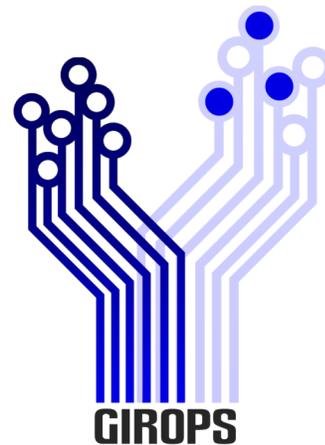


**CLASIFICACIÓN DE PATRONES DE IMAGINACIÓN MOTORA EN UNA INTERFAZ
CEREBRO COMPUTADOR DE BAJO COSTO USANDO SOFTWARE LIBRE**

JOHN EDISON MUÑOZ CARDONA

Maestría en Ingeniería Eléctrica

Código: 1088261131



**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERÍAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA
PEREIRA**

Mayo de 2014

**CLASIFICACIÓN DE PATRONES DE IMAGINACIÓN MOTORA EN UNA INTERFAZ
CEREBRO COMPUTADOR DE BAJO COSTO USANDO SOFTWARE LIBRE**

JOHN EDISON MUÑOZ CARDONA

Maestría en Ingeniería eléctrica

Código: 1088261131

**DISERTACIÓN PRESENTADA PARA OPTAR AL TÍTULO DE
MAGISTER EN INGENIERÍA ELÉCTRICA**

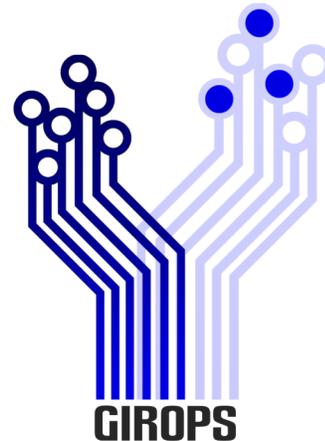
DIRECTOR

P.h.D. (c) LUIS HERNANDO RÍOS GONZALEZ

Profesor de Planta, Ingeniería Eléctrica

**LÍNEA DE INVESTIGACIÓN
AUTOMÁTICA**

**GRUPO DE INVESTIGACIÓN
ROBÓTICA Y PERCEPCIÓN SENSORIAL GIROPS**



**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERÍAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA
PEREIRA**

Mayo de 2014

Nota de aceptación:

Jurado

Jurado

Director

Pereira, Mayo de 2014

Índice general

Índice general	I
Índice de figuras	IV
Índice de tablas	VII
Resumen	IX
Objetivos	X
Justificación	X
1. Introducción	1
1.1. Introducción a la interacción hombre-computador (HCI)	1
1.2. Introducción a las interfaces cerebro-computador (BCI)	2
1.3. HCI y el puente con las Interfaces Cerebro-Computador (BCI)	3
1.4. Clasificaciones de las BCI	5
1.5. Aplicaciones	6
1.5.1. Tecnología Asistiva	6
1.5.2. BCI para la recreación	10
1.5.3. BCI en el diagnóstico cognitivo y la cognición aumentada	13
1.5.4. BCI en la rehabilitación	14
1.6. Aporte de esta tesis	15
1.7. Estructura de esta tesis	15
2. ENTRENAMIENTO DE MÁQUINA PARA APLICACIONES CON SISTEMAS BCI	17
2.1. Generalidades del entrenamiento de máquina	19
2.2. Configuración del entrenamiento de máquina para los sistemas BCI-EEG	21
2.2.1. Atención Selectiva	22
2.2.2. Imaginación Motora (MI)	23
2.3. Extracción de Características	26

2.3.1.	Análisis por Patrones Espaciales Comunes (CSP)	29
2.3.2.	Análisis de Componentes Principales (PCA)	31
2.3.3.	Análisis de Componentes Independientes (ICA)	32
2.4.	Tipología de Clasificadores	34
2.4.1.	Análisis Discriminante Lineal (LDA)	36
2.4.2.	Máquinas de Soporte Vectorial (SVM)	38
2.4.3.	Clasificadores Gaussianos	41
2.4.4.	Perceptrón Multicapa	43
2.4.5.	Cadenas Ocultas de Markov	44
2.5.	Validación de los Clasificadores	45
2.6.	Guía para la escogencia de un Clasificador BCI	46
2.6.1.	¿Cuál clasificador va con cuál sistema BCI?	47
2.6.2.	¿Cuál clasificador va con qué tipo de características?	48
3.	ESTADO DE LA TÉCNICA	50
3.1.	Fundamentos Fisiológicos	50
3.1.1.	El cerebro	51
3.1.2.	La neurona y el potencial de acción	53
3.1.3.	Generación y medición del Electroencefalograma	54
3.1.4.	Posicionamiento convencional de los electrodos de EEG	55
3.2.	Sistemas BCI basados en EEG	56
3.2.1.	Potenciales relacionados a eventos (ERP)	59
3.2.2.	Bandas de Frecuencia	62
3.3.	Acondicionamiento de la señal EEG	65
3.3.1.	Análisis Frecuencial	66
3.3.2.	Análisis Temporo-Frecuencial	68
3.3.3.	Análisis Espacial	69
3.4.	BCI Híbridas	70
3.5.	Hardware y Software BCI	71
3.5.1.	Emotiv EPOC: Una BCI confiable y de bajo costo	72
3.5.2.	EEGLAB como herramienta académica	74
3.5.3.	BCILAB Toolbox para BCI	75
3.5.4.	OpenViBe: Una herramienta gratuita en un entorno gráfico	76
3.6.	Neuromodulación con sistemas BCI para la Recuperación Motriz	80
3.7.	Tecnologías de Realidad Virtual en Rehabilitación	81
3.8.	Videojuegos para la salud usando sistemas BCI (BCI Games)	82
4.	MATERIALES Y MÉTODOS	87

4.1. Configuración Experimental	87
4.1.1. Conexión del neurocasco Emotiv EPOC con el OpenViBe	88
4.1.2. Estrategia BCI y entrenamiento	89
4.1.3. Descripción de los escenarios desarrollados	90
5. RESULTADOS Y ANÁLISIS	101
5.1. Experimento MI-BCI	101
5.2. Videjuego BCI Duck Hunt	107
5.3. Aplicaciones clínicas de la imaginación de movimiento en rehabilitación	108
5.4. Aplicaciones en Teleoperación de Sistemas Robóticos	109
6. CONCLUSIONES	111
Bibliografía	113

Índice de figuras

1.1. Mapa conceptual de las interfaces cerebro computador	7
1.2. Visualización de la GUI usada en la Bremen-BCI	8
1.3. Esquema de componentes propuesto para la comunicación entre la BCI y el tractor	10
1.4. Interacción con juegos virtuales a través de una interfaz cerebro computador	12
1.5. Diagrama de flujo de una BCI aplicada al control	14
2.1. Ilustración del dilema del sobreajuste. Si bien, dado solo un pequeño conjunto de muestras (izquierda), las hipótesis de línea sólida o la discontinua son ciertas, la discontinua es más compleja y tiene un menor error de entrenamiento. Solo con una mayor cantidad de muestras es posible ver cuál distribución se ajusta más. Si la hipótesis de la línea discontinua es cierta, la sólida deberá estar sobre ajustada (medio); si la sólida fuera la correcta, la hipótesis de la línea discontinua deberá estarlo (derecha).	21
2.2. 1. Representación Homuncular de la corteza motora según Peinfield.	24
2.3. En este experimento se le pidió a un sujeto en diferentes momentos de un día que imaginara el movimiento de su mano derecha versus el de su mano izquierda. Fueron grabadas las bandas alfa durante 3.5 segundos y se recolectaron las muestras.	27
2.4. Variabilidad inter-sujetos registrada en las señales EEG con la misma intención motora (Mover la mano derecha vs. Mover la mano izquierda).	28
2.5. Dos patrones espaciales comunes (CSP) de un ejemplo correspondiente a tareas de imaginación motora de izquierda y derecha.	30
2.6. Un hiperplano el cual separa las dos clases: los círculos y las cruces. Un umbral permite la discriminación de las clases a través de la tendencia w_0 y el vector de pesos w	37
2.7. Un ejemplo que ilustra una máquina de soporte vectorial entrenada que encontró el hiperplano óptimo con la margen de separación máxima a partir de los patrones de formación más cercanos, los cuales son llamados vectores de soporte.	39

2.8. Ejemplo del uso de un clasificador de GPs de 2 clases (C=2 caso binario). La salida de la técnica de clasificación basada en GPs toma la forma de una salida probabilística la cual es mostrada arriba como un mapa de contorno en un espacio de características bidimensional. La distancia de los contornos representa las regiones del espacio de características las cuales son equiprobables.	42
2.9. El esquema BCI-HMM comprende una fase de extracción de características a través de la transformación Whitening; la clasificación es basada sobre la selección de máxima verosimilitud.	45
3.1. Distribución de las funciones de la corteza cerebral.	52
3.2. Ejemplo de Potencial de Acción.	54
3.3. Representación diagramática de una configuración de electrodos 10-20. (a) y (b) representan medidas en 3 dimensiones, y (c) indica una vista bidimensional de una configuración 10-20 de 75 electrodos.	57
3.4. Apariencia clásica de una onda P300 generada por un estímulo visual.	60
3.5. Principio de funcionamiento de los sistemas BCI basados en SSVEP.	62
3.6. Frecuencia de bandas de EEG.	67
3.7. Izquierda: Neurocasco Emotiv Epoc. Derecha: electrodos disponibles del sensor según el sistema internacional 10-20.	73
3.8. Diagrama de integración de la API del Emotiv con la aplicación.	74
4.1. Diagrama funcional de la aplicación desarrollada.	88
4.2. Izquierda, conjunto de electrodos escogido para el experimento. Derecha, electrodos del EPOC en estándar 10-20 de EEG.	89
4.3. Previsualización del escenario de adquisición diseñado para la captura de las señales del usuario en el entrenamiento con imaginación motora.	91
4.4. Flechas de estimulación utilizadas por el cajón Graz Visualization para la recolección de datos.	92
4.5. Previsualización del Escenario de entrenamiento del filtro CSP.	93
4.6. Previsualización del Escenario de entrenamiento del clasificador.	96
4.7. Previsualización del Escenario de entrenamiento del clasificador.	97
5.1. Señales de los electrodos FC5 y FC6 antes y después del procesamiento con el filtro entre las bandas Alfa y Beta.	101
5.2. Aquí el sujeto 1 imagina el movimiento de su mano izquierda representado en el electrodo par.	102
5.3. Aquí el sujeto 2 imagina el movimiento de su mano izquierda representado en el electrodo par.	103

5.4. Aquí el sujeto 3 imagina el movimiento de su mano derecha representado en el electrodo impar.	103
5.5. Aquí el sujeto 4 imagina el movimiento de su mano derecha representado en el electrodo impar.	103
5.6. Aquí el sujeto 5 imagina el movimiento de su mano izquierda representado en el electrodo par.	104
5.7. Aquí el sujeto 6 imagina el movimiento de su mano derecha representado en el electrodo impar.	104
5.8. Aquí el sujeto 7 imagina el movimiento de su mano derecha representado en el electrodo impar.	104
5.9. Aquí el sujeto 8 imagina el movimiento de su mano derecha representado en el electrodo impar.	104
5.10. Resultados de la clasificación de los patrones de imaginación con los 3 clasificadores para todos los usuarios.	106
5.11. Exactitud del clasificador Nu-SVC con la sintonización del parámetro Nu.	106
5.12. Interfaz de usuario desarrollada para la teleoperación del sistema robótico Galileo Explorer.	110

Índice de tablas

4.1. Resumen de las diferentes técnicas utilizadas en las etapas del sistema BCI desarrollado.	98
5.1. Exactitud de los clasificadores evaluados en 8 usuarios diferentes.	105

Resumen

Las interfaces cerebro computador (BCI) son sistemas que le permiten a un usuario controlar una aplicación o un dispositivo sólo a través de su actividad neural. Una de las etapas más importantes para una aplicación con un sistema BCI es la implementación de algoritmos para la clasificación de los diferentes comandos necesarios para generar la interacción. Existen varias estrategias mentales para la interacción con sistemas BCI que pueden ser usadas en los experimentos neurocientíficos, una de ellas se conoce como Imaginación Motora, la cual permite la generación de eventos relacionados a desincronizaciones (ERDs) los cuales son decrementos temporales en la potencia de las ondas de EEG en las bandas alfa y beta. Estos ERDs ocurren cuando un sujeto realiza una imaginación de un movimiento en particular, como mover una de sus manos. Esta tesis se focaliza en el desarrollo de un experimento neurocientífico a través de la implementación de las diferentes etapas de una aplicación con una interface cerebro computador: pre-procesamiento, procesamiento, extracción de características, clasificación y aplicación. Se presentan 3 algoritmos que utilizan técnicas de aprendizaje de máquina para la clasificación de señales de una interface cerebro computador basada en electroencefalografía: LDA, C-SVC y NU-SVC con el fin de determinar cuál tarea de imaginación motora está ejecutando un usuario en un momento en particular del experimento. Se utiliza un hardware BCI comercial de bajo costo (Emotiv EPOC) con un software de acceso gratuito (OpenViBe) con el fin de demostrar que se pueden realizar de aplicaciones con sistemas BCI sin la necesidad de una gran inversión económica; la aplicación BCI final es un videojuego neurocontrolado que puede ser usado como terapia para pacientes con daños neurológicos como el accidente cerebrovascular o el Parkinson. Todos los clasificadores utilizan la técnica de patrones espaciales comunes (CSP) con el fin de extraer el filtro espacial que optimice la diferenciación entre dos tareas de imaginación motora antes de realizar la etapa de clasificación. Se evaluaron todos los algoritmos de clasificación en 8 sujetos sanos usando validación cruzada encontrando que los resultados de la máquina de soporte vectorial Nu-SVC tienen el mejor porcentaje de mejor exactitud promedio calculada 96.7%. Este resultado muestra que es posible realizar experimentos neurocientíficos con sistemas BCI de bajo costo y lograr exactitudes comparables con equipos más sofisticados y costosos, bajo la misma estrategia mental.

Objetivos

Objetivo general

Desarrollar una metodología para la implementación de un experimento de imaginación motora, basado en el uso de una interfaz cerebro computador de bajo costo usando software libre.

Objetivos específicos

- Establecer los algoritmos y técnicas necesarias para la implementación de un experimento BCI basado en imaginación motora: adquisición, pre-procesamiento, procesamiento, extracción de características, clasificación en línea y aplicación BCI final.
- Evaluar diferentes algoritmos de clasificación con el fin de optimizar la exactitud con un grupo de usuarios para la estrategia de imaginación motora utilizando software libre.
- Implementar un algoritmo de pre-procesamiento, procesamiento, extracción de características y clasificación de señales neurofisiológicas, para interactuar con un entorno de realidad virtual que permita entrenar el cerebro para mejorar y autorregular su actividad en funciones motoras específicas.
- Implementar algoritmos de aprendizaje de máquina para clasificar estados o tareas mentales del usuario BCI, para ser usados como comandos en la teleoperación de un sistema robótico en particular.

Justificación

Las interfaces cerebro computador permiten una amplia gama de aplicaciones tanto en personas con alguna condición de discapacidad, como para personas completamente sanas. La interacción entre el usuario y el sistema BCI no se da de manera arbitraria: una serie de señales generadas tras la ejecución de tareas mentales específicas pueden ser recolectadas, procesadas y clasificadas con el fin de generar aplicaciones que puedan ser neurocontroladas. Con este fin, es necesaria la implementación de múltiples técnicas de procesamiento de señal y de aprendizaje de máquina que optimicen los procesos de interacción creando protocolos confiables para la realización de experimentos en-línea. Sin embargo, la realización de estos experimentos requiere de herramientas en software y en hardware que son a menudo costosos, lo que limita ampliamente la investigación en el campo de las interfaces cerebro computador. Existen algunos sistemas BCI comerciales que además de ser cómodos y portables, también son económicos y su uso se ha extendido con diferentes grupos de personas. Sin embargo, una de las principales limitantes que presentan estas interfaces es la baja exactitud que se da en las tareas de clasificación en estrategias de interacción mental puntuales como el caso de la imaginación motora, ampliamente utilizada por neurocientíficos para aplicaciones como el manejo de prótesis neurocontroladas, el control de dispositivos asistivos y la neurorehabilitación de pacientes asistida por computador. Sumado a los inconvenientes en hardware, la carencia de herramientas en software de acceso gratuito que faciliten el procesamiento de la señal, dificulta la proliferación de experimentos serios en BCI que puedan ser aplicados al contexto socio-cultural colombiano, imposibilitando el avance científico en estos campos de la neurociencia aplicada.

1.1. Introducción a la interacción hombre-computador (HCI)

Hace décadas desde que el primer computador digital fue programado usando interruptores mecánicos y tableros de conexión, las interfaces por medio de las cuales intercambiamos información con los computadores han evolucionado significativamente. A pesar de su antigüedad, algunos periféricos tradicionales como el teclado y el ratón han resistido firmemente con el paso del tiempo, evolucionando en su ergonomía, tamaño y modo de conexión, más no en la esencia de su funcionalidad. Como los computadores han incrementado en su potencia de procesamiento y han disminuido en tamaños y costos, nuevos dispositivos se han ido creando para satisfacer las diferentes necesidades de un mercado cada vez más ávido de tecnología (ej. Smartphones, tabletas electrónicas, PDAs), nuevas plataformas de información han nacido (ej. internet), nuevas infraestructuras se han convertido en algo ampliamente disponible (ej. GPS) y nuevas industrias han surgido (ej. videojuegos, tecnologías interactivas). Todas estas tendencias han dado lugar a la democratización de la información a medida que el número de personas que interactúan directamente con los ordenadores se ha incrementado; cambiando notablemente la forma en que se desenvuelve la sociedad moderna en los ámbitos sociales, laborales, académicos, entre otros [1], debido a esto, la creación de computadores fáciles de usar y el entendimiento de cómo la computación afecta las personas se convierte en una actividad crítica. La Interacción Hombre-Computador (HCI por sus siglas en inglés) es una disciplina emergente diseñada para proporcionar la base intelectual por medio de la cual se crea esa tecnología con la que las personas interactúan con los computadores [2]; una tecnología cada vez más eficiente, portable y agradable para el usuario final. Entre estos desarrollos se encuentran herramientas de software para interfaces de usuario, modelos cognitivos, reconocimiento de voz, lenguajes de entendimiento natural, computación gráfica, reconocimiento de gestos, visualización de datos, agentes inteligentes, diseños de interfaces visuales, multimedia interactiva, drama y música computarizados, tutores inteligentes, escritura técnica y la organización del impacto social de la tecnología. Mientras la interpretación reflexiva de la historia de la HCI es compleja y matizada, ciertas generalizaciones son evidentes: la forma en cómo los humanos interactuamos con los computadores ha evolucionado y esta evolución ha

permitido a más personas hacer más cosas con los ordenadores.

1.2. Introducción a las interfaces cerebro-computador (BCI)

En el marco de la interacción, han sido múltiples los dispositivos e interfaces creadas para la captura de las diferentes señales provenientes de cualquier manifestación humana, como los movimientos, las intenciones musculares, los gestos corporales y faciales, inclusive hasta los pensamientos y las señales neuronales que se manifiestan mediante señales bioeléctricas. Estas últimas son materia de investigación desde los años 60's, en donde el Dr. Grey Walter conecto electrodos directamente a las áreas motoras del cerebro de un paciente. Al paciente se le pidió que presionara un botón para avanzar una diapositiva proyectada mientras el Dr. Walter grababa la actividad relevante del cerebro del paciente; poco después, el mismo doctor conecto el sistema directamente al proyector de diapositivas, de manera que la actividad cerebral registrada por el paciente era suficiente para activar la orden de pasar de diapositiva. De forma interesante el Dr. Walter encontró que se había introducido un retardo desde la detección de la actividad cerebral hasta el avance de la diapositiva proyectada, o sea, la diapositiva avanzaba antes que el paciente presionará el botón. El control se daba antes de que el movimiento pasara: un nuevo tipo de interacción estaba naciendo. De manera general, cualquier forma natural de comunicación o control requiere periféricos que capturan la actividad nerviosa y/o muscular, el proceso comienza con el intento del usuario. El intento desencadena un complejo proceso en el cual ciertas áreas cerebrales son activadas y entonces las señales son enviadas mediante el sistema nervioso periférico a los correspondientes músculos, los cuales a su vez realizan el movimiento necesario para la tarea de comunicación o de control [3]. La actividad resultante de este proceso es a menudo llamada salida eferente o motora. Eferente significa que contiene impulsos que se transportan desde el sistema nervioso central hasta el actuador o músculo. En contraste, un proceso aferente describe la comunicación en la otra dirección, desde los receptores sensoriales hasta el sistema nervioso central. Una interfaz cerebro computador ofrece una alternativa de comunicación y control natural entre el cerebro y dispositivos externos, se define como la ciencia y la tecnología de dispositivos y sistemas de respuesta a los procesos neuronales en el cerebro que generan movimientos motores y procesos cognitivos. Los avances en la neurociencia, la tecnología computacional, la miniaturización de componentes, biocompatibilidad de los materiales, y tecnología de sensores han conducido a una gran viabilidad en la mejora de las BCI, en donde los ingenieros, neurocientíficos, científicos físicos y los científicos sociales y del comportamiento puede integrarse como un equipo de gran alcance [4]. En lugar de depender de señales nerviosas o musculares, una BCI mide directamente la actividad cerebral asociada con la intención del usuario y traduce esta actividad grabada en señales correspondientes de control para diferentes aplicaciones. Algunas de las definiciones y características más destacadas de una BCI se encuentran plasmadas en [5]:

- Una interfaz cerebro computador (BCI) es un sistema basado en adquirir señales cerebrales mediante un ordenador, analizarlas y traducirlas en comandos que son retransmitidos a un dispositivo de salida para llevar a cabo una acción.
- En principio, cualquier tipo de señal cerebral puede ser usado para controlar un sistema BCI. Las señales más comúnmente estudiadas son las de tipo eléctrico provenientes de la actividad neuronal por medio de de electrodos en el cuero cabelludo, en la superficie cortical o en la corteza cerebral.
- Un sistema BCI consta de 4 componentes secuenciales: (1) adquisición de la señal, (2) extracción de características, (3) interpretación de las características, (4) dispositivo de salida. Estos 4 componentes son controlados mediante un protocolo de operación que define el inicio y tiempo de operación, los detalles del procesamiento de la señal, la naturaleza de los comandos del dispositivo y la supervisión del rendimiento.
- Las interfaces cerebro computador eventualmente pueden utilizarse de forma rutinaria para reemplazar o restaurar la función útil de personas con discapacidades graves que se dan debido a trastornos neuromusculares. Una BCI también podría mejorar la rehabilitación de personas con ACV (Accidente Cerebro-Vascular), trauma craneal y otros trastornos.
- El futuro de las BCIs depende a su vez del progreso de 3 áreas o aspectos críticos: desarrollo de hardware cómodo, conveniente y de adquisición de señal estable; la validación y difusión de las interfaces; y la puesta en prueba de la fiabilidad y la calidad de las BCI por parte de diferentes grupos de usuarios.

La motivación prevalente de las BCIs ha sido prever tecnología de tipo asistiva a personas con discapacidades físicas severas, como aquellas que producen parálisis completas e inhabilidades para hablar causadas por golpes o enfermedades crónicas. En algunos casos los sistemas BCI son llamados también interfaces cerebro máquina (BMI por sus siglas en inglés), en general, estos últimos suelen enfocar su aplicación final al manejo de máquinas como sistemas robóticos, prótesis, brazos electrónicos o cualquier otro tipo de máquina. Este par de términos (BCI e BMI) pueden discriminarse similarmente a como se diferencian la visión por computador y la visión de máquina.

1.3. HCI y el puente con las Interfaces Cerebro-Computador (BCI)

La evolución de cualquier tecnología en general, se puede dividir en tres fases. La fase inicial, o una prueba de concepto; muestra la funcionalidad básica de una tecnología. En esta fase, incluso los sistemas trivialmente funcionales son impresionantes y estimulan la imaginación. Por ejemplo, cuando el ratón del ordenador fue inventado, la gente estaba intrigada por la capacidad de mover distancias pequeñas por medio de dispositivos físicos sobre una mesa, un puntero en dos

dimensiones en una pantalla de ordenador. En la detección del trabajo cerebral, esto representa la capacidad de extraer cualquier pedazo de información directamente del cerebro sin utilizar los canales normales musculares. En la segunda fase, o la emulación, la tecnología se utiliza para imitar las tecnologías existentes. Los ratones de ordenador inicialmente se utilizaron para seleccionar de las listas de artículos, los que necesitaban comprar; tal y como lo habían estado haciendo con el teclado numérico. Del mismo modo, las primeras interfaces cerebro-ordenador se han dirigido a emular la funcionalidad de los ratones y teclados. Es en esta fase que la tecnología comienza a ser impulsada no tanto por su novedad y empieza a interesar a un público más amplio interesado por la ciencia de la comprensión y el desarrollo más profundo. Finalmente, la tecnología llega a la tercera fase, en la que alcanza la madurez en su derecho propio. En esta fase, los diseñadores tratan de comprender y explotar las complejidades de la nueva tecnología para crear experiencias únicas que nos proporcionan capacidades nunca antes disponibles. Se cree que las BCI recién ahora están saliendo de su infancia, y que existe la oportunidad para pasar de la prueba de concepto y de la emulación a etapas de la madurez. Sin embargo, para ello, no sólo tienen que continuar con el descubrimiento y la invención dentro del propio dominio, sino también empezar a construir puentes y generar el apalancamiento de trabajos en otros campos. Mientras tanto, el campo de interacción entre el humano y ordenador sigue trabajando para ampliar la información efectiva entre humano y máquina, y lo más importante para diseñar tecnologías que se integran perfectamente en nuestras tareas diarias [6].

Mientras que la comunidad BCI se ha centrado principalmente en mecánicas muy difíciles de adquisición de datos desde el cerebro, los investigadores en HCI podrían añadir experiencia en el diseño interfaces que permitan sacarle el mayor provecho a los escasos bits de información que tienen sobre el usuario y su intención. También traen un punto de vista ligeramente diferente que puede resultar en la innovación interesante en las aplicaciones existentes de interés. Por ejemplo, mientras que los investigadores BCI mantienen una admirable concentración en proporcionar a los pacientes que han perdido el control muscular de un dispositivo de entrada alternativo, los investigadores HCI puede complementar los esfuerzos teniendo en cuenta la totalidad de la experiencia de usuario, incluyendo factores tales como la preparación, la comunicación, el aislamiento y la conciencia. Más allá de la definición tradicional de interfaces cerebro-ordenador, los investigadores HCI ya han empezado a empujar los límites de lo que se puede hacer si se es capaz de mirar y cavar con profundidad en el cerebro del usuario, teniendo en cuenta cómo estos dispositivos se aplican a los usuarios sanos, además de los discapacitados. La comunidad HCI también ha sido particularmente exitosa en la exploración sistemática y la creación de nuevas áreas de aplicación. Además de pensar en utilizar la tecnología para solucionar los puntos existentes para el dolor, o para aliviar el trabajo difícil, esta comunidad ha buscado escenarios en los que la tecnología puede aumentar el tiempo de vida humana cotidiano de alguna manera [6].

Si bien la intersección de la HCI con los sistemas BCI es relativamente nueva, existen dos frentes de trabajo en donde estas disciplinas pueden converger y generar nuevas perspectivas: la primera son

las oportunidades de usar los sistemas BCI como herramienta de medición en los trabajos HCI, una medición dinámica de los estados emocionales de un usuario mientras utiliza una nueva interfaz, mientras interactúa con una nueva aplicación o mientras navega en una red social podría servir de apoyo para su optimización. De otra parte, la aplicación de métodos y técnicas de interacción basadas en el estudio de la HCI, podría lanzar a los sistemas BCI a un mercado más amplio, más incluyente y generar una interacción más precisa y dinámica con sus usuarios.

1.4. Clasificaciones de las BCI

El enfoque de la comunidad BCI de los últimos 20 años ha estado ceñido en desarrollar tecnologías de comunicación y control para personas que sufren de desórdenes neuromusculares las cuales a menudo conllevan a parálisis completas o estados locked-in (condición mediante la cual el paciente está consciente y despierto pero no se puede mover o comunicarse verbalmente). El objetivo final comúnmente es desarrollar tecnologías asistivas que ayuden a mejorar el nivel de vida de personas con diferentes tipos de discapacidades neuromotoras. Ahora bien, los avances en la tecnología BCI pueden ampliar el espectro de aplicaciones y usuarios que puedan utilizar este tipo de sistemas; una de las razones por las cuales para la gente “sana” pueda resultar interesante el uso de las BCIs es que estas le permiten usar su actividad cerebral como entrada a un sistema, quizá en combinación con otras modalidades, o bien sea directamente controlando una interfaz de control; mediante la utilización de ciertas tareas mentales que son asociadas a determinadas regiones del cerebro que han sido ampliamente estudiadas y ahora pueden ser distinguidas con certeza y asignadas a una amplia variedad de órdenes [7]. Las aplicaciones incluyen, entre otras cosas, navegación en mundos virtuales, control de un robot, un cursor o un menú de una aplicación. Claramente es preferible que esta asignación (a menudo llamada mapeo) sea intuitiva y natural; aquí es claro que la estrategia mental que debe ser usada debe relacionar las tareas que son implementadas en el mundo real con las de la interfaz de usuario de la aplicación. Una BCI puede ser invasiva o no invasiva y puede ser basada en señales electrofisiológicas (EEG, ECoG, intracortical, entre otras) o en otras señales como NIRS (espectroscopia de infrarrojo cercano) y fMRI (resonancia magnética funcional); en donde la diferencia más notoria en cuanto a la señal es que en las interfaces de tipo invasiva se obtiene una señal con una amplia relación señal-ruido, lo cual facilita el pre-procesamiento y procesamiento de las señales [8]. Las BCI también varían en otras cosas, por ejemplo, la estrategia mental usada para el control, algunos parámetros de la interface como el modo de operación (síncronas o asíncronas), el tipo de realimentación, el método de procesamiento de la señal y la aplicación.

La figura 1.1 muestra una visión general de los componentes de una BCI y como estos se relacionan unos con otros; el modo de cómo clasificar estos sistemas puede escogerlo el investigador según sus propio punto de vista.

Otra clasificación muy usada para los sistemas BCI es basada en los patrones cerebrales que son

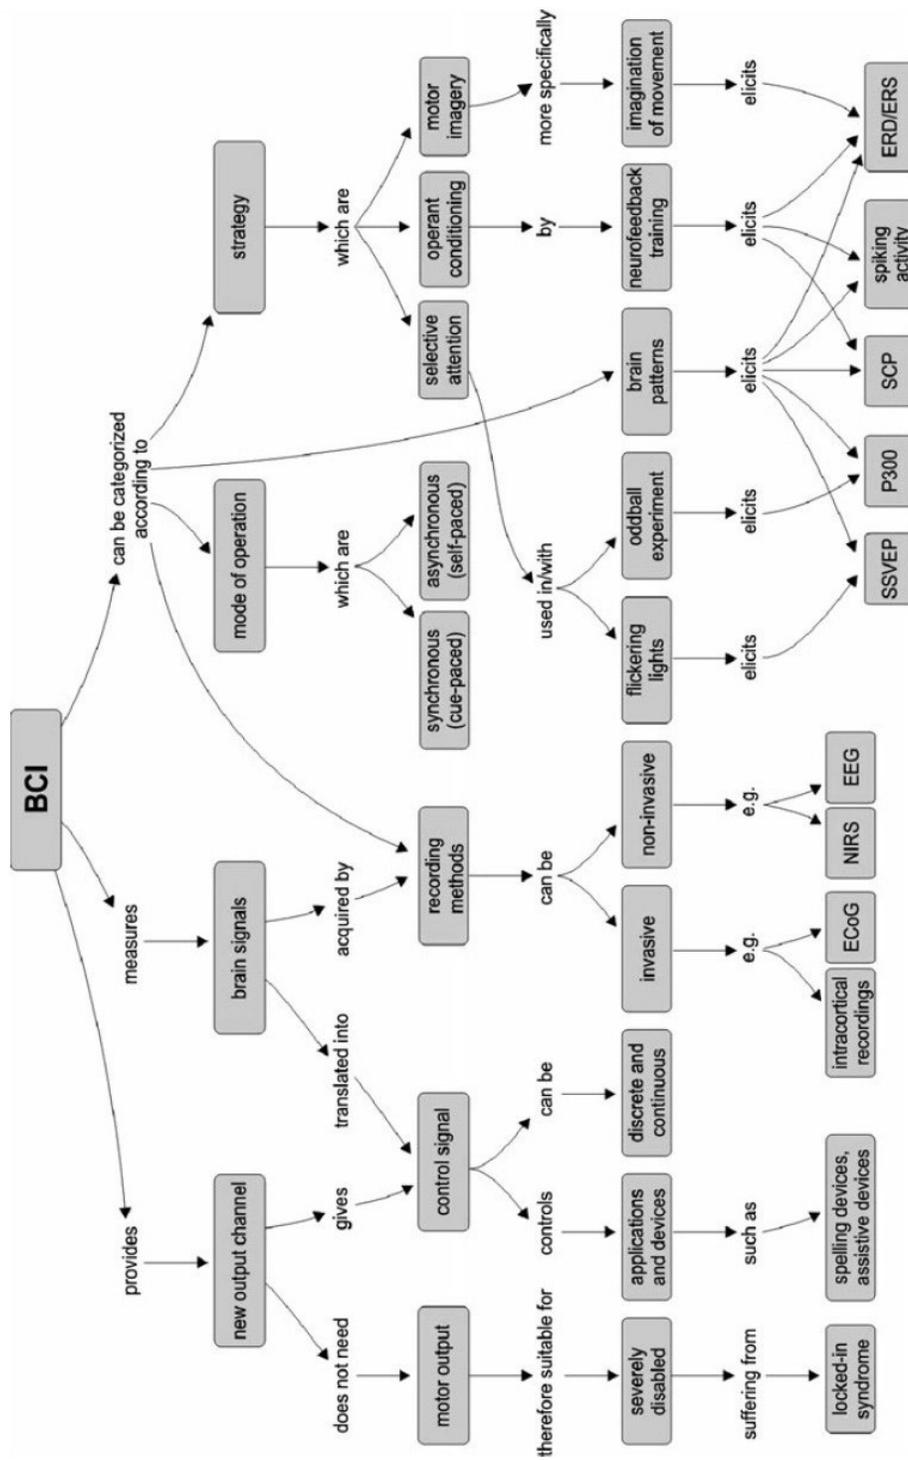


Figura 1.1. Mapa conceptual de las interfaces cerebro computador

producidos, como la onda P300 muy usada para los sistemas de escritura o deletreadores, los potenciales evocados mediante estímulos visuales usados por los sistemas BCI más comerciales y con un claro enfoque hacia la industria de los videojuegos (Emotiv EPOC, NeuroSky MindSet) y los eventos relacionados a sincronizaciones y desincronizaciones muy comunes en aplicaciones como el control de sistemas robóticos e interfaces con máquinas. A continuación se realizará una descripción de las aplicaciones más comunes de las interfaces cerebro computador, las cuales han sido implementadas gracias a la explosión del desarrollo tecnológico marcado por el incremento de la capacidad y la velocidad de procesamiento de los computadores.

1.5. Aplicaciones

Los recientes y significativos avances en computación y tecnología de biosensores han mejorado notablemente las perspectivas de las aplicaciones de las BCIs, permitiendo sacar del confinamiento investigativo el estudio de estas interfaces y sus efectos en los diferentes procesos cognitivos, transformándolos en tema de amplia discusión en diferentes entornos debido a la reducción de costos y la diversidad de herramientas disponibles. En esta sección se pretende describir las aplicaciones de los sistemas BCI, introduciendo no sólo una visión clásica motivada por el continuo desarrollo de interfaces para el apoyo de procesos en el sector de la salud, sino también, una vista más reciente de lo que hacen desarrolladores, empresas e inclusive artistas con este tipo de interfaces [6].

1.5.1. Tecnología Asistiva

Comunicación

La restauración de habilidades para la comunicación, el control del ambiente y la mejora de la movilidad son focos claros de cómo las interfaces cerebro computador ayudan al mejoramiento de la calidad de vida de las personas otorgándole herramientas de tipo asistivo para su cotidianidad. El proceso de comunicación más rudimentario es la capacidad de establecer un “sí” o un “no”; las aplicaciones recientes apuntan al paradigma en el cual los usuarios modulan su ritmo mu, el cual es asociado con los procesos sensitivomotores asociados al movimiento, con el fin de seleccionar una de las dos señales (sí o no); este señalamiento a menudo utiliza realimentaciones visuales, como cuadros o cursores, con el fin de que el usuario escoja la respuesta que desee. Por otra parte, el desarrollo y la implementación de deletreadores que utilizan BCIs han sido muy numerosos, en [9] utilizan una matriz de 6x6 con caracteres alfanuméricos donde realizan la detección de la señal P300- es un potencial relacionado a un evento que puede ser registrado mediante EEG como una deflexión positiva de voltaje-, donde una de sus filas o columnas parpadean al azar en una secuencia en particular; cuando una columna o fila contiene el carácter que el sujeto desea comunicar, se realiza una detección de la onda P300 mediante la evocación de la combinación deseada que provoca dicha señal. Diversos experimentos han establecido tasas de hasta 4 caracteres

por minuto; sin embargo en [10] presentan una interfaz un poco más elaborada compuesta por un teclado virtual de 32 caracteres localizados en la mitad de la pantalla, se utilizan además algunos cuadros blancos que contienen las cuatro flechas de navegación más un botón de selección los cuales permiten alcanzar tasas de casi 5 caracteres por minuto. Una previsualización de la interfaz guía de usuario (GUI) es presentada a continuación:

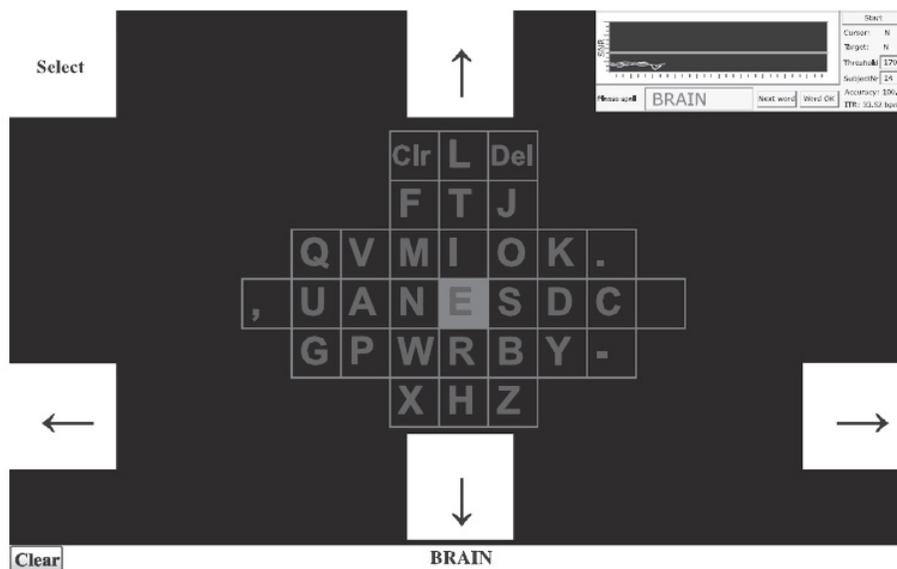


Figura 1.2. Visualización de la GUI usada en la Bremen-BCI

La investigación en esta área busca explorar métodos para reducir el número de parpadeos necesarios para hacer la selección con el objetivo de lograr la selección correcta con un estímulo simple. Otra herramienta de tipo asistiva útil en los últimos años radica en el desarrollo de buscadores web que utilizan señales neuronales como datos de entrada para realizar la búsqueda. El acceso a internet puede cambiar notablemente la vida de las personas con discapacidades físicas severas: la web proporciona la capacidad para la educación; la gestión financiera, la comunicación e incluso el empleo. Este tipo de plataformas se basan en la regulación de los Potenciales Corticales Lentos (SCPs) por parte del usuario, el control de los buscadores es implementado utilizando árboles de decisión binarios con comandos tales como escribir un correo electrónico o navegar por la red. En Colombia, por ejemplo, según la Ley 361 de 1997 su artículo 31 [11] establece que los empleadores que ocupen trabajadores con limitación no inferior al 25 % comprobada y estén obligados a presentar declaración de renta y complementarios, tienen derecho a deducir de la renta el 200 % del valor de 105 salarios y prestaciones sociales pagados durante el año o período de trabajo de la persona discapacitada; sobre este artículo, las interfaces BCI para personas con discapacidad en miembros superiores podrían convertirse en una novedoso método para el control de software especializado en empresas como centros de llamadas (call-centers), oficinas de pagos de servicios públicos y otros

en donde se maneja todo tipo de software especializado con menús y formularios básicos [12].

Control Ambiental

El uso de las BCIs dentro del área de la domótica busca interconectar elementos electrónicos del hogar como los televisores, las luces y los reproductores de audio, a un circuito de control activado por ondas neuronales. Por ejemplo si se pensara en la matriz de caracteres dentro del deletreador, se podría pensar la posibilidad de reemplazar los símbolos por órdenes directas de control, entonces, se ofrecería simultáneamente un gran número de posibilidades que el usuario podría escoger para controlar diversos dispositivos electrónicos dentro de su hogar o lugar de trabajo [13]. Una introducción prolongada de este tipo de interfaces en la vida diaria de las personas con discapacidades puede generar un incremento positivo significativo en el modo en cómo las personas perciben su nivel de vida, restaurando su independencia en la interacción social y contribuyendo a su restauración como personas activas dentro de la sociedad, a su capacidad de participación autónoma dentro de la misma e inclusive a la inclusión digital dentro de la web.

Movilidad

Naturalmente una de las investigaciones y aplicaciones más plausibles de los sistemas BCI se centra en permitir a las personas con discapacidades motoras severas la restauración del movimiento. La comunicación con sillas de ruedas y la manipulación de robots móviles son las aplicaciones más encontradas en la bibliografía del uso de estas interfaces en la movilidad, encontrando también el manejo de carros, tractores y otros mecanismos, una proeza expectante y un tema de amplia investigación el campo de las interfaces hombre máquina (HMI). En el trabajo con sillas de ruedas se busca crear sistemas que sean más inteligentes que los convencionales, los cuales se encargaban de transmitir órdenes discretas a los controladores eléctricos que accionan los arreglos mecánicos de cada silla en particular, brindando la posibilidad de moverse hacia cualquier dirección mediante una combinación lineal de órdenes sencillas como ir hacia adelante o hacia atrás; desarrollos más modernos buscan crear una conexión inteligente entre los hábitos y preferencias del usuario y la capacidad de desplazamiento, permitiéndole a los usuarios desplazarse a lugares específicos dentro de su casa con el uso de una sola orden. El costo de este tipo de sistemas también ha bajado considerablemente, impulsado no sólo por el bajo costo de las BCIs, sino también por el desarrollo de plataformas en hardware libre como el arduino [14]; el cual permite- entre otras- una transmisión inalámbrica segura y confiable de los datos procesados en un ordenador a un muy bajo costo, sirviendo de puente entre las señales bioeléctricas sensadas a través del EEG y cualquier dispositivo electrónico. Investigadores alemanes probaron la destreza y versatilidad de los sistemas BCI a través de la creación de un manipulador mental de carros, una plataforma que permite mediante un entrenamiento mental con objetos virtuales, interpretar patrones de intenciones de movimientos como girar el manubrio a la derecha o inclusive acelerar o frenar; una implementación similar

es usada para mover un tractor de granja [15]. Un diagrama de flujo de esta última aplicación es mostrado a continuación:

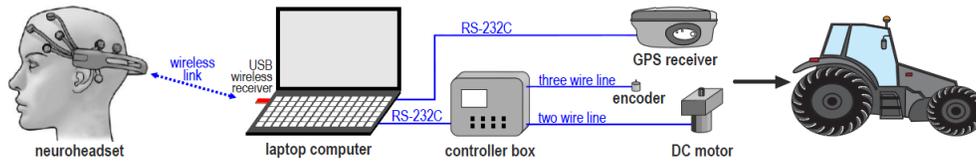


Figura 1.3. Esquema de componentes propuesto para la comunicación entre la BCI y el tractor

En general es posible pensar que cualquier sistema móvil pueda ser teleoperado inalámbricamente mediante el uso de las interfaces cerebro computador; basta con realizar un eficiente clasificador y realizar las adaptaciones electromecánicas para que el sistema móvil pueda desplazarse a través de comandos enviados desde un ordenador. El concepto de manejar sistemas robóticos a través de la mente ha sido popular desde los conceptos expuestos en la ciencia ficción; sin embargo investigaciones recientes demuestran el creciente uso de los sistemas BCI para el manejo de diversos robots centrados en el campo de la tecnología asistiva, logrando expandirse hasta las aplicaciones militares e industriales. Estos experimentos exploran los efectos de una realimentación propia del mundo real (movimientos de un robot) en conjunto con las BCIs basados en la onda P300 que dependen de la atención del usuario [6], o la producción de eventos relacionados a través de la imaginación motora.

1.5.2. BCI para la recreación

La dinámica interactiva de los sistemas BCI tienen un abanico amplio de posibilidades para el control de aplicaciones como videojuegos, realidad virtual y expresiones creativas [16]. Inicialmente las dinámicas de los aplicativos en realidad virtual generaban una opción altamente efectiva para el tratamiento y la disminución en la dependencia de fármacos de personas con discapacidades motrices y esto llamó la atención de la comunidad médica en particular. Sin embargo, el desarrollo y salida al mercado de interfaces de bajo costo que eran presentadas como nuevos dispositivos para el control de videojuegos, permitió un desarrollo acelerado de las aplicaciones y nuevos usos de estos sistemas que hasta entonces eran confinados solo a unos cuantos laboratorios especializados. Aunque todavía no han sido ampliamente aceptadas como una herramienta que reemplace los controles tradicionales como los joysticks los controles de botones, estas interfaces han sido incorporadas dentro de los juegos como controles auxiliares para funciones particulares [6].

Videojuegos

Uno de los primeros investigadores que contempló la opción de combinar simulaciones o juegos en realidad virtual con las BCI fue Nijholt [17]; como se indica en el estudio, los primeros juegos controlados por estas interfaces se enfocaron en el diagnóstico de las señales cerebrales en aspectos como la medición de la atención del usuario o la relajación en componentes afectivos de los juegos. La interacción de individuos en juegos de tipo inmersivos con ambientes tridimensionales brinda más datos característicos como emociones o interpretaciones del contexto que ayudan a entender con mayor facilidad las actividades y deseos de los usuarios; aquí, suele usarse una metodología que mediante la retroalimentación visual con imágenes, videos o animaciones les permite a los usuarios imaginar cierto movimiento en funciones como navegar en un ambiente físico virtual, este tipo de procedimiento es llamado imaginación motora y es un estado dinámico durante el cual un individuo simula mentalmente una acción determinada [18]. Usando esta metodología se realizó un estudio en China para realizar el control en línea de un sistema de prótesis de miembro superior el cual consistía en usar una BCI para orientar su control y realizar seis actividades o movimientos asignados mentalmente como mover: la mano derecha, la mano izquierda, el pie derecho o el pie izquierdo [19]; los participantes caminaban en una cinta caminadora mientras se les proporcionaba una retroalimentación visual, arrojando como resultado la factibilidad de desarrollar plataformas no invasivas neuronales para el análisis y la restauración de la marcha humana. En la figura 1.4 se muestra a Tan Le, co-fundadora de la empresa Emotiv, creadora de uno de los sistemas BCI más populares, comerciales y prometedores del momento: el EPOC; un neuro-casco provisto de 14 electrodos y un acelerómetro el cual será descrito más adelante en detalle dada su importancia en la presente tesis como sistema BCI de captura. Uno de los focos más interesantes de desarrollo del EPOC se centra en la industria de los videojuegos, en donde ha mostrado ser superior a otras interfaces debido a su portabilidad, comodidad y a la integración directa con motores de videojuegos populares como el Unity.

Aunque los ambientes virtuales suelen clasificarse dentro de la categoría de videojuegos, las finalidades y la diversidad de propósitos que van más allá de la simple diversión que proporcionan los juegos, establecen una clara diferencia para su uso.

En [20] utilizan ambientes virtuales con avatares y objetos virtuales con el fin de que pacientes con discapacidades motrices aprendan a controlar el esqueleto de su propia representación virtual a través de señales neuronales; las intenciones y voluntades motrices en cada miembro de los usuarios son traducidos al escenario virtual con el fin de permitir un desplazamiento controlado, permitiéndole al usuario un entrenamiento cinemático óptimo y evitando de esta manera complicaciones que podrían presentarse en escenarios reales. Este tipo de desarrollos son presentados como una esperanza promisoría para que en un futuro cercano, personas con parálisis puedan recobrar una amplia gama de funciones de movilidad deseadas [21].



Figura 1.4. Interacción con juegos virtuales a través de una interfaz cerebro computador

Expresión Creativa

Otro par de campos sobre los cuales se han desarrollado una gran diversidad de aplicaciones de los sistemas BCI son la música y las artes visuales. En estas disciplinas convergen gran diversidad de desarrolladores y artistas que buscan mejorar la calidad de vida de las personas mediante la promoción de la creatividad de expresión. En [22] se realizó un estudio que demuestra la potencialidad fehaciente de implementar clasificadores de emociones y sistemas de comunicación emocional aumentada para crear instrumentos musicales que son activados mediante señales de EEG; esto se realiza mediante un entrenamiento previo en donde los usuarios son expuestos a diferentes tipos de sonidos y las reacciones bioeléctricas son sensadas con el fin de encontrar parámetros comunes de comportamiento y reacción ante las diferentes tonalidades propuestas utilizando intenciones musculares, electro-oculografía y EEG. Estos resultados sugieren la posibilidad de crear sistemas BCI que comuniquen los sentimientos de los usuarios de una manera no verbal sino a través de comunicación músico afectiva; también se plantea la posibilidad de clasificar las emociones sentidas a través de la interpretación de instrumentos en determinados tonos. En el área de artes visuales [23] se ha experimentado con el uso de la onda P300 en la tarea de pintar cuadros usando solamente la actividad neuronal. Se realizaron pruebas con pacientes con ALS (Esclerosis Lateral Amiotrópica) y con personas sanas aplicando técnicas de matrices de colores y matriz de blanco y negro; encontrando entre sus resultados altas precisiones en los pacientes con ALS, permitiéndoles expresar su creatividad y participar activamente en la sociedad mediante eventos como exhibiciones y demostraciones. Se concluye que el uso de los sistemas BCI

en el campo del arte va más allá de ser una simple expresión más de la capacidad cognitiva humana: produce estados placebo que provocan una mejoría significativa en pacientes con cuadros clínicos de parálisis total o parcial que no podrían expresar su creatividad de otra manera.

1.5.3. BCI en el diagnóstico cognitivo y la cognición aumentada

En adición con la tecnología asistiva y las terapias de rehabilitación, los sistemas BCI han sido desarrollados para ayudar en el diagnóstico, la influencia y el aumento de la función cognitiva. Algunas de las aplicaciones han permitido también profundizar y abrir nuevas fronteras en campos como la cognición aumentada y el sub-campo de las ciencias computacionales conocido como la experiencia de usuario; muchas de estas investigaciones están enfocadas a la evaluación en tiempo real del estado cognitivo de las personas con el fin de ajustar la carga de trabajo propuesta a las capacidades mentales de cada trabajador. Inclusive este tipo de herramientas podrían incluir una “amplificación de la inteligencia”, otorgando información para aumentar el razonamiento humano o las habilidades para resolver los problemas [6].

Detección de coma

El “Coma Science Group”, grupo líder en tratamiento, comprensión y atención médica de las personas con trastornos de la conciencia después de una lesión aguda como el coma, los estados vegetativos o los síndromes locked-in, en un trabajo presentado recientemente [24] determinaron como los sistemas BCIs pueden servir como herramienta de soporte para detectar niveles de conciencia en pacientes con desórdenes de conciencia mediante la detección de comandos de respuesta y comunicación. Estos desarrollos hacen que las posibilidades de recuperar la conciencia o la recuperación de un estado de coma o vegetativo puedan ser evaluadas en respuesta a los ERP (Potenciales Relacionados a Eventos), lo que podría proporcionar una información importante a las familias y cuidadores de las personas con síndrome locked-in.

Experiencia de usuario computacional

Dentro del área de la HCI se busca generar múltiples prototipos para evaluar la usabilidad de los desarrollos y aplicativos con el fin de mejorar las dinámicas interactivas y los tiempos en que se realizan las actividades. La experiencia de usuario implica la clasificación de la carga de trabajo mental como un método de prueba de la efectividad en la usabilidad de un diseño dentro del área de la interacción humano computadora. Algunos estudios han demostrado que la carga mental durante el uso de una aplicación puede ser medida y evaluada usando clasificadores de señales EEG arrojando hasta un 99 % de precisión [6], mediante la recolección y clasificación de datos que reflejan estados cognitivos del usuario, se puede evaluar qué tipos de interacciones producen sensaciones como frustración o satisfacción. Esta información puede ser utilizada para realizar una adaptación automática de interfaces y sistemas a las capacidades mentales de cada usuario;

estos resultados intentan avanzar en entender cómo se realiza el proceso de interacción hombre computador dentro del cerebro [21].

Clasificación de imágenes visuales

Otra de las aplicaciones de los sistemas BCI desarrollada en años recientes es el empleo de las señales EEG para la clasificación automática de imágenes mediante la medición de las respuestas mentales del usuario ante estímulos visuales. El uso de diferentes técnicas de aprendizaje de máquina busca alcanzar resultados de clasificación en tiempo real aumentando la precisión y extendiendo su uso al trabajo en línea de los algoritmos. En [25] se diseña una serie de pruebas y experimentos neurocientíficos usando el EPOC, los cuales permiten realizar predicciones sobre estímulos visuales de imágenes de rostros y escenas mostradas en una pantalla; el resultado es la clasificación en tiempo real de imágenes de estas dos clases mediante información mental capturada vía EEG usando un método de clasificación supervisado.

1.5.4. BCI en la rehabilitación

Quizá una de las más significativas y prometedoras aplicaciones de las BCIs envuelve el estudio y la creación de terapias que ayudan a recuperar el control motor previamente perdido en pacientes con enfermedades como el ACV. El control neural de robots para la rehabilitación, por ejemplo, podría proporcionar tratamientos para las personas cuya parálisis este demasiado avanzada como para usar terapias convencionales. En [26] se muestra un diagrama de flujo que permite visualizar la forma en cómo se desarrollan las aplicaciones usando sistemas BCI para el control de robots.

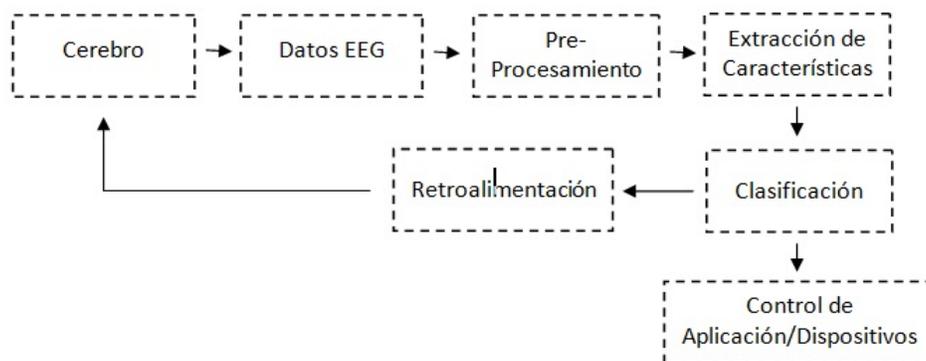


Figura 1.5. Diagrama de flujo de una BCI aplicada al control

En este estudio se buscaba probar la factibilidad de un sistema BCI particular en el control de robots personales, en este caso se utilizó un robot móvil dotado con dos ruedas y sensores de proximidad para mejorar la navegación. Se realizó un estudio en donde se combinaba el aprendizaje de máquina, redes neuronales, ondas cerebrales y una interfaz para el control del robot. Como entrada de datos,

el sistema podría utilizar señales provenientes de los nodos de oculografía de la interfaz EEG, o bien utilizar pensamientos concretos relacionados a la dirección de movimiento requerida; este tipo de investigaciones pueden ciertamente permitir una implementación directa hacia cualquier sistema robótico, una vez desarrollado el algoritmo de aprendizaje no supervisado para el proceso de clasificación de los pensamientos. De manera general, el diagrama de la figura 5 puede ser extendido para el diseño e implementación de aplicaciones usando sistemas BCI en muchas de las áreas ya mencionadas. En otros estudios relacionados con la rehabilitación [6], se describen dos estrategias para restaurar el movimiento en pacientes paralizados a través de las BCIs: el entrenamiento del paciente produce señales cerebrales motoras más “normales” esto permite un manejo más dirigido y controlado de los dispositivos que se requieran mover.

1.6. Aporte de esta tesis

La hipótesis inicial de esta tesis está sustentada en la posibilidad de generar sistemas de interacción cerebro-máquina de bajo costo usando herramientas de software libres para el trabajo con sistemas BCI. Hay que tener en cuenta que el software tendrá que ser lo suficientemente robusto como para permitir el pre-procesamiento, la extracción de características y la posterior clasificación de las señales EEG capturadas; proporcionando además, herramientas para la comunicación con hardware y otros elementos externos que permitan generar acciones precisas en diferentes aplicaciones (ej: sistemas de realidad virtual, sistemas robóticos, etc.). Tras el desarrollo de nuevas BCI más portables, económicas y eficientes, el desafío ingenieril consiste en la adecuación de estos complejos sistemas y sus señales con el fin de generar soluciones prácticas en problemas puntuales como la generación de nuevas terapias de neurorehabilitación basadas en interfaces de interacción cerebro computador, la teleoperación de sistemas robóticos a través de nuevos métodos de interacción y la creación de tecnologías asistivas más inteligentes para el mejoramiento de la calidad de vida de personas en condición de discapacidad.

1.7. Estructura de esta tesis

En el presente capítulo, el introductorio, hemos realizado un recorrido por algunos de los términos más importantes en el manejo de sistemas BCI partiendo desde su definición misma, hasta recorrer algunas de las más relevantes y promisorias áreas en donde la comunidad BCI ha centrado sus esfuerzos por transformar el uso de estas interfaces en algo más cotidiano y de interacción más natural. En el capítulo 2 se abordan los aspectos relevantes al aprendizaje de máquina para sistemas BCI: los procedimientos de extracción de características y las técnicas de aprendizaje de máquina más usadas; en donde se resalta una guía elaborada para la escogencia del clasificador óptimo para las aplicaciones con sistemas BCI basado en las características de las señales y el tipo de interfaz a usar en el experimento neurocientífico. En el capítulo 3, se realiza una revisión acerca del estado

de la técnica, trabajando los aspectos fisiológicos de la generación de la señal EEG usada para los sistemas BCI así como el proceso inicial de pre-procesamiento y acondicionamiento de la señal. Este capítulo contiene una descripción extensa del neurocasco Emotiv EPOC que es usado en este trabajo como sistema BCI y un listado de herramientas en software que permiten el desarrollo de aplicaciones a través de estas interfaces. El capítulo 4 describe el procedimiento experimental usado y desarrollado para la implementación de esta tesis; características del sensor y de la señal adquirida, metodologías usadas para la extracción de características y técnicas de aprendizaje de máquina implementadas. Finalmente el capítulo 5 expone los resultados alcanzados usando los diferentes clasificadores junto con la estrategia mental de imaginación motora propuesta. Este capítulo finaliza con un análisis extenso de los resultados alcanzados así como con las perspectivas potenciales futuras de la aplicación BCI y las conclusiones.

ENTRENAMIENTO DE MÁQUINA PARA APLICACIONES CON SISTEMAS BCI

En esta sección se abordan algunas de las características principales del uso de técnicas de entrenamiento de máquina usadas para la clasificación efectiva de la actividad neuronal, específicamente de datos obtenidos de las interfaces cerebro computador (BCI por sus siglas en inglés) que funcionan con Electroencefalografía (EEG). Los sistemas BCI permiten detectar cambios en las señales cerebrales que a menudo reflejan la intención humana; estas señales son traducidas para controlar o monitorear dispositivos externos o aplicaciones en un ordenador. El sofisticado desarrollo de algoritmos de entrenamiento de máquina y reconocimiento de patrones de las últimas 2 décadas permite convertir toda la actividad neuronal registrada por las BCI en las señales de control requeridas, la investigación en estos sistemas se ha focalizado ampliamente en implementar métodos eficientes para el procesamiento de las señales y el desarrollo de técnicas de aprendizaje de máquina que clasifiquen con precisión la complicada señal adquirida a través de estas interfaces [3]. Algunos autores han identificado un conjunto de características que son comunes y críticas en el momento de diseñar una aplicación efectiva con una BCI [27]:

- Ruido y Outliers: los datos EEG tienen una relación pobre (de poca diferencia) entre la señal y el ruido.
- Alta dimensionalidad: los vectores de características son a menudo de altas dimensionalidades. Muchas características son generalmente extraídas de muchos canales y de muchos segmentos temporales antes de ser concatenadas en un solo vector de características.
- Información Temporal: las características de las BCI contienen información en el tiempo debido a que los patrones de actividad cerebral son generalmente relacionados a variaciones específicas en el tiempo del electroencefalograma.
- No estacionariedad: las características de una BCI son no estacionarias ya que las señales EEG realizan rápidas variaciones sobre el tiempo, especialmente en sesiones periódicas.
- Conjuntos pequeños de entrenamiento: los conjuntos de entrenamiento son relativamente

pequeños ya que el proceso de entrenamiento consume tiempos considerables y es exigente para los sujetos.

Particularmente la no estacionariedad de las bioseñales adquiridas en los sistemas BCI requiere una amplia discusión desde el punto de vista del análisis de los datos debido a la variabilidad significativamente amplia entre muestra y muestra y sujeto a sujeto. Debido a estas condiciones, los métodos de entrenamiento de máquina se han convertido en una herramienta ideal para aplicaciones en tiempo real con datos EEG. Este capítulo plantea una revisión de los métodos de extracción de características y clasificación más usados en el entrenamiento de máquina para sistemas BCI, así como las estrategias mentales que deben usarse en el momento de capturar los datos de entrenamiento. Cuando se analiza la alta dimensionalidad de los datos no sólo es importante visualizar, predecir o clasificar los datos con un error bajo; también es trascendental explorar aquellas herramientas de análisis que permitan explicar la estructura compleja intrínseca del pensamiento humano con el fin de contribuir a un mejor entendimiento de los resultados obtenidos [28]. El aprendizaje y la clasificación de las señales obtenidas es, sin duda, el componente crítico de toda la aplicación que se desea desarrollar dado a que es el bloque que convierte la entrada de las señales bioeléctricas del usuario previamente caracterizadas, en una señal de mando que permite controlar cualquier tipo de dispositivo externo, como un robot o una silla de ruedas. De su tasa de acierto depende la efectividad de la aplicación, la naturalidad de la interacción y la adaptabilidad de los usuarios con los sistemas BCI; sin embargo, incluso con la mejor implementación algorítmica, el éxito de la operación depende significativamente de qué tan bien los usuarios pueden voluntariamente modular su actividad neural: las personas objeto de investigación necesitan producir señales que sean fáciles de detectar. Esto es sustancialmente importante en el control de dispositivos en el “mundo real”, en donde el fondo de la actividad mental y otras fuentes de ruidos eléctricos a menudo fluctúan impredeciblemente. El aprendizaje para operar dispositivos controlados por los sistemas BCI requiere de constantes y repetidas sesiones en donde se busca alcanzar un nivel óptimo de concentración con la información de realimentación y de fondo, por tanto, el entrenamiento con las interfaces cerebro computador involucra ampliamente los mecanismos de aprendizaje del cerebro. Es importante definir con claridad el tipo de aplicación que se desea; manejo de un cursor en una pantalla de un ordenador, selección controlada de un icono dentro de una interfaz de usuario, teleoperación de un sistema robótico, etc., ya que existen diferentes protocolos de entrenamiento y técnicas de realimentación para cada una. El modo de operación de los sistemas BCI es un tipo de aplicación de neuro-realimentación y el entendimiento de sus principios y causas permite a los investigadores BCI adaptar los procesos de entrenamiento acorde a los principios operantes del aprendizaje cognitivo [3].

2.1. Generalidades del entrenamiento de máquina

Esta sección está enfocada a brindar una noción general y unas definiciones del aprendizaje de máquina como herramienta para crear aplicaciones con los sistemas BCI en tiempo real. Los experimentos neurocientíficos a menudo permiten contrastar algunos estados específicos del cerebro; típicamente el experimentador escoge un paradigma neurofisiológico que permita maximizar las diferencias existentes entre dichos estados. Después de guardar los datos provenientes de las intenciones mentales del usuario, el objetivo del análisis es encontrar las diferencias significativas en las características espacio-temporales de los datos que permitan contrastar los diferentes estados con la mayor precisión posible. El uso de un análisis estadístico simple como la media general puede ayudar a construir el modelo, sin embargo las técnicas avanzadas de aprendizaje de máquina se han convertido en una herramienta altamente eficaz para resolver problemas de experimentos neurocientíficos. Formalmente el problema de discriminación o diferenciación entre estados cerebrales o intenciones es llamado problema de clasificación, en donde a partir de los datos controlados se calcula el clasificador que permite particionar el conjunto de observaciones en subconjuntos con características estadísticas diferenciadoras. Note que no solo los paradigmas con una connotación fisiológica conocida son el punto de partida: una hipótesis acerca de las tareas relevantes subyacentes de los procesos del cerebro generada automáticamente por una máquina aprendida puede generar un sin fin de posibilidades para la creación de nuevas aplicaciones de los sistemas BCI. La captura de esta información por parte del experimentador puede permitirle un refinamiento del paradigma inicial, el cual produce a un mejor entendimiento de los procesos cerebrales materia de estudio. En este sentido, el entrenamiento de máquina no sólo es la técnica computacional ideal para un modelamiento genérico de un experimento neurocientífico; también tiene grandes posibilidades en la exploración semi-automática de nuevos paradigmas neurofisiológicos [29].

Ahora bien, un clasificador es una función que permite particionar un conjunto de objetos en clases, por ejemplo, grabaciones de la actividad cerebral durante estímulos visuales particulares, intenciones de movimiento, estímulos auditivos singulares o procesos cognitivos inducidos. Entonces, basado en un conjunto de observaciones, la tarea del clasificador es encontrar una regla que permita asignar una observación \mathbf{x} a una de muchas clases. Aquí \mathbf{x} denota un vector de N -dimensiones del dato de EEG tomado. El caso más simple es el problema en donde solo existen dos clases (problema binario), en las interfaces BCI puede ser el problema de comunicación en donde al usuario se le muestran múltiples opciones una a una y él escoge mediante una señal de “sí” o una señal de “no” la que considera correcta, este señalamiento a menudo utiliza realimentaciones visuales como cuadros o cursores [30]. Para este caso el clasificador puede ser formalizado como una función de decisión $f : \mathcal{X}^N \rightarrow \{-1, +1\}$ tomada de una función de clase F , que asigna una observación \mathbf{x} a una de las clases denotada por -1 y 1 , respectivamente. Típicamente, el conjunto de posibles funciones de decisión f es parametrizado por el investigador, por ejemplo para el caso

de una función de decisión lineal, el elemento separador de las clases es un hiperplano que es parametrizado por su vector normal w y su término bias w_0 (también llamado tendencia). Para problemas de clasificación se realizan predicciones de etiquetas discretas de clases, o de manera general probabilidades posteriores que se encuentran en el rango $(0,1)$ [31]. Finalmente la etiqueta y es predecida a través de:

$$y(x) = f(w^T x + w_0) \quad (2.1)$$

Entonces basado en un conjunto de relaciones observadas de entrada-salida $(x_1, y_1), \dots, (x_n, y_n) \in \mathfrak{R}^N \times \{-1, +1\}$, el aprendizaje puede ser descrito formalmente como la tarea de seleccionar el valor de los parámetros (w, w_0) y por lo tanto seleccionar la función $f \in F$ tal que f debe clasificar correctamente muestras desconocidas \mathbf{x} . Aquí los datos observados (x_i, y_i) se supone que son independiente e idénticamente distribuidos (i.i.d.) de acuerdo a una distribución desconocida $P(x, y)$ que refleja la relación entre los objetos \mathbf{x} y las etiquetas de las clases \mathbf{x} , por ejemplo, entre la actividad cerebral grabada y el paradigma de estados mentales abordado para el problema. Sin embargo en orden de encontrar una función de decisión óptima se necesita especificar una función de pérdida adecuada, también llamada función de costo, que es una medida global de la pérdida sufrida en la toma de cualquiera de las decisiones o acciones disponibles. Las muestras de ensayo se supone que son generadas a través de la misma función de probabilidad $P(x, y)$, como las muestras de entrenamiento. En ese orden de ideas, dada una función de pérdida, la mejor función de decisión f que se puede obtener es aquella que minimice el riesgo esperado (también llamado error de generalización) [29].

$$R[f] = \int l(f(x), y) dP(x, y) \quad (2.2)$$

donde l denota una adecuada función de pérdida escogida [32]. Ahora bien, desafortunadamente el riesgo no puede ser minimizado directamente ya que la distribución de probabilidad $P(x, y)$ es desconocida. Entonces, se busca estimar la función que esté cerca a la óptima basado en la información disponible. Para este fin se necesita lo que llaman un principio de inducción; uno en particular consiste en aproximar el mínimo del riesgo (2) por el mínimo del riesgo empírico, así:

$$R_{emp}[f] = \frac{1}{k} \sum_{k=1}^k l(f(x_k), y_k) \quad (2.3)$$

Es posible dar condiciones sobre el aprendizaje de máquina que aseguren asintóticamente (cuando $k \rightarrow \infty$) que el riesgo empírico convergerá hacia el riesgo esperado. Sin embargo, para pequeños tamaños de muestras con grandes desviaciones es posible que un sobreajuste (overfitting) ocurra (ver figura 2.5).

Entonces, una generalización del error no puede ser obtenida mediante la simple minimización del

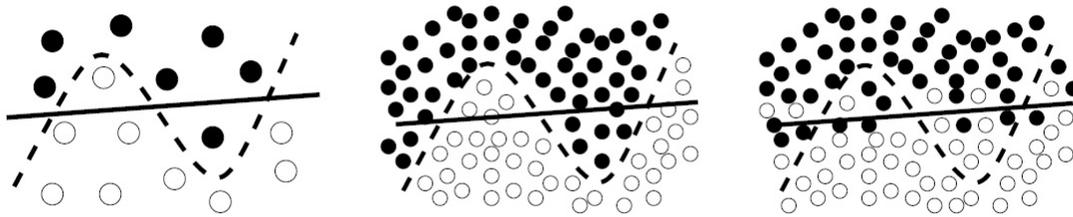


Figura 2.1. Ilustración del dilema del sobreajuste. Si bien, dado solo un pequeño conjunto de muestras (izquierda), las hipótesis de línea sólida o la discontinua son ciertas, la discontinua es más compleja y tiene un menor error de entrenamiento. Solo con una mayor cantidad de muestras es posible ver cuál distribución se ajusta más. Si la hipótesis de la línea discontinua es cierta, la sólida deberá estar sobre ajustada (medio); si la sólida fuera la correcta, la hipótesis de la línea discontinua deberá estarlo (derecha).

error de entrenamiento. Una forma de evitar el dilema del sobreajuste es restringir la complejidad de una función de clase F de donde se escoge la función f a esto comúnmente se le llama regularización. Una función simple (ejemplo: lineal) parece ser más efectiva que las funciones complejas en las aplicaciones de los sistemas BCI; en una sección posterior se explicará al detalle esta aseveración. Todos estos conceptos plantean el problema de la selección del modelo, es decir, como encontrar la complejidad óptima de la función [33].

2.2. Configuración del entrenamiento de máquina para los sistemas BCI-EEG

Para la fase de entrenamiento de los sistemas BCI, se tienen $k = 1 \dots N$, muestras denotadas como x_k , donde \mathbf{x} es un flujo continuo de EEG de n -dimensiones dependiendo del tipo de sensor. Al sujeto se le pide realizar tareas mentales individuales claramente establecidas como imaginarse un movimiento de alguna extremidad o mantener la atención puesta en mover un elemento en una pantalla. Esto permite asociar los vectores de EEG x_k con su respectiva etiqueta de clase para los determinados estados mentales como estrategia inicial para el aprendizaje. Este tipo de aprendizaje es conocido como aprendizaje supervisado y se define como el tipo de aplicaciones en donde los datos de entrenamiento contienen ejemplos de los vectores de entrada junto con su correspondiente vector de etiquetas [31]. Este proceso de asociación es necesario en las aplicaciones con sistemas BCI ya que este tipo de interfaces no pueden leer la mente o descifrar pensamientos generales; una BCI solo puede detectar y clasificar patrones específicos de las señales cerebrales asociadas a tareas o eventos específicos. Lo que el usuario BCI debe de hacer para producir estos patrones se determina mediante la estrategia mental (llamada también estrategia experimental o enfoque) que la interfaz empleará. Esta estrategia mental determina lo que el usuario debe hacer voluntariamente

para producir los patrones cerebrales que el sistema BCI puede interpretar; también establece ciertas restricciones sobre el hardware y el software BCI como las técnicas de procesamiento de señal a emplear. Las estrategias mentales más comunes según [3] son la de atención selectiva o focalizada y la de imaginación motora.

2.2.1. Atención Selectiva

Este tipo de estrategia mental requiere estímulos externos de diferentes tipos, auditivos o somatosensitivos; sin embargo los estímulos externos más usados en los sistemas BCI son los visuales, a lo que usualmente se le conoce como atención visual. Los estímulos pueden ser de diferentes tonos, diferentes simulaciones táctiles o luces intermitentes con diferentes frecuencias. En una configuración típica de una aplicación con un sistema BCI, cada estímulo es asociado con un comando que controla una acción específica. En orden de seleccionar un comando, el usuario tiene que focalizar su atención en el correspondiente estímulo generando la intención mental. Consideremos un ejemplo de un sistema BCI para una aplicación de navegación/selección, en la cual se requiere mover un cursor en una pantalla de un computador y luego realizar un proceso de selección. Un sistema BCI basado en atención selectiva podría contar con 5 tareas mentales (5 clases): 4 para los movimientos de izquierda, derecha, arriba y abajo y uno más para la acción de selección. Este sistema podría permitir una navegación bidimensional de un objeto en la pantalla y un evento más relacionado a la intención de selección, el usuario operaría esta interfaz mediante la focalización de su atención en el estímulo que ha sido asociado con el comando de intención o ítem deseado. Los ítems pueden representar una amplia variedad de mensajes o comandos deseados, como letras, palabras o instrucciones para mover un robot. La atención selectiva que utiliza estímulos visuales a menudo es llamada atención visual y puede ser implementada con dos enfoques diferentes dentro de los sistemas BCI: el primero utiliza los potenciales P300 [34] como una medición de la función cognitiva de los procesos de toma de decisiones. Suele desarrollarse en la zona centro-parietal cerca del electrodo Pz unos 300 ms después de la detección del estímulo visual, el cual generalmente es mostrado de manera sucesiva a una frecuencia establecida (como letras o números parpadeando en una pantalla). La segunda implementación utiliza el Potencial de Estado Estacionario Evocado Visualmente (SSVEP por sus siglas en inglés) para realizar el procesos de detección, aquí los estímulos visuales son asociados con un comando específico el cual es asociado a su vez a una salida que produce el sistema BCI. En contraste con el enfoque P300, estos estímulos no se muestran sucesivamente sino que parpadean continuamente en un rango de frecuencia establecido de 6 Hz a 30 Hz; enfocar la atención a uno de estos estímulos parpadeantes provoca un SSVEP en la corteza visual que tiene la misma frecuencia que el parpadeo objetivo; o sea, si el estímulo objetivo parpadea a 16 Hz, el SSVEP resultante será identificado en la señal EEG de entrada a una frecuencia de 16 Hz, entonces la interfaz puede determinar cual estímulo ocupó la atención del usuario mediante la búsqueda de actividad SSVEP en la corteza visual

en una frecuencia específica. Después de recolectar el suficiente número de muestras, el enfoque del aprendizaje de máquina permite aprender de un complejo mapeo desconocido f entre x_k y y_k mediante la deducción de los patrones típicos de EEG cuando se generan los procesos o tareas mentales de un sujeto en particular. Teóricamente, este mapeo puede ser aprendido usando sólo los datos recolectados del electroencefalograma; sin embargo el proceso de extracción de características es más eficiente cuando hay conocimientos fisiológicos a priori. Por ejemplo para el caso de la imaginación motora se conocen características útiles discriminantes como los valores de potenciales localizados en las áreas motoras relacionadas en el cerebro [28]. Con ayuda de las modernas técnicas de aprendizaje de máquina desarrolladas, los sistemas BCI necesitan solo entre 50 y 150 muestras para alcanzar exactitudes admisibles para las diferentes aplicaciones.

Aunque muchas aplicaciones de los sistemas BCI son basados en SSVEP con un número de clases que varía entre dos y ocho, estudios recientes [34] han probado que usando atención selectiva en un solo patrón visual predefinido es suficiente para un control óptimo. Nuevos métodos de control en la neuro-robótica están siendo implementados usando técnicas de atención selectiva programadas en humanoides, en donde suele primar la selección de objetos dentro de una escena mediante mecanismos de selección visual artificialmente creados [35]. Un inconveniente que suelen tener los sistemas BCI que acogen esta estrategia mental con cualquiera de los dos enfoques (P300 ó SSVEP) es que usualmente los estímulos visuales requieren que el usuario cambie la mirada o vire su cabeza constantemente, esto limitaría su uso en pacientes totalmente paralizados como los que sufren esclerosis lateral amiotrófica (ELA). Otro problema típico es que los usuarios suelen tener aversión a los estímulos externos que tienen que ser aplicados para trabajar con atención selectiva.

2.2.2. Imaginación Motora (MI)

Mover algún miembro o incluso la contracción de algún músculo cambia la actividad cerebral en la corteza. Hasta una erección involuntaria del pene en estados somnolientos genera una desincronización del EEG [36]. En efecto, la preparación del movimiento o la imaginación del movimiento cambian los llamados ritmos sensoriomotores (SMR) [3]. Estos ritmos son oscilaciones en la actividad cerebral grabados desde las áreas motora y somatosensorial. Las oscilaciones cerebrales son típicamente categorizadas de acuerdo a un conjunto de bandas específicas de frecuencia que son nombradas con letras griegas (delta: < 4 Hz, theta: 4-7 Hz, alfa: 8-12 Hz, beta: 12-30 Hz, gama: > 30 Hz). El decremento de la actividad oscilatoria en una banda específica de frecuencia es llamado una Desincronización Relacionada a un Evento (ERD por sus siglas en inglés). De manera recíproca, el incremento de la actividad oscilatoria en una banda específica de frecuencia es llamado una Sincronización Relacionada a un Evento (ERS por sus siglas en inglés). Los patrones ERS y los ERD pueden ser voluntariamente producidos mediante imaginación motora; la cual es la imaginación de movimiento sin realizarlo físicamente. La actividad alfa obtenida en las áreas sensoriomotoras es llamada la actividad mu y junto con la banda beta son

las señales EEG más importantes y más usadas en la imaginación motora. La actividad invocada por la imaginación de mover la mano derecha es más prominente sobre el electrodo C3; a su vez la de la mano izquierda es más prominente en el C4. Esto es, la actividad invocada por el movimiento de la mano, en forma general, está localizado sobre el lado opuesto al lateral (contralateral). A su vez, la imaginación de mover los pies invoca una actividad registrada sobre el electrodo Cz; la distinción entre el movimiento del pie derecho y el del izquierdo no es posible registrar usando EEG dado que las correspondientes áreas corticales están muy cerca (ver figura 2.2). De manera similar los patrones de los movimientos individuales de los dedos no pueden ser discriminados a través del EEG. Para producir patrones que puedan ser detectados, las áreas corticales implicadas tienen que ser lo suficientemente grandes para que la actividad resultante sea lo suficientemente prominente comparada con el ruido clásico de un EEG. El área de las manos, los pies y la lengua son comparativamente grandes y topográficamente diferentes. De aquí, que las interfaces BCI que utilizan como estrategia mental la imaginación motora, suelen ser controladas mediante la imaginación de mover la mano derecha, la mano izquierda, los pies y/o la lengua.

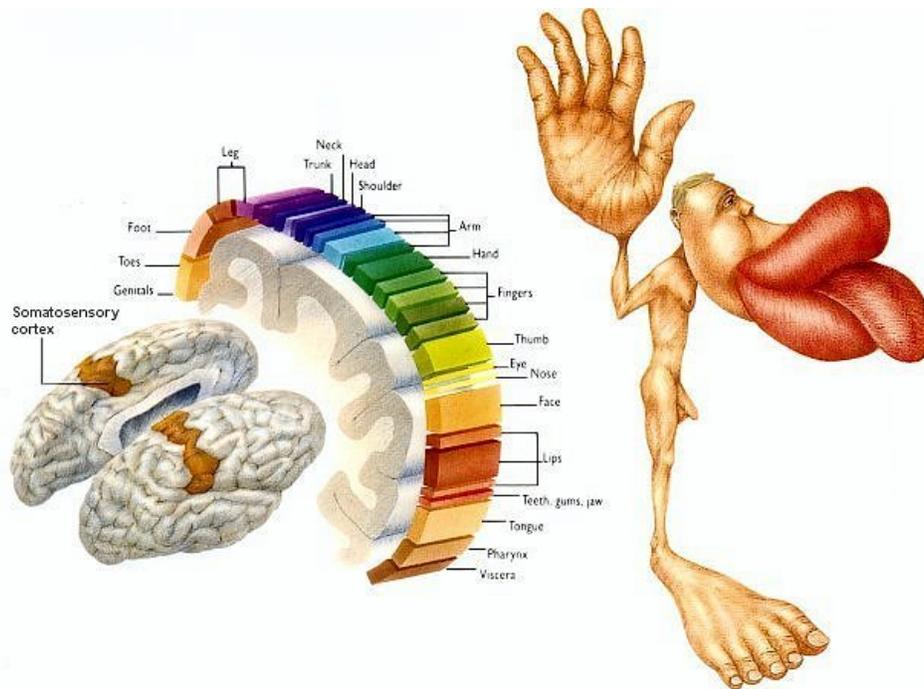


Figura 2.2. 1. Representación Homuncular de la corteza motora según Peinfeld.

Los patrones ERD/ERS producidos mediante imaginación motora son similares en su topografía y comportamiento espectral a los patrones provocados por los movimientos reales y dado que estos patrones son originados desde las áreas motoras y somatosensitivas, las cuales están directamente conectadas a la vías normales de salida neuromusculares, la imaginación motora es una estrategia mental particularmente adecuada para los sistemas BCI. La forma en que se implementa esta

estrategia para lograr un buen resultado suele variar, por ejemplo, algunas interfaces suelen decir si los usuarios están pensando en mover su mano izquierda, su mano derecha o sus pies. Esto puede ser usado en un sistema de control que tenga tres comandos de salida: uno para seleccionar, otro para moverse a la izquierda y el último para moverse a la derecha. Por ejemplo en [37], utilizan imaginación motora para pilotear un helicóptero dentro de un ambiente virtual bidimensional, para esto utilizan dos comandos provenientes de la imaginación del movimiento de la mano derecha e izquierda, de esta manera, el usuario hace girar el elemento virtual en tiempo real a través de esta estrategia mental. Otro tipo de imaginación motora en sistemas BCI se basa en tipos de movimientos específicos más abstractos para lograr una señal similar a las mencionadas. En el transcurso de muchas sesiones de entrenamiento con sistemas BCI, las personas pueden aprender y desarrollar su propia estrategia de imaginación motora según las necesidades, por ejemplo, en [38] utilizan 3 comandos para la navegación de un cuadricóptero; movimiento a la derecha, movimiento a la izquierda y un movimiento de empujar hacia el fondo. En este trabajo se destaca el uso de escalas en donde se mide el nivel de concentración de un usuario para una orden, por ejemplo, pensar en el movimiento a la derecha es dividido en “fuerte” y “débil” (pueden ser distinguidas en la forma de la señal), en donde cada una de ellas se usa como un comando diferente para la teleoperación del sistema aéreo. La cuantificación de este nivel de concentración en este caso, no es otra cosa que la similitud de la señal de entrenamiento con la señal generada en tiempo real con la cual se pretende teleoperar el sistema robótico. En contraste con los sistemas BCI basados en atención selectiva, las interfaces basadas en imaginación motora no dependen de estímulos externos. Sin embargo, la imaginación motora es un tipo de habilidad que puede ser aprendida; comúnmente las aplicaciones BCI que utilizan esta estrategia no suelen trabajar bien durante las primeras sesiones y a diferencia de la atención selectiva, suelen ser necesarias varias sesiones de entrenamiento del usuario para lograr un rendimiento y control óptimo. Mientras el tiempo de funcionamiento y entrenamiento puede variar entre usuarios, la mayoría de los sujetos pueden alcanzar un buen control de un sistema de 2 clases con 1 a 4 horas de entrenamiento [3]. Sin embargo son necesarias muchas horas de entrenamiento para mantener un control estable sobre alguna aplicación o sobre algún sistema robótico y es aquí donde el entrenamiento se transforma en un componente trascendental en el diseño de aplicaciones con sistemas BCI. Los usuarios aprenden a través de un proceso llamado condicionamiento operante [8], el cual es un término fundamental en psicología, ya que en este estado las personas aprenden a asociar cierta acción con una respuesta o efecto; aquí el sujeto tiene más probabilidades de repetir las formas de conducta que conllevan a consecuencias positivas y menos probabilidades de repetir las que conllevan a consecuencias negativas. El aprendizaje BCI es un caso especial del condicionamiento operante porque el usuario no está realizando ninguna acción en el sentido clásico, o sea, él no se mueve. Sin embargo si las acciones imaginadas producen efectos o consecuencias, entonces el acondicionamiento puede ocurrir. Durante el uso de una aplicación BCI, el condicionamiento operante involucra un entrenamiento con realimentación que a menudo es presentada en una pantalla de un ordenador;

realimentaciones positivas indican que las señales cerebrales están siendo moduladas por el usuario en la forma deseada y viceversa. Este aprendizaje en las interfaces cerebro computador es un tipo de realimentación conocido como neuro-realimentación. La realimentación suele indicar si el usuario realizó la tarea mental bien o fallo en obtener el objetivo deseado a través del sistema BCI. Los usuarios pueden utilizar esta realimentación para optimizar sus tareas mentales y mejorar el rendimiento y la precisión de la aplicación. Aunque esta realimentación puede ser de tipo táctil o auditiva, la más común en los sistemas BCI es la visual. Muchos estudios se han llevado a cabo para investigar las bases neuronales de la imaginación motora y han logrado distinguir la imaginación motora de la imaginación mental puramente visual. Aunque la imaginación visual acompaña a menudo a la imaginación motora, los investigadores han documentado que la imaginación motora se basa en mecanismos cognitivos distintos. En un estudio referenciado en [39] se concluyó que es posible que las imágenes mentales de movimiento sean producidas en otra parte diferente del cerebro de donde se producen los movimientos reales (ejemplos en los lóbulos posteriores parietales), y que solo estén siendo ejecutados allí. En resumen, la imaginación mental puede comprometer el sistema motor; estos hallazgos ayudan a explicar porque la práctica mental puede mejorar el rendimiento actual de los sistemas BCI que utilizan la estrategia de imaginación motora.

Finalmente, después de escoger la estrategia mental adecuada para la aplicación deseada se procede a realizar la captura de datos EEG a través del sistema BCI. Posteriormente se pasa a la etapa de preprocesamiento de la señal (descrita en el capítulo anterior) en la cual se simplifica la etapa de procesamiento sin perder información relevante de los datos capturados. El siguiente bloque en el esquema de una aplicación BCI es el de extracción de características el cuál será descrito a continuación.

2.3. Extracción de Características

En la etapa de procesamiento de una señal es fundamental realizar, en algún momento, un reconocimiento de patrones. Aquí un patrón es una descripción estructural o cuantitativa de un objeto o de alguna otra entidad de interés en una señal y está formado por uno o más descriptores. En otras palabras, un patrón es una disposición de descriptores o características. La observación de tareas particulares (como imaginarse el movimiento de la mano) genera en los sistemas BCI un particular efecto específico en las señales cerebrales (los ERS/ERD) medidos en una ubicación en particular. Aunque estos fenómenos cognitivos han sido ampliamente estudiados y a pesar que para la aplicación BCI se considere una sola posible señal fisiológica (como los ritmos μ); la imaginación, las tareas, las mejores frecuencias y las mejores localizaciones tendrán que ser seleccionadas para cada individuo [40]. Esta aleatoriedad entre las señales es uno de los aspectos que más limitan el procesamiento de las señales de EEG de las interfaces. A continuación se muestran la figura 2.3 en donde se evidencia no solo la aleatoriedad entre las señales obtenidas

de diferentes individuos, sino también, las obtenidas a partir del mismo sujeto

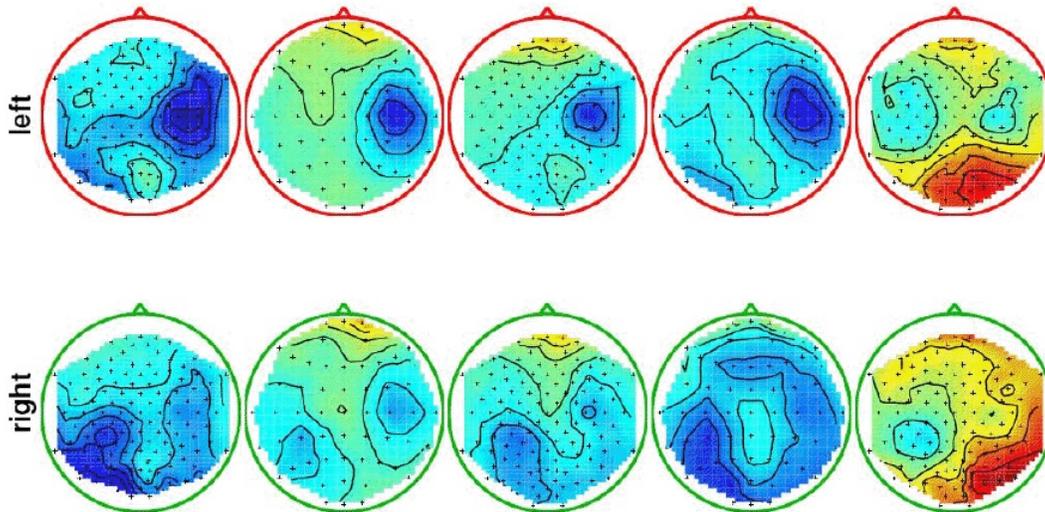


Figura 2.3. En este experimento se le pidió a un sujeto en diferentes momentos de un día que imaginara el movimiento de su mano derecha versus el de su mano izquierda. Fueron grabadas las bandas alfa durante 3.5 segundos y se recolectaron las muestras.

En la figura 2.4 fueron superpuestos los mapas de la actividad cerebral registrada por varios individuos cuando se les pedía que imaginaran el movimiento de su mano derecha versus el de su mano izquierda. La varianza de los datos, a pesar de que la intención de movimiento era la misma para cada persona, muestra la compleja dinámica a la que se enfrentan las técnicas de reconocimiento de patrones de los sistemas BCI.

Las variaciones de las propiedades de la señal sobre el tiempo, es decir, las no estacionarias, pueden surgir de muchas fuentes y tienen diferentes escalas de tiempo, por ejemplo cambios en la impedancia ocurren cuando un electrodo pierde el contacto con la piel o la conducción se deteriora, la actividad muscular o los movimientos de los ojos producen artefactos en la señal y a menudo se observa un decremento en la atención a la tarea propuesta y se generan cambios en la actividad de fondo por fatiga o cansancio y falta de concentración. Adicionalmente cambios en la señal EEG registrados pueden ser causados por diferencias entre sesiones, falta de realimentación en las sesiones de calibración o pequeñas diferencias entre las posiciones de los electros entre sesiones [41]. Los resultados de todas estas variaciones son una distribución de características o un vector de características que cambia con el tiempo. Una potente y muy usada técnica para el procesamiento y la extracción de características de las señales EEG para sistemas BCI es la de Patrones Espaciales Comunes (CSP por sus siglas en inglés). A lo largo del desarrollo de los sistemas BCI y en el marco de una famosa competencia en entrenamiento de máquina para los sistemas BCI (BCI Competition), el análisis de la señal por CSP y sus variantes han demostrado ser una herramienta robusta para explotar los efectos de las ERD/ERS dentro y fuera de la competencia estándar de clasificación. En

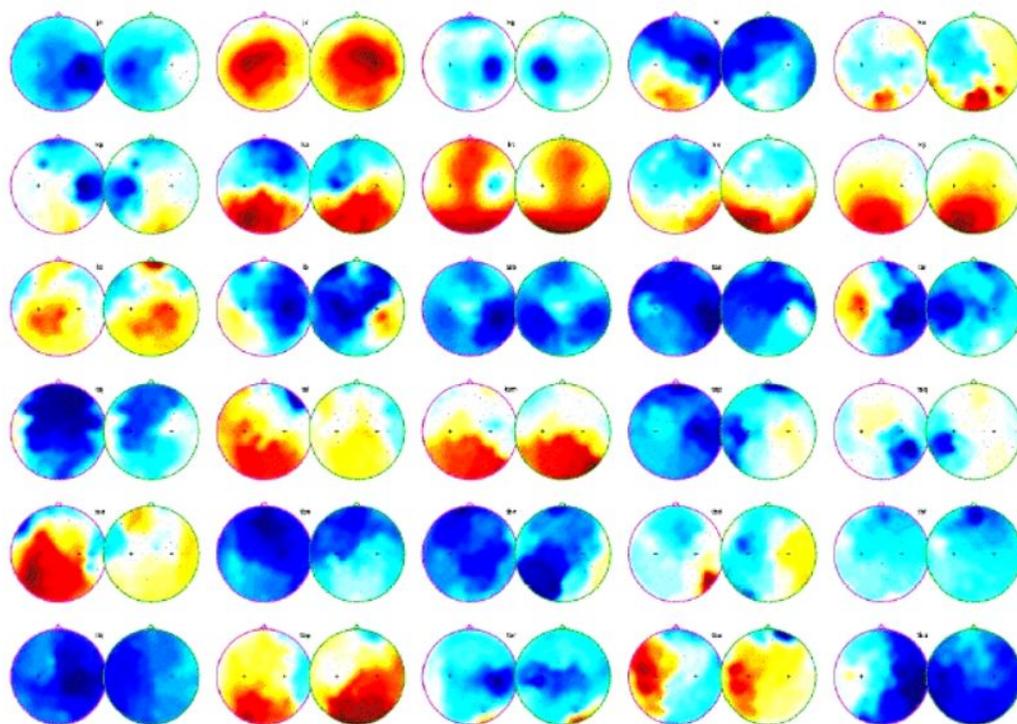


Figura 2.4. Variabilidad inter-sujetos registrada en las señales EEG con la misma intención motora (Mover la mano derecha vs. Mover la mano izquierda).

contraste a esta técnica, la aplicación del Análisis de Componentes Principales (PCA por sus siglas en inglés) y el Análisis de Componentes Independientes (ICA por sus siglas en inglés) que han sido métodos de preprocesamiento exitosamente usados en otros campos; se han notado menos efectivas para mejorar el rendimiento de la clasificación en los sistemas BCI [42]. El avance del análisis CSP comparado con el PCA y el ICA puede en gran parte ser explicado por las diferentes estrategias concernientes al uso de las etiquetas de clase. Mientras el análisis por CSP explota la información que contienen las etiquetas de una manera supervisada, ICA y PCA son métodos no supervisados. A continuación, se explicarán brevemente estos 3 métodos de procesamiento de la señal EEG para sistemas BCI debido a su trascendencia soportada en la bibliografía referenciada.

2.3.1. Análisis por Patrones Espaciales Comunes (CSP)

El análisis por CSP produce filtros espaciales que son óptimos en cuanto a que extraen las señales que son más discriminantes entre dos condiciones. La técnica de CSP permite la identificación de los filtros espaciales que maximizan la varianza de las señales de una condición y al mismo tiempo minimiza la varianza de la señal con la otra condición. Este método ayuda a distinguir entre dos estados basados en imaginación motora (por ejemplo mover la mano derecha vs. la izquierda; mover la mano derecha vs. ambos pies) comúnmente llamados clases. En contraste con PCA, el cual maximiza la varianza del primer componente en el espacio transformado, CSP maximiza la relación entre las varianzas de las dos condiciones o clases. Esta propiedad hace que el análisis por CSP sea uno de los filtros espaciales más efectivos para el procesamiento de las señales de las BCI basadas en EEG ya que permite que las intenciones de los usuarios estén codificadas en la varianza o la potencia de la señal cerebral asociada; técnicamente el algoritmo de los CSP otorga unos filtros espaciales basados en un criterio discriminativo [43]. El algoritmo CSP requiere no solo el entrenamiento de las muestras sino también la información de la clase a la que pertenecen las muestras para calcular la matriz de transformación lineal (entrenamiento supervisado); en contraste con PCA e ICA que no requieren de este tipo de información.

Ahora bien, el algoritmo CSP calcula una matriz W con filtros espaciales de altas varianzas para la primera clase y con bajas varianzas para la segunda, y viceversa. Se asume que $W \in \mathcal{R}^{n \times m}$ es una matriz de transformación de CSP. Entonces las señales transformadas son WX , donde X es la matriz de datos en la cual cada columna representa un canal del EEG o la señal de un electrodo en particular. El primer componente CSP, es decir, la primera fila de la matriz WX contiene más varianza de la clase 1 (y menos de la clase 2) mientras que el último vector fila, es decir, el último componente de la matriz WX contiene más varianza de la clase 2 (y menos de la clase 1). La interpretación de W tiene dos enfoques: las filas pueden ser vistas como los filtros espaciales estacionarios, mientras que las columnas de W^{-1} pueden ser vistas como los patrones espaciales comunes, es decir, la distribución de vectores invariantes en el tiempo de la señal EEG. Cada valor

propio indica la importancia del correspondiente filtro para la tarea de discriminación [44]. Como los valores de las columnas representan la contribución de los componentes CSP a los canales, estos pueden ser usados para visualizar una distribución topográfica de los componentes de los CSP. La figura 2.5 muestra dos patrones espaciales comunes provenientes de una señal EEG usando la estrategia mental de imaginación motora en tareas de movimiento de la mano izquierda y derecha, las cuales corresponden a la primera y a la última columna de W^{-1} respectivamente. La imaginación motora de la mano izquierda induce patrones de actividad sensoriomotora (ERD/ERS) sobre las áreas sensoriomotoras del lado derecho del cerebro y viceversa.

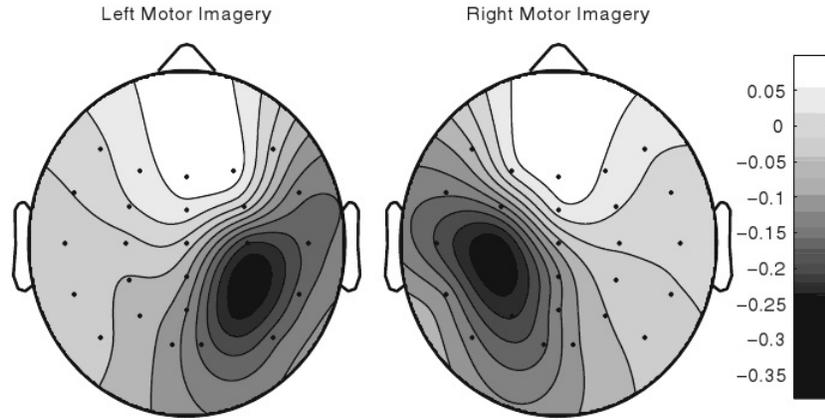


Figura 2.5. Dos patrones espaciales comunes (CSP) de un ejemplo correspondiente a tareas de imaginación motora de izquierda y derecha.

Ahora, CSP y PCA son métodos de extracción de características basados en la diagonalización de las matrices de covarianza, sin embargo, el PCA diagonaliza una matriz de covarianza, mientras que CSP diagonaliza las dos matrices R_1 y R_2 simultáneamente. Resolver el problema de los valores propios es suficiente en el método de PCA; mientras que para el análisis por CSP, la generalización del problema de los valores propios con $R_1^{-1}R^1$ ha sido resuelto para dar la matriz de transformación que simultáneamente diagonaliza las dos matrices de covarianza según las siguientes ecuaciones:

$$WR_1W^T = D \quad (2.4)$$

$$WR_2W^T = I - D \quad (2.5)$$

En este caso D es una matriz diagonal con elementos monótonamente descendientes. I es la matriz identidad, la matriz W tiene dimensiones de $M \times N$ donde M es el rango de la covarianza y N el número de canales. Aunque la forma básica del algoritmo de CSP está hecho para un problema con dos clases, algunos autores han planteado su extensión para problemas multi-clase; en donde son necesarios, por ejemplo, la identificación de más de dos comandos a través de sistemas BCI en particular [45]. Para otros detalles del algoritmo, consultar [46].

2.3.2. Análisis de Componentes Principales (PCA)

Las técnicas de PCA e ICA son métodos de preprocesamiento para separar las señales cerebrales en componentes. Algunos de estos componentes son de interés, como los patrones cerebrales asociados con la estrategia de imaginación motora implementada; sin embargo, hay algunos otros componentes remanentes como el ruido, que no son de interés. Por lo tanto, PCA e ICA son métodos usados a menudo para separar componentes útiles del ruido en una señal. Dado que las señales de los canales EEG tienden a estar altamente correlacionados, el PCA puede ser útil para localizar y mejorar cierta actividad cerebral, particularmente cuando la varianza de la amplitud está correlacionada con las tareas BCI propuestas [47]. Matemáticamente, el PCA realiza una transformación lineal ortogonal a un nuevo sistema de coordenadas (llamado eigenspace) tal que las señales originales son descompuestas en componentes no relacionados los cuales son ordenados descendientemente de acuerdo a su varianza (el primero el de mayor varianza, el último el de menor). Ahora, $X \in \mathcal{R}^{n \times m}$ es la matriz de la señal EEG adquirida en la que cada fila corresponde a la señal de cada electrodo con media cero, y cada columna corresponde a la señal con tiempo de muestreo específico; la transformación de la matriz PCA $W = [w_1, \dots, w_n]$ puede ser obtenida realizando una descomposición general de valores propios de la matriz de covarianza $R = XX^T$ que corresponde a n diferentes valores propios $\lambda_1, \dots, \lambda_n$ en orden descendente. La transformación PCA es dada por:

$$Y = W^T X \quad (2.6)$$

donde $W = [w_1, \dots, w_n]$. El resultado de la señal transformada mediante PCA Y es que las columnas están no-correlacionadas unas con otras; por lo tanto, matemáticamente el PCA utiliza las “incorrelación” de la señal de entrada X . En orden de extraer los componentes que contienen la mayor parte de la varianza de la señal, son seleccionados los p vectores columna dominantes de la matriz de transformación W . Estos son los vectores propios asociados con los p valores propios más grandes. En este sentido, los p componentes principales corresponden a los p valores propios más grandes que se mantienen, mientras que los $n-p$ unos corresponden a los $n-p$ valores propios más pequeños que son ignorados. Estos valores propios representan la varianza de la potencia de la señal cerebral, y así los valores propios más grandes corresponden a los componentes útiles, mientras que el resto corresponde a los componentes del ruido [3]. Una de las desventajas de la discriminación de diferentes tipos de actividad cerebral por medio del algoritmo PCA es que ya que no se tiene información a priori acerca de las tareas BCI que pueda ser usada para derivar la matriz de pesos W , las señales resultantes cuentan con una gran amplitud en su varianza que no pueden ser correlacionadas con las tareas mentales impuestas. Debido a esto, si por ejemplo, todas las señales originales de los electrodos son corrompidas con una línea de ruido de 60 Hz comparado con la señal EEG normal, lo más probable es que esta señal ruidosa de 60 Hz aparezca como una de las primeras componentes PCA a pesar de que esta sea independiente de cualquier condición

o tarea BCI. Así entonces, el inconveniente con el PCA es que la señal de un electrodo que sea comparativamente baja y que esté altamente correlacionada con algún estado mental, puede no ser incluida en el top del conjunto de componentes principales del algoritmo [47].

Finalmente, la idea central del análisis con PCA es reducir la dimensionalidad de un conjunto de datos que consta de un gran número de variables interrelacionadas, manteniendo al mismo tiempo tanto como sea posible la variación presente en el conjunto de datos; esto se consigue mediante la transformación de un nuevo conjunto de variables, las componentes principales, los cuales son incorrelacionados y ordenados de manera que los pocos primeros conservan más la variación presente en todas las variables originales [48].

2.3.3. Análisis de Componentes Independientes (ICA)

Aunque los canales resultantes del análisis con el algoritmo PCA son incorrelacionados, estos no necesariamente son estadísticamente independientes. Para ser estadísticamente independientes, la función de distribución de probabilidad conjunta $F_{XY}(x, y) = P[X \leq x, Y \leq y]$ de los canales x e y deben satisfacer lo siguiente:

$$F_{XY}(x, y) = F_X(x)F_Y(y) \quad (2.7)$$

En contraste, para ser incorrelacionados, el valor esperado de los canales deberán satisfacer lo siguiente:

$$E\{XY\} = E\{X\}E\{Y\} \quad (2.8)$$

Así entonces, la independencia es una limitación más estricta sobre la relación estadística entre canales incorrelacionados. Asumiendo que las fuentes particulares de la actividad cerebral son localizadas y funcionan independientemente; la identificación de un filtro espacial que produzca canales independientes es importante porque esto es en teoría más probable que la identificación de los canales sensibles a las diferentes fuentes generadoras de la señal dentro del cerebro [47]. El ICA busca determinar la matriz de peso W que produce los canales independientes en Y . Dado que los pesos resultantes espaciales tienden a corresponder a una actividad localizada, este proceso puede también ser entendido como una forma de separación de la fuente o localización de la fuente. Como con PCA, una aplicación podría usar sólo los componentes ICA más relevantes (es decir, los canales que se correlacionan bien con la tarea mental) en orden de reducir la dimensionalidad. Comúnmente el número de señales diferentes mezcladas en un simple conjunto de muestras EEG es igual al número de electrodos del sistema aún cuando el número de fuentes suele ser típicamente menor [49]. ICA es un enfoque común para resolver el problema de la separación ciega de fuentes que puede ser explicado con el “clásico efecto de coctel de fiesta” en donde mucha gente habla simultáneamente en un cuarto pero una persona tiene que prestarle atención solo a una de las dis-

cusiones. Los humanos pueden fácilmente separar estas señales de audio mezcladas, pero esta tarea resulta muy desafiante para una máquina. Sin embargo, bajo algunas limitaciones muy estrictas, este problema puede ser resuelto por ICA. Figurativamente, las señales cerebrales son similares al efecto de coctel de fiesta porque la señal medida de un electrodo en particular puede ser generada desde muchas neuronas. Las señales de estas neuronas son mezcladas y llegan a un electrodo en particular; por tanto las fuentes cerebrales actuales y el procedimiento de mezcla son desconocidos. Matemáticamente, asumiendo que hay n fuentes desconocidas mutuamente independientes $s_1(t), \dots, s_n(t)$ en las señales del cerebro denotadas como $s(t) = [s_1(t), \dots, s_n(t)]^T$ con media cero, y asumiendo allí n electrodos tales que las fuentes son instantáneamente y linealmente mezcladas para producir las n mezclas observables $x(t) = [x_1(t), \dots, x_n(t)]^T$, entonces:

$$x(t) = As(t) \quad (2.9)$$

Donde A es una matriz invariante en el tiempo de dimensiones $n \times n$ cuyos elementos necesitan ser estimados a partir de los datos de observación. A es llamada la matriz de mezcla, la cual es a menudo asumida como una matriz de rango completo con n columnas linealmente independientes. El método del ICA también asume que los componentes s_i generados por diferentes neuronas son independientes uno del otro. ICA calcula la matriz de “desmezcla” W usando las señales observadas n para obtener n componentes independientes así:

$$y(t) = Wx(t) \quad (2.10)$$

donde los componentes independientes estimados son y_1, \dots, y_n denotados como $y(t) = [y_1(t), \dots, y_n(t)]^T$. Después de descomponer las señales cerebrales usando ICA, los componentes relevantes pueden entonces ser seleccionados, o sus equivalentes irrelevantes pueden ser removidos y entonces proyectados de nuevo en el espacio de la señal usando:

$$\mathbf{x}(t) = W^{-1}y(t) \quad (2.11)$$

La señal reconstruida \mathbf{x} representa la señal limpia de x . De muchas formas, el ICA es idealmente adecuado para ser usado en datos EEG dado que existe una cantidad despreciable de retardo de transmisión entra la señal de cada electrodo fuente y porque el supuesto de que cada señal medida es una mezcla lineal de señales fuente es bastante plausible para las señales eléctricas que viajan a través del tejido humano. Por otra parte, la inversa de la matriz de “desmezcla” brinda un mapa espacial del cuero cabelludo asociado a la localización de cada señal fuente extraída mediante el ICA. Los ICA son ampliamente usados para el reconocimiento de ERP/ERD. En [50] utilizan el ICA en la extracción de eventos relacionados a la onda P300 y en [51] utilizan el ICA no lineal para la extracción de características a través de la estrategia de imaginación motora. Existen muchos algoritmos ICA que han sido implementados por diferentes investigadores alrededor del mundo, un

análisis matemático más profundo se encuentra en [49] en donde se describe ampliamente el uso de esta técnica no solo en señales EEG. Otra técnica de separación de fuentes usada en datos de EEG es el llamado Análisis de Componentes Esparcidos (SCA por sus siglas en inglés) y asume por ejemplo, que el número de componentes de la fuente es más grande que el número de mezclas observadas y los componentes pueden ser independientes uno del otro. A continuación serán explicados los clasificadores más usados en los sistemas BCI, con lo cual se podrá establecer una guía para la escogencia del clasificador que será usado en la presente tesis.

2.4. Tipología de Clasificadores

El conocimiento acerca del proceso emocional del cerebro ayuda entender la influencia que las emociones tienen en la actividad cerebral en general y por tanto, también sobre la actividad cerebral que puede ser medida a través de EEG; así este conocimiento puede ser usado para optimizar el entrenamiento o tener una adaptación emocional en línea para el algoritmo de clasificación [52]. Los patrones de actividad cerebral se consideran como procesos estocásticos debido tanto a la diversidad biológica de las señales como a los factores técnicos que rodean su proceso de adquisición. Dentro de lo que se puede llamar una taxonomía de los clasificadores [27] encontramos los generativos o informativos (ejemplo Bayes Cuadrático), los cuales para clasificar un vector de características calculan la verosimilitud de cada clase y escogen la más probable. Dentro de los llamados discriminativos suelen destacarse las Máquinas de Soporte Vectorial (SVM por sus siglas en inglés), las cuales sólo aprenden la manera de discriminar las clases o la pertenencia a una clase en orden de clasificar el vector de características directamente. Los clasificadores estáticos (ejemplo Perceptrones Multicapa), no pueden tener en cuenta la información temporal durante la clasificación, ya que ellos clasifican un solo vector de características. Por el contrario, los clasificadores dinámicos (ejemplo Cadenas Ocultas de Markov- HMM) pueden clasificar una secuencia de vectores característica y entonces, pueden trabajar con las dinámicas temporales de los datos, por ejemplo, estos clasificadores pueden extraer características de diversos segmentos temporales de la señal adquirida para construir una secuencia temporal de los vectores de características. Los clasificadores estables (ejemplo Análisis Discriminante Lineal- LDA) tienen una baja complejidad o capacidad. Son llamados estables dado que pequeñas variaciones en el conjunto de entrenamiento no afectan considerablemente su rendimiento. Contrariamente, los clasificadores inestables (ejemplo el Perceptrón Multicapa), tienen una alta complejidad y, a menudo, pequeñas variaciones del conjunto de entrenamiento puede ocasionar importantes cambios en su rendimiento. Por último, cabe recordar que la regularización consiste en el control cuidadoso de la complejidad de un clasificador en orden de prevenir el sobre entrenamiento; de esta manera, un clasificador regularizado actúa bien en las generalizaciones y es más robusto con respecto a los outliers. Ahora bien, existen dos problemas ampliamente reconocidos en la tarea de clasificación de los sistemas BCI que utilizan señales EEG [53]: el primero se relaciona con la llamada

maldición de la dimensionalidad [31] la cual afirma que la cantidad de datos necesarios para describir adecuadamente las clases, aumenta exponencialmente con la dimensionalidad del vector de características, o sea, la dificultad del problema de estimación incrementa drásticamente con la dimensión del espacio. Realmente, si el número de muestras de entrenamiento es pequeño comparado con el tamaño del vector de características, es muy probable que el clasificador arroje malos resultados. Es recomendable usar, al menos, de 5 a 10 veces más muestras de entrenamiento por clase, como la dimensionalidad del vector de características (n características numéricas). Desafortunadamente esto no puede ser aplicado en todos los sistemas BCI en general, ya que la dimensionalidad es alta y el conjunto de entrenamiento es pequeño; por tanto, esta “maldición” es una preocupación importante para el diseño de aplicaciones con interfaces cerebro computador. El segundo problema que se presenta en la tarea de clasificación es la desventaja de la relación entre el término bias y la varianza: formalmente, la clasificación consiste en encontrar la etiqueta verdadera y^* de un vector de características \mathbf{x} mediante una asignación f . Esta asignación (comúnmente llamada mapeo) es aprendida de un conjunto de entrenamiento T . El mejor mapeo f^* que ha generado las etiquetas es, por supuesto, desconocido. Si consideramos el Error por Mínimos Cuadrados (MSE por sus siglas en inglés), los errores de clasificación pueden ser descompuestos en 3 términos:

$$MSE = E[(y^* - f(x))^2] = E[(y^* - f^*(x) + f^*(x) - E[f(x)] + E[f(x)] - f(x))^2] \quad (2.12)$$

$$= E[(y^* - f^*(x))^2] + E[(f^*(x) - E[f(x)])^2] + E[(E[f(x)] - f(x))^2] \quad (2.13)$$

$$= \text{Ruido}^2 + \text{Bias}(f(x))^2 + \text{Var}(f(x)) \quad (2.14)$$

Estos tres términos describen tres posibles fuentes del error inherente de clasificación.

- Ruido: representa el irreducible ruido dentro del sistema.
- Bias o tendencia: representa un error sistemático el cual evidencia la divergencia entre el mapeo estimado (es decir la etiqueta de clase estimada) y el mejor mapeo (es decir la verdadera etiqueta de clase).
- Varianza: refleja la sensibilidad del conjunto de entrenamiento usado T .

En este orden de ideas, los únicos términos que pueden ser minimizados son la varianza y la tendencia. Clasificadores simples (como clasificadores lineales) tienen un alta tendencia pero una baja varianza mientras que en clasificadores más complejos la relación se invierte. Para seleccionar la complejidad óptima del modelo se debe solucionar el dilema varianza-bias. Normalmente los clasificadores estables tienden a tener un bias alto y una baja varianza, mientras que en los inestables es al contrario. Esto puede explicar con facilidad porque los clasificadores “simples” algunas veces,

superan a los más complejos en las tareas de clasificación de los sistemas BCI. Una baja varianza puede ser una solución para hacerle frente a la naturaleza estocástica de las señales cerebrales. En la presencia de ruidos fuertes y outliers, los sistemas lineales suelen fallar. Una manera de sobrepasar este obstáculo es el uso de técnicas conocidas como técnicas de estabilización, las cuales pueden ser usadas para reducir la varianza, tales como la combinación de clasificadores y las técnicas de regularización. Ahora bien, los clasificadores no-lineales suelen tener un mayor número de parámetros a estimar que los lineales, estos parámetros pueden ser escogidos apropiadamente, aún así, cuando hay grandes cantidades y el conocimiento de los datos es limitado, los clasificadores no-lineales son más adecuados para encontrar la estructura potencialmente más compleja de los datos. En particular cuando la fuente de los datos a clasificar no es bien conocida, el uso de métodos que sean buenos para encontrar las transformaciones no lineales de los datos es altamente recomendado. En estos casos métodos basados en kernels y redes neuronales pueden ser usados para determinar las transformaciones. Los métodos basados en kernels son métodos de clasificación que aplican una clasificación lineal en un espacio de características (kernel) apropiado. Aquí, se mantienen todas las ventajas de la clasificación lineal, pero al mismo tiempo, el clasificador en conjunto es no-lineal. Los ejemplos de estos tipo de clasificadores son las Máquina de Soporte Vectorial y el Kernel del Discriminante de Fisher [53]. A continuación se describen brevemente las diferentes técnicas de clasificación empleadas para reconocer los registros de la señal EEG capturada de los sistemas BCI, los cuales han sido adquiridos cuando el sujeto realiza las actividades cognitivas propuestas a partir de la estrategia mental planteada. Se presentará una breve explicación de los algoritmos comúnmente empleados para el diseño de aplicaciones BCI y se describirán algunas de sus propiedades más críticas. Se destacan los aportes del investigador alemán Klaus Robert Müller, los cuales han marcado un referente mundial en el entrenamiento de máquina para los sistemas BCI [29].

2.4.1. Análisis Discriminante Lineal (LDA)

Los clasificadores lineales son algoritmos discriminantes que usan funciones lineales para distinguir clases (en este caso, intenciones o estados mentales). Estos clasificadores son probablemente los algoritmos más populares usados para las aplicaciones BCI. El propósito del LDA (también conocido como LDA de Fisher) es el uso de hiperplanos para separar los datos representativos de las diferentes clases. La idea es proyectar los datos a un espacio de menor dimensionalidad donde el proceso de clasificación sea más sencillo. Comúnmente el algoritmo es usado en un problema de dos clases, en donde son asumidas normalmente distribuidas con diferentes medias e igual matriz de covarianza para ambas clases; los datos son proyectados a una dimensión usando $y = w^T x$; se establece un umbral y_0 y se clasifica un nuevo registro EEG como de la clase C1 si $y \geq y_0$, o de la clase C2 si pasa lo contrario. Se busca escoger un w de manera que maximice la separabilidad de las clases. La separabilidad de los datos es medida mediante dos cantidades: la distancia entre las

medias de las clases proyectadas (la cual debe ser grande) y el tamaño de la varianza de los datos en esta dirección (debe ser pequeña). Aquí aparece el llamado criterio de Fisher, el cual se define como el radio de la varianza entre clases sobre la varianza intraclase, así:

$$J(w) = \frac{w^T S_B w}{w^T S_C w} \quad (2.15)$$

donde $S_B = (m_1 - m_2)(m_1 - m_2)^T$ es la matriz de dispersión entre clases para dos clases, $S_C = S_1 + S_2$ es la matriz de dispersión intraclases para dos clases, w es un vector de pesos ajustable o vector de proyección. La figura 2.6 ejemplifica lo anterior:

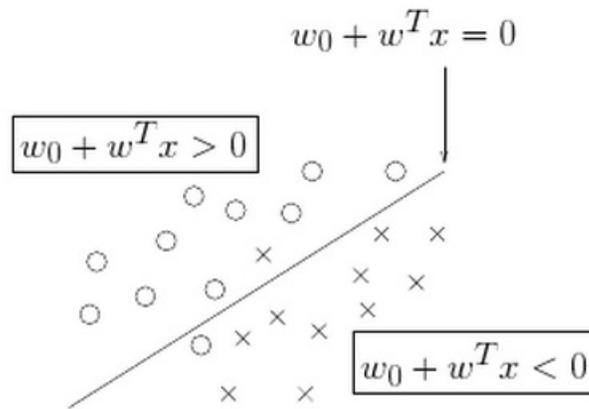


Figura 2.6. Un hiperplano el cual separa las dos clases: los círculos y las cruces. Un umbral permite la discriminación de las clases a través de la tendencia w_0 y el vector de pesos w .

Ahora, la matriz de dispersión S_C y la media del vector de muestras m_C de la clase C con $C = 1, 2$; son las siguientes:

$$S_w = \sum_{j \in I_C} (x_j - m_C)(x_j - m_C)^T \quad (2.16)$$

$$m_C = \frac{1}{n_C} \sum_{j \in I_C} x_j \quad (2.17)$$

Donde n_C es el número de datos muestra que pertenecen a la clase C , I_C es el conjunto de índices de los datos de muestra pertenecientes a la clase C . Finalmente el vector de pesos se puede calcular mediante lo que se conoce como el discriminante lineal de Fisher:

$$C \propto S_C^{-1}(m_2 - m_1) \quad (2.18)$$

Observe que esta última expresión estrictamente no es un discriminante sino más bien una elección específica de la dirección de proyección de los datos. Sin embargo los datos proyectados pueden ser

subsecuentemente usados para construir un discriminante mediante la umbralización antes descrita [31]. Para resolver un problema multiclase pueden ser usados muchos hiperplanos, la estrategia generalmente usada para los sistemas BCI multiclase es la de “Uno versus el resto” (OVR por sus siglas en inglés), la cual consiste en separar cada clase de las otras existentes. Estas técnicas tiene un costo computacional bajo lo cual lo hace adecuado para sistemas BCI que trabajen en línea [27]. Consecuentemente, el análisis discriminante lineal ha sido usado con éxito en un gran número de aplicaciones BCI con diferentes estrategias mentales como imaginación motora [54], atención selectiva [55], deletreadores con P300 [3] y aplicaciones multiclase [56].

2.4.2. Máquinas de Soporte Vectorial (SVM)

Las SVM son una herramienta lineal de discriminación que maximiza la margen de separación entre dos clases basado en la suposición de que esto mejora la capacidad de generalización del clasificador. En aprendizaje de máquina, la generalización es la habilidad de clasificar correctamente datos de validación. Este método de clasificación también es conocido por la insensibilidad que tiene al sobre entrenamiento y la robustez que presenta ante la “maldición” de la dimensionalidad [57]. En contraste, el discriminante lineal de Fisher maximiza el margen promedio, es decir la margen entre las medias de las clases. Las SVM lineales, por su parte, utilizan hiperplanos discriminantes para identificar las clases; para una SVM, un margen amplio (el hiperplano óptimo w) es alcanzado mediante la minimización de la función de costo de los datos entrenados:

$$J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2.19)$$

sobre las restricciones:

$$y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad \forall i = 1, \dots, n \quad (2.20)$$

donde x_1, x_2, \dots, x_n son los datos de entrenamiento, $y_1, y_2, \dots, y_n \in \{-1, +1\}$ son las etiquetas de entrenamiento, $\xi_1, \xi_2, \dots, \xi_n$ son las variables sueltas (variables que son añadidas a una restricción de desigualdad para transformarla en una igualdad), C es un parámetro de regularización que controla la compensación entre la complejidad y el número de puntos no separables y b es la tendencia. Las variables sueltas miden la desviación de los puntos de la condición ideal de separabilidad de los patrones. El parámetro C puede ser especificado por el usuario o determinado mediante una validación cruzada [3]. Esta máquina es llamada C-SVM, mediante un análisis del problema se puede encontrar que w puede ser determinado por $w = \sum_i \alpha_i y_i x_i$ con algunos números reales α_i . Para los datos x_i con $y_i(w^T x_i + b) > 1$, se puede obtener que $\alpha_i = 0$. Entonces, solo unos pocos datos (llamados vectores de soporte) son requeridos para calcular w . Pero note que usualmente todos los puntos son requeridos para obtener el conjunto de vectores de soporte [58]. La figura 2.7 muestra un hiperplano típico trazado por un SVM entrenado:

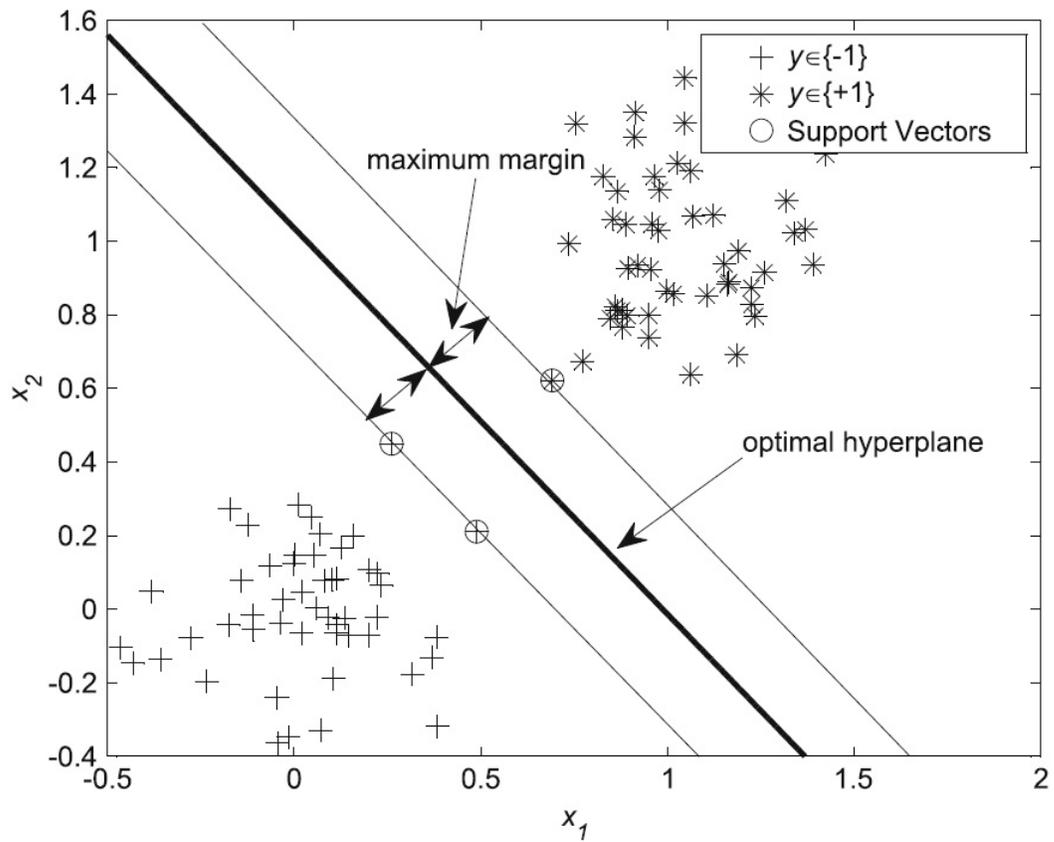


Figura 2.7. Un ejemplo que ilustra una máquina de soporte vectorial entrenada que encontró el hiperplano óptimo con la margen de separación máxima a partir de los patrones de formación más cercanos, los cuales son llamados vectores de soporte.

Generalmente, las SVM que clasifican los datos a través de límites de decisión lineales, son conocidas como SVM lineales. Es posible crear límites de decisión no lineales con solo un bajo incremento en la complejidad del clasificador mediante el uso del “truco del Kernel” el cual consiste en mapear implícitamente los datos a otro espacio, el cuál generalmente es de una dimensión mucho más alta, usando una función kernel $K(x, y)$. Existen 4 Kernels básicos para la implementación de máquinas de soporte vectorial:

- Lineal: $K(x_i, x_j) = x_i^T x_j$
- Polinomial: $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
- Funciones Base Radiales (Gaussiano): $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$
- Sigmoidal: $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Aquí, γ , r y el parámetro d son los parámetros de los kernels. El kernel generalmente usado por los investigadores BCI es el Gaussiano o también conocido como el kernel de Funciones Base Radiales (RBF por su sigla en inglés). Esta técnica denominada RBF-SVM ha brindado buenos resultados para las aplicaciones BCI. Así como el LDA, las SVM han sido utilizadas en problemas multiclase usando la estrategia de OVR [31]. Una de las ventajas de utilizar las funciones kernel es que permiten el cálculo de productos escalares en espacios en donde usando otras técnicas difícilmente se podría realizar algún cálculo computacional. Recientemente se ha observado que la excelente generalización que es típicamente observada cuando se usan las máquinas de soporte vectorial en aplicaciones de alta dimensionalidad con pocas muestras se debe a la muy económica representación en el Kernel del espacio de Hilbert [29]. Otra de las razones del éxito del uso de las SVM es la regularización: actualmente las características de los sistemas BCI son a menudo ruidosas y probablemente contiene outliers; la regularización puede superar este problema e incrementar las capacidades de generalización del clasificador. Como consecuencia, los clasificadores regularizados, y más particularmente las SVM lineales han superado los no regularizados del mismo tipo (como el LDA) en muchos estudios comparativos. Finalmente, la simplicidad de las SVM se debe a que su regla de decisión es una simple función lineal en el espacio kernel la cual hace a las SVM una técnica estable y, por consiguiente, con una baja varianza. Una de las claves quizá, para un bajo error de clasificación es que las características de las señales adquiridas por los sistemas BCI sean muy estables sobre el tiempo y presenten una baja varianza. A pesar de que una de las desventajas de las SVM es que son comparativamente lentas, resultan ser lo suficientemente rápidas para aplicaciones con sistemas BCI. En [59] se concluye que las SVM que utilizan kernels polinómicos de orden 4 ó 5 presentan mejores resultados que los basados en kernels gaussianos. Otra información más detallada del algoritmo y sus restricciones se describe en [60] y [61].

2.4.3. Clasificadores Gaussianos

En el enfoque probabilístico para la clasificación, el objetivo es lograr modelar la probabilidad posterior de la variable objetivo para un nuevo vector de entrada dado un conjunto de datos de entrenamiento. Estas probabilidades deben estar en el intervalo (0,1), mientras un modelo de un proceso gaussiano realiza predicciones que están sobre el eje real entero. Por lo tanto, se puede adaptar fácilmente un Proceso Gaussiano (GP) para problemas de clasificación mediante la transformación de la salida de los GPs usando una función apropiada de activación no lineal [31]. El algoritmo de aprendizaje basado en Procesos Gaussianos es un método kernel similar al discutido algoritmo SVM. De forma similar a muchas otras técnicas de aprendizaje, los GPs pueden ser usados para realizar una regresión multivariada o una clasificación multiclase dependiendo del problema abordado. Desde una perspectiva holística, los métodos estadísticos comúnmente se interesan en el establecimiento de modelos y el entendimiento de las relaciones entre los datos mientras que el enfoque del aprendizaje de máquina está focalizado en entender el comportamiento de los algoritmos de aprendizaje y en la realización de predicciones precisas. Los GPs brindan una combinación única de estos dos enfoques buscando a través de la adaptación de modelos que representan mejor las relaciones entre los datos, una mejora significativa de la precisión en la tarea de la clasificación; como resultado, un algoritmo basado en GPs brinda como salida una distribución probabilística. Esta distribución puede ser usada en conjunto con otro tipo de conocimiento sobre el estado global del sistema para mejorar la precisión en la toma de decisión [62]. En los sistemas BCI que utilizan clasificadores basados en GPs, la configuración requiere que exista una función discriminante de tipo gaussiana para cada intención mental propuesta (clase). Al igual que otros métodos, en los clasificadores GPs se requiere una adaptación de la función de covarianza mediante la sintonización de algunos hiperparámetros. Matemáticamente un proceso gaussiano $f(x)$ es una colección de variables aleatorias, tal que cualquier número finito de ellas sigue una distribución gaussiana conjunta; es representado según la siguiente notación:

$$f(x) \sim GP(\mu(x), \Lambda(x, x')) \quad (2.21)$$

Un proceso gaussiano está completamente especificado por una función media $\mu(x) = E[f(x)]$ y una función de covarianza $\Lambda(x, x') = E[(f(x) - \mu(x))(f(x') - \mu(x'))]$. Típicamente, la media de un GP es centrada alrededor de cero por lo cual $f(x) \sim GP(0, \Lambda(x, x'))$. Como un método kernel, los GPs mapean las funciones de entrada no lineales en un espacio de características de alta dimensionalidad. Este proceso se realiza mediante el uso de una función kernel similar a como se hace en SVM. Los elementos de la matriz de covarianza $\Lambda(x, x')$ son obtenidos mediante la evaluación de la función kernel. Entonces la escogencia de la función kernel en últimas determina la forma de la función de covarianza y sus elementos. En [62] se utiliza la siguiente función de covarianza (función kernel):

$$\Lambda(x, x') = -\varphi \times \sum (x_n - x'_n)^2 + \lambda \quad (2.22)$$

Las variables φ y λ son conocidos como los hiperparámetros del sistema. Estos hiperparámetros generalmente son concatenados dentro de un simple vector de parámetros. El valor de estas variables determina cómo están modelados los datos en el espacio de características de alta dimensionalidad, los datos de entrenamiento deben ser usados para obtener los valores óptimos los cuales minimizan el error de clasificación del sistema. La sintonización de estos parámetros es un paso esencial en el mejoramiento de la precisión del algoritmo de clasificación basado en GPs. A continuación se muestra una figura que ejemplifica una clasificación usando GPs para un sistema binario.

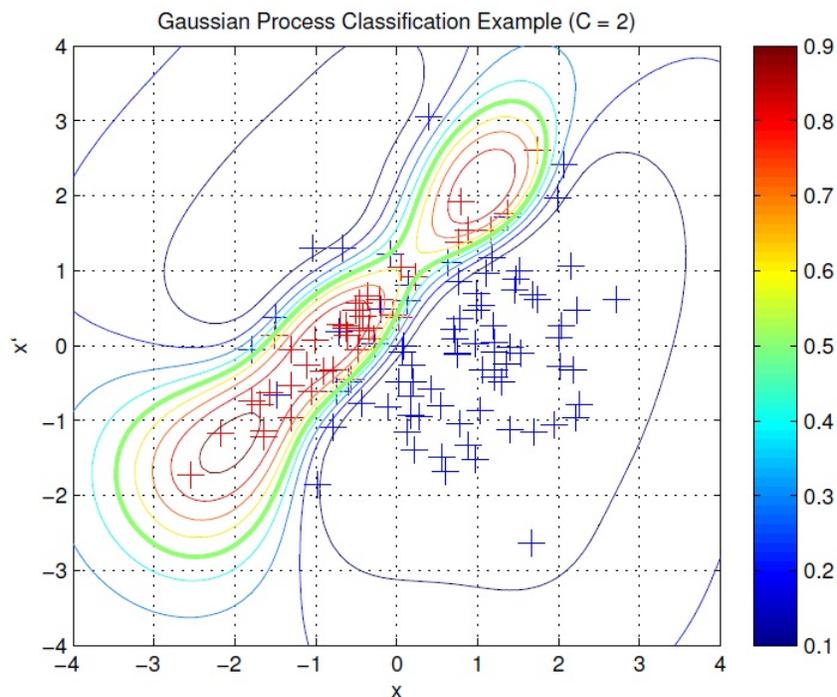


Figura 2.8. Ejemplo del uso de un clasificador de GPs de 2 clases ($C=2$ caso binario). La salida de la técnica de clasificación basada en GPs toma la forma de una salida probabilística la cual es mostrada arriba como un mapa de contorno en un espacio de características bidimensional. La distancia de los contornos representa las regiones del espacio de características las cuales son equiprobables.

En problemas de clasificación multiclase ($C > 2$) con clasificadores basados en GPs suele usarse la estrategia de imaginación motora [62], en la cual se utilizan los movimientos específicos de las manos o generales de los pies para realizar el entrenamiento y establecer el número de clases que serán correspondientes con el número de comandos de la aplicación BCI. También en [63] usaron mezclas de modelos gaussianos como regla de clasificación para señales de EEG, en donde se utilizaron los movimientos de la mano derecha y de la izquierda para establecer las dos primeras clases y la generación de diferentes palabras con la misma letra aleatoria para una tercera clase. En este artículo se muestra como las estrategias mentales pueden ser combinadas para extender el número de comandos aplicables al sistema BCI, en lo que se conoce actualmente como la

hibridación BCI (hBCI) que es materia reciente de estudio en la comunidad BCI mundial. En general, en los trabajos encontrados la precisión del clasificador basado en GPs se acerca y en ocasiones mejora al clasificador SVM. Una de las características diferenciadores de estos dos clasificadores es que mientras en las SVM la salida debe ser tomada de una forma más estricta, en el enfoque de GPs está misma puede brindar una medida probabilística debido a que en este método naturalmente se producen probabilidades posteriores (por ejemplo, el algoritmo puede determinar lo que el usuario quiere con 30 % de confiabilidad) [64]; este conocimiento puede ser combinado con información externa de sensores que puedan contener la aplicación BCI; por ejemplo, sensores de ultrasonido, acelerómetros, infrarrojos, cámaras u otros sensores comúnmente usados en robótica, esto con el fin de mejorar la precisión del clasificador.

2.4.4. Perceptrón Multicapa

Las redes neuronales (RN) son, junto con los clasificadores lineales, la categoría de clasificadores más usados en las aplicaciones con las interfaces cerebro computador [27]. Las RN son un conjunto de muchas neuronas artificiales las cuales permiten la producción de límites de decisión no lineales. Son sistemas computacionales compuestos de un gran número de elementos simples y altamente conectados (llamados nodos o neuronas artificiales) que abstractamente emulan la estructura y la operación del sistema nervioso biológico. La dificultad en la correcta escogencia de las funciones base en clasificadores como el RBF-SVM ha empujado hacia un enfoque alternativo que busca fijar las funciones base por adelantado pero permitiendo que sean adaptables, en otras palabras, el uso de formas paramétricas para las funciones base en las cuales los valores de los parámetros sean adaptados durante el entrenamiento. El modelo más exitoso de este tipo en el contexto de reconocimiento de patrones es una red neuronal de propagación hacia adelante conocida como el perceptrón multicapa (MLP por sus siglas en inglés). Su modelo resultante es para muchas aplicaciones, significativamente más compacto y por tanto más rápido de evaluar que las SVM teniendo en mismo desempeño en la generalización [31]. El perceptrón multicapa es la red neuronal más ampliamente usada para los sistemas BCI, está compuesta de muchas capas de neuronas: una capa de entrada (en una configuración BCI pueden ser por ejemplo los ritmos sensoriomotores), posiblemente una o muchas capas ocultas y una capa de salida. Cada neurona de entrada es conectada con la salida de la capa de neuronas anterior mientras las neuronas de la capa de salida determinan la clase del vector de características de entrada. Las redes neuronales son aproximadores universales, cuando están compuestas de suficientes capas y neuronas, ellas pueden aproximar cualquier función continua. Adicionalmente, el hecho de que las RN puedan clasificar cualquier número de clases hace que esta técnica se convierta en un clasificador muy flexible que puede adaptarse a una gran diversidad de problemas. Sin embargo, el hecho de que el perceptrón multicapa sea un aproximador universal hace que estos clasificadores sean muy sensibles al sobre entrenamiento, especialmente con datos EEG algo ruidosos y no-estacionarios. Para estos casos,

se requiere de una selección cuidadosa de la arquitectura y de los parámetros de regularización. La arquitectura de un MLP debe contener dos o más capas; una simple RN artificial de dos capas consiste sólo en una capa de entrada que contiene las variables de entrada del problema y una capa de salida que contiene la solución del problema. Este tipo de RN son aproximadores satisfactorios para problemas lineales, sin embargo, la aproximación de sistemas no lineales requiere del uso de capas de procesamiento intermedias (ocultas) para manejar los problemas de no linealidad y complejidad. Un MLP sin capas ocultas es conocido como un perceptrón. Curiosamente, un perceptrón es equivalente a un LDA y como tal es raramente usado en aplicaciones BCI [27]. En [65] se encuentra una implementación del MLP, sus ecuaciones e implementaciones con datos de EEG.

2.4.5. Cadenas Ocultas de Markov

Las cadenas ocultas de Markov (HMM por sus siglas en inglés) son clasificadores dinámicos muy popularmente usados en el campo de reconocimiento de voz; son autómatas probabilísticos que pueden proporcionar la probabilidad de observar una determinada secuencia de vectores característicos. Estos modelos pueden ser vistos como una representación estadística de la señal dentro de un marco doblemente estocástico, que consta de un proceso de Markov (sin memoria) de parámetros desconocidos y no observables y un proceso observado cuyos valores son dependientes estocásticamente de los estados ocultos. Un proceso aleatorio se conoce como un proceso de Markov de primer orden si su probabilidad condicional, dados todos los valores pasados, depende sólo del valor más reciente. El modelo estándar de las HMM usa un estado discreto oculto en el tiempo t para resumir toda la información antes de t y por tanto la observación en cualquier tiempo depende solo del estado oculto actual. La secuencia de tiempo del estado oculto en un HMM es una cadena de Markov [66]. Cada estado del autómata puede modelar la probabilidad de observar un vector de características dado; para los sistemas BCI estas probabilidades usualmente son modelos de mezclas de gaussianas (GMM por sus siglas en inglés). A pesar que se han encontrado resultados destacables para problemas multiclase de sistemas BCI usando clasificadores con HMM [66], [67], esta técnica aún no ha sido ampliamente extendida por la comunidad BCI. Usando la estrategia mental de imaginación motora, Muller en [68] resuelve un problema de 2 clases mediante la elaboración de un HMM para cada clase, las cuales son entrenadas usando las muestras grabadas durante las correspondientes intenciones mentales propuestas. La siguiente figura muestra un ejemplo de un diagrama de bloques de clasificación de señales EEG usando HMM.

Al igual que en todos los casos, la señal EEG es filtrada y procesada para extraer las características definitorias (potencia de determinadas bandas frecuenciales, coeficientes adaptativos, etc.). La clasificación de una muestra desconocida, en este caso, se da a través de la selección de la probabilidad máxima de producir el vector de características (Y) dadas las representaciones de los HMMs para cada clase, por tanto, se clasifica la actividad mental cuya probabilidad de generación sea más alta. Las principales ventajas de los HMM son básicamente dos: a) poseen una estructura

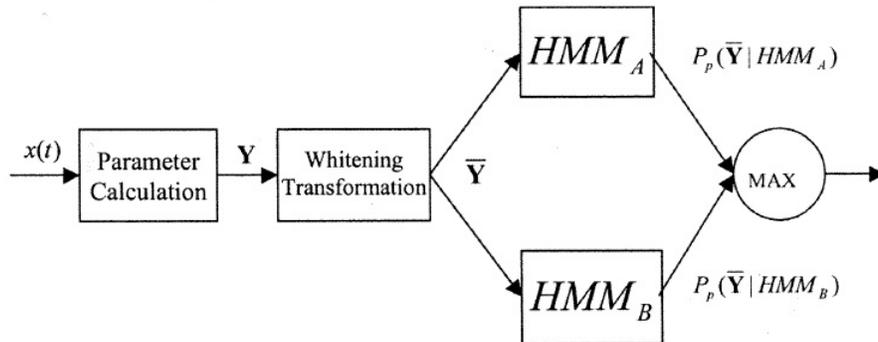


Figura 2.9. El esquema BCI-HMM comprende una fase de extracción de características a través de la transformación Whitening; la clasificación es basada sobre la selección de máxima verosimilitud.

matemáticamente muy rica de la que se desprende que puedan ser usados en una gran cantidad de aplicaciones y b) los resultados prácticos obtenidos son muy próximos a los que usan clasificadores como LDA o SVM. Para la implementación de los HMM en tareas de clasificación se deben de tener en cuenta algunas consideraciones prácticas como lo son: el problema de la estimación de los parámetros iniciales, el efecto de datos de entrenamiento insuficientes, la elección del modelo (tamaño, tipo:ergódico, izquierda-derecha, rutas paralelas, entrada-salida) el escalado, la consideración de múltiples secuencias de observación, entre otros. Ahora bien, comparativamente, mientras en las SVM las funciones kernel transforman los datos de entrada a espacios de dimensión muy superior, las capas ocultas en los HMM transforman los datos a espacios de cualquier dimensión y mientras que en las SVM se diseña una función kernel y un parámetro de coste, en los HMM lo que se diseña es el número de capas ocultas y nodos Algunos trabajos en HMM con señales EEG han mostrado resultados prometedores [31] y [59].

En la comunidad BCI han sido usados satisfactoriamente algunos otros clasificadores que no se han nombrado en esta revisión como lo son el Bayes Cuadrático, los clasificadores de vecinos cercanos (KNN, distancia de Mahalanobis), los clasificadores difusos, otras redes neuronales aplicadas de una manera más marginal como las LVQ (Learning Vector Quantization), las tipo RBF o PNN, difusas como la ARTMAP, las dinámicas como las FIRNN o las redes neuronales de regresión logística bayesiana.

2.5. Validación de los Clasificadores

Una vez que ha sido construido el modelo de clasificación se puede aplicar a un conjunto de prueba con el fin de predecir la etiqueta de clase de registros no usados en la fase de entrenamiento. Resulta de gran utilidad medir el desempeño del modelo de un conjunto de pruebas debido a que esta medida

proporciona una estimación imparcial del error. La precisión calculada del conjunto de prueba puede ser usada además, para comparar el desempeño del clasificador construido con otros clasificadores a través de un experimento reproducible. En pocas palabras, la precisión de la salida del sistema de los diferentes modelos implementados necesita ser evaluada sobre una base común de datos de muestra dados [29]. Si los datos son abundantes, entonces un enfoque para realizar una correcta selección del modelo es simplemente usar algunos de los datos disponibles para el entrenamiento para conformar el modelo para luego compararlos con un conjunto de datos independientes (a menudo llamado conjunto de validación) y seleccionar el que tenga mejor rendimiento predictivo [31]. Sin embargo en muchas aplicaciones los datos suplididos para el entrenamiento suelen ser limitados y en orden de construir un buen modelo, se desea usar la mayor cantidad de los datos disponibles para realizar un buen entrenamiento. Más aún, si el conjunto de validación es pequeño, dará una implementación estimativa o predictivamente ruidosa. Una solución a este problema es usar la validación cruzada (cross-validation), la cuál permite que una proporción $(S - 1)/S$ de los datos disponibles sean usados para el entrenamiento mientras se hace uso de todo el resto de datos para evaluar el rendimiento, o sea, cada registro se usa el mismo número de veces para el entrenamiento y solo una vez para la prueba. Este método suele tener la desventaja de ser computacionalmente costoso, ahora bien, cuando los datos son particularmente escasos, resulta apropiado considerar el caso de $S = N$, donde N es el total del número de datos, para lo cuál se usa la técnica de dejar uno afuera (leave-one-out). Aquí, el modelo estimado es validado usando la observación que se ha dejado afuera; este procedimiento se repite hasta que cada dato es utilizado como conjunto de validación. En [29] se plantean algunas recomendaciones generales para la evaluación del modelo en aplicaciones con sistemas BCI; como lo son las consideraciones a tener en cuenta en los modelos con hiperparámetros, la validación cruzada para datos dependientes, la validación cruzada en bloques, algunas advertencias en el uso de la validación cruzada, la evaluación del modelo para la selección de características y para el rechazo de outliers, las funciones de pérdida permitidas para las clases desbalanceadas y algunos aspectos concernientes a la no estacionariedad presente en las señales EEG.

2.6. Guía para la escogencia de un Clasificador BCI

Esta sección pretende establecer una serie de tips y recomendaciones para el momento de escoger el clasificador adecuado en la aplicación BCI que se desea desarrollar. Generalmente existen muchas medidas que han sido propuestas para la calificación de los clasificadores, como la precisión de la clasificación, el coeficiente Kappa, información mútua, sensibilidad y especificidad, entre otros. Sin embargo el más usado es la medición de la precisión de la clasificación, por ejemplo, el porcentaje de clasificaciones correctas realizadas. Se tendrán en cuenta dos enfoques ampliados según lo establecido en [27]: el primero identifica el o los mejores clasificadores para un tipo de BCI en específico, mientras el segundo identifica el o los mejores clasificadores para un tipo específico de

características.

2.6.1. ¿Cuál clasificador va con cuál sistema BCI?

Una de las clasificaciones usadas a menudo para los sistemas BCI es la de síncronos y asíncronos. En las BCI síncronas, los sistemas especifican la temporización de la operación; por el contrario en los sistemas asíncronos el usuario determina la temporización.

BCI Síncronas

Los protocolos síncronos facilitan el análisis EEG desde el momento en que los estados mentales comienzan a ser conocidos con precisión y las diferencias con respecto al ruido de fondo de la señal EEG pueden ser amplificadas. Desafortunadamente, la arquitectura síncrona es a menudo lenta y los sistemas BCI que la usan normalmente solo resuelven el problema de clase binario [58]. Existen dos algoritmos de clasificación que han mostrado particular eficiencia con las BCI síncronas: las máquinas de soporte vectorial y los clasificadores dinámicos. Con respecto a las SVM, su proceso de regularización parece ser uno de los motivos de su éxito; las características BCI son a menudo ruidosas y es probable que contengan outliers. La regularización puede resolver este problema e incrementar las capacidades de generalización del clasificador. Como consecuencia, los clasificadores regularizados, y más particularmente las SVM lineales, han superado a los clasificadores de la misma familia no regularizados (como los LDA) en algunos estudios [27]. La segunda razón, quizá puede ser la simplicidad del modelo. Ciertamente, la regla de decisión de las SVM es una simple función lineal en un espacio kernel el cual hace al modelo estable y por ende, con una baja varianza; dado que las características de las señales BCI son muy inestables sobre el tiempo; tener una baja varianza puede llegar a ser la clave para una error bajo en la clasificación. Finalmente, la robustez que manejan las SVM con respecto a la maldición de la dimensionalidad, les permite obtener muy buenos resultados con un vector de características de alta dimensionalidad y pequeños conjuntos de entrenamiento [69]. Por su parte, los clasificadores dinámicos como los HMM permiten capturar las variaciones temporales relevantes presentes en las características extraídas. Es más, clasificar una secuencia de vectores característica de baja dimensionalidad en vez de una de gran dimensionalidad, de alguna manera, soluciona el problema de la maldición. Finalmente, los clasificadores dinámicos resuelven el problema de encontrar el instante óptimo para la clasificación ya que la secuencia temporal de los datos es analizada desde una perspectiva holística y no solo en una ventana temporal en particular.

BCI asíncronas

En esta arquitectura, el sujeto puede voluntariamente cambiar la tarea mental que está siendo ejecutada en cualquier momento sin necesidad de esperar algún estímulo externo de cualquier índole. En una aplicación asistiva, por ejemplo, este protocolo asíncrono podría resultar en un

sistema de reacción mucho más rápida, ya que el usuario podría en un eventual ambiente complicado (lleno de obstáculos), tomar una rápida y precisa secuencia de tareas mentales para maniobrar mejor el dispositivo, por ejemplo, una silla de ruedas. En este protocolo a menudo se presentan lo que se conocen en BCI como los estados “ociosos” momentos en los cuales los usuarios no se ven envueltos en ninguna tarea mental específica. En estos protocolos, los estados ociosos aparecen durante momentos en el que el usuario no desea que el sistema BCI ejecute alguna acción. Como la diversidad de pensamientos de “nada” es tan basta individuo tras individuo y muestra tras muestra del mismo individuo, los clasificadores no suelen ser entrenados para reconocer estos estados ociosos, por lo cual, estos estados pueden ser identificados equívocamente generando falsos positivos y disminuyendo la precisión de los clasificadores [58]. Realmente son pocos los experimentos que se encuentran en la bibliografía de aplicaciones con sistemas BCI asíncronas, esto se debe quizá, a la dificultad intrínseca de identificar el comienzo de cada tarea mental en experimentos asíncronos, así, por ejemplo, los clasificadores dinámicos no podrían usar sus habilidades temporales con la suficiente eficiencia. Sin embargo, estudios recientes han utilizado las SVM [70] y clasificadores bayesianos [71] que han marcado una ruta inicial de cara al trabajo sobre estos complejos paradigmas.

2.6.2. ¿Cuál clasificador va con qué tipo de características?

Desde el otro punto de vista, se busca comparar clasificadores considerando su capacidad para superar problemas específicos de las características de la señal EEG de los sistemas BCI.

- Ruido y Outliers: clasificadores regularizados, como las SVM, parecen la herramienta apropiada para combatir los Outliers. En [33] se recomienda regular sistemáticamente los clasificadores usados en los sistemas BCI en el orden de superar el problema de los outliers.
- Alta dimensionalidad: las máquinas de soporte vectorial son probablemente los clasificadores más apropiados para tratar con vectores de características de altas dimensionalidades. Ahora bien, si la alta dimensionalidad es debido a la utilización de un gran número de segmentos de tiempo, los clasificadores dinámicos como los HMM, pueden a menudo resolver el problema mediante la consideración de una secuencia del vector de características en vez de un simple vector de características de una muy alta dimensionalidad. Así existan clasificadores óptimos para trabajar con vectores de características de altas dimensionalidades, la recomendación, sin embargo, es siempre procurar por tener un pequeño número de características [27]. Para lograr esta meta, es altamente recomendado el uso de técnicas de reducción de dimensionalidad y de selección de características, algunas de las cuales han sido descritas en este capítulo.
- Información Temporal: para experimentos síncronos, los clasificadores dinámicos parecen ser la técnica de clasificación más eficiente para explotar la información temporal contenida

en las características seleccionadas. En los problemas asíncronos, no se ha identificado con claridad una superioridad marcada de algún tipo de clasificador.

- No estacionariedad: la combinación de clasificadores [27] puede resolver este problema mediante una reducción significativa de la varianza. Clasificadores como el LDA o las SVM pueden ser clasificadores efectivos para este tipo de problemas. En [72] se realiza una implementación de una extensión del algoritmo de CSP en donde se trabaja el problema de una matriz de covarianza que envuelve no sólo fuentes de señales estacionarias, sino también fuentes de señales no estacionarias. La extensión de CSP llamada CSP estacionaria (sCSP) ayuda a separar las señales provenientes de cada fuente y de esta manera mejorar los la precisión de la tarea de clasificación. Conjuntos pequeños de entrenamiento: si el conjunto de entrenamiento es pequeño, técnicas simples como el LDA son altamente recomendadas. Wang y colegas, mencionan la importancia de utilizar una estrategia mental que permite la explotación de los ERD cuando se tienen conjuntos pequeños de entrenamiento. Finalmente en [46], concluyen que usar el algoritmo de CSP en un pequeño conjunto de entrenamiento brinda un sobre entrenamiento de los datos. Como era de esperarse, la habilidad de generalización del algoritmo de CSP mejora cuando más muestras son usadas en el conjunto de entrenamiento.

ESTADO DE LA TÉCNICA

En teoría, un sistema BCI debe usar señales cerebrales grabadas a través de una variedad de metodologías. Estas incluyen registros de campos eléctricos o magnéticos; resonancia magnética funcional (fMRI), tomografía de emisión de positrones (PET) y espectroscopia funcional del infrarrojo cercano (fNIR). Específicamente, esta tesis y en especial este capítulo, brinda las nociones fisiológicas básicas para comprender los principios biológicos en los que se fundamentan las interfaces cerebro computador que trabajan con sistemas de electroencefalografía (EEG-BCI), resaltando su importancia en accesibilidad de hardware, el carácter no invasivo del montaje y los avances en captura y procesamiento de este tipo de señales bioeléctricas. Posteriormente se hace un análisis de las características de las señales EEG típicas usadas para los sistemas BCI, resaltando los potenciales relacionados a eventos (ERP) como la onda P300 y los SSVEP y los ritmos sensoriomotores (SMR) como los eventos relacionados a sincronizaciones y desincronizaciones (ERS y ERD) por su trascendencia y usabilidad dentro de la bibliografía consultada. En este capítulo se considera también una etapa importante dentro del diagrama de flujo típico de una BCI, la etapa de preprocesamiento de la señal, también llamada etapa de acondicionamiento, aquí la señal es mejorada mediante la reducción o eliminación de interferencia conocida (artefactos) o información irrelevante y/o mediante el mejoramiento de las características espaciales, espectrales o temporales de la señal que son particularmente relevantes para la aplicación. Seguidamente, se mencionan las particularidades del sistema BCI utilizado durante la experimentación, el Emotiv EPOC, describiendo no sólo los rasgos que lo hacen un sistema confiable para experimentos neurocientíficos, sino también, su interacción con dos herramientas específicas en software que vienen siendo ampliamente usadas por la comunidad BCI a lo largo del mundo. Finalmente, se mencionan los tipos de videojuegos utilizados con sistemas BCI y el uso de la tecnología de realidad virtual en rehabilitación.

3.1. Fundamentos Fisiológicos

Desde que en 1929 Hans Berger demostrara la inherente naturaleza eléctrica del cerebro, dando lugar al nacimiento de la electroencefalografía como técnica de registro [60], se ha venido

investigando el modo de utilizar esta información para aumentar la base del conocimiento del comportamiento cognitivo humano, el diagnóstico de enfermedades e incluso el planteamiento de nuevas vías de comunicación, como los sistemas BCI. Como punto de partida se presenta una descripción fisiológica básica del cerebro entorno a la actividad eléctrica que produce.

3.1.1. El cerebro

De manera general, el cerebro está dividido en dos hemisferios separados por un surco medio profundo, la cisura interhemisférica, dichos hemisferios están comunicados entre sí mediante el Cuerpo Caloso que se extiende desde el fondo de la cisura interhemisférica hasta la base cerebral. La superficie se denomina corteza cerebral y está formada por replegamientos, su parte inferior presenta en su tercio posterior una forma arriñonada, separada del tercio anterior por la cisura de Silvio, que junto con la cisura de Rolando y la occipital dividen cada hemisferio en los diferentes lóbulos: frontal, parietal, temporal y occipital [6]. Hay una diferenciación y complementariedad de funciones entre cada uno de los lóbulos, de un modo holístico el lóbulo frontal es el encargado de decidir la conducta motora apropiada para diferentes situaciones. Este lóbulo también alberga tareas no motoras como la planificación de la conducta, el control de nuestras emociones, el razonamiento y juicio. El lóbulo parietal está involucrado con el mapa mental de “donde actuar” integrando la información sensorial interoceptiva (procedente de los órganos internos) y la exteroceptiva (del exterior). Se le atribuyen a este lóbulo básicamente funciones sensitivas, asociativas y aspectos relativos al reconocimiento del espacio. El lóbulo occipital se encarga básicamente de la visión, elabora la información visual aunque está trasciende a los lóbulos parietales y temporales; está ubicado en la zona posterior del cerebro de los mamíferos y para el caso de sistemas BCI, suele ser una zona de registro muy usada debido a que la actividad que se genera allí puede ser influenciada por estímulos visuales. El lóbulo temporal, por su parte, es el asiento de los últimos peldaños de procesamiento auditivo así como el lugar donde, en su cara medial, asientan importantes estructuras de la memoria y del sistema emotivo inconsciente. A continuación se muestra una figura en donde se encuentran relacionados cada uno de los lóbulos con las áreas en las que se dividen según algunas de las funciones allí asentadas.

La estructura del cerebro humano comparada con la de los demás seres vivos tiene un volumen y apariencia altamente diferenciados. Esta diferenciación dan idea de la trascendental importancia que posee el cerebro para el total funcionamiento del organismo humano, Llinás [73] propone que como el corazón, el cerebro opera como un sistema autorreferencial (sistemas psíquicos que pueden observar la realidad sólo mediante el autocontacto), cerrado al menos en dos sentidos: en primer lugar, como algo ajeno a la experiencia directa, en razón del cráneo; en segundo lugar, por tratarse de un sistema básicamente autorreferencial, el cerebro sólo podrá conocer el mundo externo mediante órganos sensoriales especializados. La evolución sugiere que estos órganos especifican estados internos que reflejan una selección determinada de circuitos neuronales, al nacer, estos

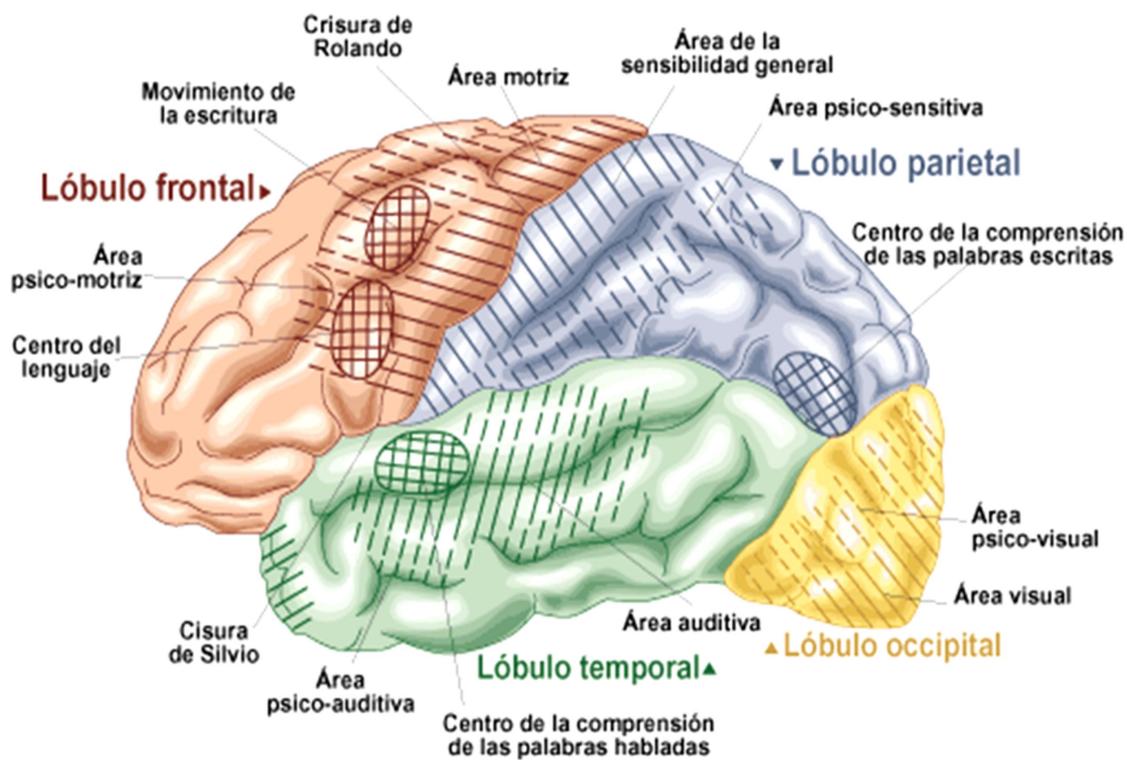


Figura 3.1. Distribución de las funciones de la corteza cerebral.

estados se enriquecen gradualmente en virtud de nuestras experiencias como individuos y, por ende, constituyen nuestras memorias particulares. La actividad intrínseca eléctrica del cerebro conforma una entidad o estructura funcional isomorfa con la realidad externa; esta actividad se manifiesta como variaciones diminutas de voltaje (del orden de milésimas de volts) a través de la membrana que rodea a las células del sistema nervioso, la neurona.

3.1.2. La neurona y el potencial de acción

Una neurona es un tipo de célula del sistema nervioso que tiene la capacidad de transferir información de una parte del organismo a otra en forma de impulsos electroquímicos, lo cual la distingue del resto de las células. Son células excitables especializadas para la recepción de estímulos de diferentes fuentes y la conducción del impulso nervioso. Las neuronas se localizan en el encéfalo, médula espinal y los ganglios nerviosos y están en contacto permanente con todo el cuerpo. La transmisión eléctrica de la neurona se da debido a su polarización, la cual se dice que es negativa en el interior de la membrana celular respecto al exterior. Toda neurona está compuesta por tres partes básicas: (a) cuerpo de la célula, (b) axón, (c) dendritas o terminaciones nerviosas [59].

El punto de contacto entre dos neuronas es llamado sinapsis y es de especial importancia en la transmisión de información del sistema nervioso. Lo que respecta a la transmisión eléctrica se dice que la neurona está polarizada cuando tiene una carga eléctrica negativa en el interior de la membrana celular respecto al exterior. Este efecto de polarización se debe a la libre circulación de iones K^+ a través de la membrana celular, a la vez que moléculas grandes con carga negativa son retenidas dentro de la célula. Los iones Na^+ se mantienen en el exterior de la célula mediante un proceso activo. Las neuronas se distinguen de otras células en que al aplicar una corriente estimuladora se provoca la penetración de los iones de sodio dentro de la célula, despolarizándola, tras un pequeño intervalo de tiempo las propiedades de la membrana cambian haciendo que la célula sea permeable al Na^+ , que entra en ella con rapidez originando una carga neta positiva en el interior de la neurona. A este efecto se le llama potencial de acción (PA) y de manera general se dice que este potencial es la información transmitida por un nervio. Usualmente el PA inicia en el cuerpo de la célula y normalmente viaja en una dirección. El potencial de membrana se despolariza (se vuelve más positivo), produciendo un pico. Después del máximo del pico la membrana se repolariza (se vuelve más negativa). El potencial se vuelve más negativo que el potencial de reposo y entonces vuelve a la normalidad. Los PAs de la mayoría de nervios duran entre 5 y 10 milisegundos [60]. La figura 3.2 muestra un ejemplo de un potencial de acción.

La velocidad de conducción de los PAs se encuentra entre 1 a 100 m/s. Los PAs son iniciados por diferentes tipos de estímulos como los nervios sensoriales que responden a muchos tipos de estímulos como químicos, de luz, electricidad, presión, táctiles, de estiramiento. Un estímulo debe estar por encima de un nivel umbral para el lanzamiento de un PA. Estímulos muy débiles causan

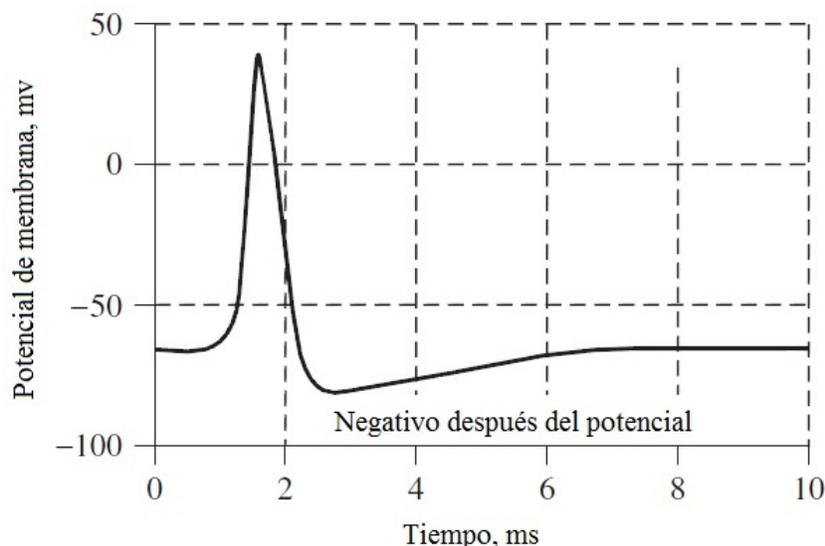


Figura 3.2. Ejemplo de Potencial de Acción.

un pequeño disturbio eléctrico, pero no producen la transmisión de un PA. Tan pronto como la fuerza del estímulo está por encima del umbral, un potencial de acción aparece y se propaga a lo largo del axón [74]. No todos los tipos de actividad neuronal tienen el mismo tipo de impacto sobre los registros electroencefalográficos. Factores como la profundidad, orientación y simetría intrínseca de las conexiones del cortex, presentan una marcada influencia sobre dichos registros. Las células de mayor importancia en el neocórtex son las de tipo piramidal. Es conocido que sus neurotransmisores son potentes transmisores excitatorios. Las células piramidales, a diferencia de otro tipo de neuronas, permiten que los axones produzcan PAs, que transmiten la información de una neurona a otra. En el caso de las neuronas piramidales, las dendritas apicales, con forma de eje alargado entre la región basal y la apical pueden provocar potenciales de acción, que a su vez actúan para amplificar los potenciales de acción producidos por las salidas de los sistemas sensorial, motor o autónomo. Por esta razón se considera que las neuronas piramidales son las causantes de la porción más significativa de la señal de EEG.

3.1.3. Generación y medición del Electroencefalograma

Una señal EEG es una medida de las corrientes que fluyen durante las excitaciones sinápticas de las dendritas y de muchas neuronas piramidales en la corteza cerebral [60]. Cuando las células del cerebro son activadas, las corrientes sinápticas son producidas dentro de las dendritas. Esta corriente genera un campo eléctrico medible por equipos de electromiografía (EMG) y un campo eléctrico

sobre el cuero cabelludo medible por sistemas de EEG. El sistema EEG consiste en un número de delicados electrodos, un conjunto de amplificadores diferenciales (uno por cada canal) seguidos por filtros y una aguja que graba los registros. El ancho de banda efectivo de la señal EEG es limitada a aproximadamente 100 Hz, para muchas aplicaciones este ancho de banda puede ser solo la mitad de éste valor. Por tanto, la frecuencia mínima son 200 Hz (para satisfacer el criterio de Nyquist); la cual es a menudo suficiente para el muestreo de las señales EEG. En algunas aplicaciones específicas en donde es requerida una alta resolución para representar las actividades cerebrales en el dominio de la frecuencia, las frecuencias de muestreo suben hasta un valor de 2000 Hz. La representación de cada muestra de la señal con 16 bits es muy popular entre los sistemas de grabación de EEG. Un simple cálculo muestra que en una hora de grabación de una señal electroencefalográfica de 128 canales muestreados a 500 Hz el tamaño en memoria necesario es de $128 \times 60 \times 60 \times 500 \times 16 = 0.45$ GB. Los formatos de grabación de los datos EEG son variables, el European Data Format (EDF) y el CSV son formatos populares entre algunos sistemas BCI. Ahora, comúnmente suelen usarse electrodos en el cuero cabelludo hechos de discos de plata o aleaciones de plata y cloruro de plata, los cuales miden generalmente menos de 3 mm de diámetro, con largos cables flexibles que son conectados al amplificador. La alta impedancia entre la corteza y los electrodos puede conducir a distorsiones de la señal EEG registrada. Para obtener registros de EEG satisfactorios las impedancias de los electrodos deben estar por debajo de 5k. Debido a la estructura capilar y en espiral del cerebro la distribución del potencial sobre el cuero cabelludo, para algunos modelos, puede ser considerada uniforme. Esto puede afectar algunos resultados de localización de fuente usando señales EEG [60].

3.1.4. Posicionamiento convencional de los electrodos de EEG

La “International Federation of Societies for Electroencephalography and Clinical Neurophysiology” ha recomendado una configuración convencional de electrodos (también llamada 10-20) para 21 electrodos, excluyendo los electrodos de los lóbulos de las orejas que son llamados A_1 y A_2 los cuales son los electrodos de referencia y son conectados en los lóbulos izquierdo y derecho de las orejas respectivamente. El sistema 10-20 emplea marcas craneales como puntos de referencia para la localización de los electrodos. En conjunto para examinar la actividad cerebral, suelen emplearse 19 electrodos superficiales distribuidos por la cabeza y los dos electrodos de referencia. Para posicionar los electrodos primero se mide a lo largo de la línea media la distancia entre la unión naso-frontal (N_z : Nasion) y la protuberancia (I_z : inion). El primer punto determina el polo frontal F_p el cual está al 10% de la distancia anterior y justo sobre la unión naso-frontal. Ningún electrodo se aplica sobre este punto de referencia, el cual se utiliza para medidas posteriores. Los puntos de los electrodos frontal F_p , central C_z , parietal P_z y occipital O_z sobre la línea media están separados por el 20% de la distancia entre la unión naso-frontal y la protuberancia occipital medida desde el polo frontal. Mediante esta técnica el electrodo central se localiza en la mitad de la distancia anterior. Un método similar de medida se emplea para posicionar dos filas de electrodos sobre los lados

derecho e izquierdo de la cabeza. Los puntos coronales son marcados midiendo la distancia entre las depresiones justo en frente de cada oreja. Al 10 % de la distancia medida hacia arriba de las depresiones se localizan los electrodos temporales (T_3, T_4), a cada lado de la cabeza. La posición de los nodos centrales (C_3, C_4), se localizan al 20 % de la distancia sobre los puntos temporales. La fila horizontal de posiciones de electrodos más baja se determina midiendo desde el polo frontal a la protuberancia occipital, en este procedimiento se localizan los electrodos F_{p2}, F_8, T_4, T_6 y O_2 para el lado derecho y F_{p1}, F_7, T_3 y O_1 para el lado izquierdo. Los electrodos restantes (F_4, C_4 y P_4 en el lado derecho y F_3, C_3 y P_3 en el izquierdo)son posicionados a lo largo de las líneas equidistantes entre la línea temporal y la línea media a lo largo de las líneas coronarias frontal y parietal respectivamente. Con el sistema 10-20 un número par de electrodos se disponen en en lado derecho e impar en el izquierdo. Los electrodos de la línea media son designados mediante una $Z(F_z, C_z, P_z)$. Existen huecos intencionales en el sistema de notación por subíndices a fin de permitir el uso de otra localización de electrodos, la cual puede ser añadida con el mismo sistem de referencia [4]. También existen técnicas de registros de referencias libres las cuales realmente usan un medio de referencia común; la escogencia de la referencia puede producir distorsión topográfica si la referencia no es relativamente neutral. Existen otros tipos de montaje en donde el sistema 10-20 es modificado para capturar mejor señales provenientes de lóbulos o sectores específicos del cerebro, por ejemplo los sistemas BCI basados en EEG [60]. La figura 3.3 representa un esquema de la convención 10-20. En el estudio de la actividad mental en sistemas BCI a menudo un pequeño número de electrodos alrededor de las regiones relativas al movimiento son seleccionadas usando sistemas con configuraciones 10-20. Por ejemplo, los electrodos C_3, C_4 pueden ser usados para el registro de las señales relacionadas a los movimientos de las manos derecha e izquierda con el fin de utilizar imaginación motora. También los electrodos F_3, F_4, P_3 y P_4 pueden ser usados para registros de la onda P300, o los electrodos O_1, O_2 y O_z para los potenciales visuales evocados.

3.2. Sistemas BCI basados en EEG

Los sistemas EEG-BCI suelen ser clasificados dentro de un grupo específico denominado sistemas no-invasivos. La flexibilidad y la ventaja de no tener que exponer al paciente a riesgos en una intervención quirúrgica cerebral, hacen que este tipo de interfaces sean las más popularmente usadas en las investigaciones con sistemas BCI. Sin embargo, los sistemas basados en técnicas de EEG brindan información limitada principalmente por la existencia de ruido en el sistema de adquisición, interferencia indeseada y los artefactos (señal no deseada dentro del registro EEG). A pesar de estos inconvenientes, los métodos basados en EEG pueden detectar modulaciones de la actividad del cerebro que pueden ser correlacionados con estímulos visuales, ángulos de miradas, intenciones voluntarias y estados cognitivos [60]. Esta ventaja permite desarrollar una gran cantidad de sistemas BCI basados en EEG, los cuales difieren de acuerdo a la cantidad de electrodos que utilizan y su posición, la finalidad, la modalidad sensorial propuesta, entre otras. Ahora bien, se dice

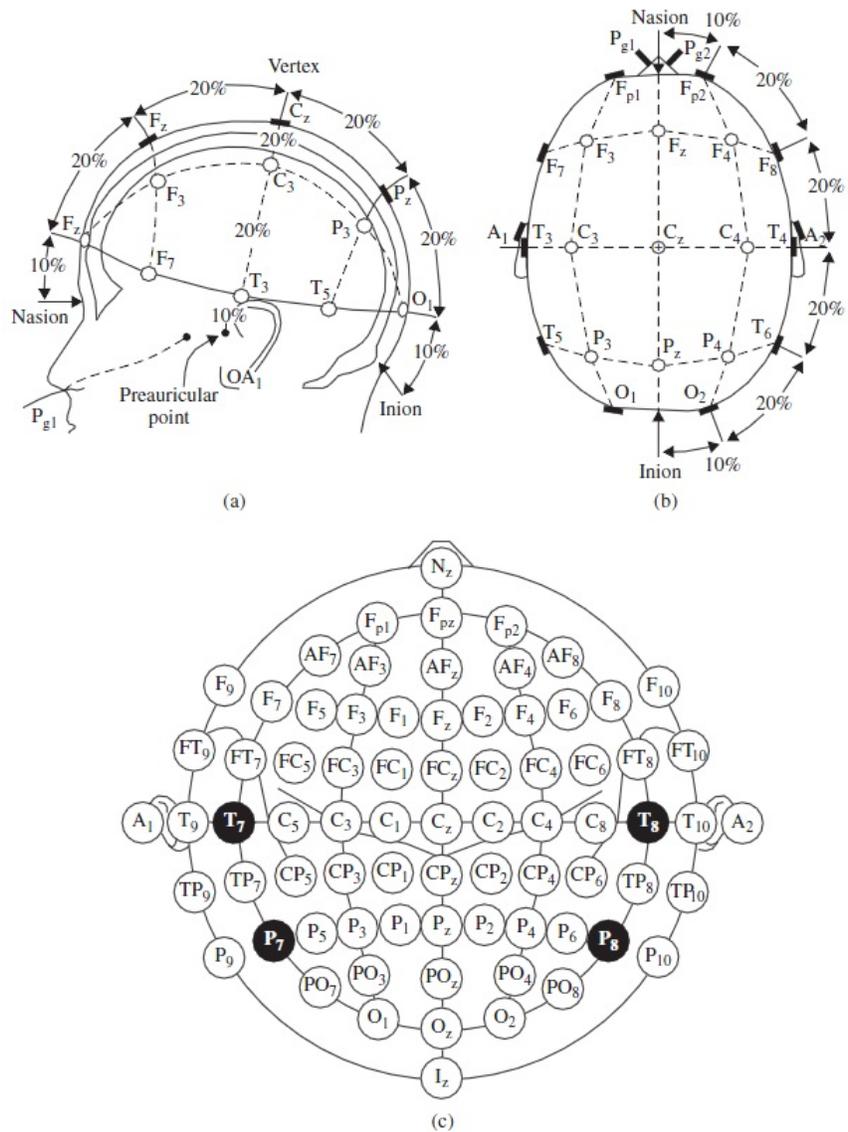


Figura 3.3. Representación diagramática de una configuración de electrodos 10-20. (a) y (b) representan medidas en 3 dimensiones, y (c) indica una vista bidimensional de una configuración 10-20 de 75 electrodos.

que un sistema EEG-BCI es eficiente si explota al máximo toda la información contenida dentro de los registros EEG; en todos los casos la detección y separación de las señales de control de las filas EEG es probablemente el primer objetivo. Señales como la onda P300, los potenciales relacionados a eventos (ERP) y los potenciales evocados (EP) pueden ser separados con alta efectividad y precisión para ser usadas como señales de control; la bibliografía en las diferentes técnicas para realizar estas tareas es extensa y abarca múltiples modelos matemáticos y computacionales para lograr este objetivo [3]. Estas señales son propias de los sistemas de EEG y su estudio ha permitido a la comunidad de investigadores plantearse paradigmas efectivos de interacción con los sistemas BCI que son determinados como efectivos si: pueden caracterizar con precisión a un individuo, pueden fácilmente modular o traducir la intención o expresión mental del usuario y si pueden ser detectados y rastreados de manera consistente y confiable [60]. Uno de los temas centrales de investigación en la EEG que se convierte en un punto de partida para el estudio de los EEG-BCI es la de selección de canales. La idea general detrás de este enfoque está basada en el criterio de eliminación recursiva de canales (RCE por sus siglas en inglés); los canales que son bien conocidos como importantes (desde el punto de vista psicológico de un estudio en particular) son consistentemente seleccionados mientras que los canales irrelevantes son descartados. Generalmente muchos de los enfoques en las investigaciones de los sistemas EEG-BCI utilizan una técnica denominada neurofeedback o neurorealimentación [75]. Esta técnica consiste en dar realimentación a los procesos internos del cuerpo a través de señales visuales y auditivas, es toda una disciplina científica que permite entrenar el cerebro para mejorar y autorregular de una manera voluntaria la actividad involuntaria del mismo.

Es posible mejorar la actividad oscilatoria del EEG de un paciente a través del uso de estrategias mentales de entrenamiento como la imaginación motora o la atención selectiva. Las herramientas computacionales especializadas son entrenadas para el reconocimiento de patrones EEG asociados a una estrategia mental en particular, esto indica entonces, que los dos sistemas (hombre y máquina) tienen que ser adaptados el uno al otro simultáneamente de forma no generalizada para mantener resultados óptimos. Posteriormente, la aplicación de técnicas de aprendizaje de máquina realiza el proceso de clasificación, en el cual, usando clasificadores especializados, el computador aprende a detectar con precisión y en tiempo real, las intenciones mentales del usuario. Usualmente y debido a la alta complejidad del pensamiento humano, los patrones EEG suelen cambiar. Por esta razón, la generación de realimentación EEG apropiada requiere el ajuste dinámico del clasificador o de los parámetros de realimentación [8]. Existen dos formas de analizar los cambios en la actividad eléctrica de la corteza que acompañan las actividades cerebrales: la estimulación sensorial y el comportamiento motor. La primera tiene seguimiento de tiempo y seguimiento de fase (en inglés *time-locked* y *phase-locked*), los cuales son términos referentes a un sistema de control que genera una señal de salida cuya fase está relacionada con la fase de una señal de referencia de entrada; o sea, permiten expresar que existe una relación en tiempo y en frecuencia entre los estímulos sensoriales y los potenciales evocados; estas señales pueden ser extraídas de la actividad cerebral en curso

mediante métodos lineales simples. La segunda, el comportamiento motor, solo tiene seguimiento de tiempo y no de fase y sólo puede ser extraída mediante algún método no-lineal. La estimulación sensorial está ligada a la generación de potenciales relacionados a eventos y el comportamiento motor está relacionado a los ritmos sensoriomotores, los cuales son explicados a continuación.

3.2.1. Potenciales relacionados a eventos (ERP)

Los ERPs son potenciales electrocorticales que pueden ser medidos por el EEG antes, durante y después de un evento sensorial, motor o psicológico. Tienen un tiempo de retardo fijo según el estímulo presentado y su amplitud es usualmente mucho más pequeña que la actividad espontánea electroencefalográfica. Las amplitudes son pequeñas porque los ERPs están localizados en áreas corticales específicas, también, estos potenciales son menos frecuentes que las ondas EEG espontáneas con forma y amplitud similar [76]. Las componentes de estos potenciales son distinguidas por las localizaciones en partes específicas del cerebro y por sus latencias. Las componentes tempranas con latencias ≤ 100 ms se originan en gran medida en las cortezas sensoriales primarias y se determinan principalmente por las propiedades del estímulo que las evoca. Posteriormente, componentes de ERP con latencias entre 100 y 500 milisegundos reflejan en mayor medida los procesos en desarrollo del cerebro, son originados en áreas corticales asociadas con procesamientos más complejos. Los potenciales con las latencias más extensas o potenciales corticales lentos (SCPs por sus siglas en inglés) tienen latencias por encima de muchos segundos o a veces minutos que reflejan respuestas orientadas de la actividad cerebral. Si bien es probable que muchos tipos de ERPs podrían ser útiles para los sistemas BCI, sólo unos pocos se han utilizado con éxito hasta el momento [3].

Señal P300

La señal P300 es una deflexión positiva de voltaje con una latencia de 300 ms en el electroencefalograma en respuesta a un estímulo auditivo, visual o somatosensitivo [3], o sea, la señal aparece aproximadamente 300 ms después del estímulo y es medida en la corteza centroparietal. Es típicamente observado cuando a los participantes se les pide atender a un estímulo de prueba presentado dentro de un intervalo de frecuencias establecido. En un sistema BCI basado en la onda P300 (P300- BCI) el usuario es expuesto a una serie de estímulos; cada uno de los cuales representa una salida en particular (por ejemplo deletrea una letra en particular), el usuario tiene que prestar atención al estímulo que representa la acción que se desea controlar. El estímulo atendido provoca una onda P300 y el otro estímulo no (ver figura [59]). El sistema BCI reconoce la P300 y entonces ejecuta la salida especificada mediante el estímulo provocado, lo que a menudo requiere que el usuario module su atención en lugar que cualquier salida muscular.

Una de las aplicaciones más usadas de la onda P300 es en deletreadores [30]. El usuario es expuesto a una matriz de letras y símbolos; mediante un centelleo o un cambio de intensidad de las letras de

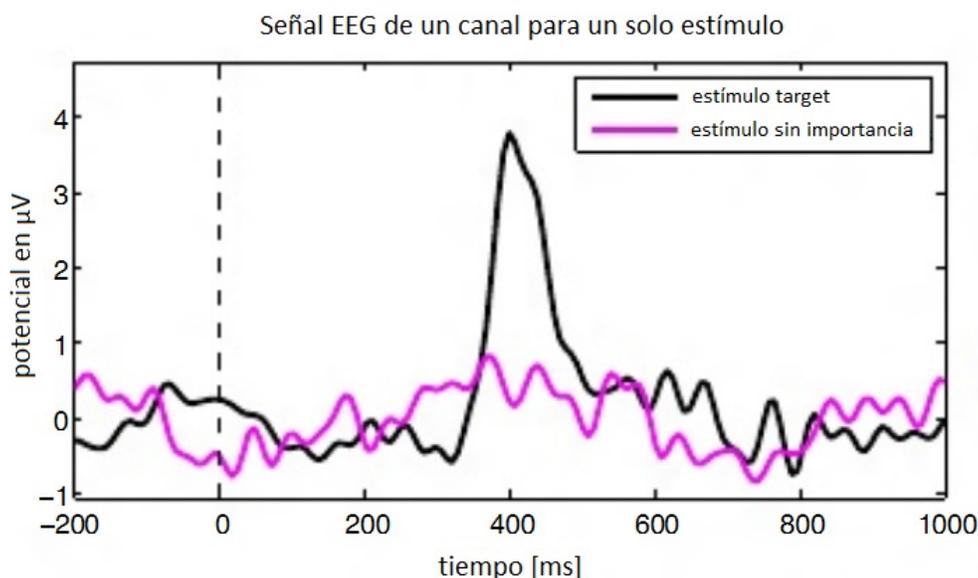


Figura 3.4. Apariencia clásica de una onda P300 generada por un estímulo visual.

la matriz, el usuario fija su atención en la letra o símbolo que desee manifestar, en el momento en el que la letra esté resaltada, una onda tipo P300 aparecerá en la zona centroparietal del EEG indicando que ese estímulo causó una reacción particular en el usuario. Este tipo de interacción si bien es un poco lenta, puede producir precisiones muy altas en sistemas BCI, debido a esto muchos grupos de investigación han explorado múltiples variaciones en la presentación de los estímulos [77]. Para la clasificación de estas señales suelen utilizarse clasificadores lineales como el LDA (Análisis Discriminante Lineal) ó el SWLDA (LDA escalonado); clasificadores bayesianos o gaussianos. También la onda P300 ha sido usada para elaborar detectores de mentiras, aplicaciones en domótica, buscadores web basados en detección de P300, entre otros.

Potenciales Evocados Visuales de Estado Estacionario

Los potenciales evocados visuales (VEPs) son los ERPs más estudiados. Estos potenciales evocados reflejan la información visual procesada través de la vía visual y la corteza visual primaria del cerebro [78]. Después de un estímulo (por ejemplo una animación en una pantalla de un ordenador), los potenciales evocados pueden ser registrados desde la corteza visual en el lóbulo occipital (O1, O2, Oz). Un potencial evocado se transforma en estacionario si la tasa de presentación del estímulo está por encima de 6 Hz. La amplitud y la fase de los SSVEP dependen de los parámetros del estímulo como la tasa de repetición y el contraste. La resolución de frecuencia de los SSVEPs es 0.2 Hz y el ancho de banda en el cual pueden ser detectados de manera confiable está entre 6 y 24 Hz [76]. Al igual que la onda P300, los sistemas BCI basados en SSVEPs (SSVEP-BCI)

requieren atención y una mirada fija y no es necesaria una fase de entrenamiento extensa. Para obtener los SSVEPs suelen utilizarse los estímulos proyectados en un ordenador o en una pantalla. El número de órdenes u objetivos que se pueden lograr varía entre 4 y 48 [76]. Los SSVEP tienen tres componentes distintivas: una componente primaria ubicada en la gamma banda (25-60 Hz), con poca variabilidad inter-individuos y una latencia de 30-60 ms, una componente secundaria en el rango de 15-25 Hz con alta variabilidad entre individuos y latencias comprendidas entre 85-120 ms y finalmente una componente rítmica abajo de los 15 Hz con una latencia promedio de 250 ms. El paradigma de utilizar SSVEP para manejar BCI fue introducido por Regan en 1979, la idea fue controlar interfaces de botones con potenciales evocados visuales [79]. La robustez de los sistemas SSVEP-BCI controlados por estímulos externos visuales se ha venido constituyendo como una herramienta más controlable para la aplicación de estas interfaces ya que su cociente señal/ruido lo hace cada vez más fiable. Una de las deficiencias o excepciones que presentan los sistemas SSVEP-BCI es la dependencia con la capacidad visual del usuario, se requiere que las capacidades de mirar, mover los ojos y fijar la vista estén intactas para lograr la interacción requerida.

Existen dos mecanismos fisiológicos sobre los cuales se basan los sistemas SSVEP-BCI. El primero es llamado “Photic Driving Response” (respuesta de conducción), la cual es caracterizada por un incremento en la amplitud a la frecuencia del estímulo; en la señal electroencefalográfica esta conducción aparece en forma de picos de amplitud a estas frecuencias. El segundo es el efecto de magnificación central, en donde se asignan grandes superficies de la corteza visual para procesar el centro de nuestro campo de visión y entonces la amplitud de los SSVEPs incrementan enormemente debido a que el estímulo es movido cerca a la zona central del estímulo visual [78]. Por estas dos razones los diferentes patrones SSVEP pueden ser producidos mediante la mirada de un número determinado de estímulos a una frecuencia dada. La figura 3.5 muestra un teclado numérico virtual que permite establecer los estímulos visuales de dos números mostrados a diferentes frecuencias, el resultado, es una concordancia directa (o armónica) de la generación de los potenciales visuales con la frecuencia de latencia del estímulo.

Ahora bien, a través del sistema Emotiv EPOC, son varios los estudios realizados en donde se explota la existencia de los electrodos O1 y O2 en el arreglo del dispositivo, para capturar los SSVEPs [80]. Estos estudios reflejan el potencial que tienen las aplicaciones BCI gobernadas por la estrategia mental de atención selectiva, específicamente la que relaciona el uso de estímulos visuales y detección de potenciales evocados visualmente. En estos estudios se reflejan precisiones hasta del 80 % en la interacción con las aplicaciones; la “Cognitive Suite” del sensor permite realizar entrenamiento a través de estímulos visuales particulares, en este caso, son animaciones en donde el usuario tiene que fijar su atención para grabar las reacciones en la señal EEG después de visualizar el estímulo en una pantalla.

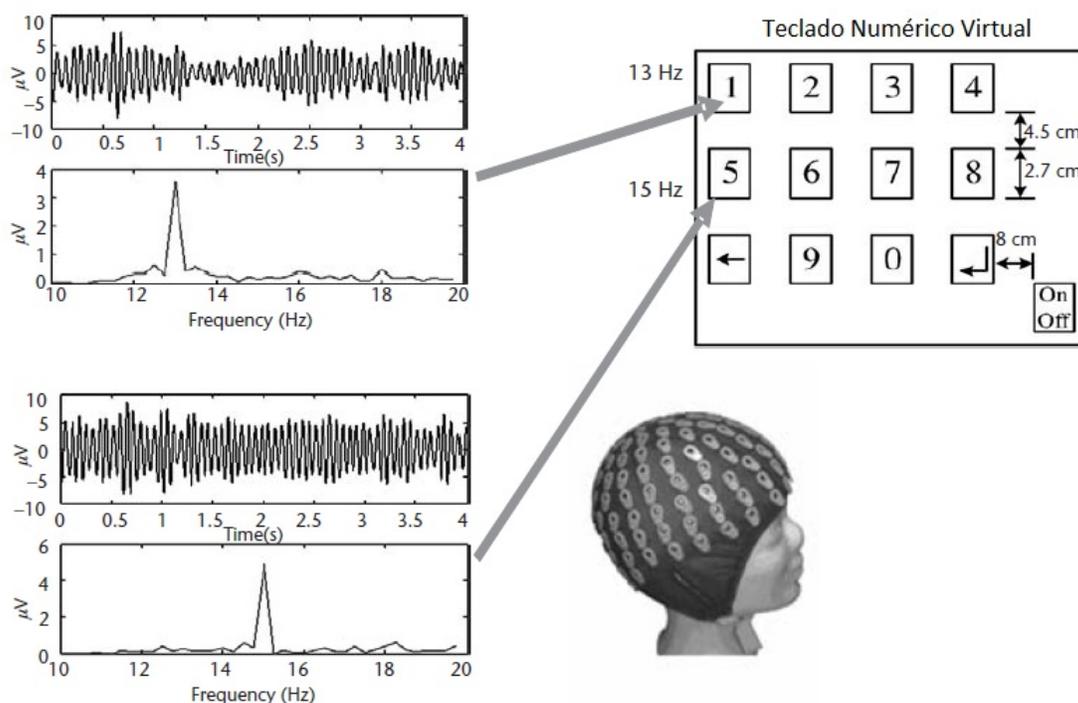


Figura 3.5. Principio de funcionamiento de los sistemas BCI basados en SSVEP.

3.2.2. Bandas de Frecuencia

En personas despiertas relajadas, la señal EEG grabada sobre las áreas corticales primarias sensoriomotoras se muestra una actividad con frecuencia aproximada de 8-12 Hz (ritmos mu) y 12-30 Hz (ritmos beta). Estas bandas de frecuencia comprenden una variedad de ritmos diferentes que son distinguidos por su localización, frecuencia y/o relación con entradas o salidas sensoriales concurrentes. A continuación se muestra un pequeño resumen [81]:

- **Ritmos Alfa (7.5 Hz - 12.5 Hz):** ellos aparecen espontáneamente en adultos normales despiertos, en estado de relajación y en condiciones de inactividad mental. Son más fácilmente detectables con los ojos cerrados y más pronunciados en las localizaciones occipitales.
- **Ritmos Beta (12.5 Hz - 30 Hz):** ellos están mejor definidos en las localizaciones central y frontal, con menor amplitud que las ondas alfa. Estos ritmos se realzan sobre cálculos mentales, estados de expectación o tensión sobre toda la superficie del cuero cabelludo.
- **Ritmos Theta (3.5 Hz- 7.5 Hz):** son típicos durante estados de sueño profundo. Estos ritmos juegan un importante rol en la infancia y en la niñez. En adultos despiertos, altos niveles de actividad theta son considerados anormales y relacionados a desórdenes mentales como la

epilepsia.

- Ritmos Delta (0.5 Hz - 3.5 Hz): son característicos también de estados de sueño profundo. Dependiendo de su morfología, localización y ritmicidad, las oscilaciones delta puede ser normales como en las ondas suaves del sueño o patológicas como en presencia de tumores cerebrales.
- Gamma bajos (30 Hz- 60 Hz): de un menor interés desde los 90s, las oscilaciones gamma se volvieron muy populares después de haber sido propuestas propuesto para jugar un papel importante en la vinculación de las características de estímulo en una sola percepción. Muchos trabajos han mostrado correlaciones de la actividad gamma con diferentes procesos sensoriales y cognitivos, notablemente durante la percepción olfativa, auditiva, visual o somatosensorial.
- Ritmos Gamma altos (80 Hz - 120+ Hz): a menudo llamado ritmos epsilon, han sido encontrados en humanos y animales con ECoG en asociación con potenciales de acción mientras el individuo está hablando.

Algunos ritmos beta son armónicos de los ritmos mu, mientras otros son separados de los ritmos mu por su topografía y características temporales. Por muchas razones los ritmos SMRs son una muy buena señal para plantear experimentos neurocientíficos con sistemas BCI. Estos ritmos están asociados con áreas corticales que están más directamente conectadas a las salidas neuromusculares directas del cerebro. Movimientos o imaginaciones de movimientos están usualmente acompañados por decrementos en los ritmos SMRs, especialmente contralaterales al movimiento. Este decremento ha sido definido como un “Evento relacionado a de-sincronización” o ERD. De forma antagónica, el incremento de los ritmos o un “Evento relacionado a una sincronización” ocurre justo después del movimiento y con la relajación [3]. Tanto los ERD como los ERS no requieren movimiento “real” estas señales pueden ocurrir con imaginación motora, la cual es una estrategia mental muy usada para la interacción con sistemas BCI. Los patrones ERD/ERS producidos por la imaginación del movimiento son similares en su topografía y comportamiento espectral a los del movimiento real. Una de las cuestiones más discutidas por la comunidad BCI es si los usuarios pueden producir de forma controlada, continua y sostenida los ERD/ERS, los cuales pueden ser vistos como estados estacionarios de la imaginación del movimiento (análogo a los SSVEP). En [82] se encuentra un listado de los electrodos que están en el área sensoriomotora, estos constituyen el conjunto óptimo de electrodos en un sistema BCI-EEG con estándar 10-20 para el trabajo con la estrategia mental de imaginación motora: FC5, FC3, FC1, C5, C3, C1, CP5, CP3, CP1, FC2, FC4, FC6, C2, C4, C6, CP2, CP4, CP6. En general, de 8-36 electrodos son necesarios para mantener exactitudes mayores al 90 % con clasificadores como el de determinante de Fisher o las máquinas de soporte vectorial los cuales son mencionadas en el capítulo de aprendizaje de máquina.

Eventos Relacionados a Sincronizaciones (ERS)

El incremento en la actividad de los SMRs en el periodo después del movimiento, la imaginación del movimiento o la relajación es relacionado a un evento de sincronización. A menudo, los sistemas BCI basados en la generación de ERS para la interacción son llamados BCI síncronas [83]. Los ERSs son los fenómenos opuestos a los ERD y están relacionados con la reacción póstuma por parte del usuario al acontecimiento. En este caso el realce de la amplitud se basa en la cooperación o el comportamiento sincronizado de una gran cantidad de neuronas. Cuando los eventos sinápticos sumados llegan a ser suficientemente grandes, los potenciales se pueden registrar no sólo con técnicas invasivas o electrodos implantados, sino también, con electrodos superficiales sobre el cuero cabelludo, aunque la producción de ondas mu en el EEG necesitan actividad coherente de los conjuntos de células por lo menos en varios centímetros cuadrados. Los ERSs son considerados una señal cerebral con relativamente buena relación señal/ruido en el EEG superficial y son producidos en el primer segundo después de la terminación de un movimiento voluntario o la imaginación del movimiento, cuando el ritmo mu aún exhibe un patrón desincronizado de baja amplitud. La señal ERS beta relativa al post-movimiento presenta las siguientes características [84]:

- El ERS beta tiene una organización somatotópica (esto significa que porciones determinadas de estructuras del Sistema Nervioso Central se asocian a determinadas áreas topográficas del cuerpo).
- El ERS beta es más perceptible con el movimiento de la mano comparado con el movimiento del dedo.
- El ERS beta se encuentra no sólo después de haber ejecutado realmente un movimiento sino también, después de un movimiento imaginado.
- El máximo del ERS coincide con una excitabilidad reducida de las neuronas de la corteza motora.

El ERS post-movimiento es un fenómeno relativamente consistente y se encuentra en casi cada sujeto después del movimiento de los dedos, de la manos, de los pies y de la lengua, según el espacio sensorial relativo a nuestras partes corporales representadas en la corteza cerebral.

Eventos Relacionados a Desincronizaciones

Los ritmos de la banda alfa muestran una desincronización relativamente extensa en tareas de percepción, juicio y memoria. Un aumento de la complejidad o de la atención a la tarea resulta en una magnitud creciente de ERD, el cual a propósito, está medido en porcentaje de la energía concerniente al intervalo de la referencia y por lo tanto depende de la cantidad de actividad rítmica en ese intervalo. Esa desincronización de la banda alfa no es un fenómeno unitario: si diferentes

bandas de frecuencia dentro de la gama de la banda alfa extendida son distinguidas, por lo menos dos patrones distintos de desincronización alfa pueden ser observados. Una desincronización de las frecuencias alfa más bajas (aproximadamente 7-10 Hz) se obtiene en respuesta a casi cualquier tipo de tarea. Su distribución topográficamente amplia en extensas áreas del cuero cabelludo refleja probablemente las demandas generales de la tarea y procesos de atención. La desincronización alfa superior (ritmo mu) muy a menudo se restringe topográficamente y se desarrolla durante el procesamiento de la información sensorial semántica sobre las áreas parieto-occipitales [85]. Los movimientos voluntarios resultan en una desincronización circunscrita en el alfa superior (mu) y las bandas beta más bajas, localizadas cerca de áreas sensoriomotoras [3]. Esta desincronización comienza cerca de 2 segundos antes del inicio del movimiento sobre la región de Rolando contralateral y llega a ser simétrica bilateral inmediatamente antes de la ejecución del movimiento. Un ERD se puede interpretar como un correlato electrofisiológico de las áreas corticales activadas implicadas en proceso de la información sensorial, cognitiva o de producción de comportamiento motor. Un ERD creciente y/o más extenso podría ser el resultado de la implicación de una red de neuronas más grande o de más conjuntos de células en el procesamiento de la información. Los factores que contribuyen a tal realce del ERD son la complejidad creciente de la tarea, un funcionamiento más eficiente de la tarea y/o más esfuerzo y atención, así como el Coeficiente Intelectual del individuo. El aprendizaje explícito de una secuencia de movimiento, por ejemplo, presionar con diferentes dedos, es acompañado por un realce del mu ERD sobre las regiones centrales contralaterales. Una vez que se ha aprendido la secuencia del movimiento y el movimiento se realiza de forma más automática o secuencial, se reduce el ERD. Estos resultados sugieren fuertemente que la actividad en áreas sensorio-motoras primarias aumenta en asociación con el aprendizaje de una nueva tarea motora y que disminuye después de que se haya aprendido.

3.3. Acondicionamiento de la señal EEG

La señal electroencefalográfica se caracteriza por tener un rango de amplitud del orden del centenar de microvolts y un rango de frecuencia comprendida entre los 0.4 Hz y los 60 Hz, sin embargo el rango de frecuencia más común detectado en condiciones de conciencia se presenta entre los 4 Hz a 25 Hz [59]. Tras pasar por una etapa de amplificación, la señal EEG filtrada mediante un filtro analógico, aplicando, según sea el caso, filtros rechaza banda tipo Notch sintonizado a 60 Hz, como filtros pasa altos que eliminan todas aquellas componentes frecuenciales menores a unos 0.4 Hz. Generalmente el filtro rechaza banda minimiza el ruido y artefactos electromagnéticos causados por la red de suministro eléctrico y por las redes inalámbricas que suelen también entorpecer la transmisión de la señal; mientras que el filtro pasa alto minimiza artefactos de acoplamiento superficial entre el electrodo y la epidermis del cuero cabelludo en la zona de disposición de los electodos. En los sistemas BCI comerciales como el Emotiv EPOC, parte del proceso de acondicionamiento de la señal se realiza en el dispositivo y las señales, que son

transmitidas de manera inalámbrica, llegan al ordenador filtradas análogamente listas para iniciar un proceso de filtrado digital más riguroso. Esta digitalización de la señal EEG es necesaria para las siguientes fases del ciclo de una aplicación BCI, en donde la identificación y clasificación de patrones asociados a actividades cognitivas se presenta como el objetivo cumbre. El proceso de digitalización comprende tanto el muestreo como la cuantificación y la codificación de la señal, la cual es transmitida hacia el ordenador mediante múltiples protocolos de comunicación; las BCI modernas integran protocolos inalámbricos como el “BlueTooth” y “Wi-Fi” para brindarle libertad y comodidad al usuario. Estos aspectos suelen tener una especial importancia en las etapas de entrenamiento del usuario, en donde la comodidad del usuario juega un rol importante en su capacidad de concentración y atención para lograr un entrenamiento óptimo [78]. Generalmente en las aplicaciones BCI a esta etapa se le conoce como preprocesamiento, la cual en resumen, busca simplificar al máximo las operaciones subsecuentes de procesamiento con la menor pérdida de información relevante. Uno de los objetivos importantes del preprocesamiento es mejorar la calidad de la señal mediante el mejoramiento de la relación señal-ruido (SNR por sus siglas en inglés). Una mala o pequeña SNR indica que los patrones cerebrales van a estar escondidos en el resto de la señal (ej. señal de fondo EEG), lo cual hace que los más relevantes sean difíciles de detectar. Por el contrario, una buena o grande SNR simplifica la detección y clasificación de tareas en el desarrollo de la aplicación BCI [3]. Diferentes tipos de transformaciones combinadas con técnicas de filtrado son a menudo empleadas durante el preprocesamiento en un sistema BCI; los investigadores suelen usar estas técnicas para poder transformar y diferenciar las componentes no deseadas de la señal para que puedan ser eliminadas o al menos reducidas. Se utilizan filtros temporales pasa bajos y pasa bandas para restringir las bandas de frecuencia en las cuales conocemos que hay actividad neurofisiológica, por ejemplo se usa la banda 8 Hz - 30 Hz que contiene ritmos sensoriomotores; para este tipo de filtros se utiliza la transformada rápida de Fourier. Se utilizan también, filtros espaciales para escoger la información relevante que se encuentra en algunos de los canales del sistema BCI, por ejemplo, el “Surface Laplacian” realiza asignaciones de peso a cada canal, lo cual permite darle mayor importancia a algunos canales que a otros. Finalmente, el uso de filtros temporo-frecuenciales (ej. Wavelets, Short Time Fourier Transform) poseen una ventaja sobre los demás filtros y es que permiten la rápida captación de variaciones de la señal sin perder de vista el comportamiento frecuencial y la no estacionariedad de las señales de los sistemas BCI [78].

3.3.1. Análisis Frecuencial

En el primer reporte de grabaciones de EEG humana, Hans Berger notó la presencia de diferentes oscilaciones cerebrales. En particular, él reportó actividad rítmica alrededor de 10 ciclos por segundo, más pronunciado en los electrodos occipitales con los ojos cerrados. Estas oscilaciones, las cuales son llamadas ritmos alfa, fueron disminuyendo dramáticamente por el flujo de la luz con los ojos abiertos. Este efecto es lo que se conoce como el bloqueo alfa y es uno de los más dramáticos y

simples demostraciones de cómo el EEG refleja los procesos cerebrales. Berger también describió la actividad oscilatoria en altas frecuencias, las cuales son llamadas ritmos beta. Después de todo el trabajo de Berger, han sido estudiadas las diferentes oscilaciones EEG y sus correlaciones con los estados mentales, funciones y patologías, en especial después de la introducción de los registros digitales y la transformada rápida de Fourier [81]. Basados principalmente en sus funciones y localizaciones, las oscilaciones EEG han sido agrupadas dentro de bandas de frecuencia (ver sección ritmos sensoriomotores). La figura 3.6 muestra un registro EEG de 20 segundos y su correspondiente potencia espectral. Las líneas verticales marcan los límites de las frecuencias EEG estándar:

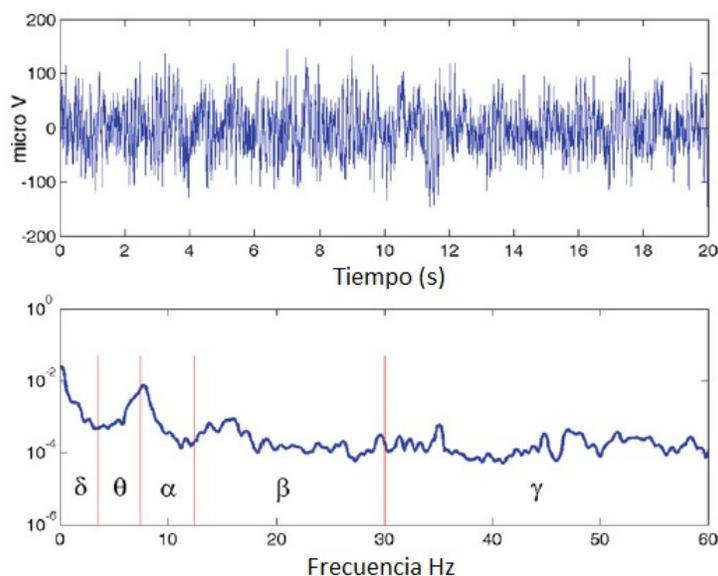


Figura 3.6. Frecuencia de bandas de EEG.

El análisis frecuencial a través de la transformada rápida de Fourier (FFT) ha sido ampliamente usado para la cuantificación de la actividad EEG [78], [81], sin embargo las tres limitaciones principales que presentan son:

- La Transformada de Fourier requiere estacionariedad de la señal. Para el propósito de estimar el espectro de potencia, la señal EEG puede ser considerada como cuasi-estacionaria solo en unos pocos segundos. Obviamente, la Transformada de Fourier tampoco resulta adecuada para el análisis de respuestas transitorias como en el caso de los potenciales evocados.
- La Transformada de Fourier es muy precisa para la caracterización de la composición frecuencial de la señal, pero no brinda información temporal de la misma, esto es por supuesto relacionado al problema de la estacionariedad; por éste motivo entonces se justifica el uso de métodos de variación temporal, como la transformada de Fourier de tiempo reducido, los Wavelets o la transformada de Hilbert.

- La Transformada de Fourier no es óptima para caracterizar señales no lineales. Patrones no lineales como los picos epilépticos son representados en el dominio de Fourier como una combinación compleja de diferentes frecuencias con precisas relaciones de fase. En realidad solo se mira el espectro de potencias y se descarta la información de fase, la naturaleza no lineal de la señal es perdida. Sin embargo, si se decide mantener las fases, describiendo los picos como una suma de senos con cierta relación de fase se transforma en algo de difícil manejo y otros métodos como los Wavelets son preferidos.

Finalmente, debido a que los patrones EEG son ampliamente variables y complejos, una inspección visual es aún, uno de las formas preferidas por los expertos electroencefalografos de analizar registros EEG. Esto más un arte que una ciencia exacta y requiere de años de entrenamiento. Ahora, el uso de mapas topográficos data de más de 30 años atrás, estas representaciones gráficas permiten una previsualización de aspectos como asimetrías y la localización de la actividad en las diferentes bandas de frecuencia. No son más que imágenes de la actividad cerebral en un momento en particular, estas imágenes texturizadas son formadas por la modulación de la amplitud y de la fase (AM y FM) de las ondas portadoras espacialmente coherentes del rango beta.

3.3.2. Análisis Temporo-Frecuencial

Las deficiencias de análisis temporal de la Transformada de Fourier para el caso de las señales de interfaces cerebro computador basadas en EEG, se enmarcan como una deficiencia crítica cuando se analizan procesos que cambian en el tiempo, como la respuesta a estímulos particulares o el desarrollo de una crisis epiléptica. Intuitivamente, podemos superar el problema de la resolución temporal de la Transformada de Fourier mediante la segmentación o el corte de los datos en piezas y entonces calcular el espectro de potencias para cada pieza, o aún mejor, mediante el uso de una ventana de tiempo envolvente que enfoque diferentes segmentos de datos. Con el fin de evitar la pérdida de información, podemos reducir el tamaño de la ventana con una función apropiada. Este procedimiento es llamado la Transformada de Fourier de Tiempo Reducido (STFT: short-time fourier transform) y en [81] se encuentra una explicación matemática completa. Con la STFT es posible seguir la evolución temporal de las diferentes frecuencias y el requerimiento de estacionariedad es satisfecho mediante la consideración que las señales son cuasi-estacionarias dentro de cada ventana. Sin embargo la escogencia del tamaño de la ventana resulta tener un grado de complejidad considerable: si la ventana es demasiado angosta, esto brindará una buena resolución en el eje del tiempo pero las frecuencias no estarán bien establecidas (la resolución de frecuencia es inversamente proporcional a la longitud del dato). Si por el contrario la ventana es demasiado grande tendremos una buena resolución de frecuencia pero la localización en el tiempo se habrá perdido. Aquí hay una compensación entre la frecuencia y el tiempo. En analogía al principio de incertidumbre de Heisenberg en mecánica cuántica, para este caso se utiliza el principio de incertidumbre del análisis de la señal: la resolución de la frecuencia y el tiempo no pueden ser hechas

pequeñas al mismo tiempo. En otras palabras, una localización muy focalizada en el tiempo y en la frecuencia son mutuamente excluyentes porque necesitamos muchos puntos de datos para definir la frecuencia. Esta limitación se convierte en algo importante cuando la señal tiene componentes transitorias localizadas en el tiempo, como es el caso de la actividad EEG de potenciales evocados tan usados en las estrategias mentales para la interacción con sistemas BCI. Para el análisis gráfico de este tipo de transformada se utilizan los espectrogramas (mapas tiempo-frecuencia), que son representaciones frecuenciales de la señal y su evolución en el tiempo; aunque los espectrogramas brindan una elegante representación visual, esta información es aún cualitativa. Para cuantificar la distribución de frecuencias dado un tiempo particular, o sea para ver su evolución, nosotros podemos calcular la entropía del espectro de potencias. La entropía es una medida de la aleatoriedad, o en otras palabras, la información contenida de una señal. Al contrario, en las señales ordenadas se pueden realizar predicciones de nuevos puntos a partir de valores previamente calculados y por lo tanto tenemos menos información. Finalmente, para señales con información relevante en diferentes rangos de frecuencia, como en el caso de los potenciales evocados, una simple ventana puede no ser óptima para el espectro de potencias completo. Idealmente, nos gustaría establecer diferentes tamaños de ventanas para diferentes rangos de frecuencia y esto es exactamente lo que hacen las Wavelets [81].

3.3.3. Análisis Espacial

En los métodos que miden las señales eléctricas del cuero cabelludo o dentro de la cabeza, la cantidad medida es diferencia de potencial eléctrico (en volts) entre dos electrodos y la señal de voltaje obtenida es comúnmente referida como canal. Cada canal refleja los campos eléctricos producidos por fuentes cerebrales próximas y generalmente, refleja también información no-cerebral (actividad muscular, artefactos de 60 Hz, etc.). La sensibilidad de un canal a diferentes fuentes cerebrales depende de los tamaños y orientaciones de las fuentes en relación a las localizaciones de los dos electrodos del canal. Así pues, mediante una apropiada selección de los pares de electrodos que comprenden cada canal, es posible hacer que cada canal sea más sensitivo a ciertas fuentes y menos sensitivo a otras. Si todos los canales de registro tienen un electrodo en común, es posible reconstruir cualquier conjunto de canales alternos deseado mediante un ponderado y combinación de canales después de la digitalización. A este procedimiento se le conoce como filtrado espacial [47]. El electrodo común llamado “electrodo de referencia” es usualmente puesto en una localización que es relativamente inactiva o insensible, con respecto a la actividad cerebral. Los filtros espaciales son generalmente creados para mejorar la sensibilidad a fuentes cerebrales particulares, para mejorar la localización de fuentes y/o eliminar ciertos artefactos. Más comúnmente, los filtros espaciales son seleccionados como combinaciones lineales (suma de pesos) de los canales y pueden ser representados en forma matricial como $Y = WX$, donde cada columna de el vector X consiste en una cantidad de muestras consecutivas P de uno de los canales N ; cada

columna de W es un conjunto de pesos de N canales que constituye un filtro espacial, y cada columna de Y es un resultado de una señal filtrada espacialmente. Existen muchos enfoques para determinar el conjunto pesos del filtro espacial W . Estos enfoques tienen dos ramas: filtros espaciales dependientes de los datos e independientes de los datos [47]:

- Filtros espaciales independientes de los datos: típicamente utilizan relaciones geométricas fijas para determinar los pesos del filtro espacial, entonces no dependen de que los datos sean filtrados. Estos filtros tienen ciertas características globales o locales, que aunque son algo genéricos, pueden ser extremadamente efectivos en muchas aplicaciones. En [86] se presentan los valores apropiados del filtrado espacial dependiente de los datos para sistemas BCI. Existen dos muy conocidos: referencia promedio común (CAR) y el filtrado espacial de superficie laplaciana (pequeña y grande). El CAR es realizado de acuerdo a una grabación de todos los canales con una referencia en común, realizando un cálculo de cada punto de tiempo del promedio global para todos los canales digitalizados y finalmente se realiza una resta de la media de cada canal individual. Este método tiene a reducir el impacto de los artefactos que son similares entre todos los canales (ejemplo: señales 60 Hz provenientes de la línea de energía eléctrica). Los filtros espaciales de superficie laplaciana son basados en el cálculo computacional de la segunda derivada espacial. Si los canales han sido registrados con una referencia común, este cálculo es efectivamente equivalente al de tomar un canal central de interés y restar la media de todos los canales de cierta distancia radial fija desde este canal central.
- Filtros espaciales dependientes de los datos: en contraste a los filtros generalizados independientes de los datos, los filtros espaciales dependientes de los datos son derivados directamente de los datos BCI tomados de cada usuario. Aunque estos filtros tienden a ser más complejos en términos de la derivación y la geometría espacial, ellos pueden producir resultados más precisos para ciertas aplicaciones. Estos filtros suelen ser particularmente útiles cuando hay poco conocimiento acerca de las características exactas de la actividad cerebral relevante. Tres de los métodos computacionales más utilizados para derivar los filtros espaciales dependientes de los datos son i) el análisis de componentes principales (PCA), ii) el análisis de componentes independientes (ICA) y iii) los patrones espaciales comunes (CSP).

3.4. BCI Híbridas

A pesar de los impresionantes avances en la industria de los sistemas BCI, la diversificación de productos y la globalización en esta área de la neurociencia; el estado de arte en las múltiples aplicaciones demuestra que la interacción efectiva con las aplicaciones BCIs y el control de dispositivos de asistencia no suele mantenerse por largos periodos de tiempo sin la ayuda de una asistencia de un experto [87]. Esta afirmación no pretende deslegitimar el formidable momento por

el cual está pasando esta tecnología, simplemente busca acercar la comunidad BCI entorno a una posible solución: usar los sistemas BCIs como un canal de entrada adicional para la aplicación. Una hibridación en donde se realiza una combinación de múltiples señales incluyendo al menos un canal BCI es llamada una BCI híbrida (hBCI). La convergencia de señales provenientes de los sistemas BCI con otras bioseñales, por ejemplo, datos de electromiografía (EMG) o señales biomecánicas particulares obtenidas a través de sistemas de captura de movimiento (MoCap), pueden permitir un control más estable y duradero de una aplicación o un dispositivo. Como variables adicionales de entrada pueden usarse señales electrocardiográficas (ECG), o señales externas de otros dispositivos de control como cámaras, sensores de proximidad, acelerómetros, pulsioxímetros u otros sensores electrónicos. En [88] proponen cuatro criterios de funcionamiento que deben cumplir la hBCI:

- Directo: el sistema debe depender de la actividad grabada directamente del cerebro.
- Control Intencional: debe existir al menos una señal cerebral grabable, la cual puede ser intencionalmente modulada para ser usada como una señal de entrada BCI (potenciales eléctricos, campos magnéticos o cambios hemodinámicos cerebrales).
- Procesamiento en tiempo real: la señal procesada debe darse (ocurrirse) en línea y producir una señal de comunicación o de control.
- Realimentación: el usuario debe obtener una realimentación acerca del suceso o falla del intento de comunicación o control.

3.5. Hardware y Software BCI

En la comunidad BCI existe una amplia y diversa gama de dispositivos e interfaces BCI creadas por diferentes entidades. Las BCI más complejas del mundo se encuentran en laboratorios prestigiosos de países como Austria (Graz BCI), Alemania (Berlín BCI) y Suiza (BrainGain). El uso de estas interfaces se encuentra limitado a los investigadores de cada uno de estos laboratorios y desde allí se generan las tendencias en el desarrollo de aplicaciones con sistemas BCI. Desde mediados de la década pasada, empresas desarrolladoras de tecnología encontraron en la creación de interfaces cerebro computador un modelo de negocio rentable y sostenible; así, nacieron dispositivos como el Neurosky MindSet y el Emotiv EPOC, los cuales hacen parte de una nueva generación de sistemas BCI comerciales de bajo costo, las cuales permitieron expandir el interés de la investigación en sistemas BCI alrededor de todo el mundo. En un ritmo de desarrollo paralelo, las herramientas en software creadas para la investigación con sistemas BCI y señales de EEG en particular, empezaron a aparecer como herramientas complementarias al hardware BCI de bajo costo. En esta sección se pretende abordar, específicamente, el sistema Emotiv EPOC, el cual ha sido adquirido por la Maestría de Ingeniería Eléctrica de la Universidad en su versión “Research Edition” con el fin promover la investigación en interfaces cerebro computador. También, se mencionan dos de las

plataformas más usadas por la comunidad BCI como lo son el toolbox de Matlab EEGLAB, con su herramienta BCILAB y el software libre OpenVibe creado recientemente; a pesar de que existen otras plataformas como el BCI2000 y el TOBI [89], este trabajo se focalizó en abordar las dos plataformas que incorporan la comunicación directa con el Emotiv EPOC.

3.5.1. Emotiv EPOC: Una BCI confiable y de bajo costo

El casco Emotiv EPOC es una interfaz cerebro-computador que tiene incorporado 14 extensiones de electrodos (7 pares), la mayoría centrados alrededor de la parte frontal de la cabeza; utiliza el sistema internacional 10-20 mencionado anteriormente. Inicialmente fue vendido como un dispositivo de juego para el sistema operativo Windows [90], sin embargo debido a su portabilidad y bajo costo ha sido objeto de múltiples investigaciones desde su salida al mercado en el año 2008. El dispositivo es verdaderamente económico comparado con un sistema EEG médico y a diferencia de la utilización de los cables en los exámenes de EEG, el casco es totalmente inalámbrico, permitiendo así al usuario moverse libre y naturalmente. El dispositivo tiene un muestreo interno de 2048 Hz y después de filtrar artefactos envía los datos al computador a una tasa aproximada de 128 Hz, el tamaño de bloques es de 16 muestras; las señales son enviadas al ordenador usando protocolo inalámbrico patentado de 2.4 GHz mediante una antena USB. Este aspecto inalámbrico del sensor permite una libertad de movimiento y una conexión rápida y cómoda; además no se requiere del uso de ningún gel para generar la conexión entre las almohadillas y el cuero cabelludo, solo es necesario impregnar cada almohadilla de una solución salina para mejorar la conducción eléctrica. El tiempo de autonomía del sensor es de aproximadamente 12 horas cuando la carga está completa, proceso que suele demorarse unas 6 horas aproximadamente. Es altamente recomendable no utilizar el sensor en zonas donde convergen muchas otras señales inalámbricas como redes de conexiones inalámbricas de internet o redes de dispositivos con Bluetooth debido a que como estas operaciones se generan a la misma frecuencia (2.4 GHz), a menudo, suele presentarse una conexión inestable del sensor.

El casco también incluye un giroscopio que permite sensar los movimientos angulares de la cabeza para controlar la cámara o el cursor del mouse.

Kit de desarrollo de Software (SDK) del EPOC

La empresa creadora ofrece diferentes paquetes de desarrollo denominados Kit de desarrollo de software (SDK) los cuales contienen herramientas especializadas para la captura y análisis de la señal electroencefalográfica proveniente del sistema BCI. Estos paquetes vienen escritos en C#, un lenguaje de programación orientado a objetos derivado del C/C++ creado y estandarizado por Microsoft. En la página web de la empresa (www.emotiv.com), se encuentran descritos todos los paquetes de desarrollo que se ofrecen, para esta investigación y gracias a una inversión realizada por la maestría de ingeniería eléctrica de la universidad, se logró adquirir el paquete de desarrollo



Figura 3.7. Izquierda: Neurocasco Emotiv Epoc. Derecha: electrodos disponibles del sensor según el sistema internacional 10-20.

denominado “Research Edition” el cual es una licencia para un investigador independiente la cual incluye (además del neurocasco) una aplicación para la previsualización de los datos provenientes de cada electrodo tal y como se realiza en un electroencefalograma llamada “TestBench” la opción para realizar registros en archivos binarios usando el software EEGLAB, el cual es un toolbox de matlab que será descrito más adelante. La previsualización de los canales se realiza según el ajuste inicial del usuario, el programa realiza un ajuste automático de la escala, permite la inclusión de marcadores o etiquetas temporales, registro de sesiones completas con una ventana de reproducción y adicional permite el cálculo de la FFT de los canales seleccionados, permitiendo la sintonización del tamaño de la ventana de muestreo así como la opción de escoger de entre diferentes técnicas de ventaneo como la Hanning, Hamming, Hann, Blackman y la Rectangular. El histograma de las sub-bandas de frecuencias como la Delta, Theta, Alpha y Beta también puede ser calculado. Finalmente los datos provenientes del acelerómetro de dos ejes pueden ser capturados para generar una interacción más natural del usuario con la aplicación creada. La programación de aplicaciones compatibles con el neurocasco se realiza en el entorno Microsoft Visual Studio a través del API del Emotiv, la cual contiene el conjunto de funciones y procedimientos que ofrecen los desarrolladores del sensor. La figura 3.8 muestra una breve representación de las etapas de una aplicación con el SDK.

El EmoEngine se refiere a la abstracción lógica de la funcionalidad que el Emotiv le brinda al edk.dll; en pocas palabras, el EmoEngine se comunica con el neurocasco, recibe los datos EEG preprocesados, dirige las configuraciones específicas del usuario y las realizaciones de post procesamiento y las traduce en resultados de detección dentro de una estructura de fácil uso llamada

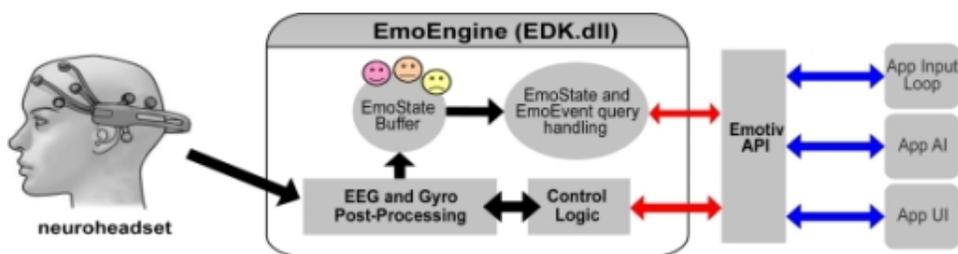


Figura 3.8. Diagrama de integración de la API del Emotiv con la aplicación.

EmoState. El EmoState entonces es la estructura de datos que contiene el estado actual de las detecciones del sensor, el cual, refleja los estados mentales particulares del usuario provenientes del EmoEngine. Existen reportes en donde se ha utilizado con éxito el SDK para la creación de novedosos sistemas que involucran dispositivos móviles [91] y técnicas para el reconocimiento de imágenes en línea [92].

3.5.2. EEGLAB como herramienta académica

EEGLAB es un software interactivo basado en menús y secuencias de comandos para el procesamiento de la señal electrofisiológica que trabaja sobre el entorno de programación interpretada Matlab. EEGLAB brinda una interfaz de usuario gráfica permitiendo a los usuarios facilidad, flexibilidad e interactividad en las etapas de procesamiento de la señal electroencefalográfica. Este toolbox implementa métodos comunes de preprocesamiento de la señal como filtros en tiempo y frecuencia, así como técnicas para la extracción de características de datos EEG incluyendo el análisis por componentes independientes (ICA). EEGLab se ha convertido en una plataforma ampliamente usada y con un componente de realimentación que ha generado una comunidad que crea y comparte nuevas técnicas para el procesamiento de la señal biofísica [93]. Las características que han posicionado a EEGLAB como una de las herramientas más utilizadas por la comunidad BCI son:

- Contiene una estructura de eventos y funciones para importar, editar y manipular la información.
- Tiene implementados métodos de extracción de características como el ICA que permiten una implementación rápida y práctica de aplicaciones con sistemas BCI.
- La integración con el resto de herramientas, scripts y toolboxes de matlab, permite que la generación de nuevas combinaciones entre técnicas de preprocesamiento, extracción de características y algoritmos de clasificación se genere de una manera fluida y a menudo, compartida.
- Posee una filosofía de fuente abierta, permitiéndole a cualquier investigador construir y

distribuir libremente nuevos plug-ins, funciones o toolboxes que aparecen automáticamente en la ventana de menú de EEGLAB. Esta estructura asegura la estabilidad del código principal que sólo un puñado de expertos modifican, mientras que al mismo tiempo, permite una fácil inclusión de nuevos algoritmos y métodos por parte de cualquier otro usuario.

Actualmente, el tutorial en línea contiene más de 300 páginas de documentación que se complementa con las más de 400 funciones creadas por investigadores y compartidas con éxito en la página [93]. Algunos de los plug-ins más nombrados y utilizados son el “Neuroelectromagnetic Forward Head Modeling Toolbox” (NFT), el cual permite la integración de un modelo realista de resonancia magnética cerebral con segmentación de imágenes, reconstrucción en alta calidad de modelos, registro de posiciones de electrodos con un modelo tridimensional de la cabeza; el “Source Information Flow Dynamics” (SIFT), el cual permite modelar y visualizar el flujo de la información entre las fuentes de la señal EEG después de una separación usando el ICA y el “Experimental Real-Time Interactive Control and Analysis framework” (ERICA), el cual se creó con el propósito de realizar procesos de adquisición y procesamiento de la señal EEG en tiempo real, creando un entorno de realimentación interactiva para una clasificación en tiempo real. Los resultados alcanzados con ERICA, brindaron las bases funcionales en el desarrollo de un plug-in de EEGLAB para la creación de aplicaciones con sistemas BCI denominado BCILAB, el cual será explicado en detalle a continuación.

3.5.3. BCILAB Toolbox para BCI

BCILAB es un toolbox de matlab de código abierto creado para realizar investigaciones avanzadas con interfaces cerebro computador. Contiene una interfaz de usuario gráfica y acceso a una larga lista de los mejores métodos de extracción de características usados por la comunidad BCI como los patrones espaciales comunes (CSP) y el análisis por componentes independientes (ICA); así como los métodos de aprendizaje de máquina más encontrados en la bibliografía como las máquinas de soporte vectorial (SVM) o el análisis discriminante lineal (LDA). Al ser interpretado por matlab, algunas de las mayores fortalezas que tiene el BCILAB es la implementación de prototipos rápidos, experimentos en tiempo real, evaluaciones offline de nuevas aplicaciones con sistemas BCI y la evaluación comparativa con métodos BCI modernos. Las señales procesadas por los sistemas BCI son tradicionalmente señales EEG, sin embargo, pueden incluirse otro tipo de datos como archivos de captura de movimiento, señales de electromiografía (EMG), conductancia en la piel o cualquier otro tipo de bioseñal que es grabado con el “DataRiver” de ERICA [89], generando así nuevos sistemas BCI híbridos. Estos tipos de datos pueden ser procesados juntos en un mismo experimento neurocientífico, en donde el resultado del algoritmo de clasificación pueda combinar los diferentes tipos de datos para generar una mejor salida. BCILAB es altamente flexible a las diferentes estrategias mentales utilizadas por los investigadores BCI como la imaginación de movimiento o la atención selectiva [93]; las herramientas que brinda el BCILAB facilitan cada una de las etapas

de un experimento BCI incluyendo la etapa de diseño, implementación, aprendizaje, evaluación y la aplicación “online” u “offline” del modelo propuesto. Otras tareas, incluyendo la exploración de los datos grabados y la visualización de los parámetros del modelo puede ser soportados usando las herramientas del EEGLAB. BCILAB tiene muchas capas, la capa superior incluye una interfaz gráfica, una interfaz para los scripts, una interfaz para la aplicación en tiempo real; una segunda capa que contiene el núcleo del modelo de aprendizaje, la ejecución del modelo y la evaluación de las funciones del modelo. Este núcleo está basado en un marco de “Paradigmas BCI” el cual puede ser entendido como un enfoque de prototipo tipo plantilla para el diseño del experimento y la elaboración del modelo BCI. Los paradigmas definen el enfoque completo como debe ser descrito en las publicaciones a realizar, desde las filas de los datos de entrada hasta la salida del clasificador, y usualmente envuelve las etapas de aprendizaje y clasificación, debido a que el rendimiento óptimo a menudo, suele alcanzarse después de que el modelo es aprendido (o calibrado) basado en datos muestra provenientes de una sesión, sujeto o tarea determinada. Los paradigmas BCI pueden ser completamente personalizados por el investigador, incluyendo la adición o remoción de componentes enteros que vienen con valores por defecto de los diferentes parámetros e hiperparámetros.

BCILAB pretende no solo ser una gran colección de herramientas y metodologías populares en la comunidad BCI, sino una gran plataforma para el diseño de nueva tecnología BCI, facilitando la creación de nuevos métodos, enfoques y paradigmas. Para esto BCILAB contiene, además de lo ya mencionado, un pequeño pero eficiente sistema de expresiones simbólicas matemáticas, un modelo de infraestructura computacional descentralizado distribuido que genera una independencia de los toolboxes de matlab y una amplia documentación de todas las funciones y herramientas contenidas en este poderoso toolbox.

3.5.4. OpenViBe: Una herramienta gratuita en un entorno gráfico

OpenVibe es una plataforma de software libre y de código abierto para el diseño, implementación y uso de interfaces cerebro computador. El software consiste en un conjunto de módulos que pueden ser integrados con facilidad y eficiencia para desarrollar aplicaciones BCI funcionales, especialmente las que se combinan con sistemas de realidad virtual [94]. Dentro de las características más destacadas del OpenVibe se encuentra su interfaz gráfica hecha para no programadores, un entorno gráfico basado en teoría de grafos que permite la programación mediante bloques funcionales que se unen mediante líneas de conexión, similar a desarrollos como LabView y Simulink. Existen 4 características que hacen de OpenVibe una plataforma integral para el desarrollo de experimentos en neurociencia con sistemas BCI:

- **Modularidad y reusabilidad:** OpenVibe es una plataforma que comprende un conjunto de módulos de software dedicadas a la adquisición, el pre-procesamiento, procesamiento y la visualización de datos cerebrales, así como la interacción con sistemas de realidad virtual. Al

ser un software de propósito general, OpenVibe permite la fácil adición de nuevos módulos de software con el fin de satisfacer las necesidades particularidades de cada investigador. Esto se da gracias al concepto de grafo o caja, un componente elemental que se añade a todo el flujo o el Pipeline de la aplicación que permite el desarrollo de componentes reusables, reduce el tiempo de desarrollo y ayuda a extender rápidamente las funcionalidades.

- **Diversidad de usuarios:** OpenVibe está diseñado para una amplia y diversa gama de usuarios, investigadores BCI, médicos, desarrolladores de sistemas de realidad virtual, entre otros. Las necesidades que plantean esta diversidad de usuarios pueden ser manejadas mediante las herramientas propuestas por esta plataforma, dependiendo de las habilidades en programación o el conocimiento en experimentos de neurociencia.
- **Portabilidad:** este sistema opera independientemente de otros paquetes de software (sistema intérprete) o de un hardware en particular, es gratuito y de código abierto. OpenVibe tiene compatibilidad con módulos de adquisición para datos como de EEG y MEG. Puede correr sobre Linux o Windows y es basado en software gratuitos y portables.
- **Conectividad con sistemas de realidad virtual:** OpenVibe puede ser integrado para desarrollar aplicaciones en realidad virtual de manera natural y compacta. Esta plataforma actúa como un periférico externo a cualquier tipo de ambiente virtual o real, permitiendo la integración con escenarios 3D (gracias a la integración con Ogre3D), objetos y personajes virtuales, así como una librería que permite la visualización de la actividad cerebral de forma legible para incentivar el entrenamiento y proporcionar las herramientas para el la correcta implementación del neurofeedback. El modo de programación es mediante arrastrar y soltar bloques funcionales dentro de la ventana de visualización 2D, cada módulo aparece como una caja rectangular con entradas, salidas y un panel de configuración dedicado. Las cajas pueden ser conectadas mediante sus entradas y salidas. El diseñador del experimento realiza la configuración y prepara las ventanas de visualización.

Utilizando un script predefinido, usuarios con habilidades en programación pueden crear nuevos cajones y drivers para diferentes sistemas de adquisición de datos; cada cajón o bloque funcional funciona como una interfaz que transfiere los datos procesados hacia otra caja vecina. Los datos son transferidos a través de estructuras de flujo definidas por un meta lenguaje establecido; estas estructuras contienen un encabezado, un buffer y una terminación, los cuales son elementos claves para la comunicación entre bloques [95]. OpenVibe es una potente herramienta para desarrollar experimentos innovadores con sistemas BCI y aunque tiene un claro enfoque sobre aplicaciones de realidad virtual, también podría ser usado para la creación de tecnología asistiva. A continuación, se realiza una descripción de los bloques más usados en experimentos clásicos BCI como el de imaginación motora o el deletreador mediante P300 según se encuentra en la página oficial (www.openvibe.inria.fr/documentation).

Clasificación

Classifier Processor: es el cajón genérico para la clasificación. Después del entrenamiento del clasificador, el algoritmo de clasificación es inicializado y su configuración es cargada desde el archivo de configuración producido en el entrenamiento. Entonces, cada vez que este cajón recibe un nuevo vector de características, es reenviado al algoritmo de clasificación y éste lo clasifica; el cajón toma el estado del algoritmo y el valor actual de la clase y traduce ésta información a su salida. La clase es enviada en forma de una estimulación, la cual puede ser interpretada en el resto del Pipeline. Consecuentemente, el uso de este flujo de salida será dependiente del algoritmo de clasificación escogido; por ejemplo el clasificador LDA envía el valor de la distancia del hiperplano y su estatus. Así, las salidas de este cajón son las etiquetas y el estado de clasificación. Desde este bloque se pueden configurar el clasificador a usar (SVM o LDA), el nombre del archivo de configuración a cargar y la clase de rechazo (para algoritmos que soportan rechazo).

Classifier Trainer: realiza un entrenamiento del clasificador para un vector de características asignado. El cajón recolecta un número de vectores características y los etiqueta dependiendo de las entradas que llegan. Cuando una estimulación específica llega, el proceso de entrenamiento es ajustado, proceso que generalmente toma algo de tiempo y por eso este cajón debe ser usado offline. Las entradas del bloque son: (1) las estimulaciones: provenientes de la etapa de entrenamiento, las cuales son recibidas y todos los vectores característica son etiquetados y enviados al algoritmo de clasificación. El algoritmo de clasificación finalmente produce el archivo del clasificador configurable que será usado en el Classifier Processor; (2) características para la clase 1: esta entrada recibe el vector característica para la primera clase; (3) características para la clase 2: esta entrada recibe el vector característica para la segunda clase. Finalmente, este bloque permite realizar el test de validación cruzada para la evaluación de la exactitud del clasificador.

Extracción de Características

Feature Aggregator: permite que cada trozo de entrada sea concatenada en un vector de características. Permite agregar las características que recibe en sus entradas dentro de un vector característica que puede ser usado para la clasificación.

Procesamiento de Señales

Epoch Average: este cajón permite promediar matrices de diferentes tipos incluyendo señales, espectros o vectores característica. El bloque permite múltiples métodos para el promediado de las épocas (segmentos de la señal EEG): promedio móvil, promedio móvil inmediato, promedio de bloque de época, promedio acumulativo.

Signal Average: este cajón calcula el promedio de cada buffer de muestra entrante y emite una señal resultante.

Channel Selector: permite realizar una selección del conjunto de canales de entrada. La selección puede ser basada en los nombres de los canales o en el número indexado arrancando desde cero. De esta manera, este cajón permite la restricción de la señal de salida a un subconjunto de los datos de entrada basado en la lista de canales.

Hilbert Transform: permite retornar la transformada de Hilbert, la fase y envolvente de la señal de entrada usando cálculo analítico de la señal.

Reference Channel: este cajón resta los valores de las muestras desde un canal de referencia a las muestras de los otros canales.

Simple DSP: este bloque es usado para aplicar formulaciones matemáticas a cada muestra de una señal entrante. El diseñador puede utilizar funciones logarítmicas, trigonométricas, operadores matemáticos, funciones binarias, operadores de comparación, operadores booleanos, entre otros.

Time Base epoching: este bloque se puede utilizar para controlar la superposición de épocas. Este bloque permite generar épocas cuya longitud es configurable, como el tiempo de desplazamiento entre dos épocas consecutivas. Este cajón tiene una entrada y un conector de salida, ambos son de tipo señal. Esta caja es esencial para otras cajas de procesamiento de señal cuando el tamaño de los bloques de los datos que se reenvían no es suficientemente significativo.

CSP Filter Trainer: este bloque permite implementar el algoritmo de Patrones Espaciales Comunes (CSP), el cual incrementa la varianza de la señal para una condición mientras minimiza la varianza de la otra condición. El objetivo del algoritmo es el de mejorar la discriminación de los dos tipos de señal. Como elementos de entrada tiene los estímulos que son necesarios para indicar el fin de la sesión (fin del archivo) con el fin de sintonizar el cálculo/entrenamiento de los filtros CSP. También espera la condición de las señales 1 y 2 (para un problema biclase) con el fin de realizar la discriminación a partir de las etiquetas suministradas. El cajón permite la configuración de la dimensión del filtro, la cual generalmente tendrá relación con la cantidad de canales que se estén usando (se recomienda utilizar una dimensión menor o igual a la cantidad de canales). La salida es un archivo de configuración que contiene los coeficientes del filtro espacial calculado según el algoritmo CSP.

Spatial Filter: este cajón permite la implementación de filtros espaciales, los cuales permiten generar un número de canales de salida a partir de un conjunto de canales de entrada, en donde cada

canal de salida será una combinación lineal de los canales de entrada. Este bloque entonces permite configurar los coeficientes del filtro espacial o cargar un archivo que contenga dicha información.

Temporal Filter: este cajón es usado para filtrar la señal de entrada, permite escoger entre tipos de filtros (Butterworth, Chebychev, Yule-Walker), tipos de bandas (pasa banda, pasa alto, paso bajo, para banda), el eje superior o inferior del pasabanda y el rizado del pasabanda en el filtro ChebyChev.

Independent component Analysis (FastICA): este filtro es usado para descomponer la señal en componentes independientes. El cajón es basado en el algoritmo de FastICA.

Spectral Analysis: este cajón realiza el cálculo del espectro sobre las señales de entrada y en la salida incluye la amplitud del espectro (la potencial de la señal en un número de bandas de frecuencia), también arroja el cálculo de la fase, parte real e imaginaria. El análisis es realizado a usando la Transformada Rápida de Fourier.

Signal display: permite la visualización de la señal. Este cajón muestra las señales entrantes usando una gráfica bidimensional por canal en donde los valores son graficados sobre el eje vertical mientras el eje horizontal representa el tiempo.

Time-frequency map display: este cajón permite elaborar mapas tiempo frecuencia que muestran la potencia espectral de las señales sobre el tiempo, haciendo posible generar un seguimiento de los cambios de amplitud sobre un tiempo determinado. Para hacer esto, usa una escala de colores que convierte las amplitudes en colores dentro del mapa. Esto hace posible la representación de un simple espectro en una columna de bloques codificados con colores. Conforme pasa el tiempo, la gráfica se desplaza hacia la izquierda para conformar toda una superficie o mapa con los espectros recientes, así se realiza un mapa por canal. Dependiendo de la resolución del mapa, un número variable de bandas de frecuencia son mostrados por espectro o columna del mapa. El cajón permite la configuración de las escalas de los dos ejes (frecuencia y tiempo) y una selección de canales.

3.6. Neuromodulación con sistemas BCI para la Recuperación Motriz

Después de un accidente cerebro vascular (ACV) o una lesión cerebral, un gran porcentaje de individuos no recuperan las características de una marcha normal o el movimiento natural de las extremidades. Algunas intervenciones utilizan ejercicios para los miembros superiores e inferiores con la expectativa de restaurar el control motor a través de la plasticidad neuronal dependiente de la actividad, la cual está ampliamente ligada a los cambios en las conexiones sinápticas en respuesta a estímulos externos generalmente correlacionados con la actividad motora. La plasticidad

que posee el sistema nervioso central (SNC) ha sido documentada por un número de científicos como la adaptación estructural y funcional de mecanismos neuronales durante el aprendizaje de nueva información y la adquisición de nuevas habilidades [96]. Esta plasticidad puede envolver modificaciones en la intensidad sináptica entre neuronas tanto del cerebro como de la médula espinal; de hecho la plasticidad es la base sobre la cual se adquieren las habilidades cognitivas y motoras. La plasticidad en el SNC se da en el caso de traumas o enfermedades y puede involucrar cambios no solo en la intensidad sináptica sino también a través de los circuitos neurales. Después de un ACV, se puede generar una plasticidad extensiva en la corteza y en otras estructuras neurales de acuerdo a modelos animales y modelos humanos [96]. En el caso de enfermedades en el SNC, la plasticidad dependiente de la actividad puede afectar el sistema nervioso de manera positiva o negativa: la plasticidad puede restaurar la función motora, pero cuando los movimientos anormales son realizados de manera repetitiva, la plasticidad dependiente de la actividad puede solidificarse o incluso agravar un funcionamiento anormal motor. La idea es que la práctica del movimiento repetitivo puede inducir plasticidad dependiente de la actividad en el SNC la cual puede restaurar la función motora afectada. En contraste, los enfoques basados en sistemas BCI podrían realizar medidas neurofisiológicas directas (ej. EEG) para brindar una realimentación al usuario con la expectativa de estimular la plasticidad cerebral que restaurará el control motor. El uso de neuro-realimentación puede mejorar la recuperación de la función cerebral y, por consiguiente, la función motora. Las investigaciones apuntan hacia tres horizontes: la identificación de la práctica de tareas motoras que pueden producir una señal cerebral que puede ser usada en rehabilitación, la identificación de las características de la señal cerebral que pueden ser usadas en rehabilitación y la practicidad (facilidad de uso y precisión) de la sesión de entrenamiento con sistemas BCI. Para pacientes sobrevivientes de un ACV, el uso de sistemas BCI puede ayudar a mejorar el desempeño en el aprendizaje motor y en la recuperación de la función motriz, la cuestión es si el movimiento afectado puede ser usado dentro de una aplicación BCI.

3.7. Tecnologías de Realidad Virtual en Rehabilitación

La realidad virtual (VR) es “el uso de simulaciones interactivas creadas con un hardware y software de computador para presentar a los usuarios oportunidades de involucrarse en ambientes que aparentan y se sienten similares a los eventos y objetos del mundo real” Los recientes avances en la tecnología de desarrollo de videojuegos y la disponibilidad de dispositivos de seguimiento de bajo costo han incrementado ampliamente las capacidades de las interfaces y el software y el hardware para la VR, permitiendo una integración significativa de esta herramienta digital en las diferentes terapias. La VR ofrece ciertas ventajas en los procesos de rehabilitación y neuorehabilitación comparados con la práctica en el mundo real [97]: i) individualización y entrenamiento de tareas específicas, la VR puede proporcionar los medios para exponer de forma segura al paciente con la formación de ambientes realistas y funcionales que pueden ser adaptados a la capacidad de

cada paciente y pueden ser implementados en terapias de rehabilitación en casa, ii) motivación: la VR ofrece unas condiciones realistas, seguras y motivacionales en las cuales se pueden practicar actividades complejas; las evidencias sugieren que cuando un usuario se concentra en el juego más que en su discapacidad o en su dolor, el ejercicio se vuelve más disfrutable, motivador y es muy probable que estos aspectos se mantengan durante las numerosas sesiones de terapia necesarias para inducir cambios en la plasticidad en el sistema nervioso, iii) realimentación: el usuario siempre necesita saber cómo y cuando una tarea fue completada exitosamente (o no) con el fin de promover (corregir) el aprendizaje y evitar la frustración. La desventaja más notoria del uso de la VR en las terapias de rehabilitación es la viabilidad económica de la implementación, a pesar de que el costo de los ordenadores y los visualizadores (monitores, proyectores, televisores) han disminuido rápidamente, los sistemas de inmersión-completa son aún costosos, especialmente los que requieren complejos montajes audiovisuales y las gafas de video que suelen ser incómodas para los pacientes y costosos para los centros clínicos. Contrariamente, dispositivos de mano y periféricos de juego como el sensor Kinect, el Wiimote, Razer Hydra y el Emotiv EPOC han brindado acceso a sensores de seguimiento e interfaces de interacción con los cuales las experiencias con VR pueden volverse más accesibles y escalables. Últimamente, aspectos legales concernientes al uso de la VR en neurorehabilitación han sido considerados [98]. De acuerdo al “Medical Device Directive un dispositivo médico es definido como: “cualquier instrumento, aparato, electrodoméstico, software, material u otro artículo, el cual usado sólo o en combinación incluyendo los programas informáticos destinados por su fabricante, que es usado específicamente para diagnóstico y/o propósitos terapéuticos [97]” Entonces, si los sistemas son usados para propósitos en rehabilitación, ellos son por definición dispositivos médicos y tienen que ser certificados por consecuencia. Esto podría eventualmente incrementar sustancialmente los costos del uso de éstos productos, y tiene que ser considerado como un riesgo potencial del uso de los sistemas basados en realidad virtual para la neurorehabilitación. Cuando se escoge una tarea basada en realidad virtual para un proceso de neurorehabilitación, los clínicos deben considerar el nivel de dificultad (¿se puede retar al paciente apropiadamente a través del proceso de rehabilitación?), la complejidad de la tarea (¿puede la tarea ser dividida en componentes individuales?), los contenidos de las tareas (¿es la tarea relevante y motivante para el paciente?), disponibilidad de la realimentación (¿es la realimentación directa y entendible para el paciente?) y el potencial para transferir las habilidades (¿puede el contenido de la tarea ser gradualmente modificado para promover la transferencia en la vida real?).

3.8. Videojuegos para la salud usando sistemas BCI (BCI Games)

Una de las aplicaciones más prometedoras en el uso de los sistemas BCI es el desarrollo de videojuegos “serios” para la salud. La accesibilidad a este tipo de tecnología ha sido posible en gran parte, gracias a los avances de la industria de la recreación, el entretenimiento y los videojuegos,

las BCI se han convertido en un nuevo y efectivo sistema para el control de aplicaciones como juegos, plataformas de realidad virtual y todo tipo de expresiones creativas. Uno de los primeros investigadores que contempló la opción de combinar simulaciones o juegos en realidad virtual con las BCI fue Nijholt [99]; como se indica en el estudio, los primeros juegos controlados por estas interfaces se enfocaron en el diagnóstico de las señales cerebrales en aspectos como la medición de la atención del usuario o la relajación en componentes afectivos de los juegos. La interacción de individuos en juegos inmersivos con ambientes tridimensionales brinda más datos característicos como emociones o interpretaciones del contexto que ayudan a entender con mayor facilidad las actividades y deseos de los pacientes. La neurorealimentación (neurofeedback) es la técnica que presenta en tiempo real la realimentación del usuario basado en las señales EEG (o fMRI) para ilustrar la actividad cerebral, a menudo con el objetivo de controlar la actividad del sistema nervioso central, esta técnica es la respuesta tecnológica a la psicoterapia y la rehabilitación cognitiva [75]; constituye una herramienta que puede cambiar efectivamente las bases fisiológicas del comportamiento, la atención y el aprendizaje a través de la habilidad que tiene el cerebro para autorregularse. El neurofeedback suele ser útil para remediar las consecuencias de ACVs, aneurismas, daños traumáticos del cerebro, o para el tratamiento de desórdenes por drogadicción, alcohol, déficit de atención e hiperactividad (ADHD por sus siglas en inglés); para el tratamiento de la depresión, la ansiedad o desórdenes de estrés postraumático, entre otros. Cuando un paciente juega un videojuego usando un sistema BCI los estímulos visuales mostrados en la pantalla están constantemente afectando la actividad neuronal del usuario brindando datos acerca del estado anímico, el nivel de funcionamiento de una región del cerebro, las intenciones mentales o el nivel de concentración del usuario sobre una acción en particular dentro de la dinámica de juego. Mientras la comunidad BCI considera los videojuegos como una aplicación potencial de este tipo de interfaces, la comunidad de videojuegos (gamers) ha empezado a considerar los sistemas BCI como un periférico alternativo de control. Sin embargo existe una discrepancia amplia entre los videojuegos elaborados por las dos comunidades [100]. La comunidad de investigación alrededor de las interfaces cerebro computador suele centrarse más en la evaluación de aspectos e hipótesis psicológicas o en la validación de métodos y técnicas de clasificación de estados o características cognitivas (para personas sanas o enfermas). Este tipo de enfoque suele mantener ciertos estándares como la focalización en los aspectos técnicos del videojuego más que en las características propias del mismo (gráficas, efectos de sonido, rol de jugabilidad), la carencia de narrativa y realimentaciones visuales con gráficos enriquecidos lo que finalmente suele desencadenarse en un juego fiable y funcional pero a menudo, poco entretenedor. Ahora bien, por el contrario, la comunidad gamer suele desarrollar videojuegos usando principios de diseño, dinámicas de juego, narrativas enriquecidas, sonidos elocuentes y toda una amalgama de características que hacen que el juego sea verdaderamente entretenedor y disfrutable; sin embargo, los aspectos neurofisiológicos y el análisis de la señal eléctrica obtenida en la experiencia suelen ser aspectos ampliamente desconocidos.

En [101] se encuentra una revisión de los neuromecanismos utilizados en los juegos BCI en orden de analizar los paradigmas de interacción más populares:

- **Juegos de estados mentales:** en esta categoría se encuentran los videojuegos de relajación y los de concentración. Estas actividades son propias de las prácticas clínicas con las cuales se busca, por ejemplo, a través de la relajación reducir la ansiedad o de la concentración reducir el déficit de atención. Muchos de los videojuegos de estados mentales le permiten al paciente realizar movimientos físicos reales [102] o representados por un avatar [103]. La relajación es la actividad preferida para usos terapéuticos ya que permite la generación de un estado positivo en donde los jugadores pueden entrar en contacto virtual con el juego de una forma más agradable. Aquí entran a jugar características como los escenarios, los sonidos y los colores usados para los objetos y/o personajes; si no se logra una combinación armoniosa entre estos factores, el estado de relajación requerido será difícil de alcanzar. Por su parte, la concentración es un paradigma de juego deseable para un efecto de absorción; de acuerdo a las teorías de flujo y de inmersión, la concentración es la clave para un juego exitoso. Por esto, los videojuegos que requieren de concentración o de prestar atención suelen brindar una mejor experiencia de usuario que aquellos que no. La velocidad con la cual podemos cambiar nuestros estados de relajación o concentración es mucho más lento que la velocidad con la que podemos presionar botones o usar cualquier otra estrategia mental para la interacción con sistemas BCI. Es por esto que a menudo este tipo de paradigmas de interacción requieren del uso de dispositivos adicionales que son usados como controles auxiliares para hacer el juego más fluido. Los videojuegos de estados mentales usualmente permiten solo un control binario, por ejemplo, en un juego de relajación, los jugadores solo podrán estar en uno de dos estados, relajado o no relajado lo que finalmente desencadena solo 2 comandos discretos.
- **Juegos de imaginación motora:** esta es otra metodología originaria de estudios clínicos, específicamente los usados para restauración de la movilidad y de las capacidades de comunicación de personas en estado de discapacidad [82]. Este tipo de estrategia mental requiere la imaginación de un movimiento físico, en particular, los más usados son los movimientos discriminados de las manos y el movimiento indiscriminado de los pies. Los jugadores imaginan los movimientos para navegar y para generar cualquier tipo de interacción dentro del ambiente virtual propuesto. La imaginación de movimiento es una estrategia mental ampliamente usada en muchas de las aplicaciones de los sistemas BCI [5], por esto su señal puede ser reconocida con facilidad a través de técnicas de extracción de características como el análisis de componentes independientes (ICA) o los patrones espaciales comunes (CSP), lo que la convierte en una señal de respuesta rápida a diferencia de la proveniente de los estados mentales. En [104] se realizó un estudio en donde concluyen que la cantidad de electrodos necesarios para una precisión del 90 % en una interacción con imaginación motora es de 8-36, los cuales de forma discriminada según el estándar 10-20 son: FC5, FC3, FC1, C5,

C1, CP5, CP3, CP1, FC2, FC4, FC6, C2, C4, C6, CP2, Cp4 y Cp6. De otra mano, el número de comandos en estos juegos es limitado al número de comandos imaginados distinguibles que el usuario pueda hacer y que el sistema puede registrar con facilidad, generalmente son cuatro: mover la mano derecha, mover la mano izquierda, mover los pies y mover la lengua.

- Juegos con potenciales evocados: en esta clase de juegos predomina una señal característica denominada Potenciales Evocados Visualmente de Estado Estacionario (SSVEP por sus siglas en inglés) [79]. La razón de este dominio se debe a que en los videojuegos generalmente, siempre existe una realimentación visual y por esto la generación de otros potenciales evocados no es tan marcada. Este paradigma de interacción dentro de los videojuegos puede ser dividido en dos enfoques: el primero es el mapeo de la fuerza del registro que los SSVEPs ocasionan sobre el EEG en un solo estímulo propuesto en un videojuego. Por ejemplo, SSVEP débil puede conducir al comando de virar hacia la izquierda de una avión, mientras que el mismo SSVEP pero con una intensidad mayor podría conducir al movimiento a la derecha de la misma aeronave en un ambiente virtual. Un jugador entrenado puede controlar a libre albedrío la fuerza de sus SSVEPs de diferentes maneras. Una forma de hacerlo es cerrando y abriendo los ojos para producir potenciales evocados visualmente débiles o fuertes; sin embargo esto podría ser una acción muy fisiológica para generar un verdadero comando de interacción en el juego. Otra forma de regular la fuerza de los SSVEPs es mediante la cantidad de atención prestada; algunas investigaciones han mostrado mantener la atención puede mejorar la interacción con los SSVEPs [101]. Es decir, se puede asegurar certeza si un usuario esta simplemente siendo expuesto a un estímulo o si en realidad le está prestando atención. La atención sostenida es una actividad que puede dar lugar a un estado de concentración. Esto hace de los SSVEPs sean usados con recurrencia para los videojuegos de concentración. El segundo enfoque, el cuál es más popular, es usar múltiples estímulos cada uno de los cuales es caracterizado y usado como un comando por separado. En la mayoría de los videojuegos que utilizan este enfoque, los sistemas BCI son usados para seleccionar la dirección, por ejemplo, en un recorrido virtual, o en un juego de disparo en primera persona (FPS). La ventaja de esta metodología es comparada con las otras clases de juegos, es que está si permite el uso de un gran número de comandos. Las restricciones como el estado (relajado o estresado) o el número de comandos que pueden ser detectados (movimiento manos derecha e izquierda) no aplican para este paradigma. Simplemente, la adición de más estímulos, incrementa el número de comandos, sin embargo, con el incremento del número de estímulos su discriminación se vuelve un trabajo más dispendioso ya que cada estímulo visual deja un registro que es ligeramente diferentes a los demás. Esto hace que enfocar la atención en un estímulo en particular dentro de la dinámica de juego pueda generar, a menudo, confusiones con los demás, lo que desencadena en un juego sin fluidez. Finalmente los videojuegos con SSVEPs son menos adecuados para juegos rápidos o que demanden una rápida respuesta por parte del

usuario, ya que el procesamiento de la señal emplea una cantidad de tiempo considerable. Sin embargo, este tipo de juegos son adecuados para interacciones multimodales gracias a su alta relación de señal/ruido, lo que los hace más fáciles de identificar en un registro EEG convencional.

A pesar de los múltiples sistemas BCI creados para la industria de los videojuegos, así como de la gran cantidad de investigaciones realizadas en este campo, se puede afirmar que el uso de interfaces cerebro computador en videojuegos está en una etapa de desarrollo temprana, en donde aspectos como la usabilidad y fluidez de interacción no se encuentran claros en los experimentos neurocientíficos propuestos [103].

MATERIALES Y MÉTODOS

4.1. Configuración Experimental

En esta sección se describe el diseño metodológico que fue escogido para el desarrollo del experimento neurocientífico. El sistema BCI utilizado es el neurocasco Emotiv EPOC y como software para el análisis de la señal EEG se escogió el OpenViBe. La escogencia de este último se debe a su carácter gratuito y de fuente abierta, lo que facilita la implementación de experimentos con sistemas BCI mediante una muy baja inversión. OpenViBe provee las herramientas necesarias para la adquisición de datos en tiempo real, el procesamiento y la visualización de datos mediante diversas técnicas. Los 4 motivos principales por los cuales se escogió el OpenViBe son: 1) conectividad con el neurocasco Emotiv EPOC, 2) disponibilidad de diversas herramientas para cada uno de las etapas de una aplicación BCI, 3) el diseño del software está hecho para no programadores, lo que permite que el tiempo de desarrollo del experimento neurocientífico disminuya y que los errores puedan ser detectados y corregidos con mayor facilidad, 4) la inclusión de bloques funcionales para la comunicación con dispositivos y aplicaciones externos. Todo el experimento tiene como objetivo conducir a un usuario sano con entrenamiento previo, a desarrollar la capacidad de interactuar con un videojuego usando solo la imaginación del movimiento. Particularmente, se utilizan dos clases: imaginación de movimiento de la mano derecha y de la mano izquierda; el videojuego realizado es basado en un rediseño del clásico Duck Hunt, creado en los 80s por Nintendo. Para este caso, el usuario no utiliza la pistola de luz (Nintendo Zapper) para realizar la cacería de patos, sino que utiliza la neuromodulación como señal de entrada para generar los disparos de ambas manos. Aunque el experimento se desarrolla con personas sanas, su uso puede extenderse hacia terapias de rehabilitación para la mejora de funciones motrices en patologías como el Accidente Cerebrovascular y el Parkinson, la reducción de dolor en condiciones neurológicas como el síndrome del miembro fantasma que se genera después de las amputaciones o algunas neuropatías que se producen después de la lesión de médula espinal [105]. Particularmente y gracias a un convenio realizado con la Clínica de Dolor del Eje Cafetero, se están reclutando pacientes sobrevivientes de un accidente cerebrovascular con negligencia espacial unilateral, una condición neuropsicológica en donde después de un daño neurológico, la persona es incapaz de

procesar y percibir estímulos de un lado del cuerpo. Estudios previos sugieren que el entrenamiento de estos pacientes con imaginación motora mejora su capacidad cinestésica, reduce la severidad de la negligencia en la exploración y mejora la orientación espacial y temporal [106]. La figura 4.1 muestra un diagrama que relaciona los elementos más importantes de todo el proyecto:

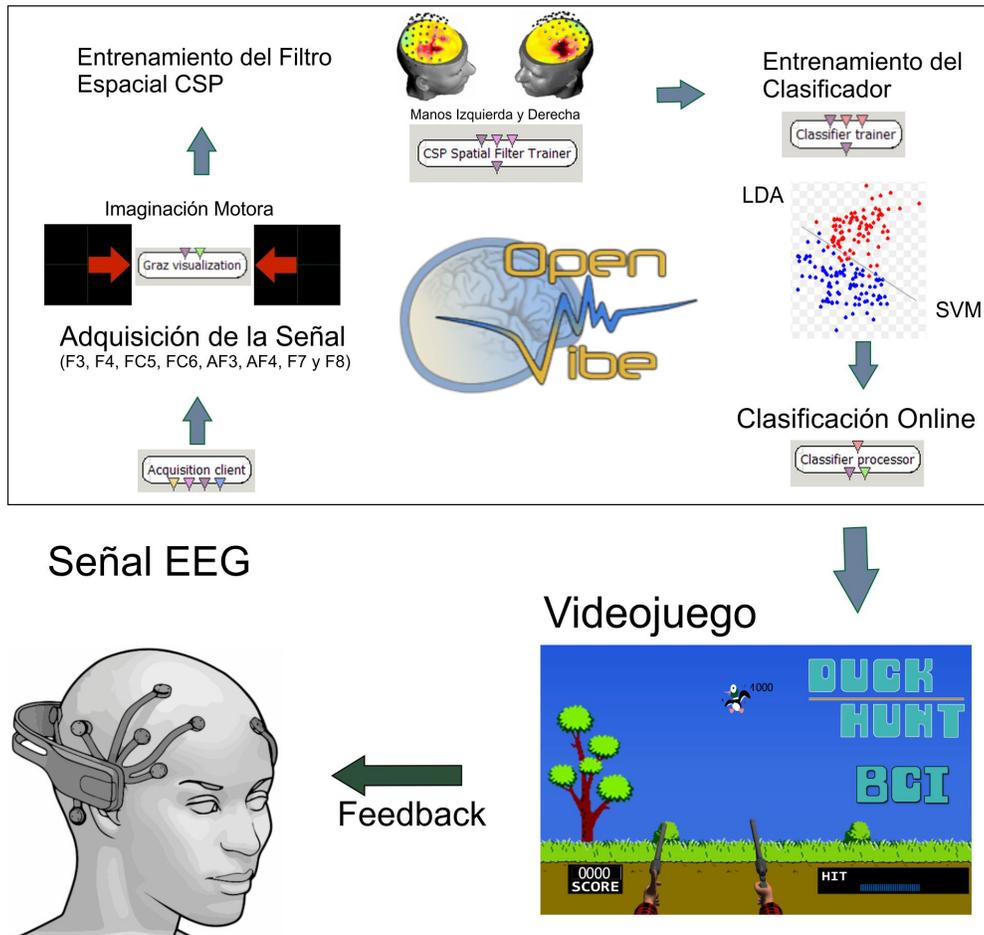


Figura 4.1. Diagrama funcional de la aplicación desarrollada.

4.1.1. Conexión del neurocasco Emotiv EPOC con el OpenViBe

OpenVibe posee una interfaz de usuario en donde convergen una gran cantidad de herramientas para el análisis de la señal EEG. Con el fin de adquirir las señales provenientes de los sistemas BCI, el OpenViBe tiene integrado un módulo para la adquisición de las señales en tiempo real provenientes de una gran lista de sistemas BCI, el Acquisition Server, dentro de los cuales se encuentra el Emotiv EPOC. Para el proceso de adquisición, es necesario haber adquirido previamente la Research Edition del neurocasco ya que el software solicita la ruta de instalación del paquete; se requiere establecer

una configuración inicial con el fin de configurar la conexión con el puerto y la frecuencia de muestreo del sistema (128 Hz para el caso del Emotiv EPOC). En este mismo punto, el investigador puede configurar algunos parámetros iniciales del usuario como el género y la edad, también podrá escoger si desea agregar dos canales más para cada eje del giroscopio del neurocasco. Esta configuración permite capturar las señales de cada uno de los electrodos del neurocasco para ser añadidas a cualquier escenario diseñado en OpenViBe a través del Box Acquisition Client.

4.1.2. Estrategia BCI y entrenamiento

El paradigma o estrategia mental utilizada para este experimento es el de Imaginación Motora (MI) con dos clases: imaginación del movimiento de la mano derecha e izquierda. A pesar que el Emotiv EPOC no tiene los electrodos C3 y C4, los cuales son los electrodos en donde se registran los ERD producidos mediante la imaginación de estos movimientos, si posee electrodos cerca a la corteza neuromotora como el F3, F4, FC5 y FC6, los cuales permiten registrar intenciones mentales de movimiento. La escogencia de este paradigma radica en la no dependencia de estímulos externos, lo que permite una mejor concentración del usuario con la aplicación desencadenando en un control más estable de la aplicación, además, la preferencia de esta estrategia mental en escenarios como la BCI Competition [42] y la interacción con videojuegos [102] comprueban la eficacia del paradigma. La inclusión de ejemplos y metodologías de estimulación de centros de excelencia como el Graz en el software OpenViBe para el trabajo con imaginación motora, también fueron factores determinantes para la escogencia final. Finalmente el conjunto de electrodos escogidos para el experimento fueron: F3, F4, FC5, FC6, AF3, AF4, F7 y F8, tal y como se registra en la figura 4.2.

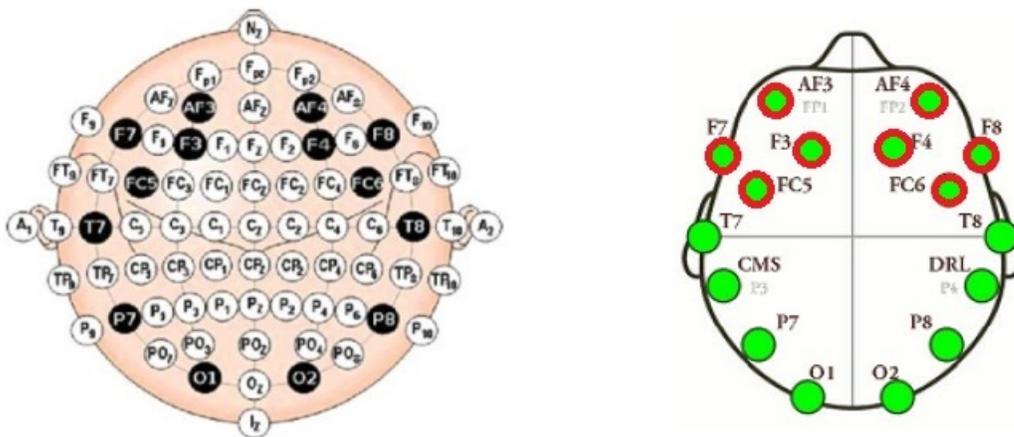


Figura 4.2. Izquierda, conjunto de electrodos escogido para el experimento. Derecha, electrodos del EPOC en estándar 10-20 de EEG.

La figura 4.2 muestra en su parte izquierda la cercanía de los electrodos FC5 y FC6 con los

electrodos C3 y C4; aunque muchos estudios apuntan a una selección de canales independiente del sujeto, otros estudios demuestran que el uso de la información proveniente sólo de dos canales (C3 y C4 en este caso) podría ocasionar una pérdida de información que eventualmente disminuirá la precisión del clasificador [107], [108]. Así entonces, una de las hipótesis más recientes es que existe una dependencia con respecto al usuario de los canales escogidos para un experimento BCI con imaginación motora. La implementación de esta estrategia en una aplicación BCI requiere de un entrenamiento previo del usuario y del sistema. Este entrenamiento se basa en la estimulación mediante imágenes (generalmente flechas) del usuario en un tiempo determinado, el cuál tendrá que imaginar un movimiento en particular cada vez que vea el estímulo. En este caso, el usuario debe imaginar el movimiento de la mano derecha cada vez que vea en pantalla una flecha apuntando hacia esa dirección y deberá imaginar el movimiento de su mano izquierda cuando observe en pantalla una flecha que apunte en esa dirección. Esto se realiza alrededor de unos 7 minutos con el usuario, en un espacio en donde no existan distracciones visuales, en las primeras horas de la mañana (generalmente es cuando la mente está más receptiva, dispuesta y libre de estrés) y se debe procurar apagar artefactos electrónicos que puedan causar interferencia electromagnética como los celulares. Finalmente se le pide al usuario que acompañe el entrenamiento con un leve movimiento de la mano con el fin de resaltar más la orden de movimiento y que procure no gesticular durante la sesión. Las señales de los electrodos son registradas y utilizadas para el entrenamiento del filtro espacial y de los clasificadores en etapas posteriores.

4.1.3. Descripción de los escenarios desarrollados

Para la implementación del experimento se desarrollaron 4 escenarios en OpenViBe. Un escenario es un conjunto de cajones de procesamiento de señal que se comunican entre sí con el fin de obtener un objetivo que es común para ese escenario. Generalmente, cada cajón tiene un conjunto de parámetros configurables, los cuales pueden verse haciendo doble clic sobre cada caja. Todos los escenarios son compilados en momentos diferentes del experimento, el orden en el que cada escenario es ejecutado no debe alterarse ya que cada escenario depende del que lo precede. Los escenarios implementados son:

Escenario de Adquisición

En este escenario se recolectan los datos provenientes del entrenamiento del usuario. Una vez conectado el Emotiv EPOC al servidor del OpenViBe, se utiliza el cajón Acquisition Client para capturar los datos del neurocasco en el escenario, se añade el seleccionador de canal en donde se enlista el conjunto de canales utilizados para este experimento mediante un número con el cuál es etiquetado cada canal de entrada, separados por un punto y coma en la configuración de este cajón. Los parámetros de estimulación son definidos mediante el Graz Motor Imagery BCI Stimulator el cuál contiene un archivo de configuración para el cuál se le asignaron valores de

20 muestras por cada clase, etiquetas para cada clase (imaginación del movimiento de las manos derecha e izquierda) y un tiempo de duración de realimentación de 3.750 segundos. Una vez obtenida la configuración del estímulo, se añade un cajón Identity, el cuál permite duplicar entradas a salidas correspondientes de forma similar, aquí se conecta la salida del selector de canales, la estimulación y la información del usuario proveniente del bloque de adquisición. Las salidas son conectadas al bloque de visualización, el Graz visualization, el cual permite mostrar los estímulos visuales de acuerdo a la configuración establecida y finalmente la sesión es almacenada usando el Generic stream writer en un sólo archivo con extensión OV. Una previsualización del escenario de adquisición es mostrada en la figura 4.3.

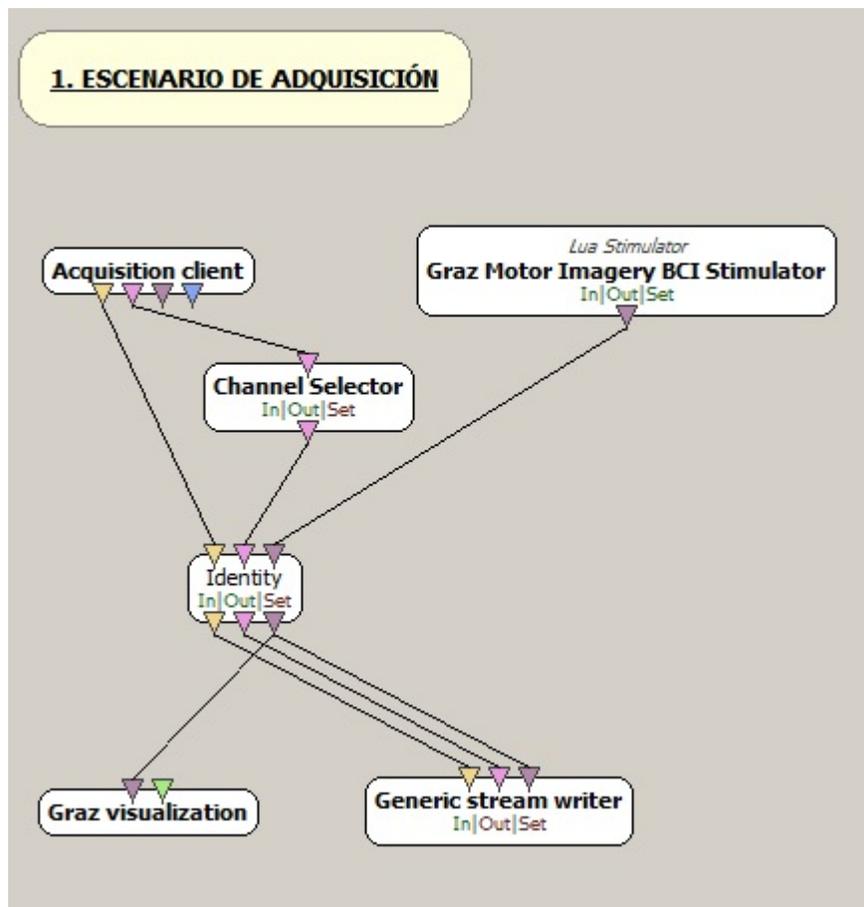


Figura 4.3. Previsualización del escenario de adquisición diseñado para la captura de las señales del usuario en el entrenamiento con imaginación motora.

Una vez es compilado el escenario, aparecerá una ventana negra en donde se empezarán a mostrar de forma ordenada flechas rojas (ver figura 4.4) que le indicarán al usuario el momento exacto en el que debe realizar la acción de imaginarse el movimiento. La señal es recolectada y etiquetada.

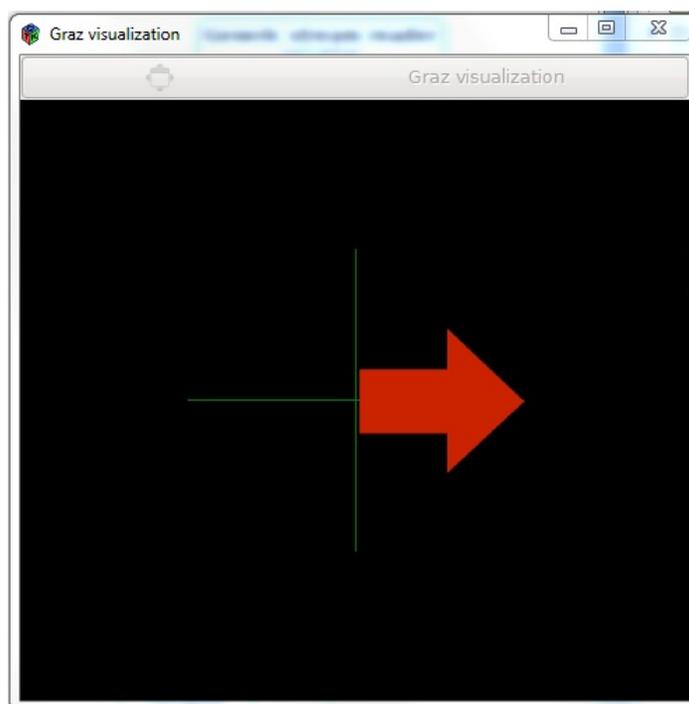


Figura 4.4. Flechas de estimulación utilizadas por el cajón Graz Visualization para la recolección de datos.

Todo el proceso de adquisición de las señales etiquetadas tiene una duración aproximada de 8 minutos.

Escenario de entrenamiento del filtro CSP

Debido a que el algoritmo de los patrones espaciales comunes permite asociar las etiquetas obtenidas a través del estimulador de Graz, fue escogido el filtro CSP para la etapa de extracción de características. El archivo de la sesión de entrenamiento es cargado mediante el cajón Generic stream reader, la señal es filtrada en la banda Alfa/Beta (8 Hz- 30 Hz), debido al estado de atención del usuario que es requerido en el entrenamiento, utilizando un filtro Butterworth pasabanda de orden 5. Tanto la señal de salida del filtro como los estímulos cargados con la sesión registrada, son enviados a un cajón Identity.

Como las señales EEG están divididas por Épocas (segmentos), el cajón Stimulation based epoching permite seleccionar algunas señales cerca a unos eventos específicos (las clases) utilizando como métrica las épocas. Para este caso, el usuario en el escenario previo, es instruido para imaginar cada uno de los movimientos de la mano derecha e izquierda; está tarea mental se registra en aproximadamente 5 segundos por cada muestra. Para seleccionar la señal del bloque relativa a la imaginación de la mano derecha, generalmente, se prevé medio segundo como una fase en donde el usuario está empezando a realizar la tarea y otro medio segundo al final de cada estímulo en

donde el usuario está agotado y no realiza la tarea de forma óptima. Entonces la configuración de este bloque es: duración 4 segundos, offset 0.5 segundos y la estimulación se registra en OpenViBe; de la misma manera se hace para la imaginación del movimiento de la mano izquierda. Esta configuración permite identificar en qué época de la señal, el usuario ejecuta cada una de las dos acciones con imaginación motora propuesta, las salidas de cada cajón son recibidas por el CSP Spatial Filter Trainer, el cual, junto con la información del estímulo permite calcular los coeficientes del filtro espacial (de orden 8 en este caso) de acuerdo al algoritmo CSP. La matriz de transformación de este filtro permite atribuir a cada uno de los 8 canales, las 8 mejores componentes CSP las cuales maximizan la diferencia entre cada clase de imaginación motora. Este algoritmo, permite incrementar la varianza de la señal de una de las clases mientras minimiza la otra. Una previsualización del Escenario de entrenamiento del filtro CSP es mostrada a continuación:

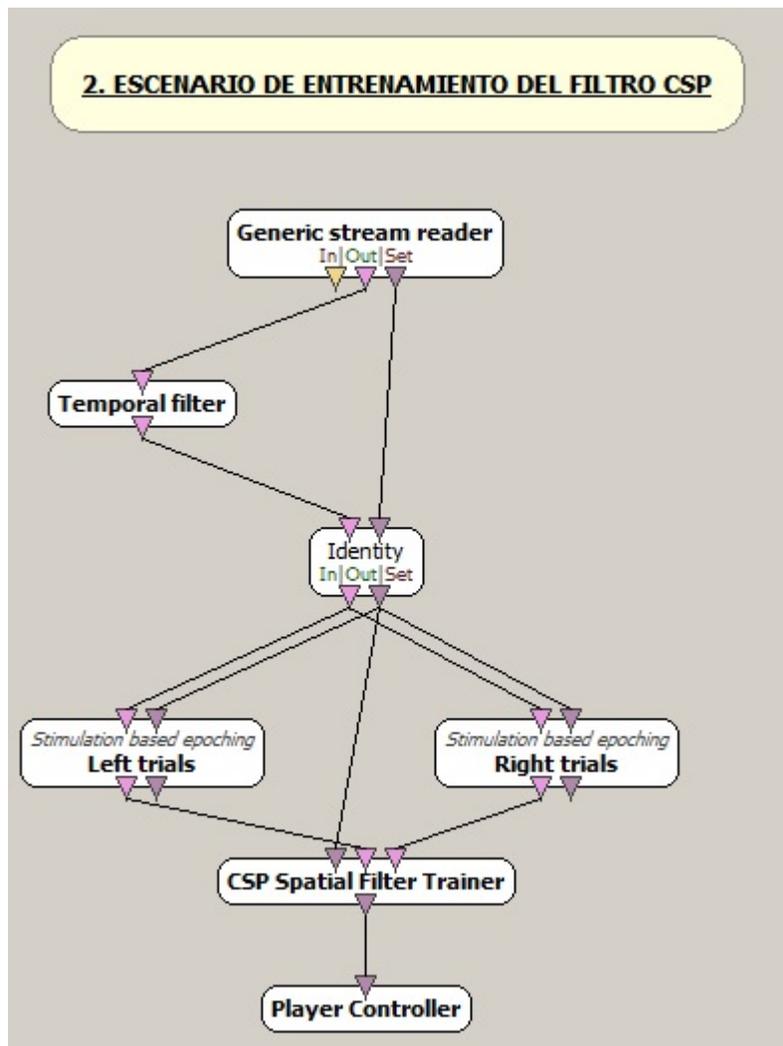


Figura 4.5. Previsualización del Escenario de entrenamiento del filtro CSP.

Finalmente, una vez entrenado el filtro CSP, el sistema arroja un archivo que contiene la configuración de los parámetros de dicho filtro y le envía la orden a la GUI de OpenviBe de detener el proceso mediante el Player Controller. Este archivo será utilizado en el próximo escenario con el fin de completar la etapa de extracción de características.

Escenario de Entrenamiento del Clasificador

Este escenario está diseñado para entrenar el algoritmo de clasificación a través de los datos de entrenamiento y el filtro espacial CSP obtenido en el escenario anterior. A través del cajón Generic Stream Reader los datos de entrenamiento son cargados, la señal es filtrada en la banda Beta y el filtro espacial CSP se carga en un cajón Spatial Filter. Se configuran los parámetros de los segmentos o Épocas con los mismos parámetros del escenario anterior (duración 4 segundos, offset 0.5 segundos) para los elementos de cada clase. El cajón Time Based Epoching permite generar Épocas (trozos de señal) en donde se pueden configurar las longitudes específicas, para este caso la señal es partida en bloques de 1 segundo con intervalos de 0.125 segundos (frecuencia de muestreo del EPOC 128 Hz y el tamaño del bloque es de 16 muestras $16/128 = 0.125$). Esto se realiza con el fin de mejorar el cálculo de la potencia espectral de la señal (de lo contrario el espectro sería grueso o tosco), para añadirlo como característica al clasificador. Usando los cajones Simple DSP se pueden aplicar fórmulas matemáticas a cada muestra de la señal, el cálculo de la potencia espectral puede ser llevado a cabo a través de un bloque que eleva al cuadrado la señal, otro que permite realizar el cálculo del promedio de la señal (Signal Average) y finalmente, se realiza el log $(1+x)$, siendo x la señal de entrada. Se agrega un bloque de Feature aggregator que permite añadir al clasificador la potencia espectral de la señal como una característica y se realiza el entrenamiento del clasificador usando el Classifier trainer, el cuál puede ser configurado para entrenar un clasificador LDA o un SVM. Para éste trabajo se realizan pruebas usando tres clasificadores; el LDA, la versión clásica de las máquinas de soporte vectorial denominada C-SVC con un Kernel Lineal y una versión modificada de las máquinas de soporte vectorial denominada -Support Vector Classification (Nu-SVC) el cual añade el parámetro ν , que permite un control del número de vectores y errores de soporte. El parámetro $\nu(0, 1]$ es un límite (cota) superior de la fracción de errores de entrenamiento y un límite inferior de la fracción de vectores de soporte; así la función de costo queda:

$$J(w, \xi) = \frac{1}{2} \|w\|^2 - \nu\rho + \frac{1}{l} \sum_{i=1}^l \xi_i \quad (4.1)$$

sobre las restricciones:

$$y_i(w^T x_i + b) \geq \rho - \xi_i, \quad \xi_i \geq 0, \quad \forall_i = 1, \dots, l, \quad \rho \geq 0 \quad (4.2)$$

Donde ν es un parámetro preseleccionado y l , es el número de puntos de entrenamiento. La sintonización escogida para los parámetros fue la siguiente: $\epsilon = 0,1$, Tolerancia $Tolerancia\epsilon =$

0,001 y finalmente el parámetro Nu fue sintonizado para obtener el mejor resultado en el clasificador. Este parámetro indica un límite inferior del número de vectores soporte a usar, dado como una fracción del total de muestras de calibración y un límite inferior sobre la fracción de muestras de entrenamiento que son errores (pobrementemente predecidas). También se aplicó un Kernel RBF que mejoró notablemente la exactitud del clasificador Nu-SVC sobre el Kernel lineal aplicado al C-SVC. El parámetro en el RBF-SVM permite controlar la forma de separación del hiperplano, con lo cual, el incremento de éste parámetro usualmente incrementa el número de vectores soporte, para este experimento se utilizó $\gamma = 100$. El resultado de este escenario es un archivo de configuración del entrenador, el cual contiene los parámetros del algoritmo que será usado para la clasificación en línea realizada en el último escenario. Para la valoración del mejor clasificador es utilizada la validación cruzada (k-fold test) con 5 iteraciones, este parámetro del cajón Classifier Trainer permite el cálculo de la exactitud del clasificador y lo imprime en consola. Si la exactitud se encuentra por debajo del 65 %, es recomendable volver a entrenar al usuario con el fin de obtener un buen control de la aplicación. El escenario es mostrado en la figura 4.6.

Escenario de Clasificación en Línea

Finalmente, en este escenario se busca realizar la clasificación en línea de las acciones de imaginación motora entrenadas con el usuario. Para esto, son cargados los archivos obtenidos en los escenarios de entrenamiento del filtro CSP y el entrenamiento del clasificador. Las señales son tomadas mediante el cajón de Acquisition client, filtradas en la banda ALFA/BETA y los canales seleccionados son exactamente los mismos usados en la etapa de entrenamiento del usuario. Se carga el archivo del filtro espacial mediante el cajón de Spatial Filter, todos los cajones de la etapa de extracción de características con los mismos parámetros son repetidos en este escenario, ya que se debe asegurar que la clasificación en línea se realice bajo las mismas condiciones del entrenamiento. Después de calcular y agregar la potencia espectral como característica, el Classifier processor permite cargar el archivo de configuración del algoritmo de aprendizaje realizado en el escenario anterior, así como las etiquetas de las clases cargadas, con el fin de realizar la clasificación en línea con LDA o SVM. Para el uso de las máquinas de soporte vectorial, es necesario agregar un cajón de Simple DSP que permita desplazar la señal mediante la función $x-0.5$, para que los valores de salida del clasificador se encuentren entre 0 y 1. Nuevamente el estimulador de Graz (Graz Motor Imagery BCI Stimulator) es usado con el fin de realimentar al usuario en la sesión online. Sin embargo, usando el Graz Visualization, se pueden escoger si mostrarle al usuario la realimentación de sus tareas mentales, las instrucciones provenientes de la estimulación de Graz o las dos juntas en una ventana. Esta herramienta, permite mostrar el porcentaje de acierto de cada acción pensada en tiempo real del usuario. Finalmente, toda la sesión es grabada utilizando el cajón Generic stream writer. Una imagen del escenario es mostrada en la figura 4.7

Adicionalmente, se presenta un resumen de las técnicas empleadas para cada una de las etapas de

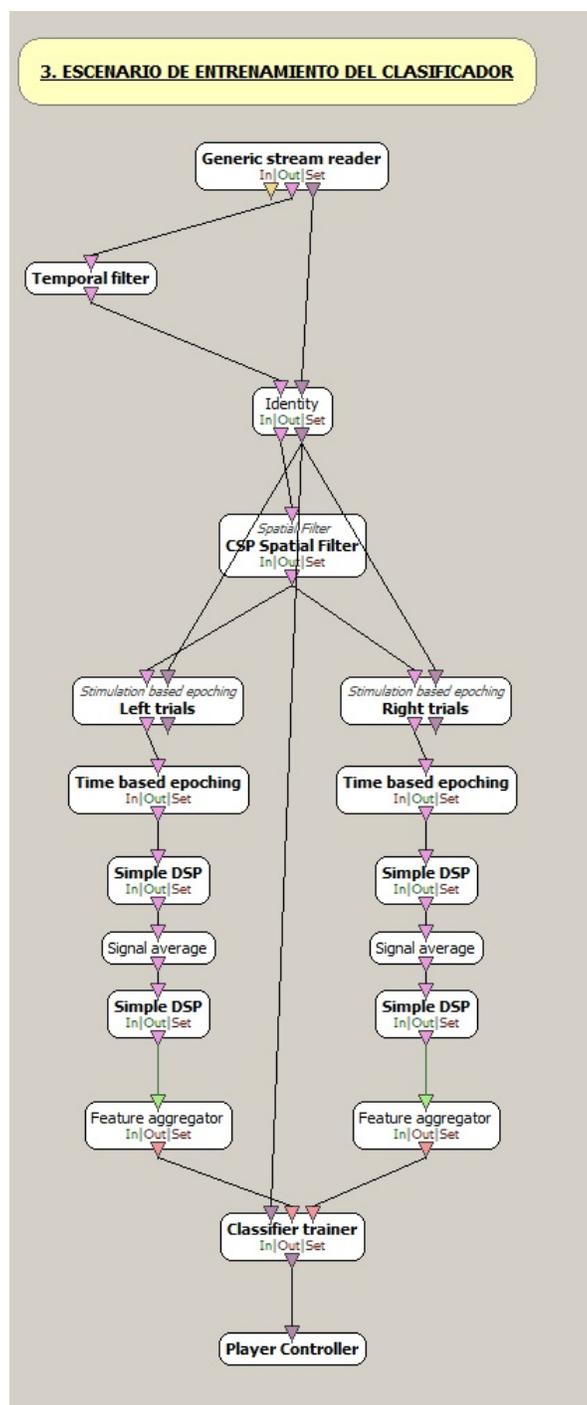


Figura 4.6. Previsualización del Escenario de entrenamiento del clasificador.

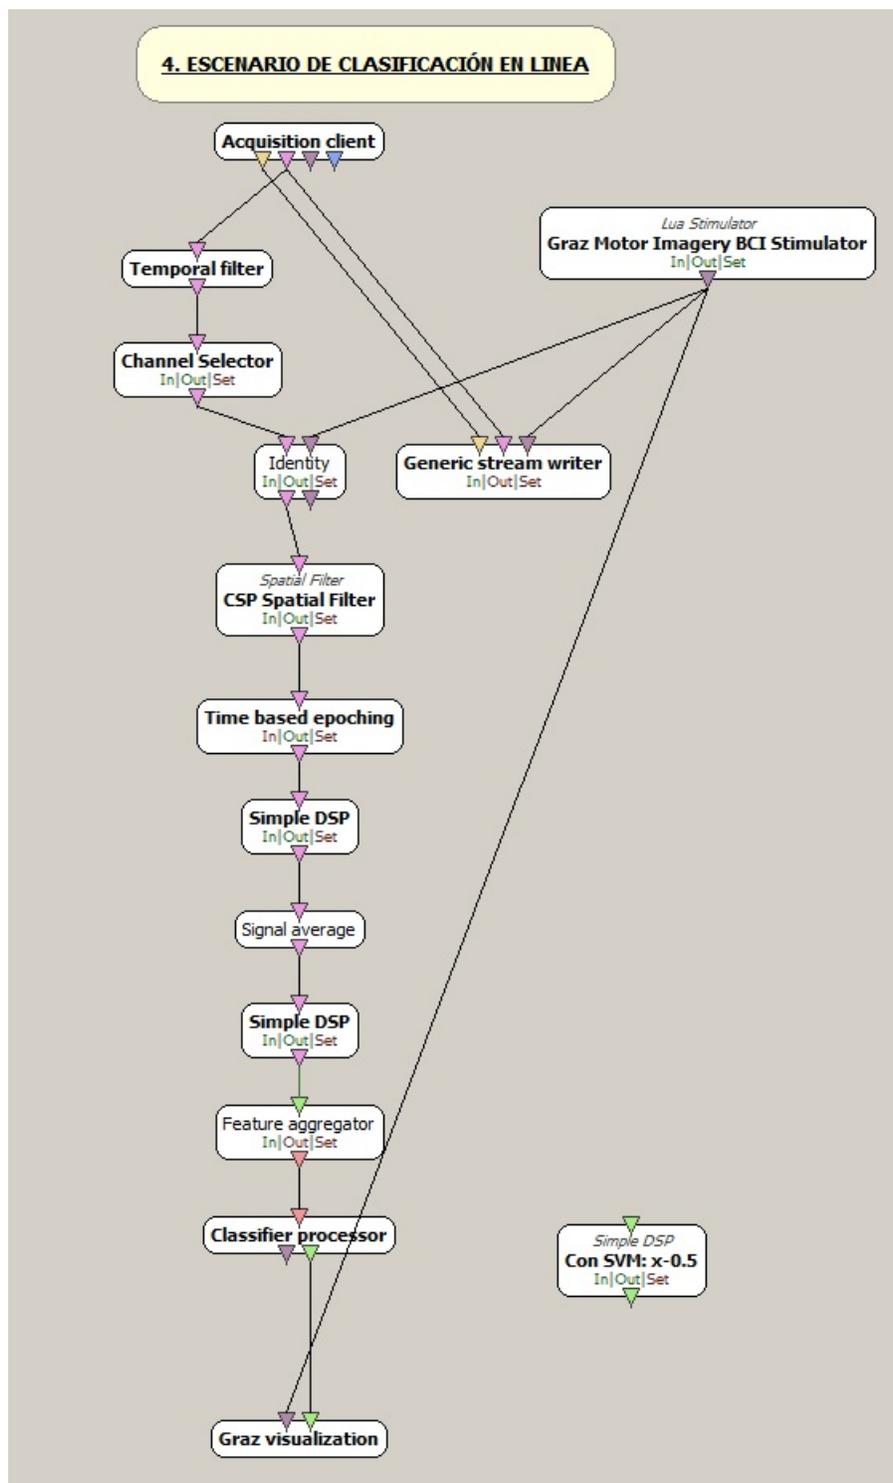


Figura 4.7. Previsualización del Escenario de entrenamiento del clasificador.

la aplicación BCI, esto es, pre-procesamiento de la señal, extracción de características, técnicas de aprendizaje de máquina y validación del clasificador. Los clasificadores utilizados fueron escogidos según la guía mostrada en el capítulo de aprendizaje de máquina.

Estrategia Mental	Clasificación BCI	Pre-procesamiento	Ext. de Características	Clasificador
Imaginación Motora (Biclas: Mano Izquierda Vs. Mano Derecha)	Sistema Asíncrono (Señales: ERD/ERS)	Selección de canales	CSP	LDA
		Rechazo de artefactos, filtrado de Banda (80-30) Hz		C-SVC con Kernel lineal
		Extracción de Época, selección de Ventana Temporo-Frecuencial		Nu-SVC con Kernel RBF

Tabla 4.1: Resumen de las diferentes técnicas utilizadas en las etapas del sistema BCI desarrollado.

Comunicación entre el OpenViBe y el Videojuego

Finalmente después de haber obtenido el clasificador, es necesario conectar el resultado de la clasificación en línea con el videojuego o la aplicación final en general. Esto se realiza a través de un sistema que brinda una interfaz de red transparente e independiente del dispositivo para la comunicación con periféricos de realidad virtual llamada VRPN (Virtual-Reality Peripheral Network) [109]. El VRPN es una biblioteca que permite la abstracción de los periféricos como un añadido de componentes básicos, como datos analógicos, botones o seguidores (que permiten una localización y orientación en el espacio). Una de las formas en la que OpenViBe utiliza estos componentes, es a través de estados de botones usando una emulación de un dispositivo multibotones. Los estados son flujos controlados de estimulación y cada botón puede ser presionado y liberado mediante identificadores de estimulación dados. El número de botones emulados del dispositivo depende del número de entradas en el cajón. Cada vez que una entrada es adicionada, las correspondientes estimulaciones de ON/OFF son añadidas a la configuración del cajón. Partiendo de estas premisas, cualquier aplicación VRPN es capaz de obtener parámetros desde OpenViBe y brindar una realimentación al usuario como información visual o cualquier forma de realimentación propuesta. Cada entrada tiene un correspondiente par de estimulación que son usados para presionar o liberar los botones. La señal también puede ser enviada a través de datos analógicos, desde donde se establece una frecuencia de muestreo y se envían datos al servidor VRPN establecido. Dentro del OpenViBe existen bloques que permiten realizar vinculaciones de los escenarios desarrollados con aplicaciones externas mediante el uso de la VRPN utilizando servidores button y analog:

- Button VRPN Server: permite crear servidores que recibirán los diferentes estados relacionados a los interruptores (ON/OFF) y activará o desactivará los botones. Las entradas del cajón

son ilimitadas, sin embargo el número total de botones del dispositivo a emular debe ser exactamente el mismo que los números de entrada (para este caso pueden agregarse botones para cada clase). Las entradas se configuran para recibir los flujos de estímulos y permiten cambiar los correspondientes estados de acuerdo a 2 estimulaciones; cada entrada tiene un par de códigos de estimulación que son usados para presionar o liberar los botones. Una configuración adicional es requerida, el nombre del periférico emulado, el cual será usado por la aplicación externa con el fin de comunicarse con el periférico. Si la configuración es `openvibe-vrpn` y la máquina corriendo en OpenViBe es `openvibe-machine`, entonces el nombre del periférico VRPN completo es `openvibe-vrpn@openvibe-machine`.

- **Analog VRPN Server:** permite crear servidores VRPN análogos que envían datos desde los cajones de entrada disponibles en el escenario hacia las aplicaciones cliente. La forma en la que OpenViBe envía los datos a la aplicación externa consiste en la emulación de un dispositivo multicanal análogo, desde los cuales se envían las señales análogas constantemente según la frecuencia de muestreo establecida. El número de elementos contenidos en los buffers del flujo fijará el número de canales del dispositivo emulado. Este cajón requiere del establecimiento del nombre del periférico que será emulado para el envío de las señales. Para la previsualización de la señal de salida puede ser vista dentro del escenario del OpenViBe utilizando el cajón `Matrix Display`. Este cajón se conecta a la salida de los clasificadores y permite obtener datos análogos de la clasificación en línea según el algoritmo de clasificación usado; por ejemplo para el caso del LDA imprime el valor de la distancia al hiperplano.

Finalmente se requiere generar un programa cliente en C++ para la recepción de los datos desde OpenViBe a través del VRPN y la comunicación con el videojuego en Unity o cualquier otra aplicación externa. Para esto, es necesario descargar y compilar las librerías del VRPN y utilizar las cabeceras `vrpn_Button.h` y `vrpn_Analog.h`, para los botones y los canales análogos respectivamente. Ahora bien, cada servidor tiene que tener un objeto cliente asociado, para esto es necesario crear los objetos utilizando la siguiente línea de código:

```
VRPNAnalog = new vrpn_Analog_Remote( "openvibe_vrpn_analog@localhost" )
```

En este caso particular, se está creando un handler para un Analog Client. El aspecto más importantes de este objeto es el contenido del paréntesis, en donde la parte antes de la `@` es el nombre del periférico especificado dentro del escenario en OpenViBe y el cajón Analog VRPN Server (en este caso). La parte después de la `@` es el nombre del host del computador donde el servidor está corriendo, como la aplicación cliente y el escenario del OpenViBe están corriendo en la misma máquina, entonces se utiliza `localhost` como el nombre del host. Ahora bien, para enlazar el objeto al handler es necesario crear un callback (una función que se usa como argumento de otra

función), así cada vez que el cliente recibe una entrada el handler del callback será ejecutado. La línea de código para realizar esto es la siguiente:

```
void VRPN_CALLBACK vrpn_analog_callback(void* user_data, vrpn_ANALOGCB analog)
```

El callback relacionado al periférico VRPN análogo contiene los siguientes miembros:

- `num_channel`: el número de canales recibidos por el client VRPN. Este valor no es necesariamente el número de entradas en el cajón VRPN
- `Analog Server` dentro del escenario del OpenViBe. `channel[]`: es un arreglo que contiene los valores recibidos.

El OpenViBe envía datos transmitidos por los bloques (streamed) de matriz que contienen varios valores. Cada matriz de streaming puede tener muchos canales, también cada cajón VRPN Analog Server puede tener muchas entradas; todos los datos tienen que ser enviados al cliente VRPN al mismo tiempo por lo que se puede procesar en una corrida. El OpenViBe se acopla a todos los datos en una matriz unidimensional y los envía a través del VRPN. La siguiente línea de código es usada para imprimir los valores del canal análogo tomado de la salida del clasificador.

```
std::cout << "Analog Channel : " \<< i \<< "Analog Value : " << analog.channel[i] << std::endl;
```

Después de esto, se captura la variable de relacionada con el valor análogo del canal con el fin de umbralizarlo y permitir la generación de los eventos de teclado para la comunicación con el videojuego. Esto se realiza en la etapa final donde se crea un bucle con el fin de consultar permanentemente el estado del objeto creado y verificar si hay nuevos datos de entrada. Para este caso se crea un bucle del objeto así:

```
while (running)
{
    VRPNAnalog->mainloop();
}
```

En este bucle entonces se añaden los eventos necesarios para la conexión con el videojuego, teniendo en cuenta la salida de la señal análoga del clasificador, para este se trabajan con eventos de teclado que coinciden con dos teclas de disparo (una para cada mano) dentro del escenario del videojuego. Particularmente, la función `keybd_event` en `C++` me permite escribir parámetros alfanuméricos utilizando las librerías `windows.h` y la siguiente línea de código:

```
keybd\_event('X', 0, 0, 0);
keybd\_event('X', 0, KEYEVENTF\_KEYUP, 0);
```

Así, cada vez que el valor del canal análogo sobrepase un valor umbral (definido según el clasificador), el programa cliente enviará la señal de disparo al videojuego mediante la simulación de presionar y soltar un parámetro alfanumérico del teclado. Después de compilar el código, se genera el ejecutable por donde se comunicarán los periféricos del VRPN establecidos en el OpenViBe.

RESULTADOS Y ANÁLISIS

5.1. Experimento MI-BCI

Se realizó el experimento descrito con 8 usuarios adultos jóvenes entre los 24 y 28 años de edad, de género masculino, sin ninguna condición patológica o desorden neurológico diagnosticado. A cada uno de los usuarios se le indicó la rutina del experimento justo antes de comenzar. Las intervenciones fueron realizadas siempre en las primeras horas del día (8:00 am. - 9:00 am.) con el fin de evitar factores como el estrés o sudoración excesiva, además se les solicito dormir bien la noche anterior con el fin de disminuir los inconvenientes con estados de somnolencia durante la intervención del experimento.

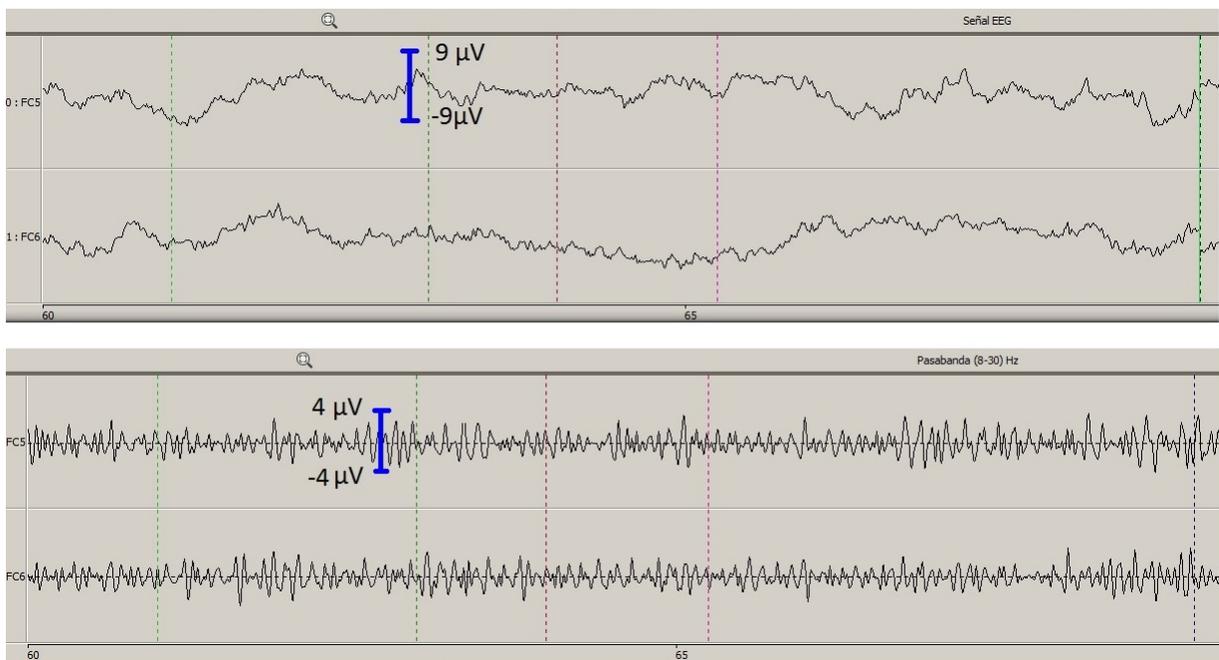


Figura 5.1. Señales de los electrodos FC5 y FC6 antes y después del procesamiento con el filtro entre las bandas Alfa y Beta.

Se verificó que el estado de conductividad de los electrodos del EPOC estuviera en un buen nivel según la convención de colores (verdes o amarillos para una buena conducción) y por último se ubicó el usuario al frente de la pantalla para iniciar la sesión de entrenamiento. Para cada usuario, fueron evaluados tres clasificadores: LDA, C-SVC con Kernel Lineal y Nu-SVC con Kernel Gaussiano. La gráfica 5.1 muestra el efecto que produce el filtro pasabanda aplicado a la señal de los electrodos FC5 y FC6 sobre uno de los usuarios.

Ahora bien, el fenómeno de los ERD/ERS que son producidos con las tareas mentales de imaginación motora en las sesiones de entrenamiento se genera en las bandas mu y beta en los electrodos cercanos a la corteza motora. En cada usuario la latencia de estas dos señales puede ser vista usando mapas tiempo-frecuencia, los cuales brindan una vista de la actividad sobre las bandas de frecuencia en cada electrodo (o sobre un filtro espacial) mostrando el incremento o decremento durante las tareas de imaginación motora. Las siguientes figuras, muestran mapas tiempo-frecuencia calculados de cada usuario durante una tarea de imaginación específica, los mapas cubren el rango de frecuencia filtrado (8 Hz- 30 Hz) y se realizan sobre los electrodos en donde de forma individual, cada usuario mostró mejor latencia de los ERD/ERS. Las capturas son realizadas en uno de los momentos en donde el usuario es expuesto a los estímulos de entrenamiento de imaginación motora en un intervalo de 4 segundos (con el fin de tomar un par de segundos antes). Aunque no es fácil detectar diferencias a través de inspecciones visuales, un análisis más extenso de estos mapas podría brindar algunos componentes frecuenciales que podrían ser seleccionados para ajustar los filtros y lograr una mejor descripción de los patrones para cada individuo. A la derecha de cada mapa se muestra el espectro de potencias de los electrodos escogidos.

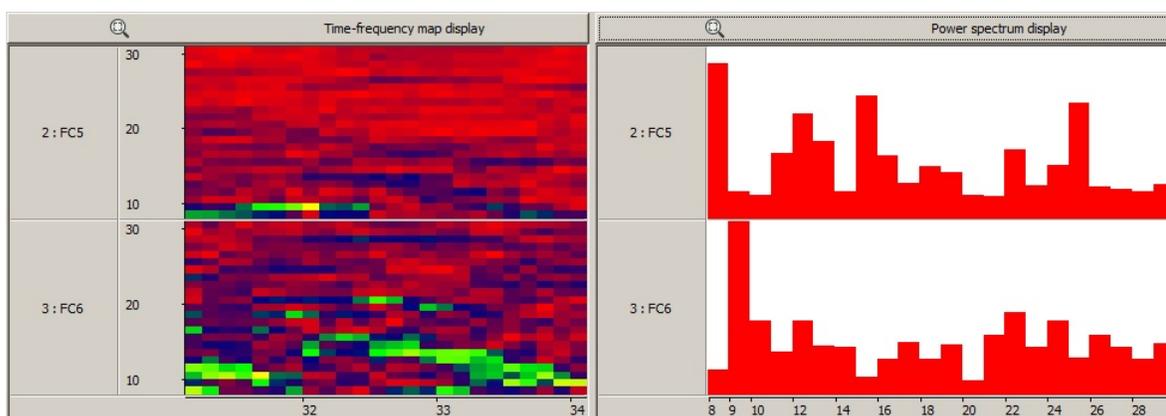


Figura 5.2. Aquí el sujeto 1 imagina el movimiento de su mano izquierda representado en el electrodo par.

Finalmente se presentan los resultados de clasificación para cada usuario con cada uno de los clasificadores usados para la estrategia mental de imaginación motora. El comportamiento de

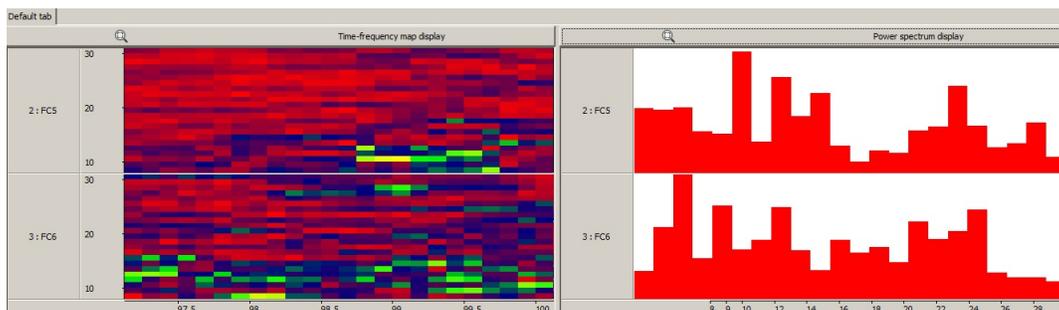


Figura 5.3. Aquí el sujeto 2 imagina el movimiento de su mano izquierda representado en el electrodo par.

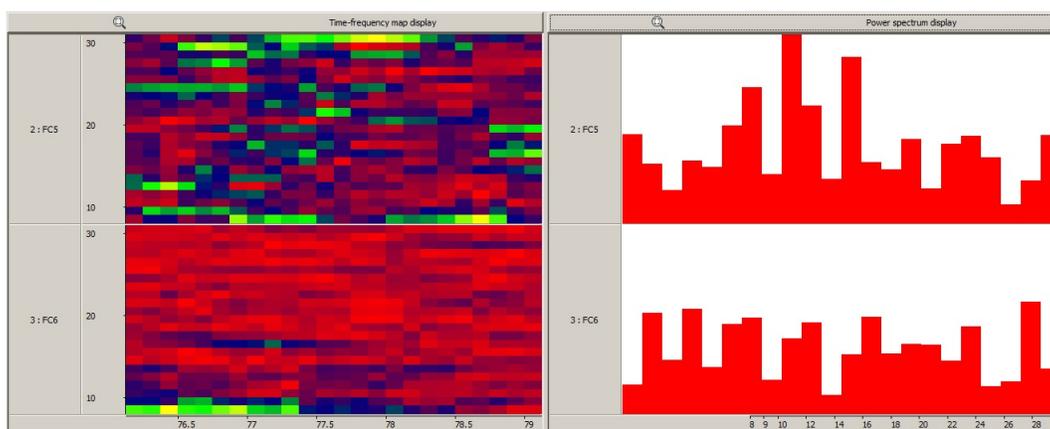


Figura 5.4. Aquí el sujeto 3 imagina el movimiento de su mano derecha representado en el electrodo impar.

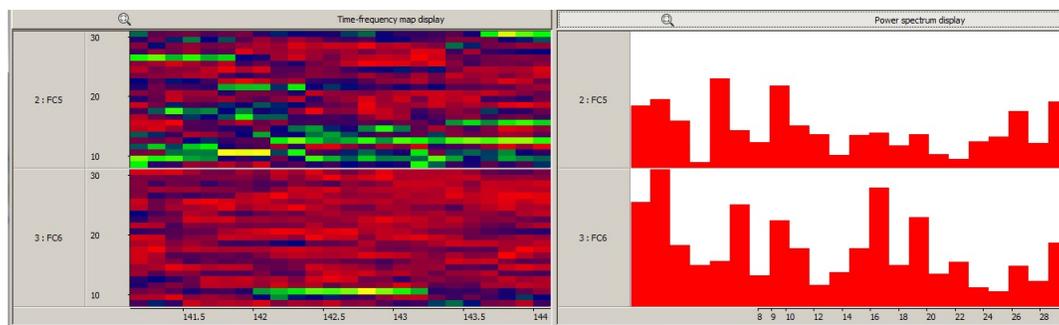


Figura 5.5. Aquí el sujeto 4 imagina el movimiento de su mano derecha representado en el electrodo impar.

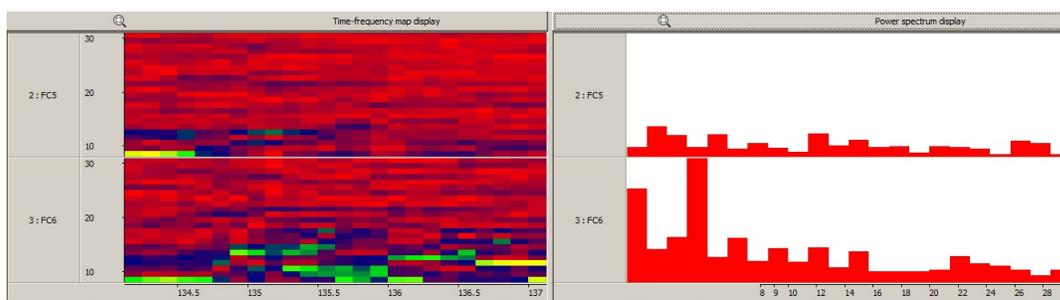


Figura 5.6. Aquí el sujeto 5 imagina el movimiento de su mano izquierda representado en el electrodo par.

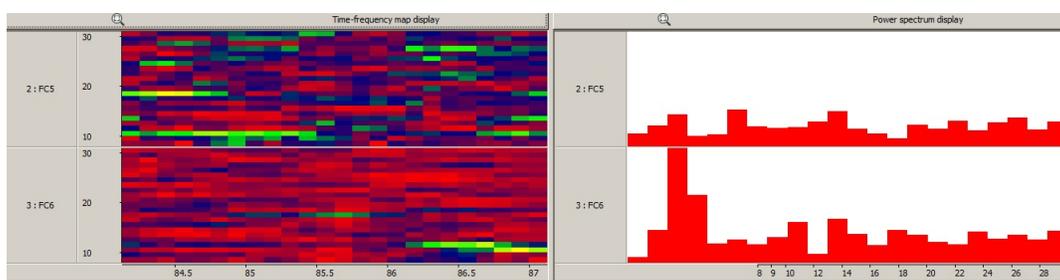


Figura 5.7. Aquí el sujeto 6 imagina el movimiento de su mano derecha representado en el electrodo impar.

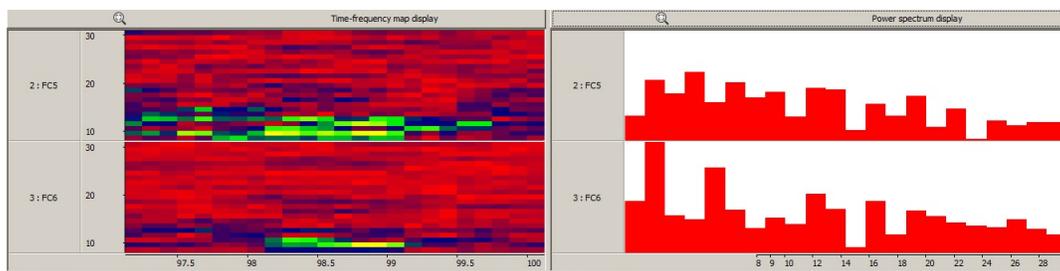


Figura 5.8. Aquí el sujeto 7 imagina el movimiento de su mano derecha representado en el electrodo impar.

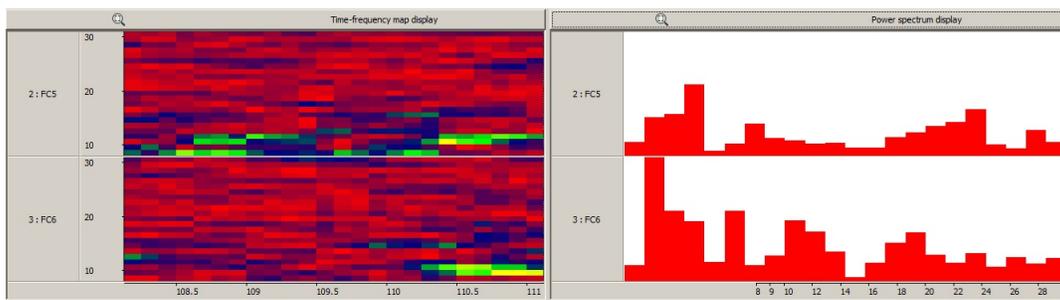


Figura 5.9. Aquí el sujeto 8 imagina el movimiento de su mano derecha representado en el electrodo impar.

Sujeto	LDA(%)	C-SVC con Kernel Lineal (%)	Nu-SVC con Kernel RBF	Mejor Valor de Nu
S1	68.1	67.3	95.7	0.2
S2	62.0	62.4	95.6	0.3
S3	73.3	73.3	97.9	0.3
S4	71.0	71.5	98.5	0.4
S5	66.7	71.2	97.2	0.3
S6	68.1	69.4	96.7	0.5
S7	59.4	59.4	95.3	0.2
S8	72.1	71.5	97.5	0.1
Prom	67.6	68.3	96.7	0.3

Tabla 5.1: Exactitud de los clasificadores evaluados en 8 usuarios diferentes.

la máquina de soporte vectorial Nu-SVC con el Kernel Gaussiano, mostró un comportamiento sobresaliente sobre los otros dos clasificadores. La sintonización manual de la cota Nu, permitió que los resultados obtenidos en este trabajo superaran trabajos previos realizados con sistemas BCI de bajo costo como el EPOC [110], [111]; los cuales siempre han sido ampliamente criticados por su baja exactitud en estrategias mentales puntuales. La siguiente tabla muestra los resultados de los diferentes clasificadores aplicados sobre los datos de los 8 usuarios.

Como se muestra, la implementación de la máquina de soporte vectorial Nu-SVC y la sintonización manual del parámetro Nu permitieron aumentar más del 25 % en la exactitud de clasificación con respecto a los demás clasificadores. La figura 5.10 muestra la exactitud promedio de los 3 clasificadores para todos los 8 usuarios.

La variación del parámetro Nu en la máquina de soporte vectorial, arrojó pequeños cambios en la exactitud del clasificador cuando se utiliza un valor de gamma igual a 100. Cuando el parámetro gamma se sintoniza en valores pequeños, la variación del parámetro Nu arroja cambios mayores en la exactitud final del clasificador Nu-SVC. La siguiente gráfica muestra el comportamiento de la clasificación del Nu-SVC cuando los valores de Nu son modificados para todos los usuarios para un mismo valor de gamma igual 100.

Esta parametrización de la máquina de soporte mediante el parámetro Nu permite un control del número de vectores de soporte y errores. Controlar el número de vectores de soporte tiene consecuencias para: 1) complejidad en el tiempo de ejecución ya que el tiempo de evaluación de la función estimada se escala de forma lineal con el número de vectores de soporte [112], 2) tiempo de entrenamiento, por ejemplo, cuando se utiliza un algoritmo de segmentación el cual incrementa la complejidad con el número de vectores de soporte, 3) los límites del error en la generalización, el algoritmo optimiza directamente una cantidad por medio de la cual uno puede dar los límites de generalización. Además, asintóticamente, el valor Nu controla directamente el número de vectores de soporte y el último puede ser usado para dar un límite de generalización en la validación con

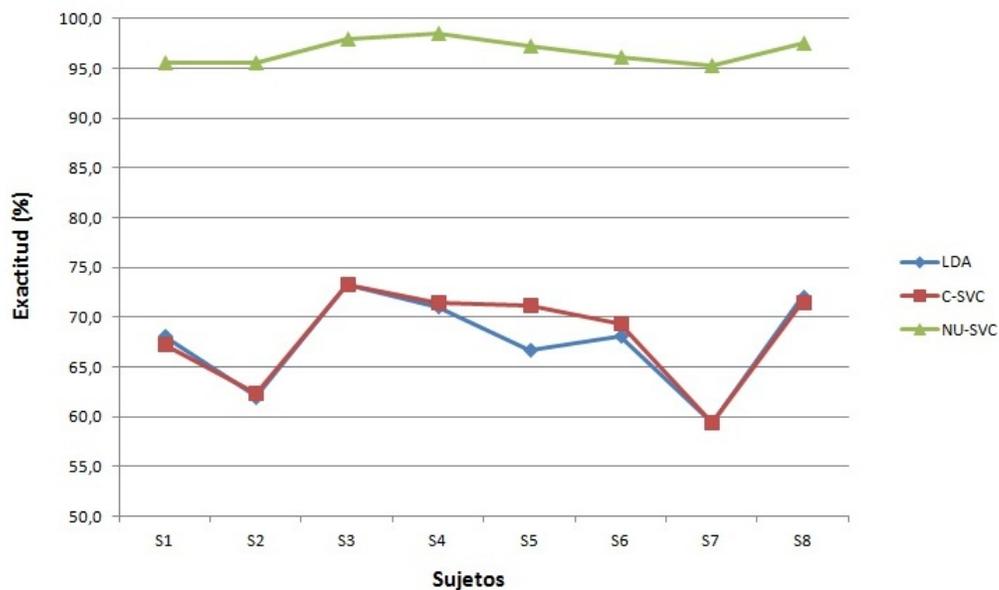


Figura 5.10. Resultados de la clasificación de los patrones de imaginación con los 3 clasificadores para todos los usuarios.

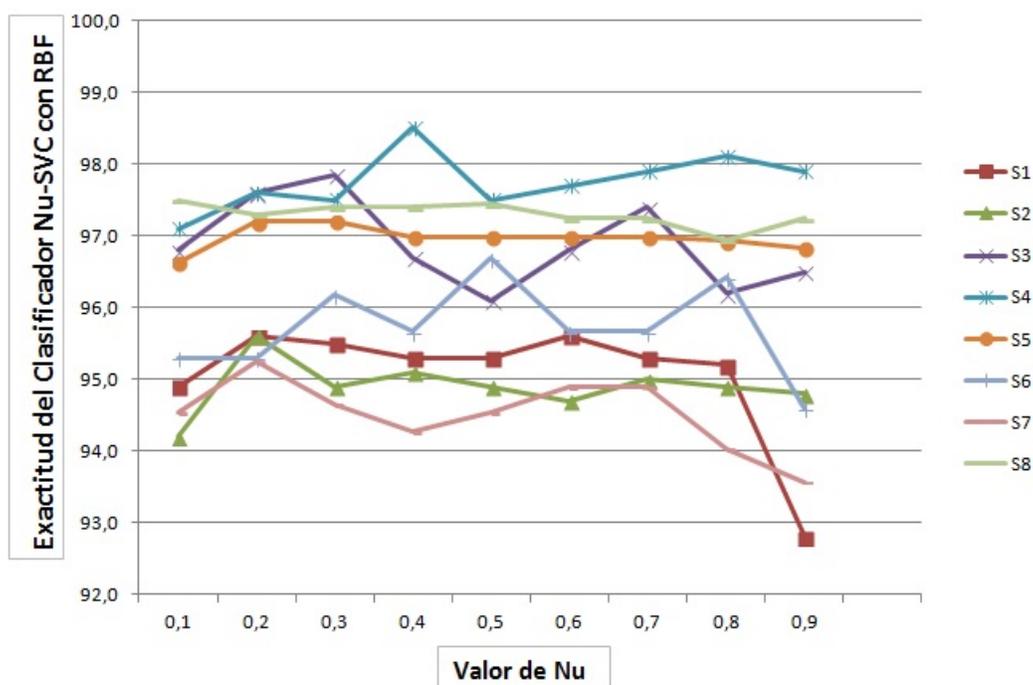


Figura 5.11. Exactitud del clasificador Nu-SVC con la sintonización del parámetro Nu.

dejar-uno-afuera [113].

Este trabajo implementa una estrategia mental muy utilizada para la interacción con sistemas BCI, la imaginación motora mediante un dispositivo inalámbrico de bajo costo usando un software gratuito de fuente abierta. A pesar de las limitaciones del sistema EPOC en cuanto a brindar señales de alta calidad para una aplicación BCI, la implementación de algoritmos de aprendizaje de máquina como las máquinas de soporte vectorial, puede brindar exactitudes interesantes en problemas biclase, comparables con experimentos que usan sistemas BCI más académicos, con una mayor cantidad de electrodos y más costosos.

5.2. Videojuego BCI Duck Hunt

BCI Duck Hunt, es un videojuego basado en la estrategia mental de imaginación motora creada para la interacción con interfaces cerebro computador. En esta estrategia, el usuario con solo imaginar ciertos movimientos de su cuerpo, puede generar señales detectables para controlar acciones dentro de un videojuego. Después de la fase de entrenamiento previa, el sistema es adaptado para reconocer dos clases en particular: la imaginación del movimiento de la mano derecha y la imaginación del movimiento de la mano izquierda con el fin de interactuar en un entorno tridimensional basado en el famoso videojuego de la Nintendo Duck Hunt. Dentro del videojuego, el jugador debe utilizar la imaginación de movimiento a través del sistema BCI Emotiv EPOC con el fin de disparar a los patos que vuelan por la pantalla, obteniendo puntos conforme su nivel de acierto. Para este caso, los disparos dependen de la capacidad que tenga el usuario de imaginarse cualquiera de los dos movimientos, si el pato sale en la parte derecha de la pantalla, el usuario deberá imaginarse el movimiento de su mano derecha para generar la acción de control que disparará y derribará el pato, de forma análoga, el usuario podrá hacerlo con los patos de la parte izquierda de la pantalla. Para disparar a los patos, el usuario dispone de unos cuantos segundos de vuelo; los patos vuelan fueran de la pantalla si no se logra la señal correcta en el tiempo estipulado. El videojuego finaliza con el total de objetivos impactados en una ronda de 10 oportunidades distribuidas aleatoriamente (derecha e izquierda). El documento de diseño fue elaborado utilizando teorías de condicionamiento operante aplicado a videojuegos [114], en donde se utilizan puntos de contingencia, los cuales permiten correlacionar eventos dentro del videojuego. Esta teoría utiliza los tres elementos clásicos del condicionamiento operante: antecedentes, establecidos como reglas y objetivos a alcanzar dentro del videojuego; comportamientos, relacionados a los estados mentales de imaginación motora a los que se desea inducir al usuario y finalmente, las consecuencias, establecidas como refuerzos positivos y negativos que se definen dentro del videojuego cada vez que el usuario realiza o no realiza la tarea mental propuesta.

5.3. Aplicaciones clínicas de la imaginación de movimiento en rehabilitación

El potencial que tiene la práctica mental (PM) a través de la imaginación de movimiento sobre la optimización de los procesos de recuperación de la función motora en varios campos de la rehabilitación física y más particularmente en la neurorehabilitación, ha creado un interés multidisciplinario que ha permitido fortalecer campos como el de la neurociencia computacional y la ingeniería neural [96]. Una de las principales ventajas de usar MI en terapia es que el ensayo mental de las tareas motoras cuando y donde el usuario es capaz de practicarla, incrementa el número de repeticiones de una manera segura y autónoma sin fatiga física. El uso de la imaginación motora también permite la práctica de tareas motoras (ej. caminar, escribir, agarrar) en fases tempranas de rehabilitación cuando los pacientes son incapaces de ejecutarlas físicamente (ej. parestias, inmovilizaciones) [105]. Desde un punto de vista clínico, la imaginación de movimiento puede ser definida como un proceso activo durante el cuál la representación de una acción es internamente reproducida (o ejecutada) sin la manifestación de ninguna salida. Por el contrario, la práctica mental es la repetición de las acciones imaginadas con la intención de mejorar la ejecución física. La justificación del por qué usar MI en la rehabilitación de deficiencias motoras surge probablemente de las correlaciones existentes entre la MI y la ejecución física del movimiento: a) la duración del movimiento imaginado se correlaciona con la duración del movimiento real, b) la simulación de los movimientos evoca respuestas autonómicas similares, c) la imaginación de una acción involucra redes neuronales muy similares a la de su ejecución física [105]. Existe entonces un gran reto relacionado a la posibilidad de integrar prácticas mentales específicas como el entrenamiento basado en imaginación de movimiento a los programas regulares de rehabilitación con el fin de comprobar profunda y detalladamente sus efectos en determinadas patologías [115].

Algunos de los factores que se modifican en la práctica de la imaginación motora son:

- **Habilidad de imaginación:** con el fin de optimizar los beneficios de la práctica de MI, la habilidad de los individuos de usar la imaginación es de consideración relevante. La imaginación es una capacidad multifacética que difiere entre individuos, específicamente la habilidad de imaginación de movimiento usualmente es evaluada por las respuestas individuales a escalas de puntaje ordinales. Imaginar mentalmente un ejercicio hasta en sus más mínimos detalles y hacerlo todos los días puede conllevar a cambios reales en los aspectos físicos [115].
- **Familiaridad con la tarea:** algunos autores han asegurado que la familiaridad es un prerrequisito para el éxito de la práctica de la MI. Mutsaerts et al [116] mostraron que individuos con parálisis cerebral hemiparética cuya habilidad de imaginación fue dañada, fueron incapaces de planear nuevas tareas. Así entonces, la noción de la efectividad de la práctica mental es relacionada a la familiaridad con la tarea motora, las tareas familiares están

asociadas a mejores resultados que las tareas no familiares y este concepto tiene fundamento en las bases del aprendizaje motor.

- Memoria de trabajo: es un complejo proceso que incluye el almacenamiento y manipulación de la información, puede ser categorizada como visual, verbal o cinestésica. Malouin y colegas [117] describieron la imaginación de movimiento como un estado dinámico durante el cual la representación de una acción específica es internamente reactivada, por ende, el ensayo mental requiere que los sujetos manipulen y mantengan la información visual y cinestésica en su memoria de trabajo. Vale la pena señalar que la práctica de MI combinada con práctica física mostró mantener las ejecuciones de una tarea motora anticipatoria más que la práctica física sola en individuos con una alta probabilidad de déficits en la memoria de trabajo.
- Motivación: personas con bajos puntajes de ansiedad cognitiva tuvieron una mejor práctica mental que personas con puntajes de ansiedad altos. Involucrar una práctica mental en sesiones de neurorehabilitación puede aumentar la excitación y la autoeficacia y por consiguiente tener un efecto positivo en la motivación y la autoconfianza [118].

5.4. Aplicaciones en Teleoperación de Sistemas Robóticos

Particularmente han sido identificadas 5 áreas de aplicación en donde personas en condición de discapacidad podrían beneficiarse ampliamente de los avances de la investigación con los sistemas BCI: a) comunicación y control, b) sustitución motora, c) entretenimiento, d) recuperación motora y d) monitoreo de estados mentales [119]. El control de sistemas robóticos con el fin de generar dinámicas de teleoperación a través de intenciones mental ha sido explorado por la comunidad BCI desde el 2004 [120], desde entonces, se han propuesto técnicas de control accionadas por el cerebro utilizando sistemas no-invasivos con el fin de operar dispositivos físicos como sillas de ruedas, manipuladores, humanoides de pequeño tamaño, órtesis operadas mediante estimulación eléctrica funcional, entre otros [121]. Utilizando el sistema de entrenamiento basado en imaginación motora, se pueden establecer comunicaciones con diferentes sistemas robóticos a través del puerto virtual creado desde el OpenViBe, el cual permite el envío continuo de datos análogos. Uno de los sistemas robóticos que posee el grupo de investigación es el Galileo Explorer, un robot explorador oruga con comunicación GSM (Global System for Mobile communications) que tiene articulado un brazo robótico con una cámara para tareas exploratorias. Una de las interfaces de comunicación con el sistema es a través de una GUI diseñada en Visual Basic, la cual permite el envío de señales para la navegación del sistema (adelante, atrás, parada, izquierda, derecha) y para el movimiento del brazo articular. Fueron adicionados comandos para el control con el sistema BCI de dos de las señales del sistema robótico: ir adelante y parada; con el fin de mostrar el principio de teleoperación basado en el accionamiento controlado a través de intenciones mentales. La siguiente imagen muestra el Galileo Explorer y la GUI final del prototipo:

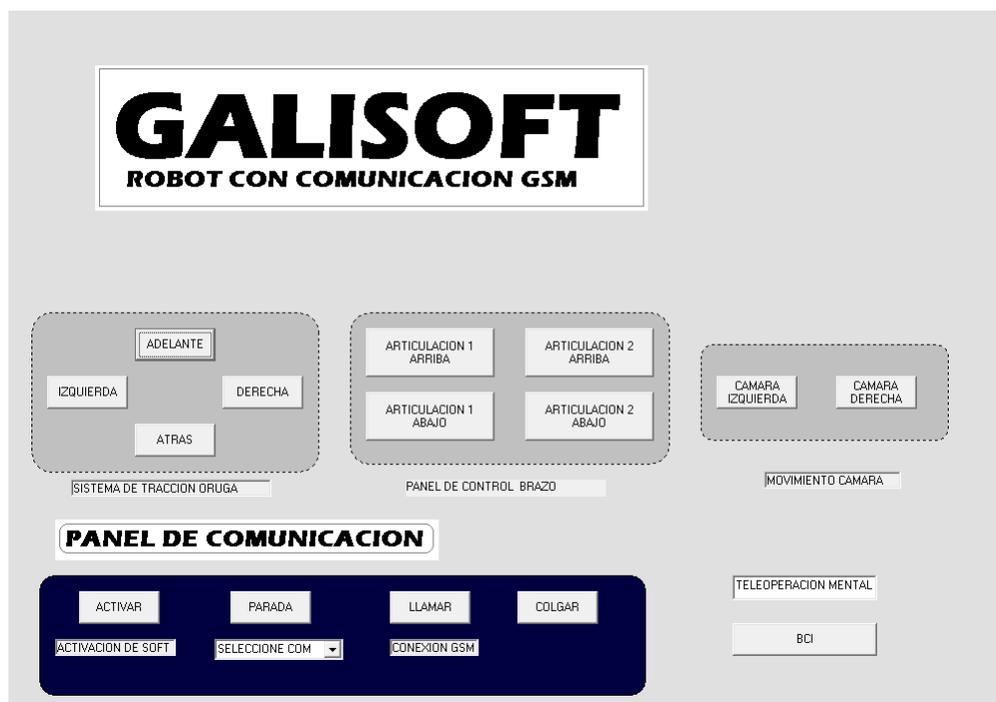


Figura 5.12. Interfaz de usuario desarrollada para la teleoperación del sistema robótico Galileo Explorer.

Se realizaron pruebas funcionales en donde utilizando la configuración BCI experimental descrita con anterioridad, se logran enviar señales de control al sistema robótico mediante la clasificación en línea de las clases de imaginación motora. Este tipo de aplicaciones brindan un punto de partida trascendental en la elaboración de sistemas neurocontrolados que pueden beneficiar a personas en condiciones de discapacidad, sistemas como sillas de ruedas eléctricas, prótesis y brazos robóticos podrían ser adaptadas para un control a través de intenciones mentales mediante un entrenamiento cuidadosamente planeado. Quizá en un futuro no muy lejano, podamos establecer una comunicación fluida entre nuestros pensamientos y movimientos, con un avatar físico real al mejor estilo de James Cameron.

CONCLUSIONES

En esta tesis se ha realizado una metodología para la implementación de un experimento de imaginación motora biclase a partir de señales de electroencefalografía (EEG) tomadas de una interfaz cerebro computador (BCI) de bajo costo, a través de la clasificación de señales usando en el fenómeno de eventos relacionados a desincronizaciones. Para ésto se utilizó el OPenViBe, un software de acceso gratuito que ha sido creado para promover la investigación con sistemas BCI, en donde se implementaron escenarios para las etapas de procesamiento, extracción de características, clasificación y aplicación final. Particularmente, fueron usados criterios de selección de canales de EEG basados en la cercanía espacial de los electrodos con la corteza premotora y motora primaria del cerebro. Se usaron filtros para el rechazo de artefactos y para la extracción de los ritmos sensoriomotores producidos entre 8 Hz y 30 Hz. También se establecieron parámetros para el procesamiento basado en épocas, en donde se segmentó la señal EEG a través de épocas en donde se pueden ubicar y etiquetar los fenómenos mentales con mayor facilidad. A través de la técnica de patrones espaciales comunes (CSP), se calculan filtros espaciales que son óptimos para la extracción de las señales EEG más discriminantes entre las dos condiciones de imaginación de movimiento, es decir, la matriz inversa de pesos calculada por el filtro es la distribución de vectores invariantes en el tiempo de la señal EEG. Esta técnica de filtrado espacial fue usada como método de extracción de características para los clasificadores evaluados: análisis discriminante lineal (LDA) y dos máquinas de soporte vectorial. Se evaluaron estos tres algoritmos de clasificación utilizando validación cruzada con un número de particiones igual a 5 (5-fold) y a partir de éste procedimiento se sintonizaron los valores óptimos de los parámetros que permitieron incrementar las exactitudes de clasificación.

Los mejores resultados fueron obtenidos usando la máquina de soporte vectorial denominada Nu-SVC con un Kernel Gaussiano, la cual permite añadir un parámetro para el control del número de vectores soporte. Esta parametrización en la máquina de soporte vectorial tiene consecuencias en el tiempo de ejecución, el tiempo de entrenamiento y en los límites del error en la generalización. Con un valor de Gamma para el Kernel gaussiano igual a 100 y un valor promedio de Nu igual a 0.300, se logró un incremento de más del 25 % en la exactitud, comparado con la clasificación

con LDA y con la máquina C-SVC con Kernel lineal. Teniendo esto en cuenta, se verificó que las máquinas de soporte vectorial combinadas con Kernel gaussianos son una potente herramienta para la clasificación de patrones mentales registrados con sistemas BCI-EEG. En resultados obtenidos mediante una prueba realizada con 8 usuarios sanos, se resaltan las exactitudes obtenidas con la máquina Nu-SVC, la cuál mostró en promedio un desempeño del 96.7 %, un valor de exactitud de clasificación alto para experimentos de imaginación motora con sistemas BCI de bajo costo, en comparación con otros estudios encontrados. A pesar que los resultados demuestran que es posible utilizar sistemas BCI de bajo costo como el EPOC para realizar experimentos neurocientíficos rigurosos, existen algunos problemas relacionados directamente con el hardware que a menudo, impiden que se puedan realizar aplicaciones más exactas y que brinden una mejor experiencia de usuario cuando se utilizan estrategias mentales de interacción puntuales como la imaginación motora: los electrodos de registro del neurocasco no cubren totalmente la corteza motora sobre la cuál se registran con efectividad las señales ERD y ERS necesarias para las tareas de imaginación motora; adicionalmente, dada la flexibilidad del EPOC, las localizaciones de los electrodos no son fijas cuando el neurocasco es llevado puesto, lo que aumenta la complejidad en la reproducibilidad del experimento con el mismo usuario, especialmente en aquellas situaciones en donde se requieren movimientos constantes del usuario (por ejemplo el movimiento de una silla de ruedas en terrenos no planos).

Futuros trabajos podrían incluir el uso de otros sistemas más robustos en donde puedan ser rastreados con mayor fiabilidad más patrones de imaginación de movimiento, como los movimientos de los pies, dedos o lengua. En otros trabajos realizados en investigaciones paralelas, hemos propuesto el uso de sistemas híbridos (hBCI) o multimodales en donde se combina el uso de sistemas de captura de movimiento con análisis cinemático y neuromecanismos detectados usando interfaces cerebro computador, para el tratamiento de enfermedades y lesiones del sistema nervioso central que conducen a un deterioro sensoriomotriz, utilizando videojuegos especializados. Estas interfaces pueden beneficiar a los usuarios en tres formas generales: a) los sistemas hBCI pueden extender las capacidades de las interfaces actuales, permitiéndole a los usuarios el control de más dimensiones de movimiento o el envío de combinaciones de comandos no disponibles de otro modo, b) los sistemas BCI híbridos pueden hacer más adaptativa e intuitiva la interacción humano-computador y c) los sistemas BCI híbridos pueden ayudar a que las interfaces cerebro computador sean más modernas y prácticas, aumentando el espectro de aplicaciones en donde pueden ser utilizadas [122].

Bibliografía

- [1] D. Wigdor and D. Wixon, *Brave NUI world: designing natural user interfaces for touch and gesture*. Elsevier, 2011.
- [2] D. Alan, F. Janet, A. Gregory, and B. Russell, “Human-computer interaction,” *England: Pearson Education Limited*, 2004.
- [3] B. Graimann, B. Allison, and G. Pfurtscheller, *Brain-computer interfaces: Revolutionizing human-computer interaction*. Springer, 2010.
- [4] T. W. Berger, *Brain-Computer Interfaces: An international assessment of research and development trends*. Springer, 2008.
- [5] J. J. Shih, D. J. Krusienski, and J. R. Wolpaw, “Brain-computer interfaces in medicine,” in *Mayo Clinic Proceedings*, vol. 87, no. 3. Elsevier, 2012, pp. 268–279.
- [6] K. L. Moore, A. F. Dalley, A. M. Agur, and M. E. Moore, *Anatomía con orientación clínica*. Ed. Medica Panamericana, 2007.
- [7] A. Nijholt and D. Heylen, “Editorial (to: Special issue on affective brain-computer interfaces),” 2013.
- [8] R. Parasuraman, J. Christensen, and S. Grafton, “Neuroergonomics: the brain in action and at work,” *Neuroimage*, vol. 59, no. 1, pp. 1–3, 2012.
- [9] H. Ekanayake, “P300 and emotiv epoc: Does emotiv epoc capture real eeg?” *Web publication <http://neurofeedback.visaduma.info/emotivresearch.htm>*, 2010.
- [10] H. Cecotti, “Spelling with non-invasive brain–computer interfaces–current and future trends,” *Journal of Physiology-Paris*, vol. 105, no. 1, pp. 106–114, 2011.
- [11] R. d. Colombia, “Ley 361,” in *Congreso de la República*, 1997.
- [12] J. E. Muñoz-Cardona, C. D. Muñoz-Cardona, and O. A. Henao-Gallo, “Diseño de una estación de trabajo para personas con discapacidad en miembros superiores usando una interfaz cerebro computador,” *Tecno Lógicas*, pp. 55–66, 2013.

-
- [13] S. C. Kleih, T. Kaufmann, C. Zickler, S. Halder, F. Leotta, F. Cincotti, F. Aloise, A. Riccio, C. Herbert, D. Mattia *et al.*, “Out of the frying pan into the fire—the p300-based bci faces real-world challenges.” *Progress in brain research*, vol. 194, pp. 27–46, 2010.
- [14] T. Karvinen and K. Karvinen, *Make a Mind-Controlled Arduino Robot: Use Your Brain as a Remote*. O’Reilly Media, Inc., 2011.
- [15] J. Gomez-Gil, I. San-Jose-Gonzalez, L. F. Nicolas-Alonso, and S. Alonso-Garcia, “Steering a tractor by means of an emg-based human-machine interface,” *Sensors*, vol. 11, no. 7, pp. 7110–7126, 2011.
- [16] F. Lotte, J. Faller, C. Guger, Y. Renard, G. Pfurtscheller, A. Lécuyer, and R. Leeb, “Combining bci with virtual reality: towards new applications and improved bci,” in *Towards Practical Brain-Computer Interfaces*. Springer, 2013, pp. 197–220.
- [17] A. Nijholt and D. Tan, “Brain-computer interfacing for intelligent systems,” *Intelligent Systems, IEEE*, vol. 23, no. 3, pp. 72–79, 2008.
- [18] M. Lotze and U. Halsband, “Motor imagery,” *Journal of Physiology-paris*, vol. 99, no. 4, pp. 386–395, 2006.
- [19] A. Presacco, L. Forrester, and J. L. Contreras-Vidal, “Towards a non-invasive brain-machine interface system to restore gait function in humans,” in *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*. IEEE, 2011, pp. 4588–4591.
- [20] J. Schouenborg, M. Garwicz, and N. Danielsen, “Toward a whole-body neuroprosthetic,” *Brain Machine Interfaces: Implications for Science, Clinical Practice and Society*, vol. 194, p. 47, 2011.
- [21] H. Gürkök, *Mind the sheep! User experience evaluation & brain-computer interface games*. University of Twente, 2012.
- [22] S. Makeig, G. Leslie, T. Mullen, D. Sarma, N. Bigdely-Shamlo, and C. Kothe, “First demonstration of a musical emotion bci,” in *Affective Computing and Intelligent Interaction*. Springer, 2011, pp. 487–496.
- [23] J. I. Münßinger, S. Halder, S. C. Kleih, A. Furdea, V. Raco, A. Höfle, and A. Kübler, “Brain painting: first evaluation of a new brain–computer interface application with als-patients and healthy volunteers,” *Frontiers in neuroscience*, vol. 4, 2010.
- [24] D. Lulé, Q. Noirhomme, S. C. Kleih, C. Chatelle, S. Halder, A. Demertzi, M.-A. Bruno, O. Gosseries, A. Vanhauzenhuysse, C. Schnakers *et al.*, “Probing command following

- in patients with disorders of consciousness using a brain–computer interface,” *Clinical Neurophysiology*, vol. 124, no. 1, pp. 101–106, 2013.
- [25] M. Adelson, “Emotiv experimenter. an experimentation and mind-reading application for the emotiv epoc.”
- [26] D. Szafrir and R. Signorile, “An exploration of the utilization of electroencephalography and neural nets to control robots,” in *Human-Computer Interaction–INTERACT 2011*. Springer, 2011, pp. 186–194.
- [27] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, B. Arnaldi *et al.*, “A review of classification algorithms for eeg-based brain–computer interfaces,” *Journal of neural engineering*, vol. 4, 2007.
- [28] K.-R. Müller, M. Tangermann, G. Dornhege, M. Krauledat, G. Curio, and B. Blankertz, “Machine learning for real-time single-trial eeg-analysis: from brain–computer interfacing to mental state monitoring,” *Journal of neuroscience methods*, vol. 167, no. 1, pp. 82–90, 2008.
- [29] S. Lemm, B. Blankertz, T. Dickhaus, and K.-R. Müller, “Introduction to machine learning for brain imaging,” *Neuroimage*, vol. 56, no. 2, pp. 387–399, 2011.
- [30] D. S. T. A. Nijholt, “Brain-computer interfaces,” 2010.
- [31] C. M. Bishop *et al.*, *Pattern recognition and machine learning*. springer New York, 2006, vol. 1.
- [32] A. J. Smola and B. Schölkopf, “On a kernel-based method for pattern recognition, regression, approximation, and operator inversion,” *Algorithmica*, vol. 22, no. 1-2, pp. 211–231, 1998.
- [33] P. Bobrov, A. Frolov, C. Cantor, I. Fedulova, M. Bakhnyan, and A. Zhavoronkov, “Brain-computer interface based on generation of visual images,” *PloS one*, vol. 6, no. 6, p. e20674, 2011.
- [34] R. Fazel-Rezai and W. Ahmad, “P300-based brain-computer interface paradigm design,” *Recent Advances in Brain-Computer Interface Systems*, pp. 83–98, 2011.
- [35] S. Jeong, Y. Park, H. Arie, J. Tani, and M. Lee, “Goal-oriented behavior generation for visually-guided manipulation task,” in *Neural Information Processing*. Springer, 2011, pp. 501–508.
- [36] J. C. T. Salas, H. Iwasaki, E. Jodo, M. H. Schmidt, A. Kawauchi, T. Miki, Y. Kayama, M. Otsuki, and Y. Koyama, “Penile erection and micturition events triggered by electrical

- stimulation of the mesopontine tegmental area,” *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, vol. 294, no. 1, pp. R102–R111, 2008.
- [37] A. S. Royer, A. J. Doud, M. L. Rose, and B. He, “Eeg control of a virtual helicopter in 3-dimensional space using intelligent control strategies,” *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 18, no. 6, pp. 581–589, 2010.
- [38] Y. Yu, D. He, W. Hua, S. Li, Y. Qi, Y. Wang, and G. Pan, “Flyingbuddy2: a brain-controlled assistant for the handicapped,” in *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*. ACM, 2012, pp. 669–670.
- [39] A. Guillot and C. Collet, *The neurophysiological foundations of mental and motor imagery*. Oxford University Press, 2010.
- [40] G. Schalk and J. Mellinger, “A practical guide to brain-computer interfacing with bci2000,” *Springer, London, UK*, 2010.
- [41] W. Samek, C. Vidaurre, K.-R. Müller, and M. Kawanabe, “Stationary common spatial patterns for brain–computer interfacing,” *Journal of neural engineering*, vol. 9, no. 2, p. 026013, 2012.
- [42] M. Tangermann, K.-R. Müller, A. Aertsen, N. Birbaumer, C. Braun, C. Brunner, R. Leeb, C. Mehring, K. J. Miller, G. R. Müller-Putz *et al.*, “Review of the bci competition iv,” *Frontiers in neuroscience*, vol. 6, pp. 55–55, 2011.
- [43] B. Blankertz, M. Kawanabe, R. Tomioka, F. Hohlefeld, V. V. Nikulin, and K.-R. Müller, “Invariant common spatial patterns: Alleviating nonstationarities in brain-computer interfacing.” in *NIPS*, 2007.
- [44] B. Blankertz, G. Dornhege, M. Krauledat, K.-R. Müller, and G. Curio, “The non-invasive berlin brain–computer interface: fast acquisition of effective performance in untrained subjects,” *NeuroImage*, vol. 37, no. 2, pp. 539–550, 2007.
- [45] M. Grosse-Wentrup and M. Buss, “Multiclass common spatial patterns and information theoretic feature extraction,” *Biomedical Engineering, IEEE Transactions on*, vol. 55, no. 8, pp. 1991–2000, 2008.
- [46] B. Reuderink and M. Poel, “Robustness of the common spatial patterns algorithm in the bci-pipeline,” 2008.
- [47] J. Wolpaw and E. W. Wolpaw, *Brain-computer interfaces: principles and practice*. Oxford University Press, 2012.
- [48] I. Jolliffe, *Principal component analysis*. Wiley Online Library, 2005.

- [49] J. V. Stone, *Independent component analysis*. Wiley Online Library, 2004.
- [50] G. Rosas-Cholula, J. M. Ramírez-Cortes, V. Alarcón-Aquino, J. Martínez-Carballido, and P. Gomez-Gil, “On signal p-300 detection for bci applications based on wavelet analysis and ica preprocessing,” in *Electronics, Robotics and Automotive Mechanics Conference (CERMA), 2010*. IEEE, 2010, pp. 360–365.
- [51] F. Oveisi, S. Oveisi, A. Efranian, and I. Patras, “Nonlinear independent component analysis for eeg-based brain-computer interface systems.”
- [52] H. Gürkök and A. Nijholt, “Brain–computer interfaces for multimodal interaction: a survey and principles,” *International Journal of Human-Computer Interaction*, vol. 28, no. 5, pp. 292–307, 2012.
- [53] T. Al-ani and D. Trad, “Signal processing and classification approaches for brain-computer interface,” *Intelligent and Biosensors, Edited by Vernon S. Somerset*, pp. 25–66, 2010.
- [54] R. Santana, L. Bonnet, J. Legény, and A. Lécuyer, “Introducing the use of model-based evolutionary algorithms for eeg-based motor imagery classification,” in *Proceedings of the fourteenth international conference on Genetic and evolutionary computation conference*. ACM, 2012, pp. 1159–1166.
- [55] E. T. Esfahani and V. Sundararajan, “Classification of primitive shapes using brain–computer interfaces,” *Computer-Aided Design*, vol. 44, no. 10, pp. 1011–1019, 2012.
- [56] E. B. Sadeghian and M. H. Moradi, “Continuous detection of motor imagery in a four-class asynchronous bci,” in *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*. IEEE, 2007, pp. 3241–3244.
- [57] A. Ahmadi, O. Dehzangi, and R. Jafari, “Brain-computer interface signal processing algorithms: A computational cost vs. accuracy analysis for wearable computers,” in *Wearable and Implantable Body Sensor Networks (BSN), 2012 Ninth International Conference on*. IEEE, 2012, pp. 40–45.
- [58] G. Dornhege, *Toward brain-computer interfacing*. MIT press, 2007.
- [59] J. L. Martínez Pérez, “Comunicación con computador mediante señales cerebrales: aplicación a la tecnología de la rehabilitación,” Ph.D. dissertation, Industriales, 2010.
- [60] S. Sanei and J. A. Chambers, *EEG signal processing*. John Wiley & Sons, 2008.
- [61] D. Garrett, D. A. Peterson, C. W. Anderson, and M. H. Thaut, “Comparison of linear, nonlinear, and feature selection methods for eeg signal classification,” *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 11, no. 2, pp. 141–144, 2003.

- [62] S. Choudhury, “Learning thought-based motor control using gaussian processes.”
- [63] S. Sun, M. Lan, and Y. Lu, “Adaptive eeg signal classification using stochastic approximation methods,” in *Acoustics, Speech and Signal Processing, 2008. ICASSP 2008. IEEE International Conference on*. IEEE, 2008, pp. 413–416.
- [64] M. Zhong, F. Lotte, M. Girolami, and A. Lécuyer, “Classifying eeg for brain computer interfaces using gaussian processes,” *Pattern Recognition Letters*, vol. 29, no. 3, pp. 354–359, 2008.
- [65] A. Subasi and E. Erçelebi, “Classification of eeg signals using neural network and logistic regression,” *Computer Methods and Programs in Biomedicine*, vol. 78, no. 2, pp. 87–99, 2005.
- [66] S. Zhong and J. Ghosh, “Hmms and coupled hmms for multi-channel eeg classification,” in *Proceedings of the IEEE International Joint Conference on Neural Networks*, vol. 2, 2002, pp. 1254–1159.
- [67] A. Ö. Argunşah, “An hmm-pca approach for eeg-based brain computer interfaces (bcis),” 2010.
- [68] B. Obermaier, G. Muller, and G. Pfurtscheller, ““virtual keyboard controlled by spontaneous eeg activity,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 4, pp. 422–426, 2003.
- [69] D. Wang, D. Miao, and G. Blohm, “Multi-class motor imagery eeg decoding for brain-computer interfaces,” *Frontiers in neuroscience*, vol. 6, 2012.
- [70] Q. Zhao, L. Zhang, and A. Cichocki, “Eeg-based asynchronous bci control of a car in 3d virtual reality environments,” *Chinese Science Bulletin*, vol. 54, no. 1, pp. 78–87, 2009.
- [71] S. Perdikis, H. Bayati, R. Leeb, and J. d. R. Millán, “Evidence accumulation in asynchronous bci,” *Int. J. Bioelectromagnetism*, vol. 13, no. 3, pp. 131–132, 2011.
- [72] T.-H. Nguyen, S.-M. Park, K.-E. Ko, and K.-B. Sim, “Multi-class stationary csp for optimal feature separation of brain source in bci system,” in *Control, Automation and Systems (ICCAS), 2012 12th International Conference on*. IEEE, 2012, pp. 1035–1039.
- [73] R. R. Llinás, *El cerebro y el mito del yo: El papel de las neuronas en el pensamiento y el comportamiento humanos*. Editorial Norma, 2002.
- [74] R. K. Hobbie and B. J. Roth, *Intermediate physics for medicine and biology*. Springer, 2007.
- [75] J. N. Demos, *Getting started with neurofeedback*. WW Norton & Company, 2005.

-
- [76] G. Dornhege, *Toward brain-computer interfacing*. MIT press, 2007.
- [77] R. Fazel-Rezai and W. Ahmad, “P300-based brain-computer interface paradigm design,” *Recent Advances in Brain-Computer Interface Systems*, pp. 83–98, 2011.
- [78] N. V. Thakor, *Quantitative EEG analysis methods and clinical applications*. Artech House, 2009.
- [79] F.-B. Vialatte, M. Maurice, J. Dauwels, and A. Cichocki, “Steady-state visually evoked potentials: focus on essential paradigms and future perspectives,” *Progress in neurobiology*, vol. 90, no. 4, pp. 418–438, 2010.
- [80] N. Chumerin, N. V. Manyakov, M. van Vliet, A. Robben, A. Combaz, and M. Van Hulle, “Steady-state visual evoked potential-based computer gaming on a consumer-grade eeg device,” *Computational Intelligence and AI in Games, IEEE Transactions on*, vol. 5, no. 2, pp. 100–110, 2013.
- [81] W. Freeman and R. Q. Quiroga, *Imaging brain function with EEG: advanced temporal and spatial analysis of electroencephalographic signals*. Springer, 2012.
- [82] W.-K. Tam, K.-y. Tong, F. Meng, and S. Gao, “A minimal set of electrodes for motor imagery bci to control an assistive device in chronic stroke subjects: a multi-session study,” *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 19, no. 6, pp. 617–627, 2011.
- [83] Q. Zhao, L. Zhang, and A. Cichocki, “Eeg-based asynchronous bci control of a car in 3d virtual reality environments,” *Chinese Science Bulletin*, vol. 54, no. 1, pp. 78–87, 2009.
- [84] E. Ferreira Lage, “La técnica de electroencefalografía en la evaluación de la actividad cortical motora.” 2009.
- [85] K. I. Panoulas, L. J. Hadjileontiadis, and S. M. Panas, “Hilbert-huang spectrum as a new field for the identification of eeg event related de-/synchronization for bci applications,” in *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*. IEEE, 2008, pp. 3832–3835.
- [86] D. J. McFarland, L. M. McCane, S. V. David, and J. R. Wolpaw, “Spatial filter selection for eeg-based communication,” *Electroencephalography and clinical Neurophysiology*, vol. 103, no. 3, pp. 386–394, 1997.
- [87] J. d. R. Millán, R. Rupp, G. R. Müller-Putz, R. Murray-Smith, C. Giugliemma, M. Tangermann, C. Vidaurre, F. Cincotti, A. Kübler, R. Leeb *et al.*, “Combining brain–computer interfaces and assistive technologies: state-of-the-art and challenges,” *Frontiers in neuroscience*, vol. 4, 2010.
-

- [88] G. Pfurtscheller, B. Z. Allison, G. Bauernfeind, C. Brunner, T. Solis Escalante, R. Scherer, T. O. Zander, G. Mueller-Putz, C. Neuper, and N. Birbaumer, "The hybrid bci," *Frontiers in neuroscience*, vol. 4, p. 3, 2010.
- [89] C. Brunner, G. Andreoni, L. Bianchi, B. Blankertz, C. Breitwieser, S. Kanoh, C. A. Kothe, A. Lécuyer, S. Makeig, J. Mellinger *et al.*, "Bci software platforms," in *Towards Practical Brain-Computer Interfaces*. Springer, 2013, pp. 303–331.
- [90] M. Lang, "Investigating the emotiv epoc for cognitive control in limited training time," *Dep of Comp Sci, Univ of Canterb*, 2012.
- [91] A. Campbell, T. Choudhury, S. Hu, H. Lu, M. K. Mukerjee, M. Rabbi, and R. D. Raizada, "Neurophone: brain-mobile phone interface using a wireless eeg headset," in *Proceedings of the second ACM SIGCOMM workshop on Networking, systems, and applications on mobile handhelds*. ACM, 2010, pp. 3–8.
- [92] M. Adelson, "Emotiv experimenter. an experimentation and mind-reading application for the emotiv epoc."
- [93] A. Delorme, T. Mullen, C. Kothe, Z. A. Acar, N. Bigdely-Shamlo, A. Vankov, and S. Makeig, "Eeglab, sift, nft, bcilab, and erica: new tools for advanced eeg processing," *Computational intelligence and neuroscience*, vol. 2011, p. 10, 2011.
- [94] Y. Renard, F. Lotte, G. Gibert, M. Congedo, E. Maby, V. Delannoy, O. Bertrand, and A. Lécuyer, "Openvibe: an open-source software platform to design, test, and use brain-computer interfaces in real and virtual environments," *Presence: teleoperators and virtual environments*, vol. 19, no. 1, pp. 35–53, 2010.
- [95] J. L. S. Vargas, "Descripción del funcionamiento de un módulo clasificador de ondas electroencefalográficas utilizando la plataforma openvibe."
- [96] D. Farina, W. Jensen, and M. Akay, *Introduction to neural engineering for motor rehabilitation*. John Wiley & Sons, 2013, vol. 40.
- [97] J. L. Pons and D. Torricelli, *Emerging Therapies in Neurorehabilitation*. Springer, 2013.
- [98] A. Lécuyer, F. Lotte, R. B. Reilly, R. Leeb, M. Hirose, M. Slater *et al.*, "Brain-computer interfaces, virtual reality, and videogames," *IEEE Computer*, vol. 41, no. 10, pp. 66–72, 2008.
- [99] A. Nijholt and D. Tan, "Brain-computer interfacing for intelligent systems," *Intelligent Systems, IEEE*, vol. 23, no. 3, pp. 72–79, 2008.
- [100] H. Gürkök, A. Nijholt, and M. Poel, "Brain-computer interface games: Towards a framework," in *Entertainment Computing-ICEC 2012*. Springer, 2012, pp. 373–380.

- [101] B. Laar, F. Nijboer, H. Gürkök, D. Plass-Oude Bos, and A. Nijholt, “User experience evaluation in bci: Bridge the gap,” *International Journal of Bioelectromagnetism*, vol. 13, no. 3, pp. 157–158, 2011.
- [102] D. Marshall, D. Coyle, S. Wilson, and M. Callaghan, “Games, gameplay, and bci: The state of the art,” *Computational Intelligence and AI in Games, IEEE Transactions on*, vol. 5, no. 2, pp. 82–99, 2013.
- [103] F. Lotte, “Brain-computer interfaces for 3d games: hype or hope?” in *Proceedings of the 6th International Conference on Foundations of Digital Games*. ACM, 2011, pp. 325–327.
- [104] F. Lotte, J. Faller, C. Guger, Y. Renard, G. Pfurtscheller, A. Lécuyer, and R. Leeb, “Combining bci with virtual reality: towards new applications and improved bci,” in *Towards Practical Brain-Computer Interfaces*. Springer, 2013, pp. 197–220.
- [105] F. Malouin and C. L. Richards, “Clinical applications of motor imagery in rehabilitation,” in *Multisensory Imagery*. Springer, 2013, pp. 397–419.
- [106] G. Leifert-Fiebach, A. Welfringer, R. Babinsky, and T. Brandt, “Motor imagery training in patients with chronic neglect: A pilot study,” *NeuroRehabilitation*, vol. 32, no. 1, pp. 43–58, 2013.
- [107] M. Arvaneh, C. Guan, K. K. Ang, and C. Quek, “Optimizing the channel selection and classification accuracy in eeg-based bci,” *Biomedical Engineering, IEEE Transactions on*, vol. 58, no. 6, pp. 1865–1873, 2011.
- [108] N. Dias, P. Mendes, and J. Correia, “Feature selection for brain-computer interface,” in *4th European Conference of the International Federation for Medical and Biological Engineering*. Springer, 2009, pp. 318–321.
- [109] R. M. Taylor II, T. C. Hudson, A. Seeger, H. Weber, J. Juliano, and A. T. Helser, “Vrpn: a device-independent, network-transparent vr peripheral system,” in *Proceedings of the ACM symposium on Virtual reality software and technology*. ACM, 2001, pp. 55–61.
- [110] P. Bobrov, A. Frolov, C. Cantor, I. Fedulova, M. Bakhnyan, and A. Zhavoronkov, “Brain-computer interface based on generation of visual images,” *PloS one*, vol. 6, no. 6, p. e20674, 2011.
- [111] B.-J. Choi and S.-H. Jo, “Hybrid ssvep/erd bci for humanoid navigation,” in *Control, Automation and Systems (ICCAS), 2013 13th International Conference on*. IEEE, 2013, pp. 1641–1645.

- [112] C. J. Burges, “A tutorial on support vector machines for pattern recognition,” *Data mining and knowledge discovery*, vol. 2, no. 2, pp. 121–167, 1998.
- [113] B. Schölkopf, A. J. Smola, R. C. Williamson, and P. L. Bartlett, “New support vector algorithms,” *Neural computation*, vol. 12, no. 5, pp. 1207–1245, 2000.
- [114] M. A. Adams, S. J. Marshall, L. Dillon, S. Caparosa, E. Ramirez, J. Phillips, and G. J. Norman, “A theory-based framework for evaluating exergames as persuasive technology,” in *Proceedings of the 4th International Conference on Persuasive Technology*. ACM, 2009, p. 45.
- [115] S. M. Braun, A. J. Beurskens, M. Kleynen, B. Oudelaar, J. M. Schols, and D. T. Wade, “A multicenter randomized controlled trial to compare subacute $\hat{\epsilon}$ -treatment as usual $\hat{\epsilon}$ ™ with and without mental practice among persons with stroke in dutch nursing homes,” *Journal of the American Medical Directors Association*, vol. 13, no. 1, pp. 85–e1, 2012.
- [116] M. Mutsaerts, B. Steenberg, and H. Bekkering, “Anticipatory planning deficits and task context effects in hemiparetic cerebral palsy,” *Experimental Brain Research*, vol. 172, no. 2, pp. 151–162, 2006.
- [117] F. Malouin, S. Belleville, C. L. Richards, J. Desrosiers, and J. Doyon, “Working memory and mental practice outcomes after stroke,” *Archives of physical medicine and rehabilitation*, vol. 85, no. 2, pp. 177–183, 2004.
- [118] R. Dickstein and J. E. Deutsch, “Motor imagery in physical therapist practice,” *Physical therapy*, vol. 87, no. 7, pp. 942–953, 2007.
- [119] R. Leeb and J. d. R. Millán, “Introduction to devices, applications and users: Towards practical bcis based on shared control techniques,” in *Towards Practical Brain-Computer Interfaces*. Springer, 2013, pp. 107–129.
- [120] J. R. Millan, F. Renkens, J. Mouriño, and W. Gerstner, “Noninvasive brain-actuated control of a mobile robot by human eeg,” *Biomedical Engineering, IEEE Transactions on*, vol. 51, no. 6, pp. 1026–1033, 2004.
- [121] C. Escolano, J. M. Antelis, and J. Minguez, “A telepresence mobile robot controlled with a noninvasive brain–computer interface,” *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, vol. 42, no. 3, pp. 793–804, 2012.
- [122] G. R. Müller-Putz, R. Leeb, J. d. R. Millán, P. Horki, A. Kreilinger, G. Bauernfeind, B. Z. Allison, C. Brunner, and R. Scherer, “Principles of hybrid brain–computer interfaces,” in *Towards Practical Brain-Computer Interfaces*. Springer, 2013, pp. 355–373.