



UNIVERSIDAD DE VALLADOLID

EDIFICIO DE LAS TECNOLOGÍAS DE LA
INFORMACIÓN Y LAS COMUNICACIONES

TRABAJO FIN DE MÁSTER

MÁSTER UNIVERSITARIO DE INVESTIGACIÓN
EN TECNOLOGÍAS DE LA INFORMACIÓN Y LAS COMUNICACIONES

**Clasificación de características de
electroencefalogramas en sistemas Brain
Computer Interface basados en ritmos
sensoriomotores**

Autor:

D. Luis Fernando Nicolás Alonso

Tutor:

Dr. D. Roberto Hornero Sánchez

Dr. D. Jaime Gómez Gil

TÍTULO: **Clasificación de características de electroencefalogramas en sistemas Brain Computer Interface basada en ritmos sensoriomotores**

AUTOR: **D. Luis Fernando Nicolás Alonso**

TUTOR: **Dr. D. Roberto Hornero Sánchez**
Dr. D. Jaime Gómez Gil

DEPARTAMENTO: **Teoría de la Señal y Comunicaciones e Ingeniería Telemática**

TRIBUNAL

PRESIDENTE: Miguel López Coronado

SECRETARIO: Jesús Poza Crespo

VOCAL: José Fernando Díez Higuera

FECHA:

CALIFICACIÓN:

Resumen

Un interfaz cerebro-máquina (BCI) es un modo de comunicación directa entre el cerebro y un dispositivo externo. En este trabajo fin de máster se ha investigado varios métodos para clasificar las señales cerebrales generadas por el usuario y de este modo interpretar su intención. Para ello, previamente se ha realizado un estudio de las investigaciones en el campo de los BCI en las dos últimas décadas. Este estudio se organiza de acuerdo a la estructura típica de un BCI, que está formada por un bloque de adquisición de las señales cerebrales, un bloque de procesamiento de las señales y otro dedicado al control del dispositivo. En primer lugar, se analizaron las diferentes técnicas que los BCI emplean para adquirir la actividad cerebral y los tipos de señales de control que se pueden encontrar en la misma y que pueden ser moduladas voluntariamente por los usuarios. En segundo lugar, se estudiaron las diferentes técnicas utilizadas para el procesamiento de señales cerebrales. Estas técnicas engloban aquéllas que pretenden extraer la información característica de las señales cerebrales y las que emplean esta información extraída para clasificar las señales con el fin de conocer las intenciones del usuario. Por último, se hizo una revisión de los distintos dispositivos que la comunidad científica ha controlado mediante sistemas basados en BCI.

A continuación, se estudiaron diferentes métodos de clasificación aplicados a las señales EEG del conjunto de datos 2b de la competición BCI de 2008. El método ganador de dicha competición se basa en un método derivado de *Common Spatial Pattern* para la extracción de características y emplea como clasificador Naïve Bayesian Parzen Window (NBPW). En este trabajo se han propuesto cuatro métodos de clasificación de características: análisis discriminante lineal, máquina de soporte vectorial, perceptrón multicapa y red probabilística de Parzen. En el resto de etapas del BCI se han mantenido los métodos empleados por el ganador de la competición. Los resultados indican que los clasificadores propuestos como alternativas al NBPW no proporcionan una mejora significativa del rendimiento. La red probabilística de Parzen y SVM consiguen mejorar el rendimiento en 3.8%, el LDA en 1.9% y el perceptrón multicapa no consigue superar el rendimiento de NBPW. Por otro lado, se estudian también otros aspectos relacionados con la etapa de clasificación como es el post-procesado de las probabilidades *a posteriori* y el tiempo de procesamiento de los clasificadores. El método de post-procesado mejora necesariamente la clasificación de las señales para todos los sujetos. Sin embargo, si que lo hace en promedio para todos los sujetos de prueba. Por último, se ha estudiado el tiempo de computación que necesitan los diferentes algoritmos de clasificación propuestos. En este punto se ha constatado que el método LDA y la red probabilística de Parzen claramente superan al resto clasificando tardan alrededor de medio segundo para procesar todas las señales de test de un sujeto.

PALABRAS CLAVE: Brain Computer Interface (BCI), electroencefalograma (EEG), ritmos sensoriomotores μ y β , extracción de características, selección de características, clasificación de características.

A mis padres, Luis y María del Pilar,
mis hermanos David y Carlos,
y María.

Agradecimientos

Agradecer a todas las personas que integran el grupo de Ingeniería Biomédica de la Universidad de Valladolid por su ayuda en la realización de este trabajo. En especial agradecer a mi tutor Roberto Hornero, su apoyo, interés y confianza para llevar a cabo este trabajo, y a Rebeca Corralejo, su colaboración y consejos para la realización del código en MATLAB que procesa las señales EEG.

Gracias

Índice abreviado

Capítulo 1: Introducción	17
1.1 Ámbito del Trabajo Fin de Máster	17
1.2 Objetivos	19
1.3 Estructura del Trabajo Fin de Máster	19
Capítulo 2: Sistemas Brain Computer Interface.....	21
2.1 Introducción.....	22
2.2 Técnicas de adquisición de señales cerebrales en BCI.....	23
2.3 Tipos de BCI	29
2.4 Señales de control.....	29
2.5 Métodos de extracción de características	34
2.6 Métodos de clasificación de características.....	40
2.7 Tratamiento de artefactos	43
2.8 Aplicaciones	44
2.9 Limitaciones de los BCI actuales	53
Capítulo 3: Competición BCI.....	55
3.1 Competición BCI 2008.....	55
3.2 Paradigma del conjunto de datos 2b de la competición BCI 2008.....	57
3.3 Descripción del método ganador	58
Capítulo 4: Estudio de métodos de clasificación	65
4.1 Análisis discriminante lineal	65
4.2 Máquina de soporte vectorial (SVM)	67
4.3 Red neuronal artificial: Perceptrón Multicapa	68
4.4 Red probabilística de Parzen	70

4.5 Combinación temporal de la salida del clasificador	70
Capítulo 5: Resultados y discusión	73
5.1 Método de evaluación: <i>Kappa</i> de Cohen	73
5.2 Resultados obtenidos y discusión	74
5.3 Últimos avances en el conjunto de datos 2b	80
Capítulo 6: Conclusiones y líneas futuras	83
6.1 Conclusiones	83
6.2 Líneas futuras	84
ANEXO I: Lista de Siglas	87
ANEXO II: Publicaciones	89
Referencias	91

Índice general

Capítulo 1: Introducción	17
1.1 Ámbito del Trabajo Fin de Máster	17
1.2 Objetivos	19
1.3 Estructura del Trabajo Fin de Máster	19
Capítulo 2: Sistemas Brain Computer Interface.....	21
2.1 Introducción.....	22
2.2 Técnicas de adquisición de señales cerebrales en BCI.....	23
2.2.1 Imagen por resonancia magnética funcional (fMRI).....	24
2.2.2 Magnetoencefalografía (MEG).....	24
2.2.3 Espectroscopia de infrarrojo cercano (NIRS).....	24
2.2.4 Electroencefalografía (EEG).....	25
2.2.5 Electroencefalografía (ECoG).....	27
2.2.6 Adquisición en neuronas intracorticales	28
2.3 Tipos de BCI	29
2.4 Señales de control.....	29
2.4.1 Potenciales visuales evocados (VEP)	30
2.4.2 Potenciales corticales lentos (SCPs).....	30
2.4.3 Potenciales evocados P300	31
2.4.4 Ritmos sensoriomotores (ritmos mu y beta)	32
2.5 Métodos de extracción de características	34
2.5.1 Análisis de componentes principales (PCA)	35
2.5.2 Análisis de componentes independientes (ICA).....	36
2.5.3 Modelos autorregresivos (AR)	37
2.5.4 Filtro adaptado (FA)	38

2.5.5 Transformada Wavelet (WT)	38
2.6 Métodos de clasificación de características	40
2.7 Tratamiento de artefactos.....	43
2.8 Aplicaciones.....	44
2.8.1 Comunicación	45
2.8.2 Recuperación de capacidades motrices	48
2.8.3 Control del entorno	49
2.8.4 Locomoción.....	49
2.8.5 Entretenimiento	51
2.9 Limitaciones de los BCI actuales.....	53
Capítulo 3: Competición BCI.....	55
3.1 Competición BCI 2008	55
3.2 Paradigma del conjunto de datos 2b de la competición BCI 2008	57
3.3 Descripción del método ganador	58
3.3.1 Algoritmo de extracción de características	59
3.3.2 Método de selección de características	60
3.3.3 Método de clasificación	61
3.3.4 Resultados obtenidos por el ganador.....	62
Capítulo 4: Estudio de métodos de clasificación.....	65
4.1 Análisis discriminante lineal.....	65
4.2 Máquina de soporte vectorial (SVM)	67
4.3 Red neuronal artificial: Perceptrón Multicapa.....	68
4.4 Red probabilística de Parzen.....	70
4.5 Combinación temporal de la salida del clasificador	70
Capítulo 5: Resultados y discusión	73
5.1 Método de evaluación: <i>Kappa</i> de Cohen.....	73
5.2 Resultados obtenidos y discusión	74
5.2.1 Clasificación de las pruebas	74
5.2.1.1 Resultados de validación cruzada.....	74
5.2.1.2 Resultados con los datos de <i>test</i>	76
5.2.2 Efectos del post-procesado de las probabilidades <i>a posteriori</i>	78
5.3 Últimos avances en el conjunto de datos 2b	80

Capítulo 6: Conclusiones y líneas futuras.....	83
6.1 Conclusiones	83
6.2 Líneas futuras	84
ANEXO I: Lista de Siglas.....	87
ANEXO II: Publicaciones.....	89
Referencias.....	91

Capítulo 1: Introducción

1.1 Ámbito del Trabajo Fin de Máster

Un interfaz cerebro-máquina (BCI) es un sistema de comunicación hardware y software que permite a los seres humanos interactuar con dispositivos del exterior sin la intervención de los nervios periféricos ni de los músculos. Para ello, se emplea únicamente las señales generadas por el cerebro [1]. Gracias a los BCI, se crea un nuevo modo de comunicación en el que no intervienen los músculos y con el que se puede controlar dispositivos externos tales como ordenadores, sintetizadores de voz, electrodomésticos, y prótesis entre otros. Esto resulta ser particularmente atractivo para aquellas personas que sufren discapacidad motriz severa ya que este nuevo modo de comunicación podría mejorar su calidad de vida al mismo tiempo que reducir el coste que supone cuidar de ellas

Las aplicaciones de los BCI son muy variadas. Pueden servir de tecnología asistiva a personas que sufren discapacidades severas. De esta manera puede mejorarse su capacidad para realizar actividades cotidianas como control del entorno (lucos, TV, etc.), comunicación (escribir, hablar) y control de una prótesis o una silla de ruedas. También los BCI se pueden emplear como medio para mejorar o aliviar los efectos de algunas enfermedades como la afasia, apraxia e incluso por autismo.

Existen múltiples formas de registrar la actividad cerebral. Es posible monitorizar múltiples tipos de actividades cerebrales con distinta procedencia como pueden ser señales de eléctricas, magnéticas o de origen metabólico. No obstante, la mayoría de los BCI usan las señales eléctricas del cerebro para obtener información de la actividad cerebral. La electroencefalografía (EEG) es la medida de la actividad eléctrica en el cerebro producida por la circulación de corriente eléctrica a través de las dendritas de las neuronas. Las señales EEG son recogidas fácilmente y de manera no invasiva a través de electrodos situados sobre la superficie de la cabeza. Por ello, es con mucho la modalidad de adquisición más extendida para el diseño de sistemas BCI.

En este Trabajo Fin de Máster (TFM) se va a estudiar las señales EEG de varios sujetos relacionadas con la generación de movimientos. Este tipo de señales son conocidos como ritmos sensoriomotores. Los ritmos sensoriomotores incluyen los ritmos mu y beta, que son ondas de la actividad cerebral localizadas respectivamente en la banda mu (8 – 12 Hz), también conocida como banda rolándica, y la banda beta (18 – 26 Hz). Ambos ritmos están asociados entre sí de tal manera que algunos ritmos beta

CAPÍTULO 1: INTRODUCCIÓN

son armónicos de los ritmos mu aunque hay algunos que son independientes [2]. La amplitud de los ritmos sensoriomotores varía cuando la actividad cerebral está involucrada con la realización o imaginación de alguna tarea motora [2]. No es necesaria la realización de ninguna tarea motora real y basta con la imaginación de la realización de alguna tarea motora para hacer variar la amplitud de los ritmos sensoriomotores. Se producen patrones similares en los ritmos sensoriomotores tanto en el caso de que se genere algún movimiento real o como en el caso de imaginar alguna tarea motora sin realizar ningún movimiento real [3]. Los ritmos sensoriomotores se han empleado en el diseño de sistemas BCI porque es posible que las personas aprendan a generar voluntariamente modulaciones sobre ellos con el objetivo de controlar dispositivos externos [4, 5].

Para el desarrollo del TFM se va a emplear el conjunto de señales de encefalograma que se propuso para una competición que se llevó a cabo durante el año 2008 [6]. Desde el año 2001, se ha llevado a cabo cada dos años una serie de competiciones 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 hasta 4 ediciones de esta competición. Las competiciones BCI han sido un mecanismo que ha impulsado enormemente la investigación en BCI. 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.

En una competición BCI se presentan varios problemas. Las señales correspondientes a un problema determinado están agrupadas en un conjunto de datos. En la competición BCI de 2008 se presentaron cuatro conjuntos de datos diferentes [7]: (i) clasificación ciega de señales EEG, (ii) clasificación de señales EEG afectadas por artefactos oculares, (iii) clasificación de la dirección del movimiento de la muñeca a partir de señales MEG (Magnetoencefalografía) y (iv) clasificación de señales ECoG (Electrocorticografía) de alta resolución espacial. Junto con cada conjunto de señales se proporciona una descripción de las mismas y los objetivos específicos. Cada conjunto de datos consta de ensayos de actividad cerebral espontánea. Una parte de los mismos están etiquetados y se denominan datos de calibración o de entrenamiento. El resto de los ensayos no etiquetados sirven para evaluar cada uno de los métodos de procesado. Asimismo en la descripción se detalla que medidas cuantitativas se van a emplear para evaluar cada uno de los procedimientos presentados en la competición.

Este TFM se centra en el análisis de las señales de EEG del dataset 2b que son señales afectadas por el movimiento de los ojos [6]. Este conjunto de datos se compone de datos de señales EEG obtenidas de 9 sujetos de un estudio. Todos los voluntarios se sentaban en un sillón mirando hacia un monitor colocado aproximadamente a 1 m de distancia de los ojos. Cada sujeto realizaba 5 sesiones: las dos primeras eran dos sesiones de entrenamiento sin realimentación y las tres restantes eran registradas con realimentación. Al principio de cada sesión, se llevaba a cabo una grabación de 5 minutos aproximadamente de las señales de los ojos. La grabación se dividía en 3 bloques: (i) dos minutos con los ojos abiertos (mirando a una cruz inmóvil en el monitor), (ii) un minuto con los ojos cerrados, y (iii) un minuto realizando diversos movimientos de los ojos que eran indicados a través de la pantalla.

1.2 Objetivos

En este TFM se plantean dos objetivos. En primer lugar, la realización de un estudio de las investigaciones en el campo de los BCI. En segundo lugar, se pretende estudiar diferentes métodos de clasificación aplicados a la clasificación de propiedades de señales de EEG.

El objetivo del estudio es adquirir un suficiente nivel de conocimiento que permita aportar innovaciones en campo de los BCI mediante la realización posteriores investigaciones, que serán utilizadas para la elaboración de una tesis. El estudio sobre los BCI se organizará de acuerdo a su estructura típica, que está formada por un bloque de adquisición de las señales cerebrales, un bloque de procesamiento de las señales y otro dedicado al control del dispositivo. En primer lugar, se analizarán las diferentes técnicas que los BCI emplean para adquirir la actividad cerebral y los tipos de señales de control que se pueden encontrar en la misma y que pueden ser moduladas por los usuarios voluntariamente. En segundo lugar, se estudiarán las diferentes técnicas utilizadas para el procesamiento de señales cerebrales. Estas técnicas engloban aquellas que pretenden extraer la información característica de las señales cerebrales y las que emplean esta información extraída para clasificar las señales con el fin de conocer las intenciones del usuario. Por último, se hará una revisión de las aplicaciones que han sido diseñadas empleando un BCI y los distintos dispositivos que la comunidad científica ha controlado mediante sistemas basados en BCI.

Por otro lado, como segundo objetivo, se pretende estudiar la etapa de clasificación y encontrar para esta etapa nuevos métodos o mejorar los ya existentes para optimizar el rendimiento del BCI. En este TFM se investigará los sistemas BCI basados en ritmos sensoriomotores, que son variaciones de las características frecuenciales en las zonas sensoriales o motoras del córtex, cuando no están ocupadas procesando entradas sensoriales o produciendo salidas motoras. Si estas variaciones se producen en la zona somático-sensorial o motora se denominan ritmos μ (rango de 8-12 Hz) y β (rango de 13-30 Hz). Se va a emplear un conjunto de señales de encefalograma que pertenecen a una competición que se llevó a cabo durante el año 2008 [6]. Esta competición consistió en que se daba un conjunto de señales y el objetivo era conseguir clasificar las intenciones del usuario con el menor error posible. Con este conjunto de señales se va a probar una serie de algoritmos clasificadores manteniendo el resto de etapas sin variar. En el resto de etapas del BCI se va a emplear los mismos métodos empleados por el ganador de la competición de 2008. Se espera mejorar los resultados obtenidos por el ganador variando el método empleado en la etapa de clasificación. Los métodos de clasificación que se van a emplear son: análisis discriminante lineal, máquinas de soporte vectorial, perceptrón multicapa, red neuronal de base radial y red probabilística de Parzen. Los resultados obtenidos se compararán con los que obtuvo el método ganador de dicha competición

1.3 Estructura del Trabajo Fin de Máster

Esta memoria se divide en seis capítulos incluyendo este primer capítulo introductorio.

En el Capítulo 2 se hace un estudio de las investigaciones realizadas en campo del diseño de BCI. Este estudio se organiza de acuerdo a la estructura típica que posee un BCI, que está formada por un bloque de adquisición de las señales cerebrales, un bloque

CAPÍTULO 1: INTRODUCCIÓN

de procesamiento de las señales y otro dedicado al control del dispositivo. En primer lugar, se analizan las diferentes técnicas que los BCI emplean para adquirir la actividad cerebral y los tipos de señales de control que se pueden encontrar en la misma y que pueden ser moduladas por los usuarios voluntariamente. En segundo lugar, se estudian las diferentes técnicas utilizadas para el procesamiento de señales cerebrales. Estas técnicas engloban aquéllas que pretenden extraer la información característica de las señales cerebrales y las que emplean esta información extraída para clasificar las señales con el fin de conocer las intenciones del usuario. Por último, se hace una revisión de los distintos dispositivos que la comunidad científica ha controlado mediante sistemas basados en BCI.

En el Capítulo 3 se describe la competición BCI de 2008 dando un breve resumen de los detalles de cada uno de los conjuntos de datos incluidos en la misma y los problemas que representan. Posteriormente, se detalla en profundidad el conjunto de datos 2b, que es el empleado para realizar el estudio de métodos de clasificación. Por último, se resume el método aplicado por el ganador de la Competición 2008 en el conjunto de datos 2b.

En el Capítulo 4 se presentan algunos detalles de los clasificadores empleados para intentar mejorar el método ganador de la Competición BCI de 2008. Los métodos de clasificación que incluye el estudio son el análisis discriminante lineal, máquina de soporte vectorial, el perceptrón multicapa y la red probabilística de Parzen. Por último, en este capítulo, se explica un procedimiento de post-procesado de las probabilidades *a posteriori* generadas por los métodos de clasificación.

En el Capítulo 5 se incluyen los resultados obtenidos después de aplicar los diferentes métodos explicados en el Capítulo 4. Se comparan estos resultados con los obtenidos por el ganador de la Competición de 2008. El método de evaluación que se va a emplear para cada una de las alternativas es el valor Kappa de Cohen. Se incluye también una discusión donde se dan algunas razones de las diferencias. También, se discute el efecto que tiene en el rendimiento, la aplicación o no de un post-procesado de las probabilidades *a posteriori* generadas por los métodos de clasificación. Por último, se describen brevemente las diferentes mejoras que otros autores ya han propuesto para incrementar el rendimiento de clasificación conseguido con el conjunto de datos 2b de la Competición de 2008.

Finalmente, en el Capítulo 6 se resumen las conclusiones que se han obtenido con la realización de este TFM así como las líneas de investigación que deja abiertas y que pueden ser objeto de futuros trabajos de investigación.

Capítulo 2: Sistemas Brain Computer Interface

El objetivo inmediato de la investigación en BCI es proporcionar la capacidad de interaccionar con dispositivos del exterior a las personas que permanecen aisladas sin poder comunicarse debido a que sufren graves discapacidades motoras causadas por trastornos neurológicos neuromusculares como la esclerosis lateral amiotrófica, ictus cerebral o lesiones de la médula espinal. Este capítulo presenta una revisión del estado del arte de los BCI recorriendo las diferentes etapas que constituyen un BCI: adquisición de la señal cerebral, pre-procesamiento, mejora de la calidad de la señal, extracción de características, clasificación e interfaz de control. Se analizan las numerosas tecnologías existentes en la literatura para construir cada una de las etapas que forman un BCI, mostrando en cada una de ellas los últimos avances y sus ventajas e inconvenientes.

En el diseño de la etapa de adquisición de la señal, se han empleado numerosas técnicas de neuroimagen que monitorizan diferentes actividades del cerebro relacionadas con las funciones del cerebro tales como la actividad eléctrica, magnética o metabólica. De esta actividad cerebral, se ha logrado extraer varias señales de control con el fin de determinar las intenciones del usuario. Estas señales son los potenciales evocados visuales (VEP), potenciales corticales lentos (SCP), potenciales P300, y ritmos mu o beta. En la etapa de mejora de la señal, existen varias técnicas de procesado de señal para hacer frente a los artefactos existentes en las señales cerebrales y mejorar el rendimiento del BCI. En las etapas de extracción y clasificación, se han usado múltiples algoritmos para obtener y clasificar las características de las señales con el fin de traducir las señales de control adquiridas en comandos que puedan ser utilizados para manipular un ordenador u otro dispositivo. En la etapa de interfaz de control, gracias a los últimos avances en las técnicas utilizadas en las anteriores etapas del BCI, ha sido posible manejar múltiples dispositivos mejorando la calidad de vida de las personas con discapacidad.

En un futuro, se espera que sea posible extender el uso de los BCI no sólo a los casos de personas con graves discapacidades, sino también en todo tipo de personas. De esta manera, los BCI podrían significar en un futuro próximo una nueva forma de interacción hombre-máquina, con una importancia similar a otras interfaces actuales.

2.1 Introducción

Un interfaz cerebro-máquina (BCI, del inglés *Brain Computer Interface*) es sistema de comunicación hardware y software que permite a los seres humanos interactuar con dispositivos del exterior sin la intervención de los nervios periféricos ni de los músculos. Para ello, se emplea únicamente las señales generadas por el cerebro. Gracias a BCI, se crea un nuevo modo de comunicación en el que no intervienen los músculos y con el que se puede controlar dispositivos externos tales como ordenadores, sintetizadores de voz, electrodomésticos, y prótesis entre otros. Esto resulta ser particularmente atractivo para aquellas personas que sufren discapacidad motriz severa ya que este nuevo modo de comunicación podría mejorar su calidad de vida al mismo tiempo que reducir el coste que supone cuidar de ellas.

El funcionamiento de un BCI se puede dividir en cinco etapas: adquisición de señal, preprocesamiento o mejora de la calidad de la señal, extracción de propiedades, clasificación de las propiedades y control del dispositivo externo [8]. La etapa de adquisición de señales recoge las señales cerebrales y, en algunos casos, puede reducir el ruido y procesar los artefactos, siempre presentes en este tipo de señales. La etapa de pre-procesado trata las señales adquiridas en la etapa anterior para que puedan ser procesadas por las etapas posteriores. La etapa de extracción de propiedades obtiene la información característica de las señales adquiridas. Es decir, crea una serie de vectores de propiedades que caracterizan a lo largo del tiempo las cualidades de la señal adquirida. Esta tarea no es sencilla ya que las señales cerebrales son una superposición en el tiempo y el espacio de señales que proceden de varias actividades cerebrales. Además, las señales cerebrales no son estacionarias e incluso pueden estar distorsionadas por artefactos tales como señales de electromiograma (EMG) o señales de electrooculograma (EOG) complicando aún más esta tarea. También se requiere que la dimensión del vector de propiedades no sea demasiado elevada con el fin de no incrementar demasiado la complejidad del sistema y que esta reducción del número de propiedades no signifique una pérdida de información relevante de la señal. La etapa de clasificación se encarga de clasificar las señales analizando la información contenida en el vector de propiedades. Esta es una de las razones por las que es tan importante la elección de un buen conjunto de propiedades para desarrollar un BCI que proporcione una buena precisión. Unas buenas propiedades permiten conseguir un reconocimiento efectivo de los patrones encontrados en las señales con el fin de descifrar correctamente las intenciones del usuario. Por último, la etapa de control del dispositivo externo traduce las señales clasificadas en comandos entendibles por el dispositivo conectado al sistema BCI, que puede ser una silla de ruedas o un ordenador entre otros.

A lo largo de la historia, la tecnología BCI ha sido considerada poco atractiva para la investigación científica. Normalmente, se ha considerado muy extraña y lejana la idea de lograr descifrar los pensamientos o intenciones de las personas por medio de la actividad cerebral. De ahí que la investigación en la actividad cerebral quedase relegada únicamente al análisis de enfermedades mentales o a la exploración de las funciones cerebrales. Se creía que el diseño de un BCI resultaba ser un campo de investigación demasiado difícil puesto que la resolución y la fiabilidad de la información detectable en el cerebro era muy baja. Además las características de las señales cerebrales son muy variables en tiempo y no era fácil conseguir detectar fenómenos neurológicos que fueran predecibles. Por otro lado, los sistemas BCI precisan hacer un procesado de la señal en tiempo real, y hasta hace relativamente poco la tecnología necesaria para ello no existía o era excesivamente cara [1].

En las dos últimas décadas, las perspectivas dentro de este campo de investigación han cambiado radicalmente. Se hicieron numerosos estudios que analizaron una gran variedad de fenómenos de las señales cerebrales y que impulsaron los avances en la investigación de los BCI. A modo de ejemplo, Gevins et al. [9, 10] mostraron alentadores resultados probando la existencia de una cierta correlación entre las señales de EEG y la realización de ciertas tareas mentales. Wolpaw et al. [11] demostraron que las personas eran capaces de controlar el movimiento de un cursor sobre un pantalla modulando voluntariamente su actividad cerebral. Por último, recientes estudios en este campo han permitido que personas discapacitadas logren guiar con éxito una silla de ruedas [12]. Por otro lado, el abaratamiento de los ordenadores o sistemas de computación ha permitido el desarrollo de sistemas de análisis de señal en tiempo real mucho más sofisticados. También, la oportunidad de usar los BCI como una tecnología que puede servir para ayudar a gente discapacitada ha despertado el interés en este campo dentro del mundo de la investigación. En la actualidad, el interés por esta tecnología ha sobrepasado las fronteras del laboratorio o la clínica e incluso se han creado compañías comerciales dedicadas a investigar en este campo tales como Emotiv o Neurosky. Estas compañías ya han desarrollado algunas aplicaciones que emplean BCI y que están dirigidas al público en general. No obstante a pesar de estos avances, todavía la mayoría de las aplicaciones que usan BCI no son más que experimentos desarrollados en un laboratorio. Para lograr extender el uso de los BCI fuera del laboratorio sería necesario facilitar su uso, y esto requiere reducir el tiempo de preparación, calibración y entrenamiento necesario para poder usar un BCI [13].

La investigación en el campo de los BCI es una disciplina relativamente joven que integra a investigadores de múltiples disciplinas tales como fisiología, psicología, ingeniería, informática o rehabilitación, entre otras. Debido a esto, a pesar de que se han logrado importantes avances en este campo, no se ha establecido todavía un lenguaje común y las diferentes tecnologías BCI existentes presentan grandes diferencias que hacen difícil su comparación ralentizando la investigación. Por esta razón, algunos investigadores ya han sugerido la necesidad de implantar un lenguaje común para el diseño de sistemas BCI [14]. En ese sentido, Mason et al. [15] han propuesto un nuevo modelo funcional para el diseño de BCI así como para su clasificación.

2.2 Técnicas de adquisición de señales cerebrales en BCI

Los BCI emplean las señales cerebrales para recoger información sobre las intenciones de los usuarios. Para ello, tienen una etapa de adquisición que mide la actividad cerebral y traduce la información contenida en ella en señales eléctricas que pueden ser tratadas más fácilmente por las posteriores etapas de procesado. Es posible monitorizar múltiples tipos de actividades cerebrales con distinta procedencia como pueden ser señales de eléctricas, magnéticas o de origen metabólico. No obstante, la mayoría de los BCI usan las señales eléctricas del cerebro para obtener información de la actividad cerebral. De hecho, la electroencefalografía (EEG) es la técnica de adquisición más empleada, aunque también se ha recurrido a otras modalidades como electrocorticografía (ECoG) o la adquisición de señales eléctricas en neuronas individuales. También es posible encontrar sistemas BCI basados en técnicas de adquisición de señales cerebrales no eléctricas tales como la magnetoencefalografía (MEG), imagen por resonancia magnética funcional (fMRI), o espectroscopia de infrarrojo cercano (NIRS). La elección entre las distintas modalidades dependerá de las

características de cada una de ellas como su resolución temporal o espacial, coste o facilidad para ser transportado. A continuación en esta sección, se explican cada una de las diferentes modalidades de adquisición empleadas en el diseño de BCI.

2.2.1 Imagen por resonancia magnética funcional (fMRI)

La imagen por resonancia magnética funcional (fMRI, del inglés *functional 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. Normalmente en los sistemas BCI, fMRI se ha empleado para medir el nivel de concentración de oxígeno en la sangre (BOLD, del inglés *blood oxygen level dependent*), que varía como consecuencia de la actividad neuronal [16]. Aunque la señal BOLD no está relacionada directamente con la actividad neuronal, sí que se ha encontrado una correspondencia entre BOLD y la actividad neuronal [17].

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 [18]. Sin embargo, fMRI ofrece una baja resolución temporal entre 1 y 2 segundos. El problema de su baja resolución temporal se agrava con que fMRI se basa en la medida de variaciones en señales que surgen como respuesta a cambios hemodinámicos, que introducen un retraso adicional entre 3 y 6 segundos [19]. 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 *offline* y los resultados no llegaban a estar disponibles hasta después de horas o incluso días [20]. Gracias a la creación de fMRI de tiempo real, ha sido posible diseñar BCI basados en esta modalidad de adquisición [19, 21, 22]. 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.

2.2.2 Magnetoencefalografía (MEG)

La magnetoencefalografía (MEG) es una técnica de neuroimagen no invasiva que monitoriza la actividad cerebral empleando la inducción magnética. Para ello, se miden los campos magnéticos existentes en el exterior de la cabeza producidos por las corrientes eléctricas que fluyen a través de las dendritas de las neuronas [23]. Los procesos neurofisiológicos que son medidos por MEG son iguales a los adquiridos por EEG. Sin embargo, MEG tiene la ventaja de que los campos magnéticos sufren menor distorsión por el cráneo y el cuero cabelludo que las campos eléctricos [24]. Otra ventaja de MEG sobre EEG es que posee mayor resolución espaciotemporal lo que reduce el tiempo de entrenamiento necesario para el control del BCI aumentando de la comunicación [25]. A pesar de estas buenas características, esta técnica de neuroimagen no ha sido empleada frecuentemente en el diseño de sistemas BCI debido a que esta tecnología requiere instrumentos demasiado voluminosos y con un elevado coste para llegar a ser una modalidad de adquisición adecuada para el uso diario.

2.2.3 Espectroscopia de infrarrojo cercano (NIRS)

La espectroscopia de infrarrojo cercano (NIRS, del inglés *Near Infrared Spectroscopy*) es una modalidad de espectroscopia que emplea la luz infrarroja para

caracterizar de manera no invasiva las fluctuaciones en el metabolismo del cerebro producidas por el desarrollo de la actividad neuronal. La luz infrarroja penetra en el cráneo y alcanza aproximadamente entre 1 y 3 cm de profundidad desde la superficie del cráneo, permitiendo la medida de las variaciones en la concentración de oxihemoglobina y deoxihemoglobina de acuerdo a los cambios de intensidad de la luz producidos por ésta. Debido a que la luz no penetra profundamente en el cerebro, la información que puede proporcionar esta técnica de neuroimagen queda reducida a las capas corticales más externas del cerebro. También, como sucede en fMRI, otra limitación de NIRS es que mide la actividad neuronal en base a la respuesta hemodinámica, que ocurre varios segundos después de que haya ocurrido la actividad neuronal asociada [26]. Otro inconveniente de NIRS es que su resolución espacial es bastante baja, del orden de 1 cm [27]. No obstante, NIRS resulta bastante atractivo para el diseño de BCI porque es método de adquisición con un bajo coste en comparación con otros, fácilmente portable y que ofrece una resolución temporal aceptable del orden de los 100 milisegundos [28].

NIRS requiere un buen acoplamiento de los sensores al cuero cabelludo. El movimiento de la cabeza o la obstrucción de los sensores por el pelo puede reducir la calidad de la señal y el rendimiento [26]. En sistemas BCI de tiempo real, es muy importante asegurar que la calidad de la señal sea buena y reducir la presencia de ruido, especialmente aquéllos inducidos por los movimientos de la cabeza. Es posible reducir el ruido usando filtros pasobanda, métodos de promediado de medias móviles y filtros de Wiener aunque todos estos algoritmos no funcionan bien cuando hay que eliminar el ruido impulsivo producido por el movimiento de la cabeza [29]. Algunos estudios han demostrado que es posible atenuar los efectos del ruido explotando la relación estadística existente entre las fluctuaciones en las concentraciones de oxihemoglobina y deoxihemoglobina [30].

Ciertamente, NIRS promete ser una excelente técnica de neuroimagen para ser aplicada en BCI [26, 31]. De hecho, podría ser una buena alternativa a EEG que no requiera emplear geles que aumenten la conductividad de los electrodos. No obstante, el principal inconveniente es que la velocidad de comunicación en los sistemas BCI basados en NIRS se vería limitada como consecuencia de que la respuesta hemodinámica introduce un retraso de manera inherente. Algunos experimentos ya han utilizado NIRS para detectar la respuesta hemodinámica relacionada con los potenciales producidos en el cerebro al escuchar estímulos auditivos [28]. Los resultados de estos experimentos parecen indicar que es posible controlar dispositivos externos empleando BCI basados en este tipo de adquisición de la actividad cerebral.

2.2.4 Electroencefalografía (EEG)

La electroencefalografía (EEG) es la medida de la actividad eléctrica en el cerebro producida por la circulación de corriente eléctrica a través de las dendritas de las neuronas. Las señales EEG son recogidas fácilmente y de manera no invasiva a través de electrodos situados sobre la superficie de la cabeza. Por ello, es con mucho la modalidad de adquisición más extendida para el diseño de sistemas BCI. A pesar de ser muy utilizada, EEG presenta varios inconvenientes importantes. La calidad de las señales proporcionadas por EEG es muy baja, ya que las señales eléctricas registradas sobre la cabeza que proceden de la actividad neuronal están muy distorsionadas por el cráneo, el cuero cabelludo entre muchas otras capas. Esta distorsión hace que la señal que recogen los electrodos sea muy débil y, por tanto, resulte muy difícil de adquirir este tipo de señales con una calidad alta. Además, el ruido existente tanto en el interior

CAPÍTULO 2: SISTEMAS BRAIN COMPUTER INTERFACE

del cerebro como en el exterior de la cabeza afecta severamente a la calidad de la señal EEG. Por otro lado, EEG requiere que los electrodos sean mantenidos continuamente para asegurar una buena calidad de la señal. Es necesario que los electrodos permanezcan húmedos para garantizar así una baja impedancia en el contacto entre el electrodo y el cuero cabelludo. Para evitar este inconveniente, algunos estudios ya han probado a usar EEG con electrodos secos con el fin de hacer más fácil el uso de los BCI basados en esta modalidad de neuroimagen [32].

La señal EEG está formada por un conjunto de señales superpuestas que pueden ser clasificadas de acuerdo a su frecuencia. Se han definido un conjunto de rangos de frecuencias en función de su distribución en el cerebro o significado biológico. Estas bandas de frecuencia son, ordenadas de menor a mayor frecuencia, delta (δ), theta (θ), alfa (α), beta (β), y gamma (γ). A continuación, se detallan algunas de las características más relevantes de cada una de ellas.

La banda delta se sitúa por debajo de 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.

Los ritmos theta se extienden de los 4 a los 7 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 soñolencia o meditación.

Los ritmos alfa se encuentran en la región occipital del cerebro y su frecuencia varía entre los 8 y 12 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.

Los ritmos beta se extienden de los 12 hasta los 30 Hz y se localizan en la parte frontal y central del cerebro. Están asociados con un elevado nivel de concentración y atención, y la resolución de problemas. Se caracterizan por tener una distribución simétrica cuando no se está realizando ninguna actividad motora. Sin embargo, en el caso de realizar un movimiento se atenúan de manera que se rompe la distribución simétrica.

Los ritmos gamma 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, entre otras [33]. Algunos experimentos han revelado una relación en los seres humanos entre las actividades motoras y las ondas gamma durante la contracción muscular máxima [34]. Esta coherencia en la banda gamma se sustituye por una coherencia en la banda beta durante las contracciones débiles, lo que sugiere que existe una correlación entre la actividad gamma o beta la fuerza ejercida por los músculos [35]. También, se han encontrado algunas evidencias

vulnerable a los efectos de los artefactos tales como el movimiento de los ojos o el parpadeo [43]. Sin embargo, ECoG presenta el inconveniente de que es un método de adquisición invasivo y que, por tanto, requiere efectuar una craneotomía para implantar los electrodos en el cerebro con los consiguientes riesgos en la salud de los humanos. Por esta razón, ECoG se midió primero en animales [44, 45]. Más tarde, se empleó ECoG en humanos para el análisis de los ritmos alfa y beta [46] o gamma [47, 48] producidos durante la ejecución de acciones motrices.

En cuanto a la aplicación de ECoG en sistemas BCI, Levine et al. [49] diseñaron un sistema BCI que clasificaba acciones motrices identificando potenciales relacionados (ERP) adquiridos mediante ECoG. Leuthardt et al. [50] mostraron por primera vez que un sistema BCI basado en ECoG podía proporcionar suficiente información para el control de un cursor, siendo esta información adquirida más rápidamente y más precisa que en los BCI basados en EEG. Algunos años más tarde, Schalk et al. [51] mostraron un sistema BCI similar al anterior que permitía el control de un cursor en dos dimensiones. Los resultados de todos estos estudios han servido para probar que es viable utilizar un BCI basado en ECoG para satisfacer las necesidades de comunicación y control de dispositivos de las personas con grandes discapacidades motrices.

2.2.6 Adquisición en neuronas intracorticales

La adquisición en neuronas intracorticales es una técnica de neuroimagen que mide la actividad neuronal eléctrica dentro de la materia gris del cerebro. En esta modalidad de neuroimagen, se capturan señales producidas por una sola neurona o campos eléctricos producidos por varias neuronas muy cercanas entre sí. Es una técnica invasiva que requiere la implantación de microelectrodos en el interior de la corteza.

Mediante la adquisición en neuronas corticales se pueden obtener tres tipos de señales: la actividad de una sola neurona (SUA, del inglés *single-unit activity*), la actividad de varias neuronas (MUA, del inglés *multi-unit activity*), y la que se corresponde con campos eléctricos muy localizados (LFPs, del *local field potentials*) [23]. SUA se obtiene mediante el filtrado paso alto (>300 Hz) de la actividad eléctrica generada por una sola neurona. MUA se obtiene de la misma manera, pero la señal puede estar formada por señales que proceden de múltiples neuronas. LFPs se extraen filtrando paso bajo (<300 Hz) la actividad de varias neuronas en las proximidades de uno de los electrodos. LFPs son señales analógicas, mientras que SUA y MUA son las medidas de la actividad de neuronas individuales que pueden ser reducidas a eventos discretos en el tiempo [23].

La adquisición en neuronas intracorticales ofrece una resolución espacial y temporal mucho más alta que EEG. De ahí que las señales intracorticales resulten ser mucho más sencillas de utilizar por los pacientes que las señales EEG. No obstante, existe el inconveniente de que el uso de la adquisición en neuronas intracorticales requiere estabilizar la calidad de la señal a lo largo del tiempo ya que los microelectrodos son progresivamente dañados con el transcurso de los días y años. Es posible que el propio usuario en un primer momento pueda acomodarse a estos cambios en la sensibilidad de los electrodos pero al final es necesario hacer una recalibración de la sensibilidad de los electrodos.

Con respecto a las aplicaciones en sistemas BCI de la adquisición en neuronas corticales, se han utilizado matrices de microelectrodos tales como Utah Intracortical Electrode Array (UIEA) para proporcionar un control simultáneo y proporcional de un gran número de dispositivos externos [52]. Kennedy et al. [53] emplearon señales de

control corticales para diseñar un BCI que permitía a los usuarios controlar el movimiento de un cursor y la flexión de un dedo en una mano virtual.

2.3 Tipos de BCI

Los BCI se pueden clasificar en (i) dependientes o independientes (ii) síncronos o asíncronos. Los BCI dependientes son aquellos BCI que, aunque no usan ninguno de caminos habituales que el cerebro emplea para transmitir el mensaje, sí que lo hacen para generar la actividad cerebral que genera el mensaje [1]. Por ejemplo, los BCI basados en potenciales visuales evocados (VEP) son un tipo de BCI dependientes. Los BCI basados en VEP normalmente presentan sobre una pantalla varios elementos parpadeando a diferente frecuencia, por ejemplo, las palabras “derecha” e “izquierda”. Entonces, el usuario fija su mirada a uno de los elementos de la pantalla para generar un patrón identificable en la señal EEG que posteriormente es traducido por el BCI en un comando. Como se puede comprobar en este tipo de BCI, el canal de salida es la señal EEG pero la generación de la actividad neuronal que es descifrable por el BCI depende de la mirada. Por tanto, los BCI dependientes no proporcionan realmente al usuario un nuevo canal de comunicación totalmente independiente de los convencionales. En cambio, los BCI independientes no dependen de ninguno de los caminos habituales que el cerebro emplea para comunicarse. Para generar la actividad cerebral no es necesario que el usuario tenga intactos los nervios periféricos ni los músculos [1]. Un ejemplo de este tipo de BCI es aquél que sólo necesita que el usuario imagine cierta acción motora. El usuario se concentraría en imaginar un cierto movimiento y el BCI lo decodificaría sin la intervención de ningún otro elemento como pueden ser los ojos o las manos. Los BCI independientes son más útiles porque pueden ser usados por personas con discapacidades motrices severas que tienen dañados canales de comunicación que el cerebro en personas sanas utiliza habitualmente como la visión.

En cuanto al segundo criterio, un BCI es síncrono si realiza un análisis de la señal solamente en ciertos intervalos de tiempo e ignora cualquier señal fuera de estos intervalos de tiempo. Los BCI solamente permiten al usuario enviar comandos en periodos de tiempos específicos, que son determinados por el propio BCI. Dentro de este tipo de BCI se encuentra el Graz BCI [54]. Los BCI asíncronos analizan las señales cerebrales continuamente por lo que no importa cuándo el usuario actúa. Es claro que los BCI asíncronos ofrecen un modo de interacción más natural que los BCI síncronos y por ello se han empleado considerablemente más. No obstante, los BCI asíncronos son más complejos y más exigentes desde un punto de vista computacional.

2.4 Señales de control

El objetivo de un BCI es lograr interpretar las intenciones del usuario monitorizando su actividad cerebral. Dentro de las señales cerebrales se pueden encontrar múltiples fenómenos relacionados con las tareas cognitivas. La mayoría de ellas son incomprensibles todavía y su origen permanece aún desconocido. Sin embargo, se ha logrado entender algunos fenómenos en ciertas señales cerebrales de manera que es posible que las personas puedan aprender a generarlos voluntariamente con el fin de que los sistemas BCI puedan decodificarlos logrando la comunicación entre el usuario y el

BCI. Estas señales son las que se han considerado como posibles señales de control en los sistemas BCI.

Se han hecho numerosos estudios describiendo un gran grupo de señales que podrían servir como señales de control en los sistemas BCI. No obstante, en esta sección solo se incluirán aquéllas que se han empleado en sistemas BCI actuales entre las que se encuentran los potenciales visuales evocados (VEP), potenciales corticales lentos (SCPs), potenciales evocados P300 y ritmos sensoriomotores.

2.4.1 Potenciales visuales evocados (VEP)

Los potenciales visuales evocados (VEP, del inglés *Visual Evoked Potentials*) son modulaciones de la actividad cerebral que ocurren en el córtex visual después de recibir un estímulo visual. Los VEP pueden ser clasificados de acuerdo a tres criterios diferentes [55]: (i) la morfología del estímulo visual, (ii) la frecuencia de la estimulación visual y (iii) el campo de estimulación. De acuerdo al primer criterio, se pueden distinguir VEP originados mediante el uso de *flashes* o mediante patrones gráficos como tableros ajedrezados, rejillas, o mapas de puntos aleatorios. De acuerdo a la frecuencia del estímulo, los VEP se pueden clasificar en VEP transitorios (TVEP, del inglés *transient VEP*) o VEP estacionarios (SSVEP, del inglés *steady-state VEP*). Los TVEP se producen cuando la frecuencia de estimulación es menor de 4 Hz mientras que los SSVEP ocurren en respuesta a estímulos con frecuencias superiores. La forma típica de la señal TVEP muestra que tras producirse cada parpadeo del estímulo visual se produce después de 50 y 100 ms dos picos positivos y después de 75 ms uno negativo. Las señales SSVEP tienen una forma parecida a una senoide cuya frecuencia fundamental es la misma que la del estímulo que lo produce. Los TVEP podrían llegar a ser SSVEP si se incrementa la frecuencia de los parpadeos. Por último, de acuerdo al tercer criterio, los VEP pueden ser clasificados como VEP de campo completo, VEP de medio campo y VEP de campo parcial dependiendo de la extensión de la parte estimulante en la pantalla. Por ejemplo, si sólo se dedica la mitad de la pantalla a mostrar los gráficos que generan el estímulo, la otra mitad de la pantalla no muestra nada, y el usuario fija su mirada al centro de la pantalla, entonces en este caso se está induciendo un VEP de medio campo.

Por lo general, los BCI basados en VEP visualizan dígitos o letras destellando con diferentes frecuencias sobre una pantalla LCD para inducir los VEP mientras el usuario fija su mirada en alguno de ellos. Así los usuarios pueden comunicarse con el sistema fijando su mirada en cada uno de los diferentes símbolos [56]. La ventaja que tiene este tipo de control es que no es necesario prácticamente ningún tipo de entrenamiento. Sin embargo, este tipo de señal de control requiere fijar la mirada en algún punto de la pantalla con lo que solo se puede emplear para diseñar BCI dependientes. De ahí que no resulte adecuada para pacientes que sufren un estado avanzado estado de Esclerosis Lateral Amiotrófica (ELA) o cualquier otra enfermedad, que no les permita controlar el movimiento del cuello y/o los ojos.

2.4.2 Potenciales corticales lentos (SCPs)

Los potenciales corticales lentos (SCPs, del inglés *slow cortical potentials*) son variaciones lentas de voltaje en las señales EEG. Los SCP pertenecen a la parte del espectro de las señales de EEG que está por debajo de 1 Hz [57]. Están asociados a cambios en el nivel de actividad cortical de manera que un incremento de la actividad con la realización de movimientos y otras funciones normalmente generan variaciones

negativas de los SCPs y el decremento de la actividad genera variaciones positivas [58]. Estas variaciones en los SCP pueden ser controladas voluntariamente por personas sanas o discapacitadas para controlar dispositivos externos a través de BCI. Algunos estudios han demostrado que, después de realizar un entrenamiento, las personas son capaces de modular sus SCPs para controlar un cursor y seleccionar una serie de elementos mostrados en una pantalla [59].

A través de un dispositivo de traducción de pensamientos (TTD del inglés *thought-translation device*) es posible entrenar a los usuarios para que sean capaces de generar voluntariamente cambios en sus SCPs. El TTD es un instrumento que informa al usuario qué tipo de modulación ha realizado sobre sus SCPs mediante una indicación visual o auditiva. Habitualmente, el TTD se diseña para que muestre un cursor en una pantalla de manera que la posición vertical del mismo refleje la amplitud de la modulación realizada por el usuario en sus SCPs. Aunque la mayoría de los TTD producen continuamente retroalimentación, es posible entrenar la modulación de los SCPs sin retroalimentación continua [60].

El éxito del entrenamiento en la regulación de los SCPs depende de numerosos factores como el estado psicológico o físico del paciente, contexto social o mismamente la relación que tenga con su entrenador [59]. También, la efectividad del entrenamiento depende en gran medida de la capacidad de aprendizaje del usuario. Por esto, en el caso de enfermedades progresivas, se recomienda comenzar el entrenamiento lo antes posible cuando el paciente se encuentre todavía en una fase temprana de la enfermedad [59]. La habilidad inicial del usuario en controlar sus propios SCPs es un factor a tener en cuenta. Se puede saber con cierta certeza si este tipo de señal es adecuado para un determinado usuario en base a la realización de unas pruebas iniciales [61]. Otros factores como la calidad del sueño, dolor o estado anímico tienen también influencia en el rendimiento en la modulación de los SCPs [59]. Los efectos de estos factores no son idénticos para todos los pacientes y no se han logrado conocer todavía ninguna regla general sobre este tipo de cuestión. Es necesario hacer más investigaciones sobre este punto.

La modulación de los SCPs se ha probado en pacientes con ELA [62-64]. La precisión obtenida en la clasificación de los SCPs es bastante aceptable variando entre el 70 y 80 por ciento. Sin embargo, los BCI que emplean este tipo de señales de control presentan el inconveniente de que proporcionan una tasa de información bastante baja. Además, para lograr realizar la modulación de SCPs de manera correcta se necesita un largo entrenamiento y es muy habitual que los usuarios precisen de varios meses de continuas prácticas para manejar este tipo de BCI.

2.4.3 Potenciales evocados P300

Los potenciales evocados P300 son una serie de picos positivos que surgen espontáneamente en la señal EEG debido a un estímulo infrecuente que se encuentra entre varios frecuentes. Estos estímulos pueden ser visuales, auditivos o somatosensoriales. Esta respuesta involuntaria surge principalmente en el córtex parietal 300 ms después de que el estímulo infrecuente entre varios frecuentes sea percibido [65]. Algunos estudios han probado que cuanto menos probable es el estímulo infrecuente, más grande es la amplitud del pico generado como respuesta [66]. Puesto que la respuesta al estímulo se origina involuntariamente, no es necesario ningún tipo de entrenamiento para usar BCI basados en potenciales evocados P300. Esto supone una ventaja sobre aquéllos que sí lo necesitan. Sin embargo, el rendimiento de este tipo de

BCI puede verse afectado porque el usuario se acostumbre a los estímulos infrecuentes y como consecuencia la amplitud del potencial evocado sea menor [67].

Las aplicaciones que emplean BCI basados en potenciales evocados P300 consisten por lo general en una matriz con letras, números, u otro tipo de símbolos o comandos [68-70]. Las filas o columnas de esta matriz son iluminadas de manera aleatoria mientras se monitoriza la señal EEG. El usuario fija la mirada sobre un determinado símbolo que quiere seleccionar y cuenta cuántas veces se ha iluminado la columna o fila que contiene el símbolo deseado. El BCI detecta las respuestas P300 que se producen cuando se ilumina la columna o fila deseada. Entonces, el BCI usa las respuestas P300 generadas para determinar cuál es el símbolo que el usuario quiere seleccionar de entre los que se encuentran en la matriz. Normalmente son necesarias varias repeticiones para detectar un único símbolo de manera relativamente fiable. Se hacen varias repeticiones iluminando varias veces la misma columna o fila para promediar la señal e incrementar el nivel de señal a ruido ya que la señal a ruido de la señal EEG es demasiado baja para conocer con seguridad cuál es el símbolo deseado en una sola prueba. No obstante, este incremento de la fiabilidad lleva a que se reduzca el número de selecciones que se pueden hacer por minuto. Por ejemplo, con 15 repeticiones solamente se puede seleccionar dos caracteres por minuto [68]. La mayoría de las aplicaciones basadas en potenciales evocados P300 emplean estímulos visuales, pero en el caso de personas invidentes es posible usar estímulos auditivos [71].

Por lo general, los BCI basados en potenciales evocados P300 proporcionan una tasa de información muy baja debido a que usan clasificadores demasiado simples. El promediado de las respuestas es un clasificador demasiado simple y su precisión para la detección de los potenciales evocados es demasiado baja. Esta precisión puede ser incrementada manteniendo el número de pruebas invariable usando clasificadores basados en algoritmos más complejos que el simple promediado [72, 73]. También, existen otros estudios que han probado que la precisión en la detección de los potenciales evocados P300 visuales depende también de las propiedades de la matriz tales como la dimensión de los símbolos o los colores empleados. El rendimiento se reduce cuando los símbolos de la matriz son más pequeños [74], mientras que puede ser mejorado haciendo que el parpadeo sea entre los colores verde y azul en lugar de entre el gris y el negro [75, 76].

2.4.4 Ritmos sensoriomotores (ritmos mu y beta)

Los ritmos sensoriomotores incluyen los ritmos mu y beta, que son ondas de la actividad cerebral localizadas respectivamente en la banda mu (8 – 12 Hz), también conocida como banda rolándica, y la banda beta (18 – 26 Hz). Ambos ritmos están asociados entre sí de tal manera que algunos ritmos beta son armónicos de los ritmos mu aunque hay algunos que son independientes [2]. La amplitud de los ritmos sensoriomotores varía cuando la actividad cerebral está involucrada con la realización o imaginación de alguna tarea motora [2]. No es necesaria la realización de ninguna tarea motora real y basta con la imaginación de la realización de alguna tarea motora para hacer variar la amplitud de los ritmos sensoriomotores. Se producen patrones similares en los ritmos sensoriomotores tanto en el caso de que se genere algún movimiento real o como en el caso de imaginar alguna tarea motora sin realizar ningún movimiento real [3]. Los ritmos sensoriomotores se han empleado en el diseño de sistemas BCI porque es posible que las personas aprendan a generar voluntariamente modulaciones sobre ellos con el objetivo de controlar dispositivos externos [4, 77].

Los ritmos sensoriomotores pueden experimentar dos tipos de modulaciones conocidas como eventos relacionados de desincronización (ERD, del inglés *event-related desynchronization*) y eventos relacionados de sincronización (ERS, del inglés *event-related synchronization*), que se generan durante la realización o imaginación de algún movimiento. Los ERDs están relacionados con la preparación e inicio del movimiento e implica una atenuación de la amplitud de los ritmos mu y beta [78]. Por otro lado, los ERS involucran un incremento de la amplitud y tienen lugar después de la ejecución del movimiento y la subsecuente relajación [78]. La Figura 2 (panel superior) muestra el comportamiento de los ERD y ERS durante la realización voluntaria de un movimiento que consistía en la elevación rápida y enérgica de un dedo [4]. El ERS que se puede encontrar en la banda mu empieza 2,5 s antes del comienzo del movimiento, alcanza su máximo poco después y termina recuperando su nivel original poco segundos después. Por el contrario, los ritmos beta experimentan un ERD muy breve durante el inicio del movimiento, seguido por un ERS que alcanza el máximo después de la ejecución del movimiento. Este último ocurre mientras los ritmos mu todavía permanecen atenuados debido al ERD. También la Figura 2 muestra la existencia de ritmos gamma (36 – 40 Hz), que es otro tipo de ritmo relacionado con las tareas motrices pero que habitualmente resulta difícil de encontrar en los humanos [4]. Como se puede ver en la Figura 2, estos ritmos gamma experimentan un ERS poco después de la preparación del movimiento. Finalmente, en el panel inferior de la Figura 2 se indica que es posible que tengan lugar simultáneamente un ERD y un ERS en diferentes localizaciones del cerebro [4].

Como ya se ha explicado antes, los ritmos sensoriomotores están relacionados con la imaginación de movimientos y no es necesaria la realización de movimientos reales para su modulación. Gracias a esta propiedad de los ritmos sensoriomotores, es posible usar los ritmos sensoriomotores para el diseño de BCI independientes, que son más útiles que los dependientes. No obstante, el control de los ritmos sensoriomotores no es sencillo y la mayoría de las personas tienen dificultades en la imaginación de movimientos para una modulación correcta de estos ritmos. Es habitual que los usuarios intenten modular sus ritmos sensoriomotores mediante la visualización interior de un movimiento real y esto resulta ser poco adecuado porque los patrones que se generan de este modo son diferentes a los que tienen lugar cuando se realiza un movimiento real [79]. Tradicionalmente el entrenamiento para imaginar tareas motrices ha estado basado en retroalimentación visual o auditiva [80]. En este tipo de entrenamiento, se solicita al

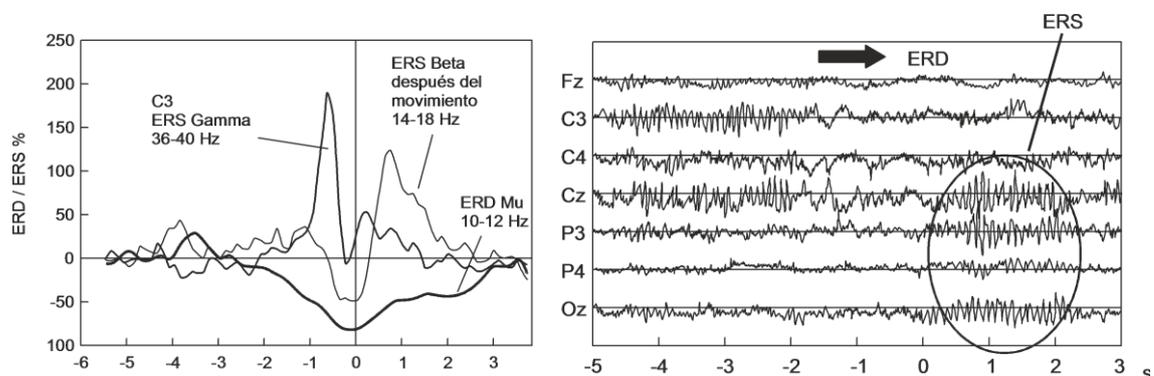


Figura 2. Panel superior: Espectro a lo largo del tiempo calculado para tres bandas diferentes (10 – 12 Hz, 14 – 18 Hz, y 36 – 40 Hz) a partir de las muestras EEG tomadas del electrodo C3 durante el levantamiento del dedo índice de la mano derecha. El movimiento del dedo comienza en el instante $t = 0$ s. Panel inferior: Señales EEG grabadas durante el movimiento del dedo de la mano derecha.

usuario que imagine la realización de un cierto movimiento y entonces el BCI extrae los ritmos sensoriomotores y los clasifica comparándolos con una referencia. Finalmente, se proporciona una retroalimentación indicando el éxito de su tarea. Este tipo de entrenamiento ha sido ampliamente utilizado aunque se ha demostrado que su efectividad no es muy alta [81]. Hwang et al. [81] presentaron una manera más efectiva para entrenar la imaginación de acciones motrices basada en un sistema que como retroalimentación visualizaba sobre una pantalla la actividad cortical en tiempo real. De este modo, los usuarios podían conocer su propia actividad cortical en tiempo real facilitando su aprendizaje para la modulación voluntaria de los ritmos motores.

Dentro del campo de los BCI, se ha investigado considerablemente los ritmos sensoriomotores. Sistemas BCI tales como BCI Wadsworth [82], BCI Berlin [83], o BCI Graz [54] emplean ritmos sensoriomotores como señales de control. También se han usado para el diseño de BCI síncronos como asíncronos. Los últimos avances en el área de los BCI basados en ritmos sensoriomotores indican que es posible predecir movimientos voluntarios antes de que estos ocurran mediante el análisis de las modulaciones que experimentan los ritmos sensoriomotores [84]. Esta predicción incluso puede ser hecha aunque solo se haya hecho la intención y el inicio del movimiento sea interrumpido y finalmente no se lleve a cabo ningún movimiento.

2.5 Métodos de extracción de características

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.

El diseño de un conjunto adecuado de propiedades de las señales cerebrales es un problema difícil. La información de interés de las señales del cerebro permanece encubierta debido a que este tipo de señales son muy sensibles al ruido y están formadas por un gran número de señales que proceden de múltiples fuentes. Dentro de la literatura científica se pueden encontrar varios métodos para obtener las características relevantes de las señales del cerebro. Métodos como el Análisis de Componentes Principales (PCA) o el método de *Common Spatial Pattern* (CSP) realizan una transformación lineal para obtener la información más relevante. Con el mismo fin, el análisis de componentes independientes (ICA) trata de dividir las señales del cerebro en sus señales fuente originales. Existen métodos de análisis en tiempo y/o frecuencia, tales como filtro adaptado o transformada wavelet, que también son muy populares como métodos de extracción de características. También, se usan habitualmente para extraer propiedades modelos paramétricos como los modelos autorregresivos (AR). Todos estos métodos se explican brevemente en esta sección excepto el método de CSP que se explica en el 0 porque fue el método de extracción de características que se emplea en el estudio de clasificadores que se hace en este TFM.

2.5.1 Análisis de componentes principales (PCA)

El Análisis de Componentes Principales (PCA, del inglés *Principal Component Analysis*) es un método estadístico de extracción de características que utiliza una transformación lineal para convertir un conjunto de observaciones, posiblemente correladas, en un conjunto de variables no correladas llamadas componentes principales. A partir de los datos de entrada, mediante la transformación lineal se genera un conjunto de componentes ordenadas según su varianza de tal manera que la primera componente tiene la mayor varianza posible. Entonces, por medio de la varianza, PCA permite la separación de las diferentes componentes contenidas en la señal del cerebro.

PCA proyecta los datos de entrada en un espacio k -dimensional generado por k autovectores, que se calculan a partir de la matriz de covarianza Σ de los datos de entrenamiento $p = [p_1 p_2 \dots p_n]$ [85]. Cada vector p_i tiene dimensión d y representa la i -ésima muestra de entrenamiento. n es el número de muestras.

La matriz de covarianza Σ se calcula como

$$\Sigma = \sum_{i=1}^n (p_i - m)(p_i - m)^t \quad (1)$$

donde $m = \frac{1}{n} \sum_{i=1}^n p_i$ es el vector correspondiente a la media de las muestras de los datos de entrenamiento p_i .

La matriz de covarianza Σ es una matriz real y simétrica $d \times d$, por lo que tiene d autovectores y autovalores. Por medio de los autovalores, es posible saber qué autovectores constituyen la parte de información más importante contenida en el conjunto de datos de entrenamiento p . Aquellos autovectores con mayor autovalor representan las principales componentes dentro del conjunto de datos de entrenamiento. Entonces, PCA selecciona aquellos primeros k autovectores, con $k < d$, que tengan mayor autovalor y con los autovectores seleccionados construye una matriz de proyección A que utilizará para extraer el vector de características de los datos de entrada q . La matriz A tiene los k autovectores como columnas ordenadas de tal manera que la primera columna de A se corresponde con el autovector de mayor autovalor. Con la matriz A , se calcula el vector de propiedades v mediante la proyección en el nuevo subespacio de los datos q

$$v = A^t(q - m) \quad (2)$$

donde $m = \frac{1}{n} \sum_{i=1}^n p_i$ sigue siendo el vector correspondiente a la media de las muestras de entrenamiento p_i .

PCA es también un procedimiento para reducir la dimensión del vector de propiedades. Dado que el número de columnas de A es menor que el número de autovectores, la dimensión de los datos de salida, que han sido proyectados a través de A , es menor que la dimensión de los datos de entrada. Esta disminución de la dimensión reduce la complejidad en la etapa posterior de clasificación del sistema BCI.

Con respecto a las aplicaciones de PCA en sistemas BCI, PCA se ha utilizado para identificar las componentes que contienen artefactos en las señales EEG y reconstruir

las señales sin esas componentes [86, 87]. También se ha empleado PCA para reducir la dimensión del espacio de características [85].

2.5.2 Análisis de componentes independientes (ICA)

El Análisis de Componentes Independientes (ICA) es un procedimiento estadístico que separa una señal formada por un conjunto de señales mezcladas en sus componentes fuente sin tener información previa sobre la naturaleza de la señal. El único supuesto asumido por ICA es que las fuentes desconocidas subyacentes sean estadísticamente independientes entre sí. ICA asume que la señal EEG observada es una mezcla de varias fuentes independientes procedentes de múltiples actividades cognitivas o artefactos. Así pues, ICA describe la señal resultante $\mathbf{x}(t)$ en relación a sus fuentes $\mathbf{s}(t)$ como

$$\mathbf{x}(t) = \mathbf{f}(\mathbf{s}(t)) + \mathbf{n}(t) \quad (3)$$

donde \mathbf{f} es una función de mezcla desconocida y $\mathbf{n}(t)$ es un vector que representa ruido aditivo. La dimensión del vector de entrada $\mathbf{s}(t)$ depende del número de fuentes. La dimensión del vector de salida $\mathbf{x}(t)$ es igual al número de canales de datos medidos. Normalmente se asume que el número de fuentes es menor o igual al número de canales.

Todo el problema de ICA se reduce a calcular la función que separa las distintas componentes invirtiendo la función \mathbf{f} y obtener una estimación de $\mathbf{s}(t)$ mediante la aplicación de $\mathbf{x}(t)$ a través de la función de desmezcla. Para resolver este problema, se pueden tomar dos modelos diferentes en función de \mathbf{f} . Se puede asumir que \mathbf{f} sea no lineal o lineal. Suponer que \mathbf{f} es no lineal resulta conveniente en aquellos casos en los que el modelo lineal podría ser demasiado simple para describir los datos observados $\mathbf{x}(t)$. Sin embargo, el problema no lineal suele ser demasiado complejo y por lo general intratable debido a la existencia de un gran número de indeterminaciones. La suposición de una función de mezcla lineal simplifica la Ecuación (3) haciendo posible volver a escribir la ecuación como una multiplicación de matrices, donde \mathbf{A} es la matriz de mezcla. La expresión matemática del modelo lineal de ICA se describe en la Ecuación (4).

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \quad (4)$$

A pesar de que la aproximación dada por la Ecuación (4) puede ser considerada demasiado simple, funciona razonablemente bien para procesar señales cerebrales. Además, incluso es posible eliminar el término de ruido $\mathbf{n}(t)$ de la Ecuación (4), suponiendo que los datos observados no han sido afectados por el ruido o que el ruido es demasiado débil para ser tenido en cuenta [88, 89]. Con estas suposiciones, ICA obtiene $\mathbf{s}(t)$ y \mathbf{A} de $\mathbf{x}(t)$ por medio de algoritmos como Infomax [90] o una posterior modificación de Infomax [91], entre otros.

ICA se ha utilizado tradicionalmente como una herramienta de procesamiento previo antes de la etapa de extracción de características con el fin de eliminar los artefactos oculares en los sistemas BCI [92-94]. Sin embargo, a pesar de que ICA ha demostrado ser una herramienta muy potente y robusta para la eliminación de artefactos en el análisis de señales, algunos estudios indican que la supresión de artefactos con ICA puede también dañar el espectro de potencia de la actividad neuronal [95]. Como otra aplicación de ICA, es posible encontrar autores que han empleado ICA como un

clasificador. Se puede modificar ICA para clasificar a las señales de EEG mediante la adecuación de un modelo ICA para cada tarea y el empleo de la regla de Bayes [96].

2.5.3 Modelos autorregresivos (AR)

El método de estimación espectral autorregresivos (AR) es un método de caracterización de señales que modela la señal EEG como una señal aleatoria producida por un filtro lineal invariante en el tiempo donde la entrada es ruido blanco de media cero y varianza σ^2 . El objetivo de los modelos AR es la obtención de los coeficientes del filtro ya que se supone que las diferentes actividades realizadas por el cerebro se relacionarán con diferentes coeficientes del filtro. Es decir, los coeficientes del filtro serán utilizados como los parámetros característicos de la señal EEG.

El modelo AR asume que la función de transferencia del filtro contiene solamente polos en el denominador. El número de polos se corresponde con el orden del modelo autorregresivo. Al suponer que el filtro tiene solamente polos se hace más sencillo el cálculo de los coeficientes del filtro porque sólo es necesario resolver ecuaciones lineales.

Matemáticamente, en un modelo AR de orden p la señal EEG $y(t)$ se describe como

$$y(t) = a_1y(t-1) + a_2y(t-2) + a_3y(t-3) + \dots + a_p y(t-p) + n(t) \quad (5)$$

donde a_i es el coeficiente i -ésimo filtro, y $n(t)$ es el ruido. Existen varios métodos para calcular los coeficientes del filtro como el Yule-Walker, Burg, covarianza, y los algoritmos *forward-backward* [97].

Los coeficientes del filtro obtenidos se pueden utilizar para estimar el espectro de potencia de la señal EEG $y(\omega)$

$$y(\omega) = \frac{1}{|1 - \sum_{k=1}^p a_k e^{-jk\omega}|^2} \quad (6)$$

donde los a_k son los coeficientes de filtro, y p es el orden del modelo AR, es decir, el número de polos.

En los modelos AR, la determinación de un orden p apropiado para caracterizar cierta señal de entrada es una cuestión de compromiso. Si el orden es demasiado bajo para modelar la señal de entrada, el resultado no representará fielmente la señal debido a que el espectro obtenido con el modelo no refleje los pequeños detalles del espectro. Por el contrario, si el orden del modelo es demasiado alto, el espectro puede presentar espurios que no se correspondan con el espectro real de la señal.

La estimación espectral mediante modelos AR es preferible a la Transformada de Fourier (TF) porque proporciona mayor resolución espectral para pequeños segmentos de la señal [98]. No obstante, los modelos AR no funcionan bien cuando la señal no es estacionaria. Debido a la naturaleza no estacionaria de las señales EEG se han propuesto modelos autorregresivos adaptativos como *multivariate adaptive autoregressive* (MVAAR) para el diseño de sistemas BCI *online* más eficaces. Jiang et al. [99] aplicaron MVAAR para clasificar neuroimágenes relacionadas con actividades motrices probando que podía ser un método adaptativo válido para extraer características de las señales EEG. El algoritmo de cálculo de MVAAR es muy similar al del modelo AR

original. Si suponemos que en este caso el BCI posee m canales teniendo m señales en lugar de una sola, entonces el vector con las m señales EEG se representa en cada instante de tiempo k como

$$\vec{y}_k = [y_{k,1} \ y_{k,2} \ \dots \ y_{k,m}]^T \quad (7)$$

y de manera similar a modelo AR, el modelo MVAAR se expresa como

$$\vec{y}_k = A_1 \vec{y}_{k-1} + A_2 \vec{y}_{k-2} + A_3 \vec{y}_{k-3} + \dots + A_p \vec{y}_{k-p} + \vec{n}_k \quad (8)$$

donde \vec{n}_k es el vector de ruido blanco, $A_1 \dots A_p$ son los coeficientes adaptativos, y p es el orden del modelo. Los coeficientes $A_1 \dots A_p$ son actualizados en cada instante k mediante un filtro *Recursive Least Squares*, que es un tipo concreto de filtro de Kalman.

2.5.4 Filtro adaptado (FA)

El filtro adaptado (FA) es un tipo de filtro que se diseña con el objetivo de detectar ciertos patrones en las señales en base a su parecido con un conjunto de señales conocidas determinado que sirven como plantillas. Se pretende decodificar las intenciones del usuario por medio de la correlación entre las señales EEG y cada una de las plantillas del conjunto de plantillas. Cada plantilla que pertenece a este conjunto de plantillas representa una intención concreta del usuario y está representada por un filtro que se emplea para calcular la correlación entre la plantilla y la señal. Cuanto mayor sea la correlación mayor será el parecido entre la plantilla y la intención del usuario con lo que existe mayor probabilidad de que efectivamente el usuario pretendía generar ese patrón en su señal EEG. Cada filtro adaptado, se puede construir simplemente como la suma de una serie de componentes sinusoidales relacionadas armónicamente [100]

$$MF(n) = \sum_{k=1}^N a_k \cos\left(\frac{2\pi k f_F}{f_s} n + \Phi_k\right) \quad (9)$$

donde n es el número de muestra del filtro adaptado, f_s es la frecuencia de muestreo, f_F es la frecuencia fundamental de la plantilla, $N-1$ es el número de armónicos, y a_t y Φ_k son la amplitud y la fase de cada uno de los armónicos con los que se construye el filtro adaptado. Los parámetros del modelo a_t y Φ_k se pueden obtener a partir del espectro de una señal que contenga el patrón que se desee detectar con ese filtro adaptado [100].

Se ha demostrado que el método de extracción de características mediante FA es especialmente eficaz en la detección de patrones con características invariantes en el tiempo. Krusienski et al. [100] utilizaron FAs para la identificación de las intenciones del usuario a través de ritmos mu. Por otra parte, Brunner et al. [101] utilizaron también FAs para la extracción de características de los SSVEP.

2.5.5 Transformada Wavelet (WT)

La Transformada Wavelet (WT, del inglés *wavelet transform*) es una herramienta matemática ampliamente utilizada para extraer información de diferentes tipos de señales, como audio o datos de imagen, entre otros. La WT es particularmente adecuada

para el análisis de señales que no son estacionarias puesto que proporciona un modo flexible de representar una señal en el dominio del tiempo y la frecuencia [102].

Las wavelets son funciones de frecuencia variable y duración limitada que, a diferencia de otras modalidades de análisis de señales tales como la TF, permiten el estudio de una señal en dominio del tiempo y la frecuencia al mismo tiempo [103]. La TF sólo proporciona un análisis de la actividad de la señal en el dominio de la frecuencia pero no indica cuando se producen las distintas frecuencias que contiene la señal. Para superar esta inconveniente en el análisis de Fourier, se propuso *Short-time Fourier Transform* (STFT). La STFT divide la señal en sucesivos periodos de tiempo y aplica la TF a cada uno de ellos. En este nuevo modo de análisis de señales, el diseño de la longitud de cada periodo supone un compromiso porque hacer los periodos más pequeños conduce a una mayor resolución temporal pero al mismo tiempo a una menor resolución en el dominio de la frecuencia. El WT soluciona este inconveniente descomponiendo la señal en el dominio del tiempo y la frecuencia con múltiples resoluciones. Para ello se emplea una ventana modulada con diferentes escalas en tiempo.

La transformada wavelet continua (CWT, del inglés *continuous wavelet transform*) se define como la convolución de la señal $x(t)$ con una cierta función wavelet $\psi_{s,\tau}(t)$ [103]

$$w(s, \tau) = \int_{-\infty}^{\infty} x(t)\psi_{s,\tau}^*(t)dt \quad (10)$$

$w(s, \tau)$ es el coeficiente de la transformada wavelet se corresponde con el escalado por s y desplazamiento en tiempo τ de la función wavelet $\psi_{s,\tau}(t)$. El símbolo '*' expresa la conjugación compleja. La función wavelet $\psi_{s,\tau}(t)$ es la versión dilatada y desplazada de la función wavelet madre $\psi(t)$

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}}\psi\left(\frac{t - \tau}{s}\right) \quad (11)$$

Una wavelet madre es una función que puede tomar múltiples formas, pero siempre satisface la condición siguiente:

$$\int_{-\infty}^{\infty} \psi(t)dt = 0 \quad (12)$$

La CWT definida en la Ecuación (16) es en realidad un tipo de filtro adaptado en el que se calcula la correlación cruzada entre la señal y la función wavelet [100]. La ventaja de la CWT frente al filtro adaptado procede de las propiedades que poseen las wavelets, que las hacen capaces de poder tratar con señales transitorias en las que las propiedades espectrales de la señal varían con el tiempo [104]. La CWT es una poderosa herramienta para descomponer en sus constituyentes señales cerebrales transitorias en base a una combinación de criterios tales como su localización en el dominio de la frecuencia y del tiempo. Señales contenidas en la misma banda de frecuencia se pueden distinguir por medio de su localización en el dominio del tiempo. Asimismo, es posible separar la superposición de señales en el dominio del tiempo gracias a la información en el dominio de la frecuencia [104].

La CWT introduce demasiada redundancia y complejidad ya que implica el análisis de la señal en un número muy elevado de frecuencias utilizando múltiples dilataciones y desplazamientos en el tiempo de la wavelet madre. La Transformada Discreta Wavelet (DWT, del inglés *discrete wavelet transform*) se introdujo como una modificación de la CWT que reducía esta redundancia y complejidad. La DWT traslada y dilata en el dominio del tiempo la wavelet madre solamente en ciertos valores discretos [105]. Farina et al. [106] diseñaron un sistema de reconocimiento de patrones que clasificaba potenciales corticales relacionados con actividades motrices donde las propiedades de la señal se obtenían a partir de los coeficientes de la DWT. A pesar de que la DWT tiene las ventajas de que es menos redundante y compleja que la CWT, la CWT se sigue empleando todavía en el diseño de BCI ya que con la CWT es posible extraer información que no puede ser descubierta con la DWT. Por ejemplo, Bostanov et al. [107] utilizaron la CWT para la extracción de características en la detección de potenciales P300 y SCP.

Para usar la WT es necesario seleccionar una wavelet madre. Dentro del campo de las aplicaciones BCI, es posible encontrar muchos tipos de wavelets madre diferentes. La elección de una wavelet madre en particular depende del tipo de características que se quiere extraer de la señal. La wavelet Mexican Hat está bien localizada en el dominio del tiempo y se emplea para la localización de componentes de ERP en el dominio del tiempo [107]. La wavelet Morlet está bien localizado en el dominio de la frecuencia y se ha utilizado para el análisis de la actividad gamma [108]. La wavelet bi-escala se ha empleado con éxito para el diseño de una máquina asíncrona BCI basada en la detección de patrones relacionados con la imaginación de movimiento en señales entre 1 y 4 Hz [109]. La wavelet Daubechies se ha utilizado para la clasificación de SCPs [110].

2.6 Métodos de clasificación de características

En este TFM se estudian varios métodos para el diseño de la etapa de clasificación de un BCI. Hay dos aproximaciones principales para el diseño de esta etapa: métodos regresivos o métodos de clasificación. En cambio, los algoritmos de clasificación usan las propiedades como variables independientes para definir los límites entre los distintos objetivos correspondientes a las intenciones del usuario descifrables por el BCI. Los más habituales son los métodos de clasificación [111].

McFarland *et al.* [112] ilustra las principales diferencias entre estas dos alternativas. Para un caso en el que se requiere descifrar dos intenciones diferentes del usuario, tanto el método de regresión y el método de clasificación requieren determinar una sola función. Sin embargo, en el caso de tener que detectar cuatro opciones, el método de regresión todavía requiere una sola función mientras que si se emplea clasificación es necesario determinar tres funciones o fronteras de decisión para lograr distinguir los cuatro objetivos. Por lo tanto, los métodos de regresión pueden ser preferibles para un mayor número de objetivos, o para aplicaciones que impliquen el control continuo de movimiento del cursor. La Figura 3 muestra estas diferencias entre los métodos de clasificación y regresión.

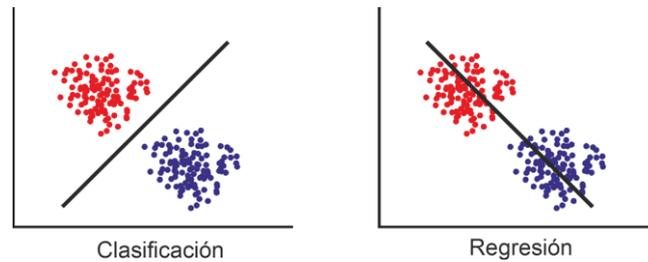


Figura 3. Representación de los métodos de clasificación y regresión para dos objetivos (adaptado de [210]). Los algoritmos de regresión emplean las características extraídas de las señales de la señal EEG como variables independientes para predecir las intenciones del usuario. Sin embargo, los métodos de clasificación utilizan las características extraídas como variables independientes para definir los límites entre los diferentes objetivos en el espacio de características.

El diseño de nuevos métodos de clasificación para BCI puede ser llevado cabo mediante sesiones *offline*, *online* o ambos tipos de sesiones. Las sesiones *offline* consisten en probar un método en concreto empleando conjuntos de datos grabados previamente como, por ejemplo, los que se proporcionan en las competiciones BCI [113, 114]. Durante las sesiones *offline* no es necesario analizar las señales de manera causal ni en tiempo real. Además es posible estimar ciertas propiedades de las señales observando todas las señales en su extensión en el tiempo y realizar cálculos que impliquen largos tiempos de computación. Los resultados del algoritmo diseñado pueden ser revisados con el objetivo de mejorar el rendimiento del algoritmo. El análisis *offline* es valioso pero no trata los problemas relacionados con el análisis de señales en tiempo real. Por el contrario, el análisis *online* es el medio para evaluar un BCI en un entorno real. Los datos solo pueden ser procesados de manera causal además de que este tipo de análisis tiene en cuenta la realimentación proporcionada por el BCI que se está diseñando. Aunque algunos investigadores proponen algoritmos que solo han sido probados con datos *offline*, son necesarios ambos tipos de análisis para el diseño de algoritmos efectivos en un entorno real en el que el usuario recibe realimentación del BCI [115, 116].

El entrenamiento o calibración de los algoritmos de clasificación habitualmente se hace de manera supervisada empleando un conjunto de señales etiquetado. Se asume que el clasificador es capaz de detectar los patrones similares que se encontrarán durante las sesiones con realimentación. Sin embargo, esto conlleva que el rendimiento del BCI baje, ya que las señales cerebrales son inherentemente no estacionarias. Los patrones observados en la sesión de entrenamiento pueden ser diferentes de los observados durante las sesiones *online*. Además, el progresivo entrenamiento de los usuario o cambios de concentración, atención, o motivación pueden afectar a las señales cerebrales [117]. Por tanto, es esencial diseñar algoritmos adaptativos para mejorar la precisión de los BCI. Esto resulta ser particularmente necesario para el diseño de BCI asíncronos y no invasivos [115, 116].

El entrenamiento supervisado, además de no ser óptimo para la clasificación de señales no estacionarias, requiere normalmente procesar una gran cantidad de datos para realizar la calibración inicial del clasificador y, por tanto, requiere que el usuario dedique gran cantidad de tiempo para la calibración del BCI. Por este motivo, se ha propuesto el entrenamiento semi-supervisado, que reduce el tiempo necesario de

CAPÍTULO 2: SISTEMAS BRAIN COMPUTER INTERFACE

calibración inicial haciendo una actualización de los algoritmos durante las sesiones *online* [118]. Con el entrenamiento supervisado, el clasificador es entrenado empleando un pequeño conjunto de datos etiquetado, y después se actualiza con los datos procesados *online*.

En un escenario más realista, no es posible conocer al mismo tiempo las señales y las intenciones de los usuarios. En este caso, se tienen que aplicar métodos que empleen entrenamiento no supervisado o aprendizaje reforzado. Los métodos no supervisados tratan de encontrar estructuras dentro de los datos no etiquetados para clasificarlos. Estos métodos se basan en técnicas enfocadas a la adaptación entre el usuario y el BCI [119-121]. El entrenamiento reforzado se basa en el hecho de que es posible detectar algunos patrones característicos en las señales de EEG que son generados cuando los usuarios son conscientes de que el BCI ha malinterpretado su intención. Este tipo de patrones se puede usar como señales de aprendizaje que eviten que el error cometido por el BCI en un momento determinado se repita en el futuro [122].

Los métodos adaptativos normalmente implican una mejora en el rendimiento del BCI. No obstante, existen algunos riesgos en los BCI adaptativos. Un BCI adaptativo podría aprender demasiado deprisa y poder confundir al usuario, ya que está aprendiendo a manejar el BCI en un entorno que para él está cambiando continuamente. Además, la adaptación del BCI podría enmascarar algunas propiedades relevantes de las señales. Existe, por tanto, un compromiso entre tener una alta capacidad de adaptación y la extracción de características [123].

El problema de la clasificación de patrones presenta dos importantes dificultades: la maldición de la dimensionalidad, el compromiso sesgo-varianza, y el sobreentrenamiento.

La maldición de dimensionalidad significa que el número de muestras necesarias para entrenar un clasificador de manera supervisada crece exponencialmente con la dimensión del vector de propiedades [124]. Desafortunadamente, los conjuntos de muestras que se pueden emplear para el entrenamiento son pequeños porque la generación de estas señales es un proceso largo que produce cansancio a los usuarios de los BCI.

El compromiso entre el sesgo y la varianza está relacionado con la tendencia natural de los clasificadores a tener un alto sesgo con baja varianza y viceversa [111]. El error medio de clasificación puede ser descompuesto en tres términos:

$$MSE = \text{Ruido}^2 + \text{Sesgo}(f(x))^2 + \text{Var}(f(x)) \quad (13)$$

El ruido representa el carácter aleatorio de las muestras de entrenamiento y de test. El sesgo representa la divergencia entre el modelo estimado y el mejor modelo. La varianza refleja la sensibilidad del clasificador al conjunto de muestras de entrenamiento empleado. Los clasificadores más estables se caracterizan por tener un elevado sesgo y baja varianza y los más inestables tienen alta varianza y bajo sesgo. El objetivo para conseguir el menor error en la clasificación es tratar de reducir al mismo tiempo el sesgo y la varianza. Se pueden emplear algunas técnicas como la regularización o la combinación de clasificadores para reducir la varianza [111].

El sobreentrenamiento se produce cuando un clasificador solo es capaz de clasificar los patrones que han sido empleados para el entrenamiento u otros muy similares. Esto puede ser evitado empleando regularización. La regularización es un método para

controlar la complejidad del clasificador con el fin de prevenir el sobreentrenamiento, limitar el efecto de los outliers, e irregularidades en las fronteras de decisión [125].

En este TFM se van a estudiar varios métodos de clasificación para señales EEG: análisis discriminante lineal, máquina de soporte vectorial, perceptrón multicapa, red probabilística de Parzen y el clasificador Naïve Bayesian Parzen Window (NBPW). En el 0 se pueden encontrar una explicación detallada de los mismos.

2.7 Tratamiento de artefactos

Los artefactos son señales no deseadas que contaminan la actividad cerebral y su origen no es cerebral. Debido a que los fenómenos neurológicos se ven afectados por estos artefactos, es posible este tipo de señales pueda reducir el rendimiento de los sistemas BCI. Los artefactos pueden ser clasificados en dos grandes categorías: artefactos fisiológicos y artefactos no fisiológicos o técnicos. Los artefactos fisiológicos son por lo general causados por el movimiento de los músculos, ojos, y pulsaciones del corazón. Se denominan respectivamente electromiograma (EMG), electrooculograma (EOG) y electrocardiograma (ECG) [126].

Los artefactos EMG implican normalmente grandes interferencias en las señales cerebrales y proceden de la actividad eléctrica originada por contracciones de los músculos que se producen al hablar, masticar o tragar. Los artefactos EOG se producen como consecuencia del parpadeo o movimientos de los ojos. El parpadeo en los ojos ocasiona señales de gran amplitud sobre las señales del cerebro y el movimiento de los ojos genera señales que se caracterizan por tener una baja frecuencia. Estas señales eléctricas que se originan desde los ojos se deben a la diferencia de potencial entre la córnea y la retina como resultado de que poseen respectivamente carga positiva y negativa. Por esa razón, cuando este dipolo se mueve, el campo eléctrico de alrededor de los ojos cambia generando los artefactos EOG. Los artefactos EOG afectan principalmente a la zona frontal, ya que se atenúan aproximadamente con el cuadrado de la distancia [127]. Por último, los artefactos ECG, que reflejan la actividad del corazón, introducen una señal periódica en la actividad cerebral [126]. Los artefactos técnicos se atribuyen principalmente al ruido de la línea eléctrica o cambios en las impedancias de electrodos. Este tipo de artefactos pueden ser generalmente evitados mediante un filtrado adecuado o apantallamiento de los cables [126]. La reducción de los artefactos fisiológicos durante la adquisición de la actividad cerebral es un problema mucho más difícil. Por ello, la comunidad científica dedicada al diseño de BCI se ha centrado mucho más en este tipo de artefactos.

En la literatura científica se pueden encontrar varios métodos de manipulación de artefactos. Los artefactos se pueden evitar, rechazar o eliminar de las señales del cerebro. Para evitar la existencia de artefactos se pide a los pacientes que repriman el parpadeo o movimiento de su cuerpo durante la monitorización de su actividad cerebral [128]. Esta forma de tratamiento de los artefactos es muy simple porque no requiere ningún tipo de consumo computacional puesto que se asume las señales cerebrales recogidas no se encuentran interferidas por ningún tipo de artefacto. Sin embargo, esta suposición no siempre es viable ya que algunos artefactos son inevitables. Los latidos del corazón son involuntarios y los movimientos de los ojos y el cuerpo no se pueden evitar fácilmente durante la grabación de datos, especialmente en el caso de fuertes trastornos neurológicos [128]. La opción de rechazar los artefactos descarta de las

señales monitorizadas aquellas partes que han sido contaminadas por artefactos. Una posibilidad para eliminar los artefactos de la señal del cerebro es rechazar estas partes de señal contaminada de manera manual. En este caso, un experto identificaría y eliminaría todos aquellos fragmentos de señal contaminados por los artefactos. El principal inconveniente de usar el rechazo manual es que requiere demasiada mano de obra y, además no es adecuado para sistemas BCI *online*. Esta tarea se puede realizar también de forma automática controlando las señales EMG y EOG y eliminando las muestras de la señal cerebral cuando se detecta actividad ocular o muscular [129]. El rechazo de artefactos automático es una manera efectiva de manejar los artefactos, pero puede fallar si la amplitud de las señales EOG es demasiado pequeña. Además, puede suceder que el usuario pierda el control del dispositivo en los momentos en los que las señales contaminadas son desechadas. Entonces, en lugar de rechazar muestras, se puede eliminar los artefactos de la señal cerebral adquirida sin descartar completamente la señal. Con este enfoque se pretende identificar y eliminar los artefactos, al mismo tiempo que conservar intactos los fenómenos neurológicos contenidos en la señal. Los métodos más comunes para la eliminación de los artefactos en las señales EEG son el filtrado lineal, combinación lineal y la regresión, BSS y PCA [126].

2.8 Aplicaciones

Los BCI ofrecen a sus usuarios un nuevo canal para comunicarse y controlar dispositivos sin la intervención de los nervios periféricos ni los músculos. Muchos investigadores están centrados en el desarrollo de aplicaciones de los BCI con la esperanza de que esta tecnología pueda ser útil para aumentar las posibilidades de comunicación para aquéllos con discapacidades motrices severas. En los últimos años, se han desarrollado muchas aplicaciones gracias a los importantes avances en el campo de los BCI basados en señales EEG. Las señales EEG son las más utilizadas por la mayoría de las aplicaciones ya que poseen una calidad aceptable al mismo tiempo que el equipo necesario es fácil de usar y no es caro.

Antes de describir las aplicaciones de los BCI, reseñar una importante diferencia entre un BCI y sus aplicaciones [14]. Un BCI es una herramienta que realiza una función particular y, por tanto, es caracterizado por la manera que desarrolla dicha función. Un BCI representa un dispositivo que puede ser usado en multitud de aplicaciones pero que su función permanece inalterada. Entonces la evaluación de un BCI se centra solamente en la eficacia con la que realiza su función específica. En cambio, las aplicaciones de los BCI se describen en términos de las herramientas que ellos emplean y las prestaciones que ofrece. Por tanto, su evaluación se centra en cómo de bien realiza los servicios que ofrece. En otras palabras, el término BCI se refiere al sistema que recoge, analiza, y traduce las señales de entrada en comandos y el término aplicación se corresponde con el entorno donde se aplican estos comandos estimados por el BCI. Como consecuencia de esta distinción, los métodos para evaluar cada uno de ellos son distintos en cada caso.

En la actualidad, existe un gran número aplicaciones de los BCI con diferentes propósitos tales como procesadores de texto, exploradores *web* adaptados, sillas de ruedas o neuroprótesis, y juegos entre otros. Las aplicaciones de los BCI se pueden clasificar según su finalidad en cinco grandes áreas: comunicación y control, recuperación de capacidades motrices, control del entorno, locomoción y entretenimiento.

2.8.1 Comunicación

Las aplicaciones de los BCI para comunicación tratan de proporcionar un modo de comunicación a aquellas personas con graves dificultades para comunicarse como consecuencia de enfermedades neurológicas. Probablemente sea este tipo de aplicaciones el que necesite ser investigado más urgentemente ya que la actividad de comunicación es esencial para los seres humanos. Las aplicaciones para la comunicación presentan normalmente un esquema de operación que consiste en mostrar un teclado virtual en una pantalla y el usuario selecciona a través de un BCI una letra del alfabeto. El elemento distintivo de cada planteamiento es generalmente el tipo de señal de control empleado para controlar el BCI.

A través de modulación voluntaria de SCPs es posible seleccionar las letras representadas en la pantalla. Con un entrenamiento previo, algunos pacientes que sufren parálisis total son capaces de producir cambios positivos y negativos en sus SCPs con el objetivo de controlar el movimiento vertical de un cursor sobre una pantalla [59]. Birbaumer et al. [130] desarrollaron un dispositivo de escritura basándose en este tipo de señal de control que mostraba un cursor sobre una pantalla, permitiendo a los usuarios seleccionar las letras del alfabeto. Las pruebas de esta aplicación en pacientes que sufrían ELA ya en estado avanzado mostraron que los pacientes eran capaces de alcanzar una velocidad de escritura de aproximadamente 2 caracteres por minuto. También se ha empleado otros tipos de señales de control para seleccionar los elementos o caracteres en un teclado virtual, tales como la detección de parpadeo de los ojos [131], que normalmente representan un artefacto en las señales de EEG, o la clasificación de la señales cerebrales producidas como consecuencia de realizar tres tareas mentales diferentes [132]. Aparte de la señal de control utilizada, ambos enfoques son prácticamente iguales. En ambos casos, el teclado virtual consistía en un total de 27 símbolos, 26 letras más el espacio para separar palabras, organizados en una matriz de tres filas por nueve columnas. Asimismo, ambas aplicaciones empleaban para escribir una letra un mismo procedimiento que requería tres pasos. En el primer paso, todo el teclado se dividía en tres bloques con 9 letras cada uno. Entonces, el usuario seleccionaba un conjunto de nueve letras generando voluntariamente uno, dos o tres parpadeos [131] o imaginando una de las tres tareas detectables [132], según cada caso. Después de la primera selección, el conjunto de nueve letras se dividía de nuevo en tres grupos cada uno con tres letras y el usuario seleccionaba uno de ellos mediante el mismo procedimiento que en el primer paso. Finalmente, en el tercer paso, el usuario elegía una sola letra de entre los tres símbolos que quedaban. Con estas aplicaciones, los pacientes conseguían escribir correctamente hasta 1 carácter por minuto en el caso de usar parpadeos [131] y 2,72 caracteres por minuto para el caso en que se emplearan tres tareas mentales [132].

Obermaier et al. [133] diseñaron basándose en el BCI estándar Graz un sistema para escribir que también incluía un teclado virtual. El procedimiento para seleccionar de las letras era prácticamente el mismo que el que se ha explicado anteriormente. La diferencia con respecto al caso anterior era que el alfabeto estaba formado por 32 letras y, en lugar de dividir el alfabeto en cada paso en tres subconjuntos, era dividido en dos mitades cada una de las cuales se seleccionaba mediante la imaginación del movimiento de una mano o de una pierna. Los usuarios lograban una tasa de escritura que variaba entre las entre 0,5 y 0,85 letras por minuto. Esta tasa aunque es inferior a la obtenida en las otras dos aplicaciones anteriores, parece fácil aumentar el número de caracteres escritos por minuto con sólo ampliar el número de movimientos a más de dos de manera que se puede dividir el abecedario en más de dos subconjuntos.

CAPÍTULO 2: SISTEMAS BRAIN COMPUTER INTERFACE

Los potenciales relacionados P300 son también muy populares en aplicaciones BCI que permiten la selección de caracteres. Se ha comprobado que los BCI basados en potenciales P300 son bastante adecuados para este tipo de aplicación incluso para pacientes que sufren ELA en las etapas temprana y media [134]. Además, este tipo de BCI resulta ser muy práctico porque la respuesta P300 se produce de forma espontánea y, por lo tanto, no requiere un entrenamiento. Los recientes avances en sistemas de escritura que emplean potenciales P300 han permitido incluso el desarrollo de una aplicación comercial a disposición del público en general [135]. Uno de los más conocidos teclados virtuales basados en potenciales P300 fue diseñado por Farwell y Donchin en 1988 [68]. En esta aplicación se mostraban sobre una pantalla, colocadas en una matriz 6x6, las 26 letras del alfabeto junto con varios otros símbolos y comandos (

Figura 4). Las filas y columnas de la matriz eran iluminadas de manera aleatoria y el usuario, que prestaba atención a la pantalla, fijaba su mirada en cada uno de los caracteres que deseaba escribir, mientras se registraba la respuesta de EEG. Para cada uno de los elementos de la matriz que el usuario iba prestando atención se producían dos respuestas P300, uno cuando se iluminaba la fila que contenía el símbolo deseado y otro cuando se iluminaba la columna. De esta manera, el sistema podía localizar en la matriz el símbolo que el usuario deseaba escribir a través de las respuestas P300 contenidas en la señal EEG. La velocidad de escritura que se ha alcanzado con este sistema de comunicación es de 2 caracteres por minuto.

El deletreador diseñado por Farwell y Donchin ofrece una tasa de escritura y precisión relativamente altas, pero es posible mejorar aún más su precisión reduciendo la posibilidad de que se produzcan errores de percepción [136]. Los errores de percepción ocurren cuando una respuesta P300 es provocada por el destello de las filas o columnas adyacentes al símbolo objetivo confundiendo al sistema. Este problema resulta ser la principal fuente de error en la precisión del deletreador de Farwell y Donchin. Para evitar este problema, se propuso una nueva manera de distribuir las letras en la pantalla (Figura 5) [136]. Se proponía dividir los símbolos en varias regiones en lugar de utilizar filas y columnas. Los símbolos se colocaban en una distribución de dos niveles. En el primer nivel, los símbolos se distribuyen en siete grupos que son iluminados aleatoriamente. Aquel grupo que contenga el carácter deseado será conocido gracias a la detección de las respuestas P300. Ya en el segundo nivel, los símbolos que contiene el grupo seleccionado serán distribuidos de nuevo en siete regiones diferentes cada una de ellas con un solo carácter. Finalmente, el carácter objetivo final es encontrado repitiendo el mismo procedimiento que para seleccionar los grupos de caracteres en el primer nivel. Ahi et al. [137] también mejoró el deletreador propuesto por Farwell y Donchin introduciendo un diccionario para disminuir el número de errores que se cometían al decidir qué símbolo seleccionaba el usuario. El diccionario se utilizaba para comprobar cada una de las palabras que se escribían a medida que se detectaban las respuestas P300. En caso de descubrir un error al deletrear la palabra porque la palabra no se encuentre en el diccionario, se seleccionaba una palabra de entre las que el diccionario sugería. Además, con el fin de reducir la probabilidad de error al formar la palabra debido a errores de percepción, se modificó la distribución de las letras dentro de la matriz que se mostraba en la pantalla de acuerdo con un análisis previo de las similitudes entre las palabras que se incluían en el diccionario.

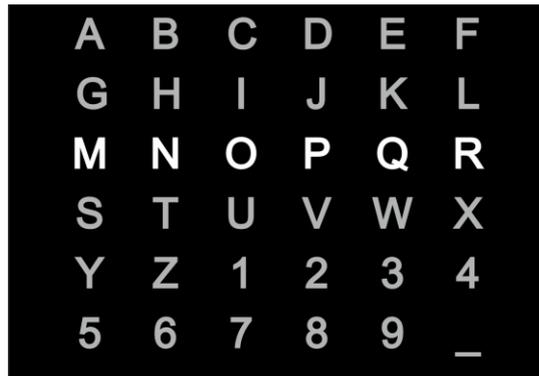


Figura 4. Deletreador original P300. Matriz de símbolos mostrada sobre una pantalla que sirve como teclado virtual.

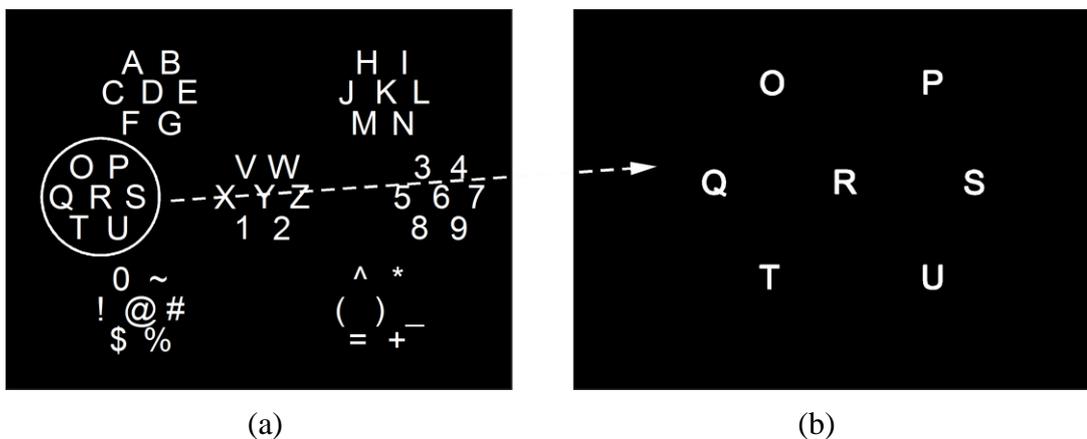


Figura 5. Nueva distribución propuesta para mejorar el deletreador P300 propuesto por Farwell y Donchin. (a) El primer nivel contiene siete grupos de letras cada uno de ellos a su vez con siete letras. (b) En el segundo nivel se expanden las letras contenidas en el grupo que se ha seleccionado.

Todos los anteriores sistemas de escritura basados en las respuestas P300 monitorizan la existencia de potenciales visuales relacionados con estímulos. Sin embargo, esto no tiene sentido en los casos de pacientes con parálisis grave y deficiencias visuales o falta de control en el movimiento de la mirada. En estos casos, es posible utilizar estímulos auditivos para generar respuestas P300 y permitir la comunicación a este grupo de pacientes [71, 138-140].

Otras aplicaciones importantes de los BCI relacionadas con la comunicación son los navegadores de Internet adaptados a usuarios con discapacidades severas ya que, en la última década, Internet se ha convertido en un elemento muy importante de la vida cotidiana de las personas. Dentro de este campo, "Descartes" es uno de los primeros navegadores Web y está controlado mediante la modulación de SCPs [141]. Su interfaz de navegador se basa en la organización de los enlaces en orden alfabético dentro un árbol de decisión con dos opciones, donde el usuario selecciona o rechaza cada elemento produciendo variaciones positivas o negativas en sus SCPs. "Descartes" presenta el inconveniente de que únicamente se pueden consultar un número limitado de las páginas web ya que al iniciar el proceso de navegación el usuario solo puede seleccionar un número de enlaces predefinidos, que se presentan organizados en un árbol. Además, no es posible seleccionar enlaces gráficos puesto que la etiqueta de texto de los enlaces contenidos en una página es la que se emplea para identificar cada uno de ellos. Existe un prototipo más avanzado de navegador, llamado "Nessi", que supera las

deficiencias de Descartes gracias a una mejor interfaz de usuario [142]. En lugar de organizar los enlaces en un árbol, se colocan una serie de marcos coloreados alrededor de los enlaces o elementos seleccionables en la página web. Más recientemente, se han diseñado otros exploradores web que en lugar de usar SCPs emplean ERPs. Mugler et al. [70] construyeron un navegador de Internet que empleaba potenciales evocados P300 donde cada una de las opciones era presentada en forma de icono dentro de una matriz 8x8. Jinghai et al. [55] desarrollaron un navegador basado en VEP. La ventaja de usar ERPs como señales de control en los navegadores es que se producen rápidamente de manera natural con lo que se puede lograr una relativa alta velocidad en la navegación web.

2.8.2 Recuperación de capacidades motrices

Las personas que padecen lesiones de la médula espinal (LME) u otras enfermedades neurológicas con la correspondiente pérdida de función sensorial y motora sufren dependencia de por vida y, con ello, una dramática disminución en su calidad de vida. Por lo tanto, la restauración de sus capacidades motrices puede disminuir su sufrimiento psicológico. En pacientes tetraplégicos, es posible recuperar movimientos como agarrar ciertos objetos mediante neuroprótesis guiadas por estimulación eléctrica funcional (FES). FES puede compensar la pérdida de las funciones voluntarias provocando contracciones artificiales en los músculos. Mediante corrientes eléctricas se genera un potencial artificial que activa los músculos que se pretenden tratar provocando una contracción muscular en ellos (ver [143] para una revisión). Es posible emplear BCI que emplean las señales EEG para generar una señal de control para el manejo de la FES ya que la señal EEG no se ve afectada por la activación eléctrica artificial de los músculos de las extremidades superiores [144]. Gracias a la combinación de un sistema BCI con FES, Pfurtscheller et al. [145] desarrollaron una aplicación en la que pacientes tetraplégicos eran capaces de controlar sus manos paralizadas para agarrar un cilindro a través de variaciones en sus ritmos beta generadas con la imaginación del movimiento de un pie. El BCI analizaba y clasificaba las modulaciones de los ritmos beta y la señal de salida se utilizaba para controlar un dispositivo FES que activaba la mano.

Se ha demostrado que FES es una manera eficaz de recuperar la capacidad motora. Sin embargo, para emplear FES es necesario que permanezcan en los músculos ciertos movimientos residuales que no son posibles en los pacientes muy afectados por la parálisis. Por esta razón, algunos grupos de investigación comenzaron a explorar enfoques que combinaran neuroprótesis con sistemas BCI sin la intervención del FES. Pfurtscheller et al. [146] demostraron, con pruebas con un paciente, que era posible controlar de manera eficaz una prótesis en una mano mediante cambios en los ritmos mu producidos con imaginación de movimientos. Este tipo de sistema requería un largo periodo de entrenamiento tras el cual el paciente finalmente era capaz de manejar la prótesis de la mano prácticamente sin error. Algunos años más tarde, el mismo grupo verificó de manera definitiva la viabilidad del acoplamiento de BCI basados en señales EEG con neuroprótesis dando más evidencias de la efectividad de BCI en el control de neuroprótesis [147]. En estos últimos estudios, se hizo que un BCI clasificara patrones existentes en la señal EEG que involucraban una reducción de la potencia en una serie de bandas específicas de frecuencia. Estos patrones eran generados por el usuario mediante la imaginación de movimientos con su mano izquierda paralizada.

Más recientemente, también se han utilizado ERPs para proporcionar la recuperación de las capacidades motrices. Muller et al. [148] presentaron una novedosa neuroprótesis para la restauración de la función motrices en personas que sufrían LME. Esta

neuroprótesis consistía en una mano con dos ejes controlada por un BCI basado en SSVEP que ofrecía cuatro opciones. Era posible seleccionar cuatro movimientos mediante cuatro LEDs que parpadeaban a diferentes frecuencias. Fijando la mirada en uno de los cuatro LEDs, el usuario podía seleccionar un movimiento. Dos de los cuatro LEDs servían para situar la mano en supinación o pronación. Estos se encontraban situados en el dedo índice y meñique del usuario y parpadeaban con una frecuencia de 6 y 7 Hz. Los dos LEDs restantes estaban colocados sobre la muñeca y parpadeaban a 8 y 13 Hz. Estos se correspondían con las órdenes de abrir y cerrar la mano.

2.8.3 Control del entorno

Uno de los principales objetivos de las aplicaciones de los BCI es la consecución de la máxima independencia de los pacientes a pesar de su discapacidad motora. Las personas que sufren discapacidades motrices graves permanecen a menudo mucho tiempo en su casa y, por esta razón, las aplicaciones que permiten el control del entorno se centran en permitir el control de dispositivos de uso diario en el hogar tales como la televisión, las luces o el sistema de control de la temperatura ambiente. Además de mejorar la calidad de vida de estas personas con discapacidades graves, gracias a que este tipo de aplicaciones que permite el control de dispositivos de asistencia, es posible liberar al cuidador de tener que prestar continuamente atención al paciente. Esto además lleva consigo una reducción en el coste de los cuidados al paciente al mismo tiempo que se hace con menos difícil la vida de los familiares.

Cincotti et al. [149] presentaron un estudio piloto relacionado con la integración de la tecnología BCI en el entorno doméstico. En este estudio, se diseñó un dispositivo que permitía el control del entorno adaptándose al nivel de independencia que tenía el paciente en función de su nivel de discapacidad. En el caso de que el paciente poseyera todavía movilidad residual en los miembros superiores se le ofrecía la posibilidad de usar periféricos típicos como el teclado, el ratón o el joystick para controlar los dispositivos externos. En el caso de que el usuario tuviera sus extremidades inhabilitadas pero los músculos del cuello o la capacidad de hablar intactos, se ofrecía un sistema para seguir los movimientos de la cabeza o para reconocer el habla. Finalmente, en los casos de personas con discapacidad total, el sistema podía ser controlado mediante la modulación voluntaria de los ritmos sensoriomotores, que eran registrados por un BCI. Al ofrecer varios niveles en el control, la aplicación se adaptaba a la pérdida gradual de las habilidades motrices causada por enfermedades neurodegenerativas progresivas. Como dispositivos de salida, el sistema permitía utilizar un grupo básico de dispositivos domésticos tales como el control de las luces, la TV o el equipo de música, una cama motorizada, el despertador, la apertura de la puerta de entrada, el teléfono, así como cámaras inalámbricas de vigilancia.

También, se han utilizado técnicas invasivas para manejar aplicaciones de control del entorno. Hochberg et al. [150] probó a implantar sensores *BrainGate* en la corteza motora primaria para controlar un cursor. Durante los ensayos iniciales que se realizaron sobre un ser humano tetrapléjico, el paciente pudo manejar aplicaciones de correo electrónico o utilizar dispositivos externos tales como un televisor, imaginando movimientos con sus extremidades, incluso mientras hablaba.

2.8.4 Locomoción

Otra aplicación importante de los BCI es aquella que permite a las personas con discapacidades motrices controlar un medio de transporte. Gracias a estas aplicaciones,

CAPÍTULO 2: SISTEMAS BRAIN COMPUTER INTERFACE

las personas que son parapléjicas o tienen alguna otra discapacidad física pueden impulsar de forma autónoma una silla de ruedas aumentando su independencia y mejorando su calidad de vida. Uno de los requisitos imprescindible en el diseño de este tipo de aplicaciones es que el sistema BCI sea portable. Como consecuencia, el tipo de BCI que se va a usar para diseñarlas emplea señales EEG ya que es el único método para registrar la actividad neuronal que es portable y está suficientemente desarrollado para ser usado en aplicaciones. Las señales de EEG suelen ser muy ruidosas y tienen una gran variabilidad por lo que es de esperar que el tiempo entre las distintas órdenes decodificadas por el BCI sea largo y la incertidumbre en cada decodificación sea alta. Por lo tanto, el principal desafío en el diseño de este tipo de aplicaciones es lograr la suficiente precisión en detección de los comandos para conseguir una conducción del medio de locomoción fiable, así como un control en tiempo real, a pesar de ultra-baja velocidad de transferencia de información que el BCI proporciona. Por esta razón, algunos estudios sobre BCI proponen que en este tipo de aplicaciones se empleen técnicas invasivas para adquirir la actividad cerebral en lugar de emplear EEG. Serruya et al.[151] experimentaron con monos implantando de un conjunto de electrodos sobre su corteza motora. Estos primeros experimentos iniciales mostraron que los monos eran capaces de mover un cursor de ordenador hacia cualquier posición, lo que abrió la posibilidad de aplicar este tipo de técnicas en humanos para controlar un móvil.

Los riesgos relacionados con estas técnicas invasivas forzaron a desarrollar este tipo de aplicaciones empleando técnicas adquisición de señales cerebrales no invasivas. Los primeros experimentos relacionados con el control de medios de locomoción se dedicaron a probar la viabilidad de poder guiar de forma continua mediante señales EEG un robot móvil dentro de una casa con varias habitaciones, pasillos y puertas [132, 152]. Los alentadores resultados de estos experimentos piloto abrieron la posibilidad de que personas con discapacidad física pudieran utilizar un BCI portátil basado en EEG para controlar sillas de ruedas. Tanaka et al. [69] presentó en 2005 por primera vez una aplicación para el control de sillas de ruedas que utilizaba únicamente señales EEG. En este estudio, el suelo por el que podía circular la silla de rueda fue fragmentado en una serie de cuadrados y el usuario decidía mediante la imaginación de movimientos de las extremidades izquierda y derecha hacia cuáles de ellos debía ser dirigida la silla de ruedas. De esta manera, la silla de ruedas se iba desplazando cuadrado a cuadrado siguiendo la trayectoria deseada por el usuario.

Como ya se ha indicado anteriormente, unos de los problemas más comunes encontrado en las aplicaciones para el control de una silla de ruedas mediante un sistema BCI es que la señal de control es discontinua y además transmite una baja tasa de bits y con poca fiabilidad. Para solucionar este problema se han presentado algunas mejoras en los últimos años. Con el fin de asegurar una mayor fiabilidad, se empezó a usar BCI basados en respuestas P300. Para superar el problema que supone la baja tasa de bits proporcionada habitualmente por los sistemas BCI, se dotó de cierta autonomía a estas aplicaciones con el objetivo de disminuir el número de interacciones necesarias para lograr que la silla de ruedas siguiera la trayectoria deseada. Rebsamen et al. [153] diseñaron una silla de ruedas, donde se simplificó el control al limitar los movimientos a una serie de caminos, que podían ser definidos por el paciente que usaba la silla de ruedas o un ayudante. Estos caminos predefinidos se hacían corresponder con algún punto específico dentro del entorno por el cual se iba a utilizar la silla de ruedas y la información se almacenaba en el sistema. Entonces, el usuario seleccionaba el destino a través de un BCI P300 y la silla de ruedas seguía el camino de manera autónoma. De este modo, el usuario sólo tenía que decidir en qué momento la silla de ruedas tenía que

parar en el caso de que se deseara que la silla de ruedas se detuviera en algún punto intermedio del trayecto. El sistema de guiado de la silla de ruedas requería conocer su localización de forma ininterrumpida para llevar a cabo el seguimiento de las trayectorias correctamente. Para tal fin, se dotó a la silla de ruedas de un odómetro y un escáner de código de barras para leer los códigos de barras, que habían sido colocados previamente en el suelo a lo largo de las trayectorias. Algunos años más tarde, se mejoró la aplicación para garantizar que la parada de la silla de ruedas se hiciera más rápidamente incrementando la seguridad de la misma. Se equipó a la silla de ruedas con dos sistemas BCI más rápidos basados en la detección de respuestas P300 y de ritmos mu y beta que permitían que el usuario detuviera más rápidamente la silla de ruedas [154].

La principal desventaja de las distintas soluciones explicadas anteriormente es el sistema que ayuda al control de la silla de ruedas es poco flexible y no es capaz de hacer frente a situaciones nuevas o de tratar con entornos muy poblados de personas. Iturrate et al. [12] superaron este inconveniente al hacer que el sistema de control construyera de manera dinámica el entorno que lo rodeaba. Otros estudios sugirieron que el usuario sólo debía ser ayudado en aquellos casos en los que tenía más dificultades para conducir la silla de ruedas, por ejemplo, en un pasillo estrecho [116, 155, 156]. Se puede establecer tres niveles de asistencia que sólo se activan en el caso de que el usuario realmente lo necesite. Uno que evite que tengan lugar colisiones, otro que evite los obstáculos y otro que se encargue de recuperar la posición en el caso de perder la orientación [155]. Antes de ejecutar los comandos transmitidos por el usuario para guiar la silla de ruedas, el sistema de asistencia evaluaría la situación con los datos proporcionados por una serie de escáneres láser. Estos escáneres estarían encargados de inspeccionar el entorno y detectar los posibles obstáculos o paredes.

2.8.5 Entretenimiento

Las aplicaciones basadas en sistemas BCI que estén orientadas hacia el entretenimiento habitualmente han tenido una baja prioridad dentro de la investigación en el campo de los BCI. Hasta ahora, la investigación en la tecnología BCI se ha centrado normalmente, en lugar de aplicaciones con fines de entretenimiento, en aplicaciones que proporcionan asistencia para mejorar la calidad de vida, tales como sistemas para escribir, guiado de silla de ruedas o control de neuroprótesis entre otras. Sin embargo, durante los últimos años ha surgido un creciente interés en las aplicaciones de entretenimiento debido a los significativos avances en la tecnología BCI. De hecho, la mejora de rendimiento de los BCI ha permitido pensar en usar las aplicaciones de los BCI hasta en personas que no padecen ninguna discapacidad. Se espera que con los BCI se pueda crear una nueva modalidad de interacción que pueda hacer las aplicaciones de entretenimiento habituales mucho más atractivas. Además, gracias a los BCI se podría obtener una serie de parámetros sobre la experiencia del usuario al manejar dichas aplicaciones de entretenimiento y emplear la información cerebral recogida por el BCI para mejorarlas. El BCI podría informar cuando el jugador está aburrido, ansioso o frustrado con el fin de utilizar esta información para el diseño de futuros juegos [157].

Muchas de las aplicaciones BCI dedicadas al entretenimiento surgen como adaptaciones de conocidos videojuegos más antiguos. Se hacen una serie de cambios en el modo de jugar para que sea posible hacerlo empleando un BCI. Por ejemplo, se han modificado conocidos juegos como Pacman o Pong y otros similares para que se puedan usar mediante la imaginación de movimientos [158]. A modo de ejemplo, la Figura 6

CAPÍTULO 2: SISTEMAS BRAIN COMPUTER INTERFACE

muestra una captura de pantalla del juego Pacman. Pacman, que es el avatar que se mueve por la pantalla controlado por el usuario, da un paso cada 1,5 o 2 s, con el objetivo de dar a los jugadores el tiempo suficiente para que puedan transmitir los comandos a la aplicación. La cabeza de Pacman se llena de color rojo o verde de abajo hacia arriba a medida que se va conociendo la intención del jugador y la punta de la nariz de color amarillo indica la dirección hacia la que Pacman va dar el siguiente paso. En otro estudio, se desarrolló un juego de Pin-ball con el fin de ilustrar que era posible realizar tareas complejas en el control de dispositivos externos usando sistemas BCI que emplean técnicas no invasivas para adquirir las señales cerebrales [159].

También se han utilizado potenciales evocados para implementar aplicaciones dirigidas al entrenamiento. Middendorf et al. [160] diseñaron un simulador de vuelo controlado por un BCI basado en la detección de SSVEP. Este simulador era muy sencillo y sólo ofrecía dos posibles acciones de control. La posición del avión solamente se podía mover hacia la izquierda o derecha. En las pruebas que se realizaron con este simulador se probaron dos métodos diferentes para controlar el avión. Por un lado, el comando de control elegido por el usuario (derecha o izquierda) era deducido según la intensidad de los SSVEP detectados por el BCI. Por otro lado, los comandos que el usuario deseaba transmitir eran decodificados teniendo en cuenta la frecuencia de los SSVEP. Los resultados del estudio mostraron que este último modo de funcionamiento era mejor ya que no requería que los usuarios realizaran prácticamente ningún entrenamiento. En este último método, el elemento que caracterizaba las señales relacionadas con cada uno de los posibles comandos surgía de manera natural. Lalor et al. [161] presentaron el juego "MindBalance" en el cual se pedía a los usuarios que mantuvieran en equilibrio sobre una cuerda floja a un funámbulo. Esta aplicación, como la anterior, también se basaba en SSVEP generados al fijar la mirada en dos tableros de ajedrez diferentes que se distinguían porque sus colores estaban invertidos. Usando otro tipo de ERPs, Finke et al. [162] implementó un juego llamado "Mindgame" en el que se empleaba como señal de control potenciales evocados P300. Se sugería que este juego podría ser una herramienta útil para el entrenamiento de la atención ya que los potenciales evocados P300 podrían ser utilizados como una herramienta para indicar el nivel de atención logrado por una persona.

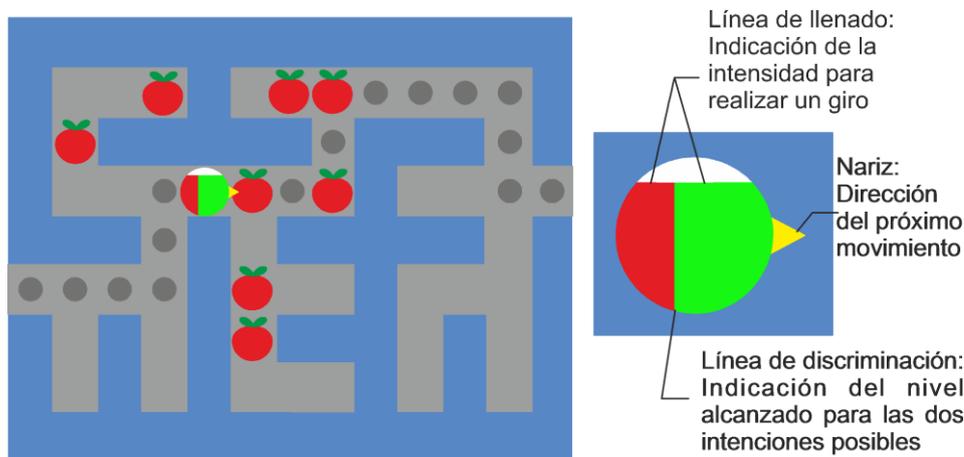


Figura 6. El juego de Pacman. El jugador tiene que recorrer el laberinto para alcanzar la salida que se encuentra en el lado derecho del mismo. El camino más corto está marcado con una serie de marcas grises pero el jugador puede decidir recorrer otros caminos del laberinto para conseguir puntos adicionales.

Todos estos ejemplos de aplicaciones orientadas al entretenimiento que han sido presentados anteriormente se han desarrollado y probado dentro de un contexto de investigación como pruebas experimentales. No obstante, dentro del campo de aplicaciones BCI orientadas al entretenimiento, ya hay algunas empresas comerciales interesadas en entrar en un mercado futuro de juegos comerciales que empleen sistemas BCI. La empresa Emotiv [163] ha desarrollado un amplio conjunto de aplicaciones BCI dedicadas al entretenimiento que incluye juegos como Arcade Cortex o Spirit Mountain Demo Game, entre otros. Además, esta misma empresa vende un BCI de bajo coste compuesto de 14 electrodos denominado neuroheadset EPOC (Figura 7 (a)) que se puede comprar junto con una interfaz de programación de aplicaciones (API). Gracias a esta API, el desarrollo de las aplicaciones basadas en BCI se hace mucho más sencillo. La compañía NeuroSky [164] ofrece otro neuroheadset denominado Mindwave (Figura 7 (b)). Se puede comprar junto con aplicaciones de software que responden a las ondas cerebrales o estados mentales del usuario. Asimismo, esta misma empresa también proporciona un conjunto de herramientas software para los desarrolladores de aplicaciones BCI. Por último, grandes empresas de software como Microsoft ya han mostrado su interés por la investigación en la tecnología BCI y han desarrollado aplicaciones experimentales que utilizan este tipo de sistemas [62].

2.9 Limitaciones de los BCI actuales

Este capítulo recoge un estudio del estado del arte de los sistemas BCI mostrando los fundamentos del diseño de los sistemas BCI. En esta revisión, se han tratado los diferentes métodos de neuroimagen que existen en el campo de diseño de BCI. Se ha presentado una somera descripción de las características de los distintos métodos para la extracción de propiedades y clasificación de las señales cerebrales que han sido utilizados en el diseño de sistemas BCI, mostrando sus ventajas e inconvenientes. Muchos de estos métodos de extracción y clasificación están basados en investigaciones anteriores dentro del campo del procesamiento de la señal y del reconocimiento de patrones. Como consecuencia, a pesar de que el campo de investigación en BCI es

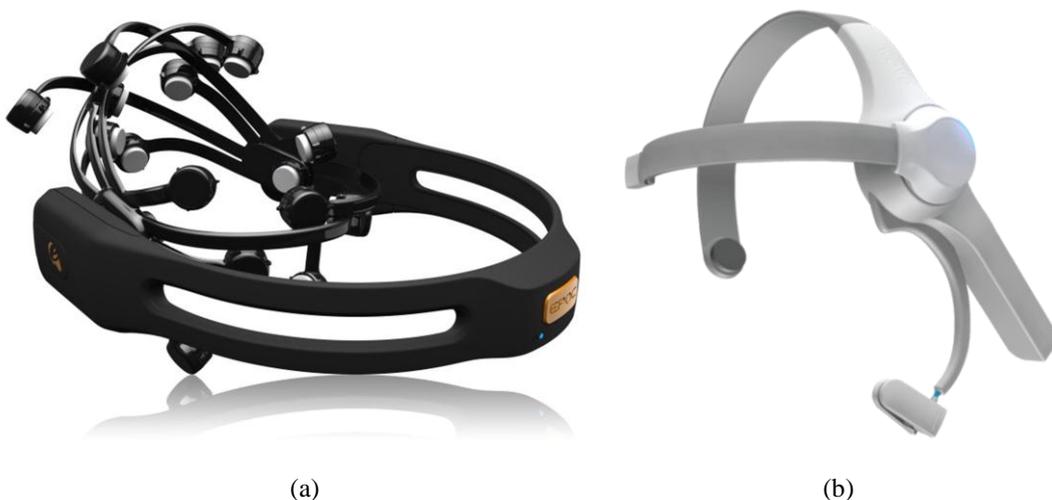


Figura 7 (a) Neuroheadset EPOC de Emotiv. (b) Mindwave de Neurosky.

CAPÍTULO 2: SISTEMAS BRAIN COMPUTER INTERFACE

relativamente joven, se han logrado muchos avances en poco más de dos décadas. La precisión de los sistemas BCI se ha mejorado significativamente y con ello se ha reducido el tiempo de entrenamiento necesario para controlarlos. Esto ha permitido desarrollar y difundir cada vez más las aplicaciones de los BCI tales como procesadores de texto, navegadores, correo electrónico, control de sillas de ruedas, control del entorno, y neuroprótesis entre otras.

A pesar de los importantes logros que se han hecho en el campo de los BCI, hay algunas cuestiones que todavía quedan sin resolver. La mayoría de los sistemas BCI todavía se encuentran en fase de investigación y no están listos para ser introducidos en los hogares para su uso continuo en su vida diaria. Aún se requiere un esfuerzo excesivo para configurar, calibrar y operar los sistemas BCI además de que es necesaria la supervisión de técnicos expertos. La mayoría de los BCI actuales están basados en la monitorización de la señal eléctrica mediante EEG. A pesar de que esta técnica de adquisición es la que está más extendida por su fácil uso, todavía resulta poco amigable porque requiere humedecer los electrodos y vigilar que la calidad de los contactos entre el cuello cabelludo y los electrodos sea buena. También el *software* con el que el BCI es controlado puede precisar de inicialización que tenga que ser realizada por un experto. Por otro lado, el uso de la tecnología BCI actual exige bastante concentración del usuario lo que puede causar rápidamente su fatiga.

A pesar de las dificultades encontradas, se ha comprobado que, en los últimos años, la comunidad científica ha impulsado su investigación y desarrollo enormemente por las beneficiosas aplicaciones que los sistemas BCI ofrecen a la sociedad. Esta disciplina ha llegado a involucrar en la actualidad a científicos de múltiples disciplinas, como por ejemplo, neurocientíficos, ingenieros, matemáticos, especialistas en rehabilitación clínica, entre otros. El principal objetivo de este creciente interés es superar las dificultades que presenta el diseño de un BCI amigable y preciso con el fin de hacer la vida más cómoda a personas afectadas por enfermedades neurológicas. No obstante, los alentadores resultados que se van obteniendo han permitido pensar que se puede extender los sistemas BCI a aplicaciones no solamente dirigidas a personas con graves discapacidades, sino también en todo tipo de personas. De esta manera, los sistemas BCI podrían significar en un futuro próximo una nueva forma de interacción hombre-máquina con una importancia similar a otras interfaces actuales.

Capítulo 3: Competición BCI

Para el desarrollo del TFM se va a emplear el conjunto de señales de encefalograma que se propuso para una competición que se llevó a cabo durante el año 2008 [6]. Desde el año 2001, se ha llevado a cabo cada dos años una serie de competiciones 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 hasta 4 ediciones de esta competición. 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, SCP, ritmos μ y β , señales medidas durante la realización de movimientos, etc. 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.

En este capítulo, se describe la Competición BCI 2008 dando una breve descripción de cada uno de los conjuntos de datos incluidos en la misma y los problemas que representan. Posteriormente, se detalla en profundidad el conjunto de datos 2b, que es el empleado para realizar el estudio de métodos de clasificación. Por último, se resume el método aplicado por el ganador de la Competición 2008 en el conjunto de datos 2b.

3.1 Competición BCI 2008

El objetivo de la "Competición BCI IV" es la evaluación de métodos de procesamiento y clasificación de señales. En comparación con los anteriores competiciones BCI, se abordan nuevos problemas que son de gran relevancia para el diseño de sistemas BCI, tales como

- La clasificación asíncrona de señales EEG (conjunto de datos 1)

CAPÍTULO 3: COMPETICIÓN BCI

- La clasificación de señales de EEG afectadas por artefactos procedentes del movimiento de los ojos (conjunto de datos 2)
- La clasificación de señales de MEG en cuatro movimientos de la muñeca (conjunto de datos 3)
- La discriminación de señales ECoG correspondientes al movimiento de un cierto dedo donde se requiere procesamiento espacial de grano fino (conjunto de datos 4)

A continuación se introduce una breve descripción de cada uno de los cuatro conjuntos de datos incluidos en la Competición BCI 2008.

El conjunto de datos 1 está proporcionado por el grupo BCI de Berlín y presenta el problema del diseño de un BCI asíncrono. La mayoría de los estudios de algoritmos aplicados al diseño de BCI basados en EEG evalúan la clasificación de un cierto número de pruebas de EEG que pertenecen a una determinada clase. Es decir, se tiene un conjunto de señales de longitud fija y se asume que cada una de ellas ha sido generada en un estado mental específico. Sin embargo, en aplicaciones BCI donde se requiera una respuesta asincrónica, se tiene con el problema de que el clasificador se debe aplicar de forma continua a la entrada de EEG sin conocer si el usuario ha cambiado o no de intención. En este conjunto de datos se plantea el reto clasificar de manera continua una señal EEG en el que no hay ninguna referencia que indique que el usuario puede haber cambiado de estado mental. Otra cuestión que se aborda en este conjunto de datos es conocer si los datos contienen periodos de tiempo en los que el usuario no está generando ninguna intención de control. Durante estos intervalos el clasificador debería retornar una clase neutra que no pertenecería a ningún comando de control.

El conjunto de datos 2 presenta el problema de clasificación síncrona con señales que han sido afectadas por artefactos procedentes del movimiento de los ojos. Este conjunto de datos está dividido en dos problemas. Por un lado, se proporciona un conjunto de datos que contiene señales que tienen que clasificarse en cuatro clases. Por otro lado, se facilita un conjunto de datos que se tiene que clasificar en dos clases. Este TFM está centrado en la clasificación de las señales que pertenecen a dos clases diferentes.

El conjunto de datos 3 contiene señales MEG adquiridas mientras los sujetos de prueba realizan movimientos de la muñeca en cuatro direcciones diferentes. La tarea que tenían que hacer los sujetos consistía en mover una palanca de mando desde una posición inicial de centro hacia uno de los cuatro objetivos situados radialmente a intervalos de 90°. Los objetivos se disponían en forma de rombo en un plano horizontal con esquinas apuntando hacia la izquierda, derecha, adelante y hacia atrás desde el cuerpo del sujeto. El sujeto debía mover la palanca utilizando exclusivamente la mano derecha y la muñeca ejerciendo movimientos de 4,5 cm. En cada una de las pruebas, el objetivo era elegido por el mismo sujeto.

El conjunto de datos 4 está dedicado al análisis de datos que proceden de la adquisición mediante ECoG de la actividad cerebral correspondiente al movimiento de los dedos. Para la generación de las señales, se pedía a los sujetos que movieran un dedo, mostrando en un monitor de ordenador la palabra correspondiente, por ejemplo, "pulgar". Durante se mostraba la indicación, los sujetos normalmente movían el dedo solicitado de 3 a 5 veces.

3.2 Paradigma del conjunto de datos 2b de la competición BCI 2008

Las señales que se emplean en este estudio pertenecen al conjunto de datos 2b de la Competición BCI 2008 [6] que fue proporcionado por el Instituto de Ingeniería Biomédica de la Universidad Tecnológica de Graz (Austria). Este conjunto de datos se compone de datos de EEG de 9 sujetos de un estudio publicado en [165]. Los sujetos eran diestros y tenían una visión normal. Para el registro de los datos todos los voluntarios se sentaron en un sillón, mirando a una pantalla colocada aproximadamente a 1 metro. El conjunto de datos proporciona 5 sesiones para cada sujeto, de las cuales las dos primeras sesiones contienen datos de entrenamiento sin realimentación, y las tres últimas sesiones fueron grabadas con la realimentación.

Cada sesión constó de varios tipos de grabaciones. Al comienzo de cada sesión, se llevó a cabo una grabación de 5 minutos aproximadamente para estimar la influencia EOG. Esta grabación está dividida en 3 bloques: (1) el sujeto permaneció dos minutos con los ojos abiertos (mirando una cruz en la pantalla), (2) un minuto con los ojos cerrados, y (3) un minuto realizando movimientos oculares. Después se incluye un bloque de artefactos dividido en cuatro secciones (15 segundos de artefactos con 5 segundos de descanso entre ellos). Durante la grabación de este bloque, se pidió a los sujetos a través de un texto en la pantalla que llevaran a cabo una de las siguientes tareas: parpadeo de los ojos, hacer círculos con la mirada, movimientos arriba-abajo o de izquierda-derecha.

En este conjunto de señales se proporcionan señales de EEG correspondientes a tres canales bipolares localizados en C3, Cz y C4. Las señales registradas fueron muestreadas a 250 Hz y filtradas con un filtro paso banda entre 0,5 Hz y 50 Hz. Además, para evitar el efecto de la señal de alimentación a 50 Hz se aplicó un filtro de ranura a 50 Hz. Como señal EEG de referencia se empleó un electrodo localizado en Fz. Las señales de EOG se registraron con tres electrodos monopolares situados en las sienes y el nasión. Estos canales de EOG se proporcionaron para el procesamiento de los artefactos en las señales EEG pero no se puede emplear para la clasificación.

El paradigma de detección consistía en la clasificación de la señal EEG en dos clases: la imaginación del movimiento de la mano izquierda (clase 1) y la mano derecha (clase 2). Durante las sesiones sin realimentación (Figura 8 (a)), el sujeto recibía una indicación del movimiento que tenía que imaginar pero no se recibía ningún tipo de indicación de cómo de bien lo estaba haciendo. Cada sujeto participaba en dos sesiones sin realimentación, las cuales contenían 120 pruebas. El número de movimientos de cada clase es el mismo, por tanto en cada sesión hay 60 movimientos de cada tipo. El protocolo seguido durante estas sesiones sin realimentación es el siguiente. Cada prueba se iniciaba mostrando con una cruz en la pantalla y un sonido de aviso de frecuencia 1 kHz y de duración 70 ms. Tres segundos más tarde se presentaba una señal visual (una flecha que apunta hacia la izquierda o la derecha, de acuerdo con la clase solicitada) durante 1,25 segundos. Después, los sujetos tenían que imaginar el movimiento de la mano correspondiente durante un período de 4 segundos. Finalmente, cada prueba se finalizaba con un breve descanso de al menos 1,5 segundos. Se incluía un tiempo aleatorio para evitar que el usuario se adaptara a este tiempo de descanso.

Durante las tres sesiones con realimentación en tiempo real (Figura 8 (b)) se mostraba en la pantalla una cara sonriente cuando el movimiento era imaginado en la dirección correcta o triste en otro caso. Al comienzo de cada prueba (segundo 0) se

CAPÍTULO 3: COMPETICIÓN BCI

mostraba una cara con una sonrisa neutral. En el segundo 2 se hacía sonar un pitido de aviso de frecuencia 1 kHz y duración 70 ms. La señal indicando qué tipo de movimiento se debía imaginar se presentaba desde el segundo 3 hasta el 7,5. Los sujetos, en función de la indicación, debían mover la cara con la sonrisa hacia la izquierda o la derecha por medio de la imaginación del movimiento de la mano izquierda o derecha. Durante el período de realimentación, la cara con la sonrisa cambiaba a color verde si era movida en la dirección correcta o a rojo en caso contrario. La distancia de la cara sonriente desde el origen se calculaba integrado la salida clasificación en los últimos dos segundos [165]. La salida de la clasificación también se empleaba para modificar la curvatura de la boca. Si el movimiento era correcto la curvatura se modificaba para mostrar una cara más sonriente y en caso contrario se mostraba una cara más triste. En el segundo 7,5 la pantalla se quedaba en blanco y se introducía un intervalo aleatorio entre 1,0 y 2,0 segundos para finalizar la prueba y comenzar la siguiente.

El criterio anunciado al comienzo de la competición para determinar el ganador de la competición es aquél que proporcione mayor valor de *kappa*. Los participantes deben proporcionar una salida de clasificación continua para cada muestra en forma de dos etiquetas para cada clase (1, 2). Todos los algoritmos deben ser causales, es decir, la salida proporcionada por el método instante de tiempo debe depender únicamente de muestras de las señales adquiridas en instantes de tiempo anteriores.

3.3 Descripción del método ganador

Para la clasificación de características se emplea un método conocido como *Filter Bank Common Spatial Pattern* (FBCSP). Este método consiste en la aplicación de *Common Spatial Pattern* (CSP), un método de extracción de características ampliamente usado para el diseño de BCI. La novedad que presenta el ganador de la

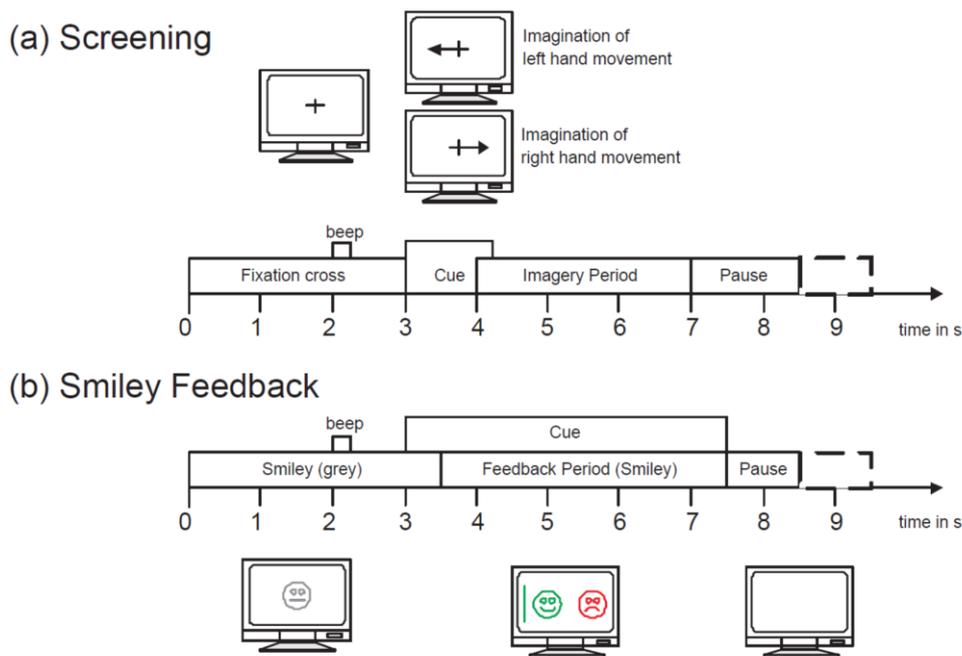


Figura 8. Esquema temporal de las pruebas. Pruebas con realimentación (a) y sin realimentación (b).

competición es que este método de extracción de característica se aplica de manera separada en varias bandas de frecuencia.

3.3.1 Algoritmo de extracción de características

Para la extracción de características se emplea en primer lugar un banco de filtros Chebychev Tipo II que descompone la señal EEG en 9 bandas de frecuencia. Las bandas de frecuencia usadas fueron 4 – 8 Hz, 8 – 12 Hz, ..., 36 – 40 Hz. Los ganadores de la competición aseguran que pueden emplearse otras configuraciones con la misma eficacia, pero que esta configuración asegura una respuesta estable de los filtros al mismo tiempo que cubre el rango de frecuencias 4 – 40 Hz, que es el que parece más interesante para el procesamiento de señales EEG.

Después de procesar la señal EEG con el banco de filtros, en una segunda fase, se emplea el algoritmo CSP para filtrar espacialmente. El algoritmo CSP ha sido empleado con gran éxito para el cálculo de filtros espaciales empleados para la detección de ERD y ERS.

CSP es un método de extracción de características que proyecta señales EEG que pueden proceder de varios canales en un subespacio donde se destacan las diferencias entre las clases y se minimizan las similitudes. El objetivo de CSP es que la posterior clasificación de las propiedades de la señal sea mucho más eficaz y para ello se diseña un filtro espacial que procesa los datos de entrada para que tengan una varianza óptima para su posterior clasificación [166]. CSP se ha empleado principalmente en el análisis de datos que proceden de múltiples fuentes o canales y que puede pertenecer a dos clases diferentes. No obstante, también es posible extender la aplicación de CSP a problemas que contienen múltiples clases [167].

CSP calcula la matriz de covarianza espacial C a partir de los datos de entrada E , que representan los datos sin procesar, por medio de

$$C = \frac{EE'}{\text{trace}(EE')} \quad (14)$$

donde E es una matriz $N \times T$, siendo T el número de canales, es decir, el número de electrodos, y N el número de muestras por canal. ' denota el operador de transposición, y $\text{trace}(X)$ representa la suma de los elementos de la diagonal de X .

Suponiendo que CSP se empleara para clasificar dos clases, por ejemplo, las neuroimágenes de mover la mano izquierda o derecha, entonces se calculan las covarianzas espaciales para cada una de las dos clases \bar{C}_l y \bar{C}_r promediando a lo largo del tiempo las covarianzas obtenidas de los datos obtenidos en sucesivas pruebas. Con las covarianzas espaciales se calcula la covarianza compuesta C_c como

$$C_c = \bar{C}_l + \bar{C}_r \quad (15)$$

Puesto que C_c es una matriz real y simétrica puede ser factorizada como $C_c = U_c \lambda_c U_c'$, donde U_c es la matriz de autovectores y λ_c la una matriz diagonal de autovalores.

Por medio de la transformación

$$P = \sqrt{\lambda_c^{-1}} U_c' \quad (16)$$

se ecualizan las varianzas en el espacio generado por U_c' de manera que todos los autovalores de $P\bar{C}_cP'$ son iguales a uno. Si \bar{C}_l y \bar{C}_r son transformados como

$$S_l = P\bar{C}_lP' \quad (17)$$

$$S_r = P\bar{C}_rP' \quad (18)$$

entonces S_l y S_r comparten los mismos autovectores. Es decir, si $S_l = B\lambda_l B'$, entonces $S_r = B\lambda_r B'$, y $\lambda_l + \lambda_r = I$, donde I es la matriz identidad. Como resultado de que la suma de los correspondientes autovalores de ambas matrices S_l y S_r sea siempre uno, los autovectores que tienen los mayores autovalores en S_l tendrán los menores autovalores en S_r . Esta propiedad resulta ser muy útil para la posterior clasificación ya que la varianza de la señal es maximizada para una clase mientras que es minimizada para la otra clase.

Finalmente, CSP calcula el vector de propiedades de la prueba E como

$$Z = WE \quad (19)$$

donde $W = (B'P)'$ es la matriz del filtro especial construido por CSP.

Después de aplicar el filtrado espacial, con la siguiente ecuación se calcula un vector V , que contiene dos medidas que son las que se emplearan como características en esa banda de frecuencias.

$$V = \frac{\log(ZZ')}{\text{traza}(ZZ')} \quad (20)$$

Hay dos propiedades por cada banda de frecuencia, por tanto, se extraen un total de 18 propiedades por cada muestra.

3.3.2 Método de selección de características

Hay principalmente dos métodos de selección de características en la literatura [168]: el método *wrapper* donde los elementos se seleccionan utilizando el clasificador, y el método *filter*, donde las propiedades se seleccionan independiente del clasificador. Aunque los método de selección *wrapper* pueden obtener un mejor rendimiento, suelen requerir mucho más esfuerzo computacional para ello.

El método ganador de la competición después de la etapa de extracción de características emplea *Mutual Information Rough Set Reduction* (MIRSR) [168], que es un método de selección basado en el cálculo de la información mutua de cada una de las características. MIRSR es un método de selección *wrapper* que emplea la información mutua para seleccionar las características más relevantes al mismo tiempo que elimina aquéllas que proporcionan mayor redundancia [169].

El ganador de la competición propuso el empleo otro método de selección para estas mismas características CSP conocido como *Mutual Information-based Best Individual*

Feature (MIBIF) [170]. MIBIF es un método *filter* de selección de características conceptualmente más simple que MIRS. En este TFM, se ha implementado MIBIF en lugar de MIRS.

3.3.3 Método de clasificación

El método ganador de la competición emplea como algoritmo de clasificación de las propiedades CSP seleccionadas el clasificador Naïve Bayesian Parzen Window (NBPW).

Supongamos que se tiene un conjunto de propiedades de entrenamiento $\mathbf{X} = [\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2, \dots, \bar{\mathbf{x}}_n]$ correspondiente a n pruebas donde $\bar{\mathbf{x}}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]$ denota el vector de d propiedades seleccionadas de la prueba i -ésima. $\mathbf{x} = [x_1, x_2, \dots, x_d]$ denota el vector de propiedades que se quiere clasificar. Para ello, NBPW estima la probabilidad *a posteriori* empleando la regla de Bayes

$$p(\omega|\mathbf{x}) = \frac{p(\mathbf{x}|\omega)P(\omega)}{\sum_{\omega=1}^2 p(\mathbf{x}|\omega)P(\omega)} \quad (21)$$

$p(\omega|\mathbf{x})$ es la probabilidad condicionada de la clase ω dado el vector de propiedades \mathbf{x} . $p(\mathbf{x}|\omega)$ es la probabilidad condicionada de \mathbf{x} dada la clase ω . $P(\omega)$ es la probabilidad de la clase ω .

Para calcular $p(\omega|\mathbf{x})$ es posible asumir de manera ‘ciega’ que todas las propiedades x_1, x_2, \dots, x_d son condicionalmente independiente dado la clase ω . Entonces $p(\omega|\mathbf{x})$ se puede calcular como

$$p(\mathbf{x}|\omega) = \prod_{j=1}^d p(x_j|\omega) \quad (22)$$

Para estimar las probabilidades condicionadas $p(x_j|\omega)$ el clasificador emplea el método de Parzen [171] dado por.

$$p(x_j|\omega) = \frac{1}{n_\omega} \sum_{i \in I_\omega} \varphi(x_j - \bar{x}_{i,j}, h) \quad (23)$$

n_ω es el número de muestras que pertenecen a la clase ω . I_ω es el conjunto de índices de los datos de entrenamiento que pertenecen a la clase ω . φ es una función núcleo de suavizado con parámetro de suavizado h . El clasificador NBPW emplea un núcleo gaussiano dado por

$$\varphi(y, h) = \frac{1}{\sqrt{2\pi}} e^{-\left(\frac{y^2}{2h^2}\right)} \quad (24)$$

El parámetro óptimo de suavizado viene dado por

$$\varphi(y, h) = \left(\frac{4}{3n}\right)^{\frac{1}{5}} \sigma \quad (25)$$

donde σ denota la desviación estándar de la distribución de y .

Finalmente, la salida del clasificador NBPW viene dada por

$$\omega = \arg \max_{\omega=1,2} p(\omega|\mathbf{x}) \quad (26)$$

3.3.4 Resultados obtenidos por el ganador

Los resultados del ganador de la competición se presentaron en términos del valor medio de $kappa$. Para el diseño del método, el ganador empleó validación cruzada 10x10 con los datos de entrenamiento etiquetados. Los resultados se muestran en la Tabla 1.

Sujeto	FBCSP MIRSR
1	0.627
2	0.208
3	0.244
4	0.988
5	0.765
6	0.650
7	0.729
8	0.761
9	0.764
Media	0.637

Tabla 1. Resultados de empleando validación cruzada 10x10. El método de selección de características empleado fue MIRSR

Los resultados del método usando los datos de evaluación de la competición se muestran en la Tabla 2. Después de la competición, los ganadores publicaron un estudio en el que emplearon dos métodos de selección de características: MIBIF y MIRSR [170]. En los resultados, se observa que se obtiene un mayor valor de $kappa$ con MIRSR. No obstante, los ganadores de la competición aseguran que haciendo un test-t no han encontrado diferencias estadísticas significativas entre los resultados obtenidos con cada uno.

Sujeto	FBCSP	
	MIBIF	MIRSR
1	0.356	0.400
2	0.171	0.207
3	0.169	0.219
4	0.963	0.950
5	0.850	0.856
6	0.594	0.613
7	0.556	0.550
8	0.856	0.850
9	0.750	0.744
Media	0.585	0.599

Tabla 2. Resultados obtenidos con los datos de validación. Los resultados se corresponden con dos métodos de selección distintos: MIBIF y MIRSR.

Capítulo 4: Estudio de métodos de clasificación

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, clasificadores lineales, y redes neuronales entre otros.

En este capítulo se presentan algunos detalles de los clasificadores empleados para intentar mejorar el método ganador de la Competición BCI de 2008. Los métodos de clasificación que incluye el estudio son el análisis discriminante lineal, máquina de soporte vectorial, el perceptrón multicapa y la red probabilística de Parzen. Por último, en este capítulo, se explica un procedimiento de post-procesado de las probabilidades *a posteriori* generadas por los métodos de clasificación.

4.1 Análisis discriminante lineal

Linear Discriminant Analysis (LDA) 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. LDA 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 [172]. LDA ofrece una precisión relativamente aceptable y se han utilizado con éxito en numerosos sistemas BCI como dispositivos de escritura basados en respuestas P300 [107], BCI multiclase [172] o BCI síncronos [173]. 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 [174].

Para un problema de dos clases, LDA 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

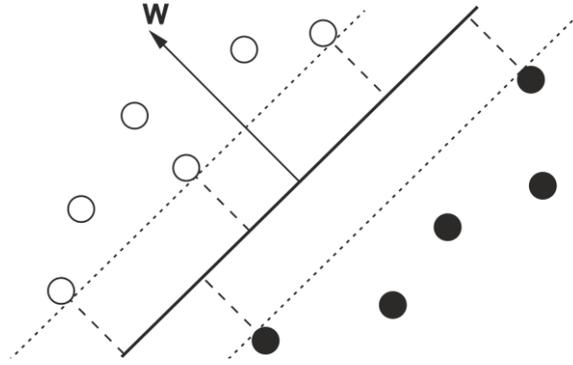


Figura 9. Clasificador lineal. La frontera de decisión es la línea continua. El margen del clasificador lineal es la mínima distancia de cualquier punto a la frontera de decisión. En este caso, el margen es la distancia entre las líneas punteadas y la línea continua.

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 (Figura 9). El plano de decisión se puede representar matemáticamente como

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 \quad (27)$$

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

Existen varios métodos para calcular w . Por ejemplo, se puede calcular w como [175]

$$\mathbf{w} = \Sigma_c^{-1}(\mu_2 - \mu_1) \quad (28)$$

donde μ_i es la media de clase i y $\Sigma_c = \frac{1}{2}(\Sigma_1 + \Sigma_2)$ 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 covarianza se hace según

$$\Sigma = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (29)$$

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (30)$$

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

Como mejoras del clasificador LDA se han propuesto algunos algoritmos como *Fisher LDA* (FLDA) y *Bayesian LDA* (BLDA) [176]. En el primero de ellos, se incrementa la precisión de LDA realizando una determinada proyección de los datos de entrada sobre un espacio de dimensión menor. El objetivo de esta proyección es lograr mayor separación entre los datos que pertenecen a distintas clases y al mismo tiempo reducir la variabilidad de los datos de la misma clase. FLDA mejora los resultados obtenidos con LDA pero no funciona muy bien cuando el número de propiedades es

demasiado grande en relación con el número de muestras de entrenamiento disponible. Este problema se conoce como el problema del pequeño tamaño de la muestra [176].

La segunda modificación se puede ver como una extensión del algoritmo FLDA. BLDA 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 BLDA clasifica con mayor precisión y más rápidamente que FLDA, especialmente en aquellos casos en los que el número de propiedades es grande [176]. Además, BLDA no consume mucho más tiempo de cálculo, que es un requisito esencial en sistemas BCI de tiempo real.

4.2 Máquina de soporte vectorial (SVM)

Las máquinas de soporte vectorial (SVM) es un clasificador que, de manera similar que LDA, construye un hiperplano o conjunto de hiperplanos, con el fin de separar los vectores de características en varias clases. Sin embargo, a diferencia de LDA, SVM selecciona los hiperplanos que maximizan los márgenes, es decir, la distancia de los vectores de propiedades a los hiperplanos [177]. 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 [178]. El teorema de Cover [179] 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 LDA, 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 [180-182] y multiclase [183, 184]. También se ha utilizado con éxito para el diseño de un gran número de BCI síncronos [182, 185].

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):

$$K(x, y) = \exp\left(\frac{-\|x - y\|^2}{2\sigma^2}\right) \quad (31)$$

El SVM con núcleo gaussiano se ha aplicado en el BCI para clasificar a los potenciales evocados P300 [186-188].

4.3 Red neuronal artificial: Perceptrón Multicapa

Las redes neuronales artificiales (ANN, del inglés *Artificial Neural Networks*) son un tipo de clasificador no lineal que ha sido utilizado en muchas aplicaciones de una amplia variedad de disciplinas tales como ciencias de la computación, física o neurociencia. La idea de las ANN está inspirada en cómo el cerebro procesa la información. El objetivo es imitar la actividad cerebral para resolver algunos problemas en los que la computación convencional no proporciona buenos resultados, pero que el cerebro de una persona es capaz de resolver sin ninguna dificultad. Por ejemplo, las ANN son ampliamente utilizadas en problemas que involucran reconocimiento de patrones ya que, como el cerebro, son capaces de aprender a reconocer patrones a partir de unos datos previos que sirven de entrenamiento. La capacidad de aprender a partir de ejemplos es una de las propiedades más importantes de las ANN. Después de que una ANN haya seguido un entrenamiento, ésta puede clasificar patrones para los cuales ha sido entrenado. Por esta razón, las ANN están relacionadas con el campo de los BCI ya que en este tipo de tecnología es necesario el reconocimiento de patrones para conocer las intenciones del usuario.

Una ANN es un conjunto de nodos y conexiones que son modificados durante el proceso de entrenamiento. Durante el entrenamiento, la ANN es alimentada con un conjunto de ejemplos de entrenamiento y se observa el resultado producido por la ANN. Si la salida no es correcta, entonces los pesos internos de la ANN se modifican de acuerdo a un determinado algoritmo de entrenamiento con el fin de reducir al mínimo la diferencia entre la salida deseada y la obtenida. El entrenamiento continúa hasta que la red alcanza un estado estacionario en el cual no se logra ninguna mejora significativa. En este estado, la ANN no sólo debería producir resultados correctos para todos los ejemplos del conjunto de entrenamiento, sino también para las entradas similares que no hayan sido observadas durante el entrenamiento.

Desde el punto de vista matemático, ANN define una aplicación de un espacio de entrada a un espacio de salida que puede ser descrito como una función vectorial $Y = f(X)$, donde X e Y pueden tener cualquier dimensión. Las ANN se componen de un conjunto de nodos o neuronas artificiales que procesan la información por medio de la función no lineal. Esta propiedad es especialmente importante sobre todo en aquellos casos en los que el mecanismo físico que genera la señal de entrada es no lineal.

Una de las estructuras más conocidas de ANN es el perceptrón multicapa (MLP, del inglés *multilayer perceptron*) presentado por Rumelhart y McClelland en 1986. El MLP se divide en varias capas que contienen varias neuronas artificiales, llamadas perceptrones. El número de neuronas en cada capa depende de la complejidad de la ANN. El MLP es un ejemplo de ANN donde las señales van siempre en dirección de la capa de entrada a la capa de salida. Esta restricción garantiza la estabilidad en el sistema. Este tipo de red neuronal casi siempre tiene tres capas activas, una capa de salida y dos capas ocultas tal como se muestra en la Figura 10. Nótese que la capa de entrada no contribuye en el algoritmo y solamente transmite su entrada a la capa siguiente. Gracias al teorema de Kolomogorov se sabe que una ANN de tres capas es suficiente para solucionar cualquier problema de clasificación, siempre y cuando el número de nodos de cada capa sea suficientemente alto.

Matemáticamente, la salida generada por un MLP se puede describir como una suma ponderada de varias entradas

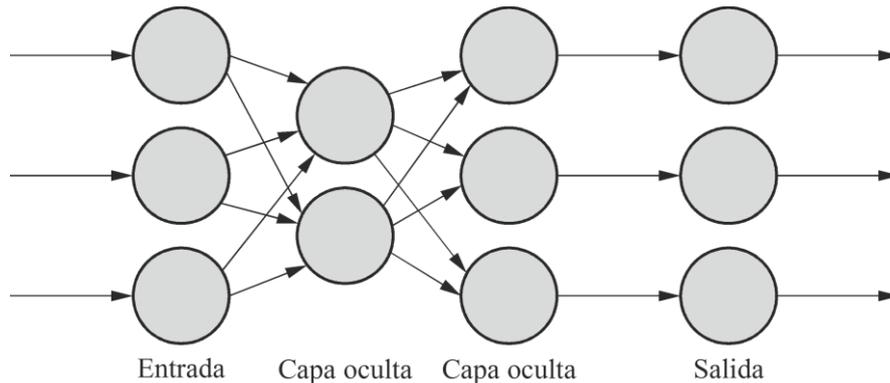


Figura 10. Estructura de un MLP con una capa de entada y tres capas activas.

$$y = f\left(\sum_{i=1}^N w_i x_i - w_0\right) \quad (32)$$

donde y es el término de salida, x_i es la i -ésima entrada de las N entradas y w_i su peso asociado. La función f es siempre una función monótona y, por lo general, es la función de Heaviside, $H(z)$, o la función sigmoidea logística $\varphi(z)$

$$H(z) = \begin{cases} 1 & z \geq 0 \\ 0 & z < 0 \end{cases}, \quad \varphi(z) = \frac{1}{1 + e^{-\beta z}} \quad (33)$$

Ambas funciones comparten la propiedad de que sus resultados tienden a cero para entradas negativas y a uno para entradas positivas. Esto significa que las funciones conmutarán de cero a uno cuando la suma ponderada de las entradas sea mayor que el término umbral w_0 .

El valor de cada peso w_i es modificado durante el proceso de aprendizaje. Durante este proceso de aprendizaje se introducen diferentes entradas a la ANN y se analiza la salida. Si la salida es incorrecta entonces se ajustan internamente los pesos para reducir el riesgo de cometer el mismo error otra vez. Con esta modificación se espera que la próxima vez la red neuronal responda correctamente a las mismas entradas o similares. Este tipo de entrenamiento se denomina aprendizaje supervisado ya que la red es guiada durante todo el proceso de entrenamiento proporcionando las respuestas correctas a todas las entradas. Todos los algoritmos de entrenamiento de este tipo se basan en el mismo principio. Cuando se detecta una salida incorrecta, los pesos de las entradas que han contribuido a producir esa salida se modifican hacia la solución correcta.

Las ANN han sido ampliamente utilizadas en el campo de los BCI ya que son clasificadores muy flexibles que puede clasificar cualquier número de clases y se adaptan a numerosos tipo de problemas. Las ANN han sido utilizadas para clasificar dos [189], tres [190] y hasta cinco [191] tareas diferentes y para BCI síncronos [192] y asíncronos [193]. También, además de como clasificadores, se han utilizado como herramienta de pre-procesamiento de señales EEG antes de la etapa de extracción de características con el fin de mejorar la separabilidad de las características de la señal EEG [194].

4.4 Red probabilística de Parzen

Las redes neuronales probabilísticas (PNN, del inglés *Probabilistic Neural Network*) son redes que implementan la regla de Bayes. Este tipo de redes consiste en varias sub-redes, una por cada clase, que calculan para cada patrón de entrada \mathbf{x} la función densidad de probabilidad del dato para una clase dada ω_i . Para ello, se aplica el procedimiento de ventana Parzen [195]. Normalmente, en el proceso de cálculo de la función de densidad se emplea un núcleo gaussiano tal como muestra la siguiente ecuación:

$$p(\mathbf{x}|\omega_i) = \frac{1}{N_i} \sum_{n=1}^{N_i} \frac{1}{(2\pi\sigma_p^2)^{\frac{d}{2}}} \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}^n\|^2}{2\sigma_p^2}\right) \quad (34)$$

Las funciones kernel gaussianas están centradas en cada uno de los patrones de entrenamiento \mathbf{x}^n correspondientes a cada clase y N_i es el número de patrones correspondientes a cada clase ω_i de entrenamiento empleados.

Para clasificar la red neuronal estima la probabilidad *a posteriori* $P(\omega_i|\mathbf{x})$ mediante el Teorema de Bayes [196]

$$P(\omega_i|\mathbf{x}) = \frac{P(\omega_i)P(\mathbf{x}|\omega_i)}{\sum_{i=0}^N P(\mathbf{x}|\omega_i)P(\omega_i)} \quad (35)$$

Las probabilidades *a priori* $P(\omega_i)$ pueden ser obtenidas mediante la proporción

$$P(\omega_i) = \frac{N_i}{N} \quad (36)$$

donde N_i es el número de muestras de entrenamiento de clase ω_i y N es el número de muestras total. Las redes neuronales probabilísticas han sido empleadas de manera exitosa en la clasificación de ritmos sensiomotores para el control de una mano en un entorno virtual [197] y de SCPs [198].

4.5 Combinación temporal de la salida del clasificador

Para dar una clasificación de la señal para cada instante de tiempo, se incorpora el conocimiento de los instantes de tiempo anteriores [199]. Esta combinación temporal se realiza tomando la media de las probabilidades *a posteriori* de cada clase ponderada por la potencia discriminativa en cada instante de tiempo ω_t :

$$p(y|\mathbf{a}(0), \dots, \mathbf{a}(t_0)) = \frac{\sum_{t \leq t_0} \omega_t p(y|\mathbf{a}(t))}{\sum_{t \leq t_0} \omega_t} \quad (37)$$

$p(y|\mathbf{a}(0), \dots, \mathbf{a}(t_0))$ representa la probabilidad de que la prueba pertenezca a una clase hasta el tiempo t_0 . Las potencias discriminativas en cada instante de tiempo ω_t se obtienen a partir del error de las dos distribuciones en el instante t . Como este error no

puede calcularse directamente se hace una aproximación mediante el límite de Chernoff y se obtiene ω_t de esta manera

$$2\omega_t = 1 - \min_{0 \leq \gamma_t \leq 1} \int p(\mathbf{a}(t)|L)^{\gamma_t} p(\mathbf{a}(t)|R)^{1-\gamma_t} d\mathbf{a} \quad (38)$$

Para el caso de distribuciones gaussianas la integral puede expresarse como

$$\int p(\mathbf{a}(t)|L)^{\gamma_t} p(\mathbf{a}(t)|R)^{1-\gamma_t} d\mathbf{a} = e^{-k(\gamma_t)} \quad (39)$$

donde $k(\gamma_t)$ se calcula como

$$k(\gamma_t) = \frac{\gamma_t - (1 - \gamma_t)}{2} (\boldsymbol{\mu}_t^R - \boldsymbol{\mu}_t^L)^T [\gamma_t \boldsymbol{\Sigma}_t^L + (1 - \gamma_t) \boldsymbol{\Sigma}_t^R]^{-1} (\boldsymbol{\mu}_t^R - \boldsymbol{\mu}_t^L) + \frac{1}{2} L n \left(\frac{\gamma_t \boldsymbol{\Sigma}_t^L + (1 - \gamma_t) \boldsymbol{\Sigma}_t^R}{|\boldsymbol{\Sigma}_t^L|^{\gamma_t} |\boldsymbol{\Sigma}_t^R|^{1-\gamma_t}} \right) \quad (40)$$

La salida finalmente se calcula comparando la probabilidad $p(y|\mathbf{a}(0), \dots, \mathbf{a}(t_0))$ con 0.5 para clasificar las pruebas en la clase 1 o en la clase 2.

Capítulo 5: Resultados y discusión

En este capítulo se incluyen los resultados obtenidos después de aplicar los diferentes métodos explicados en el Capítulo 4. Se comparan estos resultados con los obtenidos por el ganador de la Competición de 2008. El método de evaluación que se va a emplear para cada una de las alternativas es el valor *Kappa* de Cohen. Se incluye también una discusión donde se dan algunas razones de las diferencias. También, se discute el efecto que tiene en el rendimiento, la aplicación o no de un post-procesado de las probabilidades *a posteriori* generadas por los métodos de clasificación. Por último, se describen brevemente las diferentes mejoras que otros autores ya han propuesto para incrementar el rendimiento de clasificación conseguido con el conjunto de datos 2b de la Competición de 2008

5.1 Método de evaluación: *Kappa* de Cohen

La comparación de diferentes BCI requiere establecer una métrica común. La métrica más común para medir el rendimiento de un BCI es el error de clasificación o la precisión [200]. No obstante, hay otras métricas que también han sido propuestas para la evaluación de BCI como el coeficiente *Kappa* de Cohen [201], la información mutua o la transferencia de información [202], el error cuadrático medio [203], el área bajo la curva ROC [204] o la matriz de confusión [205]. En este TFM el método de evaluación que se emplea es el mismo que el propuesto para el dataset 2b de la Competición IV, es decir, el coeficiente *Kappa* de Cohen [6].

La precisión de clasificación es una medida de rendimiento que es muy fácil de calcular y de interpretar. Se trata de sumar el número de pruebas que son clasificadas correctamente y dividir por el número de pruebas total. Esto presenta el inconveniente que no se tiene en cuenta que las clases pueden tener distinta probabilidad ni los falsos positivos o negativos. El coeficiente *Kappa* de Cohen evita estos inconvenientes combinando dos medidas.

El coeficiente *Kappa* se calcula a partir de los elementos de la matriz de confusión. La matriz de confusión contiene el número de pruebas que han sido clasificadas correctamente en cada clase así como los falsos positivos y negativos. En la Tabla 3 se muestra un ejemplo de una matriz de confusión para un problema de dos clases. En la diagonal de la matriz de confusión se encuentran contabilizados los casos en los que la clasificación ha sido correcta. Es decir, aquellos casos en los que se detectó

CAPÍTULO 5: RESULTADOS Y DISCUSIÓN

correctamente que la prueba era de la clase 1 y en los que se detectó correctamente que no era de la clase 1 y, por tanto, era de la clase 2. Fuera de la diagonal, se encuentran contabilizados los falsos positivos y los falsos negativos. Los primeros se corresponde con el total de casos en los que una señal fue clasificada como de clase 1 cuando en realidad era de clases 2 y en los segundo se contabilizan los casos en los que sucede lo contrario.

Clases	1	2
1	Aciertos	Falsos negativos
2	Falsos positivos	Rechazos correctos

Tabla 3. Matriz de confusión para dos clases

Teniendo en cuenta los elementos de la matriz de confusión, el coeficiente Kappa se define como

$$p_0 = \frac{\sum_{i=1}^M n_{ii}}{N}, p_e = \frac{\sum_{j=1, i=1, j \neq i}^M n_{ij} n_{ji}}{N^2}, \kappa = \frac{p_0 - p_e}{1 - p_e} \quad (41)$$

n_{ij} es cada uno de los elementos de la matriz de confusión, N es el número total de pruebas y M el número de clases, que es igual al número de filas o columnas de la matriz de confusión.

El coeficiente Kappa evita los problemas de la medida de precisión ya que tiene en cuenta la distribución de las pruebas que han sido mal clasificadas, es decir, los elementos que no pertenecen a la diagonal de la matriz de confusión.

5.2 Resultados obtenidos y discusión

5.2.1 Clasificación de las pruebas

A continuación se presentan los resultados obtenidos por cada método de clasificación y se presenta una comparación con el método de clasificación aplicado por el ganador de la competición. Como ya se ha indicado anteriormente los métodos de clasificación fueron: análisis discriminante lineal, máquina de soporte vectorial, red neuronal artificial y red probabilística de Parzen. Además se ha reproducido el mismo método propuesto por el ganador de la competición.

En primer lugar se presentarán los resultados obtenidos de las pruebas de validación 5x5. En los que las pruebas de las sesiones de entrenamiento se dividen aleatoriamente en cinco parte quedando 4 para entrenamiento y 1 para validación. Este proceso se repite 5 veces con la misma partición. Finalmente, se calcula el valor medio y la desviación típica de los resultados obtenidos en las 5 repeticiones. En segundo lugar, se listan los resultados obtenidos con los datos de test de la competición.

5.2.1.1 Resultados de validación cruzada

Algunos de los métodos de clasificación empleados en este estudio necesitan el ajuste de algunos parámetros. El ajuste de estos parámetros se ha realizado mediante validación cruzada 5x5 empleado las sesiones etiquetadas de la competición. Se evaluó el rendimiento medio de todos los sujetos con el valor de *kappa* promediado para todos

los sujetos. Para mejorar los resultados, no se emplearon todas las sesiones con las pruebas etiquetadas de la competición sino que se hizo una selección de las mismas del mismo modo que hicieron los ganadores de la competición [170]. Para el clasificador basado en el perceptrón multicapa, se varió el número de neuronas de la capa oculta y en las máquinas de soporte vectorial se varió la anchura del núcleo gaussiano empleado para la transformación de los datos a un dominio lineal. En la Figura 11 se pueden ver los valores de kappa obtenidos para cada uno de los valores de los parámetros.

Los resultados de la validación cruzada mostrados en la Figura 11 indican que un aumento de la complejidad de la red neuronal no conlleva un mejor resultado de clasificación. Esto puede ser debido a que pueda producirse un sobre entrenamiento en la red neuronal que reduzca el rendimiento del clasificador en la fase de validación. También cabe destacar que una red neuronal con pocas neuronas en la capa oculta (10 neuronas) consigue un valor de kappa muy cercano al máximo, que se consigue con 25 neuronas en la capa oculta. Esto puede dar a pensar que la frontera de separación presenta poca complejidad y puede ser en realidad representada con un número bajo de neuronas en la capa oculta.

En la Tabla 4 se listan los valores de kappa obtenidos para cada sujeto en función del tipo de clasificador aplicado. Los resultados se corresponden con el valor medio y la varianza de los resultados obtenidos en las pruebas de validación cruzada 5x5.

Los rendimientos ofrecidos por cada uno de los clasificadores estudiados son muy similares entre sí. Cabe destacar que todos los clasificadores superan al método propuesto por el ganador de la competición si se tienen en cuenta solamente los resultados después de replicar el método del ganador. No obstante, las mejoras no son muy grandes ya que, SVM, que es el que proporciona mejor rendimiento, sólo supera al NaiveBayes en 0.05.

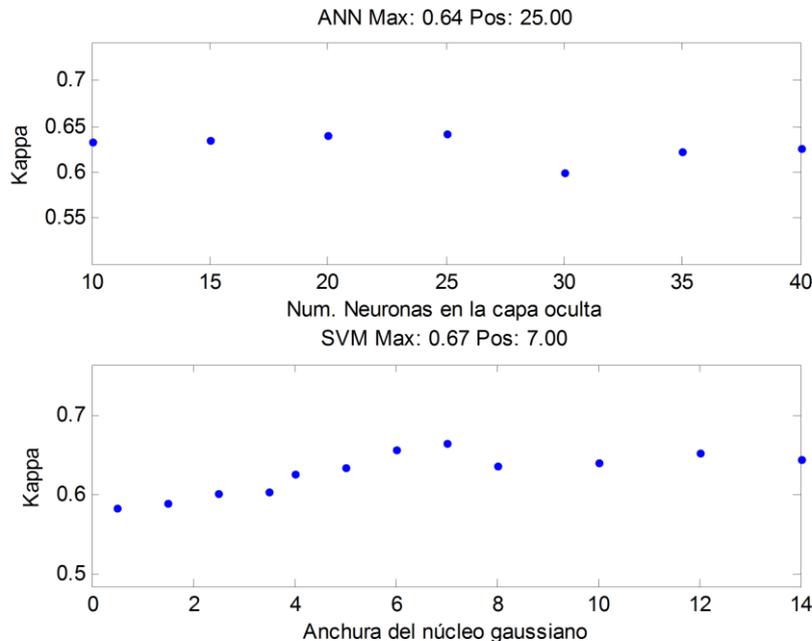


Figura 11. Valores de Kappa obtenidos variando el número de neuronas de la capa oculta del MLP (arriba) y la anchura del kernel gaussiano de la máquina de soporte vectorial (abajo).

CAPÍTULO 5: RESULTADOS Y DISCUSIÓN

El método LDA ofrece un rendimiento muy similar al resto de los métodos. Esto indica que la frontera de decisión óptima para clasificar las propiedades CSP puede aproximarse bastante bien mediante un clasificador lineal. Esto puede ser la razón de por qué no se experimenta un crecimiento en rendimiento ofrecido por el perceptrón multicapa a medida que se aumenta el número de neuronas de la capa oculta.

Sujetos	LDA	SVM	ANN	Parzen	NaiveBayes (Método del ganador)
1	0.55±0.01	0.55±0.04	0.63±0.03	0.57±0.02	0.56±0.01
2	0.18±0.02	0.23±0.04	0.13±0.05	0.16±0.03	0.10±0.02
3	0.34±0.07	0.28±0.01	0.23±0.01	0.22±0.01	0.12±0.03
4	0.97±0.01	0.99±0.01	0.97±0.01	0.97±0.01	0.99±0.01
5	0.89±0.01	0.89±0.01	0.85±0.01	0.87±0.01	0.90±0.01
6	0.72±0.03	0.74±0.02	0.76±0.01	0.65±0.02	0.68±0.03
7	0.78±0.03	0.78±0.02	0.74±0.02	0.75±0.01	0.78±0.01
8	0.63±0.02	0.73±0.01	0.71±0.05	0.69±0.07	0.64±0.03
9	0.78±0.01	0.81±0.02	0.79±0.01	0.79±0.01	0.81±0.01
Media	0.65±0.01	0.67±0.01	0.65±0.01	0.63±0.01	0.62±0.01
t	6.50	6.28	5.68	6.50	5.76

Tabla 4. Valor medio de Kappa y desviación típica obtenidas en la validación cruzada para cada sujeto en función del método de clasificación aplicado con las sesiones de entrenamiento

5.2.1.2 Resultados con los datos de test

Una vez realizada las pruebas de validación cruzada se aplicó los diferentes métodos de clasificación a los datos de test. En la Tabla 5 se presentan los valores máximos de Kappa que se han obtenido para cada sujeto en función de método aplicado y el instante en el que ocurre. En la Tabla 6 se muestran el rendimiento ofrecido por cada clasificador en el instante de tiempo seleccionado en las pruebas de validación cruzada. Se observa que los métodos aplicados no suponen una gran mejora con respecto a la implementación que replica el método ganador de la competición.

Sujetos	LDA		SVM		ANN		Parzen		NaiveBayes (Método del Ganador)	
	Kappa (máx.)	t (s)	Kappa (máx.)	t (s)						
1	0.27	5.44	0.29	5.04	0.28	5.32	0.25	3.56	0.28	2.52
2	0.22	4.60	0.19	6.24	0.12	5.16	0.22	4.64	0.16	4.76
3	0.09	0.60	0.10	0.80	0.10	1.00	0.12	5.64	0.11	0.72
4	0.92	4.12	0.92	4.08	0.93	4.92	0.93	4.36	0.92	4.12
5	0.84	5.48	0.80	5.12	0.77	4.96	0.85	6.36	0.79	5.56
6	0.62	5.96	0.62	6.08	0.58	6.16	0.70	6.16	0.64	5.36
7	0.58	4.32	0.55	4.80	0.57	5.44	0.54	4.44	0.51	6.28
8	0.79	5.40	0.86	6.28	0.88	4.84	0.80	6.12	0.85	5.20
9	0.71	5.36	0.73	5.00	0.72	4.40	0.70	5.72	0.71	6.32
MEDIA	0.54	5.40	0.54	6.32	0.52	6.28	0.55	6.44	0.53	5.40

Tabla 5. Kappa máximo obtenido para cada sujeto en función del método de clasificación aplicado con las sesiones de test.

Sujetos	LDA	SVM	ANN	Parzen	NaiveBayes (Método del ganador)
1	0.27	0.27	0.25	0.22	0.28
2	0.19	0.19	0.07	0.12	0.10
3	0.05	0.03	0.00	0.08	-0.01
4	0.87	0.86	0.90	0.90	0.90
5	0.79	0.75	0.75	0.85	0.77
6	0.62	0.62	0.57	0.70	0.63
7	0.53	0.54	0.55	0.53	0.46
8	0.78	0.86	0.86	0.79	0.83
9	0.67	0.70	0.67	0.69	0.67
MEDIA	0.53	0.54	0.51	0.54	0.52

Tabla 6. Kappa para cada sujeto en función del método de clasificación.

Los resultados obtenidos a partir de la clasificación de los datos de test muestran que el rendimiento de los métodos propuestos es prácticamente el mismo que el que proporciona el método del ganador de la competición. Los métodos que emplean una máquina de soporte vectorial o una red probabilística de Parzen ofrecen un rendimiento ligeramente superior.

La mejora en el rendimiento del método de clasificación depende de cada sujeto. En el sujeto 1 no se consiguió mejorar el método del ganador y en el sujeto 4 se consiguió igualar. En el resto, los métodos de clasificación propuestos superan al método del ganador. No obstante, el método de clasificación que lo hace depende del sujeto. En los sujetos 2 y 3 el método de clasificación mejor es el LDA, en los sujetos 4, 5 y 6 el la red probabilística de Parzen, en el sujeto 7 el perceptrón multicapa y en los sujetos 8 y 9 la máquina de soporte vectorial.

Hay claramente tres sujetos, los sujetos 1, 2 y 3 que evidencian mucha más dificultad que el resto para generar señales fácilmente de clasificar. Esto es claramente patente en los sujetos 2 y 3 en los que el rendimiento es prácticamente igual al rendimiento que ofrecería una clasificación aleatoria.

Si se comparan los resultados de test con los obtenidos mediante validación cruzada se constata que hay una pérdida significativa de rendimiento de alrededor del 1.3. Esto puede ser debido a que un sobreentrenamiento de los métodos de clasificación a las pruebas de entrenamiento o que las características extraídas de las pruebas de entrenamiento no reflejan de manera significativa el problema. Es conocido que el problema de clasificación de señales cerebrales presenta la dificultad de que tienen una gran variabilidad. Por este motivo, resulta especialmente difícil encontrar unas características de entrenamiento que representen el problema y no se obtenga una pérdida de rendimiento en la clasificación de las pruebas de test.

En la Tabla 7 se muestran los resultados indicados por el ganador de la competición [170]. El rendimiento obtenido de la reproducción del método propuesto, aunque se aproxima, es diferente. El autor de este TFM no encuentra explicación a este hecho salvo por motivos de pequeñas diferencias en la implementación. Estas diferencias se pueden deber a que no son públicos todos los detalles de la implementación del método ganador y ha sido necesario hacer algunas suposiciones para reproducir el método ganador.

Sujetos	NaiveBayes (Resultados dados por el ganador)
1	0.36
2	0.17
3	0.17
4	0.96
5	0.85
6	0.59
7	0.56
8	0.86
9	0.75
MEDIA	0.59

Tabla 7. Resultados obtenidos por el ganador con las sesiones de test [170].

5.2.2 Efectos del post-procesado de las probabilidades *a posteriori*

Los métodos de clasificación aplicados, en lugar de proporcionar únicamente la clase a la que pertenecen cada una de las señales, se configuraron de manera que proporcionaran las probabilidades *a posteriori*, es decir, la probabilidad de la pertenencia de una prueba a una determinada clase. Se espera que mediante la acumulación de evidencia a lo largo del tiempo se obtenga un mejor rendimiento en la clasificación. En esta sección se presentan únicamente los resultados que se obtuvieron empleando una red probabilística de Parzen, que es el método de clasificación de todos los analizados que mejor rendimiento proporciona. Las conclusiones que se pueden obtener aplicando el resto de los métodos de clasificación son las mismas.

Los resultados de aplicar o no un post-procesado de las probabilidades *a posteriori* se encuentran recogidos en la Tabla 8. Se observa que solamente en los sujetos 4, 5 y 8 el rendimiento es superior en el caso de hacer combinación temporal. Este resultado puede ser considerado extraño ya que si se hace un post-procesado de las probabilidades *a posteriori* es de esperar que al menos el rendimiento sea por lo menos igual que en el caso de no emplear el post-procesado. Una explicación intuitiva de este fenómeno se puede entender sabiendo que la combinación de temporal es en realidad un filtrado de la probabilidad *a posteriori* proporcionada en un instante de tiempo teniendo en cuenta la probabilidad *a posteriori* de instantes anteriores. Por esta razón, va a tener lugar un 'suavizado' en la medida de kappa ya que existe una cierta resistencia a cambiar la clase asignada a una determinada prueba. Esto hace que se eliminen algunos máximos puntuales del rendimiento. En la Figura 12 se puede observar que kappa es mayor variabilidad a lo largo del tiempo en el caso de no emplear combinación temporal.

Sujeto	Método de Parzen			
	Comb. Temp		Sin Comb. Temp	
	Kappa (máx.)	t	Kappa (máx.)	t
1	0.25	3.56	0.33	5.00
2	0.22	4.64	0.27	4.24
3	0.11	5.64	0.19	3.80
4	0.93	4.36	0.93	3.72
5	0.85	6.36	0.78	4.52
6	0.69	6.16	0.61	3.84
7	0.54	4.44	0.59	3.80
8	0.80	6.12	0.77	3.40
9	0.69	5.72	0.71	4.28
MEDIA	0.55	6.44	0.53	3.84

Tabla 8. Kappa máximo obtenido con el mejor método de clasificación, red probabilística de Parzen, empleando con combinación temporal y sin combinación temporal. También se listan para cada sujeto el instante de tiempo en los que se alcanza este máximo.

Por otro lado, en la Figura 12 se puede ver que gracias al post-procesado se consigue que el rendimiento no decaiga tan drásticamente si la información que se va proporcionando a lo largo de la prueba conduce a una mala clasificación. Los resultados de la Tabla 8 podían llevar a pensar que en realidad el rendimiento haciendo el post-procesado de las probabilidades *a posteriori* puede conducir a una pérdida de rendimiento. Sin embargo, esto no es cierto. Gracias a que el rendimiento se mantiene aproximadamente constante al final de la prueba, el valor medio de kappa para los 9 sujetos es superior que en el caso de no hacer el post-procesado. En la Figura 13 se puede comprobar que efectivamente el post-procesado mejora el rendimiento del método de clasificación.

Con los resultados de los nueve sujetos, si se aplica el post-procesado, el máximo de kappa se incrementa de 0.53 a 0.55. La aplicación del post-procesado no produce una gran mejora en el rendimiento. Sin embargo, el post-procesado hace mucho más robusto el método de clasificación ya que su rendimiento no depende tanto del instante en el que se decide la clase a la que pertenece una determinada clase.

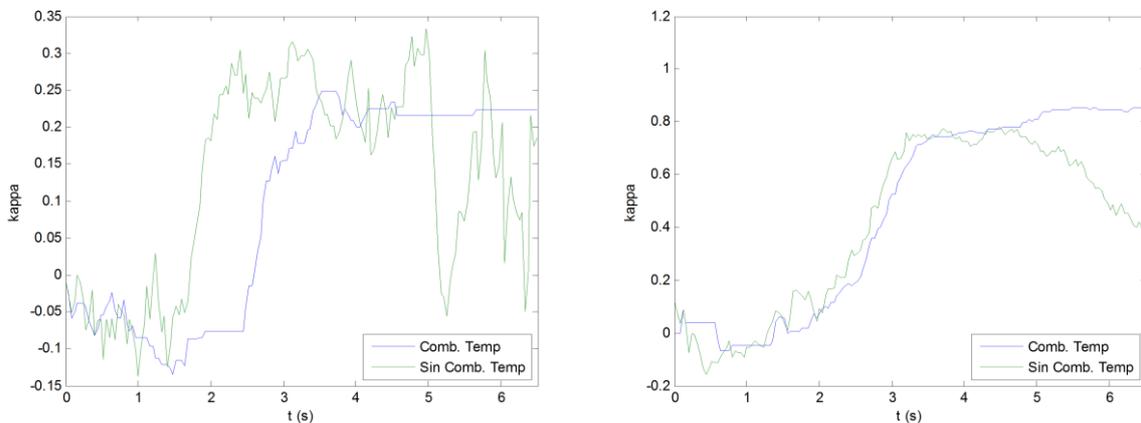


Figura 12. Medida del rendimiento *kappa* para los sujetos 1 y 5 clasificando con combinación temporal (azul) y sin combinación temporal (verde).

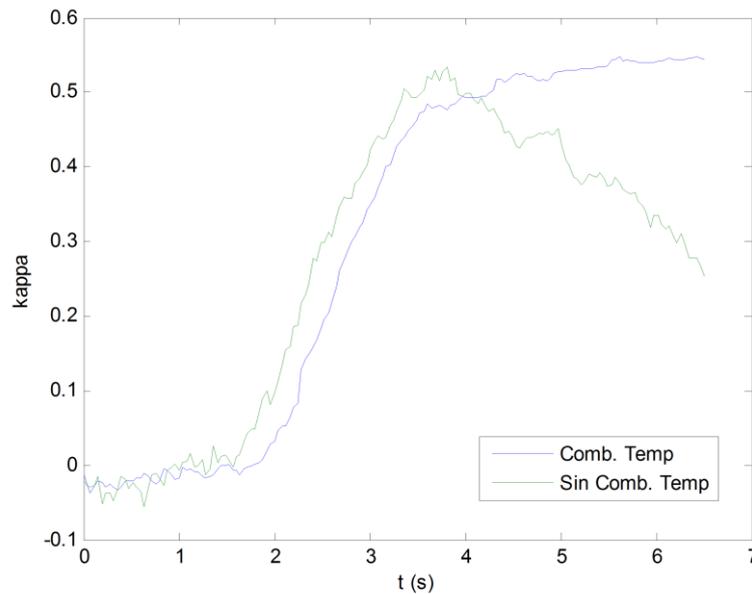


Figura 13. Kappa medio de los 9 sujetos con el post-procesado y sin el post-procesado de las probabilidades a posteriori dadas por el clasificador.

5.3 Últimos avances en el conjunto de datos 2b

Varios autores han propuesto algunos métodos que mejoran ligeramente los resultados del ganador de la competición. En esta sección, sin pretender ser exhaustiva, se incluyen la descripción de algunos de estos métodos.

Los propios ganadores introdujeron varias pequeñas modificaciones en el método ganador. Como se ha explicado en el Capítulo 3, FBCSP calcula varios filtros espaciales, uno por cada banda del banco de filtros, a partir de múltiples estimaciones de la matriz de covarianza de las señales filtradas paso banda. Con esto se pretende evitar la dependencia del filtrado espacial con la frecuencia pero tiene el inconveniente de que se incrementa la sensibilidad a los artefactos y ruido de la señal EEG en comparación de si se emplea un único filtro espacial para todas las bandas [206]. Aunque la señal de EEG sea afectada muy poco artefactos, la estimación de la matriz de covarianza normalmente difiere de manera sustancial de la que sería estimada en el caso de no tener artefactos.

Los ganadores de la competición propusieron un nuevo método para superar el efecto de la presencia de ruido en la señal EEG en la estimación de la covarianza espacial [206]. Este método calcula un único filtro espacial para todas las bandas de frecuencias del banco de filtros a partir de una matriz de covarianza espacial que es la suma ponderada de las matrices de covarianza de cada una de las bandas. Además, en esta ponderación, para calcular los pesos se tiene en cuenta la información mutua de las propiedades. Los resultados obtenidos al probar el método con el conjunto de datos 2b de la competición muestran que el valor medio de $kappa$ para los nueve sujetos se incrementa de 0.585 a 0.596 mejorando el rendimiento en los sujetos 1, 2, 3, 4, 7 y 8. Por otro lado estos mismos autores en otro estudio, para superar este mismo problema,

propusieron también emplear métodos estadísticos más robustos al efecto de los artefactos y ruido para calcular la matriz espacial basado en hacer mínima la varianza del estimador [207].

Centrados también en el problema del ruido en los métodos de extracción de características basados en CSP, otros autores han investigado la aplicación de múltiples métodos que amplían CSP. Samek et al. [208] lleva a cabo un estudio donde se empleaban un conjunto de variantes de CSP que regularizan la solución hacia espacios estacionarios. Es decir, se extiende el método CSP para que sea invariante a las no estacionariedades inherentes de las señales EEG. Estos métodos aplican técnicas como añadir términos de penalización que eviten el sobreajuste a datos ruidosos o técnicas de preprocesado que extraen la parte estacionaria de la señal de EEG antes de que sea aplicado el método CSP. El valor empleado para evaluar cada uno de los métodos de extracción de características es distinto al de la competición. Por este motivo, no se puede comparar directamente con el método propuesto por el ganador de la competición. No obstante, cabe destacar que los autores proponen un método conocido como *Stationary CSP* que por termino medio para todos los sujetos ofrece el mejor rendimiento de todos los probados. *Stationary CSP* pretende encontrar un filtro espacial que maximiza la discriminación y al mismo tiempo la estacionariedad del mismo. La idea principal de este método es extraer los filtros espaciales que maximizan y minimizan la varianza de la señal EEG en dos direcciones pero al mismo tiempo, mantiene la estimación de la varianza de la señal EEG en la dirección proyectada lo más estable posible entre cada una de las pruebas realizadas por el sujeto.

El método ganador de la competición aplica un banco de filtros para obtener las propiedades de la señal de EEG. Se filtra espacialmente aplicando CSP nueve señales procedentes de un banco de filtros constituido por nueve filtros pasobanda Chebyshev tipo II. Posteriormente, se realiza un proceso de selección de características antes de la clasificación de las señales. Thomas et al. [209] proponen un nuevo método de extracción de características que es una modificación del FBCSP. Esta modificación supone que, en lugar de utilizar un banco de filtros fijo para todos los sujetos, se utiliza un banco de filtros específico para cada sujeto para mejorar la precisión de clasificación. Para diseñar el banco de filtros determinando las bandas de frecuencia más discriminativas para cada uno de los sujetos, se emplea el coeficiente de Fisher de la densidad potencia espectral de los canales C3 ó C4, que proporciona una medida de las diferencias entre dos clases de tareas de imaginación motora. Los resultados con el conjunto de datos 2b muestran que hay una reducción del error medio de clasificación del 8.90 %. Concretamente, se reduce el error cometido en la clasificación en todos los sujetos excepto en el sujeto número 4 y 5.

Gandhi et al. [210] han propuesto el empleo de un método de preprocesado que emplea una red neuronal cuya arquitectura está basada en la ecuación de ondas de Schrödinger. Se emplea una red neuronal cuántica para filtrar el ruido no gaussiano presente en la señal EEG. De esta señal de EEG preprocesada se extraen entonces un conjunto de características Hjorth, que se emplean para entrenar a un clasificador basado en LDA. Este método se ha probado con el conjunto de datos 2b de la competición y los resultados muestran que la precisión de la salida del clasificador sobre los conjuntos de datos de entrenamiento y evaluación es mucho mayor en comparación con el que el uso de la señal del EEG sin procesar. Los valores de *kappa* que se alcanzan aplicando y sin aplicar este método de preprocesamiento son respectivamente 0.63 y 0.54. Los resultados indican que la mejora entre la clasificación con o sin preprocesado es estadísticamente significativa.

Capítulo 6: Conclusiones y líneas futuras

6.1 Conclusiones

En este trabajo fin de máster se ha realizado en primer lugar un estudio de las investigaciones más importantes en el campo de los BCI. Este estudio ha permitido conocer el funcionamiento de los BCI así como las técnicas empleadas para su diseño. En las últimas dos décadas se han logrado avances muy importantes que han permitido desarrollar BCI que detectan las intenciones del usuario con una precisión bastante aceptable. Se han detallado las diferentes técnicas de adquisición de actividad cerebral aplicadas en BCI: (i) EEG, que proporciona señales de calidad aceptable al mismo tiempo que ofrece alta portabilidad y por ello es con mucho la modalidad más habitual en el diseño de BCI, (ii) fMRI y MEG, que son métodos especialmente eficaces para la localización de las regiones activas del interior del cerebro, (iii) NIRS, que es un método muy prometedor en BCI, y (iv) las modalidades invasivas, que se han presentado como métodos que pueden proporcionar señales de muy alta calidad, que son hasta ahora imprescindibles en algunas aplicaciones de control multidimensionales como, por ejemplo, el control de neuroprótesis .

Se han revisado una amplia variedad de características de la señal y algoritmos de clasificación en el diseño BCI. Aunque la investigación en BCI es relativamente joven, se han logrado muchos avances en poco más de dos décadas, debido a que muchos de estos métodos se basan en la investigación previa en el procesamiento de señales y reconocimiento de patrones. Muchos estudios ya han conseguido diseñar BCI con una considerable precisión proporcionando a pesar de las dificultades inherentes en el procesamiento de las señales cerebrales, aceptable tasa de bits de transferencia de información para algunas aplicaciones. Como consecuencia, el tiempo de entrenamiento de los usuarios se ha reducido significativamente, lo que ha llevado a ampliar el número de aplicaciones de los BCI para personas con discapacidad, tales como procesamiento de textos, navegadores, correo electrónico, control de silla de ruedas, el control de algunos dispositivos domóticos o neuroprótesis, entre otros.

Después de realizar el estudio de las investigaciones más recientes en el campo de los BCI, se ha llevado a cabo un estudio pormenorizado de varios métodos que se pueden aplicar a la etapa de clasificación de características. Para este estudio se han empleado las señales que se proporcionan en el conjunto de datos 2b de la competición BCI de 2008. Estas señales han sido adquiridas mediante EEG y recogen ritmos sensoriomotores generados por 9 sujetos diferentes.

CAPÍTULO 6: CONCLUSIONES Y LÍNEAS FUTURAS

El estudio de diferentes métodos de clasificación de propiedades de señales EEG en BCI basados en ritmos sensiomotores comienza con el estudio del método de clasificación NBPW aplicado por el ganador de la competición. Luego se proponen un conjunto de métodos alternativos como el análisis discriminante lineal, la máquina de soporte vectorial, el perceptrón multicapa, y la red probabilística de Parzen. Además, se ha estudiado la aplicación de un método de post-procesado de las probabilidades *a posteriori* generadas por todos los algoritmos de clasificación estudiados.

Una vez realizado el estudio de métodos de procesado del EEG se han analizado los resultados obtenidos, comparando los distintos métodos entre sí y valorando la mejora que suponen respecto al método de referencia ganador de la competición. Teniendo en cuenta los resultados obtenidos mediante la replicación del método ganador de la competición y no los publicados por los organizadores de la competición, los resultados indican que los clasificadores propuestos como alternativas al NBPW superan a éste pero no proporcionan una mejora significativa del rendimiento. La red probabilística de Parzen y SVM consiguen mejorar el rendimiento en 3.8%, el LDA en 1.9% y el perceptrón multicapa no consigue superar el rendimiento de NBPW.

También se ha analizado el efecto de un método de post-procesado de las probabilidades *a posteriori* que proporcionan los algoritmos de clasificación. El método de post-procesado no mejora necesariamente la clasificación de las señales para todos los sujetos. Sin embargo, sí que lo hace en promedio para todos los sujetos de prueba. Es decir, hace mucho más robusto el método de clasificación ya que su rendimiento no se ve afectado por la variabilidad de los sujetos y el rendimiento no se ve afectado tanto por el instante en el que se decide la clase. La salida de la etapa de clasificación no depende tanto de las características de las señales y muestra mucho menos variabilidad a éstas. En el estudio, se ha hecho un post-procesado de todas las probabilidades *a posteriori* que se van dando a lo largo de la prueba. No obstante, en un entorno real, no tiene sentido considerar todas las probabilidades *a posteriori* del pasado y sería necesario hacer un inventariado de manera que solo se tenga en cuenta las probabilidades *a posteriori* hasta un cierto instante del pasado.

Por último, se ha hecho una revisión de los últimos métodos para mejorar el propuesto por el ganador de la competición. Los propios ganadores han introducido varias modificaciones al método ganador que mejoran ligeramente los resultados de la competición. Con estas modificaciones se ha hecho que la aplicación de los filtros espaciales diseñados mediante CSP que sean más robustos a la presencia de ruido en las señales EEG. También, se ha propuesto un método que adecúa de manera automática las bandas de frecuencias de los filtros del banco del método ganador a las señales generadas por cada uno de los sujetos. Por otro lado, otros autores han sugerido la aplicación de varias variantes de CSP que en algunos casos mejora la precisión conseguida por el ganador y la aplicación de un método de preprocesado de las señales EEG basado en redes neuronales cuántica que facilita la clasificación de las señales de manera significativa.

6.2 Líneas futuras

A partir del presente trabajo se plantean varias líneas futuras. Del estudio de las investigaciones en BCI se constata que, a pesar de los recientes avances importantes en el campo de BCI, existen algunas cuestiones que aún deben ser resueltas. En primer

lugar, no están totalmente claras las ventajas y desventajas de los diferentes métodos de adquisición de la señal, especialmente entre métodos invasivos e no invasivos. No está claro si es imprescindible aplicar métodos invasivos para aplicaciones que requieren el control multidimensional de prótesis o por el contrario basta con métodos no invasivos como EEG. En este sentido, se requieren más estudios con métodos invasivos sobre humanos y animales. En segundo lugar, son necesarias más investigaciones en los métodos invasivos para hacer frente a los daños que los electrodos causan en los tejidos, el riesgo de infección y los problemas de estabilidad de la calidad de la señal a largo plazo. Ya se han propuesto algunos electrodos invasivos que contienen medios neurotrópicos que conservan el tejido de las neuronas y que están conectados mediante un enlace inalámbrico eliminando la necesidad de cables para transmitir las señales neuronales adquiridas. En tercer lugar, se debería identificar y caracterizar mejor las señales electrofisiológicas y metabólicas que son más adecuadas para codificar las intenciones del usuario. Hasta ahora, la mayoría de los estudios de BCI han tratado el dominio del tiempo, la frecuencia y el espacio de las señales cerebrales de forma independiente. Estudios sobre las interdependencias entre las diferentes dimensiones de las señales pueden conducir a una mejora significativa en el rendimiento de BCI. En cuarto lugar, la tasa de información proporcionada por los BCI actuales es baja para alcanzar una interacción hombre-máquina eficaz en algunas aplicaciones. BCI exógenos basados en VEP o P300 podrían proporcionar una comunicación mucho más rápida. No obstante, estos presentan el inconveniente de que solo permiten la selección de comandos discretos. En quinto lugar, la adaptación no supervisada de los BCI a la variabilidad de las señales cerebrales del usuario es un desafío clave para el despliegue de los mismos fuera del laboratorio. En la actualidad, ya se han propuesto algunos de los algoritmos de clasificación adaptativos que han conseguido un éxito moderado. Por último, la mayoría de las aplicaciones de los BCI se encuentran en la etapa de investigación y no están listos para ser introducidos en los hogares para uso continuo en la vida diaria. Además de sus bajas tasas de transferencia de información y fiabilidad variable, los sistemas BCI actuales son incómodos, porque los electrodos deben ser humedecidos, el software precisa ser configurado por un experto y la calidad de los contactos de los electrodos necesita ser mantenida de manera continua. Un BCI basado en P300 controlado remotamente a través de una conexión de Internet podría servir para asegurar un control fiable de los dispositivos controlados a través del BCI y se reduciría la dependencia de los expertos técnicos.

Del estudio de los métodos que se pueden aplicar a la etapa de clasificación de características se pueden extraer varias líneas de investigación futuras. En primer lugar, una ampliación del número de métodos de clasificación incluyendo otros algoritmos como el clasificador de los vecinos más próximos, modelos ocultos de Markov, árboles de decisión o clasificadores basados en cuantificación del vector de aprendizaje. En segundo lugar, hacer que los métodos de clasificación tengan en cuenta información de las señales a lo largo del tiempo. En este estudio el clasificador era entrenado para clasificar en un instante de tiempo determinado de la prueba sin tener en cuenta el pasado. Posiblemente si para clasificar una prueba en un instante de tiempo se tuviera en cuenta muestras anteriores en el tiempo podría mejorarse el rendimiento. En tercer lugar, los métodos de clasificación que se han aplicado en el estudio no son adaptativos. Varios estudios ya apuntan que el empleo de métodos adaptativos podría mejorar sustancialmente la precisión. Por último, también se puede intentar mejorar el rendimiento creando comités de clasificadores. Si se tiene en cuenta la decisión de varios clasificadores creando un sistema de votación entre varios clasificadores se podrían evitar algunos errores de clasificación.

CAPÍTULO 6: CONCLUSIONES Y LÍNEAS FUTURAS

Los últimos avances en la investigación en BCI sugieren que en futuro próximo se van hacer avances significativos. Los logros conseguidos en las dos últimas décadas y el potencial de nuevas aplicaciones BCI han dado un impulso importante a la investigación BCI con participación de científicos multidisciplinares como neurocientíficos, ingenieros, matemáticos y especialistas en clínicas de rehabilitación, entre muchos otros. Se espera que el interés en el campo de los BCI aumente aún más en los próximos años y que el diseño de BCI cada vez mejores consiga incrementar de manera efectiva la calidad de vida de las personas con discapacidad. Por otra parte, existe un creciente interés por algunas empresas en extender el uso de los BCI y las ventajas que ofrece este nuevo modo de interacción a personas que no padecen discapacidad. Ya se pueden encontrar algunas aplicaciones de los BCI dirigidas a la población general. Esto sugiere que, en un futuro próximo, los BCI podrían convertirse en un nuevo modo de interacción hombre-máquina con una importancia similar a otras interfaces actuales.

ANEXO I: Lista de Siglas

ANN – Redes Neuronales Artificiales
AR – Modelo Autorregresivo
BCI – Brain Computer Interface
BLDA – Análisis Discriminante Lineal Bayesiano
BOLD – Nivel de concentración de oxígeno en la sangre
BSS – Blind Signal Separation
CSP – Patrones Espaciales Comunes
CWT – Transformada Wavelet Continua
DWT – Transformada Wavelet Discreta
ECoG – Electroencefalografía
EEG – Electroencefalografía
ELA – Esclerosis Lateral Amiotrófica
EMG – Electromiograma
ERD – Event-related Desynchronization
ERS – Event-related Synchronization
ERP – Potenciales Relacionados
EOG – Electrooculograma
FA – Filtro Adaptado
FES – Estimulación Eléctrica Funcional
FLDA – Análisis Discriminante Lineal de Fisher
fMRI – Imagen por resonancia magnética funcional
ICA – Análisis de Componentes Independientes
LDA – Análisis Discriminante Lineal
LFP – Campo eléctrico muy localizado
LME – Lesiones de Médula Espinal

ANEXO I: LISTA DE SIGLAS

MEG – Magnetoencefalografía
MIBIF – Mutual Information-based Best Individual Feature
MIRSR – Mutual Information Rough Set Reduction
MLP – Perceptrón Multicapa
MUA – Actividad de varias neuronas
MVAAR – Multivariate Adaptive Autoregressive
NBPW – Naïve Bayesian Parzen Window
NIRS – Espectroscopia de Infrarrojo cercano
PCA – Análisis de Componentes Principales
PNN – Red Probabilística de Parzen
SCP – Potenciales corticales lentos
SSVEP – Potenciales Visuales Estacionarios
STFT – Transformada de Fourier de tiempo corto
SUA – Actividad de una sola neurona
SVM – Máquina de Soporte Vectorial
TF – Transformada de Fourier
TFM – Trabajo Fin de Máster
TTD – Dispositivo de Traducción de Pensamientos
TVEP – Potenciales Visuales Transitorios
UIEA – Utah Intracortical Electrode Array
VEP – Potenciales evocados visuales
WT – Transformada Wavelet

ANEXO II: Publicaciones

- Nicolas-Alonso, L.F.; Gomez-Gil, J. “Brain Computer Interfaces, a Review”. *Sensors* **2012**, *12*, 1211-1279.

Referencias

1. Wolpaw, J.R.; Birbaumer, N.; McFarland, D.J.; Pfurtscheller, G.; Vaughan, T.M. Brain-computer interfaces for communication and control. *Clin. Neurophysiol.* **2002**, *113*, 767-791.
2. Pfurtscheller, G.; Lopes da Silva, F.H. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clin. Neurophysiol.* **1999**, *110*, 1842-1857.
3. Jeannerod, M. Mental imagery in the motor context. *Neuropsychologia* **1995**, *33*, 1419-1432.
4. Pfurtscheller, G.; Neuper, C. Motor imagery and direct brain-computer communication. *Proc. IEEE* **2001**, *89*, 1123-1134.
5. Blankertz, B.; Sannelli, C.; Halder, S.; Hammer, E.M.; Kübler, A.; Müller, K.-R.; Curio, G.; Dickhaus, T. Neurophysiological predictor of SMR-based BCI performance. *Neuroimage* **2010**, *51*, 1303-1309.
6. Leeb, R.; Brunner, C.; Müller-Putz, G.; Schlögl, A.; Pfurtscheller, G. BCI Competition 2008—Graz data set B. **2008**.
7. BCI Competition IV. Available online: <http://www.bbci.de/competition/> (accessed on March 8, 2012)
8. Khalid, M.B.; Rao, N.I.; Rizwan-i-Haque, I.; Munir, S.; Tahir, F. Towards a Brain Computer Interface using wavelet transform with averaged and time segmented adapted wavelets. In Proceedings of the 2nd International Conference on Computer, Control and Communication (IC4'09) Karachi, Sindh, Pakistan, February 2009; pp. 1-4.
9. Gevins, A.S.; Zeitlin, G.M.; Yingling, C.D.; Doyle, J.C.; Dedon, M.F.; Schaffer, R.E.; Roumasset, J.T.; Yeager, C.L. EEG patterns during 'cognitive' tasks. I. Methodology and analysis of complex behaviors. *Electroencephalogr. Clin. Neurophysiol.* **1979**, *47*, 693-703.
10. Gevins, A.S.; Zeitlin, G.M.; Doyle, J.C.; Schaffer, R.E.; Callaway, E. EEG patterns during 'cognitive' tasks. II. Analysis of controlled tasks. *Electroencephalogr. Clin. Neurophysiol.* **1979**, *47*, 704-710.
11. Wolpaw, J.R.; McFarland, D.J.; Neat, G.W.; Forneris, C.A. An EEG-based brain-computer interface for cursor control. *Electroencephalogr. Clin. Neurophysiol.* **1991**, *78*, 252-259.
12. Iturrate, I.; Antelis, J.M.; Kubler, A.; Minguez, J. A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation. *IEEE Trans. Robot.* **2009**, *25*, 614-627.

REFERENCIAS

13. Blankertz, B.; Tangermann, M.; Vidaurre, C.; Fazli, S.; Sannelli, C.; Haufe, S.; Maeder, C.; Ramsey, L.; Sturm, I.; Curio, G.; Mueller, K.R. The Berlin Brain-Computer Interface: Non-Medical Uses of BCI Technology. *Front. Neurosci.* **2010**, *4*.
14. Wolpaw, J.R.; Birbaumer, N.; Heetderks, W.J.; McFarland, D.J.; Peckham, P.H.; Schalk, G.; Donchin, E.; Quatrano, L.A.; Robinson, C.J.; Vaughan, T.M. Brain-computer interface technology: a review of the first international meeting. *IEEE Trans. Rehabil. Eng.* **2000**, *8*, 164-173.
15. Mason, S.G.; Birch, G.E. A general framework for brain-computer interface design. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2003**, *11*, 70-85.
16. Lee, J.; Ryu, J.; Jolesz, F.A.; Cho, Z.H.; Yoo, S.S. Brain-machine interface via real-time fMRI: Preliminary study on thought-controlled robotic arm. *Neurosci. Lett.* **2009**, *450*, 1-6.
17. Logothetis, N.K.; Pauls, J.; Augath, M.; Trinath, T.; Oeltermann, A. Neurophysiological investigation of the basis of the fMRI signal. *Nature* **2001**, *412*, 150-157.
18. deCharms, R.C.; Christoff, K.; Glover, G.H.; Pauly, J.M.; Whitfield, S.; Gabrieli, J.D.E. Learned regulation of spatially localized brain activation using real-time fMRI. *Neuroimage* **2004**, *21*, 436-443.
19. Weiskopf, N.; Mathiak, K.; Bock, S.W.; Scharnowski, F.; Veit, R.; Grodd, W.; Goebel, R.; 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.
20. Weiskopf, N.; Sitaram, R.; Josephs, O.; Veit, R.; Scharnowski, F.; Goebel, R.; Birbaumer, N.; Deichmann, R.; Mathiak, K. Real-time functional magnetic resonance imaging: methods and applications. *Magn. Reson. Imaging* **2007**, *25*, 989-1003.
21. Christopher deCharms, R. Applications of real-time fMRI. *Nat. Rev. Neurosci.* **2008**, *9*, 720-729.
22. Moench, T.; Hollmann, M.; Grzeschik, R.; Mueller, C.; Luetzkendorf, R.; Baecke, S.; Luchtman, M.; Wagegg, D.; 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.
23. Waldert, S.; Pistohl, T.; Braun, C.; Ball, T.; Aertsen, A.; Mehring, C. A review on directional information in neural signals for brain-machine interfaces. *J. Physiology-Paris* **2009**, *103*, 244-254.
24. Salmelin, R.; Hämäläinen, M.; Kajola, M.; Hari, R. Functional Segregation of Movement-Related Rhythmic Activity in the Human Brain. *Neuroimage* **1995**, *2*, 237-243.
25. Mellinger, J.; Schalk, G.; Braun, C.; Preissl, H.; Rosenstiel, W.; Birbaumer, N.; Kübler, A. An MEG-based brain-computer interface (BCI). *Neuroimage* **2007**, *36*, 581-593.
26. Shirley, M.C.; et al. Brain-computer interface using a simplified functional near-infrared spectroscopy system. *J. Neural Eng.* **2007**, *4*, 219.
27. Taga, G.; Homae, F.; Watanabe, H. Effects of source-detector distance of near infrared spectroscopy on the measurement of the cortical hemodynamic response in infants. *Neuroimage* **2007**, *38*, 452-460.
28. Kennan, R.P.; Horovitz, S.G.; Maki, A.; Yamashita, Y.; Koizumi, H.; Gore, J.C. Simultaneous Recording of Event-Related Auditory Oddball Response Using Transcranial Near Infrared Optical Topography and Surface EEG. *Neuroimage* **2002**, *16*, 587-592.

29. Izzetoglu, M.; Devaraj, A.; Bunce, S.; Onaral, B. Motion artifact cancellation in NIR spectroscopy using Wiener filtering. *IEEE Trans. Biomed. Eng.* **2005**, *52*, 934-938.
30. Cui, X.; Bray, S.; Reiss, A.L. Functional near infrared spectroscopy (NIRS) signal improvement based on negative correlation between oxygenated and deoxygenated hemoglobin dynamics. *Neuroimage* **2010**, *49*, 3039-3046.
31. Shirley, C.; Ward, T.a.; Markham, C.; McDarby, G. On the suitability of near-infrared (NIR) systems for next-generation brain-computer interfaces. *Physiol. Meas.* **2004**, *25*, 815.
32. Taheri, B.A.; Knight, R.T.; Smith, R.L. A dry electrode for EEG recording. *Electroencephalogr. Clin. Neurophysiol.* **1994**, *90*, 376-383.
33. Lee, K.-H.; Williams, L.M.; Breakspear, M.; Gordon, E. Synchronous Gamma activity: a review and contribution to an integrative neuroscience model of schizophrenia. *Brain Res. Rev.* **2003**, *41*, 57-78.
34. Brown, P.; Salenius, S.; Rothwell, J.C.; Hari, R. Cortical Correlate of the Piper Rhythm in Humans. *J. Neurophysiol.* **1998**, *80*, 2911-2917.
35. Mima, T.; Simpkins, N.; Oluwatimilehin, T.; Hallett, M. Force level modulates human cortical oscillatory activities. *Neurosci. Lett.* **1999**, *275*, 77-80.
36. Lutzenberger, W.; Pulvermüller, F.; Elbert, T.; Birbaumer, N. Visual stimulation alters local 40-Hz responses in humans: an EEG-study. *Neurosci. Lett.* **1995**, *183*, 39-42.
37. Müller, M.M.; Keil, A.; Gruber, T.; Elbert, T. Processing of affective pictures modulates right-hemispheric gamma band EEG activity. *Clin. Neurophysiol.* **1999**, *110*, 1913-1920.
38. Müller, M.M.; Bosch, J.; Elbert, T.; Kreiter, A.; Sosa, M.V.; Sosa, P.V.; Rockstroh, B. Visually induced gamma-band responses in human electroencephalographic activity — a link to animal studies. *Exp. Brain. Res.* **1996**, *112*, 96-102.
39. Zhang, L.; He, W.; He, C.; Wang, P. Improving Mental Task Classification by Adding High Frequency Band Information. *J. Med. Syst.* **2010**, *34*, 51-60.
40. Darvas, F.; Scherer, R.; Ojemann, J.G.; Rao, R.P.; Miller, K.J.; Sorensen, L.B. High gamma mapping using EEG. *Neuroimage* **2010**, *49*, 930-938.
41. Miller, K.J.; Leuthardt, E.C.; Schalk, G.; Rao, R.P.N.; Anderson, N.R.; Moran, D.W.; Miller, J.W.; Ojemann, J.G. Spectral Changes in Cortical Surface Potentials during Motor Movement. *J. Neurosci.* **2007**, *27*, 2424-2432.
42. Jasper, H.H. The ten-twenty electrode system of the International Federation. *Electroencephalogr. Clin. Neurophysiol.* **1958**, 371-375.
43. Ball, T.; Kern, M.; Mutschler, I.; Aertsen, A.; Schulze-Bonhage, A. Signal quality of simultaneously recorded invasive and non-invasive EEG. *Neuroimage* **2009**, *46*, 708-716.
44. Freeman, W.J.; Schneider, W. Changes in Spatial Patterns of Rabbit Olfactory EEG with Conditioning to Odors. *Psychophysiology* **1982**, *19*, 44-56.
45. Freeman, W.J.; van Dijk, B.W. Spatial patterns of visual cortical fast EEG during conditioned reflex in a rhesus monkey. *Brain Res.* **1987**, *422*, 267-276.
46. Crone, N.E.; Miglioretti, D.L.; Gordon, B.; Sieracki, J.M.; Wilson, M.T.; Uematsu, S.; Lesser, R.P. Functional mapping of human sensorimotor cortex with electrocorticographic spectral analysis. I. Alpha and beta event-related desynchronization. *Brain* **1998**, *121*, 2271-2299.

REFERENCIAS

47. Crone, N.E.; Miglioretti, D.L.; Gordon, B.; Lesser, R.P. Functional mapping of human sensorimotor cortex with electrocorticographic spectral analysis. II. Event-related synchronization in the gamma band. *Brain* **1998**, *121*, 2301-2315.
48. Miller, K.J.; denNijs, M.; Shenoy, P.; Miller, J.W.; Rao, R.P.N.; Ojemann, J.G. Real-time functional brain mapping using electrocorticography. *Neuroimage* **2007**, *37*, 504-507.
49. Levine, S.P.; Huggins, J.E.; BeMent, S.L.; Kushwaha, R.K.; Schuh, L.A.; Passaro, E.A.; Rohde, M.M.; Ross, D.A. Identification of Electrocorticogram Patterns as the Basis for a Direct Brain Interface. *J. Clin. Neurophysiol.* **1999**, *16*, 439-447.
50. Leuthardt, E.C.; Schalk, G.; Wolpaw, J.R.; G., O.J.; Moran, D.W. A brain-computer interface using electrocorticographic signals in humans. *J. Neural Eng.* **2004**, *1*, 63.
51. Schalk, G.; Schalk, G.; Kubánek, J.; Miller, K.J.; Anderson, N.R.; Leuthardt, E.C.; Ojemann, J.G.; Limbrick, D.; Moran, D.; Gerhardt, L.A.; Wolpaw, J.R. Decoding two-dimensional movement trajectories using electrocorticographic signals in humans. *J. Neural Eng.* **2007**, *4*, 264.
52. Maynard, E.M.; Nordhausen, C.T.; Normann, R.A. The Utah Intracortical Electrode Array: A recording structure for potential brain-computer interfaces. *Electroencephalogr. Clin. Neurophysiol.* **1997**, *102*, 228-239.
53. Kennedy, P.R.; Kirby, M.T.; Moore, M.M.; King, B.; Mallory, A. Computer control using human intracortical local field potentials. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2004**, *12*, 339-344.
54. Pfurtscheller, G.; Neuper, C.; Muller, G.R.; Obermaier, B.; Krausz, G.; Schlogl, A.; Scherer, R.; Graimann, B.; Keinrath, C.; Skliris, D.; Wortz, M.; Supp, G.; Schrank, C. Graz-BCI: state of the art and clinical applications. *IEEE Trans. Neural Sys. Rehabil. Eng.* **2003**, *11*, 1-4.
55. Jinghai, Y.; Derong, J.; Jianfeng, H. Design and application of brain-computer interface web browser based on VEP. In Proceedings of the International Conference on Future BioMedical Information Engineering (FBIE'09), Sanya, China, 13-14 Dec. 2009; pp. 77-80.
56. Lee, P.; Hsieh, J.; Wu, C.; Shyu, K.; Wu, Y. Brain computer interface using flash onset and offset visual evoked potentials. *Clin. Neurophysiol.* **2008**, *119*, 605-616.
57. Hinterberger, T.; Mellinger, J.; Birbaumer, N. The Thought Translation Device: structure of a multimodal brain-computer communication system. In Proceedings of the First International IEEE EMBS Conference on Neural Engineering (NER '03), Capri Island, Italy, March 2003; pp. 603-606.
58. Birbaumer, N. Slow cortical potentials: their origin, meaning, and clinical use. **1997**, 25-39.
59. Hinterberger, T.; Schmidt, S.; Neumann, N.; Mellinger, J.; Blankertz, B.; Curio, G.; Birbaumer, N. Brain-computer communication and slow cortical potentials. *IEEE Trans. Biomed. Eng.* **2004**, *51*, 1011-1018.
60. Kaiser, J. Self-initiation of EEG-based communication in paralyzed patients. *Clin. Neurophysiol.* **2001**, *112*, 551-554.
61. Neumann, N.; Birbaumer, N. Predictors of successful self control during brain-computer communication. *J. Neurol. Neurosurg. Psychiat.* **2003**, *74*, 1117-1121.
62. Kübler, A.; Kotchoubey, B.; Hinterberger, T.; Ghanayim, N.; Perelmouter, J.; Schauer, M.; Fritsch, C.; Taub, E.; Birbaumer, N. The thought translation device: a neurophysiological approach to communication in total motor paralysis. *Exp. Brain. Res.* **1999**, *124*, 223-232.

63. Birbaumer, N.; Hinterberger, T.; Kubler, A.; Neumann, N. The thought-translation device (TTD): neurobehavioral mechanisms and clinical outcome. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2003**, *11*, 120-123.
64. Iversen, I.H.; Ghanayim, N.; Kübler, A.; Neumann, N.; Birbaumer, N.; Kaiser, J. A brain-computer interface tool to assess cognitive functions in completely paralyzed patients with amyotrophic lateral sclerosis. *Clin. Neurophysiol.* **2008**, *119*, 2214-2223.
65. Donchin, E.; Smith, D.B.D. The contingent negative variation and the late positive wave of the average evoked potential. *Electroencephalogr. Clin. Neurophysiol.* **1970**, *29*, 201-203.
66. Polich, J.; Ellerson, P.C.; Cohen, J. P300, stimulus intensity, modality, and probability. *Int. J. Psychophysiol.* **1996**, *23*, 55-62.
67. Ravden, D.; Polich, J. On P300 measurement stability: habituation, intra-trial block variation, and ultradian rhythms. *Biol. Psychol.* **1999**, *51*, 59-76.
68. Farwell, L.A.; Donchin, E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalogr. Clin. Neurophysiol.* **1988**, *70*, 510-523.
69. Tanaka, K.; Matsunaga, K.; Wang, H.O. Electroencephalogram-Based Control of an Electric Wheelchair. *IEEE Trans. Robot.* **2005**, *21*, 762-766.
70. Mugler, E.M.; Ruf, C.A.; Halder, S.; Bensch, M.; Kubler, A. Design and Implementation of a P300-Based Brain-Computer Interface for Controlling an Internet Browser. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2010**, *18*, 599-609.
71. Furdea, A.; Halder, S.; Krusienski, D.J.; Bross, D.; Nijboer, F.; Birbaumer, N.; Kübler, A. An auditory oddball (P300) spelling system for brain-computer interfaces. *Psychophysiology* **2009**, *46*, 617-625.
72. Rivet, B.; Souloumiac, A.; Attina, V.; Gibert, G. xDAWN Algorithm to Enhance Evoked Potentials: Application to Brain-Computer Interface. *IEEE Trans. Biomed. Eng.* **2009**, *56*, 2035-2043.
73. Rakotomamonjy, A.; Guigue, V. BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 1147-1154.
74. Salvaris, M.; Sepulveda, F. Visual modifications on the P300 speller BCI paradigm. *J. Neural Eng.* **2009**, *6*, 046011.
75. Takano, K.; Komatsu, T.; Hata, N.; Nakajima, Y.; Kansaku, K. Visual stimuli for the P300 brain-computer interface: A comparison of white/gray and green/blue flicker matrices. *Clin. Neurophysiol.* **2009**, *120*, 1562-1566.
76. Ikegami, S.; Takano, K.; Saeki, N.; Kansaku, K. Operation of a P300-based brain-computer interface by individuals with cervical spinal cord injury. *Clin. Neurophysiol.* **2011**, *122*, 991-996.
77. Blankertz, B.; Sannelli, C.; Halder, S.; Hammer, E.M.; Kübler, A.; Müller, K.R.; Curio, G.; Dickhaus, T. Neurophysiological predictor of SMR-based BCI performance. *Neuroimage* **2010**, *51*, 1303-1309.
78. Pfurtscheller, G.; Aranibar, A. Event-related cortical desynchronization detected by power measurements of scalp EEG. *Electroencephalogr. Clin. Neurophysiol.* **1977**, *42*, 817-826.
79. Neuper, C.; Scherer, R.; Reiner, M.; Pfurtscheller, G. Imagery of motor actions: Differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG. *Cogn. Brain. Res.* **2005**, *25*, 668-677.

REFERENCIAS

80. Nijboer, F.; Furdea, A.; Gunst, I.; Mellinger, J.; McFarland, D.J.; Birbaumer, N.; Kübler, A. An auditory brain-computer interface (BCI). *J. Neurosci. Methods* **2008**, *167*, 43-50.
81. Hwang, H.; Kwon, K.; Im, C. Neurofeedback-based motor imagery training for brain-computer interface (BCI). *J. Neurosci. Methods* **2009**, *179*, 150-156.
82. Wolpaw, J.R.; McFarland, D.J.; Vaughan, T.M. Brain-computer interface research at the Wadsworth Center. *IEEE Trans. Rehabil. Eng.* **2000**, *8*, 222-226.
83. Blankertz, B.; Losch, F.; Krauledat, M.; Dornhege, G.; Curio, G.; Müller, K.R. The Berlin Brain-Computer Interface: Accurate Performance From First-Session in BCI-Naïve Subjects. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 2452-2462.
84. Bai, O.; Rathi, V.; Lin, P.; Huang, D.; Battapady, H.; Fei, D.; Schneider, L.; Houdayer, E.; Chen, X.; Hallett, M. Prediction of human voluntary movement before it occurs. *Clin. Neurophysiol.* **2011**, *122*, 364-372.
85. Lin, C.-J.; Hsieh, M.-H. Classification of mental task from EEG data using neural networks based on particle swarm optimization. **2009**, *72*, 1121-1130.
86. Lins, O.G.; Picton, T.W.; Berg, P.; Scherg, M. Ocular artifacts in recording EEGs and event-related potentials II: Source dipoles and source components. **1993**, *6*, 65-78.
87. Boye, A.T.; Kristiansen, U.Q.; Billinger, M.; Nascimento, O.F.d.; Farina, D. Identification of movement-related cortical potentials with optimized spatial filtering and principal component analysis. **2008**, *3*, 300-304.
88. Kun, L.; Sankar, R.; Arbel, Y.; Donchin, E. Single trial independent component analysis for P300 BCI system. In Proceedings of the Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE, 3-6 Sept. 2009 2009; pp. 4035-4038.
89. Castellanos, N.P.; Makarov, V.A. Recovering EEG brain signals: Artifact suppression with wavelet enhanced independent component analysis. **2006**, *158*, 300-312.
90. Bell, A.; Sejnowski, T. An Information-Maximization Approach to Blind Separation and Blind Deconvolution. **1995**, *7*, 1129-1159.
91. Lee, T.-W.; Girolami, M.; Sejnowski, T.J. Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Subgaussian and Supergaussian Sources. **1999**, *11*, 417-441.
92. Gao, J.; Yang, Y.; Lin, P.; Wang, P.; Zheng, C. Automatic Removal of Eye-Movement and Blink Artifacts from EEG Signals. **2010**, *23*, 105-114.
93. Flexer, A.; Bauer, H.; Pripfl, J.; Dorffner, G. Using ICA for removal of ocular artifacts in EEG recorded from blind subjects. **2005**, *18*, 998-1005.
94. Jung, T.-P.; Makeig, S.; Westerfield, M.; Townsend, J.; Courchesne, E.; Sejnowski, T.J. Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects. **2000**, *111*, 1745-1758.
95. Wallstrom, G.L.; Kass, R.E.; Miller, A.; Cohn, J.F.; Fox, N.A. Automatic correction of ocular artifacts in the EEG: a comparison of regression-based and component-based methods. *Int. J. Psychophysiol.* **2004**, *53*, 105-119.
96. Chiappa, S.; Barber, D. EEG classification using generative independent component analysis. **2006**, *69*, 769-777.
97. Kay, S.M.; Marple, S.L., Jr. Spectrum analysis-A modern perspective. *Proc. IEEE* **1981**, *69*, 1380-1419.
98. Krusienski, D.J.; McFarland, D.J.; Wolpaw, J.R. An Evaluation of Autoregressive Spectral Estimation Model Order for Brain-Computer Interface Applications. In

- Proceedings of the Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE, Aug. 30 2006-Sept. 3 2006 2006; pp. 1323-1326.
99. Jiang, W.; Guizhi, X.; Lei, W.; Huiyuan, Z. Feature extraction of brain-computer interface based on improved multivariate adaptive autoregressive models. In Proceedings of the Biomedical Engineering and Informatics (BMEI), 2010 3rd International Conference on, 16-18 Oct. 2010 2010; pp. 895-898.
 100. Krusienski, D.J.; Schalk, G.; McFarland, D.J.; Wolpaw, J.R. A mu-Rhythm Matched Filter for Continuous Control of a Brain-Computer Interface. **2007**, *54*, 273-280.
 101. Brunner, C.; Allison, B.Z.; Krusienski, D.J.; Kaiser, V.; Müller-Putz, G.R.; Pfurtscheller, G.; Neuper, C. Improved signal processing approaches in an offline simulation of a hybrid brain-computer interface. **2010**, *188*, 165-173.
 102. Ghanbari, A.A.; Kousarrizi, M.R.N.; Teshnehlab, M.; Aliyari, M. Wavelet and Hilbert transform-based Brain Computer Interface. In Proceedings of the Advances in Computational Tools for Engineering Applications, 2009. ACTEA '09. International Conference on, 15-17 July 2009 2009; pp. 438-442.
 103. Samar, V.J.; Bopardikar, A.; Rao, R.; Swartz, K. Wavelet analysis of neuroelectric waveforms: a conceptual tutorial. **1999**, *66*, pp. 7-60.
 104. Demiralp, T.; Yordanova, J.; Kolev, V.; Ademoglu, A.; Devrim, M.; Samar, V.J. Time-Frequency Analysis of Single-Sweep Event-Related Potentials by Means of Fast Wavelet Transform. **1999**, *66*, 129-145.
 105. Hubbard, B.B. *The world according to wavelets: the story of a mathematical technique in the making*, A.K. Peters: Natick, MA, USA, 1998.
 106. Farina, D.; Nascimento, O.F.d.; Lucas, M.-F.; Doncarli, C. Optimization of wavelets for classification of movement-related cortical potentials generated by variation of force-related parameters. **2007**, *162*, 357-363.
 107. 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.
 108. Senkowski, D.; Herrmann, C.S. Effects of task difficulty on evoked gamma activity and ERPs in a visual discrimination task. *Clin. Neurophysiol.* **2002**, *113*, 1742-1753.
 109. Mason, S.G.; Birch, G.E. A brain-controlled switch for asynchronous control applications. **2000**, *47*, 1297-1307.
 110. Hinterberger, T.; Kübler, A.; Kaiser, J.; Neumann, N.; Birbaumer, N. A brain-computer interface (BCI) for the locked-in: comparison of different EEG classifications for the thought translation device. **2003**, *114*, 416-425.
 111. Lotte, F.; Congedo, M.; Lecuyer, A.; Lamarche, F.; Arnaldi, B. A review of classification algorithms for EEG-based brain-computer interfaces. *J. Neural Eng.* **2007**, *4*, R1.
 112. McFarland, D.J.; Wolpaw, J.R. Sensorimotor rhythm-based brain-computer interface (BCI): feature selection by regression improves performance. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2005**, *13*, 372-379.
 113. Leeb, R.; Brunner, C.; Müller-Putz, G.; Schlögl, A.; Pfurtscheller, G. BCI Competition 2008-Graz data set B. **2009**.
 114. Brunner, C.; Leeb, R.; Müller-Putz, G.; Schlögl, A.; Pfurtscheller, G. BCI Competition 2008-Graz data set A. **2008**.

REFERENCIAS

115. Millan, J.R.; Mourino, J. Asynchronous BCI and local neural classifiers: an overview of the adaptive brain interface project. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2003**, *11*, 159-161.
116. Galán, F.; Nuttin, M.; Lew, E.; Ferrez, P.W.; Vanacker, G.; Philips, J.; Millán, J.d.R. A Brain-Actuated Wheelchair: Asynchronous and Non-Invasive Brain-Computer Interfaces for Continuous Control of Robots. *Clin. Neurophysiol.* **2008**, *119*, 2159-2169.
117. Pradeep, S.; et al. Towards adaptive classification for BCI. *J. Neural Eng.* **2006**, *3*, R13.
118. Li, Y.; Guan, C.; Li, H.; Chin, Z. A self-training semi-supervised SVM algorithm and its application in an EEG-based brain computer interface speller system. *Pattern Recogn. Lett.* **2008**, *29*, 1285-1294.
119. Vidaurre, C.; Sannelli, C.; Müller, K.-R.; Blankertz, B. Machine-Learning-Based Coadaptive Calibration for Brain-Computer Interfaces. *Neural Comput.* **2010**, *23*, 791-816.
120. Buttfeld, A.; Ferrez, P.W.; Millán, J.d.R., Online Classifier Adaptation in High Frequency EEG. In *Proceedings of the 3rd International Brain-Computer Interface Workshop & Training Course 2006*, 2006.
121. Shijian, L.; Cuntai, G.; Haihong, Z. Unsupervised Brain Computer Interface Based on Intersubject Information and Online Adaptation. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2009**, *17*, 135-145.
122. Ferrez, P.W.; del R. Millan, J. Error-Related EEG Potentials Generated During Simulated Brain Computer Interaction. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 923-929.
123. Millan, J.R. On the need for on-line learning in brain-computer interfaces. In *Proceedings of the IEEE International Joint Conference on Neural Networks, (IJCNN'04)*, Budapest, Hungary, July 2004; pp. 2877-2882.
124. Jain, A.K.; Duin, R.P.W.; Jianchang, M. Statistical pattern recognition: a review. *IEEE Trans. Pattern Anal.* **2000**, *22*, 4-37.
125. Muller, K.R.; Anderson, C.W.; Birch, G.E. Linear and nonlinear methods for brain-computer interfaces. **2003**, *11*, 165-169.
126. Fatourech, M.; Bashashati, A.; Ward, R.K.; Birch, G.E. EMG and EOG artifacts in brain computer interface systems: A survey. *Clin. Neurophysiol.* **2007**, *118*, 480-494.
127. Croft, R.J.; Barry, R.J. Removal of ocular artifact from the EEG: a review. *Neurophysiol. Clin.* **2000**, *30*, 5-19.
128. Vigário, R.N. Extraction of ocular artefacts from EEG using independent component analysis. *Electroencephalogr. Clin. Neurophysiol.* **1997**, *103*, 395-404.
129. del R Millan, J.; Mourino, J.; Franze, M.; Cincotti, F.; Varsta, M.; Heikkonen, J.; Babiloni, F. A local neural classifier for the recognition of EEG patterns associated to mental tasks. *IEEE Trans. Neural Netw.* **2002**, *13*, 678-686.
130. Birbaumer, N.; Ghanayim, N.; Hinterberger, T.; Iversen, I.; Kotchoubey, B.; Kubler, A.; Perelmouter, J.; Taub, E.; Flor, H. A spelling device for the paralysed. *Nature* **1999**, *398*, 297-298.
131. Chambayil, B.; Singla, R.; Jha, R. Virtual keyboard BCI using Eye blinks in EEG. In *Proceedings of the 6th IEEE International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob'10)*, Niagara Falls, ON, Canada, October 2010; pp. 466-470.

132. Millan, J.R.; Mourino, J. Asynchronous BCI and local neural classifiers: an overview of the adaptive brain interface project. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2003**, *11*, 159-161.
133. Obermaier, B.; Muller, G.R.; Pfurtscheller, G. "Virtual keyboard" controlled by spontaneous EEG activity. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2003**, *11*, 422-426.
134. Silvoni, S.; Volpato, C.; Cavinato, M.; Marchetti, M.; Priftis, K.; Merico, A.; Tonin, P.; Koutsikos, K.; Beverina, F.; Piccione, F. P300-based brain-computer interface communication: evaluation and follow-up in amyotrophic lateral sclerosis. *Front. Neurosci.* **2009**, *3*.
135. intendix.com. Available online: <http://www.intendix.com/> (accessed on July 12, 2011)
136. Fazel-Rezai, R.; Abhari, K. A region-based P300 speller for brain-computer interface. *Can. J. Elect. Comput. E.* **2009**, *34*, 81-85.
137. Ahi, S.T.; Kambara, H.; Koike, Y. A Dictionary-Driven P300 Speller With a Modified Interface. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2011**, *19*, 6-14.
138. Halder, S.; Rea, M.; Andreoni, R.; Nijboer, F.; Hammer, E.M.; Kleih, S.C.; Birbaumer, N.; Kübler, A. An auditory oddball brain-computer interface for binary choices. *Clin. Neurophysiol.* **2010**, *121*, 516-523.
139. Klobassa, D.S.; Vaughan, T.M.; Brunner, P.; Schwartz, N.E.; Wolpaw, J.R.; Neuper, C.; Sellers, E.W. Toward a high-throughput auditory P300-based brain-computer interface. *Clin. Neurophysiol.* **2009**, *120*, 1252-1261.
140. Kübler, A.; Furdea, A.; Halder, S.; Hammer, E.M.; Nijboer, F.; Kotchoubey, B. A Brain-Computer Interface Controlled Auditory Event-Related Potential (P300) Spelling System for Locked-In Patients. *Ann. NY Acad. Sci.* **2009**, *1157*, 90-100.
141. Karim, A.A.; Hinterberger, T.; Richter, J.; Mellinger, J.; Neumann, N.; Flor, H.; Kübler, A.; Birbaumer, N. Neural Internet: Web Surfing with Brain Potentials for the Completely Paralyzed. *Neurorehabil. Neural Repair* **2006**, *20*, 508-515.
142. Bensch, M.; Karim, A.A.; Mellinger, J.; Hinterberger, T.; Tangermann, M.; Bogdan, M.; Rosenstiel, W.; Birbaumer, N. Nessi: An EEG-Controlled Web Browser for Severely Paralyzed Patients. *Comput. Intell. Neurosci.* **2007**, *2007*, 5.
143. Braz, G.P.; Russold, M.; Davis, G.M. Functional Electrical Stimulation Control of Standing and Stepping After Spinal Cord Injury: A Review of Technical Characteristics. *Neuromodulation: Technol. Neural Interface* **2009**, *12*, 180-190.
144. Lauer, R.T.; Peckham, P.H.; Kilgore, K.L. EEG-based control of a hand grasp neuroprosthesis. *NeuroReport* **1999**, *10*, 1767-1771.
145. Pfurtscheller, G.; Müller, G.R.; Pfurtscheller, J.; Gerner, H.J.; Rupp, R. 'Thought' - control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. *Neurosci. Lett.* **2003**, *351*, 33-36.
146. Pfurtscheller, G.; Guger, C.; Müller, G.; Krausz, G.; Neuper, C. Brain oscillations control hand orthosis in a tetraplegic. *Neurosci. Lett.* **2000**, *292*, 211-214.
147. Müller-Putz, G.R.; Scherer, R.; Pfurtscheller, G.; Rupp, R. EEG-based neuroprosthesis control: A step towards clinical practice. *Neurosci. Lett.* **2005**, *382*, 169-174.
148. Müller-Putz, G.R.; Pfurtscheller, G. Control of an Electrical Prosthesis With an SSVEP-Based BCI. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 361-364.
149. Cincotti, F.; Mattia, D.; Aloise, F.; Bufalari, S.; Schalk, G.; Oriolo, G.; Cherubini, A.; Marciani, M.G.; Babiloni, F. Non-invasive brain-computer interface system: Towards its application as assistive technology. *Brain Res. Bull.* **2008**, *75*, 796-803.

REFERENCIAS

150. Hochberg, L.R.; Serruya, M.D.; Friehs, G.M.; Mukand, J.A.; Saleh, M.; Caplan, A.H.; Branner, A.; Chen, D.; Penn, R.D.; Donoghue, J.P. Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature* **2006**, *442*, 164-171.
151. Serruya, M.D.; Hatsopoulos, N.G.; Paninski, L.; Fellows, M.R.; Donoghue, J.P. Brain-machine interface: Instant neural control of a movement signal. *Nature* **2002**, *416*, 141-142.
152. Millan, J.R.; Renkens, F.; Mourino, J.; Gerstner, W. Noninvasive brain-actuated control of a mobile robot by human EEG. *IEEE Trans. Biomed. Eng.* **2004**, *51*, 1026-1033.
153. Rebsamen, B.; Burdet, E.; Cuntai, G.; Chee Leong, T.; Qiang, Z.; Ang, M.; Laugier, C. Controlling a wheelchair using a BCI with low information transfer rate. In Proceedings of the IEEE 10th International Conference on Rehabilitation Robotics (ICORR'07), Noordwijk, Holland, June 2007; pp. 1003-1008.
154. Rebsamen, B.; Cuntai, G.; Haihong, Z.; Chuanchu, W.; Cheeleong, T.; Ang, M.H.; Burdet, E. A Brain Controlled Wheelchair to Navigate in Familiar Environments. *IEEE Trans. Neural Sys. Rehabil. Eng.* **2010**, *18*, 590-598.
155. Philips, J.; del R. Millan, J.; Vanacker, G.; Lew, E.; Galan, F.; Ferrez, P.W.; Van Brussel, H.; Nuttin, M. Adaptive Shared Control of a Brain-Actuated Simulated Wheelchair. In Proceedings of the IEEE 10th International Conference on Rehabilitation Robotics (ICORR'07), Noordwijk, Holland, June 2007; pp. 408-414.
156. Vanacker, G.; del R. Millán, J.; Lew, E. Context-Based Filtering for Assisted Brain-Actuated Wheelchair Driving. *Comput. Intell. Neurosci.* **2007**, *2007*, 12.
157. Fun of gaming: Measuring the human experience of media enjoyment. Available online: <http://fuga.aalto.fi/> (accessed on July 12, 2011)
158. Roman, K.; Benjamin, B.; Gabriel, C.; Klaus-Robert, M. The Berlin Brain-Computer Interface (BBCI) - towards a new communication channel for online control in gaming applications. *Multimed. Tools Appl.* **2007**, *33*, 73-90.
159. Tangermann, M.; Krauledat, M.; Grzeska, K.; Sagebaum, M.; Blankertz, B.; Vidaurre, C.; Müller, K. Playing Pinball with non-invasive BCI. *Proc. NIPS* **2008**, 1641-1648.
160. Middendorf, M.; McMillan, G.; Calhoun, G.; Jones, K.S. Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE Trans. Rehabil. Eng.* **2000**, *8*, 211-214.
161. Lalor, E.C.; Kelly, S.P.; Finucane, C. Steady-State VEP-Based Brain-Computer Interface Control in an Immersive 3D Gaming Environment. *J. Appl. Signal Proc.* **2005**, *2005*, 3156-3164.
162. Finke, A.; Lenhardt, A.; Ritter, H. The MindGame: A P300-based brain-computer interface game. *Neural Netw.* **2009**, *22*, 1329-1333.
163. Emotiv - Brain Computer Interface Technology. Available online: www.emotiv.com (accessed on July 12, 2011)
164. Lauer, R.T.; Peckham, P.H.; Kilgore, K.L.; Heetderks, W.J. Applications of cortical signals to neuroprosthetic control: a critical review. *IEEE Trans. Rehabil. Eng.* **2000**, *8*, 205-208.
165. Leeb, R.; Lee, F.; Keinrath, C.; Scherer, R.; Bischof, H.; Pfurtscheller, G. Brain-computer communication: motivation, aim, and impact of exploring a virtual apartment. **2007**, *15*, 473-482.
166. Ramoser, H.; Muller-Gerking, J.; Pfurtscheller, G. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Trans. Rehabil. Eng.* **2000**, *8*, 441-446.

167. Grosse-Wentrup, M.; Buss, M. Multiclass Common Spatial Patterns and Information Theoretic Feature Extraction. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 1991-2000.
168. Kai Keng, A.; Zheng Yang, C.; Haihong, Z.; Cuntai, G. Filter Bank Common Spatial Pattern (FBCSP) algorithm using online adaptive and semi-supervised learning. In Proceedings of the The 2011 International Joint Conference on Neural Networks (IJCNN'11), , San Jose, CA, USA, July 31-Aug. 5 2011; pp. 392-396.
169. Kai Keng, A.; Chai, Q. Rough set-based neuro-fuzzy system. In Proceedings of the International Joint Conference on Neural Networks, 2006 (IJCNN '06), Vancouver, BC, Canada, 16-21 July 2006; pp. 742-749.
170. Ang, K.K.; Chin, Z.Y.; Wang, C.; Guan, C.; Zhang, H. Filter Bank Common Spatial Pattern algorithm on BCI Competition IV Datasets 2a and 2b. *Front. Neurosci.* **2012**, *6*.
171. Parzen, E. On estimation of a probability density function and mode. **1962**, *33*, 1065-1076.
172. Garrett, D.; Peterson, D.A.; Anderson, C.W.; Thaut, M.H. Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. **2003**, *11*, 141-144.
173. Scherer, R.; Muller, G.R.; Neuper, C.; Graimann, B.; Pfurtscheller, G. An asynchronously controlled EEG-based virtual keyboard: improvement of the spelling rate. **2004**, *51*, 979-984.
174. Muller, K.R.; Anderson, C.W.; Birch, G.E. Linear and nonlinear methods for brain-computer interfaces. **2003**, *11*, 165-169.
175. Blankertz, B.; Lemm, S.; Treder, M.; Haufe, S.; Müller, K.-R. Single-trial analysis and classification of ERP components -- A tutorial. *In Press, Corrected Proof*.
176. Hoffmann, U.; Vesin, J.-M.; Ebrahimi, T.; Diserens, K. An efficient P300-based brain-computer interface for disabled subjects. **2008**, *167*, 115-125.
177. Burges, C.J.C. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Min. Knowl. Discov.* **1998**, *2*, 121-167.
178. Xiang, L.; Dezhong, Y.; Wu, D.; 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.
179. 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.
180. Kayikcioglu, T.; Aydemir, O. A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data. **2010**, *31*, 1207-1215.
181. Garcia, G.N.; Ebrahimi, T.; Vesin, J.M. Support vector EEG classification in the Fourier and time-frequency correlation domains. In Proceedings of the First International IEEE EMBS Conference on Neural Engineering (NER'03), Capri Island, Italy, March 2003; pp. 591-594.
182. Blankertz, B.; Curio, G.; Müller, K. Classifying Single Trial EEG: Towards Brain Computer Interfacing. In Proceedings of the Advances in Neural Information Processing Systems (ANPS'02), Vancouver, BC, Canada, December 2002; pp. 157-164.
183. Garrett, D.; Peterson, D.A.; Anderson, C.W.; Thaut, M.H. Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. **2003**, *11*, 141-144.
184. Schlögl, A.; Lee, F.; Bischof, H.; Pfurtscheller, G. Characterization of four-class motor imagery EEG data for the BCI-competition 2005. *J. Neural Eng.* **2005**, *2*, L14.

REFERENCIAS

185. Rakotomamonjy, A.; Guigue, V. BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 1147-1154.
186. Haihong, Z.; Cuntai, G.; Chuanchu, W. Asynchronous P300-Based Brain-Computer Interfaces: A Computational Approach With Statistical Models. *IEEE Trans. Biomed. Eng.* **2008**, *55*, 1754-1763.
187. Kaper, M.; Meinicke, P.; Grossekhoefer, U.; Lingner, T.; Ritter, H. BCI competition 2003-data set IIb: support vector machines for the P300 speller paradigm. *IEEE Trans. Biomed. Eng.* **2004**, *51*, 1073-1076.
188. Meinicke, P.; Kaper, M.; Hoppe, F.; Heumann, M.; Ritter, H. Improving Transfer Rates in Brain Computer Interfacing: A Case Study. In Proceedings of the Advances in Neural Inf. Proc. Systems (NIPS'02), Vancouver, BC, Canada, December 2002; pp. 1107-1114.
189. Palaniappan, R. Brain Computer Interface Design Using Band Powers Extracted During Mental Tasks. In Proceedings of the Neural Engineering, 2005. Conference Proceedings. 2nd International IEEE EMBS Conference on, 16-19 March 2005 2005; pp. 321-324.
190. del R Millan, J.; Mourino, J.; Franze, M.; Cincotti, F.; Varsta, M.; Heikkonen, J.; Babiloni, F. A local neural classifier for the recognition of EEG patterns associated to mental tasks. **2002**, *13*, 678-686.
191. Nakayaman, K.; Inagaki, K. A Brain Computer Interface Based on Neural Network with Efficient Pre-Processing. In Proceedings of the Intelligent Signal Processing and Communications, 2006. ISPACS '06. International Symposium on, 12-15 Dec. 2006 2006; pp. 673-676.
192. Haselsteiner, E.; Pfurtscheller, G. Using time-dependent neural networks for EEG classification. **2000**, *8*, 457-463.
193. Millan, J.R.; Mourino, J. Asynchronous BCI and local neural classifiers: an overview of the adaptive brain interface project. **2003**, *11*, 159-161.
194. Coyle, D.; McGinnity, T.M.; Prasad, G. Improving the separability of multiple EEG features for a BCI by neural-time-series-prediction-preprocessing. **2010**, *5*, 196-204.
195. Specht, D.F. Probabilistic neural networks. *Neural. Netw.* **1990**, *3*, 109-118.
196. Bishop, C.M. *Neural networks for pattern recognition*, Oxford University Press: 1995.
197. Hazrati, M.K.; Erfanian, A. An online EEG-based brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network. **2010**, *32*, 730-739.
198. Ting, W.; Guo-zheng, Y.; Bang-hua, Y.; Hong, S. EEG feature extraction based on wavelet packet decomposition for brain computer interface. *Measurement* **2008**, *41*, 618-625.
199. Lemm, S.; Schafer, C.; Curio, G. BCI competition 2003-data set III: probabilistic modeling of sensorimotor mu rhythms for classification of imaginary hand movements. *IEEE Trans. Biomed. Eng.* **2004**, *51*, 1077-1080.
200. Blankertz, B.; Muller, K.R.; Curio, G.; Vaughan, T.M.; Schalk, G.; Wolpaw, J.R.; Schlogl, A.; Neuper, C.; Pfurtscheller, G.; Hinterberger, T.; Schroder, M.; Birbaumer, N. The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials. *IEEE Trans. Biomed. Eng.* **2004**, *51*, 1044-1051.
201. Schlögl, A.; Lee, F.; Bischof, H.; Pfurtscheller, G. Characterization of four-class motor imagery EEG data for the BCI-competition 2005. *J. Neural Eng.* **2005**, *2*, L14.

202. Schlogl, A.; Keinrath, C.; Scherer, R.; Furtscheller, P. Information transfer of an EEG-based brain computer interface. In Proceedings of the First International IEEE EMBS Conference on Neural Engineering (NER'03). 20-22 March 2003; pp. 641-644.
203. Wu, W.; Gao, Y.; Bienenstock, E.; Donoghue, J.P.; Black, M.J. Bayesian Population Decoding of Motor Cortical Activity Using a Kalman Filter. *Neural Comput.* **2006**, *18*, 80-118.
204. Lal, T.N.; Schörder, M.; Hill, N.J.; Preissl, H.; Hinterberger, T.; Mellinger, J.; Bogdan, M.; Rosenstiel, W.; Hofmann, T.; Birbaumer, N.; Schlkopf, B., A brain computer interface with online feedback based on magnetoencephalography. In *Proceedings of the 22nd international conference on Machine learning*, ACM: Bonn, Germany, 2005; pp 465-472.
205. Obermaier, B.; Neuper, C.; Guger, C.; Pfurtscheller, G. Information transfer rate in a five-classes brain-computer interface. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2001**, *9*, 283-288.
206. Kai Keng, A.; Zheng Yang, C.; Haihong, Z.; Cuntai, G. Composite Filter Bank Common Spatial Pattern for motor imagery-based Brain-Computer Interface. In Proceedings of the IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB'11), 11-15 April 2011; pp. 1-5.
207. Kai Keng, A.; Zheng Yang, C.; Haihong, Z.; Cuntai, G. Robust filter bank common spatial pattern (RFBCSP) in motor-imagery-based brain-computer interface. In Proceedings of the Engineering in Medicine and Biology Society, 2009 (EMBC'09). Annual International Conference of the IEEE, Minneapolis, MN, USA, 3-6 Sept. 2009; pp. 578-581.
208. Wojciech, S.; Carmen, V.; Klaus-Robert, M.; Motoaki, K. Stationary common spatial patterns for brain-computer interfacing. *J. Neural. Eng.* **2012**, *9*, 026013.
209. Thomas, K.P.; Cuntai, G.; Chiew Tong, L.; Vinod, A.P.; Kai Keng, A. A New Discriminative Common Spatial Pattern Method for Motor Imagery Brain Computer Interfaces. *IEEE Trans. Biomed. Eng.* **2009**, *56*, 2730-2733.
210. Gandhi, V.; Arora, V.; Behera, L.; Prasad, G.; Coyle, D.; McGinnity, T. EEG denoising with a recurrent quantum neural network for a brain-computer interface. In Proceedings of the International Joint Conference on Neural Networks (IJCNN'11) San Jose, CA, USA, July 31 2011-Aug. 5 2011 2011; pp. 1583-1590.