computer Interfacing: A Case Study*, Advances in Neural Inf. Proc. Systems (NIPS'02), Vancouver, BC, Canada, December 2002; pp. 1107-1114.
- [54] Bashashati, A., Fatourechi, M., Ward, R. K. and Birch G. E., *A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals*, Journal of Neural Engineering, vol. 4, no.2, pp.R32–R57,2007.

g.tec Medical Engineering: <http://www.gtec.at/>

Biosigproject: <http://biosig.sourceforge.net/>

ANEXO (datos obtenidos en experimentos)

A continuación se presentan la serie de resultados obtenidos a lo largo de la etapa experimental. Se tuvieron que realizar distintas pruebas para ajustar los distintos parámetros sobre cada sujeto, realizando seguidamente las pruebas experimentales siguiendo el paradigma explicado en el capítulo 8, punto 3.

Subject 1:

=====

Session 1 (Training, Test)

=====

FLD Classification

PSD.....0.675

Hjorth.....0.625

AAR.....0.65

All.....0.9

SVM Classification

PSD.....0.65

Hjorth.....0.675

AAR.....0.65

All.....0.85

Session 2 (Training, Test)

=====

FLD Classification

PSD.....0.775

Hjorth.....0.9

AAR.....0.75

All.....0.925

SVM Classification

PSD.....0.825

Hjorth.....0.85

AAR.....0.6

All.....0.925

Session 1 & 2 (Training, Test)

=====

FLD Classification

PSD.....0.75

Hjorth.....0.75

AAR.....0.6375

All.....0.8625

SVM Classification

PSD.....0.75
Hjorth.....0.75
AAR.....0.65
All.....0.825

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.8
Hjorth.....0.7
AAR.....0.55
All.....0.6

SVM Classification

PSD.....0.8
Hjorth.....0.625
AAR.....0.5
All.....0.725

Subject 1: (averaging)

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.775
Hjorth.....0.625
AAR.....0.825
All.....0.825

SVM Classification

PSD.....0.675
Hjorth.....0.675
AAR.....0.8
All.....0.925

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.875
Hjorth.....0.8
AAR.....0.75
All.....1

SVM Classification

PSD.....0.9
Hjorth.....0.85
AAR.....0.725
All.....0.875

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.8375
Hjorth.....0.6875
AAR.....0.675
All.....0.8375

SVM Classification

PSD.....0.8125
Hjorth.....0.6875
AAR.....0.7125
All.....0.8125

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.85
Hjorth.....0.7
AAR.....0.525
All.....0.7

SVM Classification

PSD.....0.85
Hjorth.....0.775
AAR.....0.575
All.....0.6

Subject 2:

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.625
Hjorth.....0.675
AAR.....0.725
All.....0.825

SVM Classification

PSD.....0.65
Hjorth.....0.675
AAR.....0.7
All.....0.8

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.6
Hjorth.....0.7
AAR.....0.8
All.....0.85

SVM Classification

PSD.....0.6
Hjorth.....0.675
AAR.....0.675
All.....0.85

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.575
Hjorth.....0.6625
AAR.....0.6
All.....0.65

SVM Classification

PSD.....0.575
Hjorth.....0.65
AAR.....0.5875
All.....0.6375

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.5
Hjorth.....0.525
AAR.....0.375
All.....0.375

SVM Classification

PSD.....0.475
Hjorth.....0.55
AAR.....0.425
All.....0.4

Subject 2:(averaging)

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.7
Hjorth.....0.75
AAR.....0.675
All.....0.975

SVM Classification

PSD.....0.7
Hjorth.....0.7
AAR.....0.675
All.....0.8

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.625
Hjorth.....0.7
AAR.....0.775
All.....0.9

SVM Classification

PSD.....0.625
Hjorth.....0.7
AAR.....0.725
All.....0.825

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.6
Hjorth.....0.625
AAR.....0.575
All.....0.7375

SVM Classification

PSD.....0.6
Hjorth.....0.625
AAR.....0.575
All.....0.7375

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.525
Hjorth.....0.55
AAR.....0.525
All.....0.55

SVM Classification

PSD.....0.5
Hjorth.....0.575
AAR.....0.45
All.....0.5

Subject 3:

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.725
Hjorth.....0.6
AAR.....0.85
All.....0.925

SVM Classification

PSD.....0.75
Hjorth.....0.575
AAR.....0.675
All.....0.875

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.575
Hjorth.....0.6
AAR.....0.75
All.....0.875

SVM Classification

PSD.....0.575
Hjorth.....0.625
AAR.....0.725
All.....0.875

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.6125
Hjorth.....0.6375
AAR.....0.6875
All.....0.7625

SVM Classification

PSD.....0.6
Hjorth.....0.65
AAR.....0.6375
All.....0.7125

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.5
Hjorth.....0.55
AAR.....0.475
All.....0.5

SVM Classification

PSD.....0.525
Hjorth.....0.55
AAR.....0.5
All.....0.475

Subject 3:(averaging)

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.675
Hjorth.....0.775
AAR.....0.775
All.....0.925

SVM Classification

PSD.....0.725
Hjorth.....0.775
AAR.....0.725
All.....0.95

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.575
Hjorth.....0.7
AAR.....0.675
All.....0.85

SVM Classification

PSD.....0.625
Hjorth.....0.75
AAR.....0.725
All.....0.9

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.6
Hjorth.....0.7125
AAR.....0.6875
All.....0.775

SVM Classification

PSD.....0.6125
Hjorth.....0.7125
AAR.....0.65
All.....0.75

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.525
Hjorth.....0.5
AAR.....0.45
All.....0.5

SVM Classification

PSD.....0.55
Hjorth.....0.525
AAR.....0.45
All.....0.525

Subject 4:

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.575
Hjorth.....0.6
AAR.....0.775
All.....0.825

SVM Classification

PSD.....0.575
Hjorth.....0.525
AAR.....0.75
All.....0.825

Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.575
Hjorth.....0.55
AAR.....0.8
All.....0.975

SVM Classification

PSD.....0.6
Hjorth.....0.55
AAR.....0.8
All.....0.9

Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.6375
Hjorth.....0.575
AAR.....0.6875
All.....0.8125

SVM Classification

PSD.....0.6375
Hjorth.....0.5625
AAR.....0.7
All.....0.8125

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.65
Hjorth.....0.4
AAR.....0.6
All.....0.675

SVM Classification

PSD.....0.675
Hjorth.....0.475
AAR.....0.575
All.....0.65

Subject 4: (averaging)

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.725
Hjorth.....0.625
AAR.....0.625
All.....0.85

SVM Classification

PSD.....0.725
Hjorth.....0.6
AAR.....0.675
All.....0.8

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.675
Hjorth.....0.625
AAR.....0.825
All.....0.925

SVM Classification

PSD.....0.675
Hjorth.....0.625
AAR.....0.8
All.....0.875

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.675
Hjorth.....0.525
AAR.....0.7
All.....0.8125

SVM Classification

PSD.....0.6625
Hjorth.....0.525
AAR.....0.6875
All.....0.85

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.6
Hjorth.....0.425
AAR.....0.8
All.....0.575

SVM Classification

PSD.....0.65
Hjorth.....0.4
AAR.....0.725
All.....0.575

Subject 5:

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.7
Hjorth.....0.65
AAR.....0.725
All.....0.925

SVM Classification

PSD.....0.65
Hjorth.....0.675
AAR.....0.7
All.....0.95

=====
Session 2 (Training, Test)
=====

FLD Classification

PSD.....0.625
Hjorth.....0.625
AAR.....0.8
All.....0.9

SVM Classification

PSD.....0.625
Hjorth.....0.65
AAR.....0.65
All.....0.9

=====
Session 1 & 2 (Training, Test)
=====

FLD Classification

PSD.....0.6125
Hjorth.....0.5875
AAR.....0.6875
All.....0.8

SVM Classification

PSD.....0.625
Hjorth.....0.6
AAR.....0.6625
All.....0.6875

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.45
Hjorth.....0.475
AAR.....0.525
All.....0.5

SVM Classification

PSD.....0.475
Hjorth.....0.5
AAR.....0.5
All.....0.475

Subject 5:(averaging)

=====
Session 1 (Training, Test)
=====

FLD Classification

PSD.....0.65
Hjorth.....0.525
AAR.....0.675
All.....0.875

SVM Classification

PSD.....0.65
Hjorth.....0.575
AAR.....0.675
All.....0.775

Session 2 (Training, Test)

=====

FLD Classification

PSD.....0.725
Hjorth.....0.575
AAR.....0.8
All.....0.85

SVM Classification

PSD.....0.675
Hjorth.....0.55
AAR.....0.75
All.....0.8

Session 1 & 2 (Training, Test)

=====

FLD Classification

PSD.....0.6625
Hjorth.....0.5125
AAR.....0.7125
All.....0.775

SVM Classification

PSD.....0.6625
Hjorth.....0.5
AAR.....0.725
All.....0.8

Session 1 (Training) & Session 2 (Test)

=====

FLD Classification

PSD.....0.45
Hjorth.....0.525
AAR.....0.5
All.....0.475

SVM Classification

PSD.....0.4
Hjorth.....0.5
AAR.....0.525
All.....0.55