

UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN

DISEÑO DE MECANISMOS DE  
PROCESAMIENTO INTERACTIVOS PARA EL  
ANÁLISIS DE ONDAS CEREBRALES

PEDRO ALEJANDRO ORTEGA CABALLERO

2005

UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN

DISEÑO DE MECANISMOS DE PROCESAMIENTO  
INTERACTIVOS PARA EL ANÁLISIS DE ONDAS  
CEREBRALES

PEDRO ALEJANDRO ORTEGA CABALLERO

COMISIÓN EXAMINADORA	NOTA (n°)	CALIFICACIONES: (Letras)	FIRMA
PROFESOR GUÍA SR. ALEJANDRO BASSI	:	.....	.....
PROFESOR CO-GUÍA SR. CLAUDIO GUTIÉRREZ	:	.....	.....
PROFESOR INTEGRANTE SR. PABLO ESTÉVEZ	:	.....	.....
NOTA FINAL EXAMEN DE TÍTULO	:	.....	.....

MEMORIA PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL EN COMPUTACIÓN

SANTIAGO - CHILE  
MARZO - 2005

RESUMEN DEL INFORME FINAL  
PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL EN COMPUTACIÓN  
POR : PEDRO ALEJANDRO ORTEGA CABALLERO  
FECHA : 14/07/2005  
PROF. GUIA: SR. ALEJANDRO BASSI

## DISEÑO DE MECANISMOS DE PROCESAMIENTO INTERACTIVOS PARA EL ANÁLISIS DE ONDAS CEREBRALES

En este trabajo de memoria se presenta un algoritmo para la clasificación *on-line* de eventos dentro de un electroencefalograma (EEG) temporalmente difusos y que están contaminados por ruido. El instante de tiempo en que se inicia el evento es conocido. En particular, se pretende obtener en tiempo real una decisión rápida y confiable sobre la ocurrencia de tareas mentales predefinidas.

Para proveer una decisión probabilística para cada instante, el método acumula evidencia a lo largo del tiempo incorporando decisiones previas con una estrategia integrativa. Mediante el uso de filtrados de Wavelets *Morlet* se calculan intensidades de frecuencias localizadas en el tiempo para caracterizar la señal EEG. Las características son analizadas por una red neuronal que asigna probabilidades de pertenencia a cada una de las clases posibles. Posteriormente, estas clasificaciones instantáneas se unen en un sólo vector de clasificación dado por una combinación lineal, cuyos ponderadores reflejan el poder discriminativo en cada instante de tiempo. Este último se estima en base a la entropía asociada a cada clasificación instantánea.

Este procedimiento es aplicado para mejorar la capacidad de una interfaz *Cerebro-Computador*, tecnología de comunicación basada en señales cerebrales. El método de clasificación se utiliza para la detección de tareas mentales dentro de una señal EEG. Se compara la capacidad del canal de comunicación resultante con otros métodos de clasificación, obteniendo resultados promisorios.

Si bien la tasa de transferencia obtenida por medio del canal resultante no es suficiente para aplicaciones prácticas, el algoritmo propuesto constituye una aproximación robusta y flexible para el desarrollo de interfaces cerebro-computador portables, competitivo con las alternativas existentes en la literatura.

# Agradecimientos

Este trabajo de memoria es el resultado de más de un año de trabajo, y no podría haber sido llevado a cabo por mí sin la motivación y la ayuda de mucha gente que me ha acompañado durante mi estadía en la universidad. Con el presente trabajo, finalizo una etapa importante de mi vida, fruto principal del constante apoyo y confianza que siempre me han brindado mis seres queridos. Quiero darles las gracias, y dedicarles este trabajo. Todas las personas que he conocido en mi vida me han dado una lección importante, y hoy soy lo que ellos han hecho de mí.

Quiero agradecer especialmente a mi familia y a mi mejor amiga. A mi madre, por su cariño incondicional, su paciencia, su dedicación y constante apoyo: ha estado a mi lado en las buenas y en las malas, siempre dándome el ejemplo a seguir. Gracias por creer en mí. A mi padre, que me ha dado el ejemplo de esfuerzo, perseverancia, ética, y por enseñarme a reconocer el valor de las cosas simples que uno pasa por alto. A mis hermanas Carolina y Paulina, por su compañía, su cariño, sus enseñanzas y su gran sabiduría. A mi sobrina Danae y a mi cuñado Özden. A mi mejor amiga, Francisca, por su cariño, por ayudarme a crecer y luchar. Ella me ha abierto los ojos a ver el mundo como lo veo hoy. A todos ellos, quiero que sepan que siempre tendrán el lugar más especial en mi corazón.

También aprovecho esta oportunidad para agradecer a mis grandes amigos Paul, Banana y Gaete; a mis amigos de la infancia Michael, Jean-Claude, Michel, Pascuale, Luca, Matias, Zaklina, Renato Krpoun, Claudio Derungs, Nicole Farlitto, Toni Lambrinouidakis, Hugo Fernández, Emilio Sepúlveda, Andrea Stefanowsky; a mis amigos de la universidad Carolina Rousseau, Bernd Biedermann, Sebastián Beca, José Aliste, Michel Tesmer, Gonzalo Ruz, Cristián Figueroa, Claudia Rodríguez, Emilio Castro, Cristián Gutiérrez, Julio Quinteros, Alex Bórquez, Alex Vivanco, Álvaro Gálvez, al trio palta, José Donoso, mis amigos eléctricos, mis amigos matemáticos, y a la tía Sonia.

Finalmente, quiero dar las gracias a todos los profesores que me han acompañado durante mi formación académica. Me considero afortunado por haber contado siempre no sólo con grandes profesores, sino también con grandes personas. Quisiera destacar en particular a los profesores más influyentes en mi formación, que han depositado su confianza en mí y motivado mis estudios: Profa. Bachmann, Profa. Rothenfluh, Profa. Weisskopf, Prof. Steiner, Prof. Ernst, Profa. Vogt, Prof. Castro, Profa. Fariña, Prof. Gutiérrez, Prof. Bassi, Prof. Navarro y Prof. Estévez.

# Índice general

<b>1. Introducción</b>	<b>1</b>
1.1. Prerequisitos . . . . .	1
1.2. Contexto . . . . .	1
1.3. Objetivos . . . . .	3
1.4. Contribuciones . . . . .	4
1.5. Organización del Texto . . . . .	4
<b>2. Principios de la Electroencefalografía</b>	<b>6</b>
2.1. La Naturaleza de las Señales EEG . . . . .	6
2.2. Grupos de Señales EEG . . . . .	9
2.2.1. Beta . . . . .	9
2.2.2. Alfa . . . . .	10
2.2.3. Mu . . . . .	11
2.2.4. Teta . . . . .	11
2.2.5. Delta . . . . .	11
2.2.6. Gama . . . . .	11
2.3. Patrones Básicos . . . . .	12
2.3.1. Promediación . . . . .	12
2.3.2. Configuración del Montaje . . . . .	13
<b>3. Estado del Arte de la Tecnología BCI</b>	<b>15</b>
3.1. Descripción del Sistema . . . . .	15
3.2. Señales Neurofisiológicas Utilizadas en Aplicaciones BCI . . . . .	17
3.2.1. Métodos Implantados . . . . .	18
3.2.2. Potenciales Evocados . . . . .	18
3.2.3. Condicionamiento Operante . . . . .	21
3.3. Sistemas Existentes . . . . .	24
3.3.1. Brain Response Interface . . . . .	24
3.3.2. Dispositivos Implantados . . . . .	25
3.3.3. ERS/ERD Cursor Control . . . . .	26
3.3.4. Flexible Brain Computer Interface . . . . .	26

3.3.5.	Mu Wave Cursor Control . . . . .	27
3.3.6.	P3 Character Recognition . . . . .	27
3.3.7.	SSVEP BCI . . . . .	27
3.3.8.	Thought Translation Device . . . . .	28
<b>4.</b>	<b>Adquisición y Procesamiento</b>	<b>29</b>
4.1.	Descripción de OpenBCI . . . . .	29
4.2.	Adquisición . . . . .	31
4.2.1.	Dispositivo de Adquisición . . . . .	31
4.2.2.	Registro de Trials . . . . .	32
4.3.	Preprocesamiento . . . . .	34
4.3.1.	Artefactos EEG . . . . .	35
4.3.2.	Eliminación del Ruido de la Red Eléctrica . . . . .	37
4.3.3.	Filtrado Pasa-Banda . . . . .	37
4.3.4.	Detección de Artefactos Oculares y Musculares . . . . .	38
4.4.	Extracción de Características . . . . .	42
4.4.1.	Filtrado Morlet . . . . .	43
4.4.2.	Descarte de Outliers . . . . .	48
4.4.3.	Normalización . . . . .	51
4.4.4.	Selección de Características . . . . .	51
<b>5.</b>	<b>Clasificación</b>	<b>53</b>
5.1.	Proceso de Clasificación . . . . .	55
5.2.	Clasificación Instantánea . . . . .	57
5.3.	Red Neuronal Multicapa . . . . .	59
5.3.1.	Conjunto de Entrenamiento . . . . .	59
5.3.2.	Arquitectura . . . . .	60
5.3.3.	Funciones Vectoriales y Criterios de Error . . . . .	61
5.3.4.	Entrenamiento . . . . .	64
5.3.5.	Otras Consideraciones . . . . .	64
5.4.	Integración Temporal . . . . .	66
5.4.1.	Entropía de Clasificación . . . . .	67
5.4.2.	Beneficios del Diseño . . . . .	68
<b>6.</b>	<b>Simulación y Resultados</b>	<b>70</b>
6.1.	BCI Competition 2003 . . . . .	70
6.1.1.	Datos de Graz . . . . .	71
6.1.2.	Requerimientos . . . . .	72
6.1.3.	Evaluación . . . . .	72
6.1.4.	Competidores . . . . .	73
6.1.5.	Configuración de <i>OpenBCI</i> . . . . .	74
6.1.6.	Resultados . . . . .	75

## ÍNDICE GENERAL

---

6.1.7. Discusión . . . . .	79
6.2. Primeras Pruebas con un Sistema Prototipo . . . . .	80
6.2.1. Breve Descripción del Sistema . . . . .	81
6.2.2. Experimentos . . . . .	82
6.2.3. Resultados . . . . .	85
6.2.4. Discusión . . . . .	86
6.3. Evaluación General . . . . .	87
<b>7. Conclusiones</b>	<b>89</b>
7.1. Principales Logros . . . . .	89
7.2. Observaciones Críticas . . . . .	90
7.3. Recomendaciones para Trabajos Futuros . . . . .	91
<b>A. Nociones Básicas de Teoría de Sistemas Lineales</b>	<b>93</b>
A.1. Sistemas Lineales Invariantes en el Tiempo . . . . .	93
A.2. Función de Transferencia . . . . .	94

# Índice de figuras

2.1.	Esquema general de un electrodo. . . . .	7
2.2.	Segmento de un EEG multicanal. . . . .	8
2.3.	El sistema 10-20 de posicionamiento de electrodos. . . . .	8
2.4.	Distribución de la actividad cerebral. . . . .	9
2.5.	Grupos de Señales EEG. . . . .	10
2.6.	Esquema de los hemisferios del cerebro. . . . .	12
2.7.	Ejemplo de Promediación. . . . .	14
3.1.	Arquitectura básica de un BCI. . . . .	17
3.2.	Componente P3. . . . .	20
3.3.	ERD de imaginaria de movimiento de mano. . . . .	23
4.1.	Arquitectura detallada de OpenBCI. . . . .	30
4.2.	Un dispositivo <i>ModularEEG</i> . . . . .	32
4.3.	Estructura de un <i>trial</i> . . . . .	34
4.4.	Artefacto de parpadeo. . . . .	36
4.5.	Artefacto de movimiento ocular. . . . .	36
4.6.	Artefacto muscular. . . . .	37
4.7.	Comparación entre una señal EEG antes y después del filtrado pasa-banda. . . . .	39
4.8.	Filtro pasa-banda. . . . .	40
4.9.	Conjunto de densidades espectrales de potencia. . . . .	41
4.10.	Wavelet <i>Morlet</i> . . . . .	44
4.11.	CWT de una señal de ejemplo. . . . .	45
4.12.	CWT de un <i>trial</i> EEG. . . . .	46
4.13.	Discretización de la onda <i>Morlet</i> . . . . .	47
4.14.	Medidas de distancia. . . . .	50
5.1.	El proceso de clasificación de <i>OpenBCI</i> . . . . .	56
5.2.	Dependencia temporal de un TM. . . . .	58
5.3.	Distorsión temporal ( <i>Time warping</i> ) . . . . .	58
5.4.	Mapeo a regiones suaves en espacio-tiempo continuo. . . . .	59
5.5.	Red neuronal de dos capas de pesos. . . . .	60
5.6.	Funciones de Activación . . . . .	62

## ÍNDICE DE FIGURAS

---

5.7. Diagrama de modos de uso del BCI. . . . .	66
6.1. Datos de Graz. . . . .	71
6.2. Características extraídas para los datos de Graz. . . . .	76
6.3. Series de Tiempo Resultantes, Datos de Graz. . . . .	77
6.4. Comparación de la Evolución Temporal de la Información Mutua. . . . .	78
6.5. Captura de Pantalla de <i>ABI</i> . . . . .	81
6.6. Rotación de Objeto 3D. . . . .	84
6.7. Montaje de los Electrodo y Estructura de un <i>Trial</i> , Experimento 2. . . . .	84

# Índice de cuadros

3.1. Señales electrofisiológicas utilizadas. . . . .	19
3.2. Sistemas existentes [3]. . . . .	25
4.1. Coeficientes del filtro pasa-banda. . . . .	39
5.1. Forma de las subfunciones del clasificador instantáneo. . . . .	61
6.1. Participantes de la competencia <i>BCI Competition III</i> , Datos de Graz. .	74
6.2. Resumen de resultados y <i>ranking</i> , Datos de Graz. . . . .	79

# Capítulo 1

## Introducción

### 1.1. Prerequisitos

El autor ha intentado elaborar una memoria que sea lo más autocontenida posible. Este objetivo resultó complicado, sobre todo porque el trabajo desarrollado consta de métodos que provienen de distintos temas de investigación. En particular, se ha evitado profundizar en todas las facetas asociadas a la electroencefalografía, o en el planteamiento de marcos formales más generales de lo necesario. Es decir, se pretendió enunciar lo justo y necesario para introducir al lector al área de diseño de sistemas de comunicación basados en señales electrofisiológicas, más precisamente, en señales eléctricas capturadas a partir del cuero cabelludo. La comprensión del texto, si bien requiere del conocimiento de materia básica de ingeniería, puede verse beneficiado por un conocimiento más profundo de técnicas de procesamiento de señales y de aprendizaje de máquinas.

### 1.2. Contexto

La interacción humano-computador es un área de investigación que ha crecido constantemente durante los últimos años. Se han desarrollado numerosas tecnologías que utilizan canales de comunicación novedosos, como voz, visión y háptica, y que se suman a los tradicionales basados en dispositivos de operación manual como es el teclado y el mouse [3].

En la última década han emergido líneas de investigación que se centran en la utilización de *señales cerebrales eléctricas* como vía de comunicación [1, 2, 3, 18, 9, 11, 23, 31]. La motivación principal de estos estudios se fundamenta en el apoyo de personas con enfermedades neuromusculares severas proviéndolas con nuevos canales de comunicación. Una serie de descubrimientos científicos y adelantos tecnológicos en neurociencia, psicología, procesamiento de señales, aprendizaje de máquinas y en equipos computacionales han permitido el desarrollo de interfaces cerebro-computador o BCIs,

## CAPÍTULO 1. INTRODUCCIÓN

---

siglas que provienen del inglés *Brain-Computer Interfaces*. Un BCI es un sistema de comunicación basado exclusivamente en señales cerebrales [2, 3, 18, 25].

Como sistema de comunicación, un BCI consta de *entradas*, *salidas*, elementos que *realizan la transformación*, y un *protocolo* [18]. En este caso, las entradas están dadas por las señales cerebrales emitidas por el operador que son monitoreadas por el sistema, procesadas, y convertidas a acciones o respuestas de control. Esto se traduce, por ejemplo, en la operación de una aplicación para escribir, o en la maniobra de una silla de ruedas.

Un sujeto opera el sistema por medio de la realización de tareas mentales (TMs) que son asociadas a acciones que dependen del sistema en cuestión. La asociación entre las TMs y la acción se basa en el reconocimiento de un patrón en la actividad cerebral emergente que permita identificarlo en forma única.

La actividad cerebral da origen a una serie de fenómenos que pueden ser registrados utilizando sensores adecuados. Dentro de éstos, los *electroencefalógrafos*, que registran potenciales eléctricos en la superficie del cuero cabelludo llamados *electroencefalogramas* (EEG) [4], corresponden a una fuente atractiva de señales cerebrales para el diseño de un BCI. El método de obtención de EEGs es no-invasivo, simple, y los equipos son de costo relativamente bajo [3, 10].

La elección de las TMs se basa en estudios que muestran que el cerebro presenta una especialización regional. Hay trabajos que afirman que los hemisferios cerebrales están involucrados en funciones cerebrales distintas. Por ejemplo, el procesamiento espacial se asocia al hemisferio derecho, mientras que el izquierdo a actividades verbales y de análisis. Por tanto, se utilizan TMs como respuestas cerebrales evocadas por estímulos externos, imaginación de movimiento de extremidades, operaciones aritméticas, geométricas, verbales y espaciales [3, 18].

En concordancia con las TMs, los sistemas BCI pueden categorizarse como basados en *potenciales evocados* (PE) o en *condicionamiento operante*. En el caso de los BCI basados en PEs, el operador se concentra en los estímulos presentados por el sistema para gatillar una respuesta deseada. En el caso de condicionamiento operante, el sujeto aprende a generar actividad cerebral que sea reconocida y traducida apropiadamente por el BCI.

Por otro lado, un BCI puede ser *síncrono* o *asíncrono*: un sistema *síncrono* opera a determinadas tasas de tiempo que pueden definirse en base al operador y el sistema, mientras que un sistema *asíncrono* reacciona sólo cuando el sujeto genera el estímulo apropiado.

### 1.3. Objetivos

Actualmente, el uso de señales EEG como medio de comunicación entre humano y computador representa uno de los desafíos más importantes para la teoría de procesamiento de señales [25, 33]. El objetivo principal consiste en encontrar métodos que sean capaces de caracterizar actividad cerebral.

Las señales EEG poseen una serie de propiedades que las hacen particularmente difíciles de analizar. Su naturaleza estocástica y la escasez de patrones que puedan ser percibidos por el ojo humano, requieren de nuevos métodos de análisis. A pesar de los numerosos avances que se han logrado en la última década en el área de procesamiento de señales, ninguno de ellos ha obtenido un rendimiento suficiente para la implementación de un BCI en tiempo real [25, 18].

Por otro lado, también existen restricciones prácticas en el diseño de un BCI exitoso, y en particular, de usabilidad. Un sistema bien puede poseer una tasa de error muy reducida, pero si requiere el uso de un número muy elevado de electrodos, o si provoca el agotamiento del operador debido a un protocolo inadecuadamente diseñado, tampoco puede ser considerado exitoso.

En vista de lo anterior, el objetivo del presente trabajo consiste en el diseño de un *sistema de clasificación* para un BCI que cumpla con las siguientes características:

1. *Genérico*: gran parte de los sistemas BCI actualmente bajo desarrollo poseen limitaciones en el número máximo de clases que pueden discriminar, o están diseñados para la detección de TMs bien particulares. En el trabajo presente se persigue el desarrollo de un clasificador genérico y flexible.
2. *Eficiente*: el sistema debe ser económico, requiriendo pocos recursos en tiempo y espacio. Son raros los BCIs actuales que representan un compromiso entre calidad de clasificación y eficiencia computacional.
3. *Interactivo*: este atributo deseable se refiere a la capacidad del sistema de otorgar información *on-line* sobre el estado de clasificación, de manera de proveer un *feedback* que sirva como guía para el usuario durante la ejecución de una TM.
4. *Robusto*: el sistema debe ser tolerante ante la presencia de la contaminación de las señales EEG (artefactos).
5. *Portable*: bajo el contexto de esta memoria, la portabilidad se refiere a la capacidad de utilizar el sistema BCI fuera de un ambiente de laboratorio. En particular, debe perseguir el cumplimiento de requisitos que lo conviertan en un sistema apto para ser incorporado en un BCI de uso público.

6. *Número de electrodos*: el número de electrodos que el sistema debe utilizar para la clasificación debe ser reducido. Una cota razonable consiste en el uso de un máximo de ocho electrodos.

Además, los BCIs corresponden a una tecnología cuya investigación se ha iniciado muy recientemente. En Chile, el autor no conoce trabajos de investigación relacionados con el tema. En vista de este hecho, es responsabilidad del presente trabajo proveer una base asequible para futuras investigaciones.

Una primera aproximación para la validación del diseño consiste en compararlo con *benchmarks* establecidos, y en la realización de pruebas con un software y hardware prototipo. Sin embargo, esta implementación no constituye el núcleo de este trabajo de memoria.

### 1.4. Contribuciones

En la memoria, se desarrolló un sistema de clasificación de señales EEG muy sencillo. El sistema hace uso de nociones básicas de la electroencefalografía [4]. Además, integra una serie de técnicas heterogéneas: métodos de procesamiento de señales conocidos bajo el nombre de *análisis en tiempo y frecuencia* [37, 38, 18], en particular de las *Wavelets* [39, 40, 41]; uso de la entropía para la estimación del contenido de información [6, 7, 20]; y técnicas de redes neuronales como modelos entrenables que se emplean para la clasificación [45, 46, 47, 48, 49].

El método desarrollado se pone a prueba sobre un conjunto de datos de *benchmark* [31, 32, 33], comparándolo con otros clasificadores, y obtiene los mejores resultados. El conjunto de datos fue escogido porque el problema asociado es genérico en su forma y exigente en su planteamiento.

Para probar el desempeño del sistema bajo condiciones de uso doméstico, se implementó un prototipo funcional que opera en conjunto con un sistema de adquisición de señales EEG de bajo costo [10]. Se experimentó con la aplicación resultante, y se publicó en la Web [10], bajo la licencia de distribución *GPL*. Ésta es la primera aplicación orientada a un público general.

### 1.5. Organización del Texto

La organización del texto sigue las líneas generales de los trabajos relacionados [3, 25, 18] con el aprendizaje de máquinas aplicados en el diseño de un BCI. La estructura de lo que resta de esta memoria es la que se describe a continuación.

## CAPÍTULO 1. INTRODUCCIÓN

---

*Capítulo 2:* Este capítulo explica lo básico sobre naturaleza de las señales EEG, i.e. cómo se capturan, cuál es su forma, dónde se originan, y cómo se relacionan con la actividad cerebral de un ser humano.

*Capítulo 3:* En este capítulo se presenta el estado del arte de la tecnología de clasificación de señales EEG para su uso en un BCI. Se explica la arquitectura general de estos sistemas, las señales utilizadas para el propósito de control, y una breve presentación de los sistemas existentes. El capítulo finaliza con el enunciado de la arquitectura del sistema desarrollado en este trabajo.

*Capítulo 4:* Aquí se ahonda en las técnicas específicas de procesamiento de señales utilizadas en el sistema. Esta detalla la tarea de preprocesamiento necesaria para disminuir su contaminación y la extracción de las características que el sistema de clasificación utilizará para decidir las acciones a llevar a cabo.

*Capítulo 5:* El núcleo de este trabajo lo conforma el sistema de clasificación de las señales EEG, que se describe en forma extensa en este capítulo.

*Capítulo 6:* Se realizaron simulaciones del sistema de clasificación y se presentan los resultados. Aquí se describen un total de tres simulaciones, la primera basada en un conjunto de *benchmark*, las dos siguientes sobre un prototipo desarrollado.

*Capítulo 7:* Este último capítulo presenta las conclusiones realizadas a partir del trabajo realizado.

# Capítulo 2

## Principios de la Electroencefalografía

### 2.1. La Naturaleza de las Señales EEG

Mucho se ha descubierto sobre la naturaleza de las señales EEG, pero todavía persisten muchos misterios [4, 7]. Como un BCI se alimenta a partir de señales cerebrales, el conocimiento de la naturaleza de éstas cumple un rol muy importante en el diseño del sistema [3]. Por un lado, esto permite la selección de las señales que contienen la información apropiada, y por otro, apoya el diseño de los algoritmos de procesamiento y extracción de características. La falta de conocimiento de la naturaleza de las señales EEG impide el diseño de una BCI, ya que se ha mostrado en estudios que la utilización de técnicas tradicionales de procesamiento de señales no bastan para generar resultados aceptables.

Un *electroencefalograma* es un registro de potenciales eléctricos del cerebro. Éstos se adquieren a partir de sensores llamados *electrodos* (Figura 2.1) que se fijan sobre el cuero cabelludo del sujeto. La función de un electrodo consiste en recoger pasivamente potenciales eléctricos provenientes de *bancos de neuronas* que se ubican principalmente en la corteza cerebral. El nivel de estas señales es del orden de los microvolts. La razón señal a ruido debe mantenerse lo más alta posible durante esta adquisición. Es por esta razón que un electrodo se construye a partir de material altamente conductor como oro (Au), plata (Ag), o cloruro de plata (AgCl). Además, entre la piel del sujeto y el electrodo se utilizan pastas conductoras para asegurar una buena conexión. Últimos avances en esta tecnología han dado origen a los *electrodos activos*, que poseen un microcircuito eléctrico en el propio electrodo para mejorar la calidad de la señal adquirida. Tras la captura del potencial eléctrico, éste es amplificado por un factor del orden de veinte mil, y luego, digitalizado.

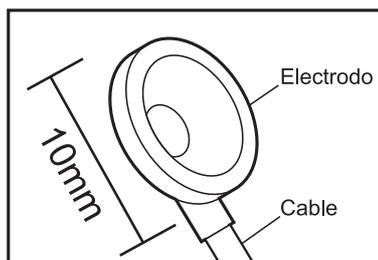


Figura 2.1: Esquema general de un electrodo.

Los electrodos son copas de metal conductor de un diámetro aproximado de 8 a 10 mm.

La configuración de los electrodos generalmente sigue el sistema internacional 10-20 que se ha establecido como estándar (Figura 2.3) [3, 25, 18]. El uso de un mayor número de electrodos resulta en un incremento de la resolución espacial de la señal obtenida. También ha propuesto un sistema 10-20 extendido con un número mayor de posiciones. Generalmente, se trabaja con dos clases de montajes: los *referenciales* y los *bipolares*. Los montajes referenciales calculan su potencial eléctrico con respecto a un electrodo referencial, que se ubica preferentemente en una zona eléctricamente neutra, o inactiva, como el *mastoide*<sup>1</sup> o la oreja. En cambio, en los montajes bipolares, un canal EEG se calcula en base a la diferencia de potencial entre un par de electrodos.

Se piensa que una señal EEG es el resultado de la superposición de potenciales eléctricos producidos por la actividad sináptica sincronizada de bancos de neuronas, principalmente ubicados en la zona cortical del cerebro [4, 3, 18]. En su formación, no todas las actividades cerebrales tienen el mismo impacto. Factores que influyen en la forma de una onda particular son la profundidad, la orientación y la simetría de las conexiones de la zona cerebral activa. Un ejemplo de señales EEG puede apreciarse en la figura 2.2.

Para el análisis clínico de señales EEG, el lector debe fijarse en propiedades tales como: forma de la onda, frecuencia, amplitud, distribución espacial, relación de fase, sincronización, persistencia y reactividad [3]. Un BCI puede usar mediciones de estas propiedades para su operación. En las señales EEG pueden apreciarse formas de onda regulares, como sinusoides, pero también otras aperiódicas y con formas irregulares.

Las frecuencias de interés se hallan en la banda entre 0.1 Hz y 40 Hz. Existen bandas que aparentemente están asociadas a distintas funciones cerebrales, por lo que la frecuencia corresponde a uno de los criterios más importantes en la investigación de señales EEG.

---

<sup>1</sup>El hueso ubicado detrás de la oreja.

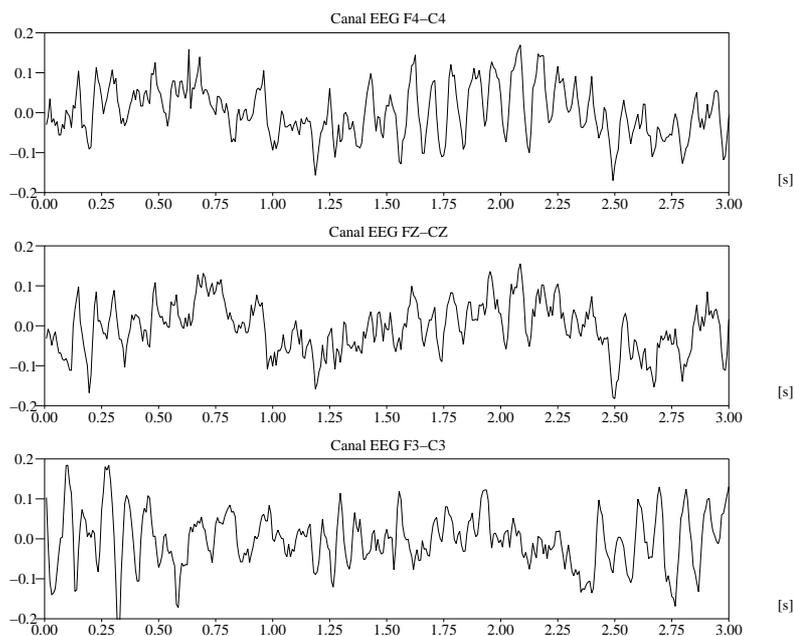


Figura 2.2: Segmento de un EEG multicanal.

El segmento corresponde a un EEG multicanal bipolar de un sujeto durante la imaginación de movimiento de brazo izquierdo.

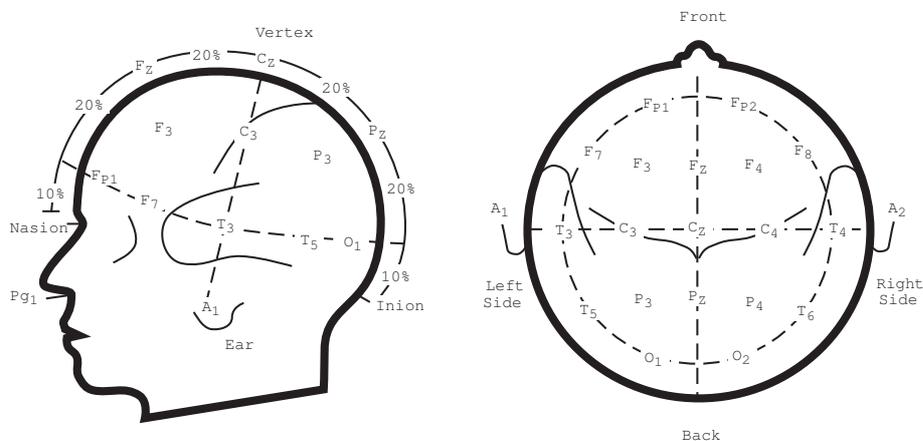


Figura 2.3: El sistema 10-20 de posicionamiento de electrodos.

Cada lóbulo se identifica por medio de una letra, más un número u otra letra que identifica la localización específica y el hemisferio. Las letras F, T, P, C, O corresponden a *frontal*, *temporal*, *parietal*, *central* y *occipital*, respectivamente. Los números impares se ubican en el hemisferio izquierdo, los pares en el hemisferio derecho.

Otra característica de gran importancia es la distribución espacial de una señal EEG. Como generalmente hay varios electrodos que cubren simultáneamente diferentes zonas de la cabeza, una señal particular puede manifestarse en distintos canales, en forma distribuída, o en caso contrario, focalizada (Figura 2.4) [5, 18, 17, 21].

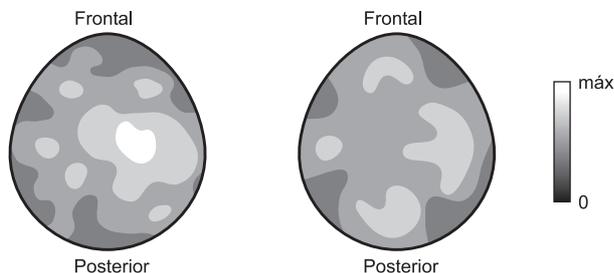


Figura 2.4: Distribución de la actividad cerebral.

La distribución de una señal EEG puede abarcar varias regiones de la corteza cerebral. En estas dos ilustraciones se aprecian dos ejemplos de la magnitud de la banda de frecuencia en torno a los 10Hz para un mismo sujeto durante la imaginación de movimiento de brazo izquierdo.

Mientras que existen descriptores obvios de las señales EEG como los anteriormente mencionados, hay otros que han generado controversia en la comunidad EEG. En particular, no se sabe si el sistema es lineal o no-lineal. Tampoco se conoce el nivel de caos presente. Por otro lado, se ha mostrado en estudios que la señal EEG es estocástica en su naturaleza. Por ejemplo, es difícil diseñar descriptores que se mantengan aproximadamente constantes en dos intentos de una misma TM. A las dificultades anteriores se le suma el hecho del nivel de contaminación de un EEG es alto, debido a distintos tipos de *artefactos* que pueden interferir la señal, como artefactos oculares, musculares, cardiológicos, de la conectividad del electrodo y de la red de alimentación eléctrica.

## 2.2. Grupos de Señales EEG

Como el análisis de las señales cerebrales es complejo, existe una terminología extensa para denotar los distintos fenómenos que se aprecian en ellas. Las distintas ondas pueden clasificarse según sus bandas de frecuencia. Si bien nunca se presentan en forma aislada, las distintas actividades cerebrales y estados mentales pueden pronunciar algunas de estas ondas. En particular, existen seis grupos de ondas importantes (Figura 2.5) [3, 25, 18].

### 2.2.1. Beta

Las *ondas Beta* se encuentran en el rango de frecuencias entre 12 Hz y 30 Hz. Su voltaje es usualmente bajo, cercano a los 5-30  $\mu V$ . *Beta* generalmente se asocia a pen-

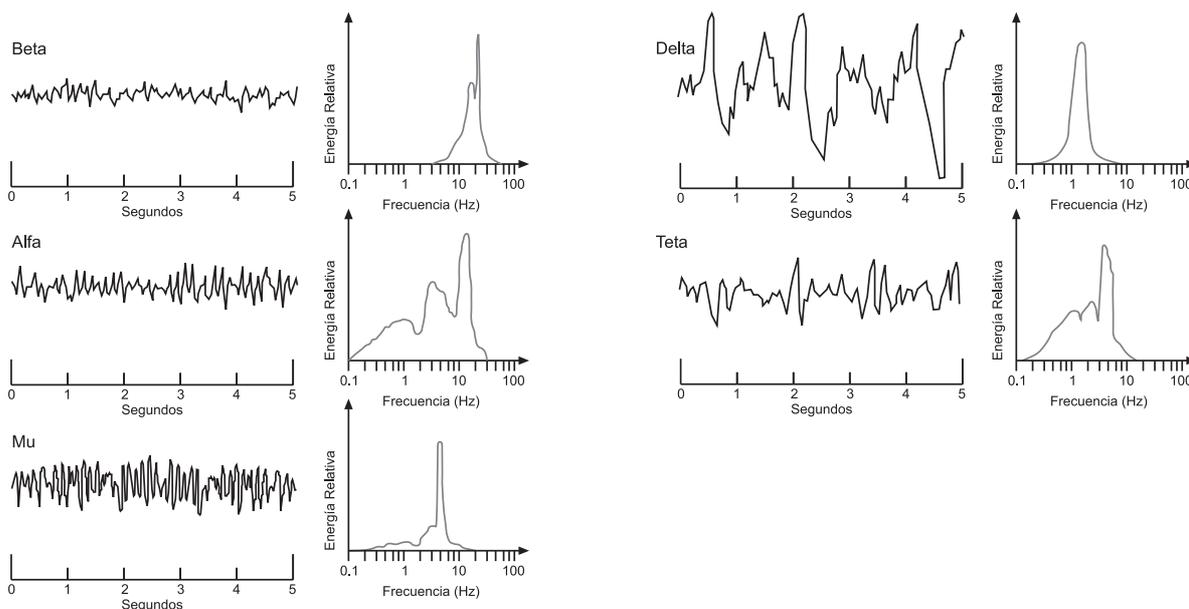


Figura 2.5: Grupos de Señales EEG.

Comparación de ondas *Beta*, *Alfa*, *Mu*, *Delta* y *Teta*. Cada grupo presenta una distribución de energía distinta en el dominio de las frecuencias.

samiento activo, estado de alerta y resolución de problemas. Durante actividades mentales intensas puede alcanzar hasta los 50 Hz. Esta onda ocurre principalmente en el lóbulo frontal y parietal.

### 2.2.2. Alfa

Las *ondas Alfa* se encuentran en el rango de frecuencias entre los 8 Hz y 12 Hz, con amplitudes generalmente superiores a los  $20 \mu V$ . Las ondas *Alfa* se asocian a inactividad cerebral, desconcentración y relajación. En algunas oportunidades se han observado ondas *Alfa* que alcanzan los 20 Hz, pasando por el rango normalmente asociado a ondas *Beta*. Éstas han sido determinadas como tales debido a que han aparecido con características y en circunstancias que descartan la posibilidad de tratarse de actividad *Beta*. Ondas *Alfa* se manifiestan principalmente en el lóbulo occipital (posiciones *O*) y frontal (posiciones *F*), y pueden reducirse abriendo los ojos, presentando estímulos no familiares al sujeto, ansiedad, y por medio actividad mental intensa. La presencia exclusiva de ondas *Alfa* refleja ausencia de actividad mental más que pasividad. Estudios han mostrado que este ritmo se origina entre la zona cortical y algunos núcleos talámicos a partir de la descarga sincrónica de grandes bancos de neuronas.

### 2.2.3. Mu

Las *ondas Mu* son ondas espontáneas que se encuentran en la banda de frecuencia entre 8 Hz y 13 Hz, igual que las ondas *Alfa*. Ellas se registran principalmente en la zona sensorimotora (posiciones *C*, ver figura (2.6)), manifestando una *atenuación* durante movimiento o intento de movimiento de extremidades.

### 2.2.4. Teta

Las *ondas Teta* se encuentran en el rango de frecuencias entre 4 Hz y 8 Hz, y poseen amplitudes que generalmente superan los 20  $\mu V$ . *Teta* se asocia a estados emocionales de estrés, como decepción o frustración, y sueño REM<sup>2</sup>. También se ha mostrado que está relacionada a funciones mentales que involucran el acceso a material subconsciente, meditación profunda e inspiración creativa.

### 2.2.5. Delta

Las *ondas Delta* se ubican en el rango de frecuencias entre 0.5 Hz y 4 Hz con amplitud variable. Éstas se manifiestan principalmente durante sueño profundo, o en ciertos estados de meditación. Los casos en que se presencia en estado de vigilia indican defectos o daños cerebrales. Es fácil confundir actividad *Delta* con artefactos musculares, como por ejemplo aquellos producidos por los músculos de la nuca. Sin embargo, un sistema BCI en línea puede discriminar fácilmente entre una onda *Delta* y una respuesta muscular, ya que la primera se origina profundamente en el cerebro y es severamente atenuada, mientras que la segunda presenta amplitudes mucho mayores.

### 2.2.6. Gama

Las *ondas Gama* se encuentran desde los 30 Hz hacia arriba. Se piensa que éstas reflejan el mecanismo subyacente de la conciencia. Se ha observado que las ondas *Gama* están asociadas a procesos de comunicación, *feedback* y sincronización entre las distintas zonas neuronales durante la realización de actividades mentales complejas.

La mayoría de los diseños de BCIs se basan en el monitoreo de las ondas *Alfa* y *Mu*, principalmente debido a que las personas pueden aprender a controlar su amplitud realizando tareas mentales apropiadas [18]. Por ejemplo, la onda *Alfa* puede atenuarse evocando una imagen muy estimulante, y la onda *Mu* por medio de intento de movimiento de los dedos.

---

<sup>2</sup>Estado de sueño que se caracteriza por movimientos oculares rápidos

Dado que ondas más lentas como *Delta* y *Teta* están más bien asociadas a estados mentales emocionales y de sueño, son muy difíciles de controlar, e incluso, inapropiados. Por otro lado, las ondas *Gama*, debido a su rol coordinador entre regiones cerebrales, presentan una distribución espacial muy amplia, y exigen métodos de alta resolución y sincronización temporal para su medición. Estas son exigencias muy difíciles de cumplir, considerando la naturaleza difusa de las señales EEG.

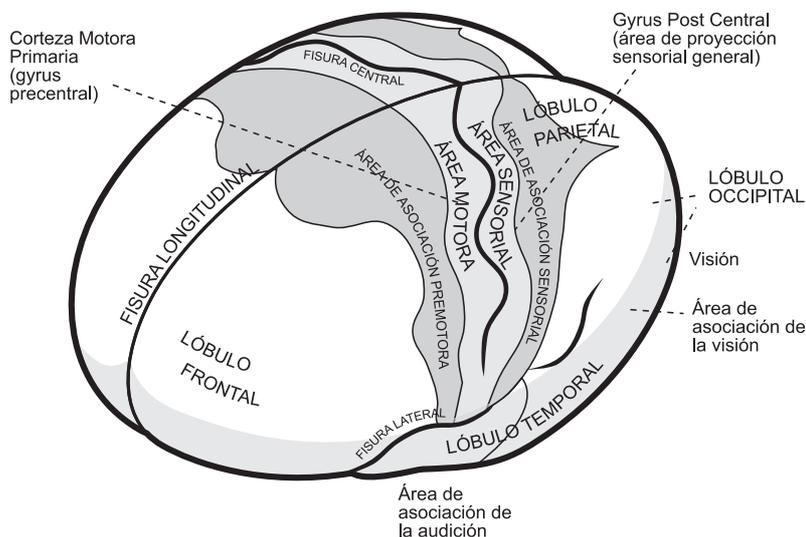


Figura 2.6: Esquema de los hemisferios del cerebro.

Se pueden apreciar las zonas motoras (más hacia el frente) y sensoriales (más hacia la parte posterior).

### 2.3. Patrones Básicos

En investigaciones usualmente se aplican algunas técnicas y consideraciones básicas para el descubrimiento de patrones en las señales EEG. Éstas constituyen excelentes ejemplos ilustrativos para comprender su naturaleza.

#### 2.3.1. Promediación

El descubrimiento de una onda característica involucrada durante la realización de una TM requiere del registro de muchos segmentos<sup>3</sup> EEG (llamados *trials*). Como el filtrado sólo sirve para mejorar lo que es originalmente una relación señal-ruido muy pobre, y como no es suficiente para extraer un patrón EEG de la actividad de fondo, se

<sup>3</sup>No se ha encontrado una traducción apropiada para la palabra *trial* en este contexto, por lo que se usará el término inglés durante el texto.

requiere un procesamiento adicional. La *promediación* es el método de procesamiento más común (Figura 2.7) [3]. Las ventajas de éste método son:

1. Se reduce la contribución de señales EEG no relacionadas.
2. Se reduce el ruido.
3. Permite la observación de una señal característica, la cual es inobservable en un solo *trial* de la TM.

Las suposiciones en que está basada la promediación de la señal son que una TM dada provocará esencialmente la misma onda cada vez que es realizada, y que este patrón se suma con la actividad de fondo, la cual es totalmente esporádica con respecto a la TM.

El método de promediación de señales no procesadas tiene la desventaja de cancelar formas de onda de alta frecuencia, como puede observarse en la figura (2.7), debido a que es difícil alinear los *trials* perfectamente. Por esta razón, en general se emplea este método en la detección de potenciales evocados, los cuales tienen componentes de frecuencia más bajas. Una extensión de esta idea es realizar la promediación sobre características extraídas de la señal que están menos localizadas en el tiempo.

### 2.3.2. Configuración del Montaje

Para la detección de un patrón EEG asociado a una TM, la ubicación de los electrodos es fundamental. Una configuración mal escogida puede no estar registrando una actividad cerebral relacionada.

Estudios han mostrado que ciertas TM están localizadas, y sugieren configuraciones de arreglos de electrodos adecuadas para su monitoreo. Por ejemplo, la ubicación de dos pares de electrodos en las posiciones próximas a  $C_3$  y  $C_4$  permiten registrar fenómenos de sincronización asociadas a la intención de movimiento de brazo izquierdo y derecho. Por otro lado, también se han detectado TMs que manifiestan actividad cerebral distinta entre las personas.

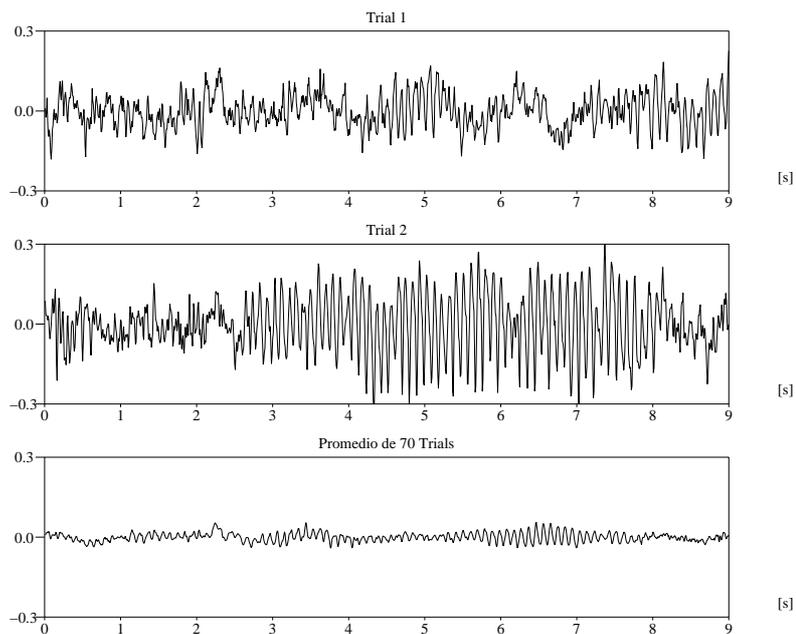


Figura 2.7: Ejemplo de Promediación.

Comparación entre dos *trials* distintos de imaginación de movimiento de brazo izquierdo a partir de los 3 segundos, con el *trial* resultante de promediar 70 *trials* distintos. En general dos *trials* distintos no presentan similitud evidente.

# Capítulo 3

## Estado del Arte de la Tecnología BCI

### 3.1. Descripción del Sistema

Un BCI es un sistema que registra y analiza señales neuronales con el objetivo de crear un canal de comunicación directo entre el cerebro y el computador. Este canal tiene múltiples posibles aplicaciones:

1. *Bioingeniería*: proveen un canal de comunicación para personas discapacitadas.
2. *Monitoreo de actividad cerebral*: anomalías en el sueño, enfermedades neurológicas, supervisión de estado de alerta y estado mental en general.
3. *Neurociencia*: métodos en tiempo real para la investigación de la dependencia entre señales cerebrales registradas y el comportamiento observable.
4. *Interacción hombre-máquina*: interfaces entre hombre y computador, herramienta, o vehículo.

En general, un BCI basado en señales EEG es un canal de comunicación lento en comparación con acciones humanas normales, debido a la complejidad y el nivel de contaminación de las señales utilizadas, como también al tiempo requerido para completar el procesamiento y la clasificación.

La utilización de EEG para la realización de tareas sencillas, como un control discreto, es extremadamente difícil, ya que las señales son muy pequeñas y están embebidas en ruido. Para que el sistema pueda ser considerado un BCI genuino, éste debe utilizar solamente señales provenientes del cerebro y tratar toda señal adicional, como el

*electrocardiograma*<sup>1</sup> (ECG), *electromiograma*<sup>2</sup> (EMG) y las señales externas al sujeto, como ruido.

Los BCIs actuales utilizan la actividad EEG para realizar tareas como controlar el movimiento de un cursor, seleccionar letras o íconos, u operar una neuroprótesis. El elemento central de un BCI es un algoritmo de transformación que convierte la señal cerebral del operador en respuestas que controlan dispositivos externos. La operación de un BCI depende de la interacción efectiva de dos agentes controladores adaptivos: el sujeto que codifica su control dentro de la señal electrofisiológica que alimenta al BCI, y el computador que reconoce el comando contenido en su entrada y lo traduce en el control de un dispositivo.

En el presente, los BCI alcanzan tasas de transferencia entre 5 hasta 25 bits por minuto [1, 25, 34]. El incremento de la rapidez y precisión depende de avances en las siguientes áreas:

1. *Adquisición de la señal*: métodos para mejorar la relación señal-ruido (SNR), la relación señal-interferencia (S/I), como también la integración óptima entre información espacial y temporal.
2. *Análisis de trials aislados*<sup>3</sup>: técnicas para la interpretación de un sólo *trial* para evitar la promediación de múltiples segmentos.
3. *Co-aprendizaje*: optimización del aprendizaje mutuo entre hombre y máquina por medio de la utilización de *feedback*.
4. *Paradigmas experimentales para la interpretación directa de señales EEG*: experimentos que permitan relacionar tareas con estados mentales del usuario (o vice versa).
5. *Comprensión de los algoritmos y modelos dentro del contexto de la neurobiología*: diseño de modelos predictivos cuyos parámetros poseen sentido neurofisiológico, y la incorporación de información *a priori* física y biológica.

La arquitectura básica de un sistema BCI se ilustra en la figura (3.1) y consta de las siguientes partes:

1. *Sujeto*: El sujeto realiza TMs con el propósito de controlar un dispositivo.
2. *Adquisición*: Las señales EEG son medidas por medio de métodos invasivos o no-invasivos. Luego son amplificadas, prefiltradas y muestreadas.

---

<sup>1</sup>Señal eléctrica del corazón.

<sup>2</sup>Señal eléctrica muscular.

<sup>3</sup>En inglés conocidos como *single-trials*.

3. *Procesamiento*: Una vez adquiridas, las señales son procesadas en dos etapas. Primero, la etapa de *preprocesamiento* limpia la señal, por ejemplo mejorando la relación señal-ruido, o eliminando artefactos. Posteriormente, en la etapa de *extracción de características*, se calculan propiedades para alimentar al clasificador.
4. *Clasificación*: El vector de características es analizado y etiquetado. Esta clasificación se basa en el reconocimiento de los patrones que caracterizan a las TMs posibles. El etiquetado da origen a un comando asociado.
5. *Respuesta*: Se ejecuta el comando en el dispositivo controlado. Esta acción sirve directamente como mecanismo de retroalimentación para el sujeto.

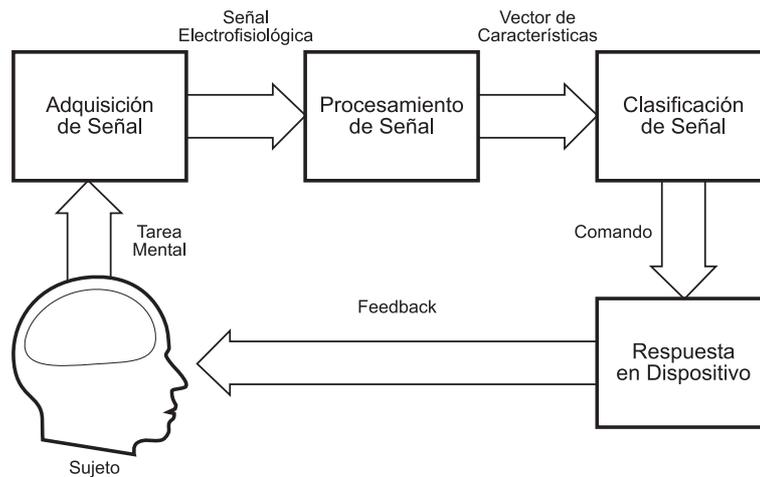


Figura 3.1: Arquitectura básica de un BCI.

Al igual que cualquier sistema de comunicación, posee entradas, salidas, elementos que realizan las transformación, y un protocolo de operación.

## 3.2. Señales Neurofisiológicas Utilizadas en Aplicaciones BCI

Las interfaces basadas en señales cerebrales requieren de la detección en línea de estados mentales a partir de registros de actividad cerebral. Estos registros pueden obtenerse de distintas maneras. Principales factores que determinan el método a emplear son: costo, tecnología disponible, invasividad y los tipos de TMs utilizados [3, 18, 25].

La invasividad refleja el nivel de intervención que se realiza en el sujeto para la adquisición de las señales neurofisiológicas. Se distingue entre métodos *no-invasivos* y *métodos implantados*.

Un BCI puede ser clasificado por el tipo de TM que utiliza para su operación. Los dos grupos principales de TMs son: *potenciales evocados*<sup>4</sup> y *condicionamiento operante*. Tanto el método de potenciales evocados como el de condicionamiento operante se basan normalmente en BCIs externos que registran la actividad cerebral por medio de electrodos ubicados sobre el cuero cabelludo.

La tabla 3.1 describe las señales más comunes en los BCIs actuales [3, 18, 25].

### 3.2.1. Métodos Implantados

Los métodos implantados utilizan señales provenientes de neuronas individuales o de pequeños grupos. Su emplazamiento requiere de una intervención neuroquirúrgica. La relación señal a ruido que se obtiene supera ampliamente a aquella obtenida por métodos no-invasivos, al costo de ser invasivos. En la mayoría de los casos, los electrodos se implantan sobre la región motora debido a su relación directa con tareas motrices, su acceso relativamente fácil comparado con las regiones motoras a mayor profundidad cerebral, y la simplicidad de registrar actividad cerebral a partir de las células piramidales. Los métodos implantados han mostrado funcionar incluso cuando no existe control motriz en el sujeto.

Usando métodos de condicionamiento operante, estudios [25] han obtenido excelentes resultados en monos que aprenden a controlar dispositivos con registros de neuronas individuales. En humanos, el estudio masivo de los métodos implantados se ha visto retrasado por la falta de electrodos adecuados para no comprometer la salud del sujeto y al mismo tiempo asegurar un nivel estable de señal a largo plazo.

### 3.2.2. Potenciales Evocados

Los potenciales evocados están relacionados con los métodos cognitivos de la psicología. Éstos consideran a la mente como una entidad de procesamiento que recoge un estímulo y entrega una respuesta que depende de ella y de los procesos cognitivos gatillados durante su operación [3, 4].

Eventos externos como un flash, sonidos o imágenes en un computador, inducen a desviaciones en el potencial de la señal EEG conocidas como *potenciales evocados* o *potenciales relacionados a eventos* (EPs<sup>5</sup> o ERPs<sup>6</sup>). Cuando el sujeto pone atención a uno de estos estímulos se produce un ERP sincronizado que aparece en su EEG. Estos cambios pueden ser detectados por medio de técnicas de promediación o *separación ciega*

---

<sup>4</sup>también conocidos bajo el nombre de *potenciales relacionados a eventos*

<sup>5</sup>del inglés *Evoked Potential*

<sup>6</sup>del inglés *Event-Related-Potencial*

Cuadro 3.1: Señales electrofisiológicas utilizadas.

Nombre de Señal	Descripción
Control de ritmos <i>Alfa</i> y <i>Mu</i> (Acond. del operador)	El ritmo <i>Mu</i> es un ritmo EEG espontáneo en la banda 8Hz-12Hz asociado a actividades motoras. Se presenta principalmente sobre la corteza sensorimotora. El ritmo <i>Alfa</i> se encuentra en la misma banda de frecuencias, pero se registra principalmente sobre el lóbulo frontal y occipital. Se puede aprender a controlar la amplitud de estas ondas con la ayuda de <i>Biofeedback</i> .
Sincronización/desincronización relacionada a eventos (ERS/ERD) (Acond. del operador)	Corresponde a un aumento o disminución de bandas de frecuencia específicas (generalmente <i>Mu</i> y <i>Beta</i> ) sobre la zona sensorimotora, durante movimiento o incluso <i>intento</i> de movimiento de extremidades. Se puede aprender a controlar la magnitud de estos ritmos por medio de <i>Biofeedback</i> .
Cambios lentos del potencial cortical (Acond. del operador)	Cambios notorios (positivos o negativos) en la señal EEG que duran desde 300 milisegundos hasta varios minutos. Un sujeto puede aprender a producir estos cambios con la ayuda de <i>Biofeedback</i> .
Componente P3 de los potenciales evocados	Cambio positivo de la señal que se produce aproximadamente 300 a 400 milisegundos tras presentar un estímulo adecuado. Se observa con mayor intensidad en la zona parietal central. Esta señal es una respuesta inherente y no debe ser aprendida.
Potenciales evocados visuales de latencia breve	Para producir esta componente se necesita una respuesta tras presentar brevemente un estímulo visual. La señal se presenta con mayor intensidad sobre el área occipital, y es una respuesta inherente que no debe ser aprendida.
Registro de neuronas individuales	A los individuos se les implantan electrodos que miden la actividad local de neuronas. En algunos casos se preparan electrodos que incentivan el crecimiento de tejido neuronal en el implante. Dependiendo de la zona neuronal medida, se puede obtener control tanto por medio del condicionamiento operante como por las respuestas naturales de una célula (o grupo celular) frente a estímulos.
Potenciales evocados visuales continuos (SSVER)	Corresponde a una respuesta que se produce al presentar un estímulo visual modulado a una frecuencia constante. El SSVER se caracteriza por un incremento de ondas EEG a la misma frecuencia que el estímulo. Típicamente este estímulo se genera a partir de tubos fluorescentes blancos modulados a 13.5 Hz u otras fuentes estroboscópicas. Un individuo puede entrenarse para modular la amplitud de su respuesta, o también pueden utilizarse múltiples SSVER simultáneamente.

de fuentes<sup>7</sup> [42, 43, 44, 45]. Al asociar un conjunto de estímulos a un set de comandos, un sujeto ejerce control sobre un dispositivo enfocando su atención al estímulo asociado a la acción deseada.

Ejemplos de BCIs que utilizan potenciales son aquellos basados en la detección de la componente P3 y potenciales evocados visuales continuos. La ventaja de estos sistemas radica en el hecho de que, al tratarse de una respuesta inherente, un sujeto no iniciado gana control inmediato sobre el sistema, requiriendo poco o nulo entrenamiento. Por otro lado, la habituación a los estímulos relevantes debilita el ERP asociado y reduce el rendimiento del sistema.

### Componente P3

Estímulos raros o particularmente significativos (auditivos, visuales o somatosensitivos) que se mezclan entre otros más frecuentes y rutinarios, típicamente evocan un *peak* en el EEG sobre la corteza parietal. Este *peak* se manifiesta aproximadamente 300 milisegundos tras la presentación del estímulo significativo (Figura 3.2).

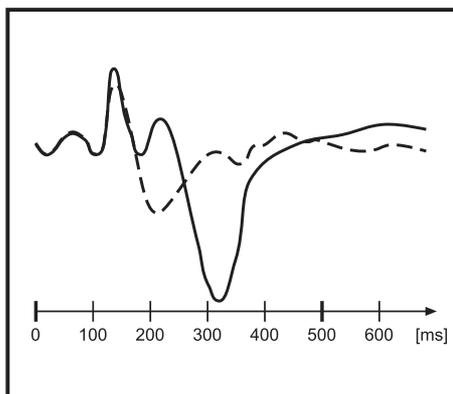


Figura 3.2: Componente P3.

Comparación entre una señal que presenta la componente P3 (línea sólida) y otra con ausencia de la componente (línea punteada).

El BCI le presenta diferentes estímulos al sujeto que han sido previamente asociados a un set de acciones. La componente P3 se pronuncia en los estímulos asociados a la decisión del sujeto, hecho del cual se sirve el BCI para dilucidar la intención del operador. Técnicas como promediación y *análisis de componentes independientes* (ICA<sup>8</sup>) sirven para aislar la componente P3 en forma efectiva [42, 43, 44, 45]. Existen estudios que

---

<sup>7</sup>en inglés *blind source separation*

<sup>8</sup>del inglés *independent component analysis*

analizan la tasa de transferencia de información obtenida para distintas configuraciones de frecuencia y cantidad distinta de presentación de estímulos [34, 35, 36].

### Potenciales Evocados Visuales Continuos

Estímulos intermitentes de frecuencia variable (entre 2 Hz y 15 Hz) dan origen a un potencial evocado visual continuo (SSVER<sup>9</sup>) que se caracteriza por un ritmo EEG con la misma frecuencia del estímulo. Esto permite detectar la presencia de un SSVER analizando las componentes de frecuencia del EEG registradas sobre la zona visual, i.e. sobre el lóbulo occipital.

El BCI presenta distintos parpadeos (previamente asociados a acciones) simultáneamente. El sujeto puede ejecutar un comando deseado mirando el estímulo asociado.

### 3.2.3. Condicionamiento Operante

Condicionamiento operante está relacionado con métodos de la psicología del comportamiento. Esta línea sugiere que un sujeto puede adquirir destrezas de control de su actividad cerebral si su entrenamiento es apoyado por medio de una retroalimentación adecuada. Los primeros intentos de aplicación de este método fueron destinados para fines clínicos como tratamiento de estrés, déficit atencional, depresión e incluso epilepsia. Este procedimiento de retroalimentación es conocido bajo el nombre de *Neurofeedback*.

A pesar de que un sujeto puede aprender a modular su actividad cerebral para inducir un BCI a la ejecución de sus intenciones, se sabe que el proceso de aprendizaje, en caso de ser exitoso, puede requerir una cantidad de tiempo considerable. Estudios han reportado tiempos que se extienden a varias semanas. Para disminuir este esfuerzo, el BCI puede adaptarse simultáneamente al usuario por medio de algoritmos de aprendizaje de máquinas.

En teoría, el control de un BCI puede basarse en la realización de cualquier TM. De hecho, se podría esperar que, por medio del aprendizaje simultáneo entre hombre (con entrenamiento retroalimentado) y BCI (con algoritmos de aprendizaje de máquinas), eventualmente el sujeto ganaría un control satisfactorio usando esa TM. Sin embargo, se prefiere el empleo de TMs para la cual existe evidencia de que son detectables en EEG. En particular, tareas que han dado mejores resultados son aquellas que dan origen a actividad cerebral espacialmente asimétrica.

---

<sup>9</sup>del inglés *steady state visual evoked potential*

El proceso de adaptación mutua generalmente sigue los siguientes pasos. En las sesiones iniciales de entrenamiento, se le solicita al sujeto realizar las TMs que servirán para el control, mientras que se registra su EEG. Posteriormente, algoritmos de aprendizaje de máquinas analizan estos datos para construir un modelo destinado a reconocer las TMs. En las sesiones subsiguientes, el sujeto realiza las TMs, y el BCI responde con un *feedback* que indica el nivel de detección de la TM. Al final de cada sesión se actualiza el modelo con los nuevos datos. El procedimiento se repite varias veces durante el transcurso de la operación del BCI. El operador puede evaluar y optimizar la ejecución de las TMs, mientras que el BCI se adapta continuamente por su lado.

BCIs basados en el condicionamiento operante utilizan los cambios lentos del potencial cortical, actividad sensorimotora oscilatoria, y otras TMs que presentan especialización hemisférica.

### Cambios Lentos del Potencial Cortical (SCPS)

Los SCPS son desplazamientos positivos o negativos notorios del potencial cortical. Duran desde 300 milisegundos hasta un par de minutos. Presentes en todo el cerebro, indican el nivel de preparación excitatoria de una red neuronal cortical. Los SCPS negativos están relacionados con movimiento y otras funciones causantes de activación cortical, mientras que los positivos se asocian a la reducción de actividad cortical.

Un sujeto puede aprender a producir SCPSs en una dirección eléctricamente positiva o negativa por medio de un *feedback* adecuado. Esta destreza, que le permite ejercer un control binario, la puede adquirir en un sistema con retroalimentación y aprendizaje con refuerzo, que premia respuestas correctas [3].

Dada la naturaleza de esta señal neurofisiológica, sistemas BCI basados en ella reportan tasas de transferencia bajas.

### Actividad Sensorimotora Oscilatoria

Grupos de neuronas pueden formar redes complejas de interacción que exhiben comportamiento eléctrico oscilatorio. La frecuencia de estos osciladores decrece con un incremento del número de neuronas involucradas. Destacan dos tipos de oscilaciones de particular importancia: el ritmo *Mu* Rolándico que abarca frecuencias entre 7 Hz y 13 Hz y el ritmo *Beta* central que se encuentra sobre los 13 Hz. Ambos se producen predominantemente sobre el área sensorimotora. Estimulación sensorial, movimiento e imaginación de movimiento resultan en una supresión de la amplitud (*desincronización relacionada a eventos* o ERD<sup>10</sup>) o en un realce de la amplitud (*sincronización rela-*

---

<sup>10</sup>del inglés *event-related-desynchronization*

cionada a eventos o ERS<sup>11</sup>) de los ritmos *Mu* y *Beta*.

En estudios [18, 17, 26, 27] se ha observado que la preparación y planificación de movimientos de mano individuales generan un ERD de duración breve en los ritmos *MU* y *Beta* central (Figura 3.3). Hallazgos similares se han hecho para movimientos de brazo y pierna, resultando en ERDs de ondas *Alfa* y *Beta*.

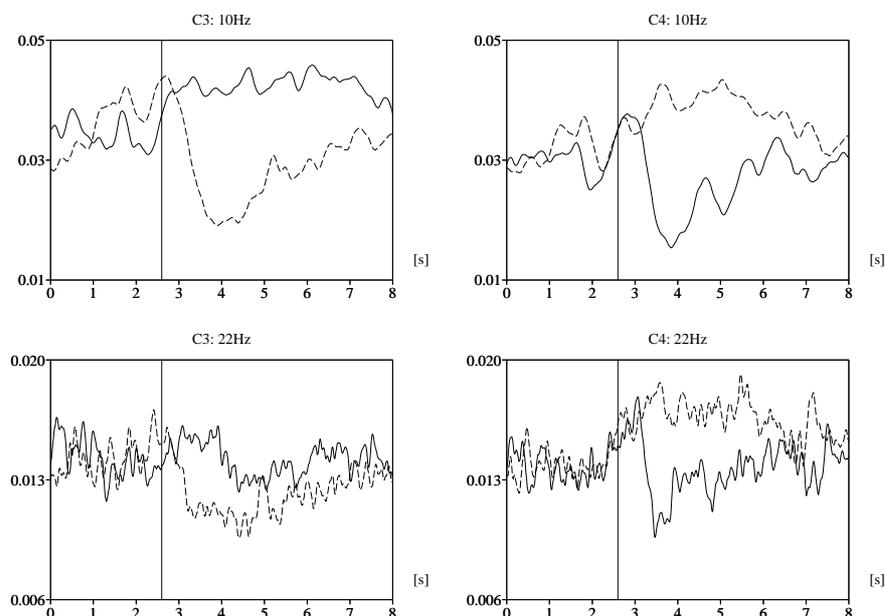


Figura 3.3: ERD de imaginaria de movimiento de mano.

Los paneles ilustran el ERD promediado sobre 70 ejemplos de los ritmos *Mu* (10 Hz) y *Beta* central (22 Hz) durante la imaginación de movimiento de mano izquierda (línea sólida) y derecha (línea punteada). La línea vertical indica el comienzo de la ejecución de la TM. Tanto el ritmo *Mu* como el *Beta* presentan una atenuación en amplitud durante la intención motriz con respecto a la media precedente. Esta atenuación se acentúa contralateral al movimiento intentado, i.e. para movimiento de brazo izquierdo sobre el hemisferio derecho (C4) y viceversa. Nótese que en particular en estos datos también puede apreciarse un ERS ipsilateral, i.e. localizado en el hemisferio del mismo lado del cuerpo.

La *imaginaria motriz* puede pensarse como un ensayo mental de movimiento sin que éste se ejecute. Está ampliamente aceptada la idea de que la imaginaria motriz involucra tanto regiones como funciones muy similares al acto de preparación y planificación de un movimiento real. Por ejemplo, la imaginación de movimiento de mano izquierda o derecha produce un ERD contralateral en la región cerebral asociada a la mano. Este fenómeno es característico de las etapas de preparación y programación de un movimiento manual real.

<sup>11</sup>del inglés *event-related-synchronization*

Así, la diferencia principal entre las señales neurofisiológicas resultantes de la imaginación motriz y el movimiento real parece radicar en un bloqueo de la señal de ejecución a nivel corticoespinal. Este hecho convierte el uso de imaginación motriz en una alternativa viable para el control mediante un BCI.

### TMs con Especialización Hemisférica

Adicionalmente a la imaginación motriz, otras TMs para las cuales se ha encontrado evidencia de especialización hemisférica son: TM geométricas, verbales y aritméticas. En particular, ejemplos de estas TMs son: imaginación y rotación mental de figuras geométricas, composición verbal de una carta, y conteo y multiplicación mental.

Algunos equipos de investigación [5, 18] han utilizado estas TM para el diseño de BCIs, reportando tasas de transferencia comparables a los demás sistemas. Sin embargo, en general, las TMs con especialización hemisférica no han gozado de mucha popularidad, porque su ejercicio no parece lo suficientemente natural para el control de objetos. La ejecución prolongada de estas TMs puede resultar en el cansancio del operador y una consiguiente baja en el rendimiento del sistema. Sin embargo, ellas abren un conjunto de alternativas de control que sobre todo pueden beneficiar aquellos casos en donde resultan más eficientes que la imaginación motriz.

## 3.3. Sistemas Existentes

Son varios los equipos de investigación que están trabajando en el desarrollo de BCIs. Los grupos más importantes se presentan en orden alfabético en la tabla 3.2. Diferentes aspectos determinan la calidad de un BCI, dentro de los cuales se destacan:

1. Tiempo de entrenamiento requerido para el uso del sistema.
2. Tasas de transferencia.
3. Cantidad y tipo de errores en que se incurre comúnmente.
4. Tiempo de retención observada en los usuarios.
5. Satisfacción de los usuarios.

### 3.3.1. Brain Response Interface

*Instituto Smith-Kettlewell de San Francisco, U.S.A.*

Cuadro 3.2: Sistemas existentes [3].

En el cuadro, la rapidez equivale al número promedio de acciones por minuto que puede ejecutar un operador del BCI.

Nombre	Tiempo Entren.	Nº de opciones	Rapidez	Errores	Retención	Satisfacción
Brain Response Interface	10-60 min	64	30	10 %	Excelente	Considerado
Dispositivos Implantados	Meses	N/A	2	No reportado	Excelente	Considerado
ERS/ERD Cursor Control	2-2.5 h	2	No disponible	< 11 %	No mencionado	No discutido
Flexible Brain Computer Interface	No mencionado	2	3	15 %	No mencionado	No discutido
Mu Wave Cursor Control	15-20 sesiones	2	20	10 %	No mencionado	No discutido
P3 Character Recognition	Minutos	36	4	5 %	Excelente	No discutido
SSVEP BCI	6 h	N/A	N	< 20 %	No mencionado	No discutido
Thought Translation Device	Meses	27	2	2-30 %	No buena	Discutido Indirectamente

Este sistema, diseñado por el grupo de Sutter, utiliza potenciales evocados visuales inducidos por estímulos breves que el operador utiliza para escoger una opción asociada a una región de la pantalla. Aplicaciones de procesamiento de texto alcanzan velocidades de 10-12 palabras por minuto, a una tasa de error de 10%. Éste es uno de los pocos sistemas que hace uso de electrodos epidurales (implantados) para obtener una señal más intensa y menos contaminada.

El sujeto focaliza un símbolo en la pantalla que contiene un total de 64 dispuestos en forma de grilla. El sistema produce variaciones en el color (rojo y verde) de subgrupos de estos símbolos para aislar aquel seleccionado por el usuario. El uso del color en vez de parpadeo produce mucho menos cansancio en el sujeto obteniendo un rendimiento similar.

El sistema corresponde básicamente a la versión EEG de los sistemas de comunicación basados en movimiento ocular y sufre de los mismos problemas, porque asume que el sujeto siempre está viendo la pantalla.

### 3.3.2. Dispositivos Implantados

*Universidad de Georgia State, U.S.A.*

Este dispositivo BCI, desarrollado por Kennedy y colegas, ha sido implantado en dos pacientes. Éstos han sido entrenados para controlar un cursor. La velocidad del

cursor está dada por la tasa de disparo de las neuronas monitoreadas. Las señales son convertidas a tres pulsos que controlan la posición horizontal, vertical y el clic (señal de confirmación) respectivamente.

Se han aplicado tres modos de operación para este BCI. Los primeros dos están basados en filas de frases comunes que el usuario puede seleccionar para sintetizar conversaciones. En el primer caso el cursor parte del extremo izquierdo superior, y una secuencia de movimientos hacia la derecha, hacia abajo, y una señal de confirmación selecciona la opción deseada. En el segundo caso, el cursor se moviliza en saltos ortogonales desde un ícono a otro colindante, hasta confirmar la opción deseada. El tercer paradigma hace uso de un teclado virtual que el sujeto opera por medio del cursor. Desgraciadamente, la tasa de transferencia de éste sólo llega a tres caracteres por minuto.

### 3.3.3. ERS/ERD Cursor Control

*Universidad Tecnológica de Graz, Austria*

El sistema experimental del equipo de Pfurtscheller utiliza varios electrodos que cubren la actividad sensorimotora para la detección de ERS/ERD. El BCI presenta una pantalla sencilla donde el sujeto controla un cursor hacia la izquierda y derecha. En el modo de aprendizaje por refuerzo se recompensa al sujeto por conseguir mover el cursor en la dirección estipulada por la interfaz. El *feedback* entregado por el sistema puede ser inmediato o con retardo.

Experimentos han mostrado que algunas personas logran un control considerable en sólo dos sesiones de entrenamiento, con una tasa de acierto entre 89 y 100 %. Al extender el sistema con una tercera clase, su rendimiento disminuyó a un 60 % en el mejor caso.

### 3.3.4. Flexible Brain Computer Interface

*Universidad de Rochester, U.S.A.*

Bayliss y colaboradores han desarrollado un sistema de control inmersivo de realidad virtual basado en la componente P3 de los potenciales evocados. Los sujetos pueden, entre otras cosas, ejercer acciones como encender/apagar la luz, fijar un canal de televisión o una estación de radio en un departamento virtual. La principal desventaja de este sistema basado en P3 es su lentitud. Análisis de *single-trials* podría acelerar la comunicación, pero al costo de una pérdida en la precisión.

En otra aplicación, en donde el sujeto conduce un vehículo en una ciudad virtual, han obtenido una exactitud de 85 % en la clasificación de *single-trials*. A los sujetos de prueba se les instruyó detenerse frente a luces rojas e ignorar los verdes y amarillos. El equipo consta de un casco de realidad virtual y un *go-kart* con freno, acelerador y volante con el cual maniobran el vehículo. A pesar que se esperaba la introducción de un gran número de artefactos adicionales a raíz de esta configuración, la mayor cantidad de artefactos descubiertos y procesados eran de origen ocular.

### 3.3.5. Mu Wave Cursor Control

*Wadsworth Center, Albany, U.S.A.*

Wolpaw y colaboradores han diseñado un BCI basado en el control por medio de ritmos *Mu*. Los sujetos son entrenados para mover un cursor hacia arriba o abajo modificando este ritmo, por medio de imaginación motriz y estimulación táctil, ejerciendo control continuo. Si bien no todas las personas logran este tipo de control con *Biofeedback*, los casos exitosos reportan una exactitud sobre 90 %. Intentos por extender el grado de libertad a un movimiento bidimensional no han logrado este nivel de precisión.

### 3.3.6. P3 Character Recognition

*Universidad de Illinois, U.S.A.*

En una aproximación parecida al *Brain Response Interface*, el equipo de Farewell y Donchin han utilizado la componente P3 de los potenciales evocados para implementar la selección de letras dentro de una grilla de  $6 \times 6$ . En este caso se utilizaron estímulos parpadeantes a aproximadamente 10 Hz. Los usuarios han logrado una precisión de 95 % a una tasa de transferencia promedio de 2.3 caracteres por minuto. Este sistema es lento, y debido al parpadeo puede provocar ataques epilépticos en algunos usuarios.

### 3.3.7. SSVEP BCI

*Base de Fuerzas Aéreas Wright-Patterson,  
Laboratorio de Investigación de las Fuerzas Aéreas, U.S.A.*

Middendorf y colaboradores utilizan un método basado en condicionamiento operante para entrenar a sujetos a modular la amplitud de SSVEPs a tubos fluorescentes a 13.5 Hz. El *Neurofeedback* se basa tanto en respuestas luminosas como de audio. Si el voltaje de este potencial evocado se mantiene por un periodo de tiempo fuera límites predefinidos se gatillan acciones discretas. Tras un periodo de 6 horas de entrenamiento,

los sujetos alcanzar precisiones sobre 80%, que emplean para ejecutar giros hacia la izquierda y la derecha en simuladores de vuelo.

Los últimos esfuerzos del equipo se han centrado en explotar a los SSVEPs como respuestas naturales. La tarea experimental consistió en seleccionar botones de la pantalla. En promedio, los 8 sujetos involucrados en el experimento alcanzaron una rapidez de 2.1 segundos por selección, a un porcentaje de 92% de precisión. Prácticamente no hubo entrenamiento previo.

### 3.3.8. Thought Translation Device

*Universidad de Tübingen, Alemania*

El laboratorio de Birbaumer desarrolló el *Thought Translation Device* [23] para apoyar a pacientes con lesiones motrices severas. El BCI se basa en la extracción de los cambios corticales lentos, que son filtrados, librados de artefactos oculares y retornados como *feedback* al usuario. La tarea consiste en mover un cursor en forma vertical acercándolo a un objetivo presentado.

A los sujetos que alcanzaban un 75% de precisión se les presentó una interfaz para seleccionar una letra. La estrategia de selección se basaba en la división sucesiva en mitades del conjunto original de caracteres hasta identificar una letra en particular.

# Capítulo 4

## Adquisición y Procesamiento

### 4.1. Descripción de OpenBCI

Los sistemas descritos anteriormente han servido como fuente de inspiración para el diseño del BCI planteado en esta memoria, bautizado como *OpenBCI*. Un prototipo de *OpenBCI*, llamado *ABI* (para plataforma *Windows XP*), forma parte del proyecto de código libre *OpenEEG*, cuyo objetivo es la creación de un dispositivo EEG de bajo precio y software libre para su operación [10].

*OpenBCI* es una sistema BCI que traduce *trials* a comandos. El sistema está basado en señales EEG adquiridas por medio del condicionamiento operante. Antes que el sujeto sea capaz de operar el BCI, éste debe familiarizarse con él. Este proceso requiere de un aprendizaje por parte del usuario que puede compararse a aquel necesario para aprender a tocar un instrumento musical. El sistema a su vez está diseñado para facilitar esta tarea adaptándose a los patrones cerebrales individuales de la persona<sup>1</sup> por medio de clasificador entrenable.

El aprendizaje se organiza en distintas sesiones de duración corta y frecuencia variable (por ejemplo, diariamente o semanalmente). Una sesión consta de una secuencia de ejecución de *trials*, los cuales son procesados, etiquetados y almacenados, formando parte de una base de ejemplos que servirá para entrenar posteriormente al clasificador interno. En general se registran entre 50 y 100 *trials* de cada clase por sesión, dispuestas de manera de no producir fatiga mental en el sujeto.

La arquitectura de *OpenBCI* se ilustra en forma más detallada en la figura 4.1. En ella pueden apreciarse las componentes que integra el BCI. El sistema posee tres modos de operación:

---

<sup>1</sup>Estudios sugieren que una misma TM puede manifestarse por medio de patrones particulares que difieren entre distintos sujetos.

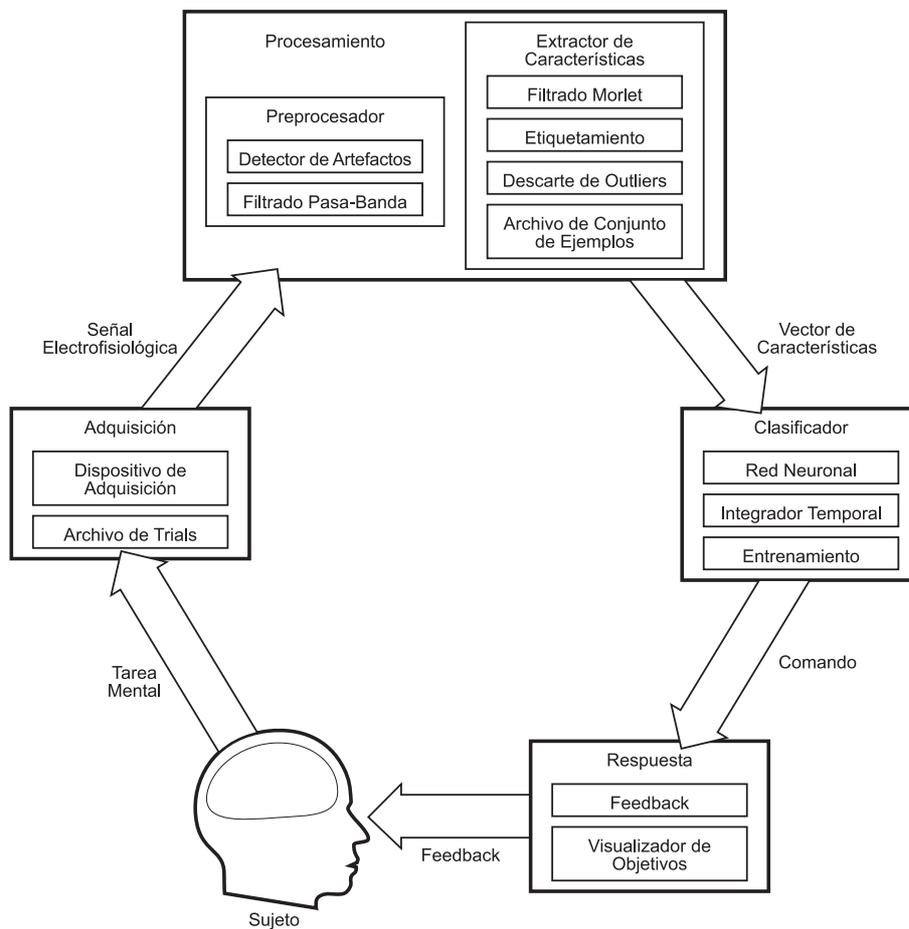


Figura 4.1: Arquitectura detallada de OpenBCI.

1. *Simulación*: Este es el modo de operación normal. Aquí el usuario ejerce las TMs para gatillar comandos. El sistema emite estímulos para indicar el comienzo y final de un *trial*. El sistema mide la señal EEG, la procesa, la clasifica y ejecuta la acción correspondiente.
2. *Registro*: La tarea de este modo de operación consiste en la adquisición de ejemplos para el posterior entrenamiento del clasificador. El sistema, haciendo uso de estímulos apropiados que indican la clase objetivo y delimitan el inicio y fin de un *trial*, guía al usuario durante la ejecución de las TMs.
3. *Entrenamiento*: Durante este modo de operación, el sistema analiza los ejemplos almacenados y luego entrena al clasificador.

En los capítulos anteriores se presentó la arquitectura general de un sistema BCI, las señales electrofisiológicas utilizadas, y se revisaron algunos de los ejemplos existentes. Los capítulos que siguen ahondarán más en los detalles internos que constituyen el sistema *OpenBCI* desarrollado en este trabajo.

## 4.2. Adquisición

Como se ha mencionado anteriormente, las señales EEG son procesadas en segmentos (*trials*) dentro de los cuales el BCI intenta reconocer las tareas mentales pertenecientes al conjunto controlador.

### 4.2.1. Dispositivo de Adquisición

El siguiente sistema de adquisición de señales EEG es un excelente ejemplo para ilustrar a un equipo con características suficientes para su aplicación en un sistema BCI, manteniendo un bajo costo.

El proyecto *OpenEEG* cuenta con un equipo de desarrollo de hardware, cuyo objetivo es el diseño de un dispositivo EEG de bajo costo. Debido al mercado reducido para estos aparatos, las unidades profesionales son demasiado caras para un público que simplemente desea experimentar. Hasta la fecha, el dispositivo funcional más importante del proyecto es el *ModularEEG*.

El *ModularEEG* está constituido por dos o más amplificadores EEG, y una tarjeta de adquisición de seis canales que se conecta a un PC a través de un cable serial estándar. El diseño modular del dispositivo permite configuraciones con un número variable entre dos a seis amplificadores para canales de montaje bipolar a una tasa de muestreo es 256 Hz con una precisión de 10 bits. El precio de las componentes necesarias para construir una unidad completa fluctúa entre 200 y 400 US\$. Una persona puede decidir comprar

una unidad ensamblada u optar por construirlo en forma independiente a partir de los esquemáticos que el proyecto ofrece sin costo.

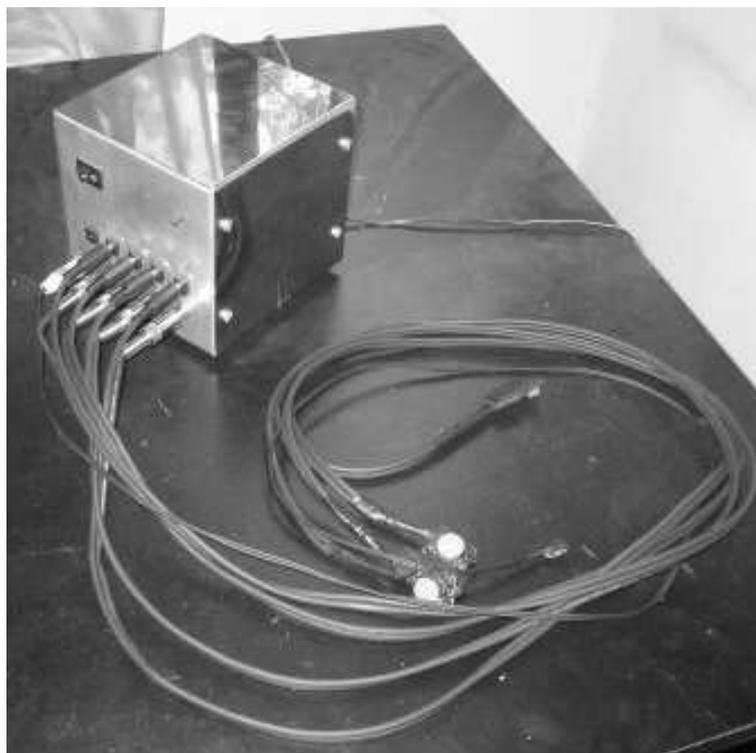


Figura 4.2: Un dispositivo *ModularEEG*.

La fotografía presenta una unidad *ModularEEG* de dos canales bipolares construido para el desarrollo del trabajo presente. Esta unidad cuenta con cuatro electrodos activos. Su tasa de muestreo es de 256 Hz con una precisión de 10 bits.

El dispositivo puede operar en conjunto con electrodos pasivos estándar para realizar las mediciones de señales EEG. Sin embargo, en el proyecto también se están desarrollado electrodos activos compatibles con el *ModularEEG*. A pesar de que éstos todavía se encuentran en etapa de desarrollo, la versión actual del diseño es funcional.

Un estudiante de ingeniería eléctrica (Paul Aguayo Sanhueza), en conjunto con el autor de esta memoria, ensamblaron una unidad *ModularEEG* más cuatro electrodos activos, para probar la aplicación *ABI*.

### 4.2.2. Registro de Trials

El procedimiento de adquisición de las señales EEG contempla los siguientes pasos:  
1. el sujeto se sienta en una silla cómoda en una habitación iluminada adecuadamente

y en lo posible con baja contaminación acústica ambiental para facilitar la concentración; 2. los electrodos se disponen sobre su cuero cabelludo siguiendo un esquema predeterminado; 3. el sistema se calibra si es necesario; 4. se registra la señal EEG.

Como el conjunto de *trials* corresponde a la fuente de datos principal para la extracción de características para el clasificador, el diseño de la estructura de éstos debe contemplar los siguientes aspectos:

1. *Continuidad Temporal*: Una TM manifiesta una actividad cerebral continua en el tiempo<sup>2</sup>. Debido a este hecho, un *trial* debe corresponder a un intervalo de tiempo (consecutivo) de un EEG.
2. *Sincronización y Correlación*: Se ha observado experimentalmente que una TM puede involucrar la ejecución de etapas secuenciales distintas de interacción cortical. Por ejemplo, la rotación mental en 3D de una figura geométrica puede descomponerse en los siguientes subprocesos: codificación de la figura, generación de la imagen, rotación. La presencia de una cadena de subprocesos mentales sugiere que es conveniente garantizar una sincronización adecuada entre un *trial* y la ejecución de una TM. El BCI debe generar estímulos para indicarle al sujeto el comienzo y fin de un *trial*. Asimismo, debe notificar oportunamente la TM que el sujeto debe realizar.
3. *Distribución Temporal*: Para evitar la aparición de artefactos sistemáticos y de acostumbamiento, es conveniente escoger el intervalo *inter-trial* en forma aleatoria. Esta técnica además introduce un factor sorpresa que mantiene al usuario en estado de alerta, más concentrado, eventualmente mejorando la calidad de los registros.

La estructura de un *trial* utilizada en *OpenBCI* se ilustra en la figura 4.3. La duración de cada una de las etapas es configurable. Todos los *trials* registrados durante el modo de operación “registro” se almacenan en conjunto con la etiqueta de su clase, para su posterior análisis.

En lo que sigue, un *trial* se representará como una matriz  $S$  de tamaño  $T \times K$ , donde las columnas corresponden a los diferentes canales, y las filas a las muestras. El superíndice  $S^i$  permite identificar al *trial*  $i$ -ésimo dentro de un total de  $I$ . Para identificar a un elemento de la matriz  $S$ , se utilizará la notación tradicional  $S_{tk}$ .

---

<sup>2</sup>Bajo un punto de vista más estricto, también puede considerarse continua espacialmente. Sin embargo, bajo la suposición de que la actividad cerebral asociada a un TM se manifiesta focalizada en ciertas zonas corticales, y teniendo en cuenta la baja precisión espacial de una medición EEG, sólo es necesario considerar un número finito de canales.

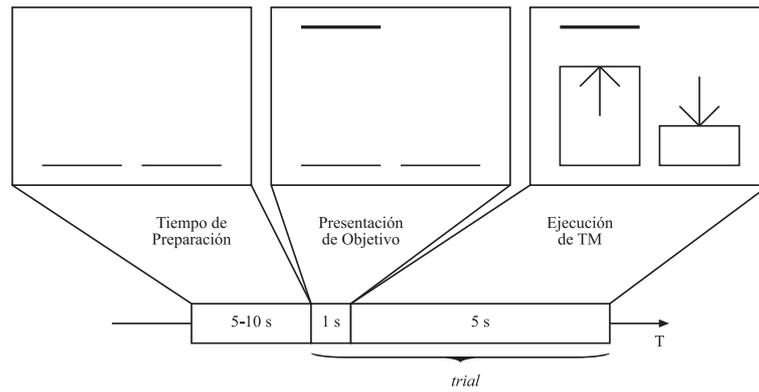


Figura 4.3: Estructura de un *trial*.

Un *trial* consta de tres partes: a) Tiempo de Preparación, intervalo de tiempo de longitud variable; b) Presentación de Objetivo, donde el BCI le indica al usuario qué TM debe realizar; c) Ejecución de TM, intervalo en que debe realizarse la TM asociada a la clase. La ilustración muestra esquemáticamente las pantallas presentadas por el BCI. En este caso, el sujeto debe incrementar el tamaño de la barra asociada a la clase objetivo.

Como convención, un índice se escribe con una letra en minúsculas. Si un índice puede tomar un número finito de valores, entonces el número total se denota por medio de la misma letra, pero escrita en mayúsculas. Por ejemplo, el índice  $t$  puede tomar los valores  $t = 1, 2, 3, \dots, T$ .

### 4.3. Preprocesamiento

La extracción de información relevante a partir de un EEG se complica debido al ruido externo y a los artefactos producidos por el operador. La mayoría de las fuentes externas de ruido pueden ser evitadas controlando adecuadamente el entorno en el cual se realizan las mediciones. Por ejemplo, el ruido proveniente de la red eléctrica está confinado a una banda angosta del espectro que se sitúa más allá de las frecuencias relevantes en un EEG, por lo que puede filtrarse fácilmente.

Los artefactos producidos por el sujeto, como parpadeo ocular, movimiento ocular y actividad muscular, producen cambios en el potencial eléctrico de mayor amplitud que la actividad cerebral endógena. A pesar de no existir correlación entre artefacto y tarea, la extracción de características puede verse severamente entorpecida. En casos más desafortunados, el sujeto puede incluso estar ejerciendo control inconscientemente por medio de artefactos. Algunos sistemas optan por detectar y descartar los segmentos EEG contaminados.

Los dos ejemplos anteriores ilustran el rol que cumple la etapa denotada como *pre-procesamiento*. En ella se procesa la señal cruda con el objetivo de descontaminarla para efectuar posteriormente la extracción de características.

### 4.3.1. Artefactos EEG

Dentro del contexto de BCIs basados en señales EEG, la *señal* corresponde a cualquier variación del potencial eléctrico registrado sobre el cuero cabelludo que tenga su origen en actividad cerebral endógena, mientras que los *artefactos* (también llamados ruido) son aquellos provenientes de otras fuentes. Las más importantes son: interferencia electromagnética, parpadeo y movimiento ocular y actividad muscular (principalmente de músculos de la cabeza y el cuello).

1. *Interferencia electromagnética*: La mayoría de estas interferencias pueden ser atenuadas o evitadas controlando el ambiente en el cual se realizan las mediciones EEG. Sin embargo, debido a que la medición de EEG requiere de por lo menos un amplificador conectado a un computador, la señal puede ser corrompida por la interferencia proveniente de la fuente de poder. Estas perturbaciones están generalmente bien localizadas en el espectro de frecuencias, y se ubican más allá de la banda EEG.
2. *Artefactos oculares*: Los artefactos de parpadeo son muy comunes en los EEG. Éstos artefactos se caracterizan por su baja frecuencia y gran amplitud. De hecho, mientras que la señal EEG se mueve en un rango entre  $-50$  y  $50 \mu V$ , un artefacto de parpadeo puede alcanzar los  $100 \mu V$  de amplitud (Figura 4.4).

Los artefactos de movimiento ocular se producen debido a la reorientación del dipolo retinocorneal. Su forma se asemeja a una onda cuadrada, y su amplitud se halla dentro de los rangos del EEG regular (Figura 4.5).

Ambos tipos de artefactos, denotados bajo el nombre común *artefactos oculares*, ocurren en intervalos de tiempo seguidos entre sí. Éstos se manifiestan principalmente en los electrodos frontales (por ejemplo,  $Fp_1$  y  $Fp_2$ ), pero pueden afectar incluso las mediciones de las zonas posteriores.

3. *Artefactos musculares*: Los artefactos musculares se producen debido a las contracciones de diferentes grupos musculares. Sin embargo, los músculos que predominan son los faciales y aquellos del cuello. Éstos afectan principalmente las mediciones de los electrodos ubicados en la zona parietal y temporal. Los artefactos musculares se caracterizan por su amplia distribución en el espectro de frecuencias (Figura 4.6).

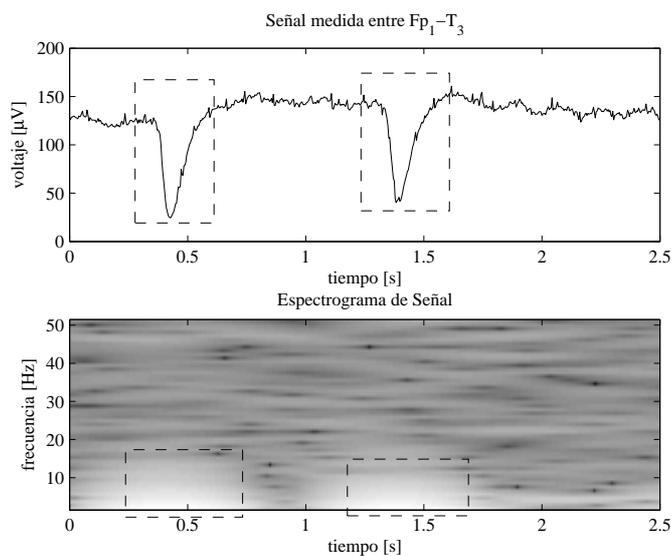


Figura 4.4: Artefacto de parpadeo.

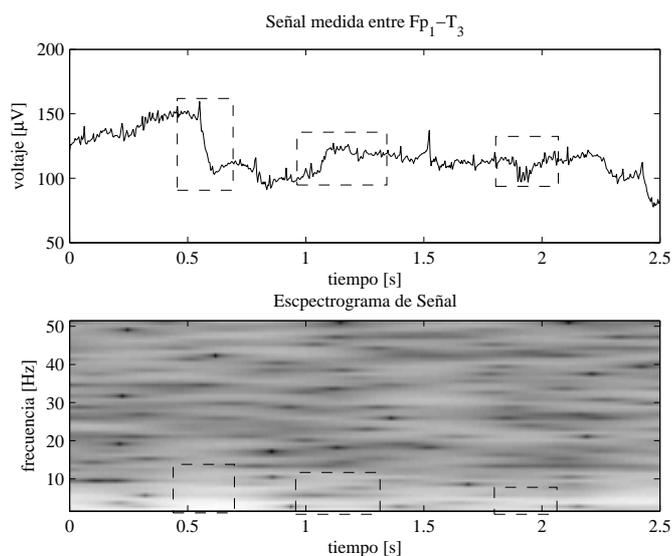


Figura 4.5: Artefacto de movimiento ocular.

En los espectrogramas ilustrados, las zonas más claras corresponden a una mayor intensidad de la componente de frecuencia en el instante de tiempo respectivo. En las zonas destacadas pueden apreciarse las manifestaciones de los artefactos.

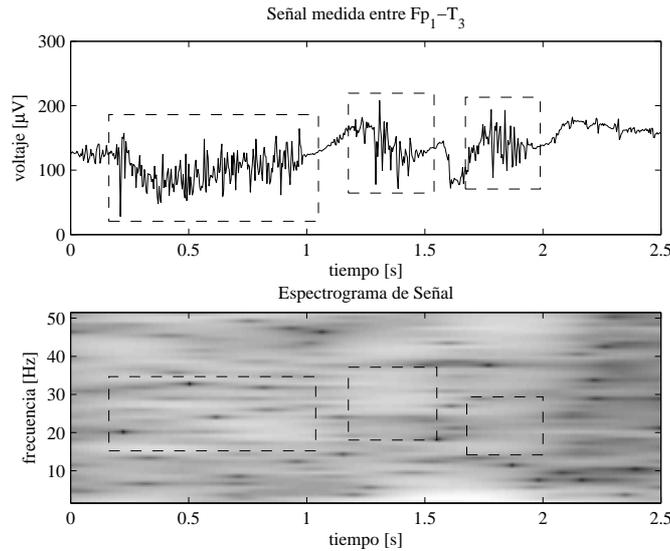


Figura 4.6: Artefacto muscular.

### 4.3.2. Eliminación del Ruido de la Red Eléctrica

El ruido proveniente de la red eléctrica está restringida en torno a una frecuencia localizada<sup>3</sup>. Dado que las frecuencias más relevantes en un EEG se hallan entre 0.1 y 40 Hz, ésta interferencia puede ser removida usando un filtro digital, por ejemplo, un filtro tipo *Notch*, que atenúa fuertemente una frecuencia particular dejando las frecuencias vecinas prácticamente intactas.

En *OpenBCI* se ha optado por utilizar un filtrado pasa-banda que cumple el propósito de aislar las frecuencias relevantes para el sistema. Debido a la localización en frecuencia de la interferencia de la red eléctrica, ésta es eliminada al realizar este filtrado.

### 4.3.3. Filtrado Pasa-Banda

Dentro de los grupos de ondas cerebrales detallados en la sección 2.2 (página 9), se pueden identificar dos tipos:

1. *No controlados*: Estos grupos de señales están asociados a actividad cerebral que el sujeto no puede controlar en forma consciente e instantánea. Por un lado, las ondas *Teta* y *Delta* se relacionan con estados mentales subyacentes, i.e. anímicos-emocionales y de sueño. Por el otro, a las ondas *Gamma* se les atribuye reflejar los mecanismos de comunicación a nivel neuronal.

<sup>3</sup>en Chile 50 Hz, en E.E.U.U. 60 Hz

2. *Controlados*: Corresponden a los tipos de onda que están directamente relacionadas a TMs que un sujeto puede producir en forma controlada en estado de vigilia. Éstas incluyen a las ondas *Beta*, *Alfa* y *Mu*.

Evidentemente, los tipos de onda controlados son más apropiados para un sistema BCI. La señal EEG cruda puede preprocesarse de manera de aislar los tipos controlados. Un filtro digital pasa-banda que abarque las ondas *Beta*, *Alfa* y *Mu* cumple este objetivo. El rango de frecuencias de estas ondas se halla principalmente entre 8 Hz y 30 Hz.

El sistema propuesto utiliza un filtro digital pasa-banda tipo *Butterworth* de orden 20. La banda de frecuencias fue definida entre 6 Hz y 32 Hz, es decir, abarcando 2 Hz adicionales en los extremos definidos por las ondas de interés. La función de transferencia del filtro<sup>4</sup> en cuestión es:

$$H(z) = \frac{B(z)}{A(z)} = \frac{b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_{20}z^{-20}}{a_0 + a_1z^{-1} + a_2z^{-2} + \dots + a_{20}z^{-20}} \quad (4.3.1)$$

donde  $z^{-1}$  es el operador de retardo. Los coeficientes de los polinomios  $A(z)$  y  $B(z)$  están tabulados en el cuadro 4.1, obtenidos por medio de un software para la construcción de filtros digitales [10]. La respuesta en tiempo y frecuencia están graficadas en la figura 4.8. Los filtros *Butterworth* son sistemas LTI no-causales (ver apéndice A) de respuesta infinita al impulso (IIR). Aplicando un poco de álgebra, y desplazando el filtro en el tiempo para convertirlo en un sistema causal, se obtiene su función de filtrado recurrente:

$$S'_t = \frac{1}{b_0} \left( \sum_{\tau=0}^{\tau=20} a_\tau S_{t-\tau} - \sum_{\tau=1}^{\tau=20} b_\tau S'_{t-\tau} \right) \quad (4.3.2)$$

donde  $S'_t$  es la señal filtrada, y  $S_t$  es la señal no-procesada (Figura 4.7). Nótese que la aplicación de este filtrado introduce un retardo de 20 muestras, lo cual equivale a aproximadamente 78 milisegundos.

El empleo de un filtrado pasa-banda como el anteriormente descrito además cumple la función de eliminar la interferencia proveniente de la red eléctrica.

#### 4.3.4. Detección de Artefactos Oculares y Musculares

La presencia de artefactos oculares y musculares en señales EEG puede ser detectada fácilmente por medio de inspección visual. De hecho, cada uno de estos artefactos presenta características en tiempo y frecuencia que lo distingue de EEG regular.

---

<sup>4</sup>Las nociones básicas de sistemas lineales invariantes en el tiempo están descritas en el apéndice A.

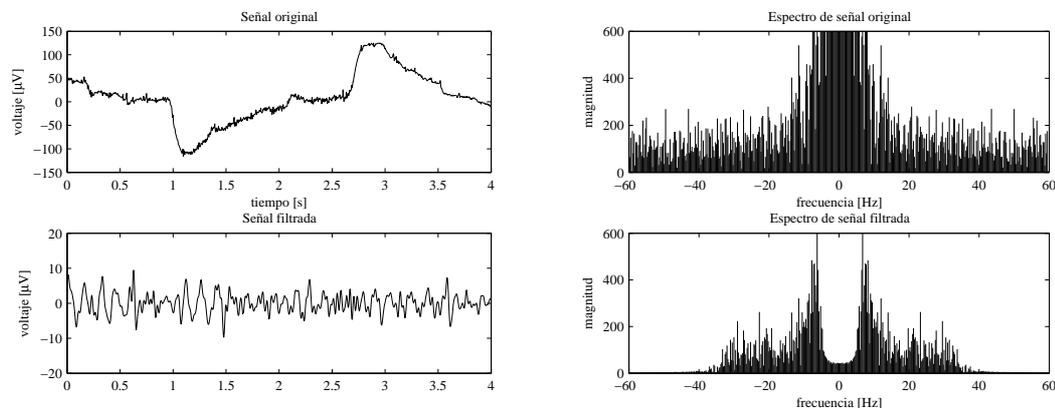


Figura 4.7: Comparación entre una señal EEG antes y después del filtrado pasa-banda.

La ilustración muestra un segmento de señal EEG de cuatro segundos de duración. Los paneles superiores corresponden al EEG original y a su espectro en el dominio de frecuencias. Los paneles inferiores presentan el mismo segmento, pero tras haber sido filtrado con un filtro digital pasa-banda tipo *Butterworth* de orden 20 entre 6 Hz y 32 Hz.

$a_0$	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$	$a_6$
0.0001	-0.0015	0.0107	-0.0490	0.1597	-0.3952	0.7704
$a_7$	$a_8$	$a_9$	$a_{10}$	$a_{11}$	$a_{12}$	$a_{13}$
-1.2117	1.5621	-1.6669	1.4805	-1.0964	0.6758	-0.3448
$a_{14}$	$a_{15}$	$a_{16}$	$a_{17}$	$a_{18}$	$a_{19}$	$a_{20}$
0.1443	-0.0487	0.0130	-0.0026	0.0004	-0.0000	0.0000
$b_0$	$b_1$	$b_2$	$b_3$	$b_4$	$b_5$	$b_6$
0.0019	0	-0.0192	0	0.0865	0	-0.2306
$b_0$	$b_1$	$b_2$	$b_3$	$b_4$	$b_5$	$b_6$
0	0.4036	0	-0.4843	0	0.4036	0
$b_{14}$	$b_{15}$	$b_{16}$	$b_{17}$	$b_{18}$	$b_{19}$	$b_{20}$
-0.2306	0	0.0865	0	-0.0192	0	0.0019

Cuadro 4.1: Coeficientes del filtro pasa-banda.

El cuadro presenta los coeficientes de los polinomios  $A(z)$  y  $B(z)$  que determinan al filtro pasa-banda tipo *Butterworth* de orden 20, para una tasa de muestreo de 256 Hz.

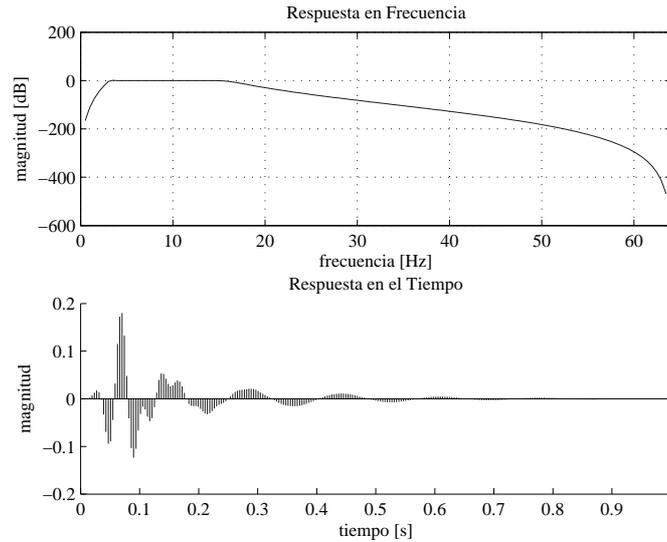


Figura 4.8: Filtro pasa-banda.

El panel superior muestra la respuesta en frecuencia del filtro pasa-banda tipo *Butterworth* de orden 20. Se preservan las frecuencias correspondientes a las TMs controladas, que se hallan principalmente entre 8 Hz y 30 Hz. La respuesta al impulso se ilustra en el panel inferior.

Los artefactos oculares se concentran principalmente en la banda *Teta* y se manifiestan con mayor intensidad en la zona frontal, i.e.  $Fp_1$  y  $Fp_2$ . Cómo puede ser apreciado en la figuras 4.4 y 4.5, la representación en tiempo y frecuencia de series de artefactos oculares presenta una concentración inusual de la potencia en la banda *Teta*.

Los artefactos musculares poseen amplitudes similares a las de EEG regular, pero su contenido espectral se condensa en la banda *Beta* y *Gama*. Estos artefactos se manifiestan con mayor intensidad en las zonas temporales y parietales, es decir, en los electrodos  $T_3$ ,  $T_4$ ,  $T_5$ ,  $P_3$ ,  $P_4$  y  $T_6$ .

Ambos tipos de artefactos pueden considerarse como eventos singulares en el plano tiempo-frecuencia que aparecen distribuidos en forma aleatoria. Para su detección, un método eficaz consiste en segmentar el EEG en intervalos de un segundo de duración con un traslape de medio segundo. Es decir, un segmento de 1500 milisegundos contiene dos intervalos de análisis, siendo el segundo aquel que parte a los 500 milisegundos. Cada intervalo obtenido así se analiza por su contenido de artefactos.

La detección utilizada en trabajos de investigación relacionados se basa en los dos hechos siguientes. Primero, los artefactos oculares se caracterizan por su concentración

extraordinaria de energía en la banda *Teta* en los electrodos  $Fp_1$  y  $Fp_2$ , y segundo, los artefactos musculares pronuncian la energía en las bandas *Beta* y *Gama* [18, 16].

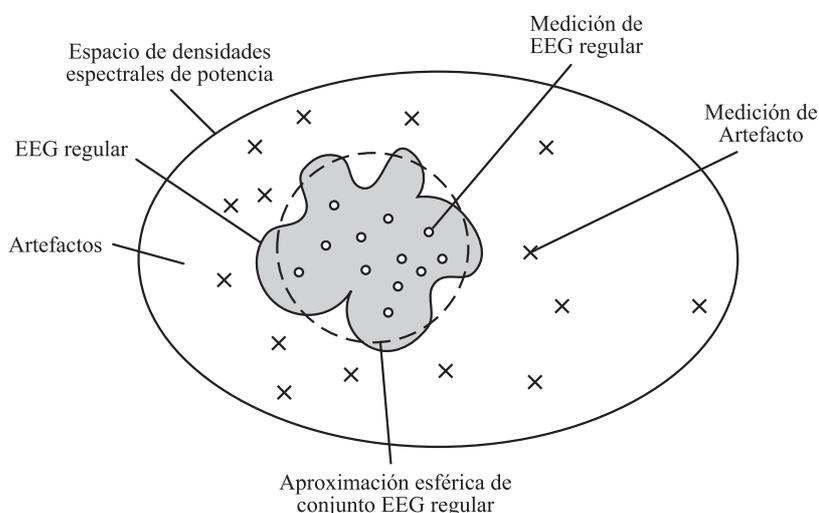


Figura 4.9: Conjunto de densidades espectrales de potencia.

El conjunto de segmentos EEG regular puede suponerse como un subconjunto reducido dentro del total de densidades espectrales de potencia. El conjunto de artefactos EEG corresponde a su conjunto complemento. Las mediciones de segmentos EEG particulares, ya sea con o sin artefactos, pueden utilizarse para aproximar la frontera entre ambos conjuntos. En este caso, se modela el conjunto de EEG regular por medio de una esfera.

Considerando lo anterior, se puede decir que dentro del conjunto total de densidades espectrales de potencia, las que corresponden a actividad EEG regular se hallan muy próximas entre sí. Ésto significa que las señales EEG sin contaminación se ubican dentro de una región pequeña rodeada de artefactos (Figura 4.9).

En *OpenBCI*, la detección de los artefactos se relega a la etapa de clasificación. Más precisamente, el clasificador emplea una estrategia de integración/ponderación de información relevante para la clasificación. Es ese sentido, debido a la ubicuidad de los artefactos a lo largo de todas las clases, el sistema considerará su aparición como irrelevante para la discriminación, y por lo tanto, les asignará un peso despreciable.

## 4.4. Extracción de Características

En la sección anterior se presentaron las técnicas asociadas al preprocesamiento de la señal EEG, con las cuales se extrae la banda de frecuencia relevante, y se detectan artefactos dentro de los *trials*. La sección presente se centra en la extracción de propiedades estadísticas (o simplemente características) que contengan información discriminativa entre distintas TMs. Las señales a procesar consisten en los *trials* libres de contaminación que provienen del módulo preprocesador del sistema. Las características obtenidas se agrupan en un vector que se denota como *vector de características*, y que sirve como entrada al clasificador del sistema.

Las características que se extraen a partir de la señal EEG deben reflejar aquellas propiedades que sean relevantes para su asociación con una TM. La elección adecuada de estas características ha sido un tema de gran importancia durante la última década, y se han realizado numerosos trabajos de investigación. Más aún, las nuevas técnicas de análisis de EEG han surgido en paralelo con nuevos conceptos y herramientas en el área de procesamiento de señales. En particular, se han desarrollado conceptos generalizados de interacción temporal, espacial, de frecuencia y de fase [13, 15, 39, 40, 41].

Un análisis completo de características requeriría de una cantidad prohibitiva de recursos en espacio y en tiempo. Una construcción ingenua de vectores de características generaría un volumen de datos que impediría la construcción de un clasificador de calidad aceptable. El problema decisivo radica en que se dispone de un número muy reducido de patrones de entrenamiento, cuya dimensionalidad<sup>5</sup> es altísima. El objetivo del diseño de un vector de características consiste en la construcción de un número muy pequeño de indicadores o atributos que contengan la información necesaria para discriminar en forma robusta entre TMs.

Asumiendo algunas hipótesis sobre la naturaleza de la señal EEG se puede reducir considerablemente el número de características necesarias. Sin embargo, no conviene fijar un set de características comunes a todos los usuarios. Los aspectos electrofisiológicos y psicológicos propios a cada sujeto requieren una adaptación del BCI inclusive a nivel de selección de características.

En lo que sigue, para mantener la consistencia con la notación empleada anteriormente, un *trial* procesado se representará como una matriz  $X$  de tamaño  $T \times N$ , donde cada fila corresponden a los vectores de características extraídos en el instante  $t$ . Se empleará un superíndice  $X^i$  en los casos en que es necesario relacionarlo con el *trial*  $i$ -ésimo.

---

<sup>5</sup>en este caso, la cantidad de información necesaria para representar un *trial* no-procesado

### 4.4.1. Filtrado Morlet

*Gabor* estaba interesado en la búsqueda de filtros que permitan la localización simultánea en tiempo y frecuencia de una señal [15, 39, 40, 41]. Las ondas sinusoidales y la función delta corresponden a ambos extremos entre localización en frecuencia y tiempo respectivamente. En sus estudios, demostró que el compromiso óptimo se obtiene por medio de ondas sinusoidales moduladas por ventanas gaussianas. La frecuencia particular a la cual que apunta esta onda se determinada por la frecuencia de la onda sinusoidal. La dispersión de la banda de frecuencia a la cual responde el filtro (el ancho de banda) se fija a través del ancho de la ventana gaussiana.

Una versión particular de las funciones *Gabor* es la función de *Morlet* dada por

$$\psi(t) = \underbrace{\frac{1}{\sqrt{\pi f_b}} e^{-\frac{t^2}{f_b}}}_{\text{Envoltorio Gaussiano}} \underbrace{e^{2j\pi f_c t}}_{\text{Sinusoide}}. \quad (4.4.1)$$

donde  $j = \sqrt{-1}$ ,  $f_c$  es la *frecuencia central*, y  $f_b$  es el *ancho de la ventana gaussiana*. Generalmente esta función se calibra para su posterior uso fijando los parámetros en  $f_c = 1$  ( $2\pi$  Rad por unidad) y  $f_b = 1$ . Nótese que la función *Morlet* es compleja (Figura 4.10).

Se puede descomponer una señal  $s(t)$  (continua y acotada) proyectándola sobre una base de funciones *Morlet* mediante la *transformada Wavelet continua* (CWT), dada por

$$C(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} s(\tau) \psi \left( \frac{\tau - b}{a} \right) dt \quad (4.4.2)$$

donde  $a > 0$  es el parámetro de *escala* y  $b$  el de *tiempo/posición*, ambos reales. El plano bidimensional  $C(a, b)$  corresponde a una representación en tiempo y frecuencia de la señal  $s(t)$ .

La CWT en combinación con la onda *Morlet* conforman una herramienta poderosa para el análisis de una señal. De hecho, tomando el módulo  $|C(a, b)|$  de la transformada, se obtiene un *detector de frecuencias* particularmente útil, ilustrado en la figura (4.11). Computacionalmente, la CWT se aproxima a través de señales discretas, aunque este procedimiento no debe confundirse con la *Transformada Wavelet Discreta* (DWT), que corresponde a otra transformación. El nexo entre las unidades de *posición-escala* y las unidades reales *tiempo-frecuencia* se establece por medio de las relaciones

$$t = \frac{b}{F_s}, \quad (4.4.3)$$

$$w = \frac{F_s}{a}, \quad (4.4.4)$$

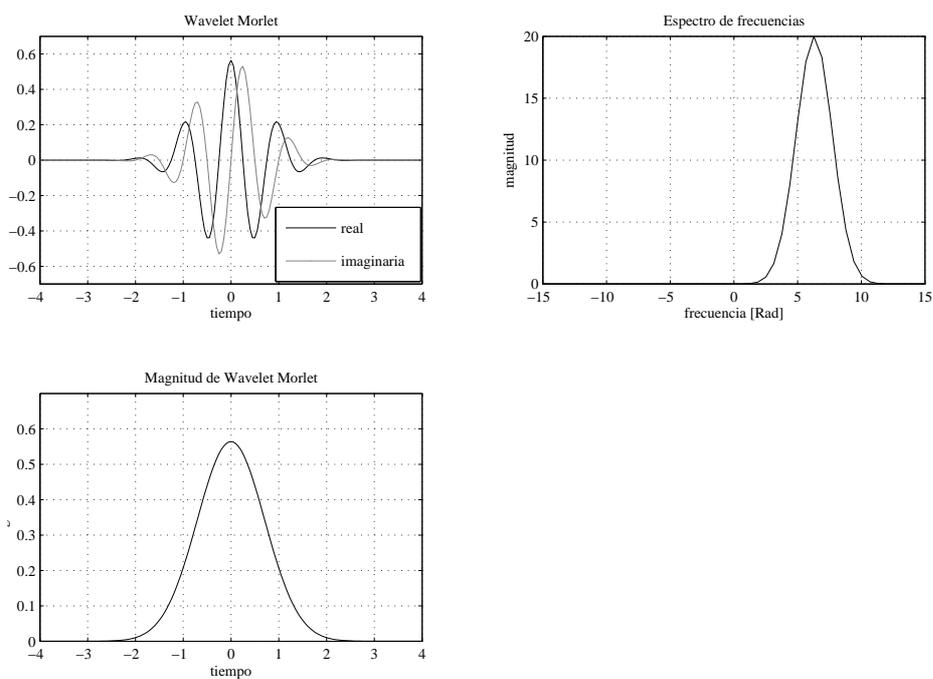


Figura 4.10: Wavelet *Morlet*.

La Wavelet *Morlet* es un caso particular de las funciones *Gabor*. El panel superior izquierdo muestra la parte real e imaginaria de la onda con frecuencia central  $f_c = 1$  y ancho de ventana  $f_b = 1$ . Se puede apreciar que la magnitud de su espectro de frecuencias corresponde a una ventana gaussiana (panel superior derecho), similar a la magnitud en el dominio del tiempo (panel inferior).

donde  $F_s$  es la tasa de muestreo de la señal  $s(t)$ . En la figura (4.12) se puede apreciar cómo la CWT resalta la onda *Alfa* en una medición EEG bipolar entre  $T_{p1}$  y  $T_3$  durante el ejercicio de rotación mental de objetos tridimensionales, confirmando las observaciones realizadas en investigaciones.

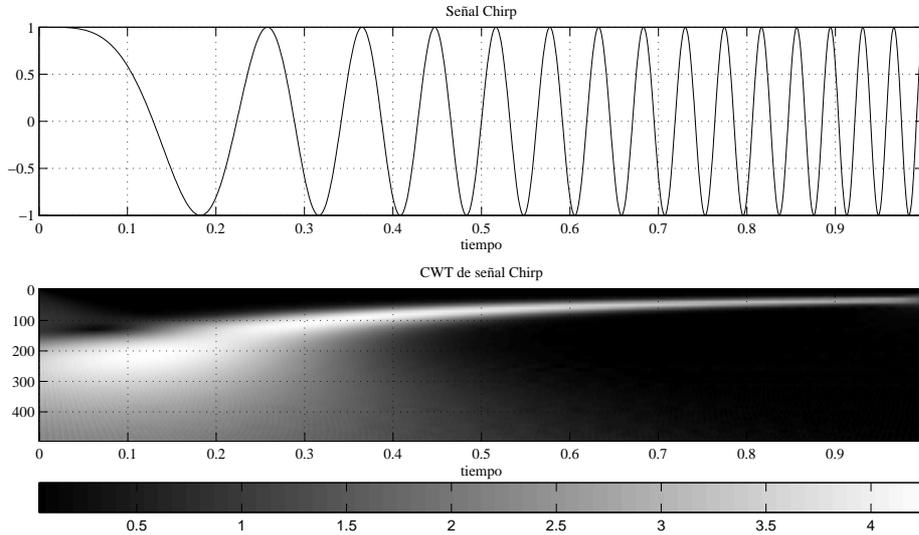


Figura 4.11: CWT de una señal de ejemplo.

La figura ilustra una señal sinusoidal cuya frecuencia aumenta a medida que transcurre el tiempo, y la magnitud de su correspondiente CWT usando la función *Morlet*. En la *representación en tiempo y frecuencia* (TFR) resultante puede apreciarse como la escala predominante decrece en el tiempo. Esta última afirmación es equivalente a decir que la frecuencia predominante crece con el transcurso del tiempo.

### Construcción

La extracción de características se realiza por medio del empleo de bancos de filtros digitales de *Morlet* centrados en un número finito de frecuencias. Estos filtros actúan como detectores de bandas angostas de frecuencia análogos a la CWT, pero por medio de la convolución (en contraste a la correlación) con la señal analizada. La construcción adecuada de filtros FIR involucra:

- la selección de un *intervalo de soporte*<sup>6</sup> acotado, pues la onda *Morlet* tiene extensión infinita en el tiempo,
- el *muestreo* en intervalos de tiempo acordes a la frecuencia objetivo.

<sup>6</sup>En estricto rigor, el *intervalo de soporte* es el intervalo en donde la señal concentra su energía. Sin embargo, en este caso se denotará así a la ventana de tiempo desde la cual se obtendrán las muestras de la Wavelet *Morlet*.

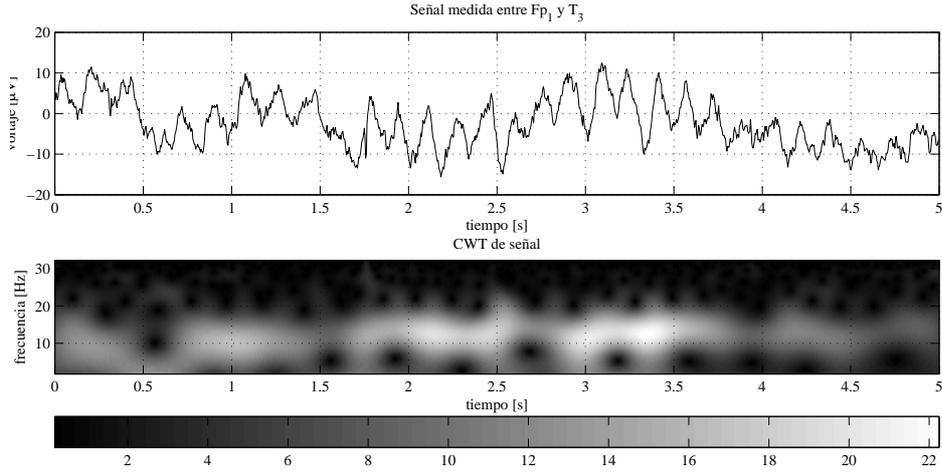


Figura 4.12: CWT de un *trial* EEG.

El gráfico corresponde a un EEG registrado mientras el sujeto rotaba mentalmente objetos tridimensionales. La TFR resultante a partir de la CWT de un señal EEG resalta la banda *Alfa* que predomina durante la ejecución de esta TM.

Tratándose de una señal simétrica (parte real) y antisimétrica (parte imaginaria), el intervalo de soporte se escoge en  $[-2;2]$ , pues allí se concentra gran parte (más del 99 %) de su energía:

$$\int_{-2}^2 \psi(\tau)\psi^*(\tau) d\tau > 0,99 \int_{-\infty}^{\infty} \psi(\tau)\psi^*(\tau) d\tau \quad (4.4.5)$$

Para obtener un filtro digital *Morlet*  $h_w$  para la frecuencia  $w$ , se obtienen  $N_w$  muestras equidistantes dentro de su intervalo de soporte

$$h_w(n) = \psi\left(\frac{T_S n}{F_s} + t_S\right), \quad n = 0, \dots, N_w - 1 \quad (4.4.6)$$

donde  $[t_S; t_S + T_S]$  es el intervalo de soporte,  $F_s$  es la tasa de muestreo, y  $N_w$  está dado por

$$N_w = \left\lceil \frac{T_S}{F_s} \right\rceil. \quad (4.4.7)$$

donde  $\lceil x \rceil$  denota al *cajón superior* de  $x$ . Como la función *Morlet* es compleja, el muestreo se realiza sobre la parte real  $\psi_{re}$  y la compleja  $\psi_{im}$  por separado, obteniendo dos filtros  $h_{re,w}$  y  $h_{im,w}$

$$\psi_{re}(t) = \frac{1}{\sqrt{\pi}} e^{-t^2} \cos(2\pi t) \quad \longrightarrow \quad h_{re,w}(n) = \psi_{re}\left(\frac{T_S n}{F_s} + t_S\right), \quad (4.4.8)$$

$$\psi_{im}(t) = \frac{1}{\sqrt{\pi}} e^{-t^2} \sin(2\pi t), \quad \longrightarrow \quad h_{im,w}(n) = \psi_{im}\left(\frac{T_S n}{F_s} + t_S\right). \quad (4.4.9)$$

La figura 4.13 ilustra la discretización en tiempo de la parte real de la onda *Morlet*, para una tasa de muestreo de  $F_s = 256$  Hz y frecuencias  $w = 10$  Hz y  $w = 20$  Hz.

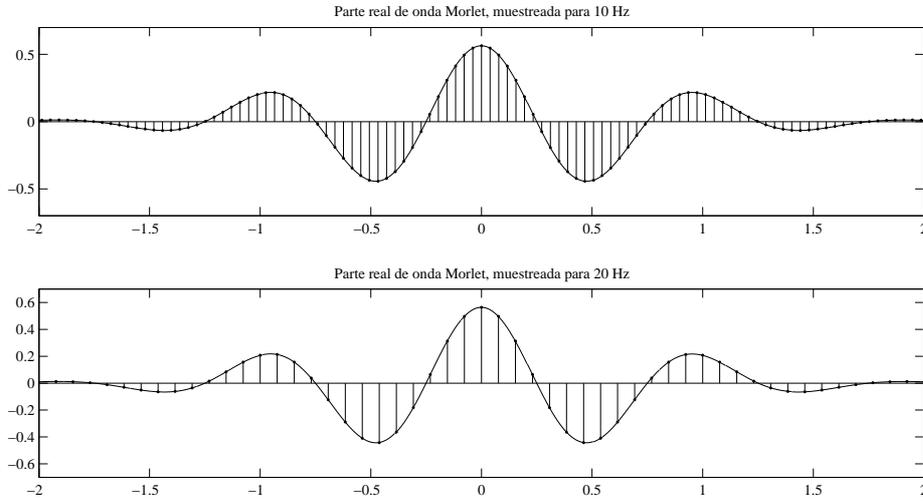


Figura 4.13: Discretización de la onda *Morlet*

Para la discretización de la onda *Morlet*, se escogió el intervalo de soporte  $[-2; 2]$  que captura gran parte de su forma. Se construyeron dos filtros digitales, uno centrado en 10 Hz (panel superior) y otro en 20 Hz (panel inferior), para una tasa de muestreo de 256 Hz. El primero requiere un total de  $4 \times 256/10 \approx 102$  muestras, y el segundo  $4 \times 256/20 \approx 51$ , produciendo filtros FIR de 51 (200 ms) y 25 (100 ms) retardos respectivamente. El mismo procedimiento debe realizarse para obtener la parte imaginaria de ambos filtros.

## Filtrado

Tras haber detallado la construcción de un filtro  $h_w$  para una frecuencia destino  $w$ , el proceso de extracción de características se realiza convolucionando un canal de un *trial*  $S_t$  con la parte real e imaginaria del filtro, y posteriormente tomando su magnitud. Sea  $X_t$  la intensidad de la frecuencia  $w$  en el instante  $t$ . El valor de  $X_t$  se obtiene como

$$\begin{aligned}
 a &= \sum_{\tau=0}^{N_w} h_{re,w}(\tau) S_{t+\lfloor N_w/2 \rfloor - \tau} \\
 b &= \sum_{\tau=0}^{N_w} h_{im,w}(\tau) S_{t+\lfloor N_w/2 \rfloor - \tau} \\
 X_t &= \sqrt{a^2 + b^2}
 \end{aligned} \tag{4.4.10}$$

Nótese que planteado tal cual, el proceso de extracción de esta característica es *no-causal*, ya que el cómputo de  $X_t$  necesita muestras pasadas y futuras de  $S_t$ . En un filtrado on-line, esto significa que debe conocer por lo menos la muestra en el instante  $t + \lfloor N_w/2 \rfloor$  para conocer la intensidad de la frecuencia  $w$  apuntada. En consecuencia, hay un retardo implícito en el proceso de extracción de características que el diseño del BCI debe contemplar. En particular, para efectos de entrenamiento del sistema, los *trials* almacenados deben contar además con un número adicional de muestras *previo y posterior* al intervalo que se analiza. Si la frecuencia mínima considerada es  $w_{min}$ , entonces basta registrar  $\lceil N_{w_{min}}/2 \rceil$  muestras previas y  $\lfloor N_{w_{min}}/2 \rfloor$  posteriores<sup>7</sup>.

### 4.4.2. Descarte de Outliers

Un *outlier* se define como un dato que se encuentra muy alejado de la media de la variable aleatoria correspondiente. Esta distancia en general se mide con respecto a un umbral predeterminado, como por ejemplo, un múltiplo de la desviación estándar. Los datos con valores que distan mucho del valor medio producen errores muy grandes durante el entrenamiento de un clasificador, y pueden, en algunas circunstancias, tener efectos desastrosos. El rendimiento de un clasificador cuyo entrenamiento es muy sensible ante la presencia de *outliers* puede verse severamente comprometido debido al sesgo que éstos introducen. En particular, los *outliers* resultantes de mediciones ruidosas constituyen una fuente importante de problemas.

Desde el punto de vista del sistema BCI desarrollado en este trabajo, un “dato” corresponde a un *trial* completo. Debido a la presencia de un gran número de perturbaciones de la señal EEG, la eliminación de *outliers* juega un rol particularmente importante. La existencia de *trials outliers* va más allá de la simple eliminación de *trials* contaminados por artefactos. Una serie de factores originados en el sujeto puede generar *outliers* inclusive dentro del conjunto de EEG regular:

1. *Fatiga*: Durante sesiones de duración prolongada puede surgir el cansancio mental del sujeto. Este efecto se produce especialmente en usuarios nuevos del sistema. Las propiedades estadísticas de la señal EEG sufren un cambio gradual con el aumento de fatiga, que se traduce generalmente en un deterioro de la calidad.
2. *Desincronización*: Distintas realizaciones de una misma TM no están perfectamente alineadas en el tiempo. Tanto la duración como la localización temporal de los subprocesos mentales involucrados en la TM pueden presentar distorsiones considerables.
3. *Desconcentración*: Durante el registro de un *trial*, un sujeto puede perder accidentalmente la concentración, perjudicando su rendimiento en el ejercicio de la TM.

---

<sup>7</sup> $\lfloor x \rfloor$  denota al *cajón inferior* de  $x$

Por un lado, eventos inesperados, como por ejemplo sonidos ambientales, pueden desconcentrar al sujeto. Por otro lado, el sujeto puede sufrir esporádicamente de déficit atencional.

4. *Realización de TM errónea*: Particularmente dañinos son los *trials* en donde el sujeto se equivocó al realizar la TM que se le exigió. Estos *trials* pueden confundir al sistema de manera de llevarlo a tomar sistemáticamente decisiones erróneas, sobre todo si fue entrenado por ejemplos con etiquetas intercambiadas.

Existe un gran número de técnicas que pretenden abordar este problema, donde la mayoría corresponde a heurísticas que se aplican a diversas situaciones particulares. El método planteado a continuación no constituye una excepción.

La idea de este procedimiento consiste en determinar la fracción  $\alpha$  de aquellos *trials* más alejados de la media de su clase y descartarlos. La proporción  $\alpha$  se fija con anterioridad en un valor adecuado, por ejemplo,  $\alpha = 0,1$ . Para ésto, se construye una medida de disimilitud que permita medir la distancia de un *trial* con respecto a la media de su clase.

La distancia se mide sobre los *trials procesados*. Dado  $X^i$  perteneciente a la clase  $c$ , primero se mide la distancia de cada una de sus filas  $X_t^i$  con respecto al promedio  $\mu_t$  de su clase,

$$\mu_t = \frac{1}{N_c} \sum_{X^j \in c} X^j \quad (4.4.11)$$

con  $N_c$  el número total de ejemplos de la clase  $c$ . La medida de distancia empleada corresponde a una versión simplificada de la distancia de *Mahalanobis*. La distancia de *Mahalanobis* está dada por

$$d_M(X_t^i, \mu_t) = ((X_t^i - \mu_t)^T \Sigma_t^{-1} (X_t^i - \mu_t)^T)^{-1/2} \quad (4.4.12)$$

donde  $\Sigma_t$  es la matriz de covarianza de los vectores  $X_t^j$  que pertenecen a la clase  $c$ . La distancia de *Mahalanobis* tiene la particularidad de que sus curvas equidistantes se ubican sobre elipses (hiperelipses). El uso de esta medida de disimilitud considera tanto la escala como la correlación entre las variables del vector características. Su cómputo es costoso, pues requiere el cálculo de la matriz de covarianza, y luego, su inversión [46].

Suponiendo que las variables del vector de características no están correlacionadas entre sí, es decir

$$E[X_{tn} X_{tm}] = 0, \quad \text{para } n \neq m \quad (4.4.13)$$

entonces la matriz  $\Sigma_t$  es diagonal, pero sus elementos  $\sigma_{tn}^2$  pueden ser distintos:

$$\Sigma_t = \begin{pmatrix} \sigma_{t1} & 0 & \cdots & 0 \\ 0 & \sigma_{t2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_{tn} \end{pmatrix}$$

Esta versión simplificada de distancia de *Mahalanobis*, que se denotará por  $d_B$ , se puede reescribir como

$$d_B(X_t^i, \mu_t) = \left( \sum_{n=1}^N \frac{(X_{tn}^i - \mu_t)^2}{\sigma_{tn}^2} \right)^{-1/2} \quad (4.4.14)$$

La figura (4.14) ilustra en forma visual la diferencia entre ambas medidas de distancia.

La hipótesis dada por (4.4.13) exige que el conjunto de características no esté correlacionado entre sí, lo cual en general no es cierto. Sin embargo, dado que se persigue el objetivo de encontrar un número reducido de variables, en lo posible exentos de redundancia, esta suposición corresponde a una aproximación válida a la distancia de *Mahalanobis*.

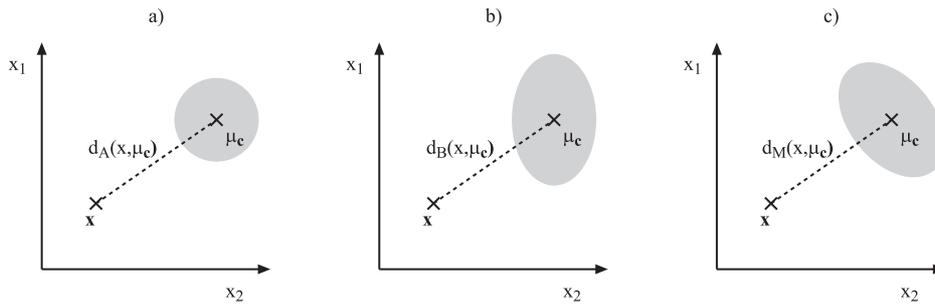


Figura 4.14: Medidas de distancia.

La distancia de *Mahalanobis* (c) mide la disimilitud entre un vector  $\mathbf{x}$  y la media de su clase  $\mu_c$  normalizando y descorrelacionando implícitamente las variables, representado por la forma elíptica de las curvas equidistantes. Si la matriz de covarianza de la población es diagonal (b), i.e. las variables no-están correlacionadas entre sí, entonces los ejes de las elipses se orientan según los ejes del espacio de características. En contraste, la distancia euclidiana (a) calcula la disimilitud sin normalizar ni descorrelacionar las variables.

Tras calcular las  $T$  distancias  $d_B(X_t^i, \mu_t)$  de un *trial* procesado  $X^i$  con respecto los promedios  $\mu_t$  de su clase, estos valores parciales se integran por medio de una suma

sencilla para obtener la distancia total  $D(X^i, \mu)$  de  $X^i$  con respecto al promedio de su clase  $\mu$ :

$$D(X^i, \mu) = \sum_{t=1}^T d_B(X_t^i, \mu_t) \quad (4.4.15)$$

### 4.4.3. Normalización

Una de las formas más comunes de preprocesamiento de las características consiste en el simple reescalamiento de las variables de entrada. Ésto suele ser muy útil en aquellos casos en donde las variables poseen valores típicos que difieren significativamente entre sí. Más aún, el sistema de clasificación puede verse influenciado en forma negativa por la magnitud relativa de las variables.

Aplicando una transformación lineal se puede lograr que todas las variables de entrada posean valores parecidos. Para las matrices de características obtenidas a partir del filtrado Morlet, el proceso de normalización se realiza como sigue. Tratando las columnas como variables independientes entre sí, se puede calcular la media  $\bar{X}_j$  y su varianza muestral  $\sigma_j^2$  como sigue:

$$\bar{X}_j = \frac{1}{N_{pats}} \sum_{t=1}^T \sum_{i=1}^{N_{pats}} X_{tj}^i \quad (4.4.16)$$

$$\sigma_j^2 = \frac{1}{TN_{pats} - 1} \sum_{t=1}^T \sum_{i=1}^{N_{pats}} [X_{tj}^i - \bar{X}_j]^2 \quad (4.4.17)$$

A partir de los valores anteriores, se obtienen nuevas matrices de características  $\tilde{X}^i$  normalizadas:

$$\tilde{X}_{tj}^i = \frac{X_{tj}^i - \bar{X}_j}{\sigma_j} \quad (4.4.18)$$

### 4.4.4. Selección de Características

Una de las técnicas más sencillas para la reducción de la dimensionalidad corresponde a la selección de un subconjunto de las características, y descartar las restantes. Este enfoque es especialmente útil cuando existen entradas que contienen poca información relevante para la discriminación entre distintas clases, o si existe una correlación muy estrecha entre algunas de las variables, de manera que la misma información se vería repetida a lo largo de las variables.

La selección de variables es un tema de investigación que goza de gran interés, y numerosos algoritmos se han desarrollado para abordar este problema [20, 46, 47].

En el contexto de un sistema BCI, un algoritmo de selección de características puede servir como herramienta de apoyo muy esclarecedora. Supóngase que se está considerando el empleo de una TM nueva, no documentada en la literatura. Se registran una serie de *trials* para el análisis que consideran varios canales EEG. A la hora de determinar las características a extraer a partir de ellas, cabe preguntarse cuáles frecuencias aportan más información para la discriminación. Una herramienta de selección de características adecuada permite la generación previa de un gran número de ellas. Posteriormente la herramienta selecciona un subconjunto reducido.

Si bien el diseño del clasificador no incluye explícitamente una etapa de selección de características, el sistema descrito no puede más que verse beneficiado de un algoritmo externo de esta índole. En particular, se destaca el algoritmo MIFS<sup>8</sup> y derivados [20], pues éstos, además de ser económicos en términos computacionales, poseen la ventaja de basarse en el análisis de la información mutua de las variables.

---

<sup>8</sup>del inglés *Mutual Information Feature Selection*

# Capítulo 5

## Clasificación

En el capítulo previo se han presentado algunos métodos para la adquisición de *trials* EEG, su preprocesamiento y la extracción de características eventualmente discriminantes entre distintas TMs. Obtenidas las matrices de características  $X$ , una para cada *trial*, la tarea siguiente consiste en su clasificación confiable, i.e. en analizar una matriz y decidir, a partir de las evidencias disponibles, a qué TM corresponde.

Cómo se ha dicho en el capítulo 3, no existen, en la actualidad, clasificadores que permitan su utilización fuera de un ambiente especialmente equipado como un laboratorio, manteniendo al mismo tiempo un nivel de rendimiento aceptable. En ese sentido, el aporte más importante de este trabajo consiste en el diseño del sistema de clasificación que se presentará en este capítulo. Esto no significa que el problema del diseño de un BCI haya sido resuelto, pero sí aborda algunos de problemas existentes de una manera sencilla, limpia y original, arrojando un poco de luz sobre esta área de investigación.

Para comprender la justificación de este diseño, es necesario enunciar y detallar las dificultades que caracterizan a este problema.

1. *Feedback inmediato*: A partir del instante en que el usuario parta ejerciendo una TM para ejecutar un comando, el sistema debe entregar una retroalimentación inmediata (o con un retardo imperceptible) que lo guíe para que pueda confirmar su desempeño durante el ejercicio de la TM. La exigencia crucial para cumplir con este requisito consiste en tomar la mejor decisión posible a partir de los datos acumulados.
2. *Variabilidad de la manifestación*: Como ya se ha explicado en los capítulos anteriores, el nivel de distorsión con el cual se manifiesta una misma TM en distintas oportunidades es considerablemente más importante que en la mayoría de los problemas de clasificación investigados en la literatura. Variables como tiempo,

frecuencia, traslación y escala, presentan un grado de variación que incluso dificulta su identificación por medio de un clasificador tan versátil como es un experto humano.

3. *Dificultad en la extracción de evidencias*: Relacionada con el punto anteriormente presentado está el hecho de que la evidencia que permite la decisión por una u otra TM se manifiesta en forma estocástica. Resulta difícil utilizar un regla sencilla para comprimir toda la información que caracteriza a un *trial* a un número muy reducido de variables discriminantes. El reconocimiento de una clase más bien exige la construcción de un volumen grande de información posiblemente relevante, y emplear una estrategia para buscar evidencia dentro de ella.
4. *Número de respuestas posibles*: Los algoritmos de clasificación de actividad mental hacen uso de conocimiento fisiológico muy ligado a las TMs particulares que pretenden reconocer, i.e. éstos fueron construidos para reconocer un set de TMs bien definidas y estudiadas, siendo, en general, no aplicables para el reconocimiento de otras. En contraste, en éste trabajo se ha dedicado un esfuerzo especial al planteamiento de un método de clasificación genérico y extensible.
5. *Escasez de patrones de entrenamiento*: Se han realizado diversos estudios que han investigado patrones comunes de manifestación electrofisiológica entre distintos sujetos. Los resultados obtenidos son diversos: pareciera existir TMs cuyos patrones de interacción neuronal son similares entre distintas personas<sup>1</sup>, y otros que se comportan en forma distinta. En la comunidad se está llegando al consenso de que un sistema BCI debe adaptarse a las características particulares de actividad EEG de cada sujeto, i.e. sistemas BCI personalizados [9, 13, 18].

Este simple hecho introduce una limitación importante. Los clasificadores deben entrenarse por medio de ejemplos obtenidos del propio usuario. Una estimación optimista que considera 1 minuto de registro por *trial* (considerando tiempos de descanso) implicaría más de 3 horas para la construcción de un conjunto pobre de apenas 200 patrones de entrenamiento. Además, el tamaño de los archivos de *trials* resultantes abarcan rápidamente varios Megabytes.

Por lo tanto, el clasificador debe estar diseñado para maximizar el uso de este conjunto, y minimizar su número de parámetros libres. Es decir, sus máximas deben consistir en: simplicidad y efectividad.

6. *Calidad del equipo EEG disponible*: Por último, la masificación de un sistema BCI no puede basarse en el empleo de un sistema de adquisición profesional como los EEG utilizados para fines clínicos, sino, en una versión simplificada de a lo más ocho canales. Esto descarta de inmediato una serie de sistemas propuestos en la literatura basados en la distribución cortical de patrones de activación EEG, que

---

<sup>1</sup>generalmente TMs *primitivas* asociadas a zonas corticales sensorimotoras

requieren una densidad espacial que sólo se obtiene mediante el uso de arreglos enteros de electrodos.

Dicho lo anterior, se prosigue con la presentación del diseño del clasificador propuesto para el sistema *OpenBCI*.

## 5.1. Proceso de Clasificación

Siguiendo la notación establecida anteriormente en el texto, sean  $X_1^i, X_2^i, \dots, X_T^i$  las filas de la matriz de características del  $i$ -ésimo *trial*  $X^i$ . Como la fila  $t$ -ésima puede verse como un vector que caracteriza al *trial*  $X^i$  en el instante  $t$ , se le denotará como *vector de características instantáneo*.

El tiempo juega un rol más pragmático si se considera que el sistema, por operar en forma *on-line*, adquiere estos datos en forma paulatina: en el instante  $t$ , éste sólo dispone de las filas

$$X_1, X_2, \dots, X_{t-T_r}$$

donde  $T_r$  el retardo de cómputo de las características<sup>2</sup>. Como el BCI debe proveer *feedback inmediato* al usuario, éste debe tomar la mejor decisión posible en base a la información recogida hasta el instante. En otras palabras, para cada instante  $t$  durante la ejecución de la TM, el sistema debe utilizar la primera hasta la  $(t - T_r)$ -ésima fila de la matriz de características para construir la respuesta que presentará al usuario.

Una primera aproximación *naïve* para la solución del problema de clasificación sería la construcción de un número reducido de estadísticos (por ejemplo, menos que diez) que caractericen todo el intervalo transcurrido hasta el momento. Sin embargo, la anteriormente mencionada *dificultad en la extracción de características* daría origen a algoritmos complejos, costosos en tiempo de procesamiento. Por otro lado, en caso de utilizarse un modelo entrenable para la extracción de características para estos intervalos, la *escasez de patrones de entrenamiento* reduciría significativamente su capacidad de generalización.

El proceso de clasificación de *OpenBCI*, inspirado por el clasificador desarrollado por Christin Schäfer [26, 27, 31, 32], resuelve este problema por medio de la integración temporal de *toda* la evidencia disponible hasta el instante  $t$ . Para ésto realiza clasificaciones instantáneas que luego integra en una decisión para el intervalo de tiempo transcurrido. La figura 5.1 ilustra este proceso. Cómo se detallará en lo siguiente, esta estrategia aborda los problemas enunciados al comienzo del capítulo.

---

<sup>2</sup>i.e. corresponde al retardo implícito al cálculo de las características, por ejemplo, aquel producido por el filtrado

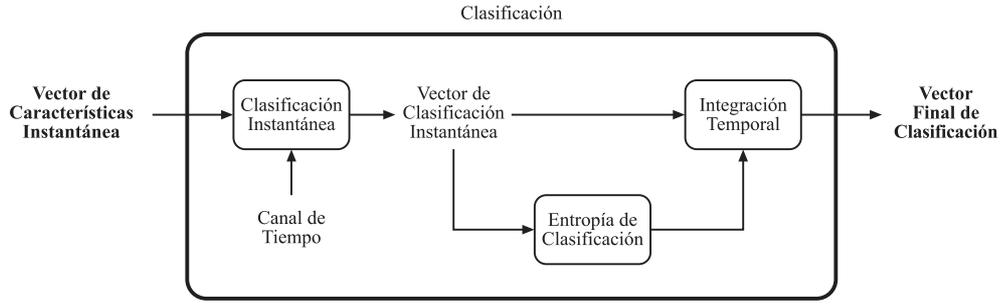


Figura 5.1: El proceso de clasificación de *OpenBCI*.

La notación para la asignación de una clase corresponde a la siguiente. Supóngase que el sistema debe ser capaz de discriminar entre  $N_C$  TMs las cuales se identificarán con los números naturales  $1, 2, \dots, N_C$  respectivamente. La probabilidad de que la TM actual representada por medio de  $X$  pertenezca a la clase  $c$ -ésima es  $P(c|X)$ , i.e. la probabilidad condicional de que pertenezca a la clase  $c$  dado el ejemplo  $X$ . Juntando probabilidades asociadas a todas las clases posibles, se obtiene un vector de clase

$$Y = \begin{pmatrix} P(1|X) \\ P(2|X) \\ \vdots \\ P(N_C|X) \end{pmatrix} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_{N_C} \end{pmatrix} \quad (5.1.1)$$

cuyos elementos toman valores en  $[0; 1]$ . El vector de clases puede interpretarse de dos formas distintas que tienen un efecto directo sobre el diseño del clasificador.

- *Variables aleatorias binarias e independientes o clasificación analítica:* Si se asume que las  $N_C$  clases pueden ocurrir en forma simultánea e independiente, entonces el vector  $Y$  debe interpretarse como un conjunto de probabilidades binarias independientes entre sí. Este enfoque es útil para el modelamiento de conjuntos (difusos), en donde puede darse la manifestación simultánea de dos o más TMs simultáneamente.

Para este caso,  $y_j = P(c_j|X)$  corresponde a la probabilidad de que  $X$  pertenezca a la clase  $c_j$ -ésima. Nótese que también puede ocurrir que la TM no pertenezca a ninguna de las clases consideradas.

- *Distribución de probabilidad o clasificación holística:* En contraste, si se supone que la información  $X$  corresponde sólo a una clase, entonces los valores  $y_1, \dots, y_{N_C}$  representan una distribución de probabilidad de una misma variable aleatoria. En este caso, se asume que debe ocurrir una de las TMs.

Nótese que una clasificación perfecta correspondería a un vector  $Y$  cuyas componentes  $y_j$  valen

$$y_j = \begin{cases} 1 & \text{si } j = c \\ 0 & \text{si } j \neq c \end{cases} \quad (5.1.2)$$

para el caso en que el ejemplo  $X$  presentado pertenezca a la clase  $c$ -ésima.

## 5.2. Clasificación Instantánea

Bajo el contexto considerado, una clasificación instantánea  $Y_t$  corresponde a la asignación de una clase a un vector de características instantáneo  $X_{t-T_r}$  que posiblemente caracteriza a una ventana de tiempo limitada, centrada en el instante  $t - T_r$ . Es decir,

$$Y_t = \begin{pmatrix} P(c_1|X_{t-T_r}) \\ P(c_2|X_{t-T_r}) \\ \vdots \\ P(c_{N_C}|X_{t-T_r}) \end{pmatrix} \quad (5.2.1)$$

La interpretación exacta de este vector puede ser holística ó analítica, dependiendo del diseño del clasificador, análogo a la ecuación (5.1.1).

La importancia de la clasificación instantánea radica en la necesidad de generar información (temporalmente) local sobre el estado de clasificación, que pueda ser integrada en forma sencilla dentro de una decisión global. Como efecto secundario beneficioso, este enfoque permite utilizar un sólo clasificador instantáneo de complejidad reducida común para todo instante  $t$ . Además, dado que para este caso cada fila de una matriz de características corresponde a un patrón de entrenamiento, el conjunto de entrenamiento resultante es muy grande.

Antes de proseguir, cabe mencionar un detalle sobre los vectores de características. Debido a la dependencia temporal de la actividad electrofisiológica (figura 5.2) es necesario anclarlos a su instante de tiempo, ya que, en su forma actual, carecen de esta información. Esto se resuelve por medio de la incorporación de un canal temporal explícito

$$X'_t = [X_t, t] \quad (5.2.2)$$

donde se obtienen nuevos vectores  $X'_t$  que servirán de entrada al clasificador instantáneo.

La *variabilidad de la manifestación* exige el empleo de un clasificador instantáneo robusto, tolerante a distorsiones espaciales y temporales (figura 5.3). En *OpenBCI*, la distorsión temporal se ha convertido esencialmente a una distorsión espacial por medio de la inclusión del canal de tiempo. Se ha optado por el uso de una red neuronal

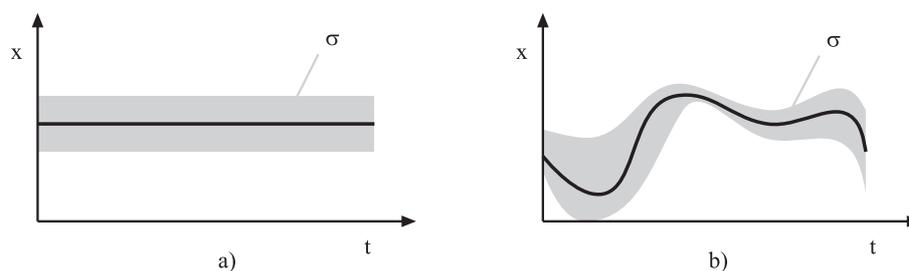


Figura 5.2: Dependencia temporal de un TM.

La ejecución de una TM da origen a una actividad cerebral que depende del tiempo. En la figura, se contrasta un caso de independencia temporal (panel a) con un caso de dependencia temporal (panel b). Ambos procesos estocásticos se representan por medio de su media (línea sólida) y su desviación estándar (región pintada). En general el nivel de varianza es muy alto, indicando una gran distorsión espacial.

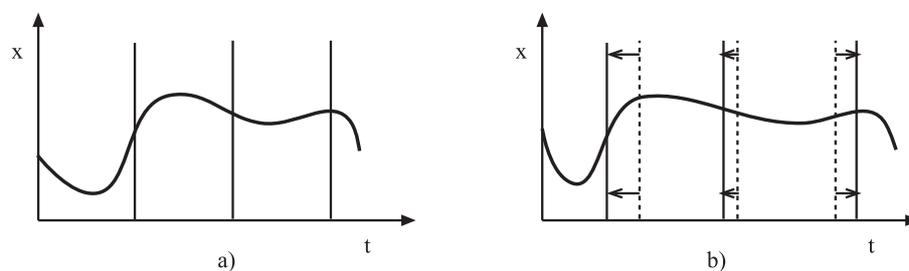


Figura 5.3: Distorsión temporal (*Time warping*)

A la distorsión espacial que quedó manifiesta en la figura (5.2) se le suma la distorsión temporal o *time warping*. Este tipo de distorsión es muy común en los problemas de reconocimiento de voz, donde una misma palabra puede ser pronunciada en forma lenta o rápida. En la figura se observa una TM (panel a) y una versión temporalmente distorsionada de ella (panel b).

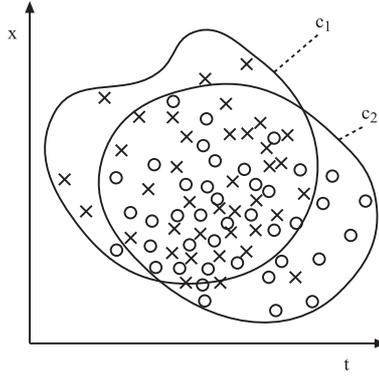


Figura 5.4: Mapeo a regiones suaves en espacio-tiempo continuo.

Los ejemplos pertenecientes a las clases  $c_1$  y  $c_2$ , representados por  $\times$  y  $\circ$  respectivamente, se mapean a un espacio-tiempo continuo. Ambos conjuntos se modelan por medio de regiones continuas de fronteras suaves, de baja complejidad.

multicapa de baja complejidad como clasificador instantáneo [24]. Con éste, se persigue el objetivo de forzar los vectores de características a un espacio-tiempo de entrada continuo, donde las clases están delimitadas por bordes suaves, cómo se ilustra en la figura (5.4).

### 5.3. Red Neuronal Multicapa

En lo que sigue, el autor se limitará a detallar la arquitectura neuronal particular empleada en *OpenBCI*. El detalle completo se escapa de los objetivos de este trabajo, por lo que se recomienda usar como referencia uno de los numerosos textos introductorios de excelente calidad [46, 47, 48, 49].

#### 5.3.1. Conjunto de Entrenamiento

Sean  $X^1, X^2, \dots, X^{N_{pats}}$  las  $N_{pats}$  matrices de características calculadas a partir de los *trials* registrados. Cabe recordar que éstas tienen  $T$  filas, una para cada instante de tiempo. A cada matriz  $X$  se le asocia un vector de clase  $D$ , cuyas componentes  $d_j$  valen

$$d_j = \begin{cases} 1 & \text{si } j = c \\ 0 & \text{si } j \neq c \end{cases} \quad (5.3.1)$$

si  $X$  corresponde a un *trial* de la clase  $c$ -ésima.

El conjunto de entrenamiento para la red neuronal consiste en pares  $(\mathbf{x}, \mathbf{d})$ , donde  $\mathbf{x}$  es la entrada y  $\mathbf{d}$  la salida deseada. Se genera un patrón por *trial* e instante de tiempo, obteniendo así un total de  $N_{train} \equiv N_C \times N_{pats}$ . Las entradas  $\mathbf{x}$  son las filas de los *trials*

y las salidas deseadas  $\mathbf{d}$  son iguales al vector de clases  $D$  respectivo. Al igual que en el caso de las matrices de características, los vectores de entrada y salida se identificarán con un superíndice, como en  $\mathbf{x}^i$  e  $\mathbf{y}^i$ .

Como puede verse, en la construcción del conjunto de entrenamiento se aspira al caso ideal de una clasificación perfecta.

### 5.3.2. Arquitectura

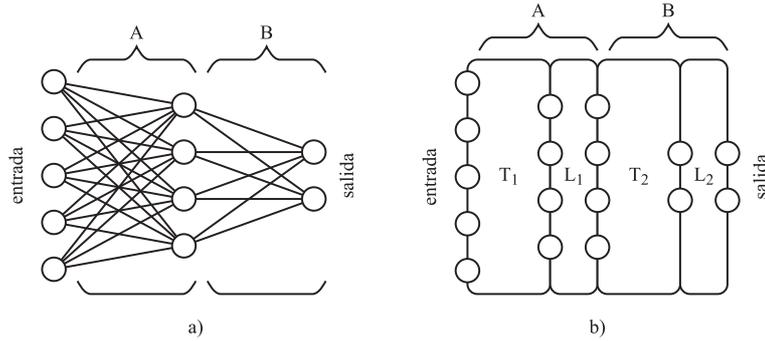


Figura 5.5: Red neuronal de dos capas de pesos.

El panel (a) ilustra una red neuronal de dos capas (arquitectura 5-4-2) usando la iconografía tradicional empleada en la literatura. En forma equivalente, se puede ver la red como una composición de cuatro funciones  $T_1$ ,  $L_1$ ,  $T_2$  y  $L_2$  respectivamente.  $T_1$  y  $T_2$  son transformaciones afines, mientras que  $L_1$  y  $L_2$  son funciones de activación.

En *OpenBCI* se puede escoger entre dos tipos de arquitecturas para la red neuronal: arquitectura holística y arquitectura analítica. Ambas corresponden a redes neuronales de dos capas de pesos (figura 5.5), pero difieren en las funciones de activación y el criterio de error utilizado. Sea  $F : \mathbb{R}^{in} \rightarrow \mathbb{R}^{out}$  la función vectorial calculada por la red neuronal, donde *in* es la dimensión de entrada, y *out* la dimensión de salida.  $F$  puede verse como la composición de cuatro subfunciones  $F = T_1 \circ L_1 \circ T_2 \circ L_2$ , cuyas dimensiones son

$$\begin{aligned} T_1 : \mathbb{R}^{in} &\rightarrow \mathbb{R}^{mid} & L_1 : \mathbb{R}^{mid} &\rightarrow \mathbb{R}^{mid} \\ T_2 : \mathbb{R}^{mid} &\rightarrow \mathbb{R}^{out} & L_2 : \mathbb{R}^{out} &\rightarrow \mathbb{R}^{out} \end{aligned}$$

donde *mid* es el número de unidades ocultas. Estas funciones, y el criterio de error  $E$ , se escogen en base a lo prescrito en el cuadro 5.1.

Las configuraciones prediseñadas del cuadro 5.1 se han escogido en base a fundamentos teóricos estadísticos y a evidencia empírica. La primera capa de pesos optimiza

Componente	Holística	Analítica
$T_1$	$afin_{in}^{mid}$	$afin_{in}^{mid}$
$L_1$	$tanh_{mid}$	$tanh_{mid}$
$T_2$	$afin_{mid}^{out}$	$afin_{mid}^{out}$
$L_2$	$softmax_{out}$	$logistic_{out}$
$E$	$CEF_{out}$	$CEE_{out}$

Cuadro 5.1: Forma de las subfunciones del clasificador instantáneo.

La tabla muestra cómo deben escogerse las subfunciones que conforman la función  $F$  implementada por la red neuronal, para la interpretación holística ó analítica de los resultados. La componente  $E$  denota a la función de error que debe emplearse.

el entrenamiento de la red neuronal. La segunda capa, más específicamente la función de activación de la segunda capa en conjunto con el criterio de error, incorpora las restricciones necesarias para posibilitar la interpretación holística o analítica de los resultados.

### 5.3.3. Funciones Vectoriales y Criterios de Error

A continuación se detalla la forma de cada una de las subfunciones y criterios posibles, junto con las derivadas necesarias para poder aplicar el algoritmo de entrenamiento.

**Transformación Afín:** Una *transformación afín* (denotada  $afin_n^m : \mathbb{R}^n \rightarrow \mathbb{R}^m$ ) es una función vectorial que se caracteriza por una matriz  $A$  de  $m \times n$  y un vector  $\mathbf{b}$  de  $n \times 1$ <sup>3</sup>:

$$\mathbf{y} = afin_n^m(\mathbf{x}) = A\mathbf{x} + \mathbf{b}. \quad (5.3.2)$$

La matriz  $A$  y el vector  $\mathbf{b}$  son los parámetros de la función. En un esquema de optimización de estos parámetros, se requiere del gradiente del error con respecto a  $A$  y  $\mathbf{b}$ ,

$$\frac{\partial E}{\partial A} = \mathbf{x} \frac{\partial E}{\partial \mathbf{y}}, \quad \frac{\partial E}{\partial \mathbf{b}} = \frac{\partial E}{\partial \mathbf{y}}, \quad (5.3.3)$$

y con respecto a sus entradas,

$$\frac{\partial E}{\partial \mathbf{x}} = \frac{\partial E}{\partial \mathbf{y}} A, \quad (5.3.4)$$

donde  $\frac{\partial E}{\partial \mathbf{y}}$  es el gradiente del error.

---

<sup>3</sup>En la literatura de redes neuronales, se habla de la matriz de *pesos*  $A$  y el vector de *umbrales de activación*  $\mathbf{b}$  en honor al análogo biológico que sirvió como fuente de inspiración.

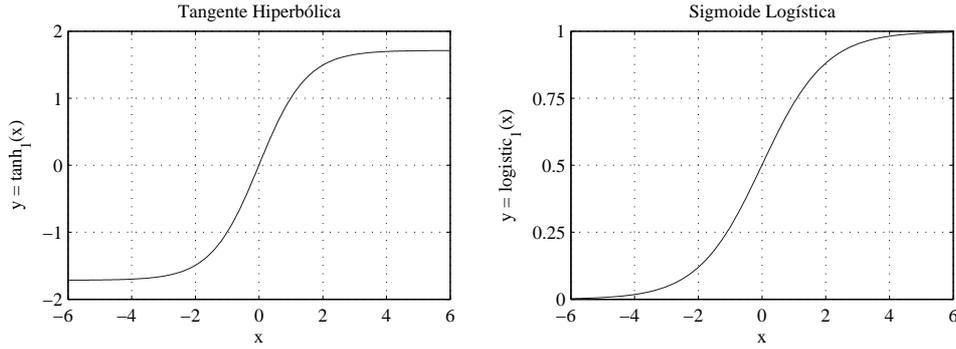


Figura 5.6: Funciones de Activación

En la figura se puede apreciar una comparación entre las funciones de activación *tangente hiperbólica* y *sigmoide logística*.

**Tangente Hiperbólica (Modificada):** Ambas configuraciones arquitectónicas de la red neuronal de *OpenBCI* utilizan en su primera capa una versión modificada de la función de activación *tangente hiperbólica* (denotada  $\tanh_n : \mathbb{R}^n \rightarrow \mathbb{R}^n$ ). Experimentalmente se ha mostrado que ésta favorece la convergencia rápida del algoritmo de entrenamiento. La función está dada por

$$y_i = 1,7159 \tanh\left(\frac{2x_i}{3}\right) \quad (5.3.5)$$

y el gradiente del error con respecto a cada una de sus entradas es

$$\frac{\partial E}{\partial x_i} = 1,1439 \left(1 - \tanh^2\left(\frac{2x_i}{3}\right)\right) \frac{\partial E}{\partial y_i}. \quad (5.3.6)$$

**Sigmoide Logística:** Para la interpretación analítica, se utiliza la función *sigmoide logística* (denotada  $\text{logistic}_n : \mathbb{R}^n \rightarrow \mathbb{R}^n$ ):

$$y_i = \frac{1}{1 + \exp(-x_i)} \quad (5.3.7)$$

cuyo gradiente del error con respecto a cada una de sus entradas es

$$\frac{\partial E}{\partial x_i} = y_i (1 - y_i) \frac{\partial E}{\partial y_i}. \quad (5.3.8)$$

**Softmax:** Para la interpretación holística, se requiere del uso de la función de activación conocida como *softmax* (denotada  $\text{softmax}_n : \mathbb{R}^n \rightarrow \mathbb{R}^n$ ):

$$y_i = \frac{\exp(-x_i)}{\sum_{k=1}^n \exp(-x_k)} \quad (5.3.9)$$

cuyo gradiente del error con respecto a cada una de sus entradas es

$$\frac{\partial E}{\partial x_i} = \sum_{k=1}^n y_k (\delta_k^i - y_i) \frac{\partial E}{\partial y_j}. \quad (5.3.10)$$

Nótese que en el caso de *softmax* el Jacobiano no es diagonal. La propiedad importante de esta función de activación es que sus salidas cumplen las restricciones de una distribución de probabilidad discreta, i.e.  $\sum_{i=1}^n y_i = 1$  y que  $\forall i, y_i \geq 0$ .

**Entropía Cruzada, Error:** El *error de entropía cruzada* (denotado por  $CEE_n$ <sup>4</sup>) se define por

$$CEE_n = \frac{1}{N_{train}} \sum_{k=1}^{N_{train}} \sum_{i=1}^n [d_i^k \ln y_i^k + (1 - d_i^k) \ln(1 - y_i^k)] \quad (5.3.11)$$

y es una medida de disimilitud entre la respuestas  $\mathbf{y}^k = F(\mathbf{x}^k)$ ,  $k = 1, \dots, N_{train}$  entregadas por la red y las salidas deseadas  $\mathbf{d}^k$  [46, 47]. El error de entropía cruzada asume que  $\mathbf{y}$  y  $\mathbf{d}$  sean vectores cuyas componentes (independientes entre sí) tengan valores en  $[0;1]$ . Esta restricción se respeta por medio del uso de la función de activación *logistic<sub>n</sub>* en la salida de la red neuronal.

El gradiente de este criterio está dado por

$$\frac{\partial CEE_n}{\partial y_i} = -\frac{1}{N_{train}} \sum_{k=1}^{N_{train}} \frac{y_i^k - d_i^k}{y_i^k (1 - d_i^k)} \quad (5.3.12)$$

**Entropía Cruzada, Función:** La *función de entropía cruzada* (denotado por  $CEF_n$ <sup>5</sup>) se define por

$$CEF_n = -\frac{1}{N_{train}} \sum_{k=1}^{N_{train}} \sum_{i=1}^n d_i^k \ln \frac{y_i^k}{d_i^k} \quad (5.3.13)$$

y corresponde a una medida de disimilitud para salidas que se interpretan como distribuciones de probabilidad discretas [46, 47]. En este caso,  $CEF_n$  entrega una diferencia entre las salidas entregadas por la red  $\mathbf{y}^k = F(\mathbf{x}^k)$  y las salidas deseadas  $\mathbf{d}^k$ , con  $k = 1, \dots, N_{train}$ . Las restricciones sobre las componentes de  $\mathbf{y}^k$  se respetan por el uso de la función de activación *softmax<sub>n</sub>* en la salida de la red neuronal.

El gradiente de este criterio está dado por

$$\frac{\partial CEF_n}{\partial y_i} = -\frac{1}{N_{train}} \sum_{k=1}^{N_{train}} \frac{d_i^k}{y_i^k} \quad (5.3.14)$$

<sup>4</sup>del inglés *cross-entropy-error*

<sup>5</sup>del inglés *cross-entropy-function*

### 5.3.4. Entrenamiento

La red neuronal de *OpenBCI* se entrena por medio del algoritmo de aprendizaje conocido como *Resilient Error-Backpropagation* (RPROP) [50]. Este algoritmo emplea una estrategia de búsqueda de un mínimo muy eficiente, de complejidad lineal tanto en tiempo como en espacio, basada en pasos que se ajustan en incrementos (decrementos) exponenciales de los parámetros. Cada uno se actualiza en forma individual, considerando sólo el signo de la derivada del error, y no la magnitud de éste. Como resultado, se obtiene un método de primer orden muy sencillo que en la práctica resulta competitivo con respecto a otros algoritmos de optimización más sofisticados como por ejemplo *Gradiente Conjugado*.

Sean  $w_k, k = 1, 2, \dots$  los parámetros de la red neuronal. La regla de actualización para la iteración  $\tau$ -ésima es

$$w_k^{(\tau)} \leftarrow w_k^{(\tau-1)} + \Delta w_k^{(\tau-1)} \quad (5.3.15)$$

Los valores  $\Delta w_k^{(\tau)}$  se calculan como

$$\Delta w_k^{(\tau)} = \begin{cases} -\Delta_k^{(\tau)} & , \text{ si } \frac{\partial E}{\partial w_k}^{(\tau)} > 0 \\ +\Delta_k^{(\tau)} & , \text{ si } \frac{\partial E}{\partial w_k}^{(\tau)} < 0 \\ 0 & , \text{ sino} \end{cases} \quad (5.3.16)$$

donde  $\Delta_k^{(\tau)}$  es el *valor de ajuste* para el  $k$ -ésimo parámetro en la iteración  $\tau$  del algoritmo que se inicializa en la primera iteración del algoritmo en 0,1. Para las siguientes iteraciones se obtiene empleando la regla

$$\Delta_k^{(\tau)} = \begin{cases} \nu^+ \cdot \Delta_k^{(\tau-1)} & , \text{ si } \frac{\partial E}{\partial w_k}^{(\tau)} \cdot \frac{\partial E}{\partial w_k}^{(\tau-1)} > 0 \\ \nu^- \cdot \Delta_k^{(\tau-1)} & , \text{ si } \frac{\partial E}{\partial w_k}^{(\tau)} \cdot \frac{\partial E}{\partial w_k}^{(\tau-1)} < 0 \\ \Delta_k^{(\tau-1)} & , \text{ sino} \end{cases} \quad (5.3.17)$$

donde  $\nu^+$  es la rapidez de incremento y  $\nu^-$  es la rapidez de decremento. Se ha determinado empíricamente que valores apropiados para éstos son  $\nu^+ = 1,2$  y  $\nu^- = 0,5$ .

### 5.3.5. Otras Consideraciones

**Dimensiones de la red:** En *OpenBCI*, las dimensiones de la red neuronal vienen dadas por la elección de los valores  $in, mid$  y  $out \in \mathbb{N}$ . Los tamaños  $in$  y  $out$  son fijos, y están dados por la dimensión de los vectores de características instantáneos y el número de clases respectivamente.  $mid$  regula la *complejidad* de la red neuronal: su valor determina los grados de libertad del modelo. Un valor pequeño da origen a un espacio de funciones  $F$  sencillas, mientras que un valor grande permite funciones  $F$



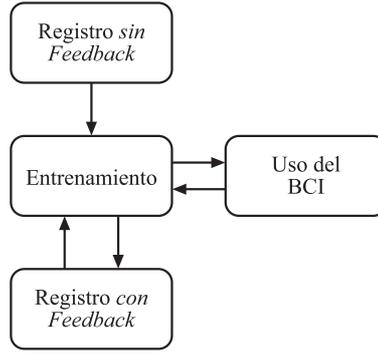


Figura 5.7: Diagrama de modos de uso del BCI.

## 5.4. Integración Temporal

Como resultado del clasificador instantáneo, se obtiene un flujo de clasificaciones que parten prácticamente desde en el inicio del *trial*:

$$Y_{T_r+1}, Y_{T_r+2}, Y_{T_r+3}, \dots \quad (5.4.1)$$

Este flujo se produce mientras el usuario ejecuta la TM asociada al comando que desea ejecutar y finaliza en el instante  $T$ , en donde el sistema toma una decisión final. Sin embargo, el sistema debe brindar una retroalimentación apropiada sobre el estado de la decisión *durante* el transcurso del *trial*. Es decir, el usuario necesita un *feedback* en cada instante  $t$  para guiarlo en su propósito. En principio se podría utilizar la propia secuencia para cumplir con este requisito, pero debido la naturaleza estocástica de las señales cerebrales, sería una retroalimentación muy inestable. En cambio, una mejor aproximación es la utilización de toda la información disponible hasta el instante, i.e. generar una respuesta en base a la combinación de

$$Y_{T_r+1}, \dots, Y_t \quad (5.4.2)$$

produciendo una decisión integrada hasta el instante  $t$  que se denotará como  $Y_{\leq t}$ . La idea consiste en la integración de la evidencia sobre el proceso de clasificación acumulada a lo largo del tiempo. Ésta se puede obtener por medio de la esperanza del vector de probabilidad de clase con respecto al poder discriminativo de cada instante de tiempo.

Más formalmente,  $Y_{\leq t}$  se obtiene como la suma ponderada

$$Y_{\leq t} = \sum_{\tau=T_r+1}^t w_{\tau} Y_{\tau} \quad , \quad \text{con} \quad \sum_{\tau=T_r+1}^t w_{\tau} = 1 \quad (5.4.3)$$

para el caso holístico, en donde  $w_\tau \geq 0$  mide el nivel de certeza que se dispone sobre la evidencia  $Y_\tau$ , ó

$$Y_{\leq t} = \begin{pmatrix} \sum_{\tau} w_{1,\tau} y_{1,\tau} \\ \sum_{\tau} w_{2,\tau} y_{2,\tau} \\ \vdots \\ \sum_{\tau} w_{N_C,\tau} y_{N_C,\tau} \end{pmatrix}, \quad \text{con} \quad \sum_{\tau=T_r+1}^t w_{j,\tau} = 1 \text{ para todo } j \quad (5.4.4)$$

para el caso analítico, en donde  $w_{j,\tau} \geq 0$  mide el nivel de certeza que se dispone sobre la evidencia  $y_{j,\tau}$  y donde  $\sum_{\tau}$  denota a una sumatoria sobre los tiempos  $\tau = T_r + 1$  hasta  $\tau = t$ .

Las fórmulas anteriores pueden resultar intimidantes a primera vista, pero en realidad tienen una razón muy sencilla. Primero que nada, lo que se está calculando es la esperanza (hasta  $t$ ) del vector de clase holístico

$$Y_{\leq t} = \mathbf{E}_{\leq t}[Y] \quad (5.4.5)$$

en donde el vector completo representa una distribución de probabilidad, y la esperanza (hasta  $t$ ) del vector de clase analítico

$$Y_{\leq t} = \begin{pmatrix} \mathbf{E}_{\leq t}[y_1] \\ \mathbf{E}_{\leq t}[y_2] \\ \vdots \\ \mathbf{E}_{\leq t}[y_{N_C}] \end{pmatrix} \quad (5.4.6)$$

en donde cada componente representa una variable aleatoria binaria e independiente. Las restricciones que se imponen sobre los pesos  $w_\tau$  (caso holístico) y los pesos  $w_{j,\tau}$  (caso analítico) hacen de éstas las distribuciones de probabilidad necesarias para permitir el cálculo de las esperanzas.

Todavía no se ha especificado la forma exacta de los pesos utilizados en el cálculo de las esperanzas anteriores. Idealmente, estos pesos deberían resaltar aquellos instantes en donde se manifiesta una TM en forma certera, y tender a suprimir los tiempos en donde predomina confusión. El integrador temporal de *OpenBCI* mide este nivel de certeza en base a la entropía de clasificación.

### 5.4.1. Entropía de Clasificación

La entropía es una medida del nivel de información contenido en una distribución de probabilidad. Su valor se maximiza para distribuciones uniformes, indicando un gran nivel de incertidumbre. Cuando una distribución tiende a concentrarse en torno a pocos valores, el valor de la entropía decrece, siendo el caso extremo aquel en que la distribución vale uno para un sólo valor y cero para los demás. En este caso, la entropía vale exactamente cero.

Para una variable aleatoria  $X$  con valores  $x_1, x_2, \dots, x_N$  con probabilidades  $p_1, p_2, \dots, p_N$  respectivamente, su *entropía* se define como

$$H(X) = - \sum_{i=1}^N p_i \log_2 p_i \quad (5.4.7)$$

Si la variable aleatoria es uniforme, es decir  $p_i = p_j$  para cualquier combinación de  $i$  y  $j$  posible, entonces se maximiza la entropía y toma el valor

$$H_{\text{máx}}(X) = - \sum_{i=1}^N \frac{1}{N} \log_2 \frac{1}{N} = \log_2 N \quad (5.4.8)$$

A partir de los valores anteriores se puede definir la *negentropía* de una variable aleatoria, dada por

$$N(X) = H_{\text{máx}}(X) - H(X) \quad (5.4.9)$$

Ésta, en contraste con la entropía, corresponde a una medida efectiva de la certidumbre sobre el estado de la variable aleatoria.

Los pesos  $w_\tau$  y  $w_{j,\tau}$  para la clasificación holística y analítica se calculan normalizando (en el tiempo) a la negentropía de las variables aleatorias participantes. Para el caso holístico, están dados por

$$w_\tau = \frac{N(Y_\tau)}{\sum_{i=1}^t N(Y_i)} \quad (5.4.10)$$

y para el caso analítico, por

$$w_{j,\tau} = \frac{N(y_{j,\tau})}{\sum_{i=1}^t N(y_{j,i})} = \frac{1 - H(y_{j,\tau})}{t - \sum_{i=1}^t H(y_{j,i})} \quad (5.4.11)$$

Los valores  $t$  (instante actual),  $\tau$  (índice de tiempo) y  $j$  (índice de componente) concuerdan exactamente con aquellos empleados en las ecuaciones (5.4.3) y (5.4.11). En otras palabras, las fórmulas mencionadas se pueden completar por medio de un reemplazo textual de  $w_\tau$  y  $w_{j,\tau}$  respectivamente. La segunda igualdad en (5.4.11) se da porque las variables aleatorias son todas binarias, y en ese caso  $N(X) = 1 - H(X)$ .

### 5.4.2. Beneficios del Diseño

El diseño del integrador temporal anteriormente planteado goza de varios beneficios.

1. *Costo computacional:* El cálculo del vector de clasificación integrado  $Y_{\leq t}$  es muy económico en términos computacionales. Para el caso holístico, manteniendo dos variables,

$$S_Y = \sum_{\tau=T_r+1}^t w_\tau Y_\tau, \quad S_w = \sum_{\tau=T_r+1}^t w_\tau$$

que se actualizan en cada iteración por medio de

$$S_Y \leftarrow S_Y + w_t Y_t, \quad S_w \leftarrow S_w + w_t$$

se obtiene el vector  $Y_{\leq t}$  instantáneamente con

$$Y_{\leq t} = \frac{1}{S_w} S_Y$$

Con esta estrategia se puede ir actualizando el valor de  $Y_{\leq t}$  en forma incremental. Para el caso analítico se puede emplear un método análogo.

2. *Complejidad:* El integrador temporal no corresponde a un modelo que requiera entrenamiento. Simplemente se trata de un método de combinación de resultados parciales y no necesita ajustes adicionales.
3. *Fundamentación:* Las decisiones que se han tomado en el diseño del integrador temporal están respaldadas por fundamentos teóricos. Se ha evitado introducir heurísticas o elementos arbitrarios.
4. *Corrección de errores:* La estrategia integrativa posee un efecto secundario positivo. Las clasificaciones instantáneas asociadas a distorsiones que no pertenecen a ninguna de las clases consideradas se ponderan con un coeficiente muy bajo debido a su alta entropía y son prácticamente excluidos de la integración temporal. Esto es especialmente útil para la eliminación de artefactos que pueden estar presentes en la señal EEG.

# Capítulo 6

## Simulación y Resultados

En los capítulos previos se ha descrito un proceso que produce un vector de clase a partir de un *trial* EEG generado por un operador de un sistema BCI. En este capítulo se presentan algunos resultados obtenidos al aplicar el método de clasificación.

### 6.1. BCI Competition 2003

Desde el año 2000 se realiza anualmente la competencia llamada *BCI-Competition*, cuyo objetivo es la validación de métodos de procesamiento de señales y clasificación aplicados a BCIs [31]. A pesar de la imposibilidad de medir el desempeño de un sistema BCI completo a través de esta competencia, el evento persigue motivar a la comunidad científica confrontándola con problemas difíciles. En ella han surgido una multitud de contribuciones interesantes que exploran nuevas formas de procesamiento.

La competencia consiste en la publicación de conjuntos de datos EEG de diferente índole. Para cada conjunto se establecen metas y medidas de desempeño. El objetivo de los participantes consiste en el diseño y la aplicación de mecanismos de procesamiento sobre estas señales cerebrales para optimizar el criterio estipulado. Más técnicamente, cada conjunto de datos consiste en registros de *trials* de actividad EEG espontánea, donde una parte se halla etiquetada (conjunto de entrenamiento), la otra sin etiquetas (conjunto de prueba), y una medida de desempeño. El objetivo consiste en la inferencia de las etiquetas reales del conjunto de prueba (desconocidas para los participantes) que maximicen la medida de desempeño a partir de la información que puedan extraer del conjunto de entrenamiento. Como resultado de esta competencia se publica un artículo en la revista *IEEE Transactions on Biomedical Engineering*, en donde los ganadores podrán describir su algoritmo.

En la competencia *BCI-Competition III*, realizada el año 2003, se publicó un conjunto de datos cuya forma es ideal para poner a prueba el sistema de clasificación de *OpenBCI*.

Además, los resultados sirvieron para poder comparar el método propuesto contra los utilizados por lo participantes [32, 33]. El conjunto fue puesto a disposición por el Departamento de Informática Médica del Instituto para la Ingeniería Biomédica de la Universidad Tecnológica de Graz, bajo la supervisión del profesor Gert Pfurtscheller. De ahora en adelante se referirá a este conjunto de datos como los *datos de Graz*.

### 6.1.1. Datos de Graz

Este conjunto de datos fue registrado de un sujeto (femenino, 25 años) en condiciones físicas y mentales normales durante una sesión con *feedback* visual. La tarea consistía en controlar una barra por medio de la imaginación del movimiento de mano izquierdo o derecho. El orden en que se solicitaban estas acciones fue escogido aleatoriamente.

El experimento consistió en la ejecución de 7 sesiones, registrándose 40 *trials* en cada uno. Todas las sesiones se llevaron a cabo durante el mismo día, con varios minutos de descanso entre ellas. En total, se obtuvieron 280 *trials* EEG de 9 segundos de duración, cuya estructura se ilustra en la figura 6.1, panel derecho. El *feedback* se basó en parámetros AAR<sup>1</sup> de los canales 1 y 2, que fueron combinados por medio del uso de un análisis de discriminantes en un sólo valor de salida. Las señales EEG se adquirieron por medio del uso de un amplificador G.tec con electrodos Ag/AgCl. Se registró un total de tres canales bipolares (anterior +, posterior -) sobre las posiciones  $C_3$ ,  $C_4$  y  $C_z$ . La tasa de muestreo fue de 128 Hz.

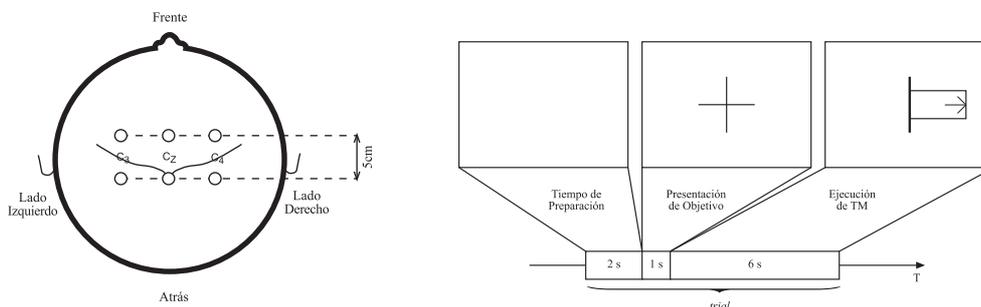


Figura 6.1: Datos de Graz.

En el panel izquierdo se ilustra la configuración bipolar utilizada para registros tres canales sobre las posiciones  $C_3$ ,  $C_4$  y  $C_z$ , que corresponden a las zonas sensorimotoras discriminantes entre un movimiento de mano izquierda y derecha. La estructura de un *trial* EEG se presenta en el panel derecho. En el instante  $t = 2$  segundos, un sonido emitido por el BCI le indica al operador el comienzo del cuerpo del *trial*.

<sup>1</sup>Adaptive Auto-Regressive

El conjunto de datos se divide en dos. La primera mitad contiene 140 *trials* etiquetados que deben usarse para entrenar al sistema de clasificación, mientras que la segunda mitad consiste en 140 *trials* no-etiquetados. Previo a la división del conjunto original de 280 *trials* en un conjunto de entrenamiento y otro de prueba, los registros EEG constituyentes fueron mezclados aleatoriamente para evitar los errores sistemáticos que podrían haber ocurrido debido al *feedback*.

Las circunstancias particulares en que se registraron los *trials* EEG, es decir, las TMs basadas en condicionamiento operante que se asociaron a las clases, la estructura de los *trials* EEG, la meta propuesta, y la existencia de resultados que sirven para una comparación, convierten a los datos de Graz en un desafío idóneo para aplicar el método de clasificación de *OpenBCI*.

La importancia que representa este problema para el trabajo presente va más allá de su mera utilización como conjunto de *Benchmark*. Sus peculiaridades, tanto en la configuración del experimento de adquisición de datos electrofisiológicos, como en las soluciones propuestas por los participantes, ha servido como principal fuente de inspiración para el diseño del método de clasificación desarrollado. Por lo tanto, la similitud en el diseño de *OpenBCI* y la configuración de sus parámetros de extracción de características con aquellos utilizados por los competidores, no es fruto de coincidencias accidentales, sino que constituyeron la base para el desarrollo.

### 6.1.2. Requerimientos

La tarea consiste en proveer un sistema de análisis que pueda ser utilizado para el control de un sistema de feedback continuo. Para ésto, el sistema debe responder en cada instante de tiempo con un valor continuo  $d$ , donde  $d < 0$  corresponde a la clase 1, y  $d > 0$  a la clase 2. La magnitud de este valor debe reflejar la confianza del proceso de clasificación, y el signo a la clase.

### 6.1.3. Evaluación

Existe una relación muy cercana entre la tasa de error y la información mutua. Se propone el uso de la información mutua como medida de desempeño del sistema de *feedback* porque ésta también toma en cuenta a la magnitud de sus respuestas. El criterio de evaluación consiste en el valor máximo de la información mutua que alcanza el sistema a partir del instante  $t = 4$  segundos. Una discusión más extensa puede hallarse en [32].

#### 6.1.4. Competidores

En la competencia participaron un total de siete equipos de investigación que enviaron un total de nueve conjuntos de resultados distintos. Un participante fue eliminado porque envió solamente etiquetas para cada *trial* EEG, sin proveer información continua ni en magnitud ni en tiempo. A continuación se explica brevemente el método utilizado para obtener los resultados, detallando las características y el algoritmo de clasificación utilizados. El cuadro 6.1 presenta a los participantes y a sus grupos de investigación.

**Grupo A (GAO Xiarong):** *Características:* Energías de  $C_3$  y  $C_4$  para las bandas 10-12 Hz. *Clasificación:* Análisis de Discriminantes Lineales.

**Grupo B (A.R. Safari):** *Características:* Parámetros AAR. *Clasificación:* Se entrenaron varias redes neuronales para distintos segmentos de tiempo. Los resultados de aquellos intervalos de tiempo que se traslaparon se promediaron.

**Grupo C (Christin Schäfer):** *Características:* Filtrado Morlet para extraer frecuencias 10 y 22 Hz de los canales  $C_3$  y  $C_4$ . *Clasificación:* Estimación de una distribución normal multivariada para cada una de las clases. Los instantes de tiempo previos se integran ponderándolos de acuerdo al error de Bayes [26, 27].

**Grupo D (Jorge del Río Vera):** *Características:* Análisis de componentes lineales. *Clasificación:* Red neuronal multicapa.

**Grupo E (Thorsten Zander):** *Características:* Evolución temporal de potencia de la banda *Mu* a partir de modelos AAR, ponderados por medio de un vector de pesos variable en el tiempo. *Clasificación:* Clasificador lineal.

**Grupo F (Akash Narayana):** *Características:* Primero se obtuvo la potencia espectral autoregresiva para cuatro bandas de frecuencia. Luego, se calcularon los cuocientes para estas energías en  $C_3$  y  $C_4$ . *Clasificación:* Análisis de Discriminantes Lineales.

**Grupo G (Mohan Sadashivaiah):** *Características:* Se utilizaron los coeficientes de un modelo autoregresivo de orden 6. *Clasificación:* Análisis de Discriminantes Lineales.

**Grupo H (Dan Rissacher):** *Características:* Entropía espectral. *Clasificación:* Red neuronal multicapa.

Cuadro 6.1: Participantes de la competencia *BCI Competition III*, Datos de Graz.

Grupo	Autores	Laboratorio de Investigación
A	GAO Xiaorong, JIA Wenyan, Zhao Xianghua, GAO Shangkai, YANG Fusheng	Universidad Tsinghua, Beijing
B	A.R. Saffari, T. Emami, S. Ashkboos	Sahand Universidad de Tecnología, Tabriz, Irán
C	Christin Schäfer, Steven Lemm	Intituto Fraunhofer FIRST y Clínica Universitaria Benjamin Franklin, Berlín, Alemania
D	Jorge del Río Vera	España
E	Thorsten Zander, Guido Dornhege, Benjamin Blankertz	FIRST FhG, Berlín, Alemania
F	Akash Narayana, Mohan Sadashivaiah, Raveendran Rengaswamy, Shanmukh Katragadda	DaimlerChrysler Research & Technology India Pvt Ltd.
G	Mohan Sadashivaiah, Akash Narayana, Raveendran Rengaswamy, Shanmukh Katragadda	DaimlerChrysler Research & Technology India Pvt Ltd.
H	Dan Rissacher	Winooski, VT

### 6.1.5. Configuración de *OpenBCI*

*OpenBCI* es un sistema flexible, por razones que abarcan desde la configuración del montaje de electrodos, la selección de las componentes de frecuencia hasta la determinación de la arquitectura del clasificador. Las decisiones respectivas se detallan a continuación.

**Características:** El ganador de la competencia fue Christin Schäfer que obtuvo un resultado significativamente superior a los demás participantes. En vista de este hecho, se han utilizado características similares para facilitar una comparación directa. Es decir, se ha descartado el canal proveniente de la posición  $C_z$  por no aportar mucho poder discriminativo, y se ha extraído un total de 5 características: 4 bandas angostas de frecuencia más el canal de tiempo. Las bandas fueron centradas en las frecuencias 10 Hz y 22 Hz, obtenidas a partir de los canales  $C_3$  y  $C_4$ , que corresponden a las ondas *Beta* y *Mu* centrales. La figura 6.2, que ya ha servido anteriormente de ejemplo para la explicación de los ERD en la página 23, ilustra estas cuatro características.

**Clasificador:** Debido al montaje del experimento, cada *trial* siempre contiene información asociada a una de dos posibles clases. Debido a ésto, el clasificador debe ser operado en modo holístico. El tamaño de la capa oculta se escogió empíricamente en 5 unidades, resultando en una arquitectura 5-5-2. Del conjunto de entrenamiento se

descartó el 10 % de los *outliers*.

**Comparación con el método de Christin Schäfer (método C):** Cómo el método desarrollado por Christin Schäfer sirvió como principal fuente de inspiración para el sistema de clasificación desarrollado en esta memoria, hace falta una breve comparación.

Ambos métodos están basados en la integración temporal de clasificaciones instantáneas en una sola decisión. Los vectores de clasificación instantánea se combinan por medio de una suma ponderada. Sin embargo, ahí se acaban las similitudes, pues ambos métodos utilizan tanto clasificadores instantáneos como ponderadores diferentes. De hecho, el método C emplea  $T$  distintos clasificadores Bayesianos Gaussianos (uno para cada instante de tiempo), mientras que *OpenBCI* emplea una sola red neuronal para minimizar el número de parámetros para el conjunto reducido de ejemplos de entrenamiento disponibles. Los ponderadores del método C miden el nivel de confusión del *clasificador* utilizado estimando la cota superior del error de clasificación de Bayes haciendo uso de las cotas de *Chernoff*. La generalización de estas cotas a más de dos clases no es evidente. Los ponderadores resultantes son estáticos, i.e. independientes del ejemplo particular. En contraste, *OpenBCI* hace uso de la entropía de la clasificación asociada a la calidad del ejemplo y simultáneamente tomando en cuenta el instante de tiempo particular, resultando así ponderadores dinámicos.

### 6.1.6. Resultados

A continuación se presentan los resultados obtenidos para los participantes y el sistema de clasificación de *OpenBCI*, los cuales se han identificado como correspondientes al grupo I.

La figura 6.3 ilustra las series de tiempo más relevantes para el problema: tasa de error, señal de *feedback* entregada por el sistema y la señal de información mutua (IM). Los métodos que presentan la mejor separación entre ambas clases son B, C, E e I. En particular, el método C y el método I logran separar efectivamente ambas clases a partir del instante  $t = 4,5$  s.

La figura 6.4 compara la evolución temporal de la IM para los participantes. En A se aprecia un incremento de la IM entre  $t = 3,5$  s y  $t = 4,2$  s hasta 0,45 bits. B parte incluso antes (en  $t = 3,0$  s), pero baja nuevamente; luego se alcanza un incremento lento hasta obtener 0,45 bits en el instante  $t = 6,7$  s. C parte subiendo en  $t = 4,0$  s, alcanzando 0,46 bits en  $t = 5,0$  s y sigue aumentando en forma estable hasta 0,61 bits. D alcanza sólo 0,09 bits en el instante  $t = 5,66$  s. El método E comienza a aumentar recién a partir de  $t = 5,0$  s, llegando a su máximo de 0,21 bits en  $t = 6,13$  s. F tiene una pendiente similar al método A 0,5 s más tarde y alcanza también un valor máximo de 0,44 bits.

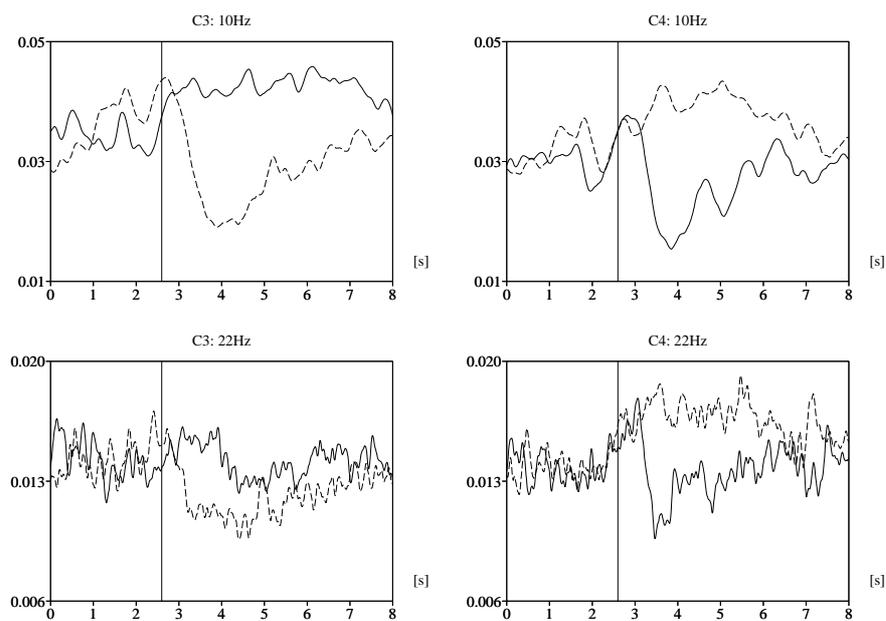


Figura 6.2: Características extraídas para los datos de Graz.

Los paneles ilustran ocho series promedio, correspondientes a las cuatro características extraídas ( $Mu$  y  $Beta$  central para los canales medidos en  $C_3$  y  $C_4$ ), tanto para la clase 1 (línea sólida) como para la clase 2 (línea punteada).

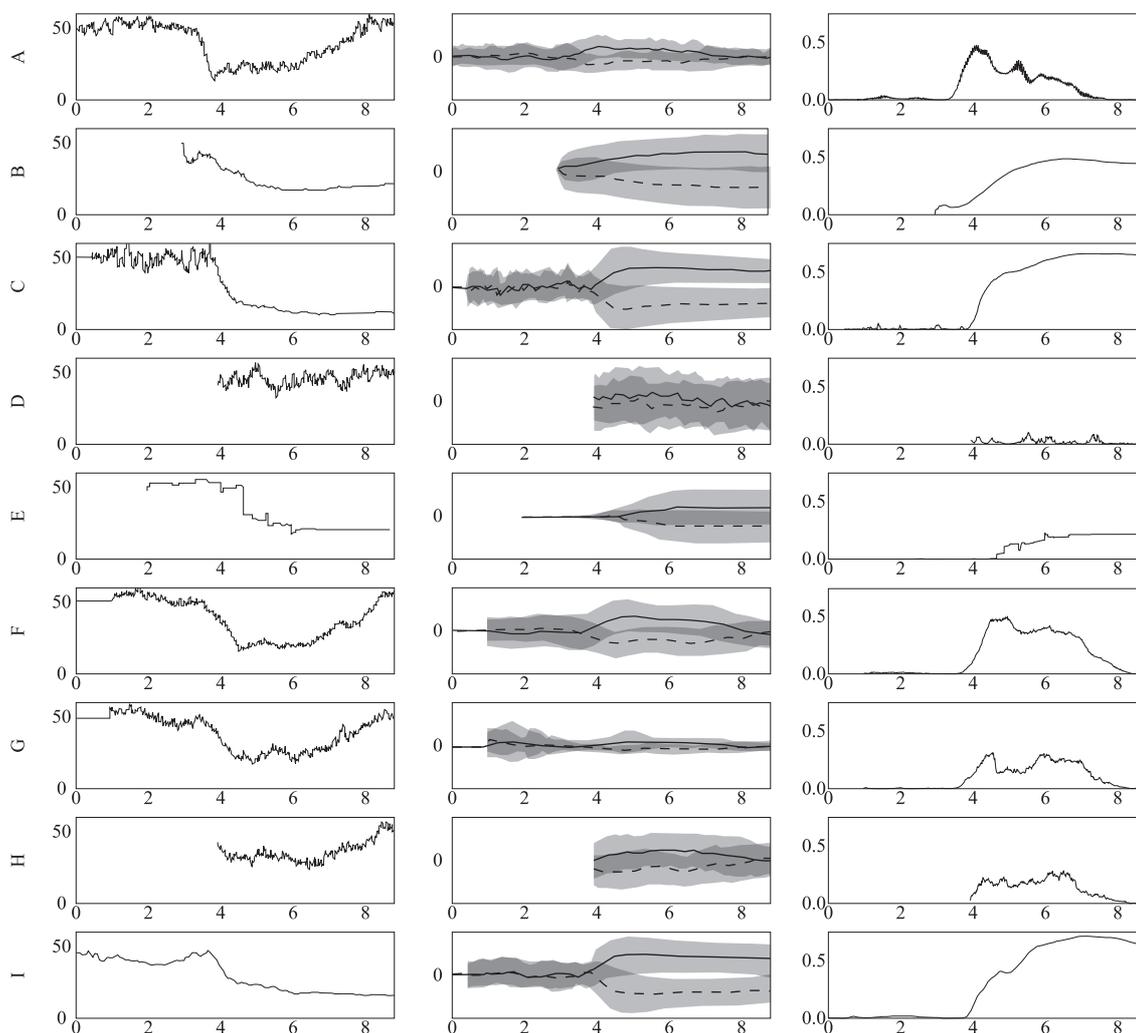


Figura 6.3: Series de Tiempo Resultantes, Datos de Graz.

Los paneles ilustran las series de tiempo resultantes para los métodos participantes. La primera columna muestra la evolución de la tasa de error. En la segunda columna se puede apreciar el promedio de la señal de *feedback* entregada por el sistema para ambas clases. Además, cada promedio está rodeado por su desviación estándar. La zona oscuro representa la zona de traslape entre ambas señales de *feedback*. La última columna grafica la evolución en el tiempo de la IM.

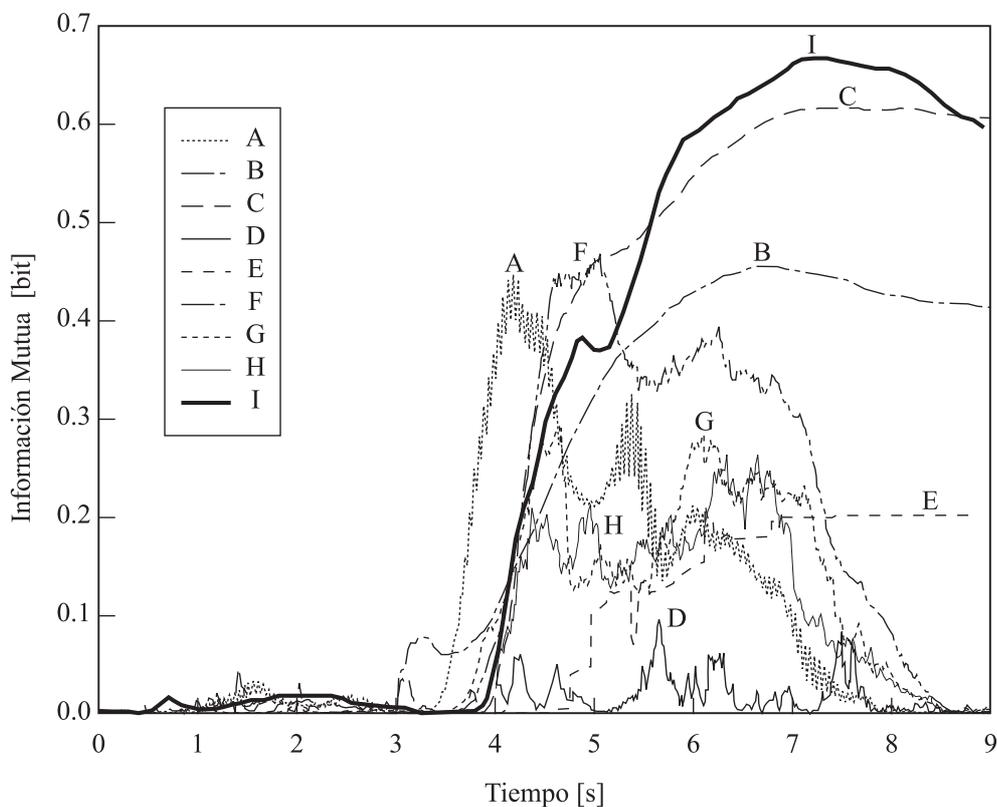


Figura 6.4: Comparación de la Evolución Temporal de la Información Mutua.

En la figura se compara la evolución en el tiempo de la información mutua (IM) de los sistemas participantes. El aumento notorio de la IM a partir  $t \approx 4,0$  se debe al instante inicial de ejecución de la TM en  $t = 3,0$  s, el tiempo que requiere la reacción del sujeto (aproximadamente 0.5 s) y el retardo introducido por los filtros empleados para la extracción de características. El ganador de la competencia, representado por la serie C, es superado sostenidamente por *OpenBCI* (serie I) a partir del instante  $t = 5,6$  s. Todos los métodos han sido entrenados únicamente con el conjunto de entrenamiento de los datos de Graz.

Debido a la similitud, se puede asumir que A y F utilizan propiedades muy parecidas de la señal EEG. G y H llegan a un valor máximo de 0,26 y 0,21 bits en  $t = 4,66$  y  $6,34$  s respectivamente. El método I posee un comportamiento muy similar al método C, con una pequeña recaída en el instante  $t = 5,0$  s. Éste último alcanza su máximo en el instante  $7,26$  s, obteniendo 0,61 bits. Por lo tanto, *OpenBCI* ha obtenido el mejor rendimiento en términos de IM, levemente superior al ganador de la competencia.

El cuadro 6.2 tabula los resultados más prominentes, es decir, error mínimo, SNR máximo, MI máxima y el instante de tiempo en el cual se produce el máximo de la IM.

Cuadro 6.2: Resumen de resultados y *ranking*, Datos de Graz.

Ranking	Grupo	Error mínimo [%]	SNR máximo [1]	IM máxima [bit]	Tiempo de Clasificación [s]
1	I	11.14	1.47	<b>0.67</b>	7.27
2	C	10.71	1.34	<b>0.61</b>	7.59
3	F	15.71	0.90	<b>0.46</b>	5.05
4	B	17.14	0.86	<b>0.45</b>	6.70
5	A	13.57	0.85	<b>0.44</b>	4.18
6	G	17.14	0.50	<b>0.29</b>	4.66
7	H	23.57	0.44	<b>0.26</b>	6.34
8	E	17.14	0.34	<b>0.21</b>	6.13
9	D	32.14	0.14	<b>0.09</b>	5.66

### 6.1.7. Discusión

Generalmente se utiliza la tasa de error para comparar distintos métodos. Sin embargo, esta tasa sólo considera el signo de la salida del clasificador pero no su magnitud. En ese sentido, la información mutua, la cual también toma en cuenta la magnitud, corresponde a un criterio de desempeño más apropiado para la validación de la calidad del *feedback* otorgada por el sistema.

Otro factor que debe ser considerado para la calificación es la rapidez con que el sistema reacciona con una respuesta que el usuario pueda utilizar para validar su desempeño en el ejercicio de la TM. Las pendientes más empinadas y estables de la IM pertenecen a los métodos A, B, C e I, siendo los dos últimos muy similares. El método A, que se eleva antes que los mencionados, sufre una recaída que se traduce en una señal que puede confundir al usuario. Un fenómeno interesante se puede observar en B; la señal presenta dos *peaks*. El primer *peak*, el cual se alcanza a los  $t = 3,5$  s, no puede provenir de una respuesta consciente por parte del usuario debido a consideraciones fisiológicas. Este máximo local probablemente refleja una respuesta al estímulo (similar

a un potencial evocado) producida en el sujeto. Las respuestas que se producen como reacción a un estímulo deben ser descartadas del análisis, porque sólo están presentes durante el registro de *trials* para formar el conjunto de entrenamiento, pues en esos experimentos es el sistema el que escoge a la TM a ejercer.

En un sistema real el clasificador no puede concluir sin que el usuario esté ejerciendo una TM asociada a un comando. Los métodos participantes lograron evitar la entrega de una respuesta antes del instante  $t = 3$  s en donde no está presente una TM objetivo. En particular destacan A, C, F, G e I, pues estos sí analizan la señal cerebral antes de la emisión del estímulo gatillante. *OpenBCI*, que opera en forma constante a lo largo de todo el *trial*, presenta la mejor estabilidad en la entrega de un *feedback* nulo.

Comparando el sistema *OpenBCI* directamente con el ganador de la competencia (grupo C), se puede realizar las siguientes observaciones. La evolución temporal de la IM es similar en ambos métodos, posiblemente debido al enfoque integrativo de la evidencia utilizado en ambos casos. *OpenBCI* supera a C en el instante  $t = 5,5$  s, y mantiene una brecha significativa hasta poco antes del final del *trial*. Analizando la tasa de error y la señal de *feedback*, se observa que a partir del instante  $t = 4,0$  s (poco después del comienzo de la ejecución de la TM) el comportamiento es similar. No obstante, la estabilidad anterior a  $t = 4,0$  s es visiblemente superior en *OpenBCI*, reflejando una actitud más conservadora en la emisión prematura de una señal de decisión. El error de clasificación mínimo tabulado en el cuadro 6.2, el cual es superior en C (10,71 % versus 11,14 %) no juega un rol importante en la práctica, porque sólo toma en cuenta un instante de tiempo para una decisión discreta (clase 1 ó clase 2). Si se considera una comparación de las componentes constituyentes del algoritmo de clasificación, hay que destacar que el método C está planteado para una discriminación binaria exclusivamente. Su extensión a más clases no es directa, pues se basa en las *cotas de Chernoff* para estimar el error de Bayes, las cuales no pueden ser generalizadas sin realizar suposiciones severas. En contraste, la generalización a más clases del clasificador de *OpenBCI* es directa.

En resumen, el clasificador de *OpenBCI* obtuvo los mejores resultados para el conjunto de datos de Graz, reflejando además propiedades de estabilidad deseables para un sistema BCI interactivo real.

### 6.2. Primeras Pruebas con un Sistema Prototipo

Los resultados promisorios obtenidos para los datos de Graz han motivado el desarrollo de una aplicación BCI prototipo, llamada *ABI* (Adaptive Brain Interface). Esta aplicación funciona en conjunto con el sistema de adquisición de señales EEG *modularEEG* del proyecto *OpenEEG*. El corazón de este sistema lo constituye una implementación

del método de clasificación de *OpenBCI*. *ABI* ha sido desarrollado principalmente por el autor de este trabajo. Actualmente, el software puede descargarse libremente desde el sitio web del proyecto *OpenEEG*<sup>2</sup> desde Enero de 2005 y goza de la licencia de distribución *GPL*, permitiendo que otros equipos de investigación o usuarios interesados puedan ver el código fuente y realizar modificaciones.

El potencial de esta estrategia es importante para el área de investigación. *ABI* es el primer software BCI que se pone a disposición del público, y que puede utilizarse sin la necesidad de contar con una ambientación de laboratorio. El objetivo principal de *ABI* es proveer una herramienta sencilla para personas que quieren experimentar por su cuenta con tecnología BCI. Con ésto se espera potenciar la investigación y atacar una multitud de problemas que enfrenta el diseño de un sistema BCI comercial. Por ejemplo, la contribución simultánea de mucha gente puede abordar en forma efectiva la búsqueda de TMs adecuadas y sus montajes de electrodos respectivos.

### 6.2.1. Breve Descripción del Sistema

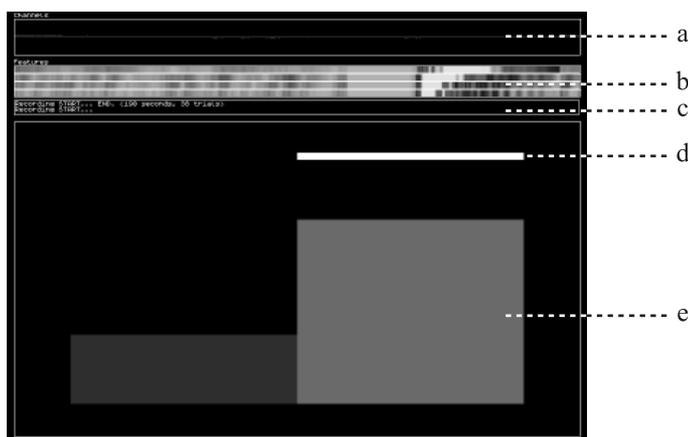


Figura 6.5: Captura de Pantalla de *ABI*.

La pantalla de *ABI* posee los siguientes elementos. (a) grafica las señales EEG que se están adquiriendo. (b) provee un *feedback* sencillo sobre la intensidad de las características (bandas angostas de frecuencia) extraídas a partir del EEG medido. (c) es una consola que entrega mensajes e información sobre las acciones y estados que está ejecutando el sistema. (d) es una barra que indica la clase objetivo que el usuario debe ejercer. (e) corresponde al *feedback* entregado por el sistema. Se aprecian dos barras (dos clases), donde la magnitud significativamente superior de la segunda barra indica que el usuario está ejerciendo adecuadamente la TM.

---

<sup>2</sup><http://openeeg.sourceforge.net>

A continuación sigue una breve descripción del prototipo desarrollado. El sistema *ABI* permite:

- realizar *Biofeedback* sencillo. Se pueden desplegar las señales EEG adquiridas, las amplitudes de las frecuencias extraídas y las clases que el sistema está reconociendo.
- registrar *trials* para un número de clases a elección del usuario. El operador puede construir un archivo de *trials* que servirá para construir el conjunto de entrenamiento. El software permite adquirir los *trials* EEG en distintas sesiones.
- entrenar al clasificador utilizando un archivo de *trials* previamente registrado, a partir del cual se construye el conjunto de entrenamiento. El usuario puede especificar los canales y las frecuencias que el sistema debe utilizar.
- simular *trials*. Una vez entrenado el sistema, el usuario puede probarlo realizando TMs que el sistema intenta reconocer.

En la forma actual del software, el BCI sólo puede operar con la configuración holística del clasificador. La figura 6.5 muestra una captura de pantalla del sistema.

### 6.2.2. Experimentos

Para poner a prueba el desempeño del sistema, se realizaron varias sesiones experimentales. El principal objetivo de estas pruebas consistió en la apreciación cualitativa de la operación del BCI desarrollado, donde se enfatizó la experiencia propiamente tal que resulta en su uso como sistema de comunicación. La descripción de los experimentos sigue a continuación. Cada experimento se llevó a cabo con el sistema *ABI* en conjunto con *modularEEG*, utilizando electrodos activos de Ag (planos para posiciones frontales, con *pin*es para posiciones cubiertas por el cabello). No se realizó un tratamiento especial previo del cuero cabelludo. Debido a las limitaciones de tiempo para el desarrollo de la memoria, ambos experimentos se realizaron con el autor de este trabajo como sujeto de prueba. Éstos se hicieron durante la noche (a partir de las 21:00 horas), pues la baja contaminación acústica que existió en ese horario favoreció la concentración.

#### Experimento 1:

En este primer experimento, se pretendió reproducir el experimento asociado a los datos de Graz (ver página 71). Éste se caracteriza por la estructura de los *trials* y las TMs asociadas a las dos clases posibles, es decir, intento de movimiento de mano izquierda y mano derecha para la clase 1 y 2 respectivamente. Los canales EEG registrados se midieron en las posiciones  $C_3$  y  $C_4$ , utilizando el mismo montaje bipolar descrito para los datos de Graz. Los electrodos (activos) se fijaron con dificultad en estas posiciones utilizando un cintillo improvisado.

Los datos de Graz adicionalmente fueron registrados mientras el sujeto recibía una retroalimentación basada en una combinación de parámetros AAR extraídos a partir de los canales medidos, opción que *ABI* no incorpora. Para simular este *feedback*, el experimento se organizó en tres sesiones de 140 trials cada uno. La primera sesión, sin *feedback*, tiene el objetivo de construir un primer conjunto de entrenamiento para entrenar el clasificador. Las dos sesiones posteriores se realizaron entregando la señal de *feedback* que se obtuvo del clasificador entrenado con los *trials* registrados en las sesiones previas.

### Experimento 2:

El experimento 1 sufrió de la baja calidad de las señales EEG capturadas. Las mediciones poseían un nivel muy elevado de contaminación producto del contacto inestable entre los electrodos y la superficie de la piel. Este ruido persistió durante todo el experimento. Por lo tanto, para obtener datos de mejor calidad, era necesario encontrar una TM que manifieste una actividad cerebral que pueda registrarse en posiciones más asequibles, como las regiones corticales frontales, temporales y occipitales. Para éstas posiciones, existe una escasez importante en la literatura sobre investigaciones que analizan las TMs y su potencial de activación cortical asociado, especialmente para TMs basadas en condicionamiento operante.

Se seleccionó sólo una TM para realizar el segundo experimento. Esta tarea consiste en la imaginación de figuras tridimensionales que el sujeto debe rotar mentalmente (figura 6.6). La ausencia de esta actividad denotaría a la clase 2. Según estudios asociados a esta TM, los procesos de codificación de la figura, su visualización mental y su rotación, se traducen en actividad cerebral focalizada en el lóbulo frontal, parietal y frontal izquierdos, respectivamente. Es decir, la actividad mental puede detectarse por medio de una configuración bipolar entre  $T_3$  y  $Fp_1$ . El proceso se manifiesta principalmente como una sincronización de la onda *Alfa* de intensidad variable.

El experimento se dividió en 3 sesiones, en cada cual se registraron 100 *trials* (50 para cada clase). La clase 1 fue asociada con la TM descrita, mientras que para la segunda clase se le solicitó al sujeto relajación completa, intentando, dentro de lo posible, dejar la mente en blanco.

El montaje de los electrodos fue sencillo. Se adquirió un sólo canal, que consistió en la medición bipolar entre las posiciones  $T_3$  y  $Fp_1$  del sistema internacional 10-20 (ver figura 6.7, panel izquierdo). De este canal, se calcularon las intensidades de las ondas *Alfa* y *Beta*, más precisamente, de las frecuencias 10 y 22 Hz. Éstas, junto con el canal de tiempo, conformaron las únicas 3 características que alimentaron al clasificador. La estructura de los *trials* se mantuvo igual al experimento 1, ilustrado en la figura 6.7,

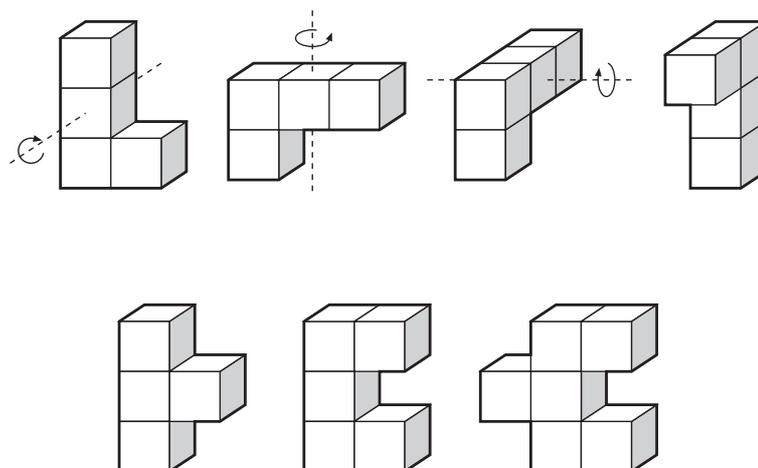


Figura 6.6: Rotación de Objeto 3D.

La TM consiste en la imaginación de secuencias de rotación de una figura geométrica sencilla. Una rotación se efectúa en 90 grados; su sentido y eje de rotación se escogen al azar. Los ejes corresponden a los ejes principales de la figura (panel superior). En lo posible, estas rotaciones deben suceder en forma rápida, manteniendo una visualización mental nítida. El panel inferior ilustra otras posibles figuras. Experimentalmente se constata que las figuras sencillas pero asimétricas (como aquella ilustrada en el panel superior) funcionan mejor.

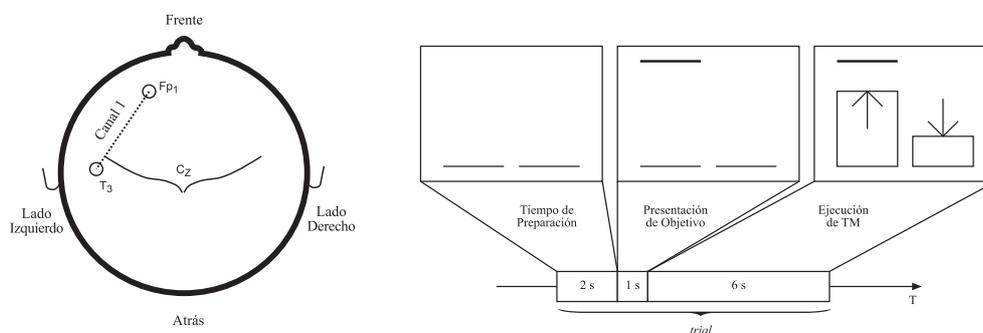


Figura 6.7: Montaje de los Electrodo y Estructura de un *Trial*, Experimento 2.

En el panel izquierdo se ilustra la configuración bipolar utilizada para registrar el canal sobre las posiciones  $T_3$  y  $Fp_1$ . Estas posiciones corresponden a las zonas corticales activadas durante la rotación mental. La estructura de un *trial* EEG se presenta en el panel derecho.

panel derecho. El clasificador utilizado operó en modo holístico, y su complejidad estuvo dada por la arquitectura 3-4-2 de la red neuronal.

### 6.2.3. Resultados

Los resultados específicos de cada experimento se detallan a continuación.

#### Experimento 1:

La primera sesión se realizó sin problemas aparentes, i.e. se registraron 140 *trials* sin *feedback*. Durante la segunda sesión se notó que el sistema no estaba entregando una respuesta esperada, más bien parecía indicar un estado de clasificación aleatorio. Este problema se repitió para la tercera sesión. No logró apreciarse ningún tipo de reconocimiento por parte del sistema.

Comparando el proceso de entrenamiento con aquel que se realizó para el conjunto de datos de Graz, se notó que la red neuronal aparentemente no lograba converger a un valor adecuado (es decir, tendiendo bajo los 0.5 bits), sino que se mantuvo, en forma repetitiva a lo largo de las reinicializaciones del algoritmo de aprendizaje, en  $1,23 \pm 0,01$  bits. A pesar del posterior ajuste de la complejidad de la red neuronal, el entrenamiento no parecía mejorar. Se supuso que este comportamiento probablemente se debió a la inseparabilidad del conjunto de entrenamiento, lo cual necesariamente (en vista de aquellos resultados obtenidos para los datos de Graz) indicaba una calidad muy pobre (i.e. altamente contaminados) de los datos registrados. Para verificar esta suposición, el sistema se entrenó un conjunto de entrenamiento generado en forma aleatoria. Como se había esperado, el sistema no logró converger, obteniendo un error de  $1,37 \pm 0,05$  bits. Por lo tanto, el experimento se declaró como fallido, abandonando mayor análisis.

El factor que causó en forma predominante la contaminación de la señal EEG se determinó como la conectividad frágil que existió entre electrodo y piel. De hecho, el sujeto presenció una correlación entre la señal EEG (contaminada) que desplegab el sistema y los movimientos leves de la cabeza.

Las TMs basadas en imaginaria motriz resultaron muy sencillas de realizar. Ellas no requieren toda la atención por parte del sujeto, y pueden ejecutarse en forma prácticamente inconsciente. No obstante, un pequeño cambio en el tono muscular de la mano sirvió como la principal señal de confirmación de que la tarea se estaba ejecutando, i.e. el ejercicio realizado sí tenía un efecto físico (aunque externamente imperceptible) sobre el sujeto.

### Experimento 2:

La TM de rotación mental produjo una fatiga mental considerable en el sujeto. Inicialmente, esta tarea requirió toda la concentración por parte del sujeto. Sin embargo, a partir de la tercera sesión éste ya percibió un dominio superior del ejercicio de la tarea. Ésta tiende a mecanizarse paulatinamente. La tasa de rotaciones mentales aumenta, y se llevan a cabo en sucesiones cada vez más rápidas y automáticas, siendo la determinación aleatoria de un eje y sentido de rotación el factor que consume la mayor cantidad de tiempo y atención.

En la segunda sesión, se apreció una correlación notoria entre la señal de *feedback* entregada por el sistema y la TM ejercida. La señal de *feedback* jugó el rol simultáneo de guía y recompensa a la vez. La señal, que inicialmente se mantenía a un nivel neutro, reaccionaba a los pocos instantes (aproximadamente 0.5 s) tras iniciar la TM. El nivel de clasificación correcta de los *trials* alcanzó el 78 %, concentrándose las clasificaciones erróneas hacia el final de la sesión. Esta disminución fue acompañada por sensaciones de frustración, incremento del nerviosismo, y la percepción de que la TM se había vuelto sencilla y mecanizada. En la tercera sesión, el porcentaje de clasificación correcta disminuyó drásticamente a 63 %. La señal de *feedback* tendía a confundir al sujeto cuando no correspondía a la clase que el sujeto perseguía.

En contraste con el experimento 1, se sumó un elemento de contaminación distinto a la señal: los artefactos oculares. Éstos, a pesar de ser corregidos por el sistema por medio de la estrategia integrativa, degradan en forma perceptible su rendimiento. Ellos son difíciles de controlar, y se manifiestan en forma casi espontánea.

El entrenamiento del clasificador se desarrolló en forma similar a aquel observado en conjunto de Graz, llegando a un error de  $0,64 \pm 0,03$  bits usando el conjunto de la primera sesión y un error de  $0,54 \pm 0,04$  bits antes de iniciar la tercera sesión. Este hecho es una evidencia a favor de la hipótesis de que un *feedback* adecuado conlleva al registro de un conjunto de entrenamiento de mejor calidad. Lo interesante es que, a pesar de que los niveles de error de entrenamiento por sí solos son relativamente altos para una red neuronal *stand-alone*, la estrategia integrativa logra combinar los resultados parciales en una respuesta notoriamente superior.

### 6.2.4. Discusión

El sistema de adquisición de señales EEG debe contar con electrodos y utensilios cómodos que garanticen una conectividad impecable a niveles de contaminación bajos. La ausencia de los dispositivos de montaje apropiados impidió completamente el funcionamiento del BCI durante el experimento 1.

Entre las TMs involucradas en ambos experimentos existió una gran diferencia en la complejidad de su ejercicio. La rotación mental empleada en el segundo experimento es notoriamente más agotadora que la imaginería motriz. No obstante, el ejercicio prolongado de una TM compleja podría conllevar a un dominio tal, que para el usuario se convierta en una actividad mecánica, como se observó en el segundo experimento. No obstante, esta automatización del proceso cognitivo pareció producir un cambio en su manifestación electrofisiológica, que probablemente fue la causa de la disminución del rendimiento durante la tercera sesión.

A pesar del efecto secundario que nace a raíz de la estrategia integrativa, el cual actúa como corrector de distorsiones menores en la señal, el sistema de clasificación sufre una recaída de su rendimiento durante la aparición de un parpadeo ocular.

Se pudo constatar el efecto que provoca la presencia de un *feedback* instantáneo en un sistema. En el caso de estar calibrado correctamente, éste sirve de apoyo durante el ejercicio de la TM. Este apoyo, si es utilizado durante el registro de *trials* que serán utilizados para la construcción del conjunto de entrenamiento, favorece la adquisición de *trials* de calidad superior. Por el contrario, un *feedback* no correlacionado puede obstruir la ejecución de las TMs debido al efecto psicológico perturbador y contraproducente que ejercen sobre el sujeto.

En ambos experimentos persistió una sensación de fragilidad de la comunicación a través de un BCI. Cualquier irrupción de un estímulo externo producía la desconcentración del sujeto de su tarea. A pesar de la complejidad considerable de la TM de la segunda prueba, los experimentos con el BCI no fueron lo suficientemente motivantes para facilitar la atención del sujeto. Cabe preguntarse qué efecto tendría el diseño de un experiencia en que la comunicación representa un medio, y no un fin por sí mismo.

### 6.3. Evaluación General

La elección de las TMs objetivo y los montajes de electrodos apropiados constituye un paso crucial en el uso de un BCI. Desde el punto de vista del usuario, la mera elección de la TM puede significar el éxito o fracaso de un sistema de comunicación, puesto que algunas de ellas requieren toda su atención, impidiendo la realización de otras actividades en forma simultánea. Considerando sólo este hecho, las TMs basadas en imaginería motriz constituyen una familia de tareas más deseables que aquellas basadas en ejercicios cognitivos de mayor complejidad.

Por otro lado, la elección anterior también debe considerar el montaje de electrodos necesario. En lo posible, deben evitarse las posiciones frontales por la presencia de una

tasa elevada de artefactos oculares que degradan el rendimiento del sistema, produciendo una disminución en la tasa de transferencia de información (para los BCIs que eliminan dichos segmentos) o porque incitan al usuario a evitar su aparición forzosamente. Los montajes problemáticos, como por ejemplo aquellos que requieren mediciones desde zonas centrales, deben hacer uso obligado de dispositivos especiales que garanticen una buena conectividad. Altamente deseable sería el desarrollo de una alternativa a un *Electrode-Cap* que sea más cómoda y fácil de instalar.

Los métodos de aprendizaje de máquinas utilizados por los participantes corresponden a un conjunto representativo de las aproximaciones exploradas en la literatura BCI, excluyendo aquellas que se basan principalmente en la distribución cortical de la actividad neurológica. Esto hecho ubica al método planteado entre una de las aproximaciones más promisorias en la literatura en términos de la señal de *feedback* y el porcentaje de clasificación correcta.

El desarrollo de un prototipo confirmó empíricamente en el experimento 2, que el sistema sí es capaz de entregar una respuesta correlacionada con la TM, bajo condiciones de registro que distan mucho de aquellas ideales presentes en un experimento de laboratorio supervisado. En ese sentido, el segundo experimento se consideró un éxito, habilitando la distribución de la aplicación resultante para uso público. Sin embargo, el diseño del experimento no permite juzgar la calidad del sistema como BCI propiamente tal, ya que para esto se requiere de su uso prolongado que estuvo fuera del alcance del tiempo asignado para esta memoria.

Pese a lo mencionado anteriormente, se pueden realizar varias críticas al sistema. Primero, el protocolo de comunicación síncrono es una limitante importante de la tasa de transferencia de información. El usuario debe regirse según los tiempos de inicio y fin de un *trial* determinados por el sistema. Para un canal de comunicación entre dos extremos que asumen el rol de actor y efector (pues es el sujeto el que *actúa a través del BCI*), la iniciativa para establecer el contacto no puede estar situada en el efector. Segundo, es necesario medir el rendimiento del sistema sobre un problema multi-clase, y compararlo con otros métodos. Por último, la aplicación prototipo ha mostrado que configuraciones experimentales en que el único objetivo es poner a prueba el rendimiento del sistema de comunicación cansan a los sujetos. Es necesario diseñar experimentos en donde la meta para el sujeto consiste en realizar una actividad atractiva (como un juego) utilizando el BCI como canal.

# Capítulo 7

## Conclusiones

En este capítulo se resumirán los puntos y contribuciones más importantes de esta memoria. Luego se discutirán posibles extensiones de este trabajo. Los objetivos de esta memoria fueron:

- Diseño de un sistema BCI que sea: *genérico*, en el sentido de la flexibilidad en el protocolo de comunicación requerido; *eficiente* en términos de uso de recursos computacionales; *interactivo*, proveyendo al operador con *feedback* instantáneo; *robusto* en la clasificación, a pesar de la presencia de artefactos EEG; *portable*, pudiendo ser utilizado en un sistema BCI de uso doméstico; y operar en base a un número mínimo de canales EEG.
- Proveer una base para futuros desarrollos en Chile en tecnología BCI. Esta base considera: *documentación*, que consiste en una introducción al área, revisión del estado de arte, y la propuesta de un sistema sencillo; y la *implementación* de un sistema BCI prototipo basado en el diseño anterior.

### 7.1. Principales Logros

Los principales logros de esta memoria se pueden resumir como sigue:

1. En esta memoria, se desarrolló el sistema *OpenBCI* de reconocimiento de TMs basadas en condicionamiento operante síncrono. Este sistema se alimenta a través de señales EEG capturadas desde la superficie de la piel, y puede ser utilizado como corazón de un sistema de comunicación.
2. El sistema clasifica segmentos de señales EEG de largo fijo (*trials*). Este largo es configurable, pero debe mantenerse constante una vez elegido. El clasificador no posee límite teórico en el número de TMs que es capaz de discriminar.
3. Tanto el archivo de *trials* como el conjunto de entrenamiento que se origina a partir de él, representan la exigencia más importante en términos computacionales. Sin

embargo, en modo de operación, es decir, un vez entrenado el sistema, los recursos necesarios en términos de espacio y tiempo son mínimos.

4. El proceso de clasificación construye su decisión final paulatinamente a medida que transcurre el tiempo y adquiere evidencia adicional. El estado de clasificación integrado (en el tiempo) sirve como *feedback* prácticamente instantáneo, limitado solamente por el retardo introducido durante la extracción de características. Ésta señal de *feedback* se ha comparado contra otros métodos que fueron aplicados a datos de *benchmark* provenientes de la competencia *BCI Competition III*, obteniendo los mejores resultados en términos de información mutua.
5. La clasificación es robusta ante perturbaciones menores de la señal adquirida. Artefactos de parpadeo ocular disminuyen el desempeño del sistema.
6. Primeras pruebas con una implementación prototipo que opera en conjunto con un hardware de bajo costo y arquitectura abierta entregan resultados promisorios. Es necesario realizar pruebas prolongadas en el tiempo que abarquen a un mayor número de sujetos. El prototipo se puso a disposición del público en Enero 2005.
7. Para la clasificación de las TMs no se exige gran precisión en la distribución del potencial cortical, sino que está basada en el procesamiento de actividad eléctrica focalizada.
8. En el presente, el autor no conoce trabajos de investigación en Chile relacionados con tecnología BCI en Chile<sup>1</sup>. El prototipo se desarrolló bajo el uso de un equipo computacional personal y un sistema de adquisición económico que fue ensamblado sin mayores dificultades por un estudiante de ingeniería eléctrica y el autor de esta memoria. Con ésto, se espera motivar estudios que continúen este primer trabajo desarrollado.

### 7.2. Observaciones Críticas

1. Control Discreto - Continuo: El diseño del sistema actual se enfocó en la generación de una clasificación que se actualiza a lo largo del tiempo. La clasificación final se realiza al final del *trial*. Planteado de esta forma, se trata de un sistema de control discreto, ya que al final de cada *trial* se determina una entre todas las clases como la clase real asociada a un control. En contraste, los sistemas de comunicación continuos permitirían asociar una intensidad a cada comando. Debido al largo fijo que tienen los *trials*, no queda claro como extender el sistema de clasificación para un control continuo.

---

<sup>1</sup>fuentes: *Google, Universidad de Chile, Pontificia Universidad Católica, Universidad de Santiago, Universidad Técnica Federico Santa María*

2. Tasa de Transferencia: Relacionado con el punto anterior está la tasa de transferencia del canal de comunicación. La sincronía es un factor importante en la limitación de esta tasa. Por ejemplo, bajo condiciones de clasificación perfectas del conjunto de Graz, su valor llegaría a apenas a 6,7 bits por minuto, es decir, una cantidad claramente insuficiente. Esta tasa de comunicación puede elevarse en parte por el uso de un protocolo asíncrono. Sin embargo, también existe la posibilidad de modificar el protocolo de comunicación. Por ejemplo, un protocolo bajo investigación consiste en la selección de uno entre  $n$  objetivos: el usuario lo escoge moviendo un puntero por medio de un control continuo binario (arriba y abajo).

### 7.3. Recomendaciones para Trabajos Futuros

El desarrollo de la tecnología BCI todavía se halla en su etapa de infancia, y su éxito depende de la investigación de resultados en neurociencia, métodos psicológicos, procesamiento de señales, algoritmos de aprendizaje de máquinas, criterios de evaluación, modos de operación y aplicaciones. El listado a continuación contiene un número no-exhaustivo de proposiciones para la extensión del trabajo presentado en esta memoria:

1. En este trabajo sólo se han considerado cuatro TMs que se escogieron en base a la literatura BCI, las cuales a su vez hicieron su elección en base a estudios de la especialización hemisférica. Sin embargo, la comunidad todavía no cuenta con un set (de tamaño razonable) de TMs de baja complejidad (que no requieran demasiado esfuerzo en su ejercicio) y que su detección simultánea pueda realizarse por medio de una configuración sencilla de electrodos. La posición y el número de electrodos empleados pueden ser optimizados tomando en cuenta consideraciones fisiológicas y criterios de evaluación. Algoritmos de selección de características pueden ser utilizados para establecer un *ranking* según su poder discriminativo entre las TMs.
2. La ejecución repetitiva de una misma TM conlleva a un aprendizaje que se manifiesta por medio de una alteración de la expresión electrofisiológica. En vista de este fenómeno, es necesario realizar experimentos que sean prolongados en el tiempo y supervisados adecuadamente.
3. El sistema de clasificación de esta memoria solo se ha basado en el análisis de intensidades de frecuencias claves. Alternativamente, pueden utilizarse otras características, por ejemplo, que midan el nivel de sincronización inter-canal, u otras basadas en los parámetros AAR. En particular, los resultados que se han obtenido por medio de las *representaciones en tiempo y frecuencia cuadráticas* (la clase de Cohen) se ven promisorios [39, 25, 13, 14, 19, 18]. Por último, también conviene explorar características inspiradas en aquellas utilizadas en el reconocimiento de voz.

4. Con respecto a lo último dicho en el punto anterior, cabe preguntarse la aplicabilidad del método de clasificación desarrollado para el problema de reconocimiento de voz. Algunos métodos exitosos de clasificación basan su decisión en representaciones en tiempo y frecuencia, por lo que el empleo del clasificador de *OpenBCI* podría alcanzar buenos niveles de desempeño.
5. El protocolo de comunicación actual síncrono limita tasa de transferencia del sistema. Un desafío para futuras investigaciones consiste en la extensión del algoritmo para permitir la comunicación asíncrona. Una primera aproximación consistiría en deslizar la ventana de análisis en pasos aproximadamente continuos a lo largo de un flujo de señal EEG. Esta extensión del algoritmo requeriría el empleo simultáneo de varios integradores temporales (uno para cada desplazamiento relativo) más un método de combinación de estos resultados.
6. Fuera del ámbito de los dispositivos de comunicación, el sistema *OpenBCI* puede emplearse también para fines clínicos, o para el estudio de sueño, en donde puede entrenarse para la detección automática de estados mentales.
7. Como último punto, cabe mencionar que también existe mucho potencial en el desarrollo de sistemas de adquisición. La tecnología actualmente utilizada, incluso en los equipos profesionales, es muy sencilla y puede mejorarse. En particular, es imperioso el diseño de nuevas unidades de amplificación de tamaño portable. Por otro lado, la tecnología de los electrodos activos, todavía en etapa experimental, significa un avance importante para la electroencefalografía.

# Apéndice A

## Nociones Básicas de Teoría de Sistemas Lineales

### A.1. Sistemas Lineales Invariantes en el Tiempo

Un sistema lineal invariante en el tiempo (LTI) se puede caracterizar en forma única por medio de su *secuencia de respuesta al pulso*,  $h(n)$ . Ésta corresponde a la salida del sistema cuando es excitado por un pulso,  $\delta(n)$

$$\delta(n) = \begin{cases} 1, & \text{para } n = 0 \\ 0, & \text{para } n \neq 0 \end{cases} \quad (\text{A.1.1})$$

Cuando la entrada de un sistema es excitada por una secuencia  $x(n)$ , su salida está dada por la *convolución* de  $x(n)$  con  $h(n)$ , definida como

$$y(n) = \sum_{k=-\infty}^{+\infty} h(k)x(n-k) = \sum_{k=-\infty}^{+\infty} x(k)h(n-k) \equiv h(n) * x(n) \quad (\text{A.1.2})$$

Un sistema LTI puede ser:

- *Causal*: Su respuesta al pulso es cero para  $n < 0$ . En otro caso es conocido como *no-causal*. Obsérvese que sólo los sistemas causales pueden ser realizados en tiempo real. Ésto se debe a que un sistema no-causal requiere el conocimiento de las muestras futuras  $x(n+1), x(n+2), \dots$ , para obtener su salida en el tiempo  $n$ , lo cual no es posible en la práctica.
- *Respuesta Finita al Impulso (FIR)*: La respuesta al pulso es de extensión finita. Si ésto no ocurre, entonces se trata de un sistema de *respuesta infinita al impulso*

(IIR). Para un sistema causal FIR, la relación de entrada y salida se convierte en

$$y(n) = \sum_{k=0}^{L-1} h(k)x(n-k) \quad (\text{A.1.3})$$

donde  $L$  es el largo de la respuesta al pulso. Cuando un sistema no es causal, éste puede ser convertido a un sistema causal retardando sus salidas.

## A.2. Función de Transferencia

La transformada- $z$  de la respuesta al pulso, definida como

$$H(z) = \sum_{n=-\infty}^{+\infty} h(n)z^{-n} \quad (\text{A.2.1})$$

es conocida como la *función de transferencia* del sistema. El parámetro libre  $z$  es una variable compleja. La definición anterior tiene sentido cuando la serie converge. Se puede demostrar fácilmente que la región de convergencia para sistemas causales y sistemas FIR es de la forma

$$|z| > |R|, \quad \text{para algún } |R| < 1 \quad (\text{A.2.2})$$

es decir, se trata del exterior de un círculo en el plano complejo, centrado en el origen, y que contiene al círculo unitario ( $|z| = 1$ ). Sean  $X(z)$  e  $Y(z)$  las transformadas- $z$  de las secuencias de entrada y salida de un sistema LTI. Entonces, se puede demostrar que la ecuación (A.1.2) es equivalente a

$$Y(z) = H(z)X(z) \quad (\text{A.2.3})$$

Si el respuesta al pulso de un sistema LTI es retardada en  $L$  muestras, por ejemplo, para convertir un sistema no-causal en un causal, entonces la función de transferencia está dada por  $z^{-L}H(z)$ .

# Bibliografía

- [1] Hesham Sheikh, Dennis J. McFarland, William A. Sarnacki, Jonathan R. Wolpaw, “Electroencephalographic(EEG)-based communication: EEG control versus system performance in humans”, *Neuroscience Letters*, 345 (2003) 89-92.
- [2] Mitchell Slep, “Single Trial Analysis of EEG Signals”, *COS 497/498*, 2003.
- [3] Jessica Bayliss, “A Flexible Brain-Computer Interface”, Ph.D. Thesis, *Science Dept., U. Rochester*, Agosto 2001.
- [4] J. Bogacz, “Los Potenciales Evocados en el Hombre: Significación y Aplicaciones Clínicas”, *Editorial “El Ateneo”*, 1985
- [5] Harwant S. Gill, Michael W. O’Boyle, Julie Hathaway, “Cortical Distribution of EEG Activity for Component Processes during Mental Rotation”, *Cortex*, (1998) 34, 707-718.
- [6] Włodzimierz Klonowski, Wojciech Jernajczyk, Krystyna Niedzielska, Andrzej Rydz, Robert Stepień, “Quantitative measure of complexity of EEG signal dynamics”, *Institute of Biocybernetics and Biomedical Engineering*.
- [7] Chris C. King, “Fractal and Chaotic Dynamics in Nervous Systems”, *Department of Mathematics & Statistics*, University of Auckland.
- [8] Gerwin Schalk, Jonathan R. Wolpaw, Dennis J. McFarland, Gert Pfurtscheller, “EEG-based communication: presence of an error potential”, *Clinical Neurophysiology* 111 (2000) 2138-2144.
- [9] J. del R. Millán, Josep Mouriño, M.G. Marciani, Fabio Babiloni, F. Topani, I. Canale, Jukka Heikkonen, K. Kaski, “Adaptive Brain Interfaces for Physically-Disabled People”, *20<sup>th</sup> Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*, 1998.
- [10] Proyecto *OpenEEG*, <http://openeeg.sourceforge.net>.
- [11] W. D. Penny y Stephen J. Roberts, “Experiments with and EEG-based computer interface”, *Depart. of Electrical Engineering, Imperial College*, Julio 1999.

- [12] L. Kilgore, P. H. Peckham, M. W. Keith, G. B. Thorpe, K. S. Wuolle, A. M. Bryden, y R. L. Hart, “An implanted upper-extremity neuro-prosthesis: Follow-up of five patients”, *J. Bone Joint Surg.*, Vol. 79A, 533-541, 1997.
- [13] Ming Li, Wei Zhao, Weijia Jia, “The Profile of Kernels in Time Frequency Distributions”, *Journal of Ship Mechanics*, Vol. 3, No. 6, Dec. 1999.
- [14] L. Atlas, J. Droppo, and J. McLaughlin, “Optimizing Time-Frequency Distributions for Automatic Classification”, *Proc. SPIE*, Vol. 3162, 1997.
- [15] U. Meyer-Bäse, “High-Speed Implementation of Gabor and Morlet Wavelet Filterbanks using RNS Frequency Sampling Filters”, *European Space Agency fellowship*, <http://www.dtro.e-technik.th-darmstadt.de/umb/papers>.
- [16] Shane M. Haas, Mark G. Frei, Iván Osorio, Bozena Pasik-Duncan, y Jeff Radel, “EEG ocular artifact removal through ARMAX model system identification using extended least squares”, *Communications in Information and Systems*, Vol. 3, No. 1, 19-40, Junio 2003.
- [17] H. Ramoser, J. Müller-Gerking, G. Pfurtscheller, “Optimal spatial filtering of single trial EEG during imagined hand movement”, *IEEE Transactions on Rehabilitation Engineering*, Agosto 1998.
- [18] Gary Garcia, Touradj Ebrahimi, Jean-Marc Vesin, “Direct Brain-Computer Communication Through Scalp Recorded Signals”, Ph.D. Thesis, *Swiss Federal Institute of Technology - EPFL*, 2004.
- [19] Gary Garcia, Touradj Ebrahimi, Jean-Marc Vesin, “Classification of EEG signals in the ambiguity domain for brain computer interface applications”, *Swiss Federal Institute of Technology - EPFL*.
- [20] R. Battiti, “Using Mutual Information for Selecting Features in Supervised Neural Net Learning”, *IEEE Transactions on Neural Networks*, Vol. 5, No. 4, 537-550, Julio 1994.
- [21] Thomas Ferree y Ramesh Srinivasan, “Theory and Calculation of the Scalp Surface Laplacian”, *Electrical Geodesics, Inc.*, Technical Note.
- [22] Lucas Parra, Chris Alvino, Akaysha Tang, Barak Pearlmutter, Nick Yeung, Allen Osman, Paul Sajda, “Single-trial detection in EEG and MEG, Keeping it linear”, *Neurocomputing* 52-54 (2003) 177-183.
- [23] Thilo Hinterberger, Andrea Kübler, Jochen Kaiser, Nicola Neumann, Niels Birbaumer, “A brain-computer interface (BCI) for the locked-in: comparison of different EEG classifications for the thought translation device”, *Clinical Neurophysiology* 114 (2003) 416-425.

## BIBLIOGRAFÍA

---

- [24] Claude Robert, Jean-François Gaudy, Aimé Limoge, Jochen Kaiser, Nicola Neumann, Niels Birbaumer, “Electroencephalogram processing using neural networks”, *Clinical Neurophysiology* 113 (2002) 694-701.
- [25] Jorge Baztarrica, “EEG Signal Classification for Brain Computer Interface Applications”, Diploma Project, *École Polytechnique Fédérale de Lausanne*, Marzo 2002.
- [26] Steven Lemm, Christin Schäfer, y Gabriel Curio, “Probabilistic Modeling of Sensorimotor  $\mu$ -Rhythms for Classification of Imaginary Hand Movements”.
- [27] Christin Schäfer, Steven Lemm, y Gabriel Curio, “Binary On-line Classification based on Temporally Integrated Information”, *IEEE Transactions on Biomedical Engineering*.
- [28] Wenjie Xu, Cuntai Guan, Chng Eng Siong, S. Ranganatha, M. Thulasidas, Jiankang Wu “High Accuracy Classification of EEG Signal”, *Biological Psychology*, 62 (2003) 237-251.
- [29] B. Obermaier, C. Guger, C. Neuper, G. Pfurtscheller, “Hidden Markov models for online classification of single trial EEG data”, *Pattern Recognition Letters*, 22 (2001), 1299-1309.
- [30] F. Babiloni, F. Cincotti, L. Lazzarini, J. Millán, J. Mouriño, M. Varsta, J. Heikonen, L. Bianchi, M. G. Marciani, “Linear Classification of Low-Resolution EEG Patterns Produced by Imagined Hand Movements”, *IEEE Transactions on Rehabilitation Engineering*, Vol. 8, No. 2, Junio 2000.
- [31] BCI Competition 2003, <http://ida.first.fhg.de/projects/bci/competition/>.
- [32] Alois Schlögl, “Outcome of the BCI-competition 2003 on the Graz data”, *BCI Competition III*, 2003.
- [33] B. Blankertz, K.-R. Müller, G. Curio, T. M. Vaughan, G. Schalk, J. R. Wolpaw, A. Schlögl, C. Neuper, G. Pfurtscheller, T. Hinterberger, M. Schröder, and N. Birbaumer, “The BCI Competition 2003: Progress and Perspectives in Detection and Discrimination of EEG Trials”, *IEEE Transactions on Biomedical Engineering*, Vol. 51, No. 6, Junio 2004.
- [34] Dennis J. McFarland, William A. Sarnacki, Jonathan R. Wolpaw, “Brain-computer interface (BCI) operation: optimizing information transfer rates”, *Biological Psychology*, 62 (2003) 237-251.
- [35] Guido Dornhege, Benjamin Blankertz, Gabriel Curio, Klaus-Robert Müller, “Boosting bit rates in non-invasive EEG single-trial classifications by feature combination and multi-class paradigms”, *Fraunhofer FIRST (IDA)*, Reporte Técnico, 2004.

- [36] M. Kraudelat, G. Dornhege, B. Blankertz, F. Losch, G. Curio, K.-R. Müller, “Improving speed and accuracy of brain-computer interfaces using readiness potential features”, financiado parcialmente por *Bundesministerium für Bildung und Forschung*, y por *Deutsche Forschungsgesellschaft*, 2004.
- [37] Athanasios Papoulis, “Probability, Random Variables and Stochastic Processes” *McGraw-Hill Inc.*, 1991.
- [38] F. G. Stremler, “Introduction to Communication Systems, Third Edition”, *Adison-Wesley*, 1990.
- [39] Shie Qian “Introduction to Time-Frequency and Wavelet Transforms”, *Prentice Hall*, 2002.
- [40] Mallat S., “A Wavelet Tour of Signal Processing”, *Academic Press*, 1998.
- [41] Überhuber C., Schneid J., Pittner S., “Wavelet Literature Survey”, *Technical University of Vienna*, Vienna, 1993.
- [42] Aapo Hyvärinen, “Survey of Independent Component Analysis”, *Helsinki University of Technology*, <http://www.cis.hut.fi/~aapo/>.
- [43] S. Amari, A. Cichocki, H. H. Yang, “A New Learning Algorithm for Blind Signal Separation”.
- [44] Juha Karhunen, “Neural Approaches to Independent Component Analysis and Source Separation”.
- [45] Anthony J. Bell y Terrence J. Sejnowski, “Learning the higher-order structure of a natural sound”, *Clinical Neurophysiology* 113 (2002) 694-701.
- [46] Theodoridis S., Koutroumbas K., “Pattern Recognition”, *Academic Press*, .
- [47] Bishop C. M., “Neural Networks for Pattern Recognition”, *Oxford University Press*, 1995.
- [48] Simon Haykin, “Neural Networks: A Comprehensive Foundation”, *Macmillan College Publishing Company*, 1994.
- [49] Yann LeCun, Leon Bottou, Genevieve B. Orr, and Klaus-Robert Müller, “Efficient BackProp”, originalmente publicado en “Neural Networks: tricks of the trade”, G. Orr y K. Müller, *Springer Verlag*, 1998.
- [50] Martin Riedmiller, Heinrich Braun, “A Direct Adaptive Method for Faster Back-propagation Learning: The RPROP Algorithm”, *Proceedings of the IEEE International Conference on Neural Networks*, 1993.