



UNIVERSIDAD DE VALLADOLID

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

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

Desarrollo y evaluación de una aplicación para navegar por Internet mediante sistemas Brain Computer Interface orientada a personas con grave discapacidad

Autor:

D. Víctor Martínez Cagigal

Tutor:

Dr. D. Roberto Hornero Sánchez

Valladolid, 9 de Julio de 2015

TÍTULO: Desarrollo y evaluación de una aplicación para navegar por Internet mediante sistemas Brain Computer Interface orientada a personas con grave discapacidad

AUTOR: D. Víctor Martínez Cagigal

TUTOR: Dr. D. Roberto Hornero Sánchez

DEPARTAMENTO: Teoría de la Señal y Comunicaciones e Ingeniería Telemática

TRIBUNAL

PRESIDENTE: Dr. D. Miguel López Coronado

VOCAL: Dr. D. Salvador Dueñas Carazo

SECRETARIO Dr. Dña. María García Gadañón

FECHA: 16 de Julio de 2015

CALIFICACIÓN:

Resumen

El electroencefalograma (EEG) fue desarrollado por Hans Berger en 1929 y las ondas cerebrales, hasta entonces desconocidas, fueron investigadas durante el siglo XX como ayuda para el diagnóstico de la epilepsia o diversos trastornos del sueño. Durante este periodo de tiempo se especuló sobre utilizar las señales EEG para desarrollar un sistema de comunicación entre el cerebro y el medio sin la intervención de los mecanismos normales de los nervios y los músculos periféricos. Ese sistema surgió a cargo de Dr. Jacques Vidal en 1977 y se bautizó como Brain Computer Interface (BCI). Estos tipos de sistemas se basan en monitorizar la actividad cerebral y traducir determinadas características, correspondientes a las intenciones del usuario, en comandos de un dispositivo.

En primer lugar, en el presente trabajo se lleva a cabo una revisión del estado del arte sobre los sistemas BCI, los métodos empleados para registrar la actividad cerebral, las señales de control que gobiernan dichos sistemas, el procesado de la señal y sobre los navegadores web desarrollados mediante BCI con anterioridad. A continuación, se estudia en profundidad el análisis de la señal y los potenciales evocados P300, señal de control utilizada en la aplicación a desarrollar, poniendo especial énfasis en el filtrado de referencia de media común, el submuestreo del EEG en crudo y en los algoritmos de análisis discriminante lineal paso-a-paso y máquinas de soporte vectorial, técnicas empleadas en el procesado de la aplicación. Adicionalmente, se establecen las pautas para diseñar un umbral basado en las curvas ROC que permita obtener una aplicación asíncrona, salvando las limitaciones de los navegadores web desarrollados con anterioridad.

Posteriormente, se presenta el diseño, el desarrollo y la evaluación de una aplicación BCI para navegar por Internet mediante las ondas cerebrales, destinada a las personas que sufren una grave discapacidad. Esta aplicación utiliza los potenciales evocados P300 como señal de control gracias al paradigma *odd-ball*, basado en exponer una serie de estímulos objetivo infrecuentes camuflados entre estímulos no-objetivo frecuentes. El usuario involuntariamente generará un potencial P300 cada vez que detecte los estímulos infrecuentes, seleccionando comandos que gobernarán la aplicación. Dicha aplicación fue evaluada satisfactoriamente por parte de cinco sujetos sanos y dieciséis enfermos de esclerosis múltiple (EM). De manera adicional, se trató de mejorar el algoritmo de traducción con el fin de aumentar la generalización del clasificador para este tipo de sujetos. Finalmente, se exponen los resultados de la evaluación, se discuten y se extraen las conclusiones oportunas.

Palabras clave

Brain Computer Interface, electroencefalograma, potenciales evocados P300, extracción y traducción de características, aplicación asíncrona, umbral, curvas ROC, navegador web, paradigma *odd-ball*.

Abstract

Electroencephalogram (EEG) was developed by Hans Berger in 1929 and brain signals, which were previously unknown, were researched over the 20th century in order to help the epilepsy or sleeping disorders diagnosis. During this period, researchers speculated that those signals might be used for developing a communication and control system between brain and environment without the normal intermediaries of peripheral nerves and muscles. In 1977, this system was invented by Dr. Jacques Vidal and it was called Brain Computer Interface (BCI). These kinds of systems are based on monitoring the brain activity and translating certain features, which reflect user intentions, into device commands.

Firstly, this project performs a review of state-of-the-art about BCI systems, methods applied in order to register brain activity, controls signals which lead these systems, signal processing and about previously developed BCI web browsers. Signal analysis and P300 evoked potentials are deeply studied, detailing the common average reference spatial filtering, the raw EEG subsampling, and the step-wise linear discriminant analysis and support vector machines algorithms, which are the techniques used in the signal processing of this application. In addition, guidelines in order to designing a threshold based on ROC curves are established too. That threshold allows us to establish an asynchronous application, overcoming the previously developed BCI browsers limitations.

Finally, a BCI application is designed, developed and evaluated. This application aims to allow disabled people surfing the Internet using only their own brain signals. The signal control, which leads the application using the *odd-ball* paradigm, is the P300 evoked potential. This paradigm is based on presenting several infrequent target stimuli interspersed with frequent routine stimuli. User will evoke, over parietal cortex, a positive peak at about 300ms when the user detects the infrequent stimuli. The application was successfully evaluated by five healthy subjects and sixteen multiple sclerosis patients. Besides that, translation algorithm was improved in order to increase the classifier generalization for this kind of subjects. To sum up, evaluation results are exposed, discussed and appropriate conclusions are drawn.

Keywords

Brain Computer Interface, electroencephalogram, P300 evoked potentials, feature extraction and translation, asynchronous application, threshold, ROC curves, web browser, *odd-ball* paradigm.

AGRADECIMIENTOS

En primera instancia quisiera agradecer a Roberto Hornero la oportunidad que me ha brindado para iniciar mi etapa investigadora. Su paciencia, sus recomendaciones y el equilibrio entre rigor y cordialidad que ha demostrado a lo largo de este tiempo han sido de gran ayuda para concluir este ciclo felizmente.

Análogamente, me gustaría hacer extensible este agradecimiento a todos los miembros del Grupo de Ingeniería Biomédica de la Universidad de Valladolid, por proporcionarme una excelente acogida entre sus filas; y en especial a Javier Gómez, puesto que se ha convertido, como dicen los nipones, en lo más parecido a un *senpai*.

A mis compañeros y amigos, porque su ayuda, sus consejos y su apoyo a lo largo de mi vida me han hecho posible desconectar del terreno académico, forjar mi personalidad y saturar el baúl de los recuerdos.

A Andrea, por estar presente tanto en lo bueno como en lo malo, por aguantarme, y en definitiva, por permitirme soñar... porque la vida es sueño, y los sueños, sueños son.

Por último, el mayor de los agradecimientos va dirigido a mi familia, especialmente para mis padres y mi hermana, por el esfuerzo que han demostrado en educarme y orientarme para crecer como persona. Puedo afirmar con toda seguridad que sin su apoyo no podría estar escribiendo estas líneas.

Muchas gracias.

*“Caminante, son tus huellas
el camino, y nada más;
caminante, no hay camino:
se hace camino al andar.*

*Al andar se hace camino,
y al volver la vista atrás
se ve la senda que nunca
se ha de volver a pisar.*

*Caminante, no hay camino,
sino estelas en la mar.”*

Antonio Machado

ÍNDICE GENERAL

CAPÍTULO 1	
INTRODUCCIÓN	1
<hr/>	
1.1. Señales biomédicas	1
1.2. Electroencefalograma (EEG)	3
1.3. Brain Computer Interface (BCI)	5
1.4. Esclerosis múltiple	6
1.5. Objetivos del Trabajo Fin de Máster	8
1.6. Estructura del Trabajo Fin de Máster	9
CAPÍTULO 2	
SISTEMAS BRAIN COMPUTER INTERFACE	11
<hr/>	
2.1. Introducción	11
2.2. Métodos para registrar la actividad cerebral	13
2.3. Tipos de señales de control en BCI	15
2.3.1. Potenciales Evocados Visuales	16
2.3.2. Potenciales Corticales Lentos	17
2.3.3. Ritmos sensoriomotores (ritmos μ y β)	18
2.3.4. Potenciales de neuronas corticales	20
2.3.5. Potenciales evocados P300	21
2.4. Procesado de la señal EEG	22
2.4.1. Adquisición de la señal	22
2.4.2. Procesado de la señal	24
2.4.3. Aplicación	29
2.5. Aplicaciones de los sistemas BCI	29
2.5.1. Selección de letras	29
2.5.2. Movimiento de un cursor	30
2.5.3. Desplazamiento sobre un mapa	30
2.6. Navegadores Web BCI	32
2.6.1. Bensch <i>et al</i> — “Nessi: An EEG-Controlled Web Browser for Severely Paralyzed Patients” [23]	32
2.6.2. Mugler <i>et al</i> — “Design and Implementation of a P300-Based Brain-Computer Interface for Controlling an Internet Browser” [26]	33
2.6.3. Sirvent Blaco <i>et al</i> — “Visual Evoked Potential-Based Brain-Machine Interface Applications to Assist Disabled People” [27]	34
2.6.4. Yu <i>et al</i> — “Surfing the Internet with a BCI Mouse” [28]	36
2.6.5. Liu <i>et al</i> — “An Online Brain-Computer Interface Using Non-Flashing Visual Evoked Potentials” [29]	38
2.6.6. Comparativa de los navegadores web	40

CAPÍTULO 3	
ANÁLISIS DE LOS POTENCIALES P300	45
3.1. Potenciales evocados P300	45
3.1.1. Aspectos psicológicos	47
3.1.2. Diferencias individuales entre sujetos	48
3.1.3. Factores farmacológicos	50
3.1.4. Enfermedades neuronales	50
3.2. Procesado de los potenciales evocados P300	51
3.2.1. Extracción de características	51
3.2.2. Traducción de características	60
CAPÍTULO 4	
SUJETOS Y MÉTODOS	63
4.1. Población de estudio	63
4.2. Metodología aplicada	64
4.2.1. Adquisición de la señal	64
4.2.2. Extracción de características	65
4.2.3. Clasificación de características	65
4.2.4. Umbralización	74
CAPÍTULO 5	
APLICACIÓN DE NAVEGACIÓN WEB	79
5.1. Objetivo de la aplicación	79
5.2. Partes de la aplicación	79
5.3. Funcionamiento general de la aplicación	80
5.4. Etapa de procesado EEG	81
5.4.1. Sistema de propósito general BCI2000	81
5.4.2. Configuración de los parámetros	82
5.4.3. Matrices <i>odd-ball</i>	84
5.5. Etapa de navegación web	87
5.6. Guía de usuario	88
5.7. Procedimiento de evaluación	90
5.7.1. Sesiones de calibración	90
5.7.2. Sesiones de evaluación	93
CAPÍTULO 6	
RESULTADOS	101
6.1. Sesiones de calibración	101
6.2. Sesiones de evaluación	102
6.3. Cuestionarios de satisfacción	104

6.4. Comparativa en la clasificación: SWLDA, s-SVM y e-SVM	108
CAPÍTULO 7	
DISCUSIÓN	111
7.1. Sesiones de calibración	111
7.2. Sesiones de evaluación	115
7.3. Cuestionarios de satisfacción	119
7.4. Comparativa en la clasificación: SWLDA, s-SVM y e-SVM	121
7.5. Comparación con otros estudios	122
7.6. Limitaciones de la aplicación	123
CAPÍTULO 8	
CONCLUSIONES Y LÍNEAS FUTURAS	125
8.1. Conclusiones	125
8.2. Líneas Futuras	128
REFERENCIAS	131
ANEXO A - ÍNDICE DE ACRÓNIMOS	135
ANEXO B - PUBLICACIÓN DE RESULTADOS	139
Comunicaciones en congresos internacionales	139
Comunicaciones en congresos nacionales	139

ÍNDICE DE FIGURAS

Capítulo 1: Introducción

- Figura 1-1.** Ejemplos de las tres señales bioeléctricas principales recogidas sobre la superficie corporal: (a) un electroencefalograma (EEG), (b) un electrocardiograma (ECG), y (c) un electromiograma (EMG). 2
- Figura 1-2.** Imágenes PET que detectan la disminución de glucosa asociada con la enfermedad del Alzheimer. A la izquierda un sujeto sano, en el centro un sujeto con DCL (Deterioro Cognitivo Leve) y a la derecha un enfermo de Alzheimer. 3
- Figura 1-3.** Ritmos electroencefalográficos observados durante el paso de vigilia a sueño profundo: (a) agitado, (b) relajado, (c) adormecido, (d) dormido, (e) sueño profundo. Se aprecia una disminución frecuencial a medida que el sujeto se duerme. 4
- Figura 1-4.** Distribución de los electrodos según el sistema internacional 10/20. 5
- Figura 1-5.** A la izquierda se muestra una neurona sana, mientras que a la derecha se muestra una neurona afectada por la esclerosis múltiple. Se observa el daño en la mielina, lo cual causa una exposición de la fibra nerviosa en ciertos puntos, dificultando la capacidad de comunicación de la neurona. 7

Capítulo 2: Sistemas Brain Computer Interface

- Figura 2-1.** Esquema del primer sistema BCI controlado por VEP y desarrollado por Dr. Jacques Vidal en 1977. En (a) aparecen los botones que se iluminaban intermitentemente para controlar el cursor. En (b) aparece el laberinto del cual debían salir los usuarios moviendo el cursor [11] 11
- Figura 2-2.** Estructura habitual que siguen los sistemas BCI desde la adquisición de la señal en crudo hasta la conversión de ésta en comandos de control de un dispositivo 13
- Figura 2-3.** Localización de los electrodos de distintas técnicas que emplean señales eléctricas 15
- Figura 2-4.** Regiones en las que se divide la corteza cerebral 16
- Figura 2-5.** Espectro frecuencial de una señal EEG recogida durante una estimulación visual a 7Hz. El fenómeno de resonancia de los potenciales VEP produce picos en 7Hz y sus armónicos 17
- Figura 2-6.** SCP recogidos durante una selección binaria [5] 17
- Figura 2-7.** Ritmos μ y β . En la selección inferior se percibe una disminución de los mismos [5] 18
- Figura 2-8.** Señal EEG registrada antes y después de realizar un movimiento con el dedo índice de la mano donde se aprecian los ERD y ERS. El panel superior se corresponde al electrodo C3 [5] 19
- Figura 2-9.** Esquema que muestra la implantación de electrodos epidurales o intracorticales [5] 20

Figura 2-10. Potencial evocado P300 recogido sobre el área centro-parietal del córtex mediante la técnica *odd-ball* con una matriz luminosa [5] 21

Figura 2-11. Etapas en las que se divide el tratamiento de la señal EEG: adquisición de la señal, procesamiento de la señal (extracción y traducción de características) y aplicación 22

Figura 2-12. Artefactos en la señal EEG causados por (a) el movimiento ocular y (b) pestañeos repetitivos y voluntarios..... 23

Figura 2-13. Registro de 5 segundos de duración de la señal EEG contaminada por episodios intermitentes de artefactos electromiográficos (EMG) 24

Figura 2-14. Comparación entre cuatro métodos espaciales de extracción de características. (A) Localización de los electrodos utilizados con la señal objetivo en rojo, concretamente, se quiere medir la señal del electrodo C3. (B) Banda de paso para cada método, raíz cuadrada de los valores cuadráticos medios de la señal recogida en C3. (C) Topografía de r_2 medida y amplitud espectral para cada método estudiado [5] 26

Figura 2-15. Clasificador lineal que maximiza el margen mínimo: en (a) se muestra el comportamiento óptimo y en (b) su comportamiento en presencia de un *outlier* 27

Figura 2-16. Comparación de los hiperplanos de separación para los tres métodos de traducción de características: K1 es un método lineal de una dimensión, K2 es un método lineal de dos dimensiones y K3 es un método no lineal..... 28

Figura 2-17. Selección de letras utilizando potenciales corticales lentos (SCP) con selecciones binarias: mitad de las mismas en magenta y la otra mitad en azul [23] 30

Figura 2-18. Control del movimiento de un cursor verticalmente mediante potenciales corticales lentos para seleccionar entre dos opciones..... 31

Figura 2-19. Control del movimiento en videojuegos mediante ritmos sensoriomotores μ y β [24] 31

Figura 2-20. Control del desplazamiento sobre un mapa con potenciales evocados visuales (VEP) [25]..... 31

Figura 2-21. Interfaz gráfica de *Nessi*, el primer navegador basado en potenciales SCP. En (a) se muestra la interfaz de selección binaria y la realimentación al usuario, mientras que en (b) aparecen las distintas codificaciones del teclado virtual [23] 33

Figura 2-22. Matriz utilizada para provocar los potenciales evocados P300 en el navegador web desarrollado por Mugler *et al* [26] 34

Figura 2-23. Potenciales recogidos en el estudio de Sirvent Blasco *et al* [27]. En (a) se muestra el potencial evocado N2PC, producido unos 200ms después del estímulo y recogido sobre el electrodo PO8 (zona parietal-occipital). En (b) se muestra el potencial evocado P300, producido unos 300ms después del estímulo y recogido sobre el electrodo Cz..... 35

Figura 2-24. Máquina de estados que gobierna las transiciones entre las matrices del navegador web de Sirvent Blasco *et al* [27] 36

Figura 2-25. Interfaz gráfica del navegador web desarrollado por Yu *et al* [28]. Se puede observar cómo se muestra un rectángulo a medida que el cursor se acerca al hipervínculo 37

Figura 2-26. Método de selección de letras, números y comandos implementado con potenciales evocados P300 y usado en el navegador de Yu *et al* [28] 38

Figura 2-27. Interfaz de usuario para el análisis *offline* en el estudio de Liu *et al* [29] donde se prueba la eficacia de los mVEP..... 39

Figura 2-28. Interfaz de usuario para el análisis *online* en el estudio de Liu *et al* [29] donde se estudia el rendimiento de la aplicación web..... 40

Capítulo 3: Análisis de la Señal y Potenciales Evocados P300

Figura 3-1. Potencial evocado P300 recogido en el electrodo Pz y generado con un *odd-ball* auditivo donde el usuario debía detectar tonos objetivos con probabilidad de ocurrencia de 0,2. La curva punteada (a) se corresponde con la primera época registrada y la curva (b) se corresponde con un promediado sincronizado de 90 épocas, permitiendo distinguir el potencial. La línea roja rayada indica el momento en el que se presentó el estímulo 46

Figura 3-2. Componentes del potencial evocado P300 en dos localizaciones distintas: Fz y Pz. En la gráfica superior aparece la respuesta cuando el sujeto no atiende al estímulo, donde se observa que la onda P3a sigue apareciendo. En la gráfica inferior, por el contrario, aparece la respuesta cuando el sujeto atiende al estímulo, generando las tres componentes principales: P3a, P3b y *slow wave* [33] 47

Figura 3-3. Variación de la forma del P300 para el electrodo Pz en función de la probabilidad de estímulo (a) y la probabilidad temporal (b) al utilizar un paradigma *odd-ball* auditivo [33] 48

Figura 3-4. Potenciales evocados P300 recogidos en el vértex (Cz) y en un electrodo nasofaríngeo (Pg2) según la dificultad de discriminación de los estímulos objetivos [33] 48

Figura 3-5. Variaciones de la forma del potencial evocado P300 según la edad del sujeto. En (a) se observa la variación de la latencia con la edad, pudiendo distinguir tres tramos distintos: de 5 a 12, de 12 a 20, y de 20 años en adelante. En (b) se observa el potencial P300 y su localización en Fz y Pz para niños de 7-8años y para adultos, pudiendo observar la onda positiva de los niños en la zona frontal y la latencia del P300 en la zona parietal [33] 49

Figura 3-6. Potencial evocado P300 recogido en el electrodo Pz y generado con un *odd-ball* auditivo para un sujeto esquizofrénico (en rojo) y un sujeto sano de control (en azul) con un promediado de 90 épocas..... 51

Figura 3-7. Tres filtrados espaciales diferentes para obtener la señal del canal C3: (a) Laplaciano corto, (b) Laplaciano largo y (c) método de referencia de media común (CAR). El electrodo objetivo C3 se corresponde con el círculo vacío y sus vecinos con círculos rellenos..... 54

Figura 3-8. Búsqueda de la dirección que consigue que la varianza de los datos proyectados sea máxima (D_1) en un problema de análisis de componentes principales 55

Figura 3-9. Esquema del filtrado adaptativo para eliminar una fuente de ruido..... 58

Figura 3-10. Plano tiempo-frecuencia para STFT en (a), con resoluciones fijas; DWT en (b), con resoluciones variables adaptadas a las señales biomédicas; y WPT en (c), con resoluciones variables según la intención del usuario 60

Figura 3-11. En la figura superior, representación del promediado sincronizado de 90 épocas de P300 para un *odd-ball* auditivo. En el centro, representación del espectrograma del mismo

obtenido a través de la STFT. En la figura inferior, representación del escalograma del mismo obtenido a través de la CWT 61

Capítulo 4: Sujetos y Métodos

Figura 4-1. Disposición de los electrodos utilizados en la aplicación según el sistema internacional 10/20: Fz, Cz, Pz, P3, P4, PO7, PO8 y Oz..... 64

Figura 4-2. Submuestreo de un promediado sincronizado en una ventana de 800 ms para detectar un P300. En azul se muestra la señal EEG original, a 256 Hz. En rojo se han marcado las muestras finales tras aplicar una frecuencia de submuestreo de 20 Hz. En gris se marcan los límites de cada segmento, dentro de los cuales se ha realizado la media. 66

Figura 4-3. Procedimiento de búsqueda del hiperplano de separación en LDA para un problema de clasificación de dos clases (verde y azul). En la parte izquierda se muestran dos proyecciones distintas de los datos. En la parte derecha se halla el hiperplano de separación óptimo, aquel que minimiza la covarianza entre ambas clases..... 67

Figura 4-4. Representación gráfica de la proyección de las características a un espacio de dimensión más alta (a) y del hiperplano óptimo de separación para el algoritmo SVM en una clasificación binaria (b). 69

Figura 4-5. Posibles errores en la clasificación SVM. En (a) el dato considerado se encuentra dentro de la región de separación y se clasifica correctamente. En (b) el dato considerado se encuentra dentro de la región de separación y se clasifica incorrectamente..... 70

Figura 4-6. Entrenamiento detallado del clasificador s-SVM, donde se incluyen como muestras de entrenamiento X intentos o selecciones. Los predictores o dimensiones del SVM serán las muestras de cada canal y la salida del SVM retornará un *score* para cada iluminación, el cual determinará la probabilidad de que se haya producido o no un P300. 71

Figura 4-7. Combinación de 4 SVMs en e-SVM, con una técnica de voting. Cada uno de los SVM se entrena con una partición $x_{sub,i}$. En la clasificación real, se introduce el mismo conjunto de datos x en todos ellos y obtiene un conjunto de scores y_i . Finalmente, los *scores* se suman para tener en cuenta la contribución de todos ellos. 72

Figura 4-8. Promedio de las precisiones obtenidas para la validación cruzada dejando uno fuera para varios valores del parámetro de regularización para los sujetos EM..... 73

Figura 4-9. Matriz de confusión que recoge los cuatro posibles resultados tras aplicar un clasificador binario: las columnas establecen el valor real de la clase y las filas el valor predicho por el clasificador 75

Figura 4-10. Construcción de una curva ROC (b) para las clases positivo (P) y negativo (N) con distribuciones gaussianas (a)..... 76

Figura 4-11. Detección del umbral óptimo: punto que minimiza la distancia entre éste y el punto óptimo de la curva ROC. Este umbral óptimo maximiza el par *Sensibilidad-Especificidad* 77

Figura 4-12. Área bajo la curva ROC (AUC) en tres casos distintos. En (a) se obtiene un valor diagnóstico perfecto, en (b) un buen valor diagnóstico y en (c) la peor curva posible, sin valor diagnóstico alguno 77

Capítulo 5: Aplicación de Navegación Web

Figura 5-1. Estructura principal de la aplicación de navegación web desarrollada 80

Figura 5-2. Interfaz gráfica de la aplicación desarrollada..... 80

Figura 5-3. Estructura del sistema de propósito general BCI2000, compuesta por cuatro módulos independientes..... 82

Figura 5-4. Interfaz gráfica del “Operador”, donde se configuran los parámetros relativos a la aplicación, además de permitir el control de ésta a tiempo real 82

Figura 5-5. Optimización de la aplicación para pantallas panorámicas con relación de aspecto 16:9..... 83

Figura 5-6. Línea de tiempo de cada intento de la etapa de procesado EEG..... 84

Figura 5-7. Matrices utilizadas en la etapa de procesado EEG. A la izquierda se muestra la matriz de navegación, a la derecha, la matriz de teclado 85

Figura 5-8. Funciones del comando “←” de la matriz de navegación en función del estado de la aplicación en el momento de su selección..... 86

Figura 5-9. Etiquetado de hipervínculos en la etapa de navegación web. En rojo se indica la posición del *buffer* que contiene el carácter introducido por el usuario, en verde los nodos posibles que concuerdan con la codificación introducida (o posibles selecciones en potencia) y en gris el resto de nodos que no pueden seleccionarse con esa codificación 87

Figura 5-10. Interfaz gráfica de la herramienta *P300Classifier*, utilizada para hallar el vector de pesos adaptado para cada usuario a partir de una serie de muestras de entrenamiento 91

Figura 5-11. Representación gráfica de los datos de la segunda sesión para el sujeto C01. A la izquierda aparecen las selecciones atendiendo e ignorando los estímulos para las 24 selecciones de la segunda sesión. A la derecha aparece la curva ROC para esa sesión concreta y el umbral óptimo calculado 92

Figura 5-12. El sujeto C05 evaluando la aplicación en la tercera sesión. La pantalla de la izquierda contiene la aplicación mientras que la de la derecha muestra el voltaje de cada electrodo y la información sobre las celdas seleccionadas y el umbral 94

Figura 5-13. El sujeto U14 evaluando la aplicación en la sesión Eval-II. Se observa al usuario realizando la tarea de publicar un *tweet*, en este momento, con la matriz de teclado..... 95

Capítulo 6: Resultados

Figura 6-1. Distribución de las respuestas de los enfermos de esclerosis múltiples a cada una de las afirmaciones planteadas en el cuestionario de satisfacción. 107

Figura 6-2. Precisiones medias para cada método de clasificación empleado variando el número de muestras finales por estímulo. 110

Capítulo 7: Discusión

Figura 7-1. Comparación de la precisión del clasificador obtenida para los enfermos de esclerosis múltiple durante las sesiones de calibración. Se omiten de la gráfica los tres sujetos que no alcanzaron una precisión superior al 70%. 112

Figura 7-2. Potenciales evocados P300 captados en el electrodo Pz durante las sesiones de calibración para los enfermos de esclerosis múltiple. En azul se muestra la respuesta atendida y en rojo la ignorada. El fondo de los sujetos que no superaron las sesiones de calibración con suficiente precisión (<70%) se ha marcado con un color gris. 112

Figura 7-3. Comparación del área bajo la curva ROC obtenida para las dos sesiones de calibración por parte de los sujetos de control. 113

Figura 7-4. Comparación del área bajo la curva ROC obtenida para las dos sesiones de calibración por parte de los enfermos de esclerosis múltiple. 114

Figura 7-5. Precisión obtenida para cada tarea realizada por parte de los sujetos de control.. 115

Figura 7-6. Precisión media de cada sujeto de control durante la sesión de evaluación sin considerar la tarea de lectura, puesto que su fin era solamente evaluar el umbral. 116

Figura 7-7. Precisión obtenida para cada tarea realizada por parte de los enfermos de esclerosis múltiple en la primera sesión de evaluación, Eval-I. 117

Figura 7-8. Precisión obtenida para cada tarea realizada por parte de los enfermos de esclerosis múltiple en la segunda sesión de evaluación, Eval-II. 117

Figura 7-9. Precisión obtenida para cada sujeto en la lectura pasiva, la cual determina la calidad del umbral escogido, así como precisiones medias de cada sesión de evaluación para los enfermos de esclerosis múltiple. 118

Figura 7-10. Precisiones medias y desviaciones estándar obtenidas para cada uno de los tipos de clasificación variando el submuestreo, donde: e-SVM es el conjunto de 4 SVM lineales, s-SVM es solamente un SVM lineal y SWLDA es el método original. 121

ÍNDICE DE TABLAS

Capítulo 2: Sistemas Brain Computer Interface

TABLA 2-1. CLASIFICACIÓN DE LOS MÉTODOS MÁS EMPLEADOS EN LA EXTRACCIÓN DE CARACTERÍSTICAS.....	25
TABLA 2-2. CLASIFICACIÓN DE LOS MÉTODOS MÁS EMPLEADOS EN LA TRADUCCIÓN DE CARACTERÍSTICAS.....	27
TABLA 2-3. COMPARATIVA DE LOS DISTINTOS ARTÍCULOS SOBRE NAVEGADORES WEB ATENDIENDO A SU METODOLOGÍA Y FUNCIONALIDADES	43

Capítulo 3: Análisis de la Señal y Potenciales Evocados P300

TABLA 3-1. CARACTERÍSTICAS DE LOS USUARIOS INDIVIDUALES QUE MODIFICAN LA FORMA DEL P300.....	52
---	----

Capítulo 4: Sujetos y Métodos

TABLA 4-1. CARACTERÍSTICAS DEMOGRÁFICAS Y CLÍNICAS DE LA POBLACIÓN DE ESTUDIO.....	63
TABLA 4-2. PRECISIONES MEDIAS OBTENIDAS PARA LA VALIDACIÓN CRUZADA DEJANDO UNO FUERA.....	74

Capítulo 5: Aplicación de Navegación Web

TABLA 5-1. RESUMEN DE LAS TAREAS PROPUESTAS EN LAS SESIONES DE EVALUACIÓN PARA TODA LA POBLACIÓN DE ESTUDIO.	95
--	----

Capítulo 6: Resultados

TABLA 6-1. RESULTADOS OBTENIDOS EN LAS SESIONES DE CALIBRACIÓN PARA TODA LA POBLACIÓN DE ESTUDIO.....	102
TABLA 6-2. RESULTADOS OBTENIDOS EN LA SESIÓN DE EVALUACIÓN PARA LOS SUJETOS DE CONTROL.	103
TABLA 6-3. PRECISIONES MEDIAS DE LA SESIÓN DE EVALUACIÓN PARA LOS SUJETOS DE CONTROL. .	104
TABLA 6-4. RESULTADOS OBTENIDOS EN LA PRIMERA SESIÓN DE EVALUACIÓN POR PARTE DE LOS ENFERMOS DE ESCLEROSIS MÚLTIPLE.	105
TABLA 6-5. RESULTADOS OBTENIDOS EN LA SEGUNDA SESIÓN DE EVALUACIÓN POR PARTE DE LOS ENFERMOS DE ESCLEROSIS MÚLTIPLE.	105
TABLA 6-6. RESULTADOS OBTENIDOS PARA EL CUESTIONARIO DE SATISFACCIÓN DE LOS SUJETOS DE CONTROL.	106

TABLA 6-7. RESULTADOS OBTENIDOS PARA EL CUESTIONARIO DE SATISFACCIÓN DE LOS ENFERMOS DE ESCLEROSIS MÚLTIPLE. 108

TABLA 6-8. COMPARATIVA DE LOS RESULTADOS OBTENIDOS DE LA PRECISIÓN DE CLASIFICACIÓN PARA LOS TRES MÉTODOS EMPLEADOS EN ENFERMOS DE ESCLEROSIS MÚLTIPLE. 109

Capítulo 7: Discusión

TABLA 7-1. COMPARATIVA ENTRE LOS NAVEGADORES WEB BCI DESARROLLADOS CON ANTERIORIDAD Y EL PRESENTE ESTUDIO.123

1.1. Señales biomédicas

La ingeniería biomédica es un campo multidisciplinar que aplica las técnicas y métodos de la ingeniería a la comprensión, definición y resolución de problemas de las especialidades relacionadas con la medicina y la biología. Entre sus competencias se encuentran reducir la subjetividad de las medidas diagnósticas visualmente, aumentar la calidad de las señales registradas y mejorar la precisión de la medida, entre otras. En consecuencia, se encarga de procesar las señales producidas por los sistemas biológicos para obtener información relevante sobre los mismos con fines diagnósticos. Esas señales se conocen con el nombre de señales biomédicas.

Las señales biomédicas pueden clasificarse atendiendo a distintos criterios: según su descripción matemática, su origen o sus características. Según su descripción matemática se clasifican como señales deterministas o señales aleatorias. Las señales deterministas son aquellas que pueden representarse matemáticamente de forma explícita mediante una expresión cerrada, de manera que sus posibles valores futuros son predecibles conociendo poca información sobre su pasado. A su vez, las señales deterministas pueden subdividirse en señales periódicas, cuasiperiódicas y transitorias. Las señales aleatorias no permiten conocer su valor futuro con exactitud ni siquiera conociendo todos sus valores pasados. Estas señales son muy abundantes en los procesos físicos, y en consecuencia el análisis de su estacionariedad y su ergodicidad es esencial. La estacionariedad y la ergodicidad son dos propiedades que pueden cumplir las señales aleatorias. La primera de ellas exige que el comportamiento estadístico de la señal no cambie a lo largo del tiempo, pudiendo distinguir entre distintos grados de estacionariedad: en sentido estricto y en sentido amplio. Con respecto a la segunda, se dice que una señal aleatoria es ergódica si toda su aleatoriedad está presente en cualquiera de sus realizaciones, y por tanto, consideramos que una realización es representativa de todas las demás [1].

Atendiendo al origen de las señales biomédicas, se pueden clasificar como señales eléctricas, impedancias, señales acústicas, señales mecánicas, señales biomagnéticas, señales bioquímicas o imágenes. Las señales más conocidas se encuentran dentro de la clasificación de señales eléctricas, las cuales recogen la actividad eléctrica de distintas partes del cuerpo humano, como son el electroencefalograma (EEG) y el electrocorticograma (ECoG), que recogen la actividad cerebral; el electrooculograma (EOG), que recoge la actividad ocular; el electromiograma (EMG), que recoge la actividad muscular; y el electrocardiograma (ECG), que recoge la actividad del corazón. En la Figura 1-1 se ilustran tres de estas señales: EEG, ECG, EMG [2].

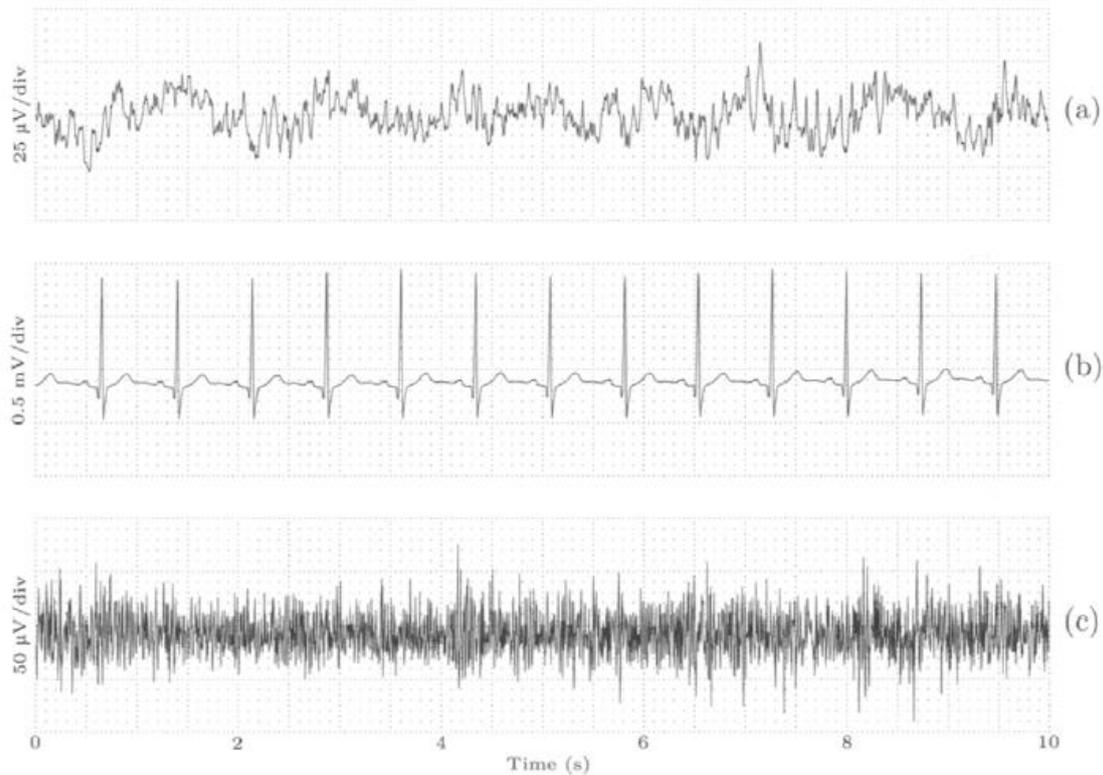


Figura 1-1. Ejemplos de las tres señales bioeléctricas principales recogidas sobre la superficie corporal: (a) un electroencefalograma (EEG), (b) un electrocardiograma (ECG), y (c) un electromiograma (EMG).

Dentro de las señales magnéticas destaca el magnetoencefalograma (MEG), que registra la actividad funcional del cerebro mediante la captación de campos magnéticos, permitiendo estudiar las relaciones entre las estructuras cerebrales y sus funciones. Otro tipo de señales son las señales bioquímicas, las cuales son el resultado de mediciones químicas de los tejidos vivos o de muestras analizadas en el laboratorio clínico.

Para finalizar, también destacan las imágenes biomédicas obtenidas mediante técnicas que emplean diversos principios físicos, tales como la imagen por resonancia magnética funcional (fMRI), que permite localizar regiones cerebrales específicas; la tomografía por emisión de positrones (PET), que mide la actividad metabólica del cuerpo humano; o la retinografía, que permite visualizar el estado de la retina para diagnosticar enfermedades como la retinopatía diabética. En la Figura 1-2 se muestra una imagen PET en el estudio de la enfermedad de Alzheimer [3].

Sin embargo, se deben realizar una serie de transformaciones a la señal antes de poder ser analizada. Estas transformaciones se aplicarán, generalmente, en tres etapas: obtención y registro de las señales (muestreo, cuantificación y digitalización de la señal), eliminación de artefactos y, finalmente, procesado de la señal (segmentación y filtrado de la misma).

En el siguiente apartado nos centraremos en el EEG, dado que es la señal utilizada en el presente estudio, introduciendo sus características principales, la forma correcta para registrar la señal y los artefactos que degradan la misma.

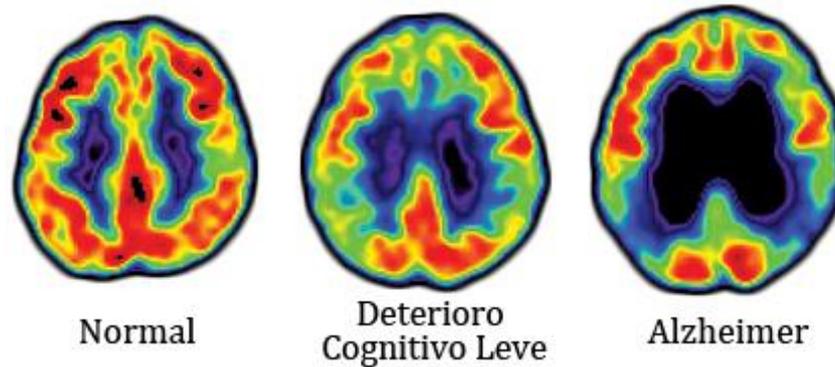


Figura 1-2. Imágenes PET que detectan la disminución de glucosa asociada con la enfermedad del Alzheimer. A la izquierda un sujeto sano, en el centro un sujeto con DCL (Deterioro Cognitivo Leve) y a la derecha un enfermo de Alzheimer.

1.2. Electroencefalograma (EEG)

El electroencefalograma (*electroencephalogram*, EEG) es una señal biomédica que registra la actividad bioeléctrica del cerebro de forma no invasiva mediante la colocación de una serie de electrodos sobre el cuero cabelludo. Debido a la atenuación que sufre la señal por las capas que separan el córtex y el electrodo (flúidos, huesos, y piel), es imposible medir la actividad de una única neurona. Consecuentemente, el EEG es la agrupación de la actividad de millones de neuronas al mismo tiempo. Esta señal se comporta de manera oscilatoria y repetitiva, y por lo tanto, nos solemos referir a esta actividad conjunta como *ritmo*. Los ritmos suelen clasificarse según su rango frecuencial y su amplitud relativa.

La amplitud de la señal EEG está relacionada con el grado de sincronía con el cual interactúan las neuronas. Una excitación sincronizada de un grupo de neuronas producirá una amplitud alta en la superficie del cráneo debido a la interferencia constructiva que se originará gracias a esa sincronización. Sin embargo, una excitación asíncrona de las neuronas producirá una señal EEG irregular con bajas amplitudes, debido a la interferencia destructiva de las actividades individuales. Este rango de amplitudes abarca desde unos pocos μV hasta $100\mu\text{V}$ [2].

El rango frecuencial de la señal EEG depende de la actividad que se esté realizando y suele estar relacionado con la amplitud de la misma. Un estado de somnolencia producirá bajas frecuencias y una sincronía entre las neuronas, causando una amplitud grande. El caso contrario se producirá cuando el cerebro está concentrado en alguna tarea determinada, desplazando el espectro a frecuencias más altas y generando una actividad asíncrona de las neuronas, forzando una amplitud más baja. En la Figura 1-3 se observan varios ritmos según el estado del sujeto [2]. El rango frecuencial comprende desde 0.5Hz (*banda delta*) hasta más de 30Hz (*banda gamma*).

La colocación de los electrodos debe atenderse a un estándar conocido como el *sistema internacional 10/20*, aprobado por la Federación Internacional de Sociedades de Electroencefalografía y Neurofisiología Clínica [4]. Este estándar distribuye los electrodos diferenciándolos según las distintas zonas del córtex y el hemisfero al que pertenecen. El cráneo se divide en seis zonas: frontopolar (Fp), frontal (F), central (C), parietal (P), occipital (O) y temporal (T). Tomando como medida de referencia la distancia recorrida entre el entrecejo (nación) y la nuca (inión) del sujeto, la sección central se encontrará a mitad de distancia y se separará de las secciones contiguas (frontal y parietal) un 20% de la distancia total. A su vez, estas dos secciones estarán

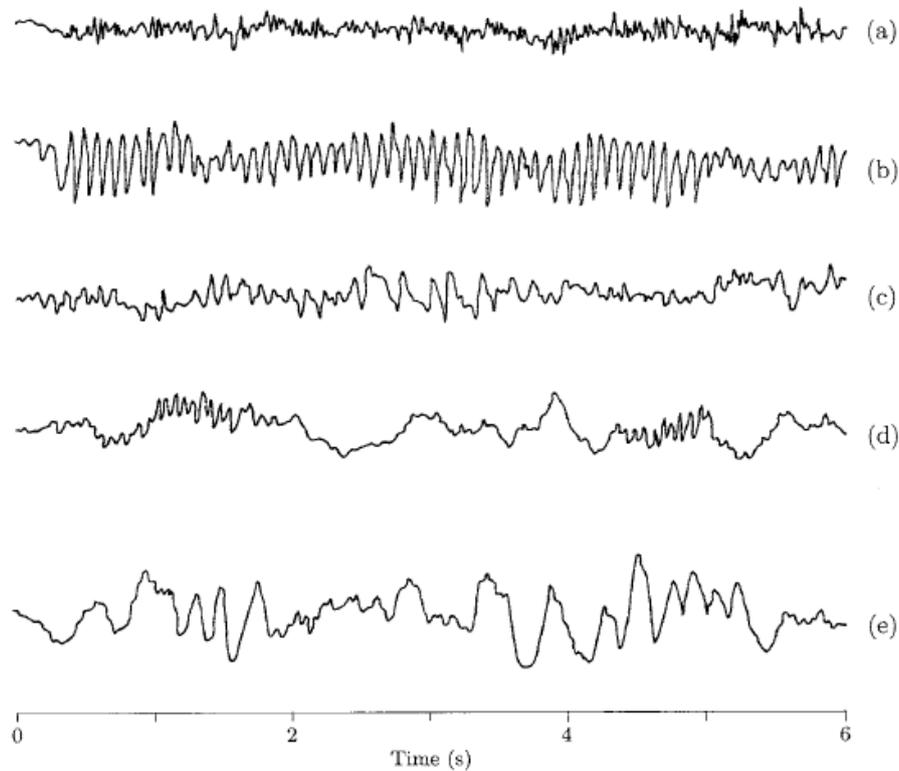


Figura 1-3. Ritmos electroencefalográficos observados durante el paso de vigilia a sueño profundo: (a) agitado, (b) relajado, (c) adormecido, (d) dormido, (e) sueño profundo. Se aprecia una disminución frecuencial a medida que el sujeto se duerme.

separadas de las secciones frontopolar y occipital, respectivamente, por un 10% de la longitud total.

La nomenclatura de los electrodos está compuesta de la letra que identifica la sección junto a un subíndice que depende del hemisferio en el que se encuentren: para el hemisferio izquierdo se asignan números impares y para el hemisferio derecho se asignan números pares. En el caso de encontrarse en el centro de ambos hemisferios, se identifican mediante una letra “z” (*zero*) minúscula en lugar de un número. Con respecto a los electrodos de referencia, suelen ubicarse en los lóbulos de las orejas y se denominan A1 (izquierdo) y A2 (derecho). En la Figura 1-4 aparecen las distribuciones de los electrodos recomendadas según el sistema internacional 10/20.

Dado que muchas componentes de ruido, incluso las que son externas al cuerpo humano, aparecen de manera común en todas las señales EEG, hay que aplicar un filtro espacial antes de procesar la señal. La referencia en la oreja elimina muchas de estas componentes, no obstante, adicionalmente se utilizan canales bipolares, métodos de media común o filtros Laplacianos. Los canales bipolares toman la diferencia de potencial entre dos electrodos no muy alejados. El método de referencia de media común (*Common Average Reference, CAR*) resta a la señal recogida por un electrodo la media de todo el conjunto de electrodos. Finalmente, el filtro Laplaciano resta a la señal recogida por un electrodo las señales adyacentes.

Además de las componentes de ruido externas al cuerpo humano, la señal puede verse afectada por una serie de artefactos o señales diferentes a la de interés. En el EEG los artefactos más conflictivos son el movimiento ocular y el movimiento muscular [5].

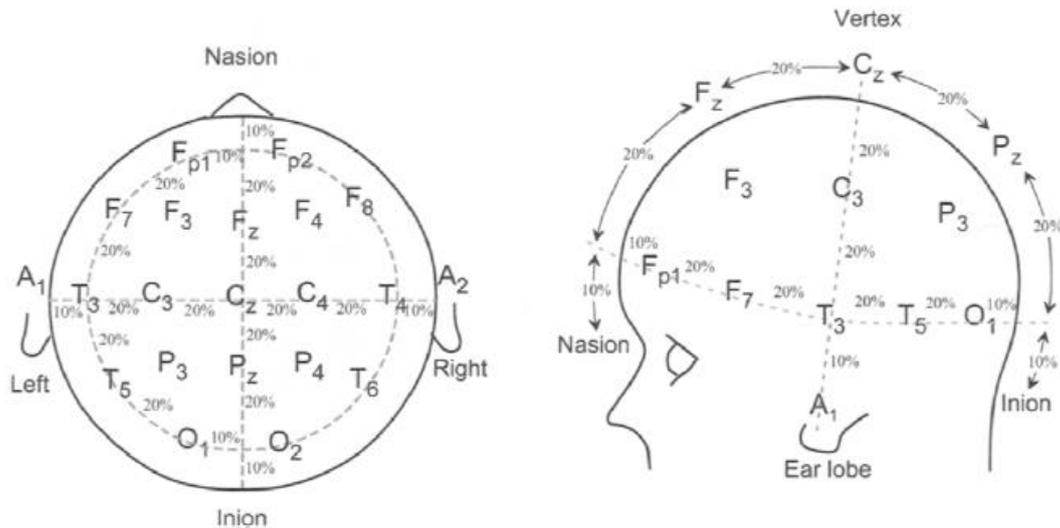


Figura 1-4. Distribución de los electrodos según el sistema internacional 10/20.

1.3. Brain Computer Interface (BCI)

Los sistemas Brain Computer Interface (*Interfaz Cerebro-Computadora*, BCI) establecen un sistema de comunicación entre el cerebro y el medio sin la intervención de los mecanismos normales de los nervios y músculos periféricos. Generalmente, los sistemas BCI procesan el EEG del usuario de manera no invasiva y traducen las intenciones del mismo en comandos de un dispositivo [6]. No obstante, también existen sistemas BCI que utilizan métodos invasivos como el ECoG o los electrodos epidurales o intracorticales como métodos de registro de la actividad cerebral. Estos sistemas consiguen mayor resolución a cambio de comprometer su estabilidad e implicar un riesgo.

Para identificar y traducir las intenciones del usuario en comandos de un determinado dispositivo, BCI utiliza señales de control tales como los potenciales evocados visuales (VEP), los potenciales evocados P300, los potenciales corticales lentos (SCP) o los ritmos sensoriomotores μ y β . Estas señales de control pueden pertenecer a dos grupos: sistemas endógenos y sistemas exógenos.

Los sistemas BCI endógenos no necesitan de ningún tipo de estimulación externa para general la actividad cerebral necesaria para clasificar las intenciones del usuario. Estos sistemas requieren entrenamiento para poder controlar satisfactoriamente la aplicación BCI. Habitualmente utilizan potenciales SCP y ritmos sensoriomotores μ y β .

En contrapartida, los sistemas BCI exógenos requieren una estimulación externa para producir la actividad cerebral necesaria para clasificar las intenciones del usuario. Estos sistemas no requieren entrenamiento alguno puesto que utilizan la respuesta natural del cerebro a diversos estímulos externos. Habitualmente utilizan potenciales VEP y potenciales evocados P300.

La señal debe ser tratada antes de poder traducir las intenciones del usuario. Este tratamiento está compuesto por dos etapas principales: adquisición de la señal y procesamiento de la señal. La primera etapa, adquisición de la señal, trata de amplificar y digitalizar la señal obtenida, además de eliminar aquellos artefactos que se han acoplado a la misma.

El procesado de la señal se compone de dos sub-etapas: la extracción y la clasificación de características. La extracción de características utiliza una serie de combinaciones y transformaciones sobre la señal EEG con el objetivo de obtener una información más discriminativa sobre las intenciones del usuario. La última parte, clasificación de características, transforma las características extraídas de la señal EEG en señales de control de un dispositivo o de una aplicación. El procesado de la señal se tratará con más detalle en el segundo, tercer y cuarto capítulo.

El desarrollo de los sistemas BCI tiene como objetivo el aumentar la independencia y la capacidad de comunicación en usuarios con enfermedades neurodegenerativas o graves discapacidades. Los sistemas BCI pueden servir de gran ayuda para personas afectadas con afasia, apraxia, autismo, parálisis, lesión medular, amputaciones, distrofias neuromusculares o esclerosis múltiple, entre otras enfermedades. En consecuencia, las aplicaciones BCI abarcan desde el control de prótesis hasta el control de un navegador web, pasando por ayudas para la comunicación, control domótico o entretenimiento en videojuegos.

De hecho, en este estudio se ha evaluado el navegador web BCI desarrollado con 16 enfermos de esclerosis múltiple, los cuales representan a los futuros usuarios de la aplicación. A continuación, se introduce el concepto de esclerosis múltiple, se presenta brevemente la sintomatología de la enfermedad y se enumeran sus distintas formas de actuación.

1.4. Esclerosis múltiple

La esclerosis múltiple (EM) se considera la enfermedad autoinmune más común que afecta al sistema nervioso central [7][8]. La EM afecta entre el 0.05% y el 0.15% de la población caucásica, causando una discapacidad severa a la mitad de ellos. Además, la enfermedad afecta más frecuentemente a las mujeres que a los hombres. Veinte años tras la aparición de los primeros síntomas, el 60% de los enfermos pierden movilidad y, aunque la mayor parte de ellos poseen una esperanza de vida en torno a la media, en casos extremos es terminal [8].

La EM se caracteriza por producir inflamaciones en las vainas de mielina de las neuronas del cerebro y la médula espinal. Como resultado, dichas neuronas pierden parcial o totalmente su capacidad de comunicación, resultando en un amplio rango de síntomas, dentro de los cuales se incluyen problemas motores, déficits cognitivos y, en ocasiones, problemas psiquiátricos [9]. Además, tales inflamaciones provocan la aparición de ataques autoinmunes contra la mielina y los oligodendrocitos, encargados de reparar la cubierta de mielina. Los ataques continuados causan remielizaciones cada vez menos frecuentes, hasta que se forma una placa alrededor de los axones dañados, perdiendo irreversiblemente dichas neuronas [9]. La figura 1-5 muestra el aspecto de una neurona dañada. Una vez se sufre un ataque, la enfermedad puede tomar diferentes formas:

- **Esclerosis múltiple benigna.** En este caso, tras uno o dos ataques a lo sumo, las vainas de mielina se recuperan. Consecuentemente, la enfermedad no empeora a lo largo del tiempo y suele tener síntomas poco graves [9].
- **Esclerosis múltiple remitente-recurrente.** Los síntomas disminuyen o desaparecen espontáneamente en un periodo de días o meses, sobre todo en fases tempranas de la enfermedad. No obstante, aparecen recaídas imprevisibles a lo largo del tiempo. En este caso, la importancia del tratamiento preventivo es alta, puesto que muchos enfermos permanecen en este estado el resto de sus vidas [9].

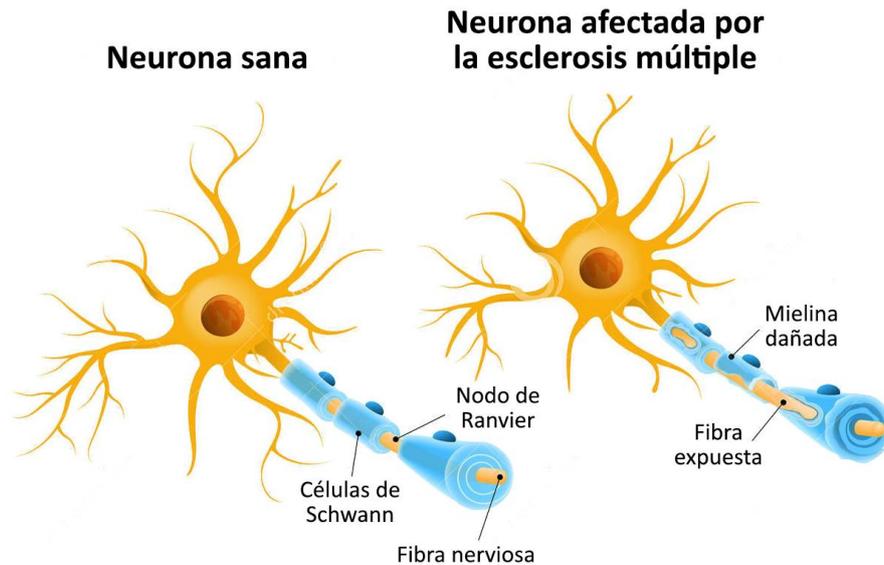


Figura 1-5. A la izquierda se muestra una neurona sana, mientras que a la derecha se muestra una neurona afectada por la esclerosis múltiple. Se observa el daño en la mielina, lo cual causa una exposición de la fibra nerviosa en ciertos puntos, dificultando la capacidad de comunicación de la neurona.

- **Esclerosis múltiple progresiva secundaria.** Este estado ocurre en el 65% de los casos de una EM remitente-recurrente, cuando de repente se produce un aumento progresivo de los síntomas de la enfermedad sin periodos de pausa [9].
- **Esclerosis múltiple progresiva primaria.** Presente en el 10% de los enfermos EM, se caracteriza por un aumento progresivo de los síntomas desde el inicio de la enfermedad sin ataques espontáneos. Comúnmente aparece con síntomas como debilidad en las piernas, alteraciones al andar y en la vejiga urinaria [9].

Las causas que provocan la enfermedad no están claras, y su búsqueda hoy en día es un campo activo de investigación. Se especula que podrían deberse a factores genéticos (posee un riesgo de recurrencia genética del 20%) o ambientales, como infecciones [9].

Actualmente no existe cura conocida para la EM, aunque la medicación empleada generalmente es eficaz. No obstante, al no existir un tratamiento preventivo efectivo para la EM progresiva primaria, suelen utilizarse tratamientos de rehabilitación como terapia ocupacional, fisioterapia o logopedia, los cuales juegan un papel importante [10].

Como consecuencia del gran avance de las telecomunicaciones durante las últimas décadas, Internet ha impactado enormemente en la vida diaria, hasta el punto de convertirse en un medio global de comunicación cotidiano. A raíz de este fenómeno, parece adecuado el proveer un acceso cómodo a Internet para las personas que sufren este tipo de enfermedades, aumentando así su capacidad de autonomía, y por ende, su calidad de vida.

1.5. Objetivos del Trabajo Fin de Máster

El objetivo general del presente Trabajo Fin de Máster es diseñar, desarrollar y evaluar una aplicación mediante sistemas BCI que permita navegar por Internet utilizando únicamente las ondas cerebrales. Esta aplicación se dirige a personas con un elevado grado de discapacidad y utiliza el EEG, un método no invasivo y de bajo coste, para traducir las intenciones del usuario en comandos de la aplicación del navegador web. La aplicación se evaluará por parte de 16 sujetos EM reclutados a través del Centro de Referencia Estatal de Discapacidad y Dependencia (CRE-DyD) de San Andrés del Rabanedo, en León (España). Para alcanzar este objetivo general, se deben cumplir los siguientes objetivos específicos:

1. Estudiar las distintas técnicas para registrar la actividad cerebral, los sistemas BCI y las señales de control que se utilizan normalmente para traducir las intenciones del usuario en comandos de un dispositivo.
2. Realizar una revisión del estado del arte de los navegadores web mediante BCI desarrollados con anterioridad junto con una comparativa que refleje las funcionalidades y las precisiones de cada uno de ellos.
3. Establecer las funcionalidades que debe implementar la aplicación en base a la comparativa realizada.
4. Diseñar las matrices que generan los potenciales evocados P300 y desarrollar la parte de la aplicación que adquiere la señal EEG, la procesa y envía los comandos necesarios a la segunda parte de la misma; mediante el lenguaje C++.
5. Desarrollar la parte de la aplicación que se encarga de interpretar los comandos, reflejando las intenciones del usuario y dotando a la aplicación de una realimentación a tiempo-real. Esta etapa se incorpora como una extensión del navegador *Google Chrome*; desarrollada en lenguaje JavaScript.
6. Diseñar un umbral para cada usuario que permita discriminar entre ausencia o no de atención de los estímulos utilizados para generar los potenciales evocados P300.
7. Evaluar el clasificador, el umbral óptimo y las funcionalidades de la aplicación con cinco sujetos sanos en tres sesiones distintas: dos de calibración y una de evaluación.
8. Implementar las mejoras de la aplicación que puedan sugerirse a raíz de la realimentación obtenida gracias a la evaluación con sujetos de control.
9. Evaluar la aplicación final con dieciséis enfermos de EM del CRE-DyD de San Andrés del Rabanedo en cuatro sesiones distintas: dos sesiones de calibración y otras dos de evaluación.
10. Analizar los resultados obtenidos e inferir las posibles causas de los mismos, además tratar de mejorar la clasificación *off-line* implementando un conjunto de máquinas de soporte vectorial.
11. Discutir los resultados obtenidos, las debilidades y los puntos fuertes de la aplicación, así como realizar una comparativa con otros estudios.
12. Extraer conclusiones a partir de los resultados obtenidos.
13. Plantear líneas futuras de investigación dentro del ámbito de estudio.

1.6. Estructura del Trabajo Fin de Máster

El Trabajo Fin de Máster está compuesto por ocho capítulos: introducción, sistemas Brain Computer Interface, análisis de la señal y potenciales evocados P300, sujetos y métodos, aplicación de navegador web, resultados, discusión y conclusiones y líneas futuras.

En el primer capítulo, introducción, se describen los distintos tipos de señales biomédicas y su clasificación atendiendo a distintas características de la señal. Posteriormente, se detallan las características de la señal EEG y la adquisición de la señal mediante el estándar internacional 10/20. A continuación, se introduce el concepto de sistema BCI, se enumeran las distintas señales de control utilizadas y se establece, brevemente, la estructura del procesado de la señal. Le sigue una pequeña introducción sobre la EM, la enfermedad que poseen los usuarios que evaluarán la aplicación. Finalmente, se detallan los objetivos y la estructura del presente trabajo.

En el segundo capítulo, sistemas Brain Computer Interface, se tratan, de manera más detallada, los aspectos sobre BCI previamente introducidos en el primer capítulo. En primer lugar, se estudian los distintos métodos para registrar la actividad cerebral, seguido por la enumeración y explicación de las distintas señales de control. Posteriormente, se detalla el procesado de la señal EEG y se enumeran las distintas aplicaciones que han surgido gracias a los sistemas BCI, junto a una comparativa entre los distintos navegadores web desarrollados con anterioridad. En último lugar, se discuten las limitaciones actuales de dichos sistemas.

En el tercer capítulo, análisis de la señal y potenciales evocados P300, se especifican las propiedades de los potenciales evocados P300 (señal de control utilizada en la aplicación web). A continuación, se introducen los distintos métodos utilizados en la literatura para procesar dicha señal de control, tanto para la extracción de características como para la clasificación de las mismas.

En el cuarto capítulo, sujetos y métodos, se especifican las características demográficas y clínicas de la población de estudio. Posteriormente, se detalla la metodología empleada en el presente trabajo, tratando la adquisición y el pre-procesado de la señal, la extracción de las características y su clasificación. También se incluye un apartado de umbralización, donde se estudia cómo diferenciar la actividad basal del usuario con respecto al deseo de seleccionar un comando, conformando así la asincronía de la aplicación.

En el quinto capítulo, aplicación de navegador web, se describen los objetivos, la estructura, el diseño y el desarrollo de la aplicación web desarrollada. Además, se incluyen los documentos entregados a los usuarios durante la evaluación de la aplicación: un breve manual de la misma y los cuestionarios de satisfacción. Para finalizar, se incluye el procedimiento de evaluación seguido, describiendo tanto las sesiones de calibración como las tareas realizadas por parte de la población de estudio.

En el sexto capítulo, resultados, se muestran los resultados obtenidos, tanto para la evaluación de la aplicación utilizando un análisis discriminante lineal paso-a-paso como para el análisis de las precisiones de clasificación utilizando máquinas de soporte vectorial. En tales resultados se incluyen las precisiones obtenidas por cada uno de los usuarios (sanos y enfermos) en cada una de las sesiones: calibración y evaluación; además de las opiniones y sugerencias de mejora recogidas en los cuestionarios de satisfacción.

En el séptimo capítulo, discusión, se discuten los resultados obtenidos, identificando, desde una postura crítica, la razón por la cual se han obtenido. Adicionalmente, se comparan con los estudios desarrollados anteriormente y se establecen las limitaciones de la aplicación, junto con las sugerencias que podrían solventarlas en un futuro.

En el octavo y último capítulo, conclusiones y líneas futuras, se recopilan las conclusiones extraídas durante el desarrollo del presente Trabajo Fin de Máster. Para terminar, se establecen las líneas futuras de investigación que se contemplan a partir del mismo.

SISTEMAS BRAIN COMPUTER INTERFACE

2.1. Introducción

La historia de los sistemas BCI está íntimamente ligada con el desarrollo de los electroencefalogramas. El EEG fue desarrollado por Hans Berger en 1929 y las ondas cerebrales, hasta entonces desconocidas, fueron investigadas durante el siglo XX, aplicando este sistema como diagnóstico de la epilepsia o diversos trastornos del sueño. Durante este periodo de tiempo, se especuló sobre utilizar las señales EEG para desarrollar un sistema de comunicación entre el cerebro y el medio sin la intervención de los mecanismos normales de los nervios y músculos periféricos [6].

El primer sistema BCI surgió en 1977 a cargo del Dr. Jacques Vidal, permitiendo controlar el movimiento de un cursor en dos dimensiones mediante los potenciales evocados visuales (VEP) que se detectaban en el EEG del usuario [11]. El sistema se componía de cuatro botones que se iluminaban con luces intermitentes de xenón a distintas frecuencias, los cuales representaban las cuatro direcciones básicas: arriba, abajo, derecha e izquierda. Cuando la mirada del usuario se centraba en uno de estos botones quedaban reflejados en el EEG los potenciales VEP que aparecen como respuesta a un estímulo visual de manera natural. De esta manera, el usuario era capaz de manejar, rígidamente, un cursor con el objetivo de escapar de un laberinto, por ejemplo [11]. El esquema de éste primitivo e innovador sistema BCI aparece en la Figura 2-1.

No obstante, aunque éste sistema fue pionero en el ámbito de la interfaz cerebro-computadora, los sistemas BCI no se han desarrollado completamente hasta la década de los 90 debido al coste computacional que requieren las aplicaciones prácticas.

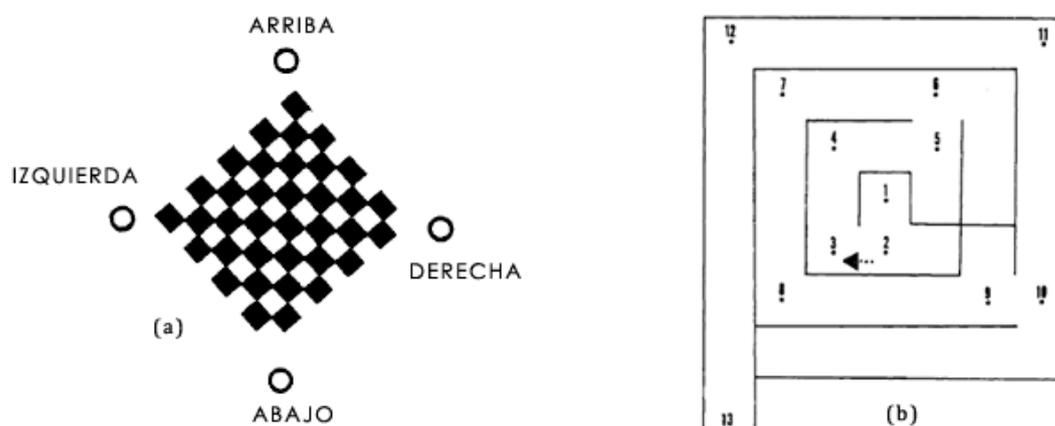


Figura 2-1. Esquema del primer sistema BCI controlado por VEP y desarrollado por Dr. Jacques Vidal en 1977. En (a) aparecen los botones que se iluminaban intermitentemente para controlar el cursor. En (b) aparece el laberinto del cual debían salir los usuarios moviendo el cursor [11].

Tal y como se ha explicado anteriormente, un sistema BCI puede clasificarse atendiendo a varios aspectos. Podemos hablar de sistemas BCI endógenos y exógenos. Los sistemas BCI endógenos no necesitan de ningún tipo de estimulación externa para generar la actividad cerebral necesaria para clasificar las intenciones del usuario y, por tanto, requieren entrenamiento. En contrapartida, los sistemas BCI exógenos sí que requieren de una estimulación externa para producir esa actividad cerebral. Dado que la respuesta del cerebro es natural, no necesitan entrenamiento.

Atendiendo a los métodos que se utilizan para registrar la actividad cerebral, un sistema BCI se puede clasificar en dos grupos: sistemas invasivos y sistemas no invasivos. Los sistemas invasivos, menos utilizados en la práctica con seres humanos, necesitan una intervención previa para implantar los electrodos que recogen la actividad bioeléctrica del cerebro. Consecuentemente, estos sistemas implican un riesgo para la salud a cambio de obtener mayor calidad en las señales registradas. Los sistemas BCI invasivos suelen utilizar el ECoG como método de adquisición de la señal. En cambio, los sistemas no invasivos no requieren de ningún tipo de implantación previa para recoger la actividad cerebral, convirtiéndose así en los sistemas más utilizados en la práctica. Estos sistemas suelen utilizar el EEG como método de adquisición de la señal.

La finalidad principal de los sistemas BCI es la de mejorar la calidad de vida de personas con discapacidades severas, ya sea por sufrir una enfermedad neurodegenerativa (la esclerosis lateral amiotrófica, la esclerosis múltiple o la distrofia neuromuscular), o por sufrir algún tipo de parálisis o amputación (las lesiones cerebrales, medulares o la apoplejía), ayudando en la comunicación e incluso en el control de dispositivos domóticos.

La estructura de los sistemas BCI comprende dos etapas bien diferenciadas: la adquisición de la señal y el procesado de la misma. En este capítulo se sigue la misma estructura, indicando cuáles son los principales métodos de adquisición de la señal y las distintas señales de control que se utilizan, detallando sus características y la zona del córtex donde se producen.

A continuación se detallan los artefactos más comunes que afectan a la señal, entendiendo como artefacto cualquier otra señal recogida diferente a la de interés, siendo éstos el movimiento ocular y pestaños, la actividad eléctrica de músculos cercanos y la actividad eléctrica del corazón.

Una vez digitalizada la señal y libre de artefactos, se trata el procesado de la misma, distinguiendo dos sub-etapas: la extracción de características y el algoritmo de traducción. En la extracción de características se usan una serie de combinaciones y transformaciones sobre la señal con el objetivo de obtener una información más discriminatoria sobre las intenciones del usuario. A continuación, el algoritmo de traducción (también conocido con el nombre de traducción de características) se encarga de transformar las características extraídas en señales de control de un dispositivo o de una aplicación [5]. La estructura habitual de los sistemas BCI se puede observar detenidamente en la Figura 2-2.

Posteriormente, se enumeran las principales aplicaciones de los sistemas BCI tales como ayudas en la comunicación, selección de letras, movimiento de un cursor, desplazamiento sobre un mapa, etcétera; haciendo hincapié en las aplicaciones que se encargan de controlar un navegador web. Seguidamente se realiza una presentación sobre el estado del arte de los navegadores basados en BCI desarrollados con anterioridad, además de incluir una comparación entre cinco soluciones distintas.

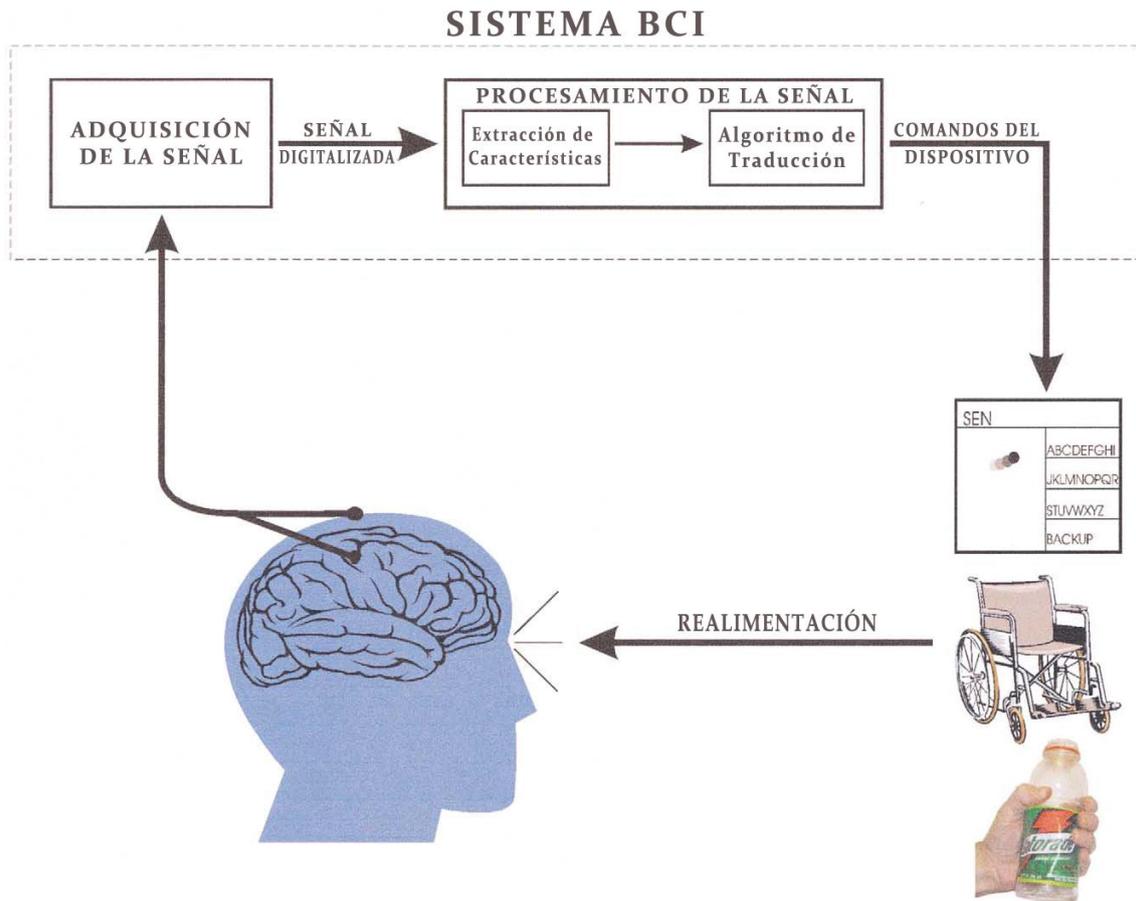


Figura 2-2. Estructura habitual que siguen los sistemas BCI desde la adquisición de la señal en crudo hasta la conversión de ésta en comandos de control de un dispositivo.

2.2. Métodos para registrar la actividad cerebral

Existen una gran variedad de métodos de adquisición de las señales que se utilizan para controlar los sistemas BCI. Estos métodos se pueden clasificar en métodos que extraen señales eléctricas, ampliamente utilizados, y métodos que no utilizan señales eléctricas, detallados a continuación.

- **Imágenes de resonancia magnética funcional (*functional Magnetic Resonance Imaging, fMRI*).** La fMRI hace uso de los fenómenos de resonancia magnética para medir la respuesta hemodinámica del cerebro con fines clínicos y de investigación. La principal utilidad de esta técnica es la de proveer información sobre la localización de las funciones cerebrales mientras se realiza alguna acción. Normalmente se utiliza para pacientes que requieren cirugía cerebral.
- **Magnetoencefalografía (*Magnetoencephalography, MEG*).** La técnica MEG se define como un método no invasivo que registra la actividad funcional del cerebro mediante la captación de campos magnéticos, permitiendo investigar las relaciones entre las estructuras cerebrales y sus funciones.
- **Espectroscopía de infrarrojo cercano (*Near Infrared Spectroscopy, NIRS*).** La espectroscopía estudia la interacción de la radiación electromagnética con la materia. En este caso se emiten fotones de luz cercanos al infrarrojo (NIR, longitudes de onda entre 780 nm y 3.000 nm)

sobre la piel de la frente del paciente. Después de dispersarse por el interior del cuero cabelludo, cráneo y cerebro, parte de esos fotones vuelven a la piel gracias a los fenómenos de reflectancia espectral. Al medir la cantidad de fotones recibidos se extraen conclusiones sobre la respuesta hemodinámica del cerebro y los niveles de saturación de oxígeno y azúcar en sangre.

- **Tomografía por emisión de positrones (*Positron Emission Tomography, PET*)**. La técnica PET se basa en detectar y analizar la distribución tridimensional que adopta en el interior del cuerpo un radiofármaco administrado a través de una inyección intravenosa. Esta técnica se clasifica como una técnica no invasiva de diagnóstico *in vivo* por imagen capaz de medir la actividad metabólica del cuerpo humano.

Aunque prácticamente todas las técnicas mencionadas son métodos no invasivos, no están exentas de inconvenientes. La resolución espacial que proveen las técnicas fMRI y NIRS es excelente, sin embargo, la resolución temporal es muy pobre. Por tanto, no se podrían utilizar en aplicaciones que requieren funcionar en tiempo-real. No ocurre lo mismo para las técnicas MEG, las cuales consiguen muy buenas resoluciones tanto temporales como espaciales, sin embargo, dado que ésta técnica y fMRI requieren un superconductor, el equipamiento necesario para llevarlas a cabo tiene un coste demasiado elevado. Adicionalmente, también necesitan aislamiento magnético, provocando el uso de habitaciones aisladas y equipamientos demasiado voluminosos [12].

Teniendo en cuenta que la aplicación a desarrollar, y en general todas las aplicaciones que utilizan BCI, requiere un sistema portátil, eficiente, de coste razonable y a tiempo real, las técnicas explicadas previamente no se adecúan a los requerimientos buscados. Es por esta razón por la cual los métodos que extraen señales eléctricas son los más utilizados actualmente, detallados a continuación y representados esquemáticamente en la Figura 2-3.

- **Electroencefalografía (*Electroencephalography, EEG*)**. La técnica EEG es un método no invasivo que registra la actividad bioeléctrica del cerebro mediante la colocación de una serie de electrodos sobre el cuero cabelludo. Normalmente, en los sistemas BCI se utilizan 64 electrodos, no obstante, para aplicaciones concretas se suelen aplicar menos, dependiendo de la señal de control que se desee analizar.
- **Electrocorticografía (*Electrocorticography, ECoG*)**. La técnica ECoG persigue el mismo objetivo que la técnica EEG, sin embargo, ésta sí es una técnica invasiva. Se basa en implantar electrodos directamente sobre la superficie del córtex, proveyendo mayor resolución temporal y espectral a cambio de implicar un riesgo para el paciente.
- **Electrodos epidurales o intracorticales**. Los electrodos epidurales se basan en la colocación de electrodos de cristal con forma de cono hueco en neuronas aisladas. Estos electrodos ofrecen mayor resolución espacial y temporal que las técnicas anteriores, sin embargo, el tiempo que pueden permanecer implantados es limitado, además de que la neurona en cuestión podría morir u otra neurona podría pasar a realizar sus funciones, haciendo inservible la obtención de la señal a través de éste método.

Cada alternativa posee ventajas y desventajas. El EEG es una técnica frecuentemente utilizada debido a su naturaleza no invasiva. No obstante, ofrece una resolución espacial limitada, además de estar contaminado por artefactos

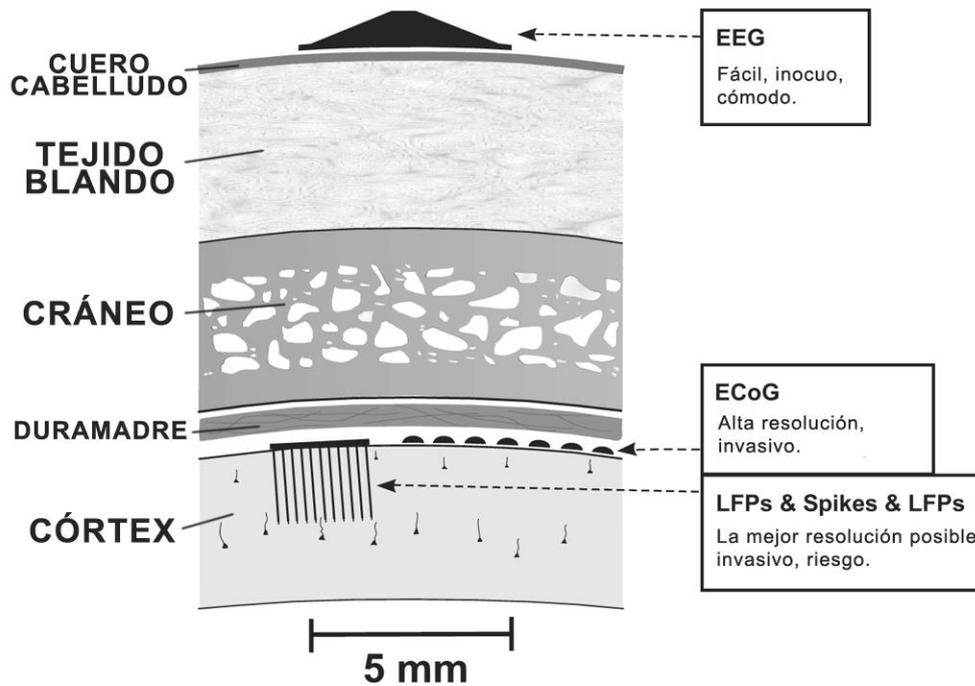


Figura 2-3. Localización de los electrodos de distintas técnicas que emplean señales eléctricas.

tales como el movimiento de los ojos o de los músculos cercanos. También requiere un mantenimiento continuo para asegurar una baja impedancia en los electrodos y así obtener una señal con calidad.

A diferencia del EEG, el ECoG ofrece mayor resolución espacial y está libre de artefactos. En contrapartida, este método requiere una intervención quirúrgica y en la práctica solamente lo usan las personas que ya poseen estos electrodos porque sufren alguna enfermedad, como la epilepsia. Para finalizar, los electrodos epidurales o intracorticales ofrecen las mayores resoluciones posibles pero, debido a los inconvenientes ya mencionados, solamente se usan en experimentos con animales [12].

Parece razonable considerar el EEG como el método más indicado para la aplicación a desarrollar. El EEG es un método no invasivo, portátil, fácil de usar y con un precio razonable, lo cual lo convierte en el mejor candidato posible. Después de obtener la señal a través de los electrodos del cuero cabelludo, se procede a digitalizarla y eliminar los artefactos que puedan deteriorarla.

2.3. Tipos de señales de control en BCI

Una vez seleccionado el EEG como método para registrar la actividad cerebral en la aplicación BCI a desarrollar, es necesario elegir una señal de control específica que permita gobernar la aplicación. Estas señales se pueden generar de manera natural como respuesta a un estímulo externo (señales de control exógenas), o se pueden generar de manera voluntaria con entrenamiento (señales de control endógenas).

Para registrar un EEG en los sistemas BCI habitualmente se utilizan 64 electrodos, sin embargo, para aplicaciones que usan señales de control concretas se puede reducir este número conociendo la localización específica donde se generan. Para comprender la localización de los electrodos a la hora de utilizar una aplicación BCI se incluye a continuación un gráfico donde se indican las distintas regiones en las que se divide la corteza cerebral (Figura 2-4).

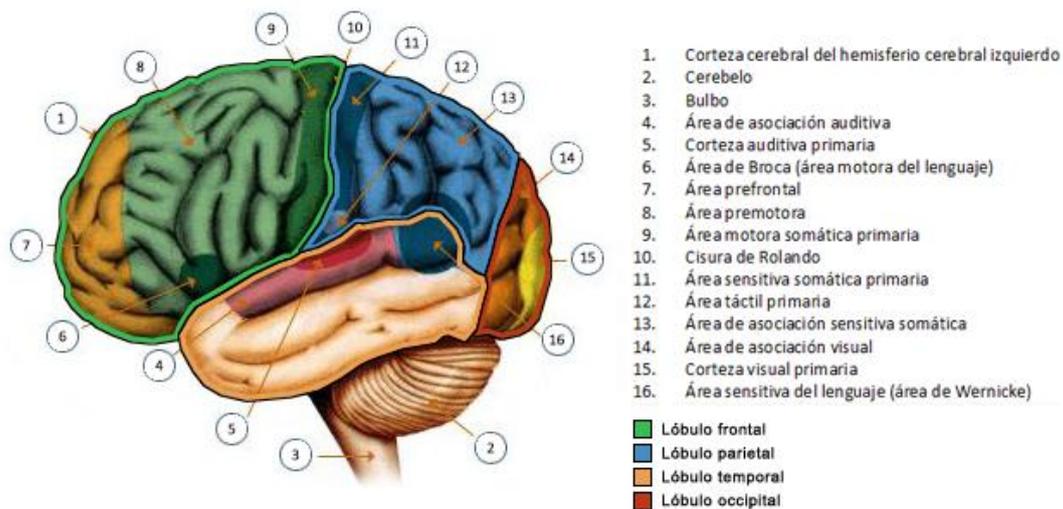


Figura 2-4. Regiones en las que se divide la corteza cerebral.

Las señales de control que trataremos a continuación son las siguientes: potenciales VEP, potenciales corticales lentos SCP, ritmos sensoriomotores μ y β , potenciales de neuronas corticales y potenciales evocados P300.

2.3.1. Potenciales Evocados Visuales

Los potenciales evocados visuales (*Visual Evoked Potentials*, VEP) son cambios de potencial que se producen en la corteza visual tras una estimulación luminosa [5]. Estos potenciales VEP producen un fenómeno de resonancia cuando el sujeto se fija en una fuente luminosa que parpadea a una determinada frecuencia superior a 4Hz. El fenómeno de resonancia se utiliza para determinar la dirección de la mirada [13]. Se recogen en la parte visual del córtex, ubicada en torno al lóbulo parietal y occipital.

Un método muy utilizado para determinar la dirección de la mirada consiste en la presentación al usuario de una serie de fuentes de luz que parpadean a distintas frecuencias. Cuando el usuario se fija en una fuente concreta, el sistema mide la frecuencia con la que aparecen los potenciales VEP (en torno a 100ms después de la iluminación [5]) y se genera el fenómeno de resonancia. Este fenómeno provoca que en el EEG del usuario aparezca un pico en la frecuencia que corresponde a la fuente de luz en la que se fija el usuario, además de sus armónicos. Distinguiendo este pico frecuencial se determina la dirección de su mirada y, por tanto, las intenciones del usuario [13]. En la Figura 2-5 aparece el espectro frecuencial de un usuario cuando experimenta este método.

Esta señal de control es exógena, provocada por una respuesta natural del cerebro, y por tanto no requiere entrenamiento. Gracias a ello, se consiguen precisiones de hasta el 90% en pocas sesiones [14]. Además, Friman *et al* [13] demostró que el número de electrodos afecta en la precisión del sistema, concluyendo que los mejores resultados se obtienen cuando se utilizan pocos electrodos colocados correctamente en sobre la zona donde se generan los potenciales VEP. Las tasas binarias obtenidas se encuentran en torno a los 27 bits por minuto [15].

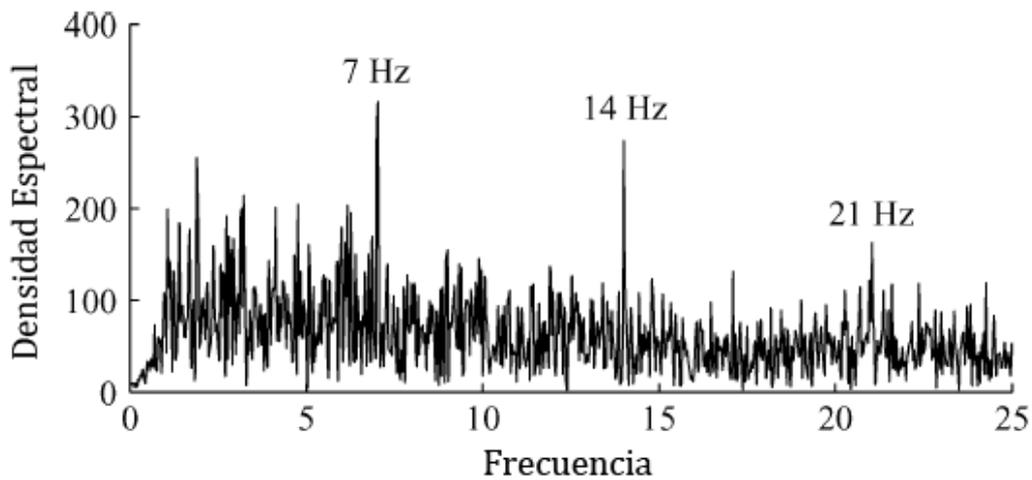


Figura 2-5. Espectro frecuencial de una señal EEG recogida durante una estimulación visual a 7Hz. El fenómeno de resonancia de los potenciales VEP produce picos en 7Hz y sus armónicos.

Los sistemas BCI que se basan en los potenciales VEP se clasifican dentro de los sistemas BCI dependientes, puesto que para poder realizar con éxito el control mediante estas señales se requiere que el usuario sea capaz de mantener la mirada fija en un punto concreto. El rango de aplicaciones es inmenso, pasando desde la selección de diversos comandos al control de un cursor en dos dimensiones.

2.3.2. Potenciales Corticales Lentos

Los potenciales corticales lentos (*Slow Cortical Potentials*, SCP) son cambios de voltaje lentos, entre 0,5 y 10 segundos, generados en el córtex a bajas frecuencias. Los valores SCP negativos están asociados al movimiento y otras funciones que involucran un aumento de la activación cortical, mientras que valores SCP positivos están asociados a la ausencia de movimiento o reducción de la activación cortical [5]. En la Figura 2-6 se pueden observar las diferencias entre el aumento y reducción de la activación cortical. Estos potenciales se generan en el vértex, la zona superior de la cabeza, en torno a la unión del lóbulo frontal y parietal, asociada con el movimiento.

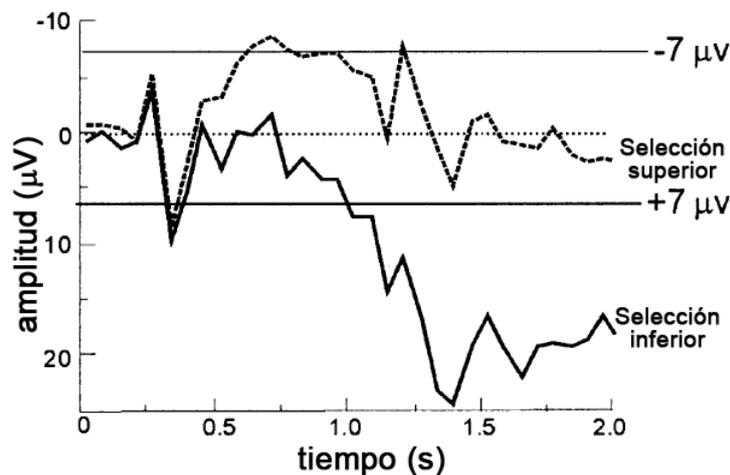


Figura 2-6. SCP recogidos durante una selección binaria [5].

Esta señal es endógena y requiere de entrenamiento para poder controlarse correctamente. En el estudio de Birbaumer *et al* [16] se desarrolla la técnica conocida como “dispositivo de interpretación de pensamiento” (*Thought Translation Device*, TTD). Para empezar se mide durante 2 segundos el voltaje inicial del EEG del usuario y durante los 2 segundos siguientes se determina si se ha producido o no activación cortical. La técnica consiste en un cursor que se mueve horizontalmente a velocidad constante, mientras que el movimiento vertical se controla a través de los SCP. Por encima del movimiento del cursor aparecen una serie de selecciones, y cuando el usuario desea seleccionar alguna de ellas basta con generar un SCP que produzca que el cursor se desplace verticalmente sobre ella. Es, por tanto, un sistema de selección binaria.

El entrenamiento para controlar adecuadamente estas señales de control varía entre 1 y 5 meses (obteniendo precisiones en torno al 75%), constituyendo la principal desventaja de esta señal. Las tasas binarias conseguidas se sitúan en torno a los 15 bits por minuto, inferiores a las obtenidas con los potenciales VEP [17].

Los artefactos que más afectan a los potenciales SCP son la respiración del sujeto y, sobre todo, el movimiento ocular. En consecuencia, deberán ser eliminados en la etapa de adquisición de la señal para poder analizarse adecuadamente.

2.3.3. Ritmos sensoriomotores (ritmos μ y β)

La señal EEG es el resultado de la agrupación de la actividad conjunta de millones de neuronas, lo cual produce un comportamiento oscilatorio y repetitivo, y por consiguiente, nos solemos referir a esa actividad conjunta como *ritmo*. En estado de vigila la mayoría de personas muestran una actividad en la banda de 8-12Hz cuando no están realizando ninguna acción motora o procesando algún estímulo externo (este fenómeno se puede apreciar en la Figura 2-7).

Esta actividad se denomina *ritmo μ* cuando se produce sobre la zona somatosensorial o motora del córtex y *ritmo α* cuando se produce sobre la zona visual del córtex. Los electrodos, por tanto, que son capaces de obtener la señal se deben colocar en estas zonas, ocupando las posiciones Cz, C3 y C4; y en ocasiones también F3, F4, O1 y O2 [5].

Los *ritmos μ* (de 8 a 12 Hz) están asociados con otros ritmos de mayor frecuencia llamados *ritmos β* (de 18 a 26 Hz) y, aunque alguno de los *ritmos β* se correspondan con los armónicos de los *ritmos μ* , otros son independientes, pudiendo usar ambos como dos características distintas o dos señales de control autónomas [5].

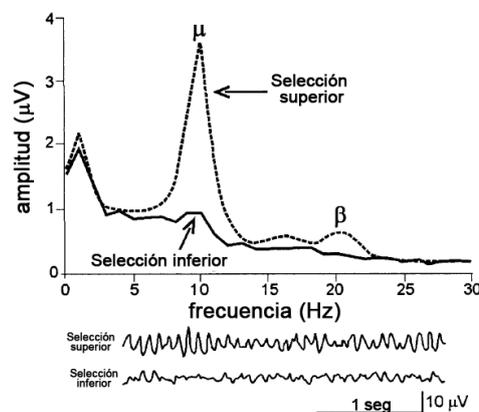


Figura 2-7. Ritmos μ y β . En la selección inferior se percibe una disminución de los mismos [5].

La preparación del movimiento o la intención de realizarlo conllevan una disminución de los ritmos μ y β , particularmente contralateral al movimiento. Esta disminución se denomina ERD (*Event-Related Desynchronization*, Desincronización del evento relacionado) y ocurre pocos segundos antes de realizar el movimiento. Se conoce como “desincronización” porque la señal pierde su carácter oscilatorio, provocando una disminución de los picos frecuenciales que la caracterizaban [5].

En contraposición, una vez se realiza o se finaliza la intención de realizar un movimiento, se produce un aumento de los ritmos μ y β . Este aumento se denomina ERS (*Event-Related Synchronization*, Sincronización del evento relacionado) y determina el punto en el cual la señal volverá a obtener su carácter oscilatorio, provocando la recuperación de sus picos frecuenciales característicos. Adicionalmente, tanto los ERD como los ERS se localizan en el lado del cerebro contrario al movimiento que se desea realizar [5].

En la Figura 2-8 se recogen varios registros que muestran estos fenómenos [18]. En la gráfica superior se muestran tres tipos de oscilaciones a distintas frecuencias recogidas por el mismo electrodo (C3) sobre la zona sensoriomotora cuando el usuario mueve el dedo índice de la mano. Se puede apreciar un claro ERD en el ritmo μ que aparece, aproximadamente, 2,5s antes de la realización del movimiento (marcado en línea roja, correspondiente a $t=0$ s) y recupera el nivel inicial pasados unos segundos. La actividad del ritmo β presenta un ERD de corta duración cerca del inicio del movimiento, seguido por un ERS con un máximo al segundo de ejecutar el movimiento. Con respecto a las oscilaciones de la banda γ (36-40Hz), presentan un ERS antes de realizar el movimiento, pudiendo proveer información y ser útiles en ocasiones, sin embargo, estas oscilaciones de alta frecuencia no están presentes en todos los seres humanos.

En el gráfico inferior se muestra el EEG en cada electrodo para el mismo movimiento. Se pueden observar claramente los ERD en las posiciones centrales de los electrodos (C3, C4 y Cz) antes de realizar el movimiento y los ERS inmediatamente después del mismo sobre los electrodos de la zona visual del córtex (ritmo α , P3, P4, Oz).

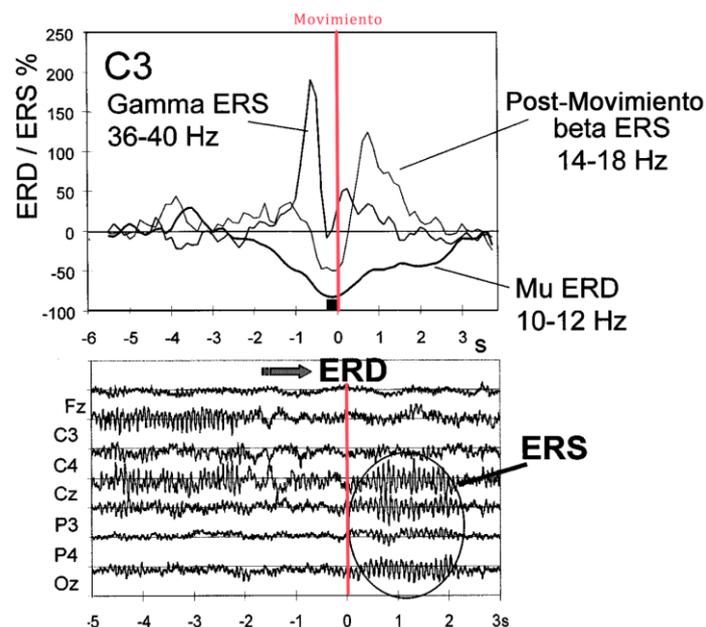


Figura 2-8. Señal EEG registrada antes y después de realizar un movimiento con el dedo índice de la mano donde se aprecian los ERD y ERS. El panel superior se corresponde al electrodo C3 [5].

Se ha demostrado que no solamente la ejecución del movimiento genera los ERD y los ERS, también la imaginación del movimiento o la visualización del mismo provocan los mismos cambios en los ritmos μ y β . Esta es la razón por la cual un sistema BCI basado en ritmos sensoriomotores se trata como un sistema independiente, el cual no depende de la capacidad del usuario para fijar la vista en un punto concreto o mover una articulación, simplemente es necesario imaginar el movimiento para generar la señal de control [19].

Al igual que los SCP, la señal de control generada gracias a los ritmos sensoriomotores es endógena y, por tanto, requiere entrenamiento para poder ser controlada de manera adecuada. Con un entrenamiento de unas 6 horas se pueden llegar a alcanzar precisiones por encima del 80% y tasas binarias de 20-25 bits por minuto [5].

2.3.4. Potenciales de neuronas corticales

Los potenciales de neuronas corticales se corresponden a la activación de neuronas aisladas. Estos potenciales se recogen mediante electrodos epidurales o intracorticales, considerándose un método invasivo. En la Figura 2-9 aparece un esquema sobre la implantación de un electrodo intracortical.

Diversos estudios con monos han demostrado que éstos son capaces de aprender a controlar la activación de neuronas aisladas, así que se espera que los humanos sean capaces también. Sin embargo, la evaluación de esta especulación se retrasó debido a la ausencia de los electrodos adecuados y a que no era posible registrar la actividad neuronal de forma estable a largo plazo (normalmente no superan el año). De hecho, la neurona que está siendo monitorizada por el electrodo en cuestión puede morir o relevar su función a otra neurona distinta, causando que el electrodo se vuelva inútil [5].

Utilizando esta señal de control se podría controlar un cursor en 1D para seleccionar comandos o letras en una pantalla. También podría llegar a controlarse un cursor en 2D si se logra el control de la actividad EMG residual (se obtuvieron tasas de 15bits por minuto y precisiones del 67% en animales) [5]. Sin embargo, no se puede generalizar con total seguridad para los humanos y debido a la escasez de experimentos con los mismos no se puede determinar que su uso sea satisfactorio.

Dado que los experimentos con animales se realizaron cuando éstos realizaron los movimientos oportunos, tampoco se conoce si se producirán los mismos patrones en la actividad neuronal cuando no se realice el movimiento debido a la incapacidad del usuario para realizarlo.

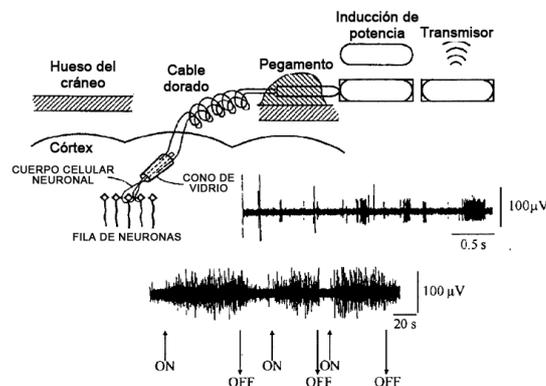


Figura 2-9. Esquema que muestra la implantación de electrodos epidurales o intracorticales [5].

2.3.5. Potenciales evocados P300

Los potenciales evocados P300 son deflexiones positivas de voltaje localizadas en la zona parietal del córtex como respuesta a un estímulo que aparecen en torno a 300ms después de que éste se produzca [5]. Por tanto, el potencial P300 es una señal exógena (no requiere entrenamiento) provocada por una respuesta natural del cerebro ante un estímulo, ya sea visual, auditivo o somato-sensorial [2]. Los electrodos que se emplean para recoger este potencial normalmente se sitúan en la región centro-parietal del córtex, típicamente en Cz, Fz y Pz.

La aparición de los potenciales evocados P300 se provoca de acuerdo al paradigma *odd-ball*, el cual trata de presentar un estímulo deseado de forma infrecuente camuflado entre estímulos frecuentes. Es decir, el potencial evocado P300 se produce cuando la opción que pretende elegir el usuario se encuentra entre muchas otras opciones que no interesan. En consecuencia, se concluye que cuanto más improbable sea el estímulo deseado, más probable será que aparezca el potencial evocado P300 y que su amplitud sea mayor.

La aplicación más frecuente de este paradigma se basa en presentar una matriz cuyas celdas sean las opciones a seleccionar: habitualmente letras, números o comandos de una aplicación. En cada intento se iluminan aleatoriamente las filas y las columnas de forma que, tras un número determinado de iluminaciones, cada fila y columna se haya iluminado una vez. El usuario, fijándose en la celda que desea seleccionar, provocará dos potenciales evocados P300 cuando se iluminen la fila y la columna que contienen dicha celda. Promediando la respuesta para cada elemento de la matriz y detectando el potencial P300 con mayor amplitud se determina cuál es la celda seleccionada por el usuario [5]. El resultado de este tipo de aplicaciones se puede observar en la Figura 2-10.

Dado que se trata de una señal exógena y no requiere entrenamiento, se pueden alcanzar precisiones muy altas en intervalos muy cortos de tiempo (90% de precisión con 4 selecciones por minuto en sujetos de control [5]). Sin embargo, su rendimiento puede verse afectado a lo largo del tiempo cuando el usuario se acostumbra a los estímulos que generan los P300, pudiendo dejar de ser notables.

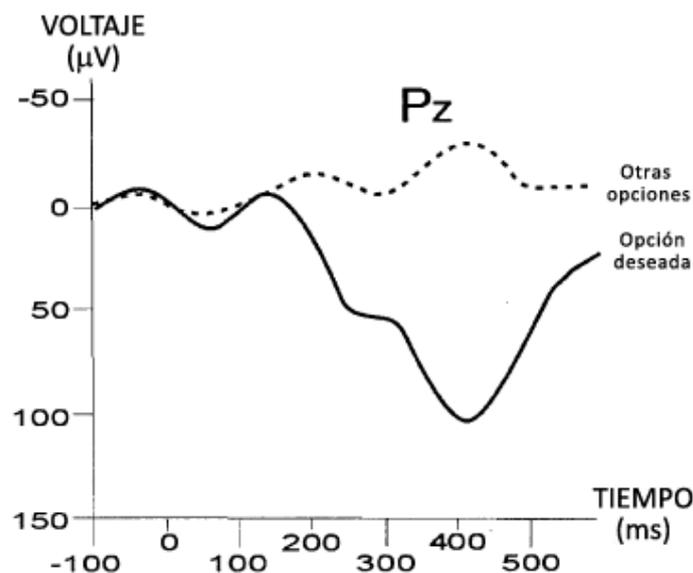


Figura 2-10. Potencial evocado P300 recogido sobre el área centro-parietal del córtex mediante la técnica *odd-ball* con una matriz luminosa [5].

2.4. Procesado de la señal EEG

El tratamiento de la señal EEG puede dividirse en tres etapas principales: adquisición de la señal, procesado de la señal y aplicación. A su vez, el procesado de la señal se puede subdividir en otras dos etapas, siendo éstas la extracción de características y la traducción de las mismas. En la Figura 2-11 se representan de manera esquemática.

2.4.1. Adquisición de la señal

La primera etapa es la de la adquisición de la señal. Esta etapa se encarga de obtener la señal, amplificarla, digitalizarla, eliminar los artefactos que la degraden y almacenarla para un posterior análisis *offline*.

Tal y como se comentó en el capítulo de introducción, la obtención de la señal EEG se realiza mediante la colocación de los electrodos superficiales atendiendo al *sistema internacional 10/20* con la ayuda de un gel conductor que reduzca la impedancia del cráneo. Posteriormente, se amplificará y se digitalizará con una frecuencia de muestreo adecuada. De acuerdo al teorema de Nyquist debe ser mayor o igual que el doble de la frecuencia máxima de la banda que deseemos analizar.

A continuación, la señal debe ser filtrada para eliminar los artefactos que pueda contener. En la señal EEG se distinguen tres artefactos principales que son capaces de degradar la señal, siendo éstos el movimiento ocular (EOG) y pestañeos, la actividad de músculos cercanos y la actividad cardiaca (ECG) [2].

- **Movimiento ocular y pestañeos.** La actividad eléctrica producida por el movimiento ocular, o EOG, es claramente visible en la señal EEG debido a su gran intensidad. El EOG refleja la diferencia de potencial que varía durante el movimiento ocular entre la córnea y la retina, cuya amplitud se comporta de manera proporcional al ángulo de visión. La intensidad de esta señal depende de la proximidad del electrodo y, por esta razón, este artefacto molesta más en los electrodos situados en la zona frontopolar del córtex, efecto que puede observarse en la Figura 2-12. Este artefacto no solo está presente en el estado de vigilia, sino que aparece también cuando el sujeto duerme, concretamente cuando entra en fase REM. El pestañeo también produce una actividad molesta, de mayor frecuencia que el movimiento ocular y con cambios más abruptos.

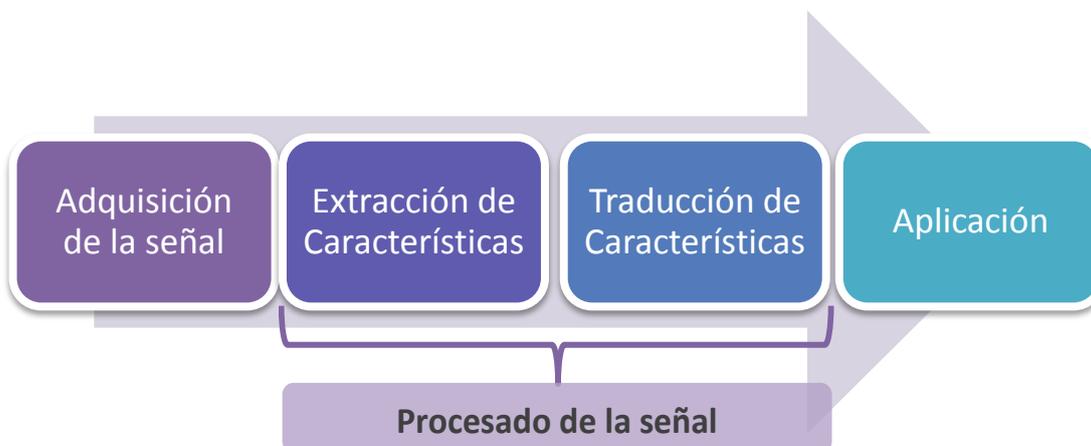


Figura 2-11. Etapas en las que se divide el tratamiento de la señal EEG: adquisición de la señal, procesamiento de la señal (extracción y traducción de características) y aplicación.

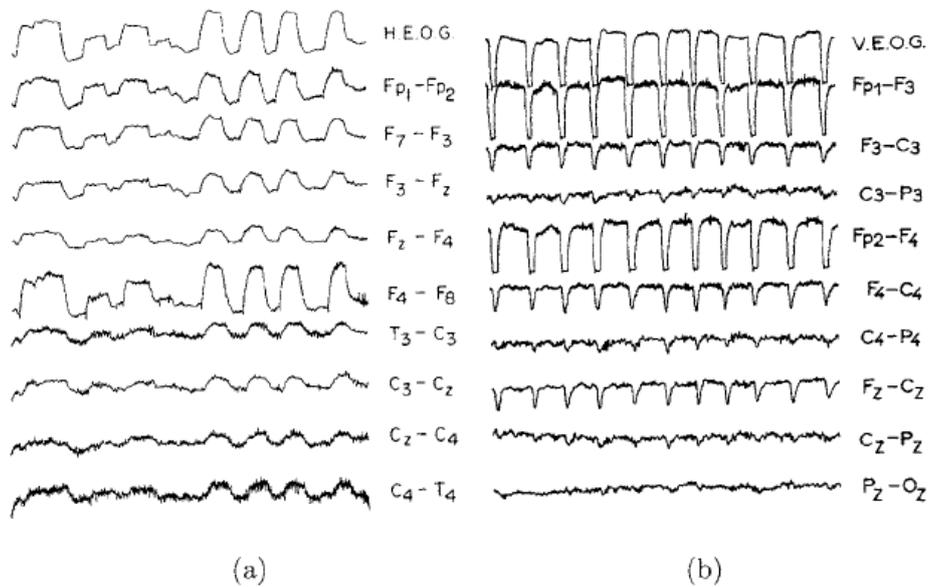


Figura 2-12. Artefactos en la señal EEG causados por (a) el movimiento ocular y (b) pestañeos repetitivos y voluntarios.

En términos de procesamiento, el artefacto causado por el movimiento de los ojos se puede reducir obteniendo una señal de referencia en la que solamente aparezca la molestia, colocando electrodos cerca de los ojos. De esta manera se podría eliminar el artefacto, por ejemplo, con un filtrado adaptativo.

- **Actividad muscular cercana.** Otro artefacto común lo causa la actividad eléctrica muscular, sobre todo, de músculos cercanos. Esta actividad se encuentra normalmente cuando el sujeto está en estado de vigilia y se encuentra tragando, haciendo muecas, ciñendo el cejo, masticando, hablando, o en resumen, realizando cualquier actividad que implique mover los músculos faciales o la mandíbula. Este artefacto se reduce drásticamente cuando el sujeto se encuentra relajado o dormido. El efecto que produce depende de la fuerza de la contracción muscular, pudiendo generar irregularidades de baja amplitud si la contracción es débil o altas irregularidades que se asemejan a ruido blanco cuando la contracción es fuerte. Este artefacto puede observarse en la Figura 2-13.

En términos de procesamiento, la actividad muscular es un artefacto mucho más molesto que el movimiento ocular, puesto que solapa la *banda β* dentro del rango entre 15 y 30Hz. Esta desventaja está agravada por el hecho de que es imposible adquirir una señal de referencia que solamente contenga la actividad muscular interferente, a diferencia del EOG.

- **Actividad cardiaca.** El ECG puede llegar a interferir con la señal EEG en algunas personas. Aunque la amplitud del ECG normalmente es baja en el cráneo en comparación con el EEG, puede aparecer en determinados electrodos y en determinados cuerpos, por ejemplo, en personas bajas con cuellos cortos. Debido a la naturaleza repetitiva y regular que caracteriza al ECG, la eliminación del mismo resulta sencilla.

Para finalizar esta etapa, aunque la aplicación a desarrollar se realiza en tiempo real, se puede almacenar el registro para poder realizar un posible análisis *offline*.

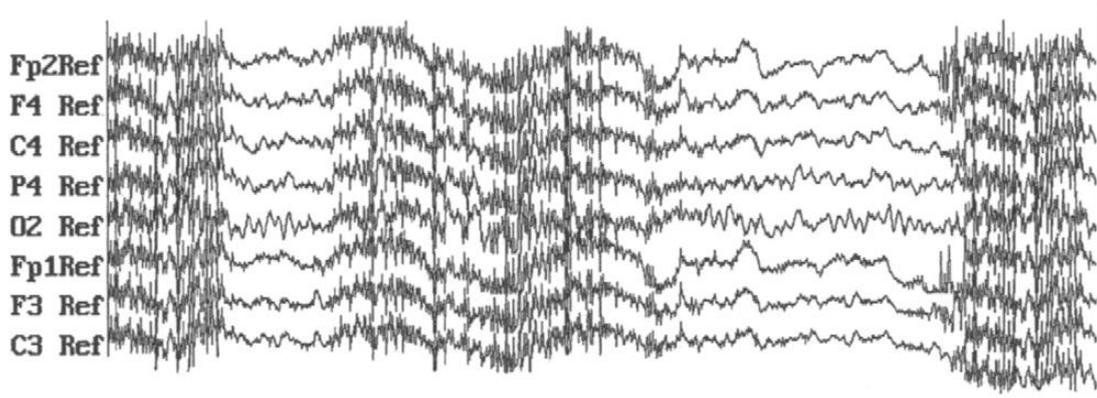


Figura 2-13. Registro de 5 segundos de duración de la señal EEG contaminada por episodios intermitentes de artefactos electromiográficos (EMG).

2.4.2. Procesado de la señal

La segunda etapa es el procesado de la señal, a su vez subdividido en la extracción de características y la traducción de las mismas.

a) Extracción de características

La etapa de extracción de características se basa en obtener información que sea capaz de discriminar o identificar la señal EEG. Esta información se denomina característica y será lo que permita diferenciar entre distintas patologías o intenciones del usuario una vez sea analizada.

Aparte de los artefactos ya mencionados, existen otros factores que pueden afectar a las características de la señal del usuario. Entre ellos se encuentran la motivación, la intención, la frustración, la fatiga, etcétera. El buen funcionamiento del sistema BCI depende de la adaptabilidad del sistema al usuario así como de la selección de las técnicas de procesado de señal adecuadas [5].

Aunque en otros tipos de sistemas que tratan también las señales biomédicas la cancelación de artefactos y la extracción de características están totalmente diferenciadas, en los sistemas BCI muchos autores clasifican técnicas que se pueden emplear para cancelación de artefactos como técnicas de extracción de características debido a que su salida usualmente se convierte en la entrada del clasificador. En la Tabla 2-1 se muestran una serie de técnicas de extracción de características empleadas con anterioridad en los sistemas BCI [20].

Los principales métodos se dividen en dos grandes grupos: los que trabajan con señales en tiempo o frecuencia y los que trabajan con señales en el espacio. Lo más común es aplicar un método de cada tipo indistintamente del orden en el que se apliquen, tratando las dimensiones de manera independiente, o emplear un solo método espacio-temporal.

Dentro de los métodos que trabajan en el dominio temporal y frecuencial destacan los métodos temporales a causa de su rapidez y el reducido coste computacional que requieren. Estos métodos suelen utilizarse en aplicaciones BCI a tiempo real y la elección de los mismos depende en gran parte de la señal de control utilizada y de los artefactos que la degraden. Por ejemplo, un simple promediado sincronizado aumenta de manera significativa la capacidad de detección de los

TABLA 2-1. CLASIFICACIÓN DE LOS MÉTODOS MÁS EMPLEADOS EN LA EXTRACCIÓN DE CARACTERÍSTICAS.

Tiempo-Frecuencia	Espacio	Tiempo-Espacio	Modelos Inversos
Transformada de Fourier	Filtro Laplaciano	Análisis en Componentes de Tiempo y Espacio	EEG a ECoG
Transformada Wavelet			
Modelos Autorregresivos (AR)	Análisis de Componentes Independientes (ICA)		
Filtrado Paso-Banda	Patrones Espaciales Comunes (CSP)		
Filtro Adaptado	Amplitudes	Coherencia	
Filtro de Kalman	Proporciones y Diferencias		
Detección de Pico			

potenciales evocados P300. Sin embargo, los métodos que operan en el dominio frecuencial requieren una transformación de la señal, convirtiéndose así en métodos que requieren más coste computacional que los temporales. De esta manera, para aplicaciones a tiempo real interesan aquellos métodos espectrales que operan con segmentos de la señal relativamente cortos.

Los métodos espaciales también dependen de la señal de control que utiliza el sistema y, concretamente, de lo localizada que esté su fuente en la corteza cerebral. Por consiguiente, el método más adecuado para detectar los ritmos μ y β , que se encuentran bastante localizados en el córtex, no será el mismo que para detectar los potenciales SCP o los P300, que se encuentran más distribuidos a lo largo del mismo.

Una medida útil para realizar un análisis *offline* de los métodos espaciales es el coeficiente de determinación o r^2 , que básicamente consiste en la correlación de los datos elevada al cuadrado. En la Figura 2-14 se muestra el resultado de este coeficiente para intentar detectar los ritmos μ y β sobre el electrodo C3 empleando cuatro métodos espaciales diferentes, siendo éstos el filtro Laplaciano con dos distancias distintas de separación de los electrodos, el método de referencia de media común (CAR) y el uso del electrodo C3 con una única referencia en la oreja. Tal y como se puede observar, el filtro Laplaciano con una distancia entre electrodos de 6 cm o el filtrado CAR proporcionan mejores resultados que los otros dos métodos analizados [5].

Además de los cuatro métodos espaciales comparados, es frecuente en los sistemas BCI utilizar PCA (*Principal Component Analysis*, Análisis de Componentes Principales) o ICA (*Independent Component Analysis*, Análisis de Componentes Independientes), útiles para realizar una combinación lineal de varios canales y seleccionar la información más relevante. Por esta razón también son conocidos como métodos de reducción de dimensionalidad.

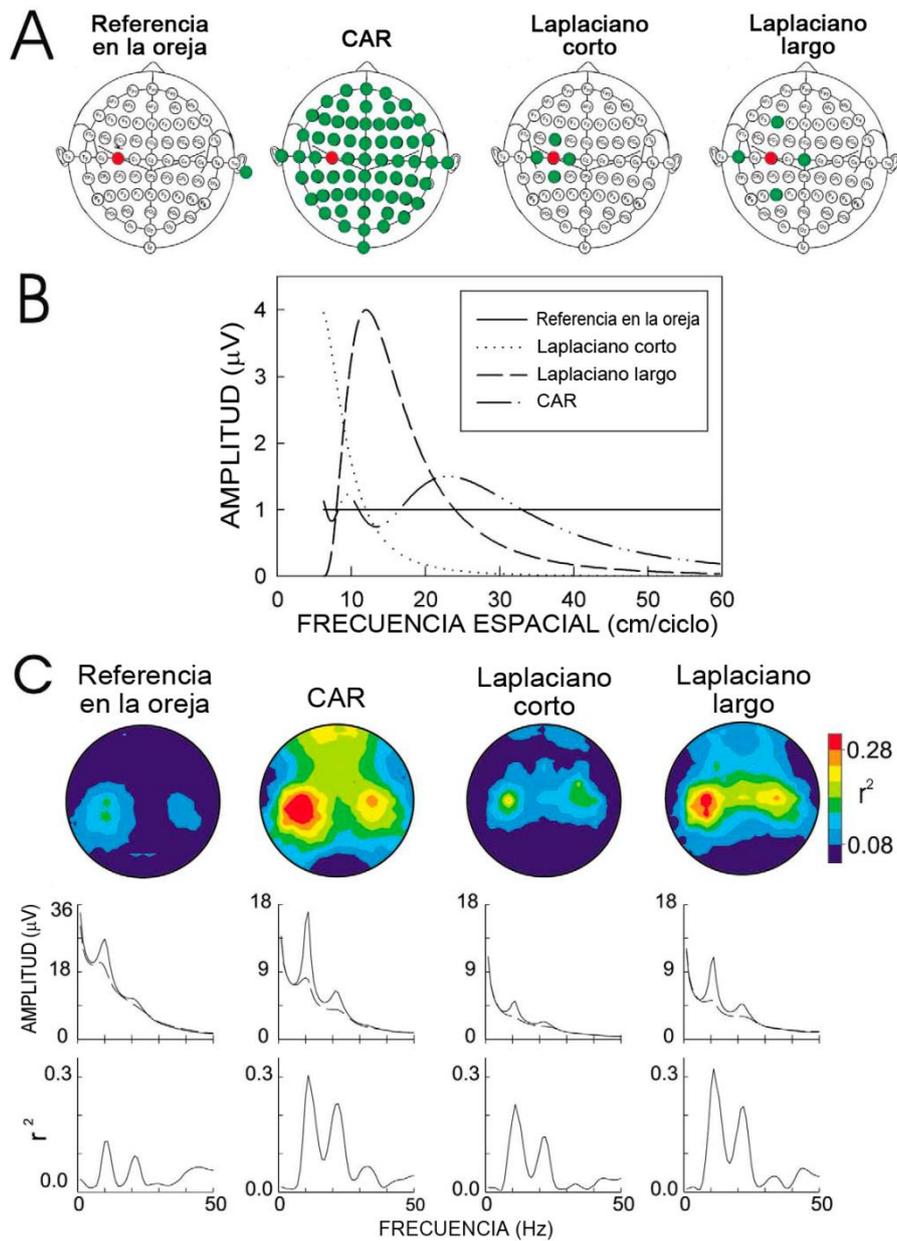


Figura 2-14. Comparación entre cuatro métodos espaciales de extracción de características. (A) Localización de los electrodos utilizados con la señal objetivo en rojo, concretamente, se quiere medir la señal del electrodo C3. (B) Banda de paso para cada método, raíz cuadrada de los valores cuadráticos medios de la señal recogida en C3. (C) Topografía de r^2 medida y amplitud espectral para cada método estudiado [5].

b) Traducción de características

La etapa de traducción de características, o algoritmo de clasificación, se encarga de convertir las características extraídas anteriormente en comandos de un dispositivo. Para ello, clasificará las características obtenidas en función de diversos parámetros y las asociará con un comando determinado [5]. El objetivo es asegurar que la selección atribuida se corresponda con la selección que el usuario pretendía realizar.

Los clasificadores se pueden dividir en dos grupos: clasificadores lineales y no lineales. En la Tabla 2-2 aparecen los clasificadores más usados en los sistemas BCI para ambos grupos.

TABLA 2-2. CLASIFICACIÓN DE LOS MÉTODOS MÁS EMPLEADOS EN LA TRADUCCIÓN DE CARACTERÍSTICAS.

Lineales	No Lineales			
	Estructura Fija	Estructura Modificable		
		Basados en Memoria	Combinaciones de No Linealidades Simples	Modelos Generativos
Análisis Discriminante Lineal (LDA)	Análisis Cuadrático Discriminante (QDA)	Algoritmo del vecino más próximo	Redes Neuronales Artificiales (ANN)	Modelo de Mezclas Gaussianas
Perceptrón		Máquinas de Soporte Vectorial (SVM)	Árbol de Decisión	Modelo Oculito de Markov (HMM)
Regresión, regularización y adaptación		Regresión de Mínimos Cuadrados Parciales (PLS Regression)	Aprendizaje por Cuantificación Vectorial (LVQ)	

Los métodos lineales asumen que los datos pueden separarse linealmente a través de un hiperplano de separación, el cual divide el espacio de datos en varias regiones, cada una correspondiente a una selección distinta. Este hiperplano de separación se coloca de tal manera que minimice el margen mínimo (distancia mínima entre cada punto y el hiperplano) o el margen medio [21]. En la Figura 2-15 se puede observar un clasificador lineal que maximiza el margen mínimo.

Pese a que los métodos lineales suelen ser más robustos que los no lineales y suelen requerir menor carga computacional, también pueden fallar en presencia de ruido u *outliers*, valores atípicos que provocan datos numéricamente distantes del resto, frecuentemente engañosos. En la Figura 2-15 (b) se observa cómo la presencia de *outliers* puede cambiar la localización del hiperplano de separación si la influencia de valores atípicos no está limitada. Se recomienda aplicar una regulación de los datos para limitar su influencia antes de aplicar el clasificador para obtener un hiperplano más fiable.

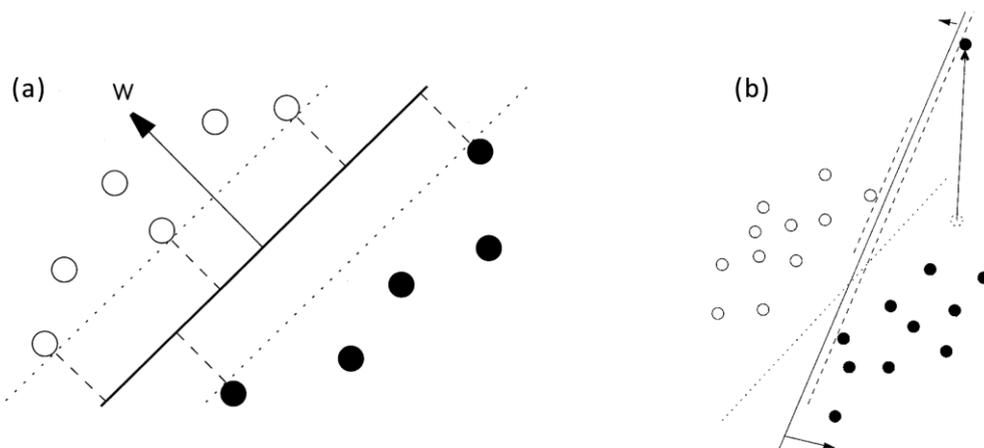


Figura 2-15. Clasificador lineal que maximiza el margen mínimo: en (a) se muestra el comportamiento óptimo y en (b) su comportamiento en presencia de un *outlier*.

Los métodos no lineales son capaces de obtener precisiones mayores al tener en cuenta un mayor número de parámetros que los métodos lineales a cambio de requerir un mayor coste computacional [21].

En el estudio de Fabiani *et al* [22] se comparan tres métodos de traducción de características para diferenciar entre tres clases de datos: opción superior, inferior y central. El resultado puede observarse gráficamente en la Figura 2-16. Los dos primeros clasificadores son lineales: K1 y K2. Sin embargo, K1 solamente emplea una dimensión, mientras que K2 emplea dos dimensiones. El clasificador K3 se corresponde con una función no lineal de K1. Tal y como se puede observar se aprecia una mejora significativa en los resultados de los clasificadores K2 y K3. Esto se debe principalmente a que K1 consiste en dos hiperplanos de decisión paralelos, por lo que impone una fuerte restricción en la clasificación de los datos.

Generalmente se prefiere la simplicidad de los métodos lineales. Los métodos de clasificación no lineales son preferibles en el caso de que el número de muestras sea pequeño y la información sobre los datos sea limitada [21].

Adicionalmente, la etapa de traducción de características también debe considerar la adaptabilidad al usuario [5]. Los clasificadores óptimos varían entre usuarios, es decir, el clasificador óptimo para un usuario normalmente no será el mismo que el clasificador óptimo para otro usuario distinto y, debido a esto, el sistema BCI debe cumplir una serie de requisitos repartidos en tres niveles.

El primer nivel requiere adaptar las características de las señales a cada usuario, puesto que habrá diferencias significativas entre un usuario y otro, por ejemplo, la amplitud de los potenciales SCP o P300. El segundo nivel requiere adaptar el clasificador a las fluctuaciones que pueden sufrir las características obtenidas debido a variaciones entre la motivación, la fatiga o la frustración, entre otros, del usuario dependiendo de la sesión. Finalmente, el tercer nivel requiere mantener la precisión del clasificador a largo plazo, siendo capaz de detectar disminuciones en los niveles de atención del usuario, responder ante ellos y ofrecer una realimentación que lo motive para los próximos intentos.

El tercer nivel está fuertemente ligado al fenómeno de aprendizaje de los clasificadores. Existen una serie de clasificadores, habitualmente no lineales, que son capaces de “aprender” las características de la señal de cada usuario y adaptarse a ellas gracias a una serie de datos de entrenamiento. Entre ellos se encuentran las máquinas de soporte vectorial (SVM, *Support Vector Machines*) o las redes neuronales artificiales (ANN, *Artificial Neural Networks*), caracterizados por ser algoritmos muy rápidos una vez están entrenados, y adecuados para aplicaciones en tiempo-real.

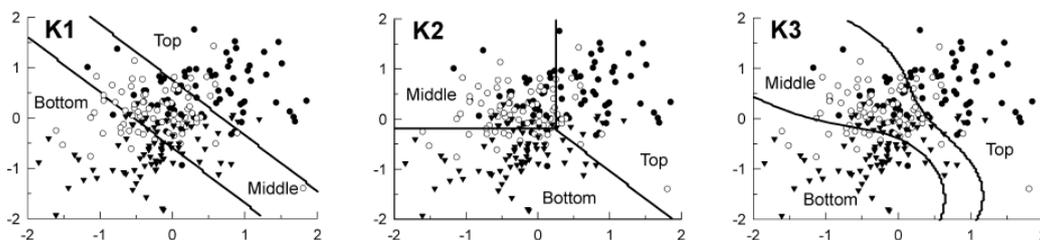


Figura 2-16. Comparación de los hiperplanos de separación para los tres métodos de traducción de características: K1 es un método lineal de una dimensión, K2 es un método lineal de dos dimensiones y K3 es un método no lineal.

2.4.3. Aplicación

La tercera y última etapa del tratamiento de la señal es la etapa de aplicación, la cual se encargará de recibir la señal de control producida por la traducción de características y de implementar un *software* que traduzca ésta señal en comandos que realicen las acciones correspondientes. En la siguiente sección se detallarán las aplicaciones más comunes de los sistemas BCI.

2.5. Aplicaciones de los sistemas BCI

Existen multitud de aplicaciones prácticas desarrolladas con sistemas BCI. A continuación se exponen las aplicaciones más básicas que utilizan las señales de control mencionadas anteriormente, como son la selección de letras, el movimiento de un cursor o el desplazamiento sobre un mapa.

2.5.1. Selección de letras

La aplicación de selección de letras es, probablemente, la más utilizada en los sistemas BCI. Un sinnúmero de aplicaciones más complejas utilizan técnicas de selección de letras, números o comandos para implementar alguna funcionalidad, ya sea con potenciales evocados P300, potenciales VEP o potenciales SCP.

a) Potenciales evocados P300

Las aplicaciones de selección de letras, de aquí en adelante conocidas como *P3Speller*, números o comandos con potenciales evocados P300 se basan en la técnica *odd-ball* descrita anteriormente. Se presenta al usuario una matriz de, por ejemplo, 6x6 letras y números. Cada cierto tiempo, del orden de milisegundos, se ilumina una fila o columna de forma que tras una ronda de un determinado número de iluminaciones cada fila y columna se han iluminado una vez y, por lo tanto, cada letra se ha iluminado dos veces.

Cada vez que se ilumina la letra que el usuario quiere seleccionar, éste provoca la aparición de dos potenciales evocados P300. El número de intentos que serán necesarios para obtener buenas precisiones lo determinará el clasificador que se haya generado para cada usuario y la experiencia del mismo con estos sistemas. Normalmente 10 intentos son suficientes para obtener una buena precisión en sujetos de control [5].

b) Potenciales Evocados Visuales

A continuación se introduce una manera de seleccionar letras para mejorar la comunicación de personas con graves discapacidades utilizando como señal de control los potenciales VEP.

La interfaz de la aplicación presenta una matriz de letras, cuyas celdas se iluminan continuamente a distintas frecuencias. El usuario debe mirar fijamente a la celda que contiene la letra que desea escribir, generando un fenómeno de resonancia a la misma frecuencia a la que se ilumina la letra a seleccionar. El sistema identifica los picos frecuenciales de ésta y sus armónicos y determina hacia dónde está mirando el usuario. Si la matriz es demasiado grande como para utilizar todas las frecuencias indistintamente, se pueden iluminar aleatoriamente subgrupos de letras hasta que cada una de ellas se haya iluminado a una frecuencia diferente [5].

El utilizar una señal de control exógena tiene la ventaja de no requerir entrenamiento alguno. Sin embargo, sí es necesaria la capacidad de mantener la mirada fija en un punto.

c) Potenciales Corticales Lentos

Dado que utilizando únicamente los potenciales SCP solamente pueden realizarse selecciones binarias, la selección de letras se lleva a cabo dividiendo sucesivamente el alfabeto en dos partes: primero se elige una mitad, luego un cuarto, etcétera.

Teniendo en cuenta que los potenciales corticales lentos se clasifican dentro de las señales de control endógenas, el usuario necesitará entrenamiento para poder seleccionar las letras adecuadamente. En la Figura 2-17 se puede observar la solución de Bensch *et al* [23].

2.5.2. Movimiento de un cursor

El objetivo de esta aplicación será el de aprovechar el control de movimiento de un cursor para seleccionar botones, navegar por menús o moverse dentro de algún videojuego.

a) Potenciales Corticales Lentos

Una aplicación utilizando potenciales corticales lentos se basa en mostrar por pantalla un cursor que se desplace horizontalmente a velocidad constante. El usuario debe controlar el movimiento vertical con los potenciales corticales lentos y así seleccionar una de las dos opciones posibles. Este procedimiento puede observarse en la Figura 2-18.

b) Ritmos Sensoriomotores μ y β

A diferencia de los cursores controlados mediante potenciales corticales lentos, los ritmos sensoriomotores μ y β pueden llegar a controlar un cursor en dos dimensiones con el suficiente entrenamiento. De esta manera, se pueden controlar menús complejos, aplicarse al control de prótesis, al movimiento de sillas de ruedas o el movimiento en videojuegos, tal y como se muestra en la Figura 2-19 [24].

2.5.3. Desplazamiento sobre un mapa

Esta aplicación se puede ver como una extensión de la anterior. El usuario se coloca frente a una pantalla en la que se muestra un mapa por satélite junto a cuatro botones que controlan el movimiento vertical y horizontal.

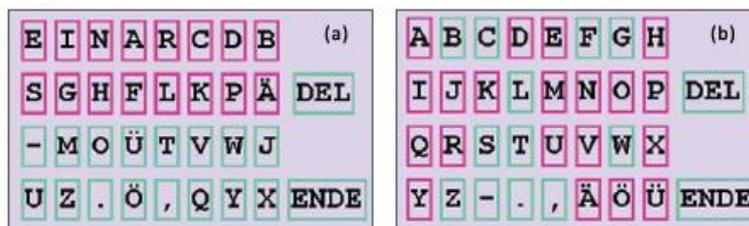


Figura 2-17. Selección de letras utilizando potenciales corticales lentos (SCP) con selecciones binarias: mitad de las mismas en magenta y la otra mitad en azul [23].

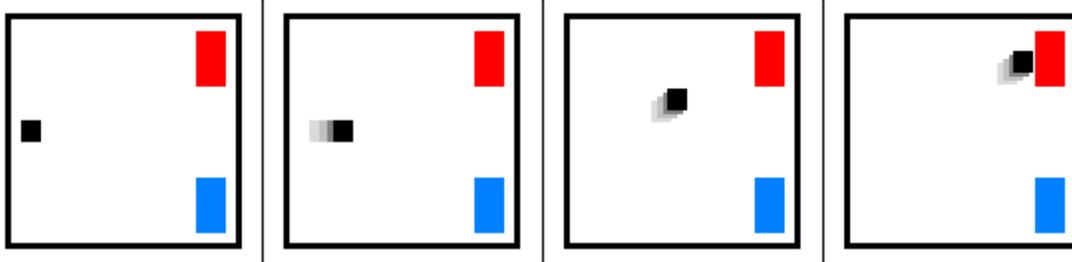


Figura 2-18. Control del movimiento de un cursor verticalmente mediante potenciales corticales lentos para seleccionar entre dos opciones.

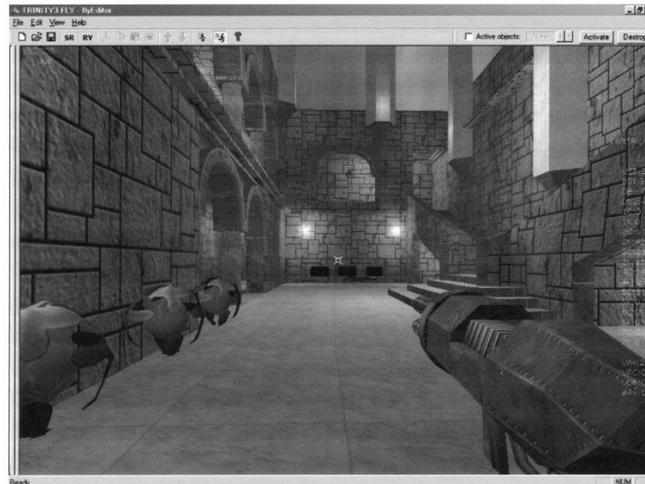


Figura 2-19. Control del movimiento en videojuegos mediante ritmos sensoriomotores μ y β [24].

En el trabajo de Trejo *et al* [25] se desarrolla este sistema, bautizado como *Think Pointer BCI System* (o sistema de puntero dirigido por el pensamiento) empleando potenciales VEP. Cada botón se ilumina a una frecuencia distinta y el usuario mira fijamente al que quiere seleccionar, controlando así el desplazamiento sobre el mapa. Midiendo la frecuencia en la que aparecen los VEP del usuario, se determina la dirección seleccionada. En la Figura 2-20 aparece la pantalla que se muestra al usuario.

Una aplicación similar podría controlarse mediante los ritmos μ y β , controlando el desplazamiento en dos dimensiones, tal y como se ha utilizado anteriormente en el control del movimiento de un cursor.



Figura 2-20. Control del desplazamiento sobre un mapa con potenciales evocados visuales [25].

2.6. Navegadores Web BCI

Una vez vistas las aplicaciones más sencillas en las que se basan los sistemas BCI es hora de introducir una revisión del estado del arte sobre los navegadores web desarrollados con anterioridad. La decisión de cómo implementar la aplicación a desarrollar en el presente Trabajo Fin de Máster se basa en la comparativa que se muestra a continuación. En esta comparativa se estudian cinco artículos distintos, atendiendo a las señales de control que utilizan y a las funcionalidades que implementan.

2.6.1. Bensch *et al* — “Nessi: An EEG-Controlled Web Browser for Severely Paralyzed Patients” [23]

El primer artículo a tratar se centra en mejorar el primer navegador web creado mediante BCI, bautizado como Descartes, utilizando potenciales SCP como señal de control.

Nessi (*Neuronal Signal Surfing Interface*), el navegador web implementado como mejora de Descartes, funciona a través de selecciones binarias controladas por potenciales SCP. Los potenciales corticales lentos se corresponden a cambios de voltaje, entre 0,5 y 10s de duración, generados en el córtex a bajas frecuencias tras seleccionar una opción binaria (aumento o reducción de la activación cortical) [5].

La interfaz se compone del navegador en la parte derecha de la pantalla y la selección binaria en la parte izquierda. Ésta distingue entre dos objetivos: el magenta y el azul; y se ofrece una realimentación al usuario en forma de círculo amarillo para que el control sea más intuitivo. El usuario seleccionará el objetivo magenta desplazando el círculo amarillo hacia la parte superior y seleccionará el objetivo azul desplazando el círculo amarillo hacia la parte inferior, tal y como se observa en la Figura 2-21 (a).

Todos los hipervínculos de la página web que se esté visualizando estarán rodeados por rectángulos magentas o azules. El usuario deberá elegir el color que corresponda al hipervínculo que desea seleccionar y, tras sucesivas selecciones, se habrán descartado todos los hipervínculos no deseados. Para facilitar la selección de los hipervínculos todos aquellos que apunten a la misma URL se agruparán.

Una vez se ha seleccionado una página, el usuario tiene un tiempo de lectura predeterminado por el supervisor. Durante este tiempo se desactiva el control de selección y la realimentación. Si el usuario se confunde de selección, podrá corregir su error. No obstante, si una web carece de hipervínculos, el navegador volverá a la página anterior una vez haya terminado el tiempo de lectura. Con respecto a la estructura de la página inicial, se ofrece una lista de las URLs más usadas por el usuario, es decir, una lista de marcadores.

A la hora de introducir caracteres en algún formulario web, aparecerá un teclado virtual controlado también por potenciales SCP. El color del marco rectangular de cada carácter no es aleatorio, sino que puede estar basado en distintas codificaciones, entre ellas *Huffman-Coded* o *LSP* (se ha demostrado que los mejores resultados los proporciona la codificación *LSP*). En la Figura 2-21 (b) se observan los posibles teclados virtuales que implementa la aplicación.

Adicionalmente, se ha diseñado una interfaz para leer y escribir e-mails. La pantalla se divide en varias partes, cada una de ellas con una función distinta: mostrar los e-mails, leer un e-mail y escribir un e-mail. Las direcciones estarán contenidas en un *Address Book* que tendrá que crear el supervisor.

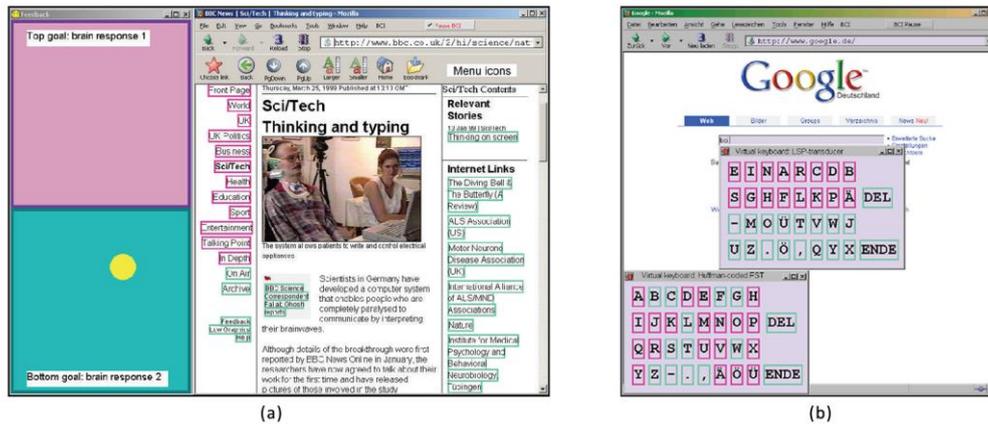


Figura 2-21. Interfaz gráfica de *Nessi*, el primer navegador basado en potenciales SCP. En (a) se muestra la interfaz de selección binaria y la realimentación al usuario, mientras que en (b) aparecen las distintas codificaciones del teclado virtual [23].

Nessi fue evaluado por cuatro pacientes con ELA (*Amyotrophic Lateral Sclerosis*, o Esclerosis Lateral Amiotrófica) y dos personas sanas, sin embargo, no hay resultados publicados.

2.6.2. Mugler *et al* — “Design and Implementation of a P300-Based Brain-Computer Interface for Controlling an Internet Browser” [26]

A diferencia de las publicaciones anteriores, en este artículo se desarrolla un nuevo navegador web controlado por potenciales evocados P300. El objetivo es asegurar un verdadero acceso a Internet para los pacientes, los cuales podrán visitar cualquier página accesible para los navegadores habituales.

Gracias al código abierto de Mozilla Firefox y sus *add-ons*, el navegador desarrollado es capaz de navegar por cualquier web, introducir URLs y manejar la barra de desplazamiento (*scroll up & down*).

Los hipervínculos se etiquetan con uno o dos caracteres y se seleccionan introduciéndolos con la técnica de selección de letras explicada anteriormente. De esta manera, la búsqueda del hipervínculo deseado es mucho más rápida que con un sistema de selección binaria. Para introducir los caracteres se usa la técnica *odd-ball*, mostrando una matriz de caracteres cuyas filas y columnas se iluminan aleatoriamente. El usuario debe prestar atención al carácter que le gustaría seleccionar y, en consecuencia, se generan dos potenciales P300, uno cuando se ilumina la columna que lo contiene y otro cuando se ilumina la fila [5]. La matriz utilizada se puede observar en la Figura 2-22.

Se introducen pausas de 5s de manera predeterminada para evitar los distintos tiempos de carga de las páginas web. En consecuencia, no se podrá realizar ninguna acción hasta que hayan finalizado. También se incluye un modo lectura que deshabilita todos los comandos exceptuando el movimiento de la barra de desplazamiento. Si el usuario introduce un comando incorrectamente puede corregirlo utilizando la opción de *back* (si seleccionó un link no deseado), *reload* (si se introdujo una letra incorrecta en el filtro) o *delete* (para errores tipográficos).

Este sistema fue probado con 10 personas sanas y 3 pacientes con ELA. En cada sesión se ordenó a los pacientes realizar una serie de tareas, tales como buscar términos en la *Wikipedia*, buscar información sobre la universidad local o comprar un libro específico por Internet.



Figura 2-22. Matriz utilizada para provocar los potenciales evocados P300 en el navegador web desarrollado por Mugler *et al* [26].

Las sesiones dedicadas a los participantes con ELA fueron interrumpidas en varios intervalos de tiempo por problemas respiratorios, excesiva generación de saliva, etcétera. Las personas sanas manejaron el navegador web desarrollado con una precisión del 90%, mientras que los pacientes con ELA lo hicieron con una precisión del 72% [26]. Consecuentemente, es evidente que la neurodegeneración en el área motora puede provocar una gran reducción de atención y un movimiento ocular mucho más lento que el de una persona sana.

2.6.3. Sirvent Blaco *et al* — “Visual Evoked Potential-Based Brain-Machine Interface Applications to Assist Disabled People” [27]

En este artículo se desarrollan tres aplicaciones orientadas a personas discapacitadas basadas en los potenciales evocados P300 y N2PC. La primera aplicación es un navegador web, la segunda un control de una mano robótica y la tercera es una herramienta de comunicación básica. Este informe se centrará en la aplicación de interés, es decir, el navegador web.

Este sistema pretende aumentar el rendimiento del navegador tratando de precisar más la detección de los potenciales evocados teniendo en cuenta no solo los potenciales P300, sino también los N2PC. El estímulo que produjo los potenciales P300 y N2PC se generó con la tradicional técnica *odd-ball*. Se ilumina una matriz de selección aleatoriamente y los usuarios generan involuntariamente los potenciales al ver iluminada la celda que quieren seleccionar, además, cuanto menor sea la probabilidad del evento mayor serán los potenciales evocados [5].

La señal P300 se corresponde con una deflexión positiva de la señal EEG unos 300ms después del estímulo. Para detectar los potenciales P300 se realizó un filtrado espacial y como consecuencia se utilizaron los electrodos Cz, Fz, Pz y cercanos (e.g C3 y C4). El segundo tipo de potencial evocado que interesa es el N2PC, el cual se corresponde a una deflexión negativa de la señal EEG en torno a unos 200ms después del estímulo. La “N” denota una polaridad negativa, el “2” su la latencia a los 200ms, “P” viene de posterior o parietal y “C” de contralateral al movimiento. Para detectar correctamente este potencial se ubicaron los electrodos en Po4, Po3 y cercanos (e.g P3, P4, PO1 y PO3).

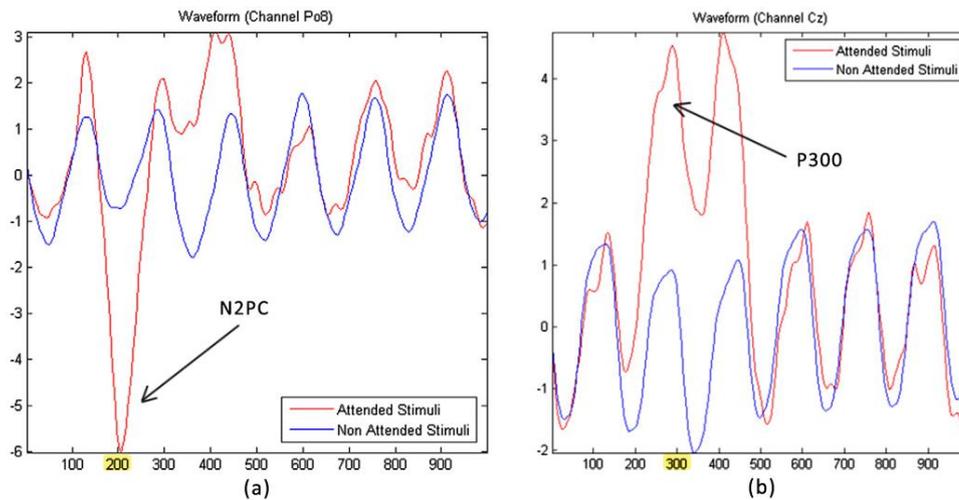


Figura 2-23. Potenciales recogidos en el estudio de Sirvent Blasco *et al* [27]. En (a) se muestra el potencial evocado N2PC, producido unos 200ms después del estímulo y recogido sobre el electrodo PO8 (zona parietal-occipital). En (b) se muestra el potencial evocado P300, producido unos 300ms después del estímulo y recogido sobre el electrodo Cz.

Con el fin de detectar los potenciales evocados con la mejor resolución posible, se compararon la señal obtenida en cada electrodo cuando no se atendía al estímulo y la señal obtenida cuando sí se atendía al mismo, ilustrado en la Figura 2-23.

Para la detección y el tratamiento de las señales EEG se usaron 16 electrodos conectados a un amplificador de 16 canales. Como resultado, la mayor diferencia entre las señales se produjo en la zona parietal/occipital del córtex y se concluyó que la contribución de los potenciales N2PC es más fuerte que la de los potenciales P300.

Las señales se digitalizaron con una frecuencia de muestreo de 256Hz y 8 bits por muestra. Se aplicó un filtro paso banda y un filtro de ranura (filtro elimina-banda muy estrecho en 50 o 60 Hz) para evitar interferencias electromagnéticas con la red eléctrica. Adicionalmente, se aplicó un filtro temporal que consideró solamente los primeros 600ms posteriores a cada estímulo con el fin de evitar patrones repetitivos y artefactos.

Posteriormente, se diezmaron las señales a 20Hz y se obtuvieron 192 muestras, de las cuales se seleccionaron las 60 más significativas, consiguiendo una media de 4 muestras por canal. Para el proceso de traducción de características se utilizó un análisis discriminante lineal paso-a-paso.

La interfaz del navegador se compone de dos partes: la navegación y el control. La ventana de navegación ocupa 2/3 de la parte vertical de la pantalla y el control el 1/3 restante. En la ventana de control pueden aparecer tres matrices implementadas con la técnica *odd-ball* según las intenciones del usuario: el teclado, el ratón y el control de distancia.

El teclado virtual posee una matriz que contiene los caracteres básicos: letras, números y símbolos necesarios para navegar satisfactoriamente. La matriz del ratón contiene las distintas direcciones a tomar, las acciones del mismo (*clicks* derecho e izquierdo, *scrolls*) y el botón del modo lectura. Para terminar, el control de distancia ofrece nueve opciones para establecer la distancia en píxeles que debería recorrer el cursor del ratón hacia la dirección seleccionada. La máquina de estados que gobierna las transiciones entre las tres matrices se muestra en la Figura 2-24.

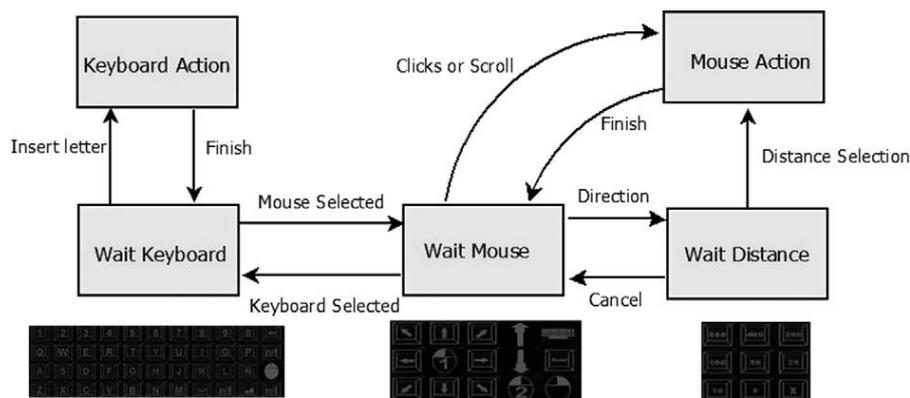


Figura 2-24. Máquina de estados que gobierna las transiciones entre las matrices del navegador web

Inicialmente, el navegador muestra el teclado virtual. A través del mismo se puede acceder a la matriz del ratón. Si la opción seleccionada es la de moverse a través de una dirección determinada, aparecerá a continuación la matriz del control de distancias.

La aplicación se evaluó por parte de cuatro usuarios sanos. Antes de la realización de los experimentos se tuvo que llevar a cabo una sesión de entrenamiento para establecer los coeficientes del clasificador SWLDA de cada usuario. En esta sesión se les ordenó escribir una serie de palabras con el teclado virtual.

En el experimento se ordenó a los usuarios realizar una búsqueda en *Google* para poner a prueba su capacidad de control del movimiento del ratón e introducción de caracteres con el teclado. El tiempo medio en finalizar el experimento fue de 4.20min y la precisión al introducir caracteres con el teclado virtual fue del 93% [27]. También se aprecia que los resultados en el segundo intento fueron significativamente mejores, lo cual indica que los usuarios se adaptan rápidamente al sistema.

Se concluye que los resultados obtenidos teniendo en cuenta ambos potenciales (P300 y N2PC) son mejores que utilizando solamente uno de ellos. No obstante, se ha demostrado que es posible implementar una aplicación utilizando únicamente potenciales N2PC, normalmente ignorados.

2.6.4. Yu *et al* — “Surfing the Internet with a BCI Mouse” [28]

Este artículo se centra en aproximar la navegación web a través de BCI a la navegación web con un ordenador común mediante la implementación de un cursor controlado simultáneamente con potenciales evocados P300 y ritmos sensoriomotores μ y β . También se ha diseñado un filtro capaz de ignorar los hipervínculos no deseados. Gracias a este sistema, los usuarios se desenvuelven rápidamente en un entorno con multitud de hipervínculos filtrando los no deseados y seleccionando el objetivo con el cursor.

La posición del ratón se actualiza cada 200ms y los movimientos verticales y horizontales son independientes entre sí. El movimiento vertical se controla a través de potenciales evocados P300 y el horizontal a través de los ritmos μ y β .

En la interfaz del usuario aparecen ocho botones que se iluminan aleatoriamente, destinados a evocar los potenciales P300. Tres de ellos se encuentran en la parte superior de la pantalla (UP), otros tres de ellos en la parte inferior (DOWN) y dos de ellos en los lados (STOP), los cuales provocan que el cursor suba, baje o pare, respectivamente. En cada actualización del ratón se tiene en cuenta la dirección tomada en la muestra anterior para no interrumpir el movimiento del cursor. El

movimiento vertical solamente podrá interrumpirse cuando el usuario se centre en el botón de *STOP*. La interfaz del usuario se muestra en la Figura 2-25.

Una vez que el usuario ha seleccionado el movimiento vertical del ratón con los potenciales P300 deberá controlar el movimiento horizontal del mismo con los ritmos sensoriomotores, es decir, imaginando el movimiento de su mano derecha o izquierda, según sea la dirección que quiera tomar.

Dado que los botones continúan iluminándose mientras el usuario lee la página web o mientras controla el movimiento horizontal del cursor, se introduce un umbral para la detección de los potenciales evocados P300. Si se supera este umbral indicará que el usuario está prestando atención expresamente a uno de los botones, y en consecuencia se activará la función del botón seleccionado. Sin embargo, si no se supera este umbral se considera que el usuario no está prestando atención al mismo, y no se ejecutará ninguna acción.

A la hora de encontrar un hipervínculo, éste aparecerá en el centro de una caja cuando el cursor pase sobre el mismo. Si el usuario desea seleccionarlo, deberá prestar atención al botón izquierdo de *STOP*. No obstante, si el usuario desea rechazarlo, bastará con seguir controlando los ritmos μ y β imaginando el movimiento de una de las manos, causando que el cursor abandone el hipervínculo.

En numerosas páginas web el número de hipervínculos es extremadamente alto. Para facilitar la navegación a través de todos ellos, se introduce un filtro en la parte superior derecha de la pantalla. Introduciendo unas palabras clave, se filtrarán todos los hipervínculos y solamente podrán seleccionarse aquellos que las contengan. Para introducir estas palabras clave aparecerá una nueva ventana con una matriz de letras y símbolos, *P300-Based Speller*, que se iluminarán aleatoriamente para poder ser controlados a través de potenciales evocados P300, mostrada en la Figura 2-26.

La página inicial se compone de los ocho hipervínculos más usados por el usuario, facilitando así la tarea de introducir URLs comunes a través de la matriz de letras y números y reduciendo el tiempo utilizado en la navegación. Estos hipervínculos aparecen acompañados de una imagen previa de la página web y están lo suficientemente separados entre sí como para que el usuario pueda seleccionarlos rápidamente y tener que rechazar el menor número posible.

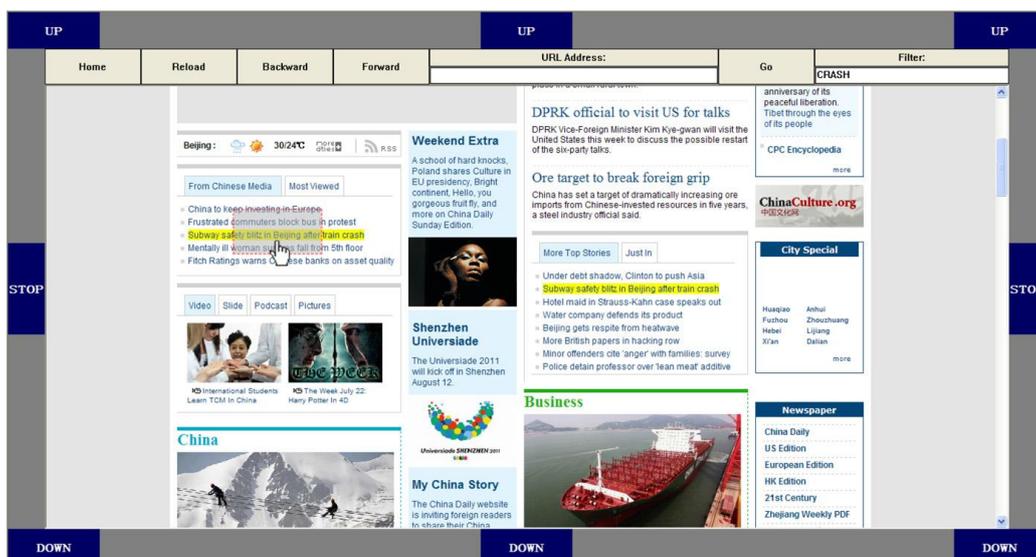


Figura 2-25. Interfaz gráfica del navegador web desarrollado por Yu *et al* [28]. Se puede observar cómo se muestra un rectángulo a medida que el cursor se acerca al hipervínculo.

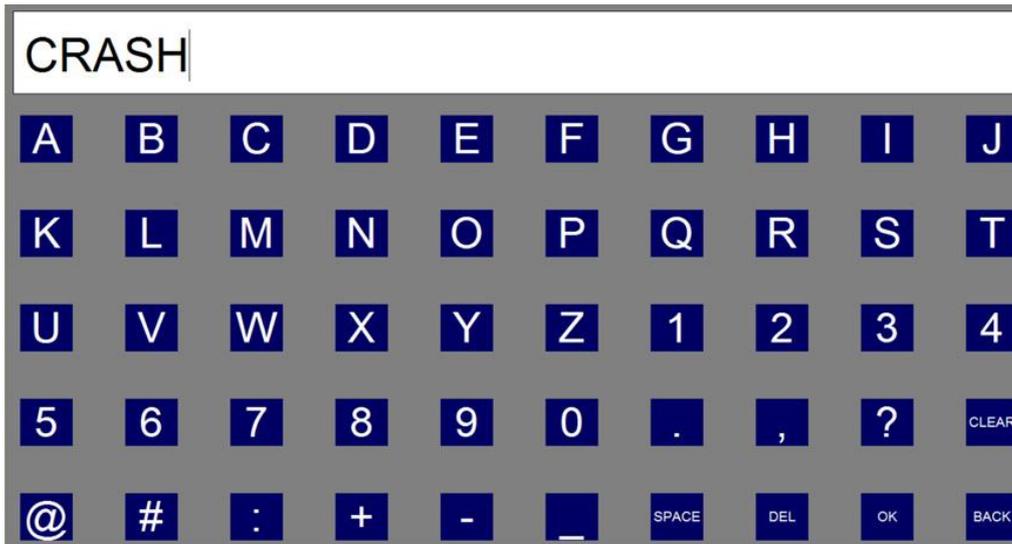


Figura 2-26. Método de selección de letras, números y comandos implementado con potenciales evocados P300 y usado en el navegador de Yu *et al* [28].

Antes de la realización de los experimentos se llevaron a cabo tres sesiones de entrenamiento. La primera de ellas estuvo dedicada a practicar con el *P300-Based Speller*, la segunda estuvo centrada en practicar la detección de los ritmos μ y β imaginando el movimiento de las manos y, como consecuencia, a establecer los parámetros necesarios para una correcta detección y, finalmente, la tercera sesión practicó la selección, o bien el rechazo, de los hipervínculos.

En el primer experimento se mostró al usuario 10 esferas colocadas aleatoriamente en la pantalla. Nueve de ellas eran verdes y solamente una era de color rojo. El usuario tenía que conseguir seleccionar la esfera roja y rechazar todas las esferas verdes que encontrase en el camino. Los resultados, para siete sujetos sanos, muestran que la media de precisión para este experimento de entre todos los usuarios fue un 93,21%, el tiempo medio en cumplir el objetivo fue de 32,71 segundos y el tiempo medio en decidir si se selecciona o rechaza un objetivo fue de 1,25 segundos [28].

En el segundo experimento se ordenó a los usuarios que navegasen a través de una página web y utilizasen el filtro de hipervínculos para seleccionar un vínculo de interés. Para una media de 6.8 caracteres introducidos en el filtro, se tardó una media de 92,26 segundos en utilizar el *P300-Based Speller*. La media de selecciones fue de 3,2 y el tiempo total en terminar el experimento fue de 247,08 segundos (~ 4 min) [28].

Estos resultados dan a entender que el navegador BCI es aceptable para todos los usuarios. Sin embargo, los usuarios demandaron una mejora en la velocidad del sistema.

2.6.5. Liu *et al* — “An Online Brain-Computer Interface Using Non-Flashing Visual Evoked Potentials” [29]

En este estudio se presenta un navegador web controlado por BCI basado en potenciales mVEP (*Motion-onset Visual Evoked Potentials*, o Potenciales Evocados Visuales de Movimiento). Este procedimiento difiere un poco de la técnica tradicional *odd-ball*, donde ciertas matrices de selección se iluminaban aleatoriamente.

Con el fin de reducir la fatiga visual del usuario y aumentar su comodidad, se utiliza una técnica en la que las selecciones no se iluminan constantemente. También destaca como objetivo el utilizar el menor número de canales posibles para detectar la respuesta a los estímulos.

Para empezar, se realiza un análisis *offline* que pretende investigar el patrón espacial para ubicar la señal óptima de los mVEPs, y en consecuencia, minimizar el número de canales necesarios. La interfaz gráfica presentada consta de seis botones virtuales que contienen un cursor vertical, tal y como se muestra en la Figura 2-27.

Este cursor aparece en el borde derecho de cada botón y se desplaza hacia la izquierda para generar el estímulo. El cursor se mueve dentro de cada botón durante 100ms y el intervalo de tiempo entre dos intentos es de 500ms. Teniendo en cuenta que un intento concluye cuando el cursor aparece y desaparece en todos los botones, la duración del mismo será de unos 1100ms. Los usuarios deben fijarse en un botón objetivo durante 15 intentos para obtener un bloque de datos. Con el fin de aumentar la concentración de los usuarios, se pide que cuenten el número de veces que el cursor aparece en el botón deseado.

A continuación se realiza un análisis *online* para evaluar el sistema mVEP y la aplicación web. En la evaluación del sistema se utiliza la misma interfaz gráfica que en el análisis *offline*, sin embargo, esta vez se establece una tarea. Se ordena a los usuarios introducir una secuencia con letras proporcionadas. El usuario recibe una realimentación cuando se haya seleccionado una opción, iluminándose durante 3s.

Con respecto a la aplicación web, el teclado virtual mostrado en la Figura 2-28 aparece cada vez que sea necesario rellenar un formulario. Para reducir la complejidad, la página de *Google* es la versión para móviles. Gracias a esta interfaz del teclado virtual, cada selección se realiza en dos pasos: el primero selecciona el conjunto de 6 caracteres y el segundo se encarga de seleccionar uno de los caracteres del grupo anterior. Adicionalmente, el carácter “<” sirve para retroceder o eliminar un carácter y el “>” permite buscar y seleccionar el hipervínculo deseado.

Para determinar la detección óptima de la señal se utilizaron 30 electrodos y se estableció una ventana en las señales obtenidas entre 100ms y 500ms para seguir el potencial mVEP. También se utilizó un clasificador SVM como algoritmo de traducción. Como resultado, el electrodo P3 consiguió el mayor valor de r^2 en torno a 195ms después del estímulo. Utilizando solamente este canal se obtuvo una precisión del sistema del 84%, sin embargo, utilizando seis canales se mejoró considerablemente el resultado, obteniendo una precisión del 93% [29].

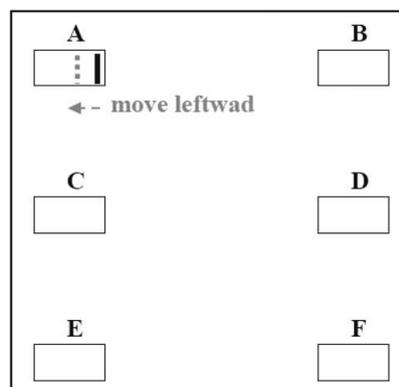


Figura 2-27. Interfaz de usuario para el análisis *offline* en el estudio de Liu *et al* [29] donde se prueba la eficacia de los mVEP.

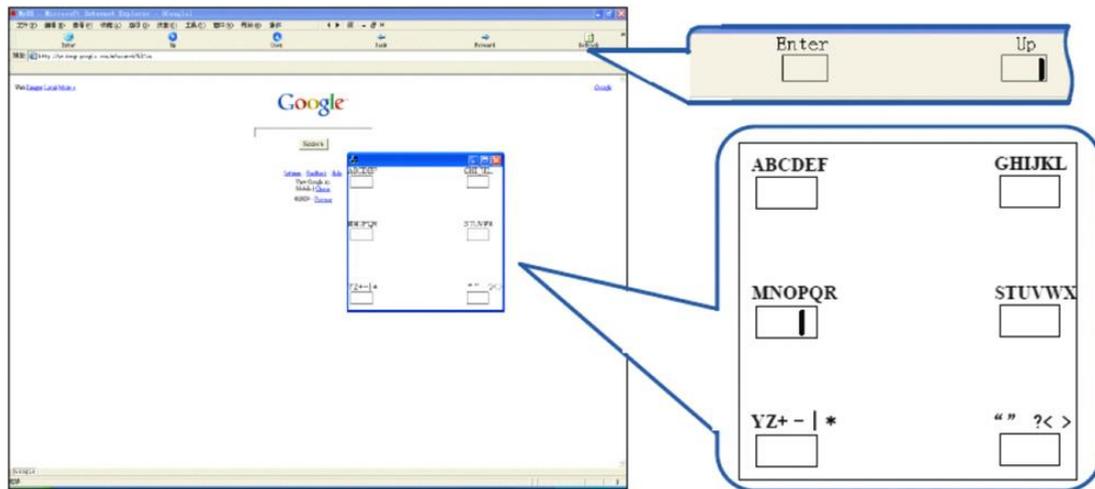


Figura 2-28. Interfaz de usuario para el análisis *online* en el estudio de Liu *et al* [29] donde se estudia el rendimiento de la aplicación web.

Se ha demostrado que el tiempo de entrenamiento necesario para configurar el clasificador utilizando mVEP no sobrepasa los 5 minutos. También se ha detectado que las amplitudes de los potenciales son mayores en la evaluación *online* con respecto a la evaluación *offline*, debido a que en la primera evaluación los usuarios estaban más motivados a cumplir una meta.

La realimentación instantánea ayudó a los usuarios a mejorar su control sobre el sistema, convirtiéndolo en un sistema fácil de manejar. Los doce sujetos sanos fueron capaces de navegar libremente. Dado que este artículo más que presentar un navegador web presenta una técnica innovadora para poder controlar una aplicación libre de fatigas visuales, no se incluirá en la comparativa por falta de información.

2.6.6. Comparativa de los navegadores web

Con el transcurso de los años se han empezado a sustituir los potenciales SCP por los potenciales evocados P300 como señales de control. En los últimos artículos, además de los potenciales evocados P300 también se utilizan los potenciales evocados N2PC, los ritmos sensoriomotores y los potenciales mVEP, lo cual produce grandes mejoras de rendimiento.

Con respecto al entrenamiento, todos los navegadores web desarrollados en estos artículos necesitan entrenamiento por parte del usuario, ya sea para controlar correctamente la aplicación (potenciales SCP o ritmos μ y β) o para establecer diversos coeficientes que puedan mejorar su experiencia con la misma (potenciales P300, N2PC y mVEP).

Sin embargo, atendiendo a las funcionalidades, se encuentran grandes diferencias.

- i. La selección de hipervínculos en los dos primeros artículos estaba centrada en buscar el deseado entre una lista. En Bensch *et al* [23] se utiliza una selección binaria para encontrarlo a base de iteraciones y en Mugler *et al* [26] es necesario seleccionarlo introduciendo los caracteres de su etiquetado. En cambio, en los últimos artículos, Sirvent Blasco *et al* [27] y Yu *et al* [28], la selección de hipervínculos se lleva a cabo desplazando un cursor sobre los mismos.

- ii. El filtrado de hipervínculos solamente está disponible en Yu *et al* [28]. Este filtro y su método de selección de hipervínculos confieren al navegador una rapidez que no poseen sus predecesores.
- iii. Solamente Bensch *et al* [23] requiere supervisión. Varias de sus funcionalidades, como el tiempo de lectura o la lista de direcciones de correo, son gestionadas por el supervisor.
- iv. El historial de navegación está disponible en Sirvent Blasco *et al* [27]. No obstante, no está orientado a personas discapacitadas debido a la dificultad para su uso. El resto de navegadores no incluyen esta funcionalidad.
- v. Todos los navegadores implementan la funcionalidad de los marcadores excepto Mugler *et al* [26]. Sin embargo, Sirvent Blasco *et al* [27] no lo orienta a personas discapacitadas y Yu *et al* [28] simplemente almacena los ocho más populares en su página de inicio, no permitiendo su modificación.
- vi. A diferencia de los primeros navegadores web implementados con BCI, como *Descartes*, todos los navegadores de esta comparativa poseen una barra para introducir URLs.
- vii. Todos los navegadores exceptuando Yu *et al* [28] implementan un modo de lectura, aunque su metodología hace que no lo necesite. En Bensch *et al* [23] el supervisor debe introducir el tiempo que el usuario puede estar leyendo una página, sin embargo, en Mugler *et al* [26] y Sirvent Blasco *et al* [27] este modo es controlado plenamente por el usuario.
- viii. Finalmente, tanto Sirvent Blasco *et al* [27] como Yu *et al* [28] implementan un ratón que es capaz de mover un cursor. No obstante, en Sirvent Blasco *et al* [27] el desplazamiento es más rígido y es necesario introducir la distancia en píxeles a recorrer, mientras que en Yu *et al* [28] no es necesario.

En términos de precisiones, Yu *et al* [28] consigue la mayor precisión con un 93,21%, seguido por Sirvent Blasco *et al* [27] y Liu *et al* [29] con 90% y, finalmente, por Mugler *et al* [26] con 90% para los sujetos sanos y 72% para los pacientes con ELA. No obstante, cada uno de estos estudios utilizó un distinto número de sujetos. Por tanto, las precisiones obtenidas podrían variar si todos los estudios utilizaran el mismo número de sujetos sanos y de pacientes.

Esta comparativa aparece en la Tabla 2-3 a modo de resumen. A continuación se muestran una serie de artículos que se limitan a desarrollar otras técnicas que pueden implementarse como mejora en cada uno de los navegadores web.

En Liu *et al* [29] se desarrolla un sistema basado en potenciales evocados mVEP. Mediante el desplazamiento de un cursor se evocan los potenciales y, en consecuencia, no es necesario utilizar botones que se iluminan constantemente. Con respecto a los artículos comparados anteriormente, reduce drásticamente la fatiga visual producida por los cambios de brillo de la pantalla, convirtiéndose en una alternativa innovadora.

Yin *et al* [30] determinó el brillo óptimo para no dañar a los ojos cuando se utilizan los potenciales evocados visuales P300 mediante la técnica *odd-ball*, algo a tener en cuenta. En el experimento se concluyó que la luminancia RGB debe encontrarse entre 160 y 180. La fórmula de la luminancia es la siguiente [31].

$$Y = 0,21246 \cdot R + 0,7152 \cdot G + 0,0722 \cdot B, \quad \text{con } R, G, B, Y \in [0,255] \quad (2.1)$$

En Kübler et al [32] se desarrolla un sistema de deletreo basado en potenciales evocados P300 auditivos. Los artículos basados anteriormente se basaban en una capacidad visual ordinaria, sin embargo, muchos de los pacientes con ELA han perdido el control de los músculos oculares y, por tanto, no podrían utilizar dichos sistemas. Este sistema posee la ventaja de poder ser usado por personas con una capacidad visual reducida, a diferencia del resto. Sin embargo, la precisión obtenida (23,53%) en este sistema es muy inferior al resto. También es notable que las personas con capacidad visual reducida obtengan mejores precisiones que las sanas, debido a un desarrollo superior de su audición.

TABLA 2-3. COMPARATIVA DE LOS DISTINTOS ARTÍCULOS SOBRE NAVEGADORES WEB ATENDIENDO A SU METODOLOGÍA Y FUNCIONALIDADES.

Artículo	Basado en	Funcionalidades										Sujetos	Precisión
		Requiere entrenamiento	Requiere supervisión	Selección de hipervínculos	Filtrado de hipervínculos	Marcadores	Historial	Barra de URL	Modo de lectura	Implementa ratón	Distancias mediante píxeles		
<i>Bensch et al</i> (2007) [23]	Potenciales Corticales Lentos (SCP)	Sí	Sí	Mediante selección binaria	No	Sí	No	Sí	Tiempo impuesto por el supervisor	No	No	4 ELA	No especificado
												2 sanos	
<i>Mugler et al</i> (2010) [26]	Potenciales Evocados P300	Sí	No	Etiquetado con uno o dos caracteres	No	No	No	Sí	Sí	No	No	3 ELA	72%
												10 sanos	90%
<i>Sirvent Blasco et al</i> (2012) [27]	Potenciales Evocados P300 y N2PC	Sí	No	Mediante desplazamiento del cursor	No	No orientado a personas discapacitadas	No orientado a personas discapacitadas	Sí	Sí	Sí	Sí	4 sanos	93%
<i>Yu et al</i> (2012) [28]	Potenciales Evocados P300 y ritmos sensorio-motores	Sí	No	Mediante desplazamiento del cursor	Sí	Ocho marcadores populares en la página inicial	No	Sí	No	Sí	No	7 sanos	93,21%
<i>Liu et al</i> (2010) [29]	Potenciales Evocados mVEP	Sí	No	No especificado	No	No especificado	No especificado	Sí	No especificado	No	No	12 sanos	93%

ANÁLISIS DE LOS POTENCIALES P300

3.1. Potenciales evocados P300

Tal y como se ha explicado de manera breve en el anterior capítulo, un potencial evocado P300 se corresponde con una deflexión positiva del EEG del usuario provocada como respuesta natural del cerebro ante un estímulo [5]. Se localiza en torno a la zona centro-parietal del córtex (Fz, Cz y Pz), su amplitud se encuentra en torno a los $10\mu\text{V}$ y su nombre deriva del hecho de que su latencia con respecto al inicio del estímulo se encuentra en torno a 300ms. También se conoce como potencial P3 puesto que es el pico con la tercera amplitud más elevada entre los potenciales evocados sensoriales [33].

La manera más habitual de provocar un potencial evocado P300 se fundamenta en aplicar el paradigma *odd-ball*, consistente en presentar una serie de estímulos objetivo de forma infrecuente camuflados entre otros estímulos no deseados mucho más frecuentes. Está demostrado que a menor probabilidad de evento mayor será el potencial P300 generado.

Numerosos estudios han tratado de caracterizar este potencial y de establecer las pautas óptimas para su obtención. Se ha declarado que la utilización de filtros paso-alto para eliminar las variaciones lentas de la señal influye en la forma del potencial, siendo conveniente aplicar un filtro a partir de 0,1Hz (frecuencias de corte mayores distorsionarían la forma de la señal).

La respuesta de los potenciales P300 es pequeña y aparece superpuesta con la actividad EEG de fondo, así como con ruido, y debido a ello, una respuesta individual no suele ser reconocible. No obstante, resulta fundamental poder distinguir la actividad evocada por el estímulo de la actividad EEG de fondo. En este sentido conviene mencionar que la señal P300 está solapada en frecuencia con el contenido espectral del EEG de fondo, por lo que no es posible aplicar un filtrado en frecuencia para aislar la respuesta evocada. Como alternativa, comúnmente se realiza un filtrado en el dominio del tiempo aprovechando la relación temporal, repetitiva a lo largo de las diferentes épocas de la señal obtenida, entre la aparición del estímulo y la actividad evocada, típicamente a 300ms desde la presentación del estímulo. Este filtrado temporal se conoce como promediado sincronizado, y consiste en promediar todas las épocas de la señal estableciendo como referencia el punto en el que se ha generado el estímulo que produce el potencial P300 [34]. En la Figura 3-1 se observa el resultado de promediar la señal a la hora de detectar los potenciales P300.

Dentro de la parte de adquisición de la señal, la eliminación de artefactos, y en concreto la eliminación movimiento ocular, es una etapa muy importante a la hora de analizar la señal. Para eliminar el movimiento ocular y los pestañeos producidos por el usuario que degradan los potenciales P300 se pueden utilizar dos enfoques distintos, explicados a continuación [33].

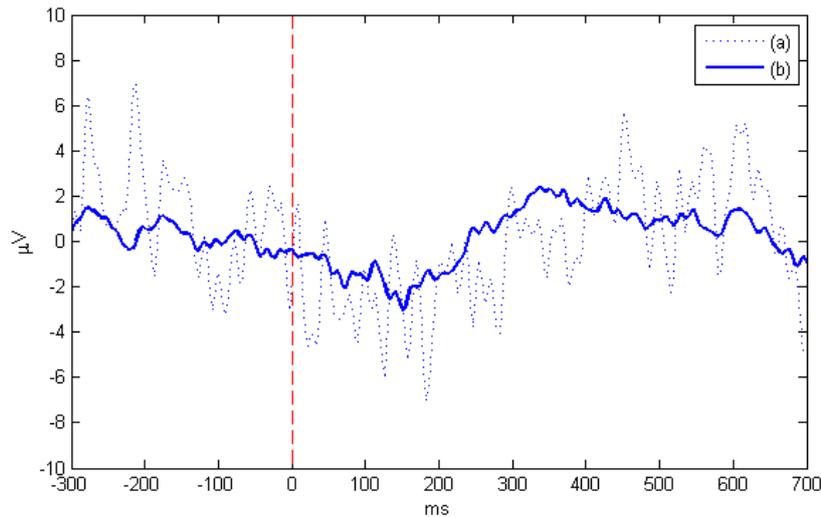


Figura 3-1. Potencial evocado P300 recogido en el electrodo Pz y generado con un *odd-ball* auditivo donde el usuario debía detectar tonos objetivos con probabilidad de ocurrencia de 0,2. La curva punteada (a) se corresponde con la primera época registrada y la curva (b) se corresponde con un promediado sincronizado de 90 épocas, permitiendo distinguir el potencial. La línea roja rayada indica el momento en el que se presentó el estímulo.

El primero se basa en rechazar las épocas donde se hayan producido movimientos oculares o pestañeos. Para ello se monitoriza el EOG posicionando electrodos cerca de los ojos (típicamente encima y debajo de ellos) y se rechaza cada época si la señal EOG supera cierto umbral (e.g., $\pm 100 \mu\text{V}$). Sin embargo, este enfoque posee dos inconvenientes principales: el primero reside en que rechazar épocas de la señal disminuye la eficiencia del registro (en el peor caso posible todas las épocas serían rechazadas) y, por tanto, se recomienda a los sujetos no mover los ojos o pestañear mientras se realizan las pruebas; esto conduce al segundo inconveniente, puesto que recomendar a los sujetos no producir movimientos oculares cambia la naturaleza de la prueba, causando que los sujetos dividan su atención entre sus ojos y el estímulo, produciendo un cambio en la forma del potencial P300.

El segundo enfoque se basa en sustraer la señal EOG del EEG. Para ello se suelen emplear filtros adaptativos, los cuales requieren una señal de referencia fuertemente correlada con el ruido o artefacto que se desea eliminar (en este caso sería la señal EOG extraída con los electrodos situados en torno al ojo). Desafortunadamente esta extracción no es perfecta y puede eliminar ciertas porciones de la señal EEG recogida en los electrodos frontales, más cercanos a los ojos.

La detección de los potenciales evocados P300 comúnmente se lleva a cabo detectando un pico de amplitud que se eleva de la actividad basal, el cual se encuentra retrasado 200 o más milisegundos después de la presentación del estímulo. Esta detección se realiza en un solo electrodo, típicamente Cz o Pz, y la latencia del P300 varía de un electrodo a otro, alcanzando el valor mínimo en los electrodos situados en la zona frontal del córtex [33]. Sin embargo, esta manera de tratar a los potenciales P300 no tiene en cuenta la posibilidad de que éstos estén conformados por múltiples procesos generados en distintas localizaciones. Un estudio más detallado del potencial P300 revela que éste está compuesto de tres ondas positivas superpuestas e independientes: P3a con un máximo en torno a 250ms, P3b con un máximo en torno a 350ms y una onda lenta (SW, *Slow Wave*) [35]. Estas componentes se observan en la Figura 3-2.

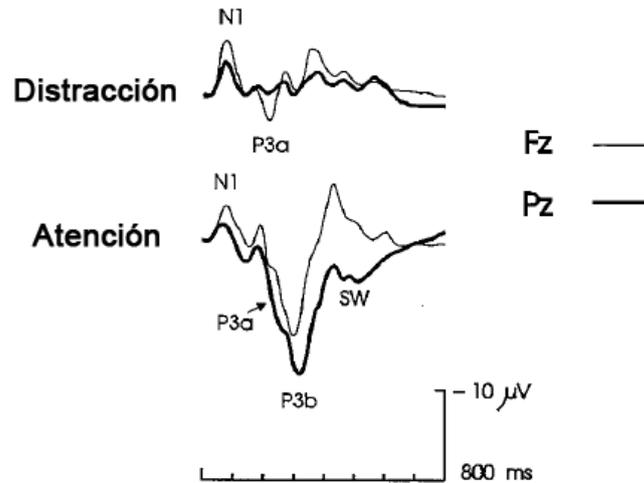


Figura 3-2. Componentes del potencial evocado P300 en dos localizaciones distintas: Fz y Pz. En la gráfica superior aparece la respuesta cuando el sujeto no atiende al estímulo, donde se observa que la onda P3a sigue apareciendo. En la gráfica inferior, por el contrario, aparece la respuesta cuando el sujeto atiende al estímulo, generando las tres componentes principales: P3a, P3b y *slow wave* [33].

Estas componentes se consideran independientes porque poseen distintas relaciones con diversas variables experimentales. La onda P3a se distribuye en la zona frontal del córtex, mientras que la onda P3b se detecta mejor en la zona parietal. Aunque las tres componentes varían de la misma manera con la probabilidad de estímulo (aumentando su amplitud a medida que el objetivo objetivo se hace más improbable), son sensibles a la información obtenida sobre el estímulo en cuestión: la onda P3a no se afecta si el sujeto está atendiendo o no al estímulo, mientras que la onda P3b y la onda lenta aumentan su amplitud si el sujeto pone atención, tal y como se puede observar, de nuevo, en la Figura 3-2. Si fuese necesario identificar las tres componentes por separado se podría realizar un PCA (*Principal Component Analysis*, o Análisis de Componentes Principales).

A continuación se muestra cómo varía la forma del potencial evocado P300 según las características del sujeto, atendiendo a sus aspectos psicológicos, diferencias individuales entre sujetos, los factores farmacológicos y las enfermedades neuronales.

3.1.1. Aspectos psicológicos

Dentro de los aspectos psicológicos del sujeto cobran importancia la atención del sujeto y la probabilidad de que ocurra el estímulo que generará el P300. Numerosos estudios han demostrado que la amplitud del potencial P300 aumenta de manera significativa cuando el usuario aumenta su nivel de atención y cuanto menor sea la probabilidad de aparición del estímulo objetivo. En la Figura 3-3 (a) se muestra el efecto de la probabilidad del estímulo en el P300.

Además, los efectos de la probabilidad del estímulo ocurren independientemente del conocimiento sobre ellos del sujeto. Si se modifica la probabilidad del estímulo durante un experimento y el usuario no es consciente de ello, la amplitud del potencial P300 cambia igualmente [33].

Aunque esté fuertemente correlado con la probabilidad de estímulo, otro aspecto importante es la probabilidad temporal, es decir, el tiempo que pasa entre la aparición de un estímulo objetivo y el siguiente. Se ha demostrado que cuanto mayor sea este tiempo mayor será la amplitud obtenida en el potencial evocado P300, tal y como muestra la Figura 3-3 (b).

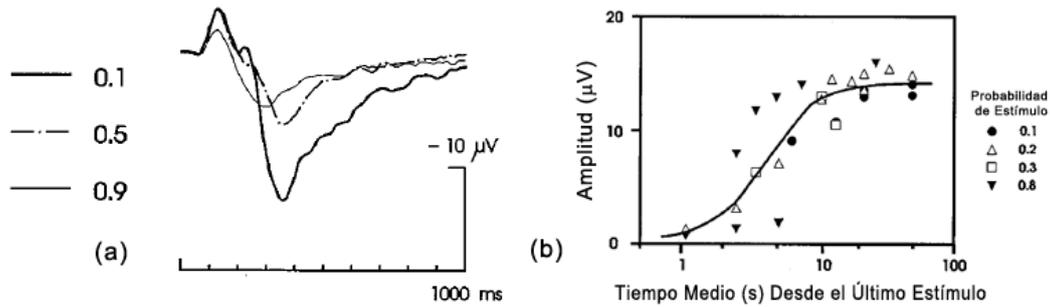


Figura 3-3. Variación de la forma del P300 para el electrodo Pz en función de la probabilidad de estímulo (a) y la probabilidad temporal (b) al utilizar un paradigma *odd-ball* auditivo [33].

Para terminar, también influye la dificultad de la tarea en la forma del P300 obtenido. Cuando discriminar el estímulo objetivo del resto de estímulos se convierte en una tarea ardua, la amplitud del potencial P300 disminuye y su latencia aumenta, tal y como se puede observar en la Figura 3-4.

La disminución de amplitud es producida por una reducción de la confianza del usuario. La amplitud es mayor cuando éste se encuentra confiado porque la tarea es sencilla, sin embargo, al incrementarse al dificultad de la tarea la confianza en sí mismo disminuye, causando que la amplitud del potencial P300 caiga. No obstante, si la tarea se vuelve demasiado sencilla, la amplitud puede disminuir también, puesto que el usuario no dedicará toda su atención [33].

3.1.2. Diferencias individuales entre sujetos

También afectan a la forma del potencial P300 las diferencias individuales de cada sujeto, siendo éstas la edad, la inteligencia, la personalidad o el oído absoluto, entre otras [33]. La edad de los sujetos posee dos comportamientos distintos según el rango que se analice.

Para sujetos adultos con más de 20 años, aproximadamente, la latencia del potencial P300 muestra un comportamiento lineal con la edad provocando un aumento de unos 1,3ms por año (con un error estándar de 31ms), tal y como muestra la Figura 3-4 (a) [33]. Analizando el tiempo de reacción (RT, *Reaction Time*) del sujeto, se ha demostrado que éste se encuentra en torno a 50ms después de la generación del P300. Sin embargo, el RT puede cambiar con la edad dependiendo de la dificultad de la tarea: si la tarea es sencilla, la edad aumenta más la latencia del P300 que el RT, mientras que si la tarea es complicada, ocurre el fenómeno contrario.

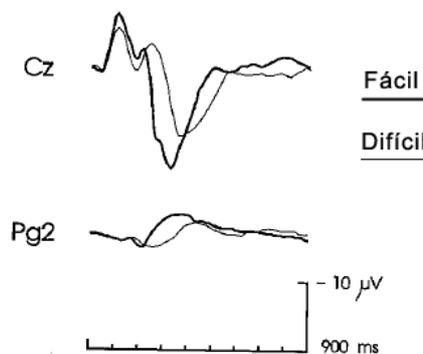


Figura 3-4. Potenciales evocados P300 recogidos en el vértex (Cz) y en un electrodo nasofaríngeo (Pg2) según la dificultad de discriminación de los estímulos objetivos [33].

En general también puede afirmarse que la amplitud del P300 decrece con la edad en sujetos adultos, además de modificarse la localización del potencial, ubicándose más en la zona frontal del córtex a medida que se envejece [33].

No obstante, el comportamiento del potencial P300 varía de forma distinta para los niños (entre 5 y 20 años) que para los adultos. Determinar el comportamiento del potencial P300 en niños es complicado debido al gran número de artefactos que presentan y a que normalmente no son capaces de mantener constante su atención.

El potencial evocado P300 para los niños se solapa con otra onda negativa producida en la zona frontocentral del córtex, más intensa cuanto más pequeño sea el niño. Sin embargo, en la zona parietal del córtex sí se muestra una onda parecida al P300 de los adultos, caracterizada por tener mayor latencia. Esta latencia disminuye a medida que aumenta la edad del niño, pudiendo distinguir dos tramos principales: entre los 5 y 12 años de edad la latencia disminuye con una tasa de 25ms por año, mientras que entre los 12 y 20 años de edad disminuye más lentamente, con una tasa de 1-5ms por año [33]. Estos efectos pueden observarse en la Figura 3-5.

Adicionalmente, la distinción entre la onda P3b y la SW en niños se convierte en una tarea ardua y confusa. Con respecto a la amplitud, ésta aumenta a medida que aumenta la edad del niño hasta los 13 años, aproximadamente. Después de ese punto la amplitud decrece levemente como en los adultos. Los efectos de la probabilidad del estímulo en los adultos son similares a los encontrados en niños.

Para terminar, cabe destacar que la localización del potencial P300 en el córtex para los niños difiere de la localización de los adultos. A medida que los niños crecen, la localización del mismo se desplaza desde la zona parietal del córtex a la zona frontocentral. Además de ello, la ubicación de los potenciales P300 visuales y auditivos en los adultos es similar, sin embargo, en los niños se obtienen mejor los potenciales P300 visuales en las zonas frontocentrales que los potenciales P300 auditivos [33].

Dejando a un lado la edad del sujeto, también se ha estudiado la variación de la forma del potencial P300 según la inteligencia o personalidad del sujeto. Considerando la inteligencia como el coeficiente intelectual (CI) clásico, se ha demostrado que a medida que aumenta el CI, disminuyen la latencia y la amplitud del P300 [33].

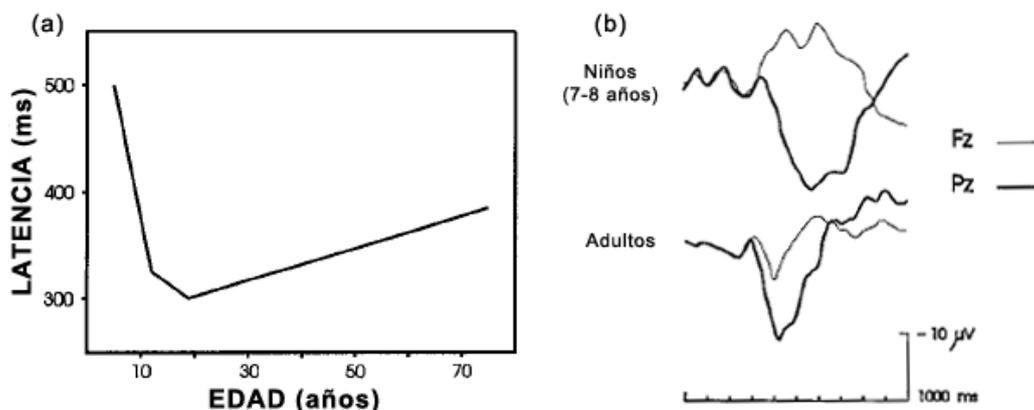


Figura 3-5. Variaciones de la forma del potencial evocado P300 según la edad del sujeto. En (a) se observa la variación de la latencia con la edad, pudiendo distinguir tres tramos distintos: de 5 a 12, de 12 a 20, y de 20 años en adelante. En (b) se observa el potencial P300 y su localización en Fz y Pz para niños de 7-8 años y para adultos, pudiendo observar la onda positiva de los niños en la zona frontal y la latencia del P300 en la zona parietal [33].

Además, se ha demostrado que la personalidad y, concretamente, la extroversión, el neuroticismo y el psicoticismo (rasgos elegidos por Hans Eysenck para describir la misma), modifican la forma del P300 [36]. Los resultados del experimento demuestran que cuanto más extrovertido sea el usuario, menor será el RT medido, posiblemente a causa de la impulsividad característica de éstos sujetos, además de mostrar una disminución de amplitud, posiblemente a causa de la imposibilidad de mantener la atención en largos intervalos de tiempo. También demuestran que el neuroticismo, o inestabilidad emocional, está negativamente correlado con la latencia, es decir, cuanto más inestable sea emocionalmente un sujeto menor será la latencia del P300 recogido. Finalmente, se concluye también que a medida que aumenta el psicoticismo (caracterizado por su agresividad y antipatía) menor será la amplitud del P300 [36].

Finalmente se expone el efecto de una característica concreta e infrecuente en la mayor parte de los sujetos, conocida como oído absoluto. El oído absoluto permite, al sujeto que lo posee, identificar o producir una nota musical concreta sin la ayuda de una nota de referencia, capacidad fuertemente relacionada con la memoria auditiva. Se ha demostrado que los potenciales P300 auditivos generados atendiendo al paradigma *odd-ball* para los sujetos que poseen oído absoluto muestran una amplitud minúscula, posiblemente debido a que los sujetos con oído absoluto no necesitan estar atentos para distinguir un estímulo auditivo infrecuente. Tal y como era de esperar, los resultados para P300 visuales son los mismos que para los sujetos normales [37].

3.1.3. Factores farmacológicos

Cuando el sujeto se encuentra bajo los efectos de ciertos medicamentos, del alcohol o de las drogas, la forma de sus potenciales evocados P300 varía.

Concretamente, los efectos del alcohol producen una reducción de amplitud del potencial P300 y un aumento de su latencia [33]. Sin embargo, este fenómeno no aparece cuando la dificultad de la tarea de discriminación entre los estímulos es complicada, probablemente debido a que el sujeto intenta superar los efectos del alcohol cuando la tarea lo requiere.

Los efectos producidos por las drogas y medicamentos son muy diversos, entre ellos destacan el efecto de la escopolamina (también conocida como *burundanga*), que disminuye drásticamente la amplitud del P300 hasta hacerlo desaparecer en *odd-ball* auditivos debido a la pérdida de memoria a corto plazo; el metilfenidato (psicoestimulante aprobado para el tratamiento de la hiperactividad), que aumenta el RT del sujeto; la clonidina (utilizado como antihipertensivo), las benzodiacepinas (medicamentos psicotrópicos) y los antihistamínicos, que atenúa la amplitud; y la dopamina, que disminuye la latencia; entre otros [33].

3.1.4. Enfermedades neuronales

Las enfermedades neuronales también afectan a la forma del potencial evocado P300. A continuación se tratan los efectos de enfermedades como la esquizofrenia, el autismo, la depresión, el trastorno obsesivo-compulsivo, la psicopatía o la demencia.

Los sujetos que sufren de esquizofrenia generan potenciales P300 con muy baja amplitud, siendo prácticamente irreconocibles, tal y como se muestra en la Figura 3-6. Este fenómeno no parece estar relacionado con la falta de atención o la medicación sino con la severidad de los síntomas del paciente y, adicionalmente, los

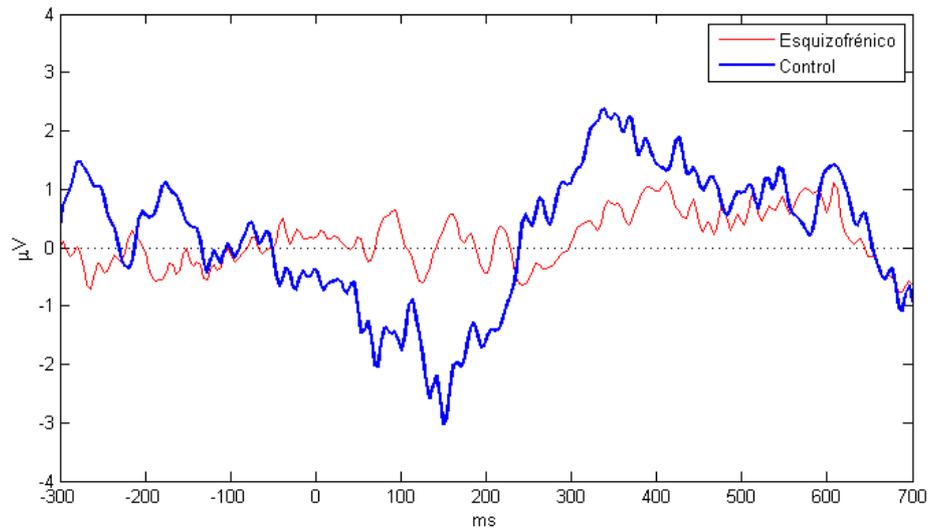


Figura 3-6. Potencial evocado P300 recogido en el electrodo Pz y generado con un *odd-ball* auditivo para un sujeto esquizofrénico (en rojo) y un sujeto sano de control (en azul) con un promediado de 90 épocas.

sujetos esquizofrénicos muestran un potencial P300 menos concentrado en la zona parietal del córtex que los sujetos de control [33].

El autismo y la depresión severa también afectan a la forma del potencial P300, causando una reducción de su amplitud. Sin embargo, en algunos tipos de pacientes psiquiátricos la latencia del P300 puede disminuir, como es el caso de los pacientes que sufren un trastorno obsesivo-compulsivo. Otro fenómeno característico consiste en obtener un potencial P300 mucho más prolongado, típico de los pacientes que sufren psicopatía o ELA. Para terminar, también se ha demostrado que la dislexia y la demencia producen una disminución de amplitud acompañada de un aumento en la latencia del potencial [33].

En la Tabla 3-1 se recogen todas las posibles variaciones del potencial P300 según las distintas características de cada sujeto, explicadas anteriormente.

3.2. Procesado de los potenciales evocados P300

Una vez adquiridos los potenciales P300 y libres de los artefactos comunes tales como el movimiento ocular, el movimiento de los músculos cercanos o la actividad eléctrica del corazón; es necesario procesar la señal para identificar la presencia de los potenciales P300.

3.2.1. Extracción de características

Normalmente, en los sistemas BCI que emplean los potenciales evocados P300 como señal de control, la extracción de características se convierte en una etapa muy sencilla. Tal y como se vio en el capítulo 2, se pueden clasificar las técnicas de extracción de características en dos grandes grupos: filtrado en tiempo o frecuencia y filtrado espacial, como norma general.

Es habitual el utilizar un filtrado de cada tipo en el sistema BCI, sin importar el orden en el que se apliquen. Adicionalmente, la eliminación de artefactos y la extracción de características no están completamente separadas en este tipo de sistemas, pudiendo aplicar un mismo método para ambas. En estas ocasiones los

TABLA 3-1. CARACTERÍSTICAS DE LOS USUARIOS INDIVIDUALES QUE MODIFICAN LA FORMA DEL P300.

Aspectos Psicológicos						
Aumento de →	Atención	Probabilidad de Estímulo	Tiempo entre Estímulos	Sencillez de la Tarea		
Amplitud de P300	Aumenta	Disminuye	Aumenta	Aumenta (*)		
Latencia de P300				Disminuye		
(*) Si las tareas son demasiado sencillas termina disminuyendo						
Diferencias Individuales entre Sujetos						
Aumento de →	Edad		Coeficiente Intelectual	Personalidad		
	Adultos (>20 años)	Niños (5-20 años)		Extroversión	Neuroticismo	Psicoticismo
Amplitud de P300	Disminuye	Aumenta (hasta los 13)	Disminuye	Disminuye		Disminuye
Latencia de P300	Aumenta	Disminuye	Disminuye		Disminuye	
Otros efectos	Se desplaza a la zona frontal	Onda parietal disminuye	(**)	RT disminuye		
(**) El oído absoluto no muestra potenciales P300 auditivos, solamente visuales						
Factores Farmacológicos						
En presencia de →	Alcohol	Escopolamina (burundanga)	Metilfenidato	Clonidina Benzodiacepina Antihistamínicos	Dopamina	
Amplitud de P300	Disminuye	Disminuye (casi desaparece)		Disminuye		
Latencia de P300	Aumenta				Disminuye	
Otros efectos	No afecta en tareas complicadas		RT aumenta			
Enfermedades Neuronales						
En presencia de →	Esquizofrenia	Autismo Depresión severa	Trastorno Obsesivo-Compulsivo	Psicopatía ELA	Dislexia Demencia	
Amplitud de P300	Disminuye (casi desaparece)	Disminuye		Disminuye	Disminuye	
Latencia de P300			Disminuye		Aumenta	
Otros efectos	Menor concentración en la zona parietal			Potencial más prolongado		

métodos de eliminación de artefactos pueden considerarse como técnicas de extracción de características debido a que su salida se introduce seguidamente como entrada del algoritmo de traducción.

A continuación se estudian una serie de métodos de extracción de características de cada grupo que se han empleado con anterioridad en los sistemas BCI y utilizan los potenciales evocados P300 como señal de control. Cabe destacar que la aplicación a desarrollar utilizará un filtrado CAR como filtrado espacial, y un submuestreo de la señal que servirá de entrada al clasificador. No obstante, para

visualizar los potenciales evocados P300 de cada usuario, se empleará un promediado sincronizado.

a) Filtrado espacial

El objetivo de realizar un filtrado espacial es reducir el difuminado espacial. El difuminado espacial es un efecto provocado por la distancia entre los electrodos y las fuentes que generan la señal dentro el cerebro debido a la no homogeneidad de los tejidos que se encuentran entre ellos.

Se han propuesto diversos métodos para reducir este difuminado espacial, siendo los más populares los filtros Laplacianos, los métodos de referencia de media común (CAR), el análisis de componentes independientes (ICA) y el análisis de componentes principales (PCA) [38].

a.1) Filtro Laplaciano

Para empezar, el filtro Laplaciano calcula, para cada electrodo, la segunda derivada de la distribución de voltaje espacial instantánea y, consecuentemente, enfatiza la actividad originada en un radio concreto alrededor de cada electrodo. De esta manera, en la práctica se comporta como un filtro espacial paso-alto que acentúa la actividad que está más localizada y reduce la actividad más difusa.

A continuación, se halla el valor del Laplaciano para cada electrodo que se va a utilizar, combinando la señal recogida en esas posiciones con las señales de un conjunto de electrodos adyacentes. La distancia desde el electrodo hasta el conjunto de electrodos adyacentes determina las características del filtro: cuanto menor sea la distancia el Laplaciano será más sensible a potenciales con altas frecuencias espaciales y menos sensible a potenciales con bajas frecuencias espaciales, y viceversa. Es decir, funcionará mejor con señales de control muy localizadas en el córtex [39].

Para obtener el Laplaciano, se emplea un método de diferencia finita que aproxima la segunda derivada de la distribución espacial Gaussiana en dos dimensiones del cuero cabelludo en un electrodo, restando la actividad media de los electrodos adyacentes al canal de interés, de acuerdo con la siguiente fórmula [38].

$$v_h^{LAP}(t) = v_h(t) - \sum_{i \in S_i} w_{h,i} \cdot v_i(t) \quad (3.1)$$

Donde $v_n(t)$ es el voltaje recogido por el canal n -ésimo, concretamente h para el canal en el que se aplica el filtrado e i para los canales adyacentes. Adicionalmente, S_i se corresponde con el conjunto de índices de los canales adyacentes y $w_{h,i}$ es el peso en función de la distancia $d_{h,i}$ entre el electrodo de interés y sus vecinos.

$$w_{h,i} = \frac{\frac{1}{d_{h,i}}}{\sum_{i \in S_i} \frac{1}{d_{h,i}}} \quad (3.2)$$

Por tanto, se habla de Laplaciano corto cuando los electrodos vecinos se corresponden con los electrodos adyacentes al electrodo en el que se aplica el filtrado y de Laplaciano largo cuando los electrodos vecinos se encuentran a una distancia mayor. En la Figura 3-7 (a) y (b) se emplean estos dos tipos de Laplacianos sustrayendo la media de cuatro canales vecinos, indicados con un círculo relleno de la localización central, indicada con un círculo abierto. Por tanto, el peso de cada vecino será de $w_{h,i} = -0,25$.

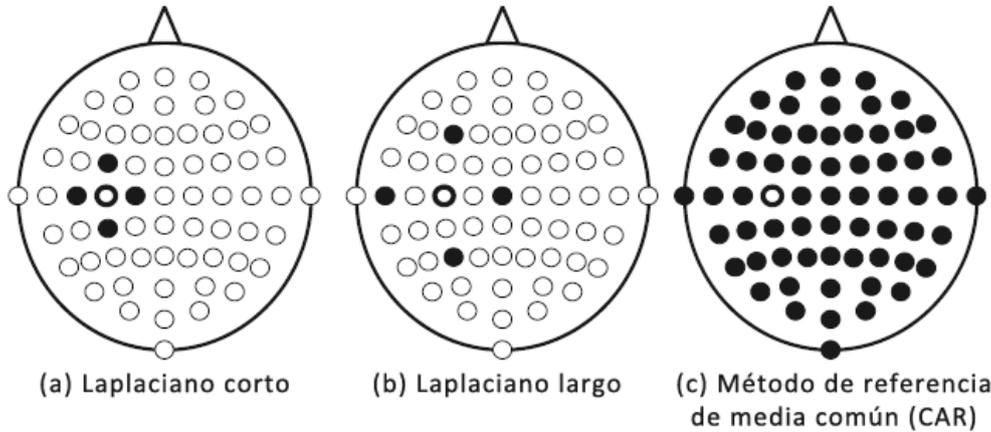


Figura 3-7. Tres filtrados espaciales diferentes para obtener la señal del canal C3: (a) Laplaciano corto, (b) Laplaciano largo y (c) método de referencia de media común (CAR). El electrodo objetivo C3 se corresponde con el círculo vacío y sus vecinos con círculos rellenos.

a.2) Método de referencia de media común

El método de referencia de media común (CAR, *Common Average Reference*) se basa en el mismo procedimiento que el filtro Laplaciano, sin embargo, difiere de éste en que esta vez se resta del canal obtenido la media común de todos los electrodos. Si la cabeza está completamente cubierta de electrodos equiespaciados entre ellos y el potencial generado en el córtex está muy localizado en fuentes puntuales, el método CAR provee un voltaje espacial de media cero, además de actuar como un filtro espacial paso-alto, acentuando las componentes que se encuentran más localizadas [39]. En la Figura 3-7 (c) se pueden observar los electrodos involucrados.

El voltaje del canal deseado se obtiene restando a éste la media común del voltaje obtenido en el resto de electrodos ($\frac{1}{H} \cdot \sum_{i=1}^H v_i(t)$), de acuerdo a la expresión [38]:

$$v_h^{CAR}(t) = v_h(t) - \frac{1}{H} \cdot \sum_{i=1}^H v_i(t) \quad (3.3)$$

Donde $v_n(t)$ es el voltaje recogido por el canal n -ésimo referenciado a la oreja, etiquetando como h el canal en el que se aplica el filtrado y siendo H el número total de electrodos empleados, incluyendo el canal filtrado.

a.3) Análisis de componentes independientes

El análisis de componentes independientes (ICA, *Independent Component Analysis*) es una solución estadística particular al problema de la separación ciega de fuentes, consistente en obtener las fuentes originales de un proceso a partir de una mezcla de dichas señales. Por tanto, ICA trata de subdividir la señal EEG en diversas componentes independientes suponiendo que la señal de origen posee una independencia estadística y una distribución no gaussiana [40]. El objetivo de esta técnica es el de revelar características del EEG ocultas por el ruido basal para detectar los potenciales P300 con un solo intento (en Li *et al* [40] se han conseguido precisiones del 76,67%).

Una escena particular del problema de la separación ciega de fuentes sería la siguiente: dos personas (S_1 y S_2) están hablando en un extremo de una habitación simultáneamente y en el otro extremo se encuentran dos micrófonos (R_1 y R_2) en

distintas localizaciones que registran la conversación. Las señales registradas podrían expresarse de la siguiente manera:

$$\begin{cases} R_1(t) = a_{11}S_1(t) + a_{12}S_2(t) \\ R_2(t) = a_{21}S_1(t) + a_{22}S_2(t) \end{cases} \quad (3.4)$$

Si conociésemos los valores de a_{11} , a_{12} , a_{21} y a_{22} podríamos resolver esas ecuaciones para obtener los valores de S_1 y S_2 , y así distinguir ambas conversaciones sin solapamiento alguno. Desgraciadamente, esos pesos son desconocidos y únicamente podemos obtenerlos si consideramos que las fuentes (S_1 y S_2) son señales independientes y de naturaleza no gaussiana. Este ejemplo se conoce como el problema *cocktail party*, y es el mismo que intenta resolver ICA. La señal EEG también se considera un problema *cocktail party*, puesto que los electrodos registran la señal EEG en distintas localizaciones sobre el cuero cabelludo. Con ICA se intentan distinguir aquellas fuentes que producen esa mezcla y, concretamente, las que producen los potenciales evocados P300 para facilitar su posterior detección [40].

Por tanto, de forma análoga a (3.4) se puede expresar el problema generalizándolo de la siguiente forma:

$$\begin{cases} x_1(t) = a_{11}s_1(t) + a_{12}s_2(t) + \dots \\ x_2(t) = a_{21}s_1(t) + a_{22}s_2(t) + \dots \\ \dots \end{cases} \rightarrow \mathbf{x} = \mathbf{A} \cdot \mathbf{s} \quad (3.5)$$

Siendo \mathbf{x} la matriz vertical de las señales mezcladas y conocidas, \mathbf{A} la matriz que contiene los pesos a_{ij} y \mathbf{s} la matriz de las fuentes que se desean discriminar. Se asume que los coeficientes de pesos a_{ij} son desconocidos y que permiten que la matriz \mathbf{A} sea invertible, además de asumir (como ya se ha indicado,) que las componentes de \mathbf{s} son no gaussianas e independientes, que la mezcla es lineal y espontánea y que los datos son estacionarios.

Bajo estas suposiciones, se concluye que existe una matriz \mathbf{W} con coeficientes w_{ij} que permite obtener las fuentes estimadas $\hat{\mathbf{s}}$ al multiplicarse con las señales mezcladas, de la siguiente manera:

$$\mathbf{y} = \mathbf{W} \cdot \mathbf{x} = \mathbf{W} \cdot [\mathbf{A} \cdot \mathbf{s}] = \hat{\mathbf{s}} \rightarrow \hat{\mathbf{s}} = \mathbf{W} \cdot \mathbf{x} \quad (3.6)$$

Por tanto, la matriz \mathbf{W} es la matriz pseudoinversa de \mathbf{A} , expresado: $\mathbf{W} = \hat{\mathbf{A}}^+$. Existen una gran variedad de algoritmos para hallar la matriz \mathbf{W} , entre ellos *Infomax*, *JADE* o *FastICA*, siendo *Infomax* el que mejores resultados presenta [40].

a.4) Análisis de componentes principales

El análisis de componentes principales (PCA, *Principal Component Analysis*) es un método de reducción de dimensionalidad que permite seleccionar las componentes de la señal EEG más relevantes y descartar los canales que proveen información redundante. Este método cobra importancia cuando se trabaja con sistemas multicanal para discriminar qué canales aportan información útil para la discriminación de tareas y cuáles no.

El análisis PCA trata de encontrar, a partir del espacio geométrico resultante de proyectar los datos, una dirección del espacio tal que la varianza de los datos proyectados sea máxima. Este problema se describe en la Figura 3-8 y, tal y como se puede observar, la dirección que consigue la varianza máxima de los datos es D_1 , mientras que D_2 es una dirección cualquiera [41].

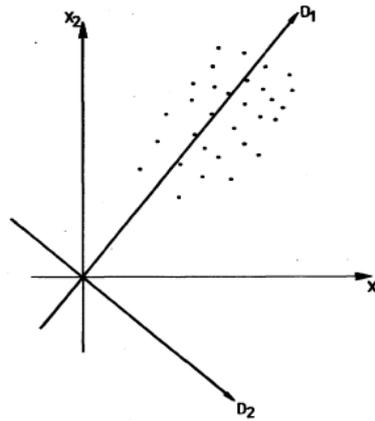


Figura 3-8. Búsqueda de la dirección que consigue que la varianza de los datos proyectados sea máxima (D_1) en un problema de análisis de componentes principales.

Para encontrar las direcciones buscadas se parte de un conjunto de datos de dimensión n , y éstas se obtienen restando la media de cada dimensión, calculando la matriz de covarianzas y obteniendo sus autovalores y autovectores. Estos autovectores se corresponden con las direcciones buscadas y se cumple que, además de ser ortonormales, al proyectar los datos sobre ellos la varianza que se obtiene en cada dirección coincide con su autovalor asociado. Por ende, el autovector asociado al autovalor más alto se corresponde con la dirección de máxima varianza [41].

De esta manera se pueden seleccionar las m direcciones principales y sobre ellas proyectar los datos, obteniendo un espacio resultante de dimensión m . Por tanto, si la dimensión m es menor que n , se habrá producido una compresión de los datos y en consecuencia, una pérdida de información. Se pretende que la pérdida de información sea principalmente de información redundante y, a causa de ello, se descartan los autovectores con los autovalores más pequeños.

b) Filtrado y análisis temporal

Dentro del filtrado y del análisis temporal para la extracción de los potenciales P300 cobran una gran importancia el promediado sincronizado, la detección de picos (*peak picking*), el cálculo del área de la señal y el filtrado adaptativo. Estas técnicas son muy rápidas y muy convenientes para el análisis a tiempo-real de la señal, sin embargo, para un análisis *offline* más exhaustivo, pueden emplearse técnicas frecuenciales, como la STFT (*Short Time Fourier Transform*, Transformada de Fourier de Tiempo Corto) o las transformadas *wavelet*.

Además del análisis temporal para determinar los potenciales P300, algunas de las técnicas temporales descritas a continuación también se aplican para eliminar artefactos comunes, tal y como se ha explicado anteriormente.

b.1) Promediado sincronizado

El promediado sincronizado permite distinguir los potenciales evocados P300 del ruido del EEG basal. Dado que el contenido espectral no deseado solapa la banda frecuencial donde se detectan los potenciales, los filtros lineales (como el filtrado paso-alto, paso-bajo o paso-banda) no son capaces de separar ambas señales [34].

El promediado sincronizado requiere poseer varias épocas de realización de la señal tras aplicar de manera repetitiva un estímulo y poseer una referencia temporal

para alinearlas adecuadamente. Estos requerimientos hacen que este análisis temporal sea idóneo para distinguir los potenciales P300 generados gracias al paradigma *odd-ball*.

Tal y como muestra la ecuación (3.7), consiste en promediar todas las épocas de la señal estableciendo como referencia ($n = 0$) el punto en el que se ha generado el estímulo que produce el potencial P300 [34].

$$Prom(n) = \sum_{k=1}^M y_k(n) = \sum_{k=1}^M x_k(n) + \sum_{k=1}^M w_k(n), \quad n = 1, 2, \dots, N \quad (3.7)$$

Siendo $y_k(n) = x_k(n) + w_k(n)$ una realización de la señal (con $x_k(n)$ la señal original sin ruido y $w_k(n)$ el ruido en la k -ésima época), k el índice de promediado, n el índice de tiempo discreto, M el número de épocas y N el número de muestras en cada época.

En el caso de la aplicación de la matriz *odd-ball* que genera P300 para la selección de letras, conocida como *P3Speller*, la manera de detectar qué celda se ha seleccionado es realizando un promediado sincronizado. Tanto la fila como la columna que contienen la celda deseada deben haber generado un potencial evocado P300 y, puesto que es imposible visualizar la presencia de un potencial P300 en una sola época de la señal, es necesario aplicar un promediado sincronizado de todas las combinaciones de filas y columnas (si la matriz es de 6x6 se promediarán 36 épocas). Posteriormente se aplicará la detección de picos o el cálculo del área para detectarlos automáticamente y poder averiguar cuál es la celda seleccionada [42].

b.2) Detección de picos y cálculo del área

La detección de picos o *peak picking* es una técnica muy simple que trata de detectar los potenciales evocados P300 monitorizando la amplitud de un promediado sincronizado de la señal. Para ello, se determina la diferencia entre el punto más negativo previo a la ventana establecida y el punto más alto dentro de dicha ventana [43] y se compara con la obtenida para un segmento basal. Los tamaños de la ventana son muy diversos, normalmente comprendiendo desde cientos de milisegundos antes de cada estímulo hasta más de 500ms después de éste, para comprender el potencial evocado, típicamente 300ms después del estímulo.

El cálculo del área comprendida bajo la señal promediada es un método muy sencillo y útil para detectar la presencia de este tipo de potenciales. En la práctica se suman todos los puntos de la ventana establecida y se determina la presencia de un P300 si el área comprendida es drásticamente mayor que en un segmento basal [43].

b.3) Filtrado adaptativo

El filtrado adaptativo no suele utilizarse frecuentemente en las aplicaciones que utilizan los potenciales evocados P300 debido a su estacionariedad, sin embargo, es útil para eliminar artefactos conocidos (e.g., el ECG residual). El filtrado adaptativo elimina un artefacto de la señal EEG sin asumir estacionariedad en la señal, no obstante, requiere una señal fuertemente correlada con el ruido a eliminar [34].

Tal y como propone su nombre, este filtro se adapta continuamente a las características de la señal, cambiando el vector de pesos a lo largo del tiempo, como se observa en la Figura 3-9. Para ello partimos de una señal de entrada $x(n)$, mezcla de la señal de interés $v(n)$ y del ruido primario $m(n)$, asumiendo que ambas componentes están incorreladas, como expresa la ecuación (3.8).

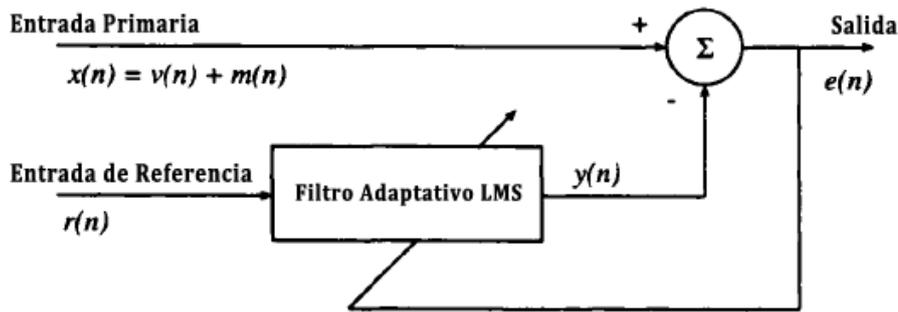


Figura 3-9. Esquema del filtrado adaptativo para eliminar una fuente de ruido.

El filtro adaptativo LMS filtra la referencia $r(n)$, fuertemente correlada con $m(n)$, para obtener una señal $y(n)$ lo más parecida al ruido primario que sea posible. Posteriormente, $y(n)$ es sustraída de la señal, obteniendo la estimación de la señal de interés $e(n)$, expresado en la ecuación (3.9).

$$x(n) = v(n) + m(n) \quad (3.8)$$

$$e(n) = \hat{v}(n) = x(n) - y(n) \quad (3.9)$$

El algoritmo LMS (*Least Mean Squares*, o Mínimos Cuadrados Promediados), que rige el funcionamiento del filtro adaptativo, trata de ajustar el vector de pesos \mathbf{w} para minimizar el error cuadrático medio (MSE, *Mean Square Error*) calculando un nuevo vector de pesos $\mathbf{w}(n+1)$ en base al vector de pesos actual $\mathbf{w}(n)$ más una correlación proporcional al gradiente negativo MSE. La ecuación (3.10) es una particularización de la regla de Widrow-Hoff y se encarga de actualizar los pesos en cada momento.

$$e^2(n) = x^2(n) - 2x(n)\mathbf{r}^T(n)\mathbf{w}(n) + \mathbf{w}^T(n)\mathbf{r}(n)\mathbf{r}^T(n)\mathbf{w}(n) \quad (3.10)$$

Este algoritmo es fácil de implementar y no requiere derivar, elevar al cuadrado o promediar aunque se base en minimizar el MSE. También puede utilizarse el algoritmo RLS (*Recursive Least Squares*, o Mínimos Cuadrados Recursivos), óptimo cuando las señales varían mucho en oscilaciones rápidas de tiempo [34].

c) Análisis tiempo-frecuencia

El uso de las técnicas de análisis espectral para extraer las características en aplicaciones que usan potenciales evocados P300 también está ampliamente extendido, en las que destacan la transformada de Fourier de tiempo corto; las técnicas *wavelet*, tanto la transformada wavelet continua, la transformada wavelet discreta y la transformada de paquetes wavelet; y los modelos autorregresivos (AR, *Autoregressive Models*).

c.1) Transformada de Fourier de Tiempo Corto

La STFT (*Short-Time Fourier Transform*, o Transformada de Fourier de Tiempo Corto) básicamente divide la señal a analizar en una serie de segmentos que se suponen estacionarios y calcula la transformada de Fourier en ellos. Dado que la STFT no calcula la transformada de Fourier continua sino una versión enventanada, aparece distorsión debida a la ventana empleada creando un compromiso entre resolución temporal y frecuencial. Su expresión matemática se resume en la ecuación (3.11).

$$X_w[n, k] = \sum_{m=0}^{N-1} x[m] \cdot w^*[m-n] \cdot e^{-\frac{j2\pi km}{N}}, \quad \text{con} \quad \begin{array}{l} k \in [0, L-1] \\ n \in [0, N_T-1] \end{array} \quad (3.11)$$

Donde $w[n]$ representa la función ventana, $x[m]$ el segmento de la señal en el que se aplica la STFT y $N_T = N/L$ el número de segmentos no solapados en los que se ha dividido la señal [2].

Sin embargo, la suposición de que la señal segmentada es estacionaria y la resolución fija en el plano tiempo-frecuencia (Figura 3-10 (a)), que presenta su espectrograma una vez fijada la ventana, hacen que otras técnicas como las transformadas *wavelet* sean mucho más adecuadas en el análisis de señales biomédicas.

c.2) Transformadas Wavelet

Las desventajas de la STFT provocaron el desarrollo de las transformadas *wavelet* aplicadas a las señales EEG como sustitutas de este método. Todas las técnicas *wavelet* que se exponen a continuación se basan en la traslación y el escalado de una función *wavelet* madre (ecuación 3.12), generando así una resolución variable en el plano-tiempo frecuencia con buena resolución temporal para oscilaciones rápidas y buena resolución frecuencial para oscilaciones lentas, atendiendo al comportamiento característico de las señales biomédicas en general [2].

$$\varphi_{\tau,s} = \frac{1}{\sqrt{s}} \cdot \varphi\left(\frac{t-\tau}{s}\right) \quad (3.12)$$

Donde $\varphi(\tau, s)$ es la función *wavelet* madre, τ es el parámetro de traslación y s el parámetro de escalado. Existe un gran conjunto de *wavelets* madre y, habitualmente, el rendimiento de la aplicación se basa principalmente en elegir correctamente la más indicada; entre ellas se encuentran la *wavelet* de Haar, de Morlet, de Meyer, de Daubechies (en [44] se han conseguido precisiones de hasta 97,50% utilizando una *wavelet* madre de Daubechies4), etcétera.

La transformada *wavelet* continua (CWT, *Continous Wavelet Transform*) se define como la correlación entre la señal EEG y la función *wavelet* madre escalada y desplazada, expresada en la ecuación (3.13). De esta manera obtenemos una representación de la señal en el plano tiempo-escala, donde las bajas frecuencias de la señal se analizarían con altas escalas (produciendo una buena resolución frecuencial), y las altas frecuencias se analizarían con las escalas más bajas (produciendo una buena resolución temporal); tal y como muestra la Figura 3-10 (b).

$$w(\tau, s) = \int_{-\infty}^{+\infty} x(t) \cdot \frac{1}{\sqrt{s}} \cdot \varphi\left(\frac{t-\tau}{s}\right) dt \quad (3.13)$$

Sin embargo, esta transformación de la señal es demasiado redundante, dando paso a la transformada *wavelet* discreta (DWT, *Discrete Fourier Transform*). La DWT muestrea los valores de los parámetros de traslación (τ) y de escalado (s) de forma diádica (ecuación (3.14)) y, puesto que la CWT es demasiado redundante, la DWT no pierde excesiva información discriminativa sobre la señal. De esta manera, se requiere menor coste computacional, además de permitir un análisis multiresolución.

$$s = 2^{-j}; \tau = k \cdot 2^{-j} \rightarrow \varphi_{j,k}(t) = 2^{j/2} \cdot \varphi(2^j \cdot t - k) \quad (3.14)$$

Donde el factor $2^{j/2}$ se denomina factor de normalización, el cual garantiza la condición de ortonormalidad [2].

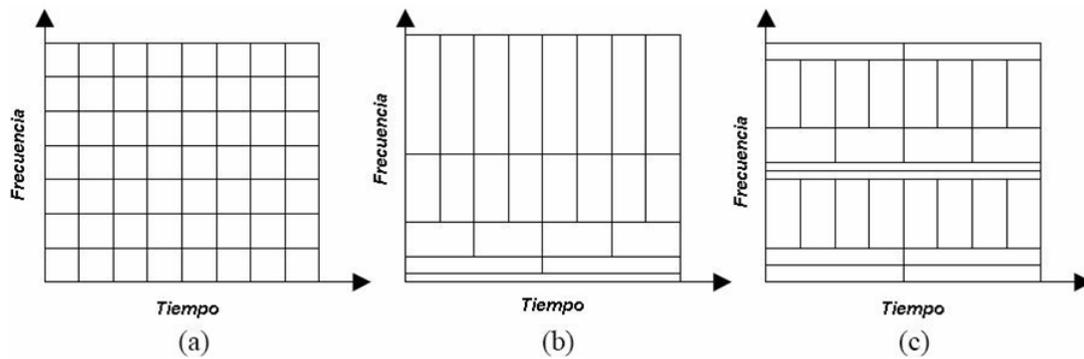


Figura 3-10. Plano tiempo-frecuencia para STFT en (a), con resoluciones fijas; DWT en (b), con resoluciones variables adaptadas a las señales biomédicas; y WPT en (c), con resoluciones variables según la intención del usuario.

El análisis multiresolución se basa en descomponer la señal en una parte de aproximación (coeficientes $c_{j,k}$) y una de detalle (coeficientes $d_{j,k}$). La aproximación refleja las principales características de la señal y el detalle contiene las fluctuaciones más rápidas, pudiendo considerarse como un filtro paso-bajo y un filtro paso-alto, respectivamente. A su vez, la aproximación se subdivide en otra señal de aproximación y otra de detalle, y así sucesivamente hasta alcanzar el número de escalas de descomposición deseado.

En la Figura 3-11 se muestran el espectrograma obtenido de la STFT (distribución de la densidad de potencia en el dominio tiempo-frecuencia) y el escalograma obtenido de la CWT (distribución de la densidad de potencia en el dominio tiempo-escala) para un promediado sincronizado de 90 épocas P300 obtenidas a través de un paradigma *odd-ball* auditivo. Tal y como se puede observar, la resolución del espectrograma es fija y no representa adecuadamente la distribución de potencia debido a una mala resolución temporal. Sin embargo, ese problema no se encuentra en el escalograma, donde sí existe una buena resolución temporal para las escalas más bajas [2].

No obstante, los resultados más precisos los provee la transformada de paquetes *wavelet* (WPT, *Wavelet Packet Transform*). La diferencia respecto a la DWT radica en que ésta nueva transformada, aparte de la señal de aproximación, subdivide también la señal de detalle, creando un árbol de descomposición mucho más extenso. Este análisis multiresolución extendido permite cambiar la resolución del plano tiempo-frecuencia tal y como desee el usuario a cambio de requerir un mayor coste computacional.

3.2.2. Traducción de características

Una vez extraídos los potenciales P300 de la señal EEG conviene clasificar si se ha producido un potencial o no en un momento determinado. Esta tarea la realizan los métodos de traducción de características, también conocidos con el nombre de clasificadores. Los clasificadores pueden dividirse en dos grandes grupos, tal y como se ha explicado anteriormente: los clasificadores lineales y los no lineales. Adicionalmente, en esta etapa es necesario considerar la adaptabilidad del usuario y asegurar que el clasificador vaya a funcionar en todas las situaciones posibles [5].

A continuación, se detallan los algoritmos de traducción más usados para clasificar las dos clases existentes en las señales de control P300: presencia o ausencia de potencial. Entre ellos se encuentran discriminante lineal de Fisher, el análisis

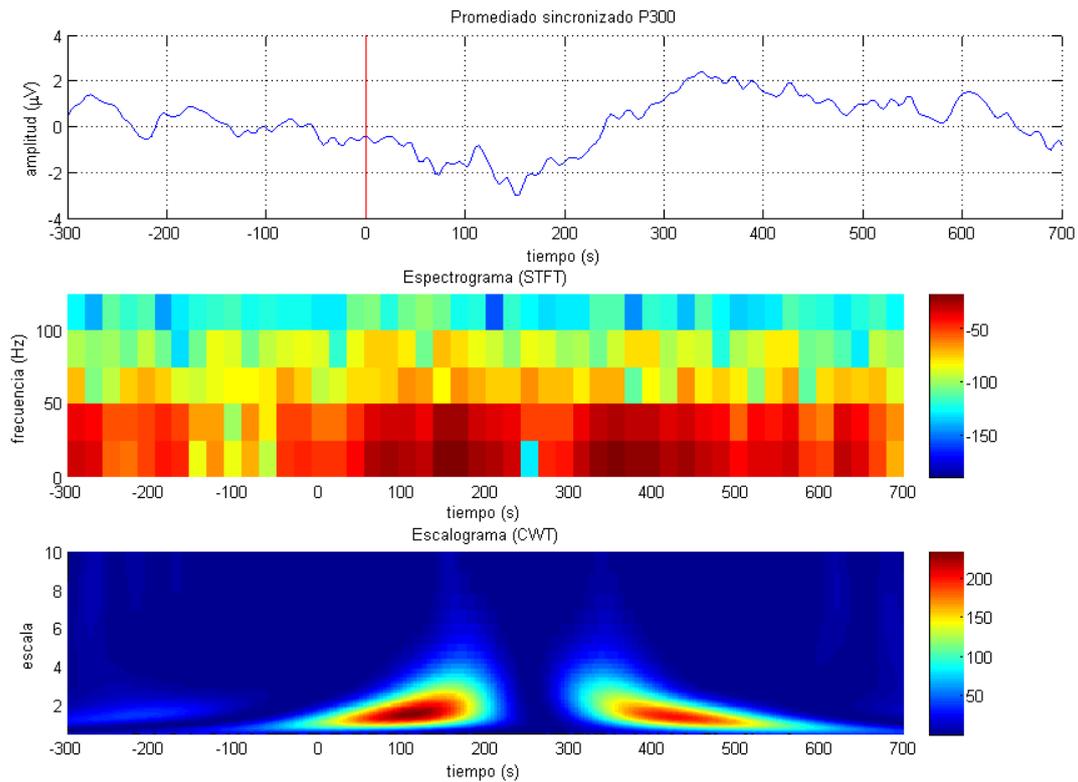


Figura 3-11. En la figura superior, representación del promediado sincronizado de 90 épocas de P300 para un *odd-ball* auditivo. En el centro, representación del espectrograma del mismo obtenido a través de la STFT. En la figura inferior, representación del escalograma del mismo obtenido a través de la CWT.

discriminante lineal paso-a-paso y las máquinas de soporte vectorial.

Determinar la presencia o la ausencia de un potencial evocado P300 a través de las características extraídas puede considerarse un problema de clasificación binario con una función discriminante cuyo hiperplano de decisión se define como:

$$\mathbf{w} \cdot \mathbf{f}(\mathbf{x}) + b = 0 \quad (3.15)$$

Donde \mathbf{x} es el vector de características, $\mathbf{f}(\cdot)$ es la función de transformación, \mathbf{w} es un vector de pesos y b es el sesgo (*bias*). Para los métodos no lineales, la función $\mathbf{f}(\cdot)$ puede representar una transformación que asigna las características a un espacio de dimensión mayor con el propósito de crear un conjunto de puntos que puedan separarse linealmente. Para los métodos lineales, la función $\mathbf{f}(\cdot)$ simplemente es $\mathbf{f}(\mathbf{x}) = \mathbf{x}$, [45].

En consecuencia, el vector de pesos \mathbf{w} asignará una etiqueta de clase a cada época o estímulo computado (comprendida entre -1 y +1), concretamente, +1 y -1 para el estímulo atendido y no atendido, respectivamente. Este diseño permite distinguir la respuesta con la mayor distancia positiva de todas las filas y columnas del *P300Speller* y determinar cuál es la celda seleccionada. Por tanto, los métodos explicados a continuación son distintos enfoques sobre cómo calcular ese vector de pesos (para los métodos lineales) y, adicionalmente, la función de transformación (para no lineales).

a) Discriminante lineal de Fisher

El FLD (*Fisher's Linear Discriminant*, o Discriminante Lineal de Fisher) es el punto de referencia para determinar el hiperplano de separación óptimo entre dos clases. Para clasificaciones binarias como la presentada aquí, la solución FLD y LMS son equivalentes, tratando de encontrar, a partir del espacio geométrico resultante de proyectar los datos, una dirección del espacio tal que el MSE de los datos proyectados sea mínimo. Este clasificador solamente se puede emplear cuando las dos clases poseen una distribución gaussiana y tienen la misma covarianza [45].

El vector de pesos para el caso propuesto se calcula de la siguiente manera:

$$\hat{\mathbf{w}} = (\mathbf{X}^T \mathbf{X})^{-1} \cdot \mathbf{X}^T \cdot \mathbf{Y} \quad (3.16)$$

Siendo \mathbf{X} la matriz formada por los vectores de características e \mathbf{Y} las etiquetas de cada clase, tal y como se ha explicado anteriormente.

Se ha comprobado que los resultados obtenidos para el FLD reflejan con mayor fidelidad la calidad del estimador que PCM (*Pearson's Correlation Method*, o Método de Correlación de Pearson), debido a que este último solo indica si existe una relación lineal entre las dos variables, a diferencia de FLD, el cual emplea la covarianza entre características [45].

b) Análisis discriminante lineal paso-a-paso

El SWLDA (*StepWise Linear Discriminant Analysis*, o Análisis Discriminante Lineal Paso-a-paso) es uno de los clasificadores más usados en sistemas BCI basados en potenciales evocados P300 [46]. Numerosos estudios han demostrado la efectividad del uso de este algoritmo de entrenamiento para el clasificador empleado en este tipo de aplicaciones, como el *P3Speller* [26][27][45][46][47].

Se trata de una extensión de LDA (*Linear Discriminant Analysis*, o Análisis Discriminante Lineal), una generalización del FLD, que incorpora una selección de características. Para ello, se encarga de añadir y eliminar términos de un modelo discriminante lineal, basándose en su significancia estadística. Por tanto, es capaz de producir un modelo que se ajuste completamente a los datos de entrenamiento, reduciendo la dimensionalidad del mismo si fuese necesario [46].

c) Máquinas de soporte vectorial

En el caso de las SVM (*Support Vector Machines*, o Máquinas de Soporte Vectorial), se trata de buscar un hiperplano de separación de margen máximo, es decir, que guarde la máxima distancia con los puntos que estén más cerca del mismo [48][49].

En la literatura que involucra BCI con potenciales evocados P300, se considera a las SVM como uno de los clasificadores más precisos [45][46]. Se han utilizado con éxito en multitud de estudios, como por ejemplo, en [50] o [51]. De hecho, el ganador de la III Competición de BCI en 2003 empleó un conjunto de SVMs en la clasificación del *data set II*, correspondiente al *P3Speller*, obteniendo una precisión del 96,5% [51].

SUJETOS Y MÉTODOS

En este capítulo, a diferencia de los anteriores, más centrados en el análisis del estado del arte, se detalla la metodología aplicada en el presente Trabajo Fin de Máster. Para ello, se especifican las características demográficas y clínicas de la población de estudio, así como los métodos de adquisición y procesado de la señal empleados tanto para la extracción (submuestreo de la señal EEG en crudo) como para la traducción de características (análisis discriminante lineal paso-a-paso y máquinas de soporte vectorial). Además, se incluye un apartado de umbralización, donde se estudia cómo diferenciar la actividad basal del usuario con respecto al deseo de seleccionar un comando.

4.1. Población de estudio

La población de estudio está compuesta por 5 sujetos de control (SC) y 16 enfermos de EM. Todos los sujetos fueron informados y preguntados sobre su participación en el estudio, dando su consentimiento para formar parte del mismo. Las características demográficas de la población de estudio aparecen en la Tabla 4-1.

Los 16 sujetos EM fueron reclutados a través del CRE-DyD de San Andrés del Rabanedo, León (España). La población EM está compuesta por sujetos de ambos sexos (10 hombres y 6 mujeres) mayores de edad, con una edad media de $42,06 \pm 7,47$

TABLA 4-1. CARACTERÍSTICAS DEMOGRÁFICAS Y CLÍNICAS DE LA POBLACIÓN DE ESTUDIO.

	Usuario	Sexo	Edad	Años de estudio	Discapacidad motora	Capacidad cognitiva	Capacidad de atención sostenida
Sujetos EM	U01	M	30	19	Nula	Muy buena	Muy buena
	U02	H	31	14	Nula	Buena	Muy buena
	U03	H	43	13	Leve	Muy buena	Buena
	U04	M	47	16	Moderada	Normal	Buena
	U05	H	56	12	Moderada	Baja	Muy mala
	U06	M	32	20	Nula	Normal	Regular
	U07	H	35	9	Nula	Muy buena	Muy buena
	U08	H	41	11	Nula	Buena	Buena
	U09	M	49	13	Nula	Normal	Muy buena
	U10	H	44	10	Leve	Normal	Mala
	U11	M	41	17	Moderada	Normal	Buena
	U12	H	43	10	Moderada	Muy buena	Regular
	U13	H	44	15	Nula	Buena	Buena
	U14	H	52	11	Moderada	Muy buena	Regular
	U15	M	38	14	Nula	Normal	Buena
	U16	H	47	12	Moderada	Normal	Regular
Sujetos SC	C01	H	21	-	-	-	-
	C02	H	25	-	-	-	-
	C03	H	21	-	-	-	-
	C04	H	30	-	-	-	-
	C05	H	33	-	-	-	-

EM: Esclerosis Múltiple, SC: Sujetos de Control, M: Mujer, H: Hombre.

años. Tal y como se puede observar, las características clínicas de la población muestran una gran variedad de discapacidades motoras, capacidades cognitivas y de atención sostenida entre los sujetos EM, lo cual podría afectar a la eficacia de la navegación a través de la aplicación.

Los 5 sujetos SC, por su parte, son todos varones y mayores de edad, con una edad media de $26 \pm 5,39$ años. Obviamente, todos son sujetos sanos que no presentan ningún tipo de discapacidad motora o cognitiva.

4.2. Metodología aplicada

A continuación se detalla la metodología aplicada en la adquisición y el procesamiento de la señal, la umbralización y el procedimiento de evaluación empleados en el presente estudio.

4.2.1. Adquisición de la señal

Para adquirir la señal EEG se utilizaron 8 electrodos activos colocados en las posiciones Fz, Cz, Pz, P3, P4, PO7, PO8 y Oz según la distribución del Sistema Internacional 10–20, tal y como se puede observar en la Figura 4-1 [4]. Se utilizó como referencia un electrodo colocado en el lóbulo de la oreja derecha y como tierra el electrodo FPz. Esta configuración es típica para obtener los potenciales P300, puesto que se producen en la zona parietal del córtex, no obstante, si la señal de control utilizada fuese otra, la localización de los electrodos hubiese variado enormemente.

Tal y como se ha explicado anteriormente, es necesario colocar un gel conductor entre los electrodos y el cuero cabelludo para reducir la impedancia del cráneo y poder amplificar la señal correctamente. La amplificación se realiza a manos de *g.USBamp*, un amplificador desarrollado por la empresa *g.Tec*. Su rango de entrada abarca los ± 250 mV, con una resolución inferior a 30 nV. Como resultado, cualquier

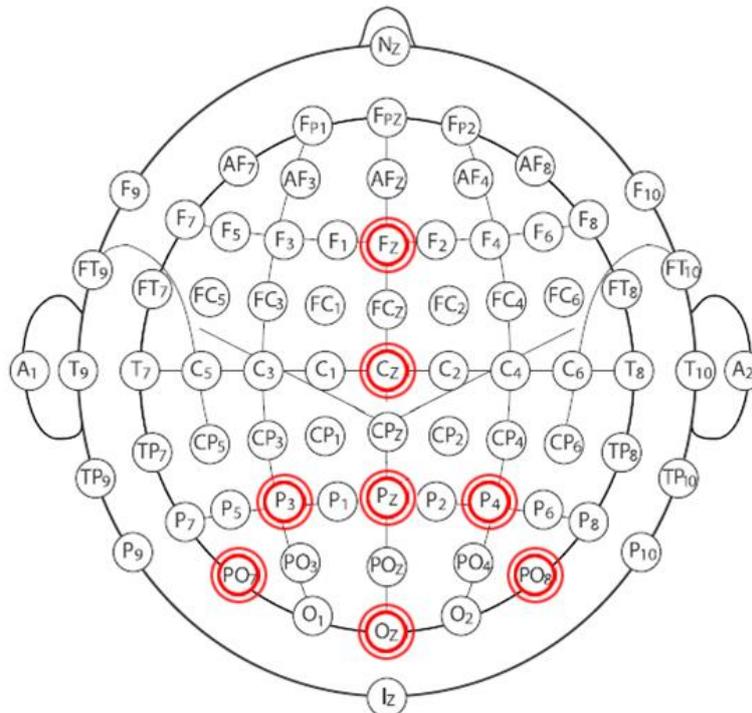


Figura 4-1. Disposición de los electrodos utilizados en la aplicación según el sistema internacional 10/20: Fz, Cz, Pz, P3, P4, PO7, PO8 y Oz.

señal electrofisiológica puede registrarse directamente sin ningún tipo de *hardware* adicional.

La frecuencia de muestreo utilizada se ha establecido en 256 Hz, adecuada para el análisis del EEG puesto que cumple de sobra el Teorema de Nyquist, evitando el solapamiento en el dominio de la frecuencia. Además, se ha aplicado un filtrado *hardware* paso-banda entre 0.1–60 Hz y un filtro de ranura a 50 Hz, con el objetivo de eliminar la interferencia de la red eléctrica.

Adicionalmente, como pre-procesado de la señal, se ha empleado un filtrado espacial CAR con el fin de eliminar el posible difuminado espacial. Como ya se explicó anteriormente, en el filtrado CAR se resta de cada canal a analizar la media común de todos los electrodos utilizados.

4.2.2. Extracción de características

Realmente, en la extracción de características empleada en la aplicación desarrollada solamente se realiza un submuestreo de la señal EEG en crudo. Se podría considerar extracción de características porque su salida es la entrada del clasificador, aunque no se aplique ningún tipo de filtrado. La sencillez del procesado permite asegurar el funcionamiento de la aplicación en tiempo-real.

Dado que en la aplicación se utiliza un *P3Speller*, como los explicados anteriormente, donde las filas y columnas de la matriz se iluminan aleatoriamente para generar los potenciales evocados P300 en el EEG del usuario, la entrada del clasificador a tiempo-real será la señal EEG correspondiente a cada iluminación en cada canal. Obviamente, solamente se submuestra el EEG dentro de una ventana temporal, lo suficientemente grande como para detectar el P300 (si está presente) y lo suficientemente pequeña como para que no se solapen las iluminaciones consecutivas. En la aplicación desarrollada se ha empleado una ventana temporal de 800 ms.

Por tanto, una vez identificada la iluminación y establecida su ventana temporal, se submuestra la señal. Por defecto, se emplea una frecuencia de submuestreo de 20 Hz, es decir, se generan 20 muestras por cada segundo de registro que compondrán la entrada del clasificador en cada iluminación. Como la ventana utilizada es de 800 ms, el número de muestras finales por iluminación es de 16 [38].

No obstante, si consideramos un número de muestras finales N , no se escogen las N muestras necesarias de la serie temporal original, sino que se divide la señal en N segmentos y se halla la media de voltaje de las muestras contenidas en cada segmento. De esta manera, se obtienen las N muestras necesarias teniendo en cuenta la contribución de las muestras adyacentes. En la Figura 4-2 se puede observar el submuestreo realizado para un potencial P300, hallado mediante un promediado sincronizado de las iluminaciones de un *P3Speller*.

Durante la evaluación de la aplicación se ha empleado este tipo de extracción de características. Sin embargo, posteriormente se ha realizado un estudio variando el número de muestras de dicha extracción, con el fin de identificar el número de muestras óptimo para maximizar la precisión en la clasificación de las respuestas de los enfermos de EM.

4.2.3. Clasificación de características

En la clasificación de características a tiempo-real se emplea un sistema de discriminación lineal que determina si se ha producido o no un P300 en cada

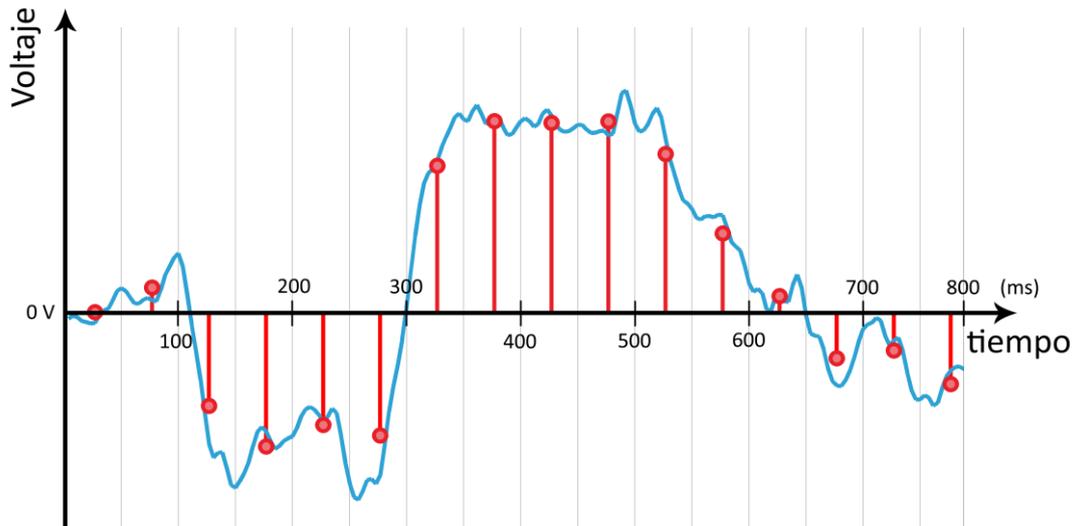


Figura 4-2. Submuestreo de un promediado sincronizado en una ventana de 800 ms para detectar un P300. En azul se muestra la señal EEG original, a 256 Hz. En rojo se han marcado las muestras finales tras aplicar una frecuencia de submuestreo de 20 Hz. En gris se marcan los límites de cada segmento, dentro de los cuales se ha realizado la media.

iluminación gracias a un sistema de pesos. No obstante, para hallar esos pesos, o lo que es lo mismo, para entrenar el clasificador, se han empleado tres técnicas distintas, explicadas a continuación.

a) Análisis discriminante lineal paso-a-paso

Tal y como se introdujo en el capítulo anterior, SWLDA es uno de los clasificadores más usados en este tipo de problemas [46]. No es más que una extensión de LDA que incorpora una selección de características, lo cual resulta útil para reducir la dimensionalidad del conjunto, bastante amplio teniendo en cuenta el número de iluminaciones necesarias para determinar la intención del usuario.

En general, los métodos LDA tratan de encontrar una combinación lineal de características capaz de separar dos o más clases de eventos mediante el uso de estadísticas de segundo orden para obtener el vector de pesos \mathbf{w} . Por tanto, el objetivo es hallar una proyección de los datos que maximice la distancia entre la media de las clases y que minimice la covarianza entre ellas. En consecuencia, la calidad del clasificador resultante depende de la calidad de la covarianza estimada y, en la práctica, por cuestiones de tiempo y coste computacional, es difícil o imposible obtener la cantidad de datos necesarios para establecer un buen clasificador LDA. En la Figura 4-3 se ilustra el procedimiento para hallar el hiperplano de separación.

Por esta razón surge el algoritmo SWLDA, que trata de mejorar la covarianza estimada reduciendo el número de pesos mayores que cero al mínimo. SWDLA empieza con un subconjunto de dimensiones de datos y determina, para cada dimensión, cuánto afectará a la calidad de la estimación el incluirla o eliminarla al realizar el cálculo, y modifica el conjunto de datos consecuentemente. Realmente, este análisis es una particularización del método de regresión paso-a-paso, el cual combina dos técnicas básicas de selección de características: el análisis paso-a-paso hacia delante y el análisis paso-a-paso hacia atrás [52].

El análisis paso-a-paso hacia delante (*forward stepwise regression*) parte de un conjunto vacío de características y evalúa la significación de cada una, añadiéndola al

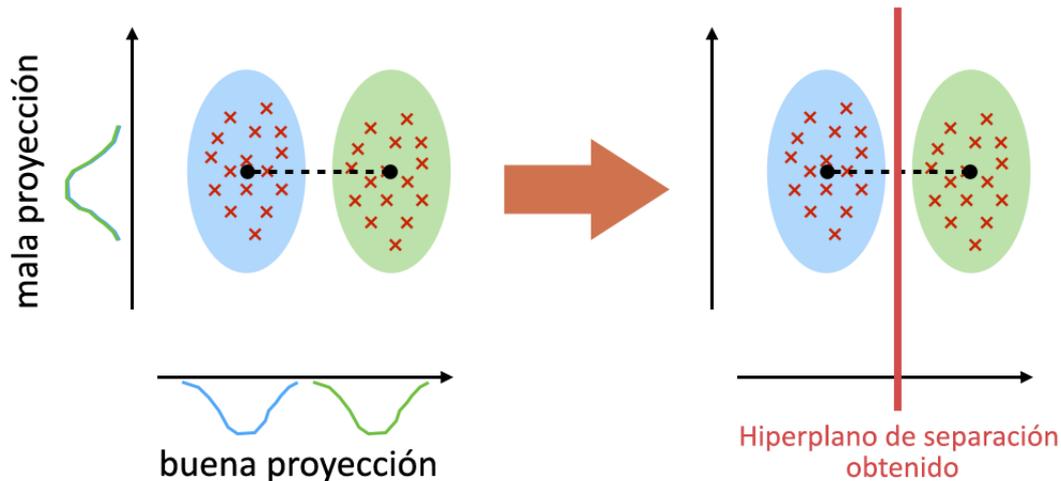


Figura 4-3. Procedimiento de búsqueda del hiperplano de separación en LDA para un problema de clasificación de dos clases (verde y azul). En la parte izquierda se muestran dos proyecciones distintas de los datos. En la parte derecha se halla el hiperplano de separación óptimo, aquel que minimiza la covarianza entre ambas clases.

conjunto si supera un cierto umbral o criterio de entrada y descartándola en caso contrario.

El análisis paso-a-paso hacia atrás (*backward stepwise regression*) realiza la función contraria: parte de un conjunto con todas las características posibles y evalúa cada una de ellas, preguntándose si deberían estar incluidas en el conjunto o no. Para ello, establece un criterio de salida y recorre el conjunto de características comprobando si éstas cumplen el criterio o no. Si una característica cumple el criterio, se descarta, reduciendo así el tamaño del conjunto.

El algoritmo SWLDA combina estos métodos de la siguiente manera: parte de un conjunto vacío y realiza un análisis paso-a-paso hacia delante para añadir las características más significativas, es decir, aquellas que cumplan con el criterio de entrada. Cada vez que se añade una característica al conjunto de datos, se calculan los *p-valores* de nuevo y se establece si alguna de las características incluidas en el conjunto cumple un determinado criterio de salida, utilizando un análisis paso-a-paso hacia atrás. Si la respuesta es afirmativa, se descartan las características que lo cumplan y se vuelve a realizar un análisis paso-a-paso hacia delante. La significación de cada característica se evalúa en términos de diferencias significativas estadísticas asociadas con el Test F de Fisher. Este procedimiento se repite constantemente hasta que el conjunto de datos alcance el número máximo de características o hasta que no existan más características que cumplan los criterios descritos [52].

En este caso, se han utilizado los siguientes criterios de entrada y de salida, comunes en la literatura que tratan este tipo de problemas [38][45][47][53]. Además, se ha restringido el conjunto hasta un máximo de 60 características [38][45][53].

$$\begin{cases} \text{Criterio de entrada} \rightarrow p\text{-valor} < 0.1 \\ \text{Criterio de salida} \rightarrow p\text{-valor} > 0.15 \end{cases} \quad (4.1)$$

Por tanto, se añaden a la función discriminante, o conjunto de datos, las características que obtienen un *p-valor* inferior a 0.1. Después de cada introducción a la función discriminante se calculan los nuevos *p-valores* y se realiza un análisis paso-a-paso hacia atrás para eliminar las características menos significativas, en concreto, las que obtienen un *p-valor* superior a 0.15. El algoritmo, por tanto, terminará cuando

se alcancen un máximo de 60 características o hasta que no existan más que cumplan los criterios descritos.

Según lo descrito anteriormente, un clasificador a tiempo-real entrenado mediante SWLDA recibe continuamente muestras procedentes de cada iluminación de cada fila y columna para todos los canales. Con la información recibida determina si en esa iluminación se detecta un potencial evocado P300 o no. Identificando las filas y las columnas donde se han producido tales P300 se puede determinar la celda que desea seleccionar el usuario.

Durante la evaluación de la aplicación, tanto para los sujetos sanos como para los enfermos de EM, se ha utilizado SWLDA como método de entrenamiento de los pesos del clasificador lineal. No obstante, en el estudio de maximización de la precisión del clasificador se han utilizado también otros métodos distintos, los cuales se explican a continuación.

b) Máquinas de soporte vectorial

Se han utilizado dos tipos de SVM en la maximización de la precisión de clasificación realizada, siendo éstos el s-SVM (*Single SVM*, o SVM único) y el e-SVM (*Ensemble of SVMs*, o Conjunto de SVMs). No obstante, es necesario detallar en qué consiste un SVM antes de particularizar el caso de estudio del presente Trabajo Fin de Máster.

Como bien se introdujo en el capítulo anterior, habitualmente los SVM proporcionan las precisiones más altas en el problema *P3Speller* [45][46][50][51]. Las SVM son un conjunto de algoritmos de aprendizaje supervisado que tratan de construir un hiperplano o conjunto de hiperplanos en un conjunto de dimensionalidad muy alta que pueden ser utilizados en problemas de clasificación o regresión no lineal.

El hiperplano buscado debe de guardar la máxima distancia (margen ρ) con los puntos que estén más cerca del mismo, y por esta razón, es conocido como un clasificador de margen máximo. La manera más simple de separar las clases es mediante una función lineal, sin embargo, los conjuntos de datos a estudiar no suelen presentar esos casos idílicos y suele ser necesario proyectar la información a un espacio de características de mayor dimensión a través de funciones *kernel* [48].

Dado el vector de características \mathbf{x} y el vector de etiquetas de clases \mathbf{d} (ambos vectores con longitud N), cuyos valores cumplen que $d_i \in [\pm 1]$, la ecuación de la función discriminante puede reformularse como sigue [45].

$$d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad \text{para } i \in [1, N] \quad (4.2)$$

El hiperplano óptimo de separación deberá maximizar la ecuación (4.2), cuyo margen de separación para la clasificación binaria es equivalente a minimizar la norma euclídea del vector de pesos óptimo \mathbf{w}_0 , como expresa la ecuación (4.3) [48].

$$\rho = \frac{2}{\|\mathbf{w}_0\|} \quad (4.3)$$

Los puntos que se encuentran más próximos al hiperplano de separación y cuyo margen de separación ρ_0 es máximo se denominan vectores de soporte y su clasificación es complicada. Una vez conocida la expresión del margen de separación es necesario maximizar la ecuación (4.2) mediante el método de los multiplicadores de Lagrange.

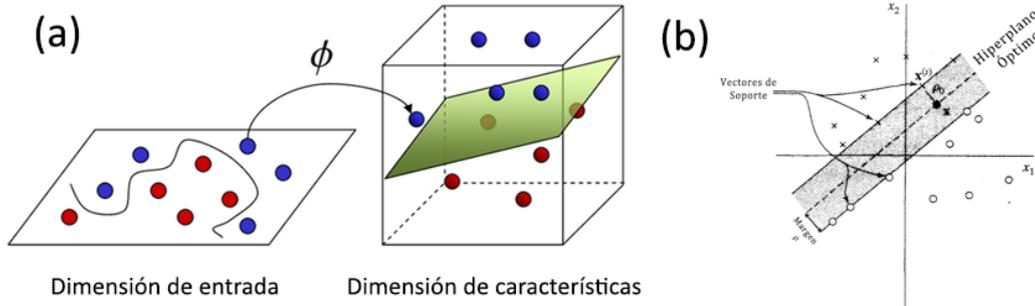


Figura 4-4. Representación gráfica de la proyección de las características a un espacio de dimensión más alta (a) y del hiperplano óptimo de separación para el algoritmo SVM en una clasificación binaria (b).

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j x_i^T x_j \quad (4.4)$$

A continuación se hallan los multiplicadores de Lagrange óptimos $\alpha[\alpha_0, \dots, \alpha_i]$ tratando de maximizar la ecuación (4.4) anterior, sujeta a las siguientes restricciones.

$$\sum_{i=1}^N \alpha_i d_i = 0, \quad \text{con } \alpha_i \geq 0 \quad \text{para } i = 1, \dots, N \quad (4.5)$$

Finalmente, el hiperplano óptimo, el vector de pesos óptimo w_0 y el sesgo óptimo b_0 se detallan en las ecuaciones (4.6) y (4.7) para una separación lineal [48].

$$w_0 = \sum_{i=1}^N \alpha_{0,i} d_i x_i \quad (4.6)$$

$$b_0 = 1 - w_0^T x^{(s)}, \quad \text{con } d^{(s)} = 1 \quad (4.7)$$

Desgraciadamente, cuando las clases no pueden separarse linealmente no se puede construir el hiperplano con las ecuaciones (4.6) y (4.7) sin que se produzcan errores en la clasificación. El parámetro ξ_i mide la diferencia desde el patrón considerado hasta el hiperplano óptimo, cuantizando este error y pudiendo darse dos casos, representados en la Figura 4-5 [48].

1. Que uno de los datos caiga en la zona de decisión y en el lado correcto del hiperplano de separación, Figura 4-5 (a). Entonces $0 \leq \xi_i \leq 1$.
2. Que uno de los datos caiga en el lado incorrecto de la frontera de decisión establecida por el hiperplano, Figura 4-5 (b). Entonces $\xi_i > 1$.

El hiperplano óptimo cuando las variables no son linealmente separables se encuentra aumentando la dimensión del conjunto de datos y minimizando la ecuación siguiente (4.8), donde C es un parámetro de regularización escalar determinado experimentalmente.

$$\phi(w, \xi) = \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad (4.9)$$

Para realizar esta transformación no lineal se suelen utilizar funciones *kernel* gaussianas debido a sus propiedades de aproximación universal, como se indica a continuación [45].

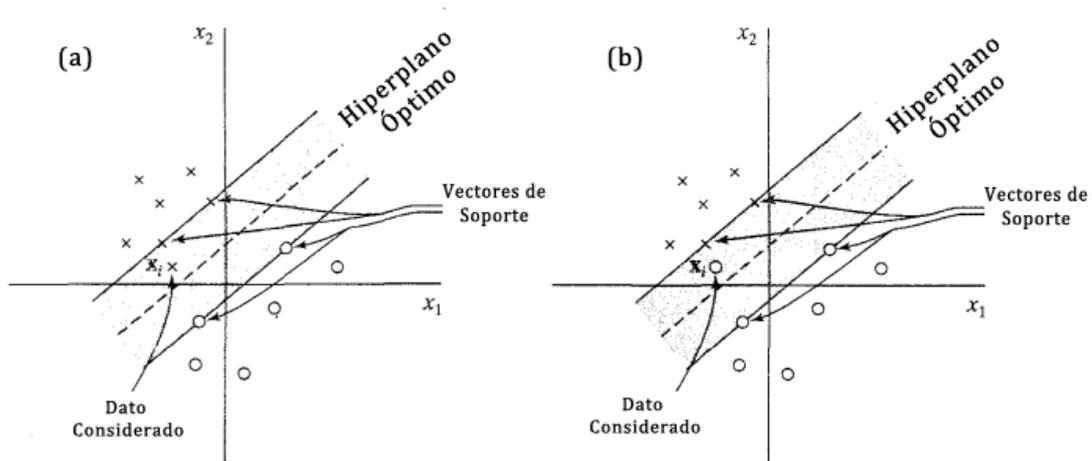


Figura 4-5. Posibles errores en la clasificación SVM. En (a) el dato considerado se encuentra dentro de la región de separación y se clasifica correctamente. En (b) el dato considerado se encuentra dentro de la región de separación y se clasifica incorrectamente.

$$score_{SVM} = \sum_{i=1}^N \alpha_{0,i} d_i \cdot \mathbf{K}(x_i, x_j), \quad \text{con } \mathbf{K}(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}$$

b.1) Single SVM

El s-SVM es el primer tipo de SVM usado para mejorar la precisión del clasificador. No es más que un SVM idéntico al explicado, con un *kernel* lineal.

Con respecto al problema a tratar, nótese que el *score* de la ecuación (4.9) representa la distancia de cada muestra al hiperplano de decisión, es decir, cuanto mayor sea su valor absoluto menos dudas se tienen al clasificarlo. En otras palabras, cuanto mayor sea su valor absoluto, existe una mayor probabilidad de clasificarlo correctamente.

En este caso, los predictores de entrada al s-SVM, que condicionan el número de dimensiones del problema de clasificación a resolver, serán todas las muestras extraídas para cada canal. Por tanto, en el caso particular de 8 canales y 16 muestras por canal, el s-SVM tendrá $8 \times 16 = 128$ predictores.

En tiempo-real, el clasificador ya entrenado, recibirá conjuntos de 128 muestras para cada iluminación, y retornará la probabilidad de que en cada iluminación esté presente un potencial evocado P300. No obstante, a la hora de entrenar el clasificador mediante s-SVM es necesario introducir todo el conjunto de iluminaciones realizadas en la calibración del mismo. En la Figura 4-6 se muestran todas las muestras que conforman el entrenamiento del clasificador. En el caso de la imagen, para cada intento, es decir, para cada selección, se introduce la información de cada fila y columna. En otras palabras, se pasan todas las iluminaciones de cada fila y columna de la matriz *P3Speller*. En este caso, si la matriz tiene R filas y C columnas, el número de filas y columnas totales será $N = R + C$. Además, si el número de iluminaciones por cada una de ellas es de M , se pasan por cada intento $N \cdot M$ vectores con la información de cada uno de los predictores. Teniendo en cuenta que se tienen X intentos de entrenamiento, el número total de vectores de predicción será:

$$\#x_{pre} = X \cdot M \cdot (R + C) \tag{4.10}$$

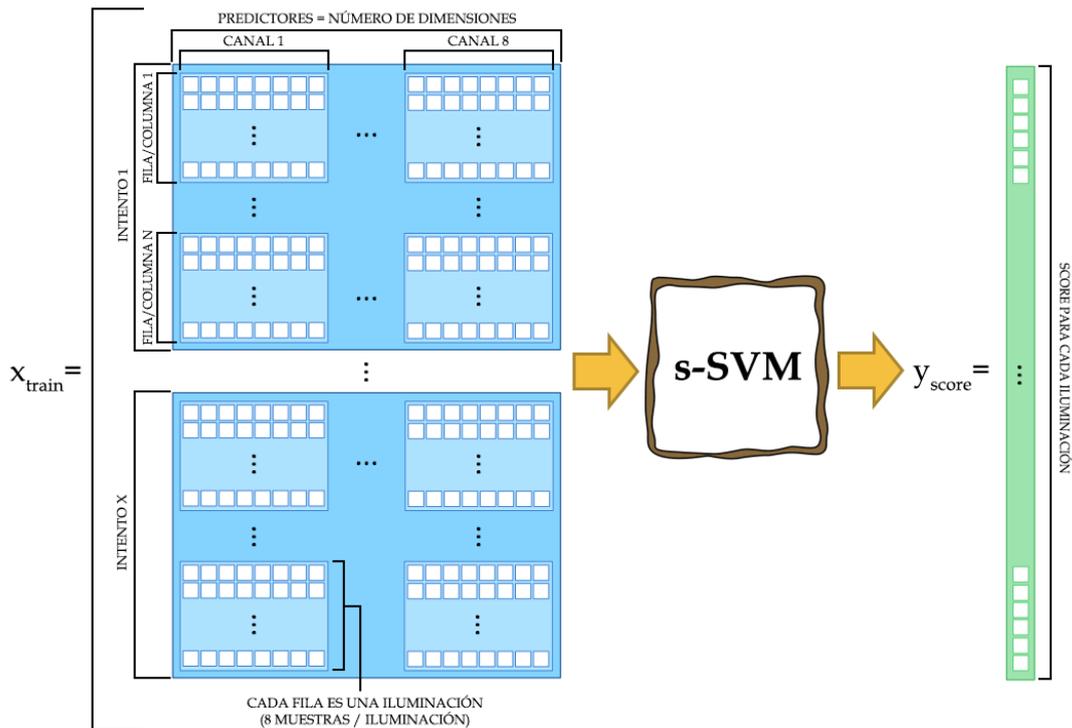


Figura 4-6. Entrenamiento detallado del clasificador s-SVM, donde se incluyen como muestras de entrenamiento X intentos o selecciones. Los predictores o dimensiones del SVM serán las muestras de cada canal y la salida del SVM retornará un *score* para cada iluminación, el cual determinará la probabilidad de que se haya producido o no un P300.

En el caso particular de la aplicación desarrollada, el número de intentos de entrenamiento por usuario fueron $X = 24$, el número de iluminaciones fueron $M = 15$, el número de filas de la matriz fueron $R = 9$ y el número de columnas $C = 5$. Por tanto, para el caso particular de 16 muestras por canal, la matriz de entrenamiento usada en s-SVM tenía un tamaño de:

$$x_{train} \rightarrow 24 \cdot 15 \cdot (9 + 5) \times 16 \cdot 8 = 5040 \times 128 \text{ muestras} \quad (4.11)$$

Aunque se haya reducido la dimensionalidad del conjunto de características mediante el submuestreo previo del EEG en crudo, el número total de características que componen la entrada del clasificador sigue siendo inmenso. Por lo tanto, el SVM estará, probablemente, sobre-entrenado. Sorprendentemente, este tipo de técnicas obtienen, en la literatura, los mejores resultados de clasificación en el paradigma *P3Speller*, a pesar de este hecho [45][46][50].

Como se puede observar en la Figura 4-6, la salida del clasificador retorna un *score* para cada una de las iluminaciones. Obviamente, cuando se trabaja a tiempo-real no se puede determinar qué comando ha deseado seleccionar el usuario hasta que no se reciban los *scores* para todas las iluminaciones de cada fila y de cada columna. Una vez hallados, se suman los *scores* de cada una de las filas y de cada una de las columnas y se escogen la fila y la columna que han obtenido valores más altos. De esta manera, se halla el comando que ha querido seleccionar el usuario determinando cuál es la celda donde se forma la intersección de la fila y la columna escogidas.

b.2) Ensemble of SVMs

Un e-SVM es un conjunto de SVMs que trabajan juntos para clasificar un conjunto de características determinado. La estrategia para converger la decisión se

basa en un algoritmo de votación, es decir, la clase final de cada característica será la que obtenga la mayor probabilidad teniendo en cuenta el *score* obtenido en cada uno de los SVM empleados. La votación, comúnmente conocida como *voting*, es la estrategia más común de combinar varios clasificadores en la investigación BCI, probablemente debido a su sencillez y eficiencia [49][51][54]. De hecho, el ganador de la III Competición de BCI en 2003 empleó un e-SVM en la clasificación del *data set II*, correspondiente al *P3Speller* [51]. En este trabajo se ha utilizado un algoritmo similar.

En concreto, se ha utilizado un conjunto de 4 SVMs lineales, similares al s-SVM anteriormente explicado. Para calibrar los clasificadores, los datos de entrenamiento se dividen en 4 particiones y se introducen en cada uno de los SVM. Obviamente, en el momento de utilizar la clasificación real se introduce el mismo conjunto de datos en todos ellos, y se obtiene una ristra de *scores* por cada SVM. Para tener en cuenta la contribución de todos ellos, se suman los *scores*. A partir de aquí, se procede como en s-SVM: se determina la fila y la columna con los valores más altos y se halla la celda seleccionada por el usuario. En este caso se han registrado 24 intentos como datos de entrenamiento para cada uno de los usuarios. Por tanto, las particiones de cada SVM se componen de 6 intentos por usuarios. En la Figura 4-7 se ilustra la técnica empleada.

$$score_{total} = \sum_{i=1}^4 y_i \quad (4.12)$$

b.3) Parámetro de regularización

Según lo explicado anteriormente, en un SVM se puede introducir un parámetro de regularización C que controla el equilibrio óptimo entre obtener un margen de separación amplio y un pequeño número de características clasificadas erróneamente. La introducción de este parámetro regula el tiempo necesario para

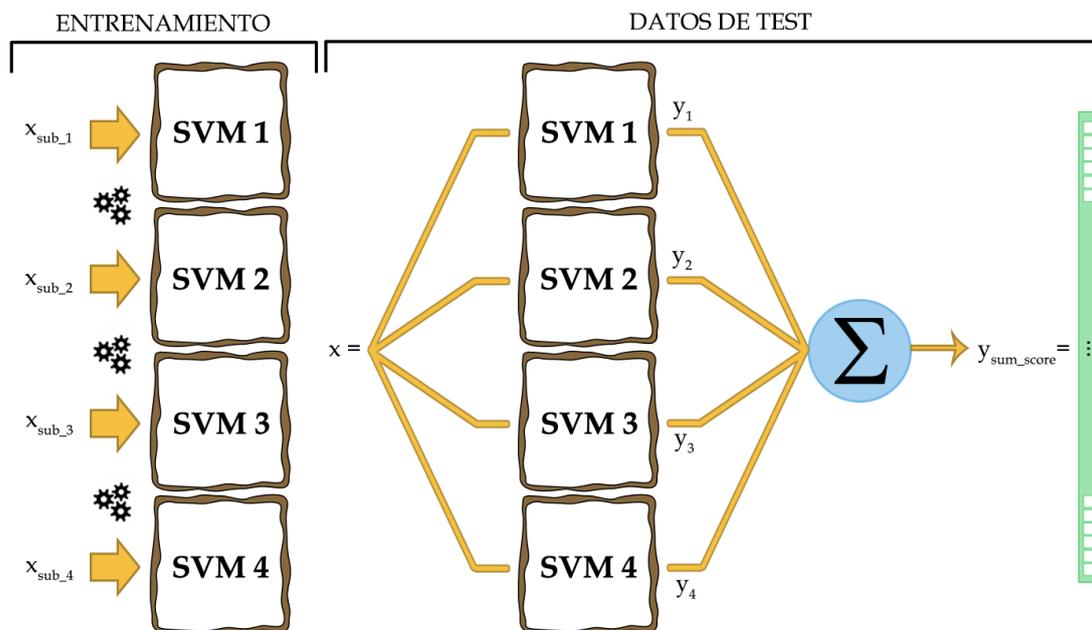


Figura 4-7. Combinación de 4 SVMs en e-SVM, con una técnica de *voting*. Cada uno de los SVM se entrena con una partición x_{sub_i} . En la clasificación real, se introduce el mismo conjunto de datos x en todos ellos y obtiene un conjunto de *scores* y_i . Finalmente, los *scores* se suman para tener en cuenta la contribución de todos ellos.

entrenar un SVM, el número de errores a cometer y el sobre-entrenamiento que puede sufrir [48].

En este caso se ha empleado una validación cruzada dejando uno fuera. Esta técnica se utiliza para optimizar algoritmos de clasificación paramétricos, ayudando a seleccionar el valor escalar más óptimo del parámetro a estudiar, entendiendo como clasificación óptima aquella que obtenga un menor número de características clasificadas erróneamente.

Para ello, se han utilizado las particiones de los datos de entrenamiento del apartado b.2). El procedimiento ha consistido en entrenar un s-SVM con tres de las particiones, dejando una fuera, utilizada como dato de *test*. Se han obtenido las precisiones de la clasificación de cada usuario dejando fuera cada una de las particiones para los siguientes valores de $C = \{0.1, 0.5, 1\}$ [51]. Promediando las precisiones de todos los usuarios EM para cada uno de los valores se obtienen los resultados de la Figura 4-8.

Parece obvio pensar que el parámetro de regularización óptimo depende del número de muestras de cada iluminación, puesto que a mayor número de muestras, más grande será el conjunto de características, y requerirá un valor de C más restrictivo. No obstante, en este caso el valor máximo de precisión es $C = 0,1$ para todas las muestras estudiadas por iluminación. Probablemente, si se escogiesen números totales de muestras más altos, el valor del parámetro de regularización óptimo disminuiría. Sin embargo, parece que para el número de muestras escogidas no se observan grandes diferencias. Las precisiones medias obtenidas en detalle se pueden consultar en la Tabla 4-2.

Por tanto, en el presente estudio, cuando se usan SVMs se emplea el mismo parámetro de regularización para todas las muestras: $C = 0,1$, puesto que ha adquirido las mejores precisiones en una validación cruzada con los datos de entrenamiento.

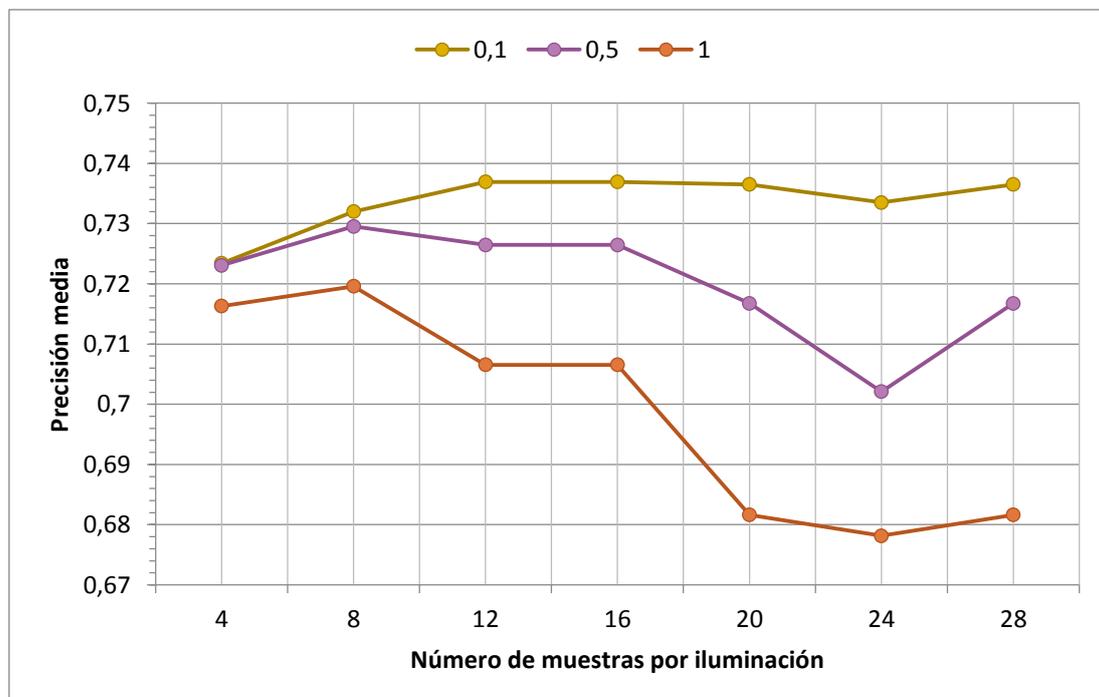


Figura 4-8. Promedio de las precisiones obtenidas para la validación cruzada dejando uno fuera para varios valores del parámetro de regularización para los sujetos EM.

TABLA 4-2. PRECISIONES MEDIAS OBTENIDAS PARA LA VALIDACIÓN CRUZADA DEJANDO UNO FUERA.

		Parámetro de regularización		
		0,1	0,5	1
Número de muestras	4	72,34%	72,31%	71,63%
	8	73,20%	72,95%	71,96%
	12	73,69%	72,64%	70,66%
	16	73,69%	72,64%	70,66%
	20	73,65%	71,67%	68,16%
	24	73,35%	70,21%	67,81%
	28	73,65%	71,67%	68,16%

4.2.4. Umbralización

Al clasificar cada iluminación y asignar pesos a cada una de ellas para determinar cuál es, en el caso del *P3Speller*, la fila y columna que ha querido seleccionar el usuario, se establece que los estímulos P300 con mayor peso son los seleccionados.

Sin embargo, puede darse el caso de que el usuario no haya querido seleccionar nada puesto que no estaba atendiendo a la presentación de los estímulos. En ese caso el clasificador establecerá una selección igualmente escogiendo los máximos *scores*, aunque la intensidad de cada estímulo sea más baja de lo normal, atendiendo a un paradigma síncrono. Como solución a este problema se propone la implementación de un umbral que decida cuándo tener en cuenta la decisión del clasificador y cuándo no, con el fin de evitar selecciones indeseadas por el usuario, conformando la asincronía de la aplicación desarrollada.

El umbral óptimo utilizado en el presente trabajo se basa en la curva ROC resultante de representar la sensibilidad y especificidad obtenidas en las sesiones de calibración de los usuarios, procedimiento explicado a continuación.

a) Curvas ROC

Una curva ROC (acrónimo de *Receive Operating Characteristic*, o Característica Operativa del Receptor) es una representación gráfica de la *sensibilidad* frente a *1-especificidad* para un sistema de clasificación binario.

Considerando un problema de predicción de clases binario en el que las clases se etiquetan como positivas **P** o negativas **N**, existen cuatro tipos de resultados tras la clasificación. Por ejemplo, si se intentase clasificar la presencia de una enfermedad en ciertos sujetos y se etiquetase como positivos a los enfermos y como negativos a los sujetos sanos, ésta clasificación podría causar una de las cuatro situaciones siguientes:

1. **TP** (*True Positives*, o Verdaderos Positivos): Cuando las clases positivas **P** se clasifican como positivas **P**, es decir, los sujetos enfermos se diagnosticarían correctamente como enfermos.
2. **FP** (*False Positives*, o Falsos Positivos): Cuando las clases negativas **N** se clasifican como positivas **P**, es decir, los sujetos sanos se diagnosticarían erróneamente como enfermos.

3. **TN** (*True Negatives*, o Verdaderos Negativos): Cuando las clases negativas **N** se clasifican como negativas **N**, es decir, los sujetos sanos se diagnosticarían correctamente como sanos.
4. **FN** (*False Negatives*, o Falsos Negativos): Cuando las clases positivas **P** se clasifican como negativas **N**, es decir, los sujetos enfermos se diagnosticarían erróneamente como sanos.

En la Figura 4-9 se muestran los cuatro posibles resultados en una matriz de confusión según el valor de la clase y la predicción del clasificador. En base a estos cuatro posibles resultados se establecen los siguientes parámetros:

1. **Sensibilidad**: Probabilidad de que las clases positivas **P** se clasifiquen correctamente, es decir, probabilidad de que el clasificador determine enfermedad cuando es aplicado sobre una población de sujetos enfermos.

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (4.13)$$

2. **Especificidad**: Probabilidad de que las clases negativas **N** se clasifiquen correctamente, es decir, probabilidad de que el clasificador determine ausencia de enfermedad cuando es aplicado sobre una población de sujetos sanos.

$$\text{Especificidad} = \frac{TN}{TN + FP} \quad (4.14)$$

3. **Precisión**: Probabilidad de que ambas clases se clasifiquen correctamente, es decir, probabilidad de que un sujeto, esté sano o enfermo, se clasifique correctamente.

$$\text{Precisión} = \frac{TP + TN}{TP + FP + FN + TN} \quad (4.15)$$

4. **PPV** (*Positive Predictive Value*, o Valor Predictivo Positivo): Probabilidad de que una clase clasificada como positiva **P** sea realmente positiva **P**, es decir, probabilidad de que un sujeto clasificado como enfermo esté realmente enfermo.



Figura 4-9. Matriz de confusión que recoge los cuatro posibles resultados tras aplicar un clasificador binario: las columnas establecen el valor real de la clase y las filas el valor predicho por el clasificador.

$$PPV = \frac{TP}{TP + FP} \tag{4.16}$$

5. **NPV** (*Negative Predictive Value*, o Valor Predictivo Negativo): Probabilidad de que una clase clasificada como negativa **N** sea realmente negativa **N**, es decir, probabilidad de que un sujeto clasificado como sano esté realmente sano.

$$NPV = \frac{TN}{TN + FN} \tag{4.17}$$

La curva ROC está íntimamente ligada con la sensibilidad y la especificidad de las dos clases de datos, concretamente, representa en el eje de abscisas *1-especificidad* y en el eje de ordenadas la *sensibilidad*. La finalidad de las curvas ROC es la determinación de un umbral de decisión que permita dividir las dos clases de datos de manera óptima.

El primer paso para la construcción de una curva ROC es establecer una serie de umbrales μ_k que se recorrerá sucesivamente. Posteriormente, se calcula la sensibilidad y la especificidad de ambas clases para cada umbral y finalmente se representa gráficamente con los ejes descritos. En conclusión, se deben obtener tantos pares sensibilidad-especificidad como umbrales se hayan definido. En la Figura 4-10 se aprecian los valores de la curva ROC para tres umbrales distintos.

Los datos que se encuentren por debajo del umbral elegido se considerarán negativos **N** y los que se encuentren por encima se considerarán positivos **P**. Tal y como se puede observar, el umbral indicado como μ_1 clasifica correctamente a todos los negativos **N** pero incorrectamente a todos los positivos **P** y, por tanto, su especificidad será de 1 y su sensibilidad será nula. El umbral indicado como μ_2 clasifica correctamente a casi todos los positivos **P**, aunque posee errores de clasificación para ambas clases y, por tanto, su especificidad y su sensibilidad serán mayores que 0 pero menores que 1. Finalmente, el umbral indicado como μ_3 clasifica correctamente a todos los positivos **P** pero incorrectamente a todos los negativos **N** y, por tanto, su especificidad será nula y su sensibilidad valdrá 1.

Una vez construida la curva es necesario establecer el umbral óptimo para la clasificación. El punto óptimo se encontraría en (0,1) puesto que la especificidad y la sensibilidad serían máximas, clasificando correctamente a todas las clases. Sin embargo, una curva ROC solamente contendrá este punto si ambas distribuciones están completamente separadas. Cuando las distribuciones están solapadas, se establece el umbral óptimo en el punto que minimice la distancia hasta el punto óptimo, tal y como muestra la Figura 4-11.

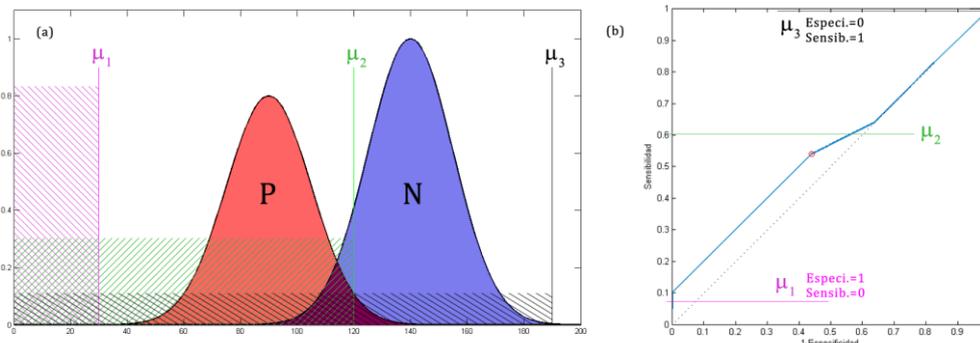


Figura 4-10. Construcción de una curva ROC (b) para las clases positivo (P) y negativo (N) con distribuciones gaussianas (a).

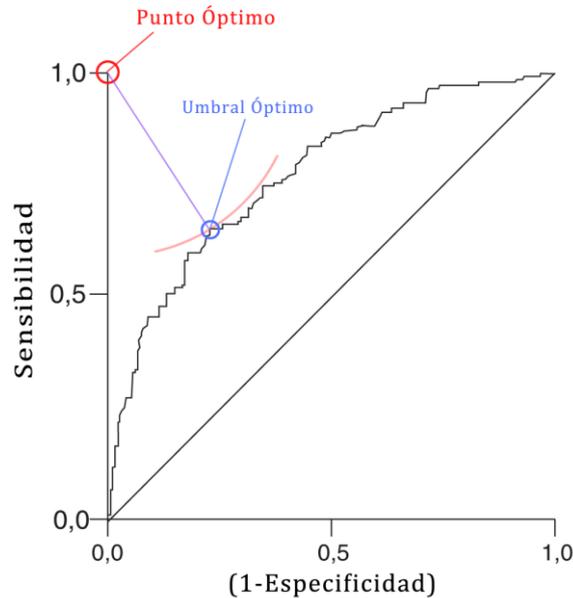


Figura 4-11. Detección del umbral óptimo: punto que minimiza la distancia entre éste y el punto óptimo de la curva ROC. Este umbral óptimo maximiza el par *Sensibilidad-Especificidad*.

El área bajo la curva ROC indica la robustez del método. Este área posee un valor comprendido entre 0,5 y 1, donde 1 representa un valor diagnóstico perfecto (puesto que clasifica correctamente ambas clases) y 0,5 es una prueba sin capacidad discriminativa diagnóstica (ver Figura 4-12). Si se obtienen valores inferiores a 0,5 se recomienda cambiar el orden de las clases, puesto que la curva es simétrica.

El umbral óptimo típico se establece tal y como se ha explicado anteriormente, sin embargo, la elección del umbral depende completamente de cada caso particular y siempre se verá afectado por el compromiso entre especificidad y sensibilidad. Considerando el caso de sujetos sanos y enfermos nuevamente; en unos casos será preferible descartar el menor número posible de enfermos aunque se diagnostiquen erróneamente sujetos sanos, por ejemplo cuando las consecuencias de la enfermedad sean graves, tendiendo entonces a seleccionar umbrales que proporcionen un mayor valor de sensibilidad; mientras que en otros casos se puede preferir reducir costes y

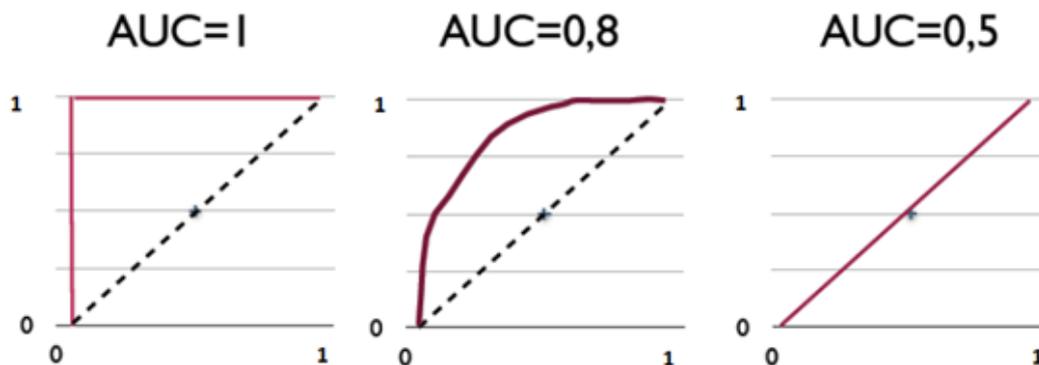


Figura 4-12. Área bajo la curva ROC (AUC) en tres casos distintos. En (a) se obtiene un valor diagnóstico perfecto, en (b) un buen valor diagnóstico y en (c) la peor curva posible, sin valor diagnóstico alguno.

no sobrediagnosticar la enfermedad, tendiendo en estos casos hacia umbrales que supongan un mayor valor de especificidad.

En la aplicación desarrollada en el presente Trabajo Fin de Máster es necesario establecer un umbral para detectar si el usuario atiende a los estímulos del *P3Speller* o, por el contrario, los ignora. En este caso se han realizado pruebas con cada sujeto en dos sesiones distintas. En cada sesión se ha ordenado al usuario atender a ciertos estímulos e ignorar otros, generando datos de manera simétrica. Posteriormente se ha calculado la curva ROC para cada usuario y para cada sesión realizada, eligiendo como umbrales óptimos los umbrales típicos de las curvas ROC. Finalmente, se ha optado por calcular el promedio de ambos umbrales y utilizar éste para clasificar entre atención e indiferencia ante los estímulos.

De esta manera, se establece una aproximación asíncrona, puesto que aunque se busque continuamente una selección de comandos, solamente se seleccionarán cuando el umbral determine que es necesario hacerlo.

APLICACIÓN DE NAVEGACIÓN WEB

5.1. Objetivo de la aplicación

El objetivo principal de la aplicación a desarrollar es desarrollar un navegador web BCI orientado a personas con grave discapacidad que supere las limitaciones de las aproximaciones desarrolladas con anterioridad con el fin de proveer una herramienta rápida, intuitiva y autónoma.

El método seleccionado para registrar la actividad cerebral que permitirá controlar la aplicación es el EEG debido al bajo coste que implica su obtención, a que es un método no invasivo, portátil y de fácil uso. Las señales de control seleccionadas para esta aplicación son los potenciales evocados P300 (al igual que en [26], [27] y [28]), generados a través del paradigma *odd-ball*, puesto que no requieren entrenamiento por parte del usuario y su procesado es rápido y sencillo.

El navegador web a desarrollar deberá ser una aplicación en la que el usuario pueda ser independiente, sin necesidad de contar con ningún supervisor (a diferencia de [23]) y que permita una navegación completa y libre, sin tiempos de lectura predeterminados, es decir, deberá ser una aplicación asíncrona. Las selecciones deberán ser rápidas y el sistema deberá adaptarse al número de hipervínculos de una página web, adecuando la velocidad del sistema en función de éstos.

A continuación se detallan las partes y el desarrollo de la aplicación, además de la evaluación por parte de los usuarios finales y las tareas propuestas con ese fin.

5.2. Partes de la aplicación

Como advierte la Figura 5-1, se pueden distinguir tres partes principales de la aplicación: la adquisición de la señal, la etapa de procesado EEG y la etapa de navegación web.

La parte de adquisición de la señal registra el EEG del usuario a través de los electrodos y el amplificador proporcionados por la empresa *G·Tec*. Además, realiza un pre-procesado de la señal, tal y como se detalló en el capítulo anterior.

La segunda parte de la aplicación, la etapa de procesado EEG, se encarga de procesar la señal EEG a través del sistema de propósito general BCI2000 y una aplicación programada en lenguaje C++. Esta parte de la aplicación filtra la señal y extrae las características de los potenciales P300 generados atendiendo a un paradigma *odd-ball* visual compuesto por dos matrices que intercalará el usuario a voluntad. Para ello, aplica el procesado detallado en el capítulo anterior. Si se desearan visualizar los P300 de cada usuario, se requeriría utilizar un promediado sincronizado de todas las épocas. Finalmente compara la intensidad del potencial para determinar si el usuario ha querido, efectivamente, seleccionar la celda o por el contrario deseaba ignorar los estímulos. Si se supera el umbral, envía una pulsación de teclado correspondiente al comando deseado hacia la siguiente parte de la aplicación; en caso contrario, indica que el umbral no ha sido superado.



Figura 5-1. Estructura principal de la aplicación de navegación web desarrollada.

La tercera y última parte de la aplicación, la etapa de navegación web, se encarga de procesar los comandos de teclado recibidos y traducirlos en comandos del navegador *Google Chrome*. Para ello se ha desarrollado una extensión del mismo basada en el lenguaje JavaScript, cuyo funcionamiento se detalla más tarde.

5.3. Funcionamiento general de la aplicación

Como ya se ha advertido en el apartado anterior, la aplicación consta de tres partes principales que se comunican entre sí para poder proveer al usuario de una navegación completa y libre.

En términos generales, la interfaz gráfica se compone de una matriz de comandos a la derecha de la pantalla y el navegador web *Google Chrome* a la izquierda de la misma. Debido al gran número de comandos necesarios para controlar el navegador web, se han desarrollado dos matrices que se intercalan a voluntad del usuario. Esta interfaz se muestra en la Figura 5-2.

Estas matrices se encargarán de seleccionar el comando que desee el usuario a través del paradigma *odd-ball*. Para ello, se iluminan de manera aleatoria sus filas y sus columnas y se genera un potencial evocado P300 en el EEG de usuario cada vez que la celda que quiera seleccionar se ilumine. Detectando esos potenciales evocados P300 se determina cuál es el comando seleccionado. Sin embargo, éstas matrices no dejan de

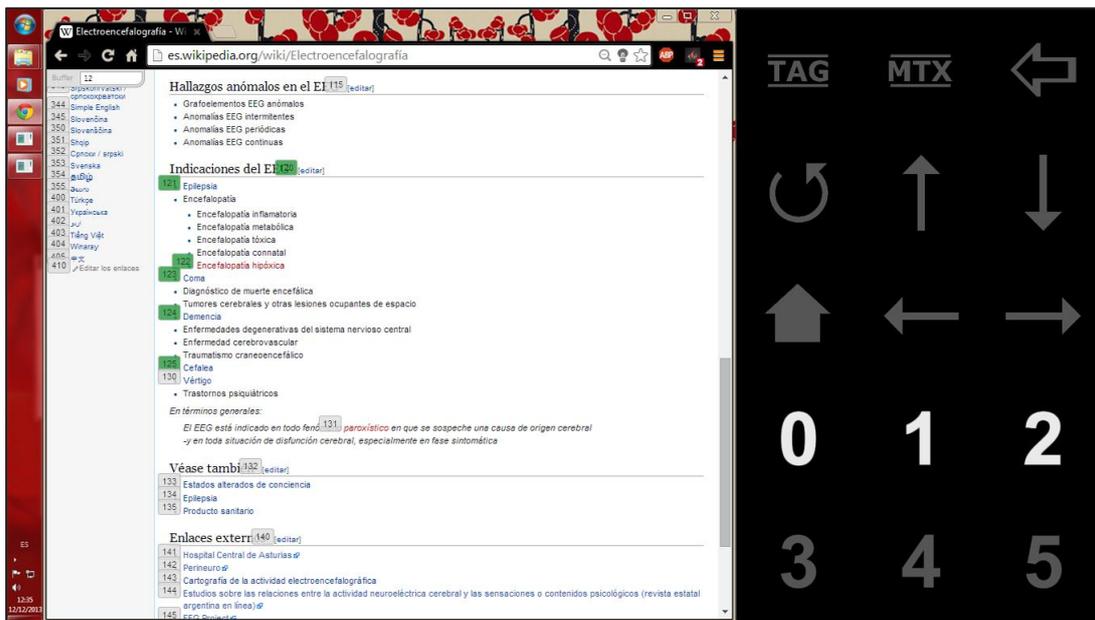


Figura 5-2. Interfaz gráfica de la aplicación desarrollada.

iluminarse en ningún momento, provocando que continuamente se seleccionen comandos no deseados. Por esta razón se ha implementado un umbral que determina si la intensidad del potencial es lo suficientemente alta como para considerarlo como una selección, puesto que el usuario podría estar leyendo la página web tranquilamente. De esta manera, se realiza la conversión de una aplicación síncrona a una asíncrona, donde solamente se seleccionan comandos si el usuario así lo desea. Este umbral varía entre usuarios y se determina en una sesión de entrenamiento previa.

Para seleccionar los hipervínculos de una web y poder navegar entre varias sin necesidad de ningún supervisor, la aplicación codifica y etiqueta los hipervínculos y los formularios de la página web que se esté visualizando. De esta manera, cuando el usuario desee seleccionar un hipervínculo o introducir texto en un formulario, solamente tendrá que introducir la codificación del mismo, la cual estará formada por números del 0 al 5, a través de las matrices de la etapa de procesado EEG.

A continuación, se detallan el diseño y el desarrollo de las partes principales de la aplicación, en términos más específicos.

5.4. Etapa de procesado EEG

La etapa de procesado EEG permite al usuario configurar los distintos parámetros que caracterizarán a la aplicación y se encarga de generar los potenciales evocados P300, de procesar la señal EEG adecuadamente y de determinar si realmente el usuario deseaba seleccionar un comando determinado gracias al umbral.

5.4.1. Sistema de propósito general BCI2000

La implementación del *P3Speller* se realizó con la ayuda del sistema de propósito general BCI2000, junto con una aplicación implementada en C++ [38]. La finalidad del sistema BCI2000 es facilitar el desarrollo, la investigación y la monitorización de aplicaciones en tiempo real que requieren adquirir una señal EEG y procesarla utilizando diversas señales de control.

La estructura de BCI2000 se compone de cuatro módulos que se comunican entre ellos: la "Fuente", el "Procesado de la Señal", la "Aplicación" y el "Operador". Estos módulos son programas independientes y se comunican entre sí a través de un protocolo basado en TCP/IP, sin embargo, dado que esta aplicación no requiere un sistema distribuido, los módulos se comunican en la máquina local. La estructura se puede observar en la Figura 5-3.

La señal EEG se adquiere en el módulo "Fuente" y se procesa de manera síncrona, en bloques que contienen un determinado número de muestras. Cada vez que se adquiere un nuevo bloque de datos, el módulo "Fuente" lo envía al módulo de "Procesado de la Señal", a su vez subdividido en dos partes: extracción y traducción de características, que se encarga de producir señales de control que envía al módulo de "Aplicación". Finalmente, el módulo de "Aplicación" envía la señal EEG analizada y marcada con eventos que facilitan la distinción de las diversas señales de control a utilizar al módulo "Fuente", con el fin de poder realizar un análisis *off-line* gracias al almacenamiento en disco de la señal por parte de este último módulo. El módulo "Operador" se encuentra apartado de este análisis EEG, sin embargo, provee al usuario una interfaz gráfica que permite configurar los distintos parámetros del sistema y visualizar en tiempo-real el análisis de la señal. Por esta razón, el módulo "Operador"

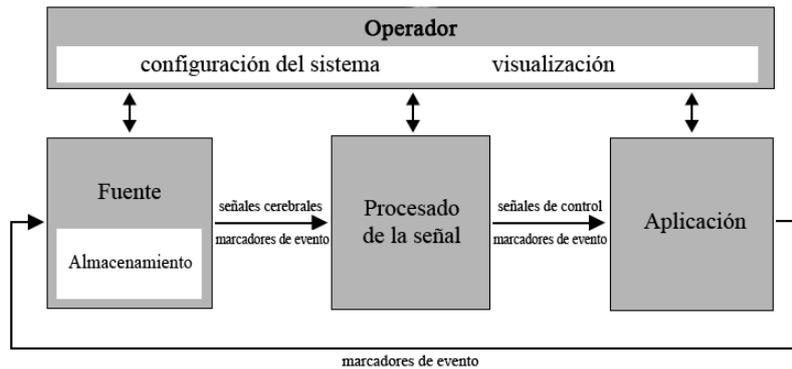


Figura 5-3. Estructura del sistema de propósito general BCI2000, compuesta por cuatro módulos independientes.

se comunica con el resto de módulos y permite al usuario iniciar, parar, suspender o continuar las operaciones que realiza el sistema [38].

En el presente trabajo se ha mantenido el submuestreo utilizado para reducir la dimensionalidad del conjunto de características, sin embargo, se ha adaptado la aplicación para producir los comandos necesarios para la navegación web y para establecer un umbral que permita identificar la intención del usuario en cada momento. Además, se ha estudiado el comportamiento de un clasificador basado en un SVMs, con el fin de aumentar la precisión de SWLDA, utilizado originalmente. Para ello se han modificado principalmente el módulo de “Aplicación” y parte del “Operador”.

5.4.2. Configuración de los parámetros

Nada más iniciar la aplicación se inicia el módulo “Operador”, donde el usuario puede configurar diversos parámetros como la ruta de los archivos *.dat* que generará, el número de canales a analizar, el nombre de los electrodos utilizados, el filtro espacial a utilizar, los pesos del clasificador del usuario, el tamaño y las celdas de las matrices que generan los P300, la duración y el número de las secuencias, la duración de los estímulos o el modo de funcionamiento o el umbral de cada usuario, entre otros. En la Figura 5-4 aparece la interfaz gráfica del “Operador”.

La aplicación está optimizada para pantallas panorámicas, donde aproximadamente 2/3 de la longitud horizontal de la pantalla los ocupará el navegador web *Google Chrome* y el 1/3 restante lo ocupará una matriz de selección de comandos, utilizada para generar los potenciales evocados P300 y poder controlar el navegador web. La estructura de la interfaz gráfica aparece representada en la Figura 5-5. Teniendo en cuenta estos aspectos, se recomienda modificar los parámetros oportunos en el “Operador” como sigue, si consideramos como X a la longitud horizontal y como Y a la longitud vertical de la pantalla en píxeles.

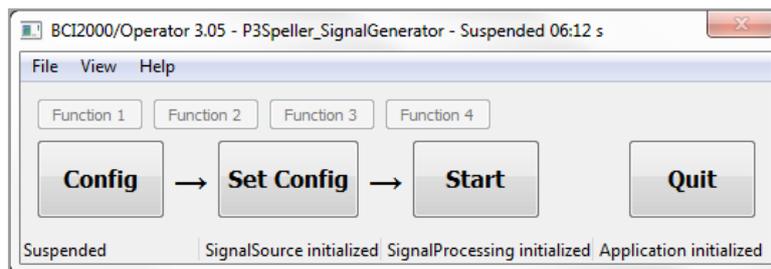


Figura 5-4. Interfaz gráfica del “Operador”, donde se configuran los parámetros relativos a la aplicación, además de permitir el control de ésta a tiempo real.

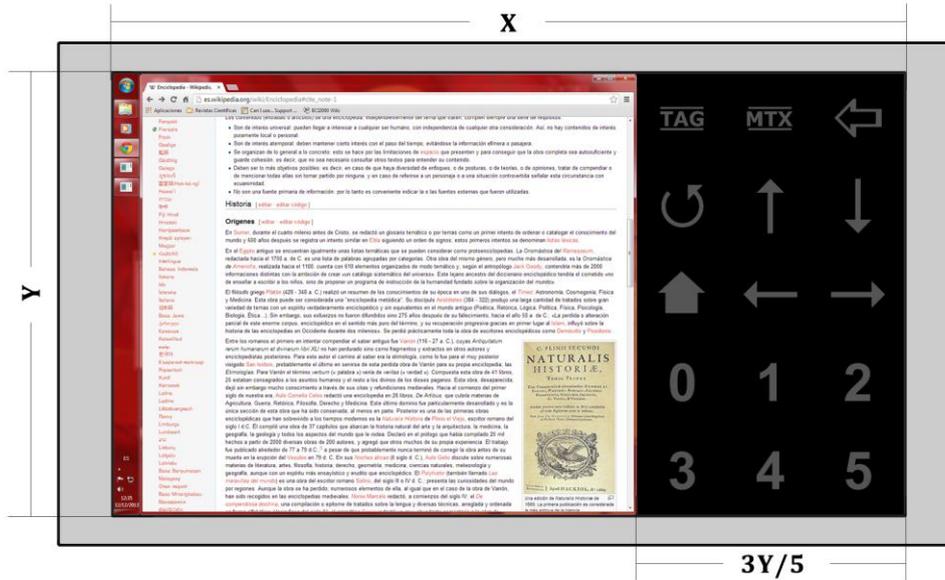


Figura 5-5. Optimización de la aplicación para pantallas panorámicas con relación de aspecto 16:9.

$$WindowHeight = Y; WindowWidth = \left[\frac{3}{5} \cdot Y \right] \text{ y } WindowLeft = X - WindowWidth \quad (5.1)$$

Antes de iniciar la aplicación es necesario establecer ciertos parámetros que determinarán el funcionamiento del paradigma *odd-ball*. Considerando como un intento (*o trial*) la selección de un comando determinado, éste puede descomponerse en una serie de fases cuya duración programa el usuario en función de la finalidad que tenga cada sesión. A continuación se exponen los parámetros involucrados y en la Figura 5-6 se muestra la línea de tiempo de cada intento [38].

- **PreRunDuration.** Establece la pausa que inicia el intento.
- **PreSequenceDuration.** Establece la pausa que precede a la primera secuencia. Se considera como una secuencia la iluminación de todas las filas y de todas las columnas que componen la matriz y, por tanto, el número de secuencias de cada intento es equivalente al número de veces que se va a iluminar cada fila y cada columna antes de determinar la selección del usuario. Por ejemplo, para la matriz de navegación, de tamaño 5x3, una secuencia se corresponde con “5+3 = 8” iluminaciones.
- **StimulusDuration.** Establece la duración del estímulo visual, es decir, cada iluminación.
- **ISIMinDuration, ISIMaxDuration.** Establecen la duración mínima y máxima del intervalo entre estímulos, respectivamente. Especifican el tiempo que pasa entre dos iluminaciones, siendo éste aleatorio, con una distribución uniforme para los valores intermedios.
- **PostSequenceDuration.** Establece la pausa que sigue a la última secuencia del intento.
- **PostRunDuration.** Establece la pausa que finaliza el intento.
- **NumberOfSequences.** Número de secuencias que compondrán un solo intento. Este valor debe ser el mismo que el del parámetro *EpochsToAverage*, el cual determina el número de épocas que deben considerarse en el promediado sincronizado (la duración de las mismas la establece *EpochLength*).

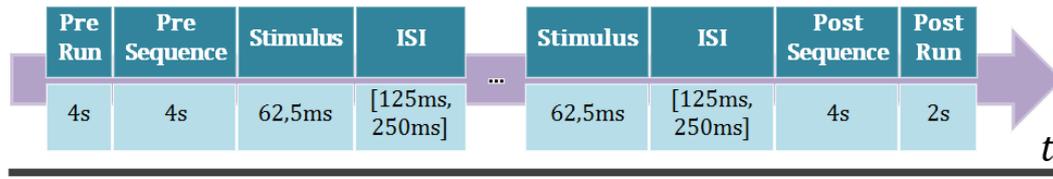


Figura 5-6. Línea de tiempo de cada intento de la etapa de procesamiento EEG.

- **Threshold.** Indica el umbral óptimo de cada usuario para determinar si se debe considerar o no la selección realizada.

5.4.3. Matrices *odd-ball*

A causa del gran número de comandos necesarios para poder experimentar una navegación web libre de restricciones se han desarrollado dos matrices *odd-ball* distintas que se intercalan entre ellas a voluntad del usuario. Estas matrices son la matriz de navegación y la matriz de teclado.

La matriz de navegación es una matriz pequeña, compuesta por 5 filas y 3 columnas, con 15 celdas en total. En esta matriz se incluyen únicamente los comandos que afectan a la navegación web, como los *scrolls*, el retroceso de página, la actualización del navegador, etcétera. El pequeño tamaño de esta matriz provoca que la navegación a través de las distintas páginas web sea rápida debido a que se necesitan un menor número de iluminaciones para seleccionar cada comando deseado, por esta razón se han omitido la mayor parte de los caracteres alfanuméricos habituales, más útiles para la redacción que para la navegación web. En la Figura 5-7 aparece la matriz de navegación y a continuación se explican los distintos comandos que contiene.

- (1) El primer comando, denominado "TAG", es un conmutador que permite activar o desactivar el etiquetado de nodos (hipervínculos y formularios) por parte de la etapa de navegación web. De esta manera, el usuario puede leer tranquilamente una web sin etiquetas y activarlas cuando desee navegar a través de los hipervínculos o introducir algo en los formularios.
- (2) El segundo comando, denominado "MTX", es otro conmutador que permite alternar entre la matriz de navegación y la matriz de teclado.
- (3) El tercer comando ("↶", *back/forward*) permite retroceder a la última web visitada. Si se vuelve a seleccionar el comando inmediatamente después, elimina el retroceso, es decir, avanza a la siguiente web del historial, resultando en la web de partida. Gracias a esta doble funcionalidad, permite subsanar un posible error de una manera rápida y sencilla.
- (4) El cuarto comando ("↻", *reload*) permite actualizar la web que se está visualizando.
- (5) El quinto comando ("↑", *scroll up*) permite mover la barra de desplazamiento hacia arriba, equivalente a una pulsación de teclado habitual denominada "Re Pág", o retroceso de página.
- (6) El sexto comando ("↓", *scroll down*) permite mover la barra de desplazamiento hacia abajo, equivalente a una pulsación de teclado habitual denominada "Av Pág", o avance de página.
- (7) El séptimo comando ("🏠", *home*) permite ir a la página de inicio.

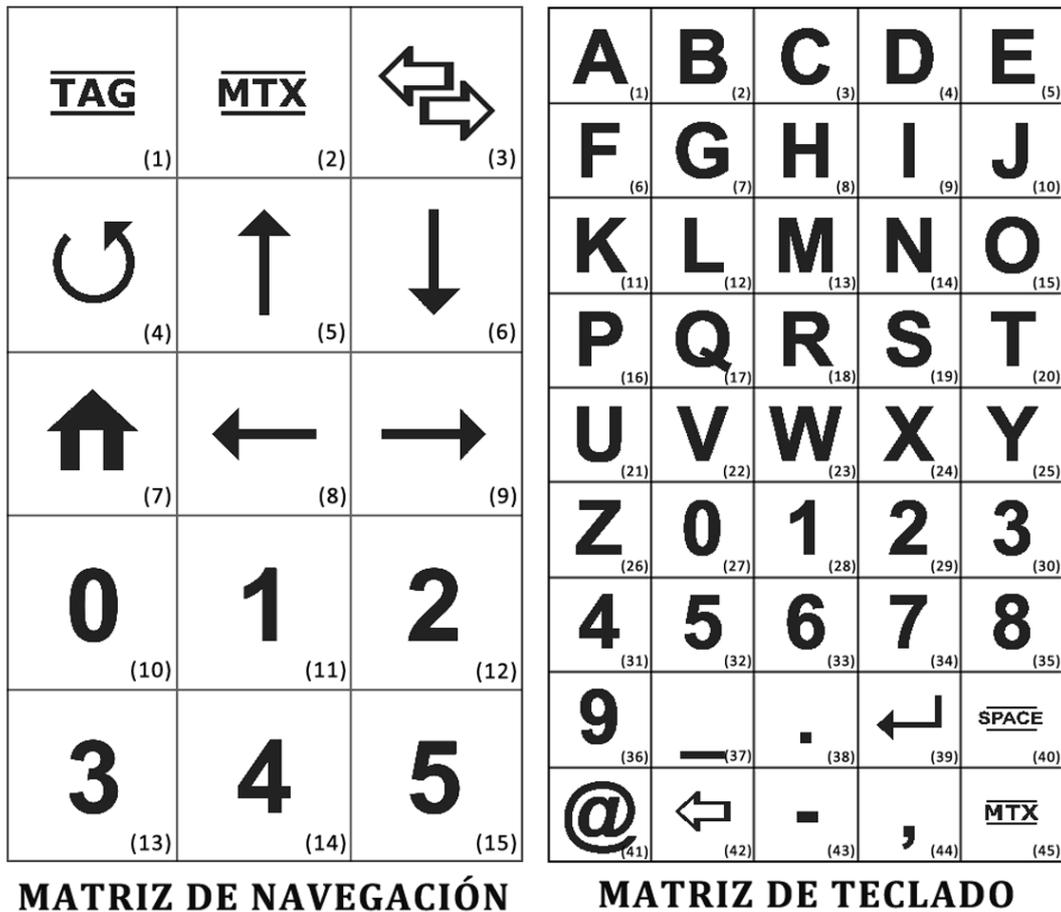


Figura 5-7. Matrices utilizadas en la parte del procesado EEG de la aplicación desarrollada. A la izquierda se muestra la matriz de navegación, a la derecha, la matriz de teclado.

- (8) El octavo comando (“←”) es, posiblemente, el que más funciones puede realizar en toda la aplicación. Este comando varía su función dependiendo del estado del programa: si el conmutador “TAG” no está activo y, por tanto, no se ha activado el etiquetado de los nodos de la web, la función de “←” es la de un desplazamiento horizontal de la web hacia la izquierda (*scroll left*); por el contrario, si el conmutador “TAG” sí está activo y los nodos están etiquetados, la función del comando variará dependiendo de si el cursor se encuentra dentro de un formulario o no. Si no se ha seleccionado ningún formulario, la función de “←” será la de borrar el último carácter introducido en el *buffer*, sin embargo, si el cursor se encuentra dentro de un formulario, “←” permitirá abandonar el mismo para poder seleccionar otro nodo distinto. Las funciones de “←” vienen recogidas en el diagrama de flujo de la Figura 5-8.
- (9) El noveno comando (“→”, *scroll right*) permite mover la barra de desplazamiento hacia la derecha.
- (10), (11), (12), (13), (14) y (15) Los siguientes comandos simplemente envían una pulsación de teclado de los cinco posibles números que se utilizan para codificar los nodos en la etapa de navegación web. La finalidad de incluir estos caracteres alfanuméricos en la matriz de navegación no es otra que agilizar las selecciones de nodos, tal y como se ha explicado anteriormente.

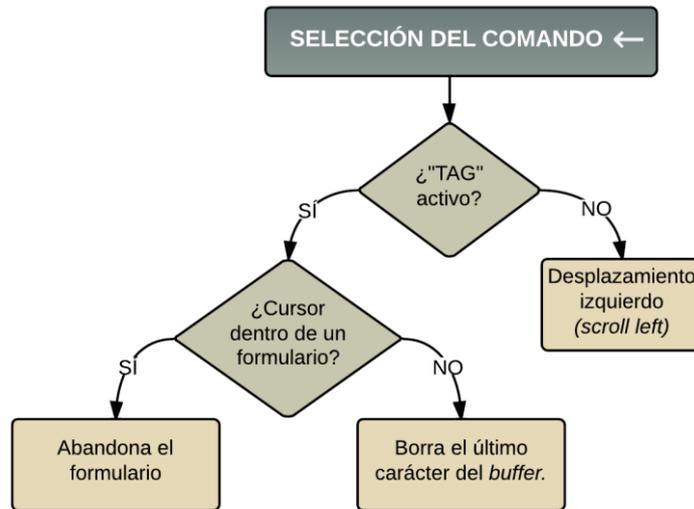


Figura 5-8. Funciones del comando “←” de la matriz de navegación en función del estado de la aplicación en el momento de su selección.

A diferencia de la matriz de navegación, la matriz de teclado es una matriz grande, compuesta por 5 columnas y 9 filas, resultando en 45 celdas en total. Esta matriz está especialmente destinada para redactar o rellenar formularios. Cuenta con la mayor parte de caracteres alfanuméricos y con los símbolos más utilizados en la jerga de Internet. Atendiendo a la Figura 5-7, desde el comando (1) hasta el (26) se corresponden con las letras del alfabeto latino y simplemente se encargan de enviar las pulsaciones de teclado adecuadas para cada una. Lo mismo ocurre con todos los números, desde el (27) hasta el (36). De ahí en adelante encontramos diversos símbolos.

(37), (38), (39), (40), (41), (42), (43), y (44) Envía las pulsaciones de teclado correspondientes a la barra baja (“_”, *underscore*), al punto (“.”, *point*), al retorno (“↵”, *enter*), a la barra espaciadora (“ ”, *spacebar*), a la arroba (“@”, *at*), al retroceso (“↶”, *backspace*), al guión (“-”, *dash*) y a la coma (“,”, *comma*), respectivamente.

(45) Aparece el comando “MTX” de nuevo, conmutador que permite alternar entre la matriz de navegación y la matriz de teclado.

La matriz predeterminada al iniciar la aplicación es la matriz de navegación. No obstante, indistintamente de cuál sea la matriz que está activada en cada momento, ésta iluminará continuamente sus filas y sus columnas y no parará a no ser que se detenga la aplicación. Esto hace necesario la introducción de un umbral de decisión que establezca cuándo una pulsación de teclado debe enviarse a la etapa de navegación web y cuándo no. Este umbral se determina mediante el procedimiento descrito en el capítulo anterior.

Adicionalmente, se incluye una funcionalidad de pausa, útil para el primer contacto del usuario con la aplicación, puesto que un supervisor puede aprovechar para explicar los distintos comandos de la misma mientras la aplicación se encuentra pausada. Dicha funcionalidad se activa presionando la letra “P” en cualquier momento, sin afectar negativamente al registro del EEG. Para retomarla en el punto en el que se había pausado, basta con presionar la misma tecla otra vez.

5.5. Etapa de navegación web

Tal y como se ha explicado anteriormente, la etapa de navegación web se encarga de procesar los comandos de teclado recibidos de la etapa de procesado EEG y traducirlos en comandos del navegador *Google Chrome*.

Para ello se ha desarrollado una extensión del mismo en lenguaje JavaScript que interpreta las pulsaciones de teclado y actúa en consecuencia. La función más relevante de la extensión es la de etiquetar todos los hipervínculos y formularios existentes en la página web que se está visualizando con uno o varios caracteres numéricos. El usuario podrá seleccionar el hipervínculo o formulario deseado introduciendo esos caracteres, consiguiendo así una navegación libre controlada plenamente por el usuario.

Para facilitar la fluidez de la aplicación, el número de caracteres numéricos que se utilizan para etiquetar los hipervínculos y los formularios, considerados ambos como *nodos* de la web, depende de la página que se esté visualizando. En primer lugar, la aplicación calcula el número de nodos que contiene la web y codifica éstos con un número de caracteres que permita etiquetarlos todos utilizando únicamente los números 0, 1, 2, 3, 4 y 5.

Una vez codificados y etiquetados se inicializa un *buffer* en la parte superior izquierda del navegador que servirá de realimentación al usuario para poder visualizar los caracteres que escribe mientras intenta seleccionar un nodo determinado. Además de indicar qué caracteres se han escrito anteriormente, el *buffer* indica qué nodos comienzan con la misma codificación, proveyendo al sistema de una realimentación intuitiva y a tiempo real. En la Figura 5-9 se muestra un ejemplo en el que el usuario ha introducido un "0", el *buffer* lo indica e ilumina los nodos que empiezan con esa codificación y, por tanto, pueden ser selecciones en potencia.



Figura 5-9. Etiquetado de hipervínculos en la etapa de navegación web. En rojo se indica la posición del *buffer* que contiene el carácter introducido por el usuario, en verde los nodos posibles que concuerdan con la codificación introducida (o posibles selecciones en potencia) y en gris el resto de nodos que no pueden seleccionarse con esa codificación.

Como medida preventiva para aumentar la rapidez de la selección de nodos, la aplicación simula la introducción de un “ENTER” cuando el usuario ha introducido en el *buffer* el número necesario de caracteres para seleccionarlo, evitando así la creación de un comando adicional para confirmar la introducción de teclas en el *buffer* y disminuyendo el tiempo necesario para realizar la selección. Adicionalmente, el *buffer* permite borrar los caracteres introducidos si el usuario ha fallado en la selección del comando deseado.

Además de las funciones descritas, la activación o no de la extensión también está gobernada por el usuario. El usuario decide si activar el etiquetado de nodos o no activarlo, puesto que éstos pueden ser molestos si el usuario desea leer tranquilamente una página web que está cargada de hipervínculos.

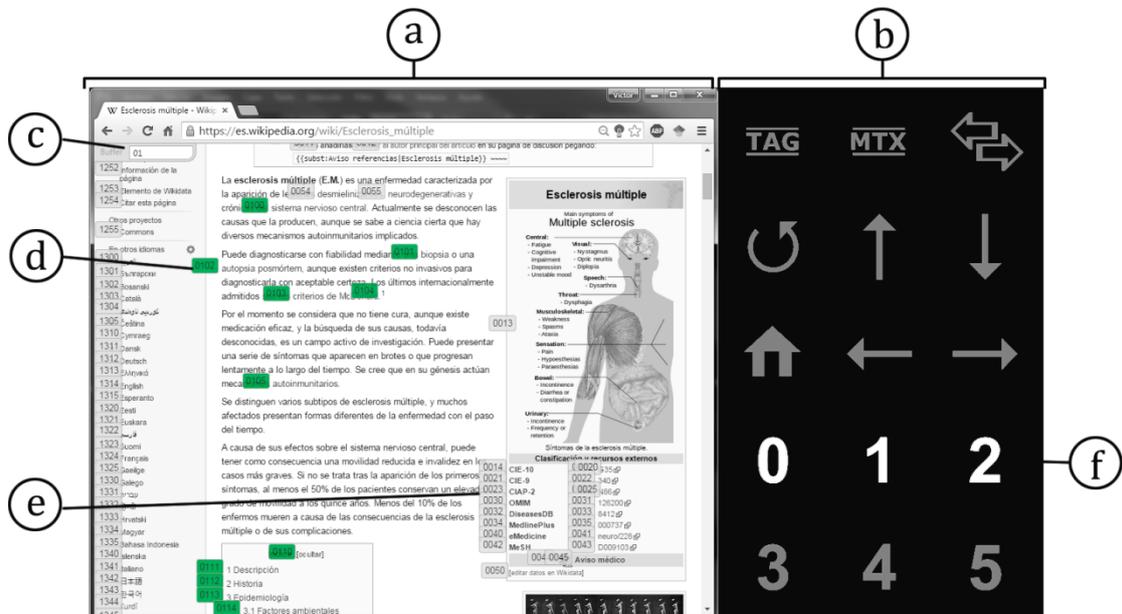
5.6. Guía de usuario

Para facilitar la comprensión del funcionamiento de la aplicación a los usuarios, se ha desarrollado una guía de usuario que resume brevemente sus funcionalidades y cómo se utiliza la misma.

GUÍA DE USUARIO NAVEGACIÓN WEB MEDIANTE SISTEMAS P300-BCI

Una vez tenga el gorro con los electrodos colocados y se haya aplicado el gel estará preparado/a para navegar por Internet. Es importante que mueva la cabeza o cualquier extremidad lo menos posible para no dificultar la navegación. El habla, los estornudos y el movimiento de la mandíbula también deben evitarse.

I. Estructura de la aplicación



- a. Navegador web *Google Chrome*.
- b. Matriz de selección de comandos.
- c. Indicador de comandos seleccionados.
- d. Etiqueta de enlace posible.
- e. Etiqueta de enlace ignorado.
- f. Fila de la matriz iluminada en ese instante.

El navegador que muestra las páginas web aparece a la izquierda de la pantalla (a) y a la derecha se sitúa la matriz de selección (b). Esta matriz contiene los comandos que deberá seleccionar para navegar por Internet.

II. Selección de comandos

Para seleccionar un comando basta con mirar fijamente a su icono. Mientras tanto, la matriz iluminará aleatoriamente (f) sus filas y columnas. No pierda la concentración, una estrategia recomendable para asegurarse de que fija usted la vista correctamente es contar cuántas veces se ilumina el icono que quiere seleccionar. Tras un número determinado de selecciones, el comando se seleccionará y podrá ver el resultado en el navegador.

III. Navegación a través de los enlaces

Navegar a través de los enlaces de las webs es sencillo. Para ello, seleccione el comando "TAG" de la matriz de menor tamaño. Verá que se colocan unas etiquetas al lado de cada uno de los enlaces de la web, identificándolos con varios números. Para seleccionar el enlace deseado, basta con seleccionar los números en las matrices de selección de comandos.

Además, una vez introducido algún número, las etiquetas que empiecen por tales números se pondrán verdes, indicando que son selecciones posibles (d). El resto se mantendrá de color gris (e). En la parte superior izquierda del navegador se incluye un indicador (c) que marca los números introducidos hasta el momento.

IV. Matrices de selección

Existen dos matrices de selección distintas, la primera es útil para navegar rápidamente a través de las páginas web y la segunda es necesaria para poder rellenar formularios o escribir. Son las siguientes:

TAG	MTX		TAG Activa o desactiva el etiquetado de enlaces
			MTX Cambia a la matriz de teclado
			(1) Retrocede a la página web anterior (2) <u>Avanza</u> a la página siguiente si antes se ha retrocedido
			 Recarga la página web
			 Desplaza la página web hacia arriba
			 Desplaza la página web hacia abajo
			 Cambia a la página de inicio
			 Desplaza la página web hacia la derecha
			(1) Desplaza la página web hacia la izquierda (2) Borra un carácter del buffer si está activo (3) Abandona un formulario de texto
			0:5 Escribe los números comprendidos del 0 al 5

A	B	C	D	E	A:z	Escribe las letras comprendidas de la A a la Z
F	G	H	I	J	0:9	Escribe los números comprendidos del 0 al 9
K	L	M	N	O	-	Escribe una barra baja
P	Q	R	S	T	.	Escribe un punto
U	V	W	X	Y	↵	Simula la pulsación de un "intro" o "enter"
Z	0	1	2	3	SPACE	Escribe un espacio
4	5	6	7	8	@	Escribe una "arroba"
9	-	.	↵	SPACE	←	Borra el último carácter introducido
@	←	-	,	MTX	-	Escribe un guión
					,	Escribe una coma
					MTX	Desplaza la página web hacia la derecha

V. Funcionalidad de pausa

Si no tiene intención de seleccionar ningún comando porque desea leer la página web lo único que tiene que hacer es ignorar las iluminaciones de la matriz. Simplemente dirija la vista hacia la página web. Sin embargo, existe una funcionalidad de pausa que podría utilizar usted o alguna persona que esté con usted. Basta con pulsar la letra "P" en el teclado del ordenador para pausar la aplicación de forma permanente. Para reanudarla, pulse de nuevo la misma tecla.

5.7. Procedimiento de evaluación

A continuación se describe el procedimiento seguido tanto en las sesiones de calibración (Cal-I y Cal-II) como en las sesiones de evaluación (Eval-I y Eval-II).

5.7.1. Sesiones de calibración

La calibración del clasificador y el umbral óptimos para cada usuario se realizó en dos sesiones distintas: Cal-I y Cal-II. A su vez, la primera sesión (Cal-I) se dividió en dos partes: entrenamiento del clasificador y entrenamiento del umbral.

a) Entrenamiento del clasificador

El primer objetivo de la primera sesión fue determinar los pesos del clasificador para cada usuario, utilizando el algoritmo SWLDA. Este entrenamiento se realizó con la matriz de mayor tamaño (teclado), puesto que un clasificador adaptado para una matriz amplia servirá perfectamente para una matriz más pequeña, sin embargo, si se realizase al contrario probablemente se obtendrían errores de selección.

Se ordenó a los usuarios intentar escribir una palabra de seis letras cuatro veces con la matriz de teclado, es decir, se emplearon 4 rondas con 6 intentos cada una

de ellas. El número de secuencias fue de 15, en otras palabras, cada fila y cada columna se iluminaron 15 veces; y la duración de cada ronda se encontraba en torno a los 6 minutos. Durante este proceso el usuario debía mirar fijamente a la letra que debía seleccionar.

Una vez completadas todas las rondas se establecieron los pesos del clasificador de cada usuario gracias a la herramienta *P300Classifier*, que provee el sistema BCI2000 (ver Figura 5-10). Para ello se cargan los 4 ficheros *.dat* de cada ronda realizada, generados para cada usuario, y se calcula el vector de pesos. Además de proveer el vector de pesos, la herramienta también establece el número mínimo de secuencias para que un determinado usuario pueda seleccionar cualquier celda satisfactoriamente, pudiendo resultar inferior a las 15 secuencias propuestas inicialmente.

De esta manera, se obtiene el clasificador y el número de secuencias óptimas para cada usuario. Cuanto menor sea ese número, menos iluminaciones son necesarias para llevar a cabo una selección y, por tanto, cada selección se realiza más rápido. No obstante, para poder reducir el número de selecciones es necesario que la precisión obtenida para el usuario en cuestión sea alta, puesto que a menor cantidad de información existe mayor probabilidad de error en la toma de decisión del clasificador.

b) Entrenamiento del umbral

El siguiente objetivo de la sesión fue adquirir muestras para determinar el umbral del usuario. Las muestras de entrenamiento se obtuvieron ordenando a los usuarios realizar dos tareas distintas. La primera tarea consistió en tratar de seleccionar una serie de comandos objetivo con la matriz de navegación. Se registraron 4 rondas, con 6 intentos cada una (los seis comandos), las secuencias y los pesos del clasificador óptimos para cada usuario.

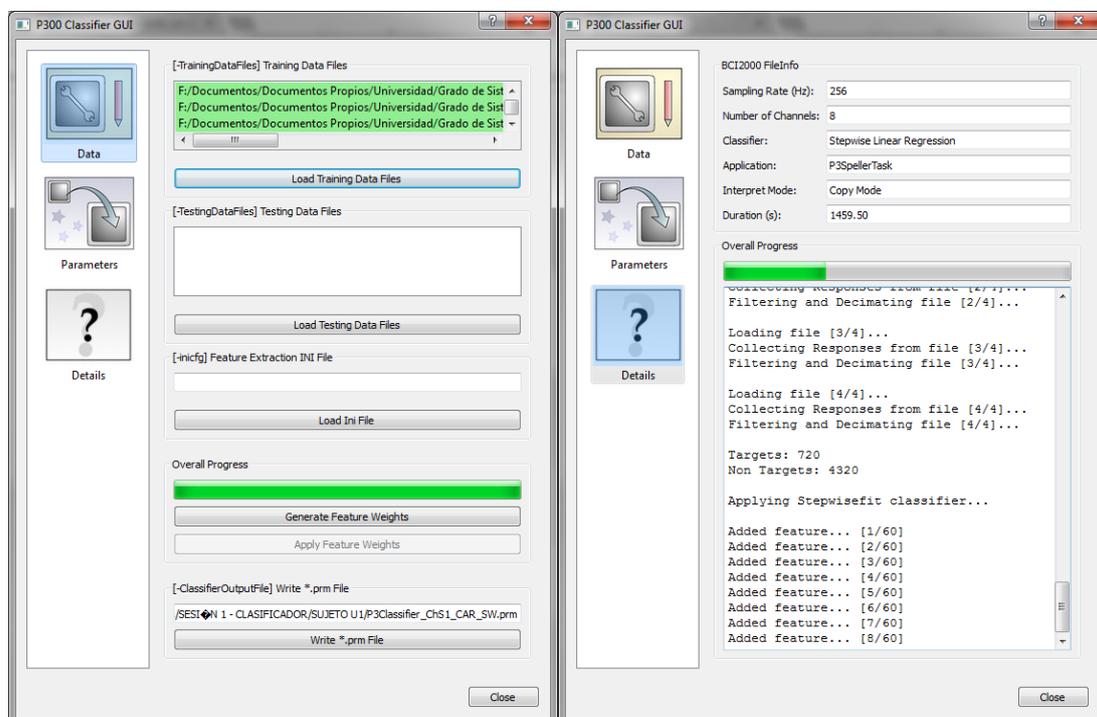


Figura 5-10. Interfaz gráfica de la herramienta *P300Classifier*, utilizada para hallar el vector de pesos del clasificador para cada usuario mediante SWLDA a partir de una serie de muestras de entrenamiento.

La segunda tarea consistió en leer una página web mientras la matriz de navegación seleccionaba comandos de manera aleatoria, es decir, se ordenó al usuario ignorar los estímulos, para ver así la intensidad con la que se recibían éstos y ver las probabilidades de selección con las que trabajaba el clasificador. Se realizaron también 4 rondas con 6 intentos y 10 secuencias por intento.

Como ya es conocido, el umbral óptimo varía entre usuarios y también varía, en menor medida, entre sesiones. Por esta razón se adquirieron las muestras de entrenamiento requeridas para calcularlo en dos sesiones distintas, tanto en Cal-I como en Cal-II.

Una vez obtenidas las 8 rondas de estímulo atendido e ignorado, y considerando los datos de ambos días, se trató de estimar la intensidad de la celda seleccionada en cada intento. Para ello, se extrajeron las probabilidades de selección con las que trabaja el módulo de “Procesamiento de la señal” en BCI2000, relacionadas con el vector de pesos de cada usuario. Una vez extraídas se representó gráficamente cada selección y se halló la curva ROC de los datos para cada sesión, tal y como se muestra en la Figura 5-11. Una vez estimado el umbral óptimo para cada sesión se realizó un promedio entre ambos, resultando en el umbral final del usuario, como expresa la ecuación (5.2).

$$Umbral\ final = (UmbralROC_{S1} + UmbralROC_{S2})/2 \quad (5.2)$$

Antes de introducir las sesiones de evaluación, cabe destacar que en los casos en los que durante la primera sesión, Cal-I, el usuario no alcanzó un nivel de precisión del 70% durante el entrenamiento del clasificador, se repitieron de nuevo las rondas correspondientes a dicho proceso en la segunda sesión, Cal-II. Si tras la realización de las dos sesiones de calibración no fue posible obtener un clasificador fiable para dicho usuario, es decir, si no fue posible determinar con un 70% de precisión cuáles eran los comandos deseados, se descartó el usuario para las sesiones de evaluación, debido a la incapacidad para poder realizarlas.

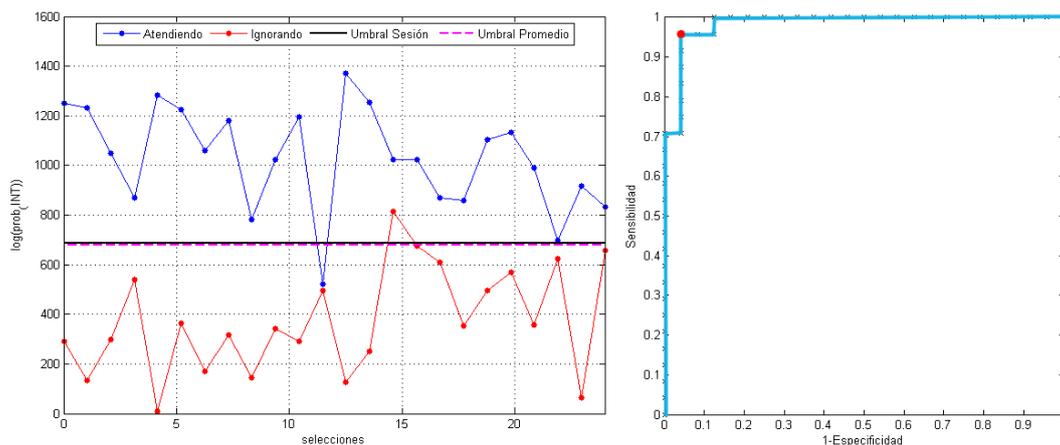


Figura 5-11. Representación gráfica de los datos de la segunda sesión para el sujeto C01. A la izquierda aparecen las selecciones atendiendo e ignorando los estímulos para las 24 selecciones de la segunda sesión. A la derecha aparece la curva ROC para esa sesión concreta y el umbral óptimo calculado.

5.7.2. Sesiones de evaluación

La aplicación se evaluó primero con los sujetos SC, con el fin de asegurar un buen funcionamiento antes de evaluarla con enfermos reales de EM. Por esta razón, al observar los resultados de los sujetos SC, se decidió modificar las tareas de evaluación, con el fin de adaptarlas a los sujetos EM. Es decir, el procedimiento de evaluación difiere ligeramente entre ambas poblaciones.

a) Sujetos de control

Para los sujetos de control se utilizó una sola sesión de evaluación en la que se establecieron cuatro tareas con una dificultad progresiva que evaluaron cada una de las funcionalidades de la aplicación.

La primera tarea consistía en la visualización simple de una web. El sujeto debía centrar su atención en visualizar una página web haciendo uso de los comandos de la matriz de navegación, además de practicar la selección de hipervínculos. La tarea partía del artículo de la *Wikipedia* sobre los potenciales evocados P300 y, posteriormente, el sujeto debía hacer *scroll* dos veces hacia abajo y hacia arriba, seleccionar un hipervínculo y cambiar de web a través de él. Finalmente, se ordenó al usuario volver a la página anterior. Las selecciones mínimas para realizar esta tarea fueron 10 selecciones, sin embargo, si el usuario erraba debía solventarlo, causando un aumento de las selecciones necesarias para finalizar la prueba exitosamente. Además de eso, es posible que el programa indicase que no se había superado el umbral en alguna selección concreta y, por tanto, debería repetirla para intentar sobrepasar la intensidad necesaria (indicado como un *warning* en el log).

La segunda tarea requería más selecciones que la anterior, concretamente, 14 selecciones. Aun así, para realizarla solamente se necesitaba utilizar la matriz de navegación y, en consecuencia, el tiempo necesario para finalizar la prueba no aumentó de manera significativa con respecto a la primera. El sujeto debía centrar su atención en visualizar un e-mail de su bandeja de entrada y, finalmente, responderlo con un cuerpo de mensaje corto. La tarea partía de la versión HTML básica de *Gmail*, donde el sujeto debía seleccionar el e-mail objetivo, leerlo, seleccionar el formulario de respuesta rápida, introducir un cuerpo de mensaje corto, abandonar el formulario y, finalmente, seleccionar el botón de enviar.

La tercera tarea fue la más complicada de todas. Aunque solamente requería 13 selecciones, varias de éstas solamente podían realizarse con la matriz de teclado y, dado que tiene un mayor número de celdas, el tiempo necesario para finalizar la prueba aumentó considerablemente. El usuario debía realizar una búsqueda en *Google* introduciendo el acrónimo "EEG" y seleccionar el primer resultado encontrado. Para ello debía seleccionar el formulario de búsqueda, introducir los caracteres alternando entre ambas matrices y seleccionar el primer hipervínculo activando el etiquetado. En la Figura 5-12 aparece un usuario SC realizando dicha tarea.

La cuarta y última tarea estaba destinada a comprobar el funcionamiento del umbral óptimo de cada usuario. Se ordenó a cada usuario leer una página web durante 5 minutos mientras la aplicación estaba en curso, ignorando los estímulos, con el fin de comprobar si se seleccionaban comandos o no.

b) Enfermos de esclerosis múltiple

Debido a que las precisiones obtenidas habitualmente en la literatura para los sujetos EM suelen ser inferiores que las obtenidas para los sujetos SC, se han utilizado

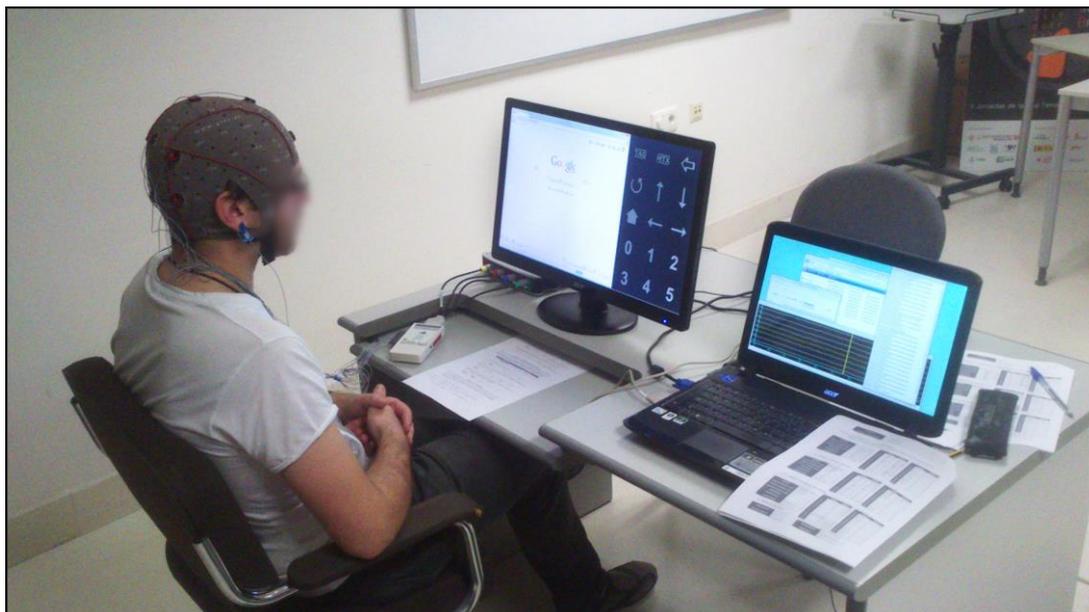


Figura 5-12. El sujeto C05 evaluando la aplicación en la tercera sesión. La pantalla de la izquierda contiene la aplicación mientras que la de la derecha muestra el voltaje de cada electrodo y la información sobre las celdas seleccionadas y el umbral.

dos sesiones distintas para evaluar la aplicación por parte de los sujetos EM. El objetivo de esta diferenciación es el de obtener una mayor información para poder realizar un análisis post-evaluación para identificar las ventajas e inconvenientes presentes en la aplicación desarrollada.

Para ello, se realizaron cinco tareas de dificultad progresiva, parecidas a las realizadas por los sujetos SC, pero con un número menor de selecciones, es decir, eran más cortas. En la primera sesión de evaluación, Eval-I, se realizaron las tareas sin el umbral óptimo para cada usuario, con el fin de estudiar la precisión de los usuarios solamente con su clasificador personalizado. En este caso, la tarea de navegación por *Wikipedia* se redujo a 6 selecciones mínimas, la búsqueda en *Google* se redujo a 8 y la visualización y respuesta de un e-mail se redujo a 13. La tarea de lectura quedó intacta.

La única tarea nueva consistía en publicar un *tweet* corto, de dos caracteres como mínimo. Esta tarea era rápida, con un número mínimo de selecciones de 6, sin embargo, también sirvió de realimentación al usuario, puesto que al terminar la sesión podía comprobar que efectivamente el *tweet* estaba público en Internet, y que la aplicación es funcional. En la Figura 5-13 se puede observar a un usuario EM realizando dicha tarea.

En la segunda sesión, Eval-II, se utilizó el umbral óptimo para cada usuario, utilizando la asincronía de la aplicación, con el fin de estudiar si el umbral supone una mejora en la aplicación. Solamente se realizaron las tareas de navegación en *Wikipedia* y la de la publicación de un *tweet*. No obstante, la tarea de lectura se modificó, añadiendo ciertas selecciones para avanzar la página y continuar la lectura.

En la Tabla 5-1 se muestran las tareas realizadas por cada tipo de usuario, a modo de resumen.

TABLA 5-1. RESUMEN DE LAS TAREAS PROPUESTAS EN LAS SESIONES DE EVALUACIÓN PARA TODA LA POBLACIÓN DE ESTUDIO.

Sujetos SC		Sujetos EA			
Tareas	Sel. Mín.	Tareas	Sel. Mín.	Eval-I	Eval-II
Navegación por <i>Wikipedia</i>	10	Navegación por <i>Wikipedia</i>	6	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Visualización y respuesta de un e-mail		Búsqueda en <i>Google</i>	8	<input checked="" type="checkbox"/>	<input type="checkbox"/>
Búsqueda en <i>Google</i>	14	Publicación de un <i>tweet</i>	6	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Lectura pasiva de una página web	13	Visualización y respuesta de un e-mail	13	<input checked="" type="checkbox"/>	<input type="checkbox"/>
		Lectura pasiva de una página web	10	<input checked="" type="checkbox"/>	<input type="checkbox"/>
		Lectura activa de una página web	10	<input type="checkbox"/>	<input checked="" type="checkbox"/>

EM: Esclerosis Múltiple, SC: Sujetos de Control.

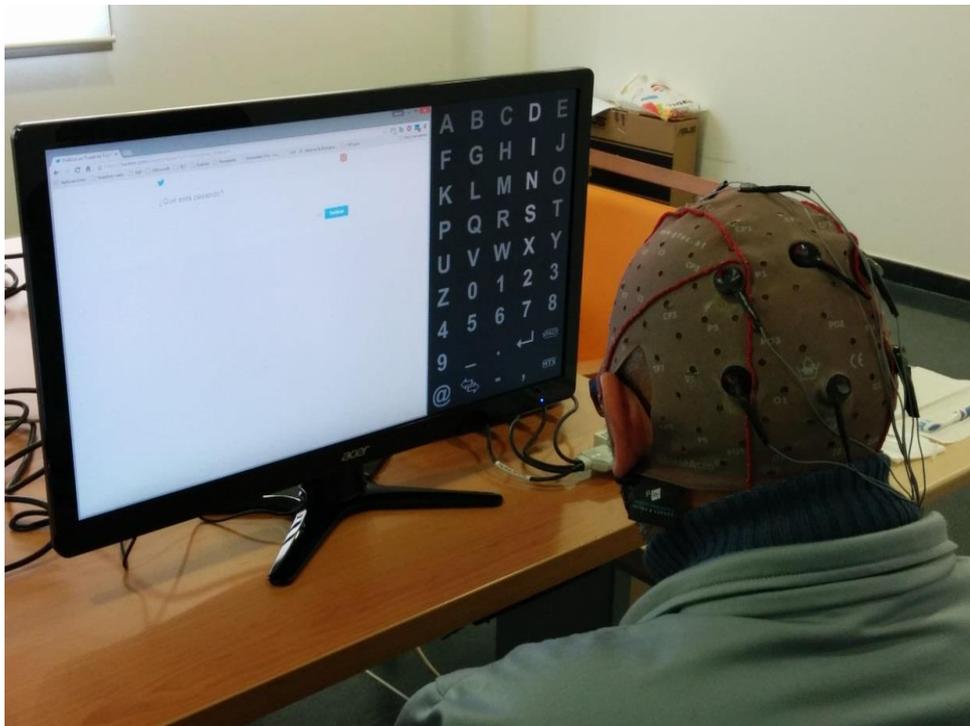


Figura 5-13. El sujeto U14 evaluando la aplicación en la sesión Eval-II. Se observa al usuario realizando la tarea de publicar un *tweet*, en este momento, con la matriz de teclado.

c) Cuestionarios de satisfacción

Una vez finalizadas las sesiones de evaluación, se entregó a los usuarios un cuestionario de satisfacción, con el fin de recoger su experiencia personal y las sugerencias para mejorar la aplicación en un futuro.

c.1) Sujetos de control

El cuestionario de los sujetos SC se componía de 10 afirmaciones, tanto positivas como negativas, y se muestra a continuación.

CUESTIONARIO DE SATISFACCIÓN NAVEGACIÓN WEB MEDIANTE SISTEMAS P300-BCI

Valore las siguientes afirmaciones sobre la aplicación BCI para navegar por Internet:

1. La interfaz del sistema es intuitiva y fácil de entender.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

2. Me ha resultado sencillo seleccionar comandos de la matriz de navegación.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

3. El efecto de parpadeo de los botones de la aplicación resulta molesto.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

4. Me ha resultado complicado seleccionar comandos de la matriz de teclado.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

5. El tiempo necesario para seleccionar un enlace es muy grande.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

6. Habitualmente se seleccionan comandos que no deseo que se seleccionen, complicando el uso de la aplicación.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

7. La adquisición de la actividad cerebral mediante EEG con el gorro y electrodos activos es poco práctica.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

8. La duración de las sesiones realizadas es adecuada.

Totalmente en desacuerdo	En desacuerdo	Neutral	De acuerdo	Totalmente de acuerdo

9. ¿Volvería a participar en un proyecto de características similares?
- Sí.
 - Sí, aunque me supone bastante esfuerzo.
 - No. ¿Por qué razón? _____
10. ¿Qué cree usted que debería mejorarse para una futura versión?

c.2) Enfermos de esclerosis múltiple

El cuestionario entregado a los sujetos EM contenía 20 afirmaciones (tanto positivas como negativas), en contraposición al cuestionario de 10 afirmaciones de los sujetos SC, puesto que se consideró necesario recoger más específicamente las opiniones de los sujetos EM, futuros usuarios de la aplicación. Dicho cuestionario se muestra a continuación.

**CUESTIONARIO DE SATISFACCIÓN
NAVEGACIÓN WEB MEDIANTE SISTEMAS P300-BCI**

Valore las siguientes afirmaciones sobre la aplicación BCI para navegar por Internet:

1. Me ha resultado interesante conocer y usar el navegador web BCI.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

2. Mis expectativas para el navegador web BCI se cumplieron.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

3. Puedo imaginarme usando el navegador en mi vida diaria.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

4. En mi opinión, se tarda demasiado en navegar por Internet con el navegador BCI.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

5. Me he aburrido durante las sesiones.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

6. Me he impacientado durante las sesiones.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

7. Las sesiones me parecieron entretenidas/divertidas.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

8. Fue estresante concentrarme durante el tiempo requerido.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

9. Las sesiones me cansaron mucho.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

10. Realizaría nuevas sesiones con el navegador gustosamente.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

11. Estoy feliz de que hayan terminado las sesiones.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

12. Me ha resultado difícil seleccionar los comandos de la matriz de navegación.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

13. La interfaz del sistema es intuitiva y fácil de entender.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

14. Me ha resultado sencillo seleccionar los comandos de la matriz de teclado (letras).

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

15. El efecto de iluminación de los botones de la aplicación resulta molesto.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

16. Me gustan los ordenadores y la informática.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

17. Navego poco a través de Internet.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

18. Me encantaría participar de nuevo en un estudio de características similares.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

19. La duración de las sesiones ha sido demasiado larga.

1	2	3	4	5	6	7
Totalmente en desacuerdo			Ni mucho / ni poco			Totalmente de acuerdo

¿Qué aspectos mejoraría usted de la aplicación de navegación web?

En este capítulo se muestran los resultados obtenidos de las sesiones de evaluación con SWLDA tanto por parte de sujetos SC como sujetos EM, además de los obtenidos en la mejora de la clasificación, donde se han empleado s-SVM y e-SVM también. El procedimiento de evaluación seguido se ha detallado en el capítulo 4. Entre tales resultados se encuentran la precisión de SWLDA y el área bajo la curva ROC hallados en las sesiones de calibración, así como la precisión obtenida en cada una de las tareas propuestas en las sesiones de evaluación. También se incluyen los resultados de los cuestionarios de satisfacción y las sugerencias de mejora propuestas por los usuarios. Para finalizar, se compara la precisión de la clasificación con SWLDA, s-SVM y e-SVM, variando el número de muestras resultantes del submuestreo previo a dicha clasificación.

6.1. Sesiones de calibración

Los primeros resultados a presentar son los obtenidos de las sesiones de calibración del clasificador y el umbral para cada sujeto, utilizando SWLDA como algoritmo de entrenamiento. Puesto que la metodología seguida es idéntica en ambas poblaciones (SC y EM), en la Tabla 6-1 se muestran los resultados en conjunto.

En dicha tabla se muestran las precisiones del clasificador obtenidas en ambas sesiones de calibración, el número de secuencias establecido según dicha precisión, el área bajo la curva ROC para ambas sesiones de determinación del umbral y, finalmente, el umbral establecido para cada usuario.

Nótese que tres de los sujetos EM no fueron capaces de obtener un mínimo del 70% de precisión en las sesiones de calibración y, por tanto, no se estableció ningún umbral de decisión. Tales sujetos se descartaron para las sesiones de evaluación, debido a la incapacidad de seleccionar los comandos deseados. No obstante, sí se incluyeron en la clasificación post-evaluación con SVM, con el fin de intentar mejorar sus resultados en las sesiones de calibración.

Es necesario destacar que todos los sujetos SC obtuvieron la máxima precisión, aunque no todos alcanzaron un área bajo la curva máximo. Debido a este comportamiento, se fijó el número de secuencias a 10 para los sujetos SC, menor que el utilizado para el entrenamiento del clasificador, pero no demasiado bajo como para poder cometer algún error en la clasificación. En contraposición, como era de esperar, los sujetos EM obtuvieron precisiones más bajas, tal y como se ha comentado.

Se puede observar una gran variación entre los valores del umbral para cada usuario, de hecho, se ve una diferencia de tres órdenes de magnitud entre el valor más grande y el más pequeño. No obstante, el valor del umbral depende únicamente de los pesos asignados para el clasificador de cada usuario, y no tiene nada que ver con el rendimiento del mismo.

TABLA 6-1. RESULTADOS OBTENIDOS EN LAS SESIONES DE CALIBRACIÓN PARA TODA LA POBLACIÓN DE ESTUDIO.

Usuario	Precisión Cal-I	Precisión Cal-II	Número secuencias	Área ROC Cal-I	Área ROC Cal-II	Umbral establecido	
Sujetos EM	U01	87,50%	79,17%	10	0,829861	0,692708	823,58700
	U02	91,67%	87,50%	6	0,881944	0,850694	985,09760
	U03	<70%	75,00%	15	0,495660	0,495660	488,77900
	U04	79,17%	95,83%	13	0,703125	0,930556	256,96075
	U05	<70%	<70%	15	-	-	-
	U06	83,33%	66,67%	15	0,979167	0,916667	736,47375
	U07	83,33%	91,67%	7	0,789931	0,967014	738,74525
	U08	83,33%	70,83%	6	0,727431	0,937500	501,03625
	U09	75,00%	97,22%	10	0,708333	0,944444	428,95100
	U10	91,67%	85,42%	13	1	0,774691	623,53725
	U11	<70%	<70%	-	-	-	-
	U12	91,67%	61,11%	9	0,826389	0,555556	650,19450
	U13	100,00%	66,67%	5	1	0,562500	1710,05250
	U14	91,67%	86,11%	10	0,875000	0,782407	507,42700
	U15	91,67%	80,56%	6	0,875000	0,710648	489,18000
	U16	<70%	<70%	15	-	-	-
Sujetos SC	C01	100,00%	100,00%	10	1	0,9844	680,65450
	C02	100,00%	100,00%	10	1	1	518,90125
	C03	100,00%	100,00%	10	0,9549	1	0,027448
	C04	100,00%	100,00%	10	1	1	813,1090
	C05	100,00%	100,00%	10	1	0,875	506,1560

EM: Esclerosis Múltiple, SC: Sujetos de Control.

6.2. Sesiones de evaluación

A causa de la variación del procedimiento de evaluación entre ambas poblaciones, se muestran a continuación los resultados para los sujetos SC y EM por separado. Nótese que, tal y como se explicó en el capítulo 4, en estas sesiones los usuarios utilizan los pesos del clasificador (hallados mediante SWLDA) y el umbral óptimos para cada uno de ellos.

6.2.1. Sujetos de control

En la Tabla 6-2 se muestran los resultados obtenidos en la sesión de evaluación por parte de los sujetos SC, con los datos necesarios para realizar correctamente la evaluación de todas las tareas, siendo éstos:

- **FIN:** indica si el usuario pudo completar o no la tarea propuesta.
- **ERR:** número de selecciones que el clasificador y el umbral discriminaron de manera errónea.
- **FPU:** número de selecciones para las que el umbral determinó que el usuario no estaba atendiendo a la matriz cuando sí lo estaba haciendo, provocando un aviso cuando la selección era correcta.
- **EXT:** número de selecciones adicionales que fueron necesarias para solventar un error cometido por el usuario o el umbral.
- **Tiempo:** duración de la prueba en minutos para ese usuario en concreto.

TABLA 6-2. RESULTADOS OBTENIDOS EN LA SESIÓN DE EVALUACIÓN PARA LOS SUJETOS DE CONTROL.

Usuario	Navegación por <i>Wikipedia</i>					
	FIN	ERR	FPU	EXT	Tiempo	Precisión
C01	Sí	0	1	0	5:10	100,00%
C02	Sí	0	0	0	4:50	100,00%
C03	Sí	1	0	0	4:43	90,00%
C04	Sí	0	0	1	5:07	100,00%
C05	Sí	0	0	0	4:39	100,00%
Usuario	Visualización y respuesta de un e-mail					
	FIN	ERR	FPU	EXT	Tiempo	Precisión
C01	Sí	2	2	0	8:55	88,88%
C02	Sí	0	0	0	6:28	100,00%
C03	Sí	0	0	0	6:32	100,00%
C04	Sí	0	0	0	6:36	100,00%
C05	Sí	1	0	1	7:30	93,75%
Usuario	Búsqueda en <i>Google</i>					
	FIN	ERR	FPU	EXT	Tiempo	Precisión
C01	Sí	2	0	1	10:04	88,24%
C02	Sí	0	0	0	7:20	100,00%
C03	Sí	0	0	0	7:21	100,00%
C04	Sí	0	0	0	7:23	100,00%
C05	Sí	3	0	1	8:30	83,35%
Usuario	Lectura de una página web					
	FIN	ERR	FPU	EXT	Tiempo	Precisión
C01	Sí	0	0	0	5:00	100,00%
C02	Sí	0	0	0	5:00	100,00%
C03	Sí	0	0	0	5:00	100,00%
C04	Sí	0	0	0	5:00	100,00%
C05	Sí	0	0	0	5:00	100,00%

- **Precisión:** porcentaje de selecciones correctas sobre el total de selecciones realizadas para una tarea concreta.

Se observa un comportamiento inmejorable del umbral y del clasificador para los sujetos C02 y C04, los cuales obtuvieron una precisión del 100,00% para todas las tareas propuestas. Les sigue el sujeto C03, que obtuvo la máxima precisión para todas las tareas menos para la navegación por *Wikipedia*, donde obtuvo una precisión del 90,00%. Los con menor precisión fueron C01 y C05, donde algunas de las precisiones obtenidas bajaron hasta el 83,35%. Aun así, todas las precisiones son altas, lo cual significa que la aplicación puede ser controlada satisfactoriamente por sujetos SC. En la Tabla 6-3 se muestran las precisiones medias obtenidas por cada uno de ellos, sin tener en cuenta la tarea de lectura.

Con respecto a las tareas, se observa una mayor dificultad en la búsqueda en *Google*, probablemente debido al uso necesario de la matriz de teclado; seguida por la visualización y respuesta de un e-mail; y, finalmente, por la navegación por *Wikipedia*. Por tanto, parece que las tareas propuestas sí que muestran una dificultad progresiva. Cabe mencionar que en la tarea de lectura se obtuvieron resultados perfectos para los cinco sujetos, lo cual indica que el umbral de decisión discrimina de manera excepcional la atención de estos usuarios.

TABLA 6-3. PRECISIONES MEDIAS DE LA SESIÓN DE EVALUACIÓN PARA LOS SUJETOS DE CONTROL.

Usuario	C01	C02	C03	C04	C05
Precisión Media	92,37%	100,00%	96,67%	100,00%	92,37%

Nota: no se ha considerado la precisión de la tarea de lectura, puesto que su fin era solamente evaluar el umbral.

6.2.2. Enfermos de esclerosis múltiple

Con respecto a los resultados de las sesiones de evaluación Eval-I y Eval-II por parte de los sujetos EM, aparecen en las Tablas 6-4 y 6-5, respectivamente. Se mantienen las siglas utilizadas para los sujetos SC y se añaden las siguientes:

- **PRE:** precisión obtenida en una tarea concreta.
- **Precisión lectura:** precisión obtenida en la tarea de lectura pasiva de una web.

En las tablas de resultados de las sesiones de evaluación se observa cómo muchos de los sujetos no fueron capaces de terminar todas las tareas satisfactoriamente. A simple vista, comparando las precisiones de Eval-I, se puede observar cómo la precisión del umbral es más alta, en general, que la precisión media general de todas las tareas. Por tanto, como era de esperar, en la sesión Eval-II, donde se utilizó el umbral, se mejoraron dichas precisiones.

6.3. Cuestionarios de satisfacción

Según se ha comentado en apartados anteriores, al finalizar las sesiones de calibración y evaluación se pidió a los usuarios que rellenasen un cuestionario de satisfacción.

6.3.1. Sujetos de control

Para los sujetos de control, el cuestionario estaba formado por 10 preguntas, de las cuales 9 se rellenaban según el siguiente código. En la tabla 6-6 se recoge la media y la desviación estándar de cada cuestión, resultados que se discutirán ampliamente en el siguiente capítulo.

- (1) Totalmente en desacuerdo.
- (2) En desacuerdo.
- (3) Neutral.
- (4) De acuerdo.
- (5) Totalmente de acuerdo.

La pregunta restante tenía como intención el recoger las sugerencias de los usuarios para mejorar la aplicación, formulada como: “¿qué cree usted que debería mejorarse para una futura versión?”. Las respuestas de los tres usuarios que contestaron a la misma vienen recogidas a continuación.

El sujeto C02 recalcó que, en su opinión, hay poco tiempo para pensar los comandos a utilizar en cada momento y que, si el usuario no lo piensa rápidamente, hay que esperar a la finalización del intento para poder llevar a cabo la selección. Es decir, demanda más tiempo de reacción entre los intentos.

TABLA 6-4. RESULTADOS OBTENIDOS EN LA PRIMERA SESIÓN DE EVALUACIÓN POR PARTE DE LOS ENFERMOS DE ESCLEROSIS MÚLTIPLE.

Usuario	Navegación por <i>Wikipedia</i>					Búsqueda en <i>Google</i>					Publicación de un <i>tweet</i>					Respuesta de un e-mail					Precisión lectura	Precisión media
	FIN	ERR	EXT	TIE	PRE	FIN	ERR	EXT	TIE	PRE	FIN	ERR	EXT	TIE	PRE	FIN	ERR	EXT	TIE	PRE		
U01	Sí	0	0	3:35	100,00%	No	0	0	6:05	100,00%	Sí	2	3	5:20	77,78%	Sí	7	8	15:04	66,67%	90,00%	79,54%
U02	Sí	0	0	2:22	100,00%	Sí	0	0	4:02	100,00%	Sí	0	0	4:24	100,00%	Sí	0	0	5:17	100,00%	100,00%	100,00%
U03	No	6	-	-	25,00%	No	1	1	6:42	85,71%	Sí	3	-	-	57,14%	-	-	-	-	-	100,00%	61,11%
U04	Sí	0	0	2:48	100,00%	Sí	0	0	4:45	100,00%	Sí	0	0	2:49	100,00%	Sí	1	1	6:24	92,86%	87,50%	96,97%
U06	Sí	1	2	4:20	87,50%	Sí	3	3	8:05	72,73%	Sí	2	3	4:49	77,78%	Sí	3	3	8:54	75,00%	87,50%	77,27%
U07	No	3	5	4:45	72,73%	Sí	4	-	-	40,00%	Sí	1	1	3:37	83,33%	No	4	-	-	50,00%	60,00%	63,33%
U08	Sí	0	0	3:12	100,00%	Sí	0	0	6:20	100,00%	Sí	1	2	4:50	88,89%	Sí	0	0	6:58	100,00%	90,00%	97,20%
U09	No	4	7	7:35	100,00%	No	3	-	-	70,00%	No	0	0	3:20	100,00%	No	8	-	-	62,50%	50,00%	82,35%
U10	No	0	0	3:41	100,00%	No	3	-	-	66,67%	No	2	2	5:01	75,00%	No	5	-	-	62,50%	100,00%	76,00%
U12	No	5	-	-	66,67%	No	4	3	8:0	72,73%	No	6	5	7:02	63,64%	No	7	-	-	53,33%	90,00%	62,79%
U13	Sí	4	-	-	71,43%	Sí	1	1	4:26	88,89%	Sí	0	0	2:13	100,00%	Sí	3	2	7:12	80,00%	90,00%	83,78%
U14	No	2	2	3:48	75,00%	Sí	6	-	-	75,00%	Sí	2	1	3:08	57,14%	No	7	-	-	46,15%	80,00%	62,50%
U15	No	5	-	-	42,86%	No	3	2	5:31	70,00%	No	2	2	3:57	75,00%	No	4	-	-	64,29%	90,00%	64,10%

TABLA 6-5. RESULTADOS OBTENIDOS EN LA SEGUNDA SESIÓN DE EVALUACIÓN POR PARTE DE LOS ENFERMOS DE ESCLEROSIS MÚLTIPLE.

Usuario	Navegación por <i>Wikipedia</i>						Publicación de un <i>tweet</i>						Lectura activa de una web						Precisión media
	FIN	ERR	FPU	EXT	TIE	PRE	FIN	ERR	FPU	EXT	TIE	PRE	FIN	ERR	FPU	EXT	TIE	PRE	
U01	Sí	1	5	5	6:05	92,31%	No	6	0	-	-	44,44%	Sí	0	0	0	1:45	100,00%	76,92%
U02	Sí	0	4	4	4:02	91,67%	Sí	0	2	2	2:31	85,71%	Sí	0	0	0	2:48	100,00%	92,00%
U03	No	0	5	-	-	100,00%	No	0	6	-	-	62,50%	Sí	0	0	0	2:39	100,00%	85,00%
U04	Sí	0	0	0	3:50	100,00%	Sí	0	0	0	2:48	100,00%	Sí	0	0	0	1:53	100,00%	100,00%
U06	Sí	2	0	1	5:42	77,78%	Sí	1	0	1	3:45	85,71%	Sí	1	0	1	4:30	85,71%	82,61%
U07	No	0	4	-	-	100,00%	Sí	1	2	3	3:21	88,89%	Sí	0	0	0	1:29	100,00%	95,65%
U08	Sí	3	0	2	3:22	70,00%	Sí	2	1	4	3:42	81,82%	Sí	1	0	1	2:08	75,00%	76,00%
U09	No	2	5	-	-	83,33%	No	1	3	-	-	92,86%	No	1	0	-	-	75,00%	86,67%
U10	No	4	2	-	-	63,64%	No	4	2	-	-	71,43%	No	1	0	-	-	75,00%	68,18%
U12	No	4	0	-	-	33,33%	No	0	7	-	-	75,00%	No	0	2	-	-	83,33%	72,00%
U13	Sí	1	4	4	5:24	91,67%	Sí	0	4	4	5:24	100,00%	Sí	0	0	0	1:54	100,00%	96,30%
U14	No	2	5	-	-	72,73%	Sí	2	1	3	4:37	100,00%	Sí	0	0	0	1:56	100,00%	87,50%
U15	No	2	4	-	-	85,71%	No	1	4	-	-	66,67%	No	1	0	-	-	75,00%	75,00%

TABLA 6-6. RESULTADOS OBTENIDOS PARA EL CUESTIONARIO DE SATISFACCIÓN DE LOS SUJETOS DE CONTROL.

Cuestión	Puntuación	
	Media	DE
1 La interfaz del sistema es intuitiva y fácil de entender.	4,00	1,00
2 Me ha resultado sencillo seleccionar comandos de la matriz de navegación.	4,40	0,55
3 El efecto de parpadeo de los botones de la aplicación resulta molesto.	3,20	0,45
4 Me ha resultado complicado seleccionar comandos de la matriz de teclado.	2,20	1,30
5 El tiempo necesario para seleccionar un enlace es muy grande.	3,40	1,14
6 Habitualmente se seleccionan comandos que no deseo que se seleccionen, complicando el uso de la aplicación.	1,40	0,55
7 La adquisición de la actividad cerebral mediante EEG con el gorro y electrodos activos es poco práctica.	2,20	1,30
8 La duración de las sesiones realizadas es adecuada.	3,80	1,30
9 ¿Volvería a participar en un proyecto de características similares?	Sí	-

DE: Desviación Estándar.

El sujeto C03 incidió en la necesidad de poder intercalar entre letras mayúsculas y minúsculas en una futura versión, comando útil y en ocasiones necesario para los sitios web que requieren contraseñas. Además, destacó que la sesión utilizada para entrenar el clasificador se hizo un poco pesada y que el gel conductor es molesto.

Finalmente, el sujeto C05 subrayó que existen ciertas celdas de las matrices, correspondientes a la parte inferior o superior de la pantalla, que la visión no detecta con la misma intensidad debido a variaciones de contraste o a la posición de la pantalla panorámica y que, probablemente, podrían influir en la selecciones del usuario. También sugirió la inclusión del comando "TAG" en ambas matrices, no solamente en la matriz de navegación, y demandó una mejora en el etiquetado de nodos, recalcando que existen nodos muy cercanos y que sus codificaciones pueden llegar a superponerse en ciertas ocasiones.

6.3.2. Enfermos de esclerosis múltiple

Para los sujetos EM, el cuestionario estaba formado por 20 preguntas, de las cuales 19 se rellenaban según un código entre 1 y 7. En la Tabla 6-7 se recoge la media y la desviación estándar de cada cuestión y en la Figura 6-1 se detallan las respuestas. La razón de aumentar el cuestionario radicaba en que se consideró necesario recoger más detalladamente las opiniones de los enfermos de esclerosis, puesto que serán ellos los futuros usuarios de la aplicación, y no así los sujetos de control.

La pregunta restante tenía como intención el recoger las sugerencias de los usuarios para mejorar la aplicación, formulada como: "¿qué aspectos mejoraría usted de la aplicación de navegación web?". De los 13 usuarios que finalizaron las sesiones de evaluación y, por tanto, que rellenaron el cuestionario, solamente 6 de ellos respondieron a la pregunta.

Los usuarios U01 y U14 demandaron más rapidez en la selección de comandos, mientras que los usuarios U03 y U08 reincidieron en que la iluminación de las filas y las columnas de la matriz se hace molesta, especialmente después de la decena de iluminaciones de cada fila y columna. El usuario U07 indicó que sería más adecuado el disminuir el tiempo de las sesiones, aunque haya que aumentar el número de éstas. Finalmente, el usuario U02 sugirió el incluir en la matriz de comandos un tabulador, lo

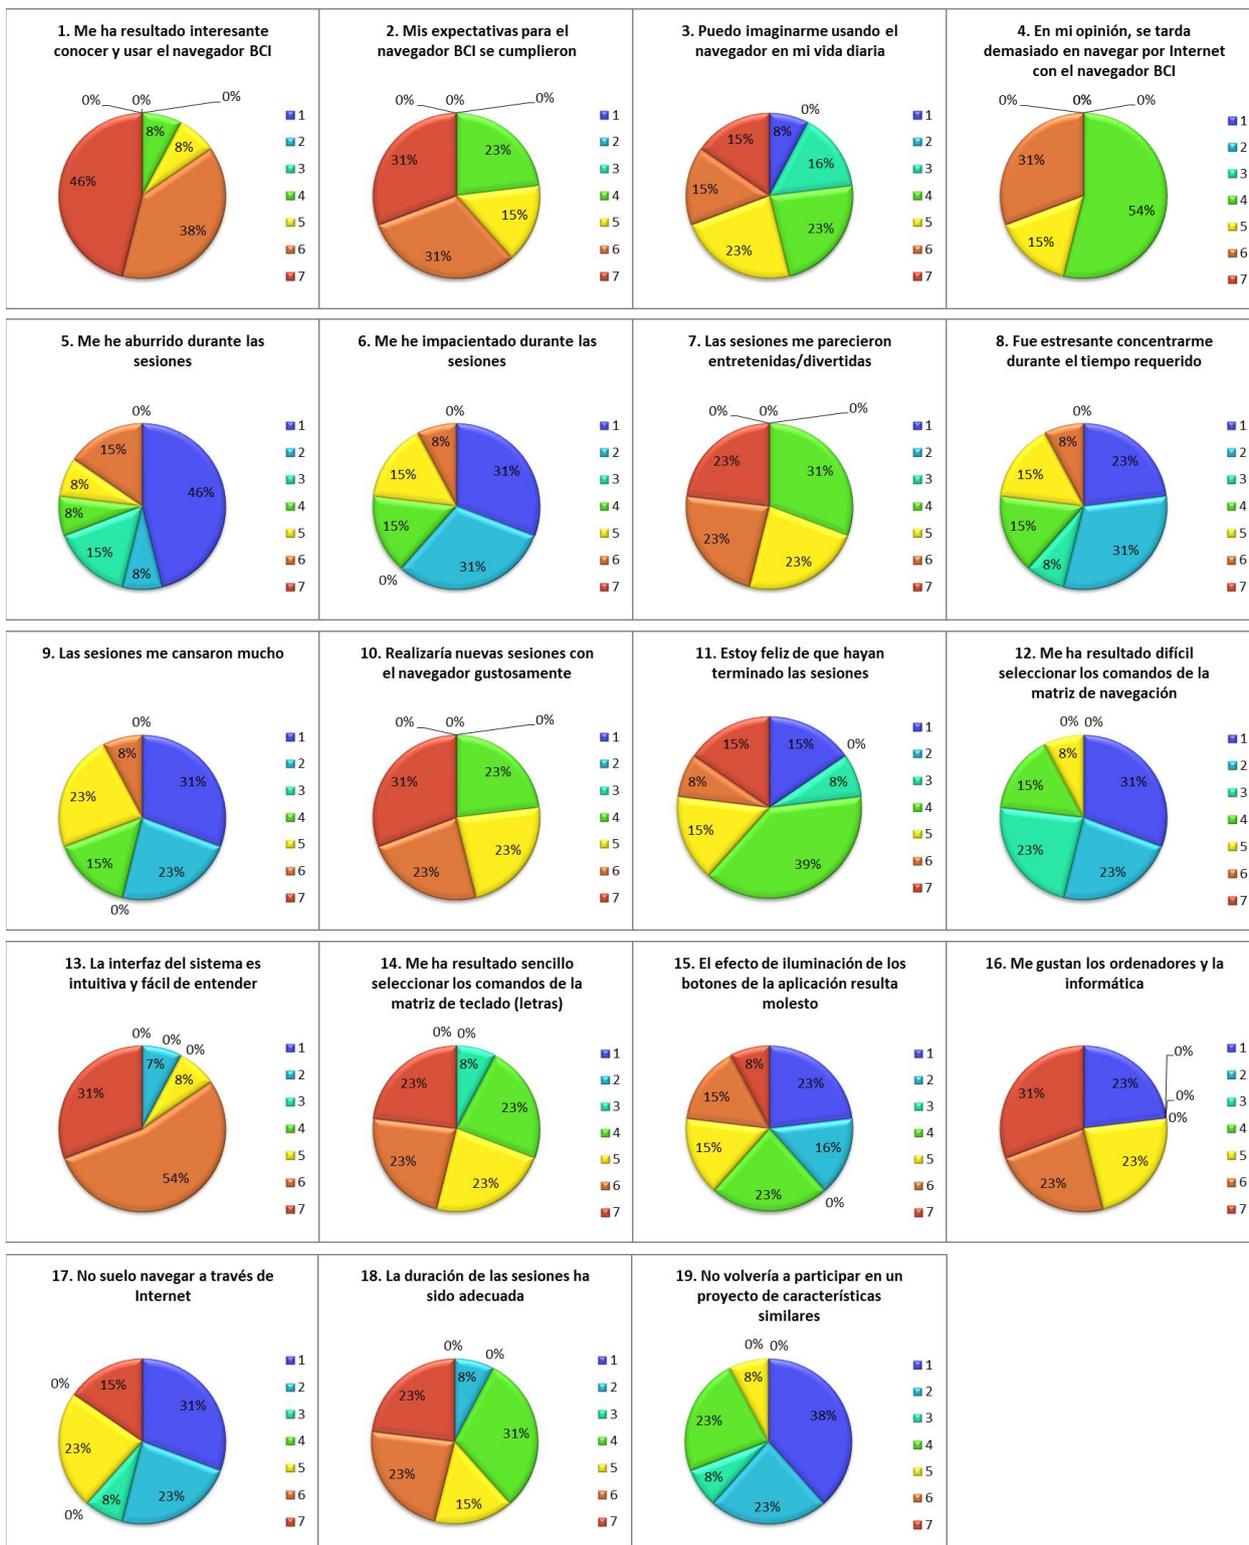


Figura 6-1. Distribución de las respuestas de los enfermos de esclerosis múltiple a cada una de las afirmaciones planteadas en el cuestionario de satisfacción.

TABLA 6-7. RESULTADOS OBTENIDOS PARA EL CUESTIONARIO DE SATISFACCIÓN DE LOS ENFERMOS DE ESCLEROSIS MÚLTIPLE.

Cuestión	Puntuación	
	Media	DE
1 Me ha resultado interesante conocer y usar el navegador BCI	6.23	0.93
2 Mis expectativas para el navegador BCI se cumplieron	5.69	1.18
3 Puedo imaginarme usando el navegador en mi vida diaria	4.62	1.71
4 En mi opinión, se tarda demasiado en navegar por Internet con el navegador BCI	4.77	0.93
5 Me he aburrido durante las sesiones	2.69	1.97
6 Me he impacientado durante las sesiones	2.77	1.79
7 Las sesiones me parecieron entretenidas/divertidas	5.38	1.19
8 Fue estresante concentrarme durante el tiempo requerido	2.92	1.71
9 Las sesiones me cansaron mucho	3.00	1.87
10 Realizaría nuevas sesiones con el navegador gustosamente	5.62	1.19
11 Estoy feliz de que hayan terminado las sesiones	4.23	1.88
12 Me ha resultado difícil seleccionar los comandos de la matriz de navegación	2.46	1.33
13 La interfaz del sistema es intuitiva y fácil de entender	5.92	1.32
14 Me ha resultado sencillo seleccionar los comandos de la matriz de teclado (letras)	5.31	1.32
15 El efecto de iluminación de los botones de la aplicación resulta molesto	3.69	2.10
16 Me gustan los ordenadores y la informática	4.92	2.36
17 Navego poco a través de internet	3.23	2.28
18 Me encantaría participar de nuevo en un estudio de características similares	5.15	1.52
19 La duración de las sesiones ha sido demasiado larga	2.38	1.45

DE: Desviación Estándar.

cual aumentaría la rapidez para seleccionar formularios. También sugiere incluir un comando que permita crear y moverse entre pestañas.

6.4. Comparativa en la clasificación: SWLDA, s-SVM y e-SVM

A raíz de los resultados mostrados en los apartados anteriores, parece evidente que el umbral funciona mejor que el clasificador. Por esta razón, y tal y como se comentó anteriormente, se ha tratado de mejorar la precisión de la clasificación utilizando s-SVM y e-SVM. Además, también se ha variado la frecuencia de submuestreo que se realiza en la extracción de características con el fin de identificar cuál es el número de muestras óptimo por iluminación. Los algoritmos se entrenaron con los datos de la sesión de calibración del clasificador y se testearon con los datos de la sesión de determinación del umbral. Los resultados se muestran en la Tabla 6-8 y en la Figura 6-2.

Nótese que no se muestran las precisiones del usuario U11. Esto se debe a que no se pudieron registrar datos de test para este usuario, puesto que no pudo mantener la concentración. Se movía y hablaba continuamente durante las sesiones, lo que produjo una clasificación SWLDA inferior al 70% en las sesiones de calibración y, por tanto, se descartó de las sesiones de evaluación.

TABLA 6-8. COMPARATIVA DE LOS RESULTADOS OBTENIDOS DE LA PRECISIÓN DE CLASIFICACIÓN PARA LOS TRES MÉTODOS EMPLEADOS EN ENFERMOS DE ESCLEROSIS MÚLTIPLE.

%	4 muestras = 5 Hz			8 muestras = 10 Hz			12 muestras = 15 Hz			16 muestras = 20 Hz			20 muestras = 25 Hz			24 muestras = 30 Hz			28 muestras = 35 Hz		
	SWLDA	s-SVM	e-SVM	SWLDA	s-SVM	e-SVM	SWLDA	s-SVM	e-SVM	SWLDA	s-SVM	e-SVM	SWLDA	s-SVM	e-SVM	SWLDA	s-SVM	e-SVM	SWLDA	s-SVM	e-SVM
U01	0,58	0,35	0,48	0,77	0,77	0,85	0,79	0,85	0,81	0,81	0,92	0,85	0,79	0,92	0,83	0,85	0,85	0,83	0,81	0,85	0,79
U02	0,94	0,88	0,90	0,96	1,00	1,00	0,96	1,00	0,98	0,96	1,00	1,00	0,92	0,98	0,98	0,98	0,98	1,00	0,94	1,00	0,98
U03	0,17	0,31	0,31	0,25	0,50	0,28	0,33	0,50	0,39	0,36	0,50	0,47	0,31	0,58	0,58	0,42	0,56	0,53	0,47	0,56	0,58
U04	0,71	0,38	0,33	0,77	0,83	0,81	0,83	0,83	0,85	0,83	0,90	0,90	0,90	0,90	0,90	0,81	0,90	0,90	0,90	0,88	0,90
U05	0,42	0,58	0,54	0,54	0,42	0,71	0,54	0,46	0,71	0,50	0,54	0,67	0,46	0,50	0,63	0,54	0,63	0,67	0,46	0,54	0,71
U06	0,25	0,38	0,73	0,56	0,77	0,71	0,67	0,79	0,77	0,69	0,85	0,79	0,77	0,81	0,79	0,79	0,79	0,79	0,81	0,83	0,77
U07	0,81	0,77	0,79	0,83	0,92	0,92	0,88	0,85	0,90	0,88	0,90	0,94	0,90	0,94	0,94	0,90	0,94	0,92	0,90	0,90	0,88
U08	0,50	0,38	0,40	0,75	0,79	0,73	0,71	0,79	0,77	0,75	0,79	0,77	0,79	0,90	0,81	0,79	0,83	0,83	0,83	0,85	0,83
U09	0,81	0,85	0,83	0,85	0,94	0,94	0,88	0,94	0,98	0,92	0,92	0,92	0,92	0,96	0,90	0,92	0,96	0,92	0,92	0,96	0,92
U10	0,35	0,35	0,50	0,65	0,75	0,77	0,77	0,63	0,73	0,81	0,79	0,79	0,81	0,73	0,77	0,88	0,77	0,83	0,83	0,77	0,79
U12	0,56	0,83	0,77	0,69	0,83	0,81	0,73	0,81	0,73	0,77	0,81	0,81	0,75	0,85	0,81	0,79	0,81	0,79	0,71	0,81	0,85
U13	0,54	0,52	0,54	0,65	0,63	0,58	0,69	0,63	0,60	0,73	0,63	0,63	0,69	0,65	0,63	0,69	0,65	0,65	0,71	0,60	0,65
U14	0,67	0,65	0,71	0,77	0,73	0,77	0,88	0,81	0,79	0,88	0,81	0,81	0,81	0,90	0,85	0,85	0,83	0,81	0,90	0,85	0,85
U15	0,52	0,29	0,35	0,73	0,71	0,67	0,77	0,81	0,75	0,81	0,77	0,83	0,81	0,83	0,81	0,83	0,85	0,90	0,88	0,85	0,83
U16	0,29	0,08	0,08	0,29	0,38	0,42	0,33	0,17	0,29	0,29	0,33	0,33	0,38	0,25	0,42	0,33	0,38	0,54	0,29	0,29	0,42
Me.	54,13	50,68	55,12	67,07	73,06	73,12	71,73	72,50	73,71	73,27	76,39	76,74	73,40	77,89	77,62	75,80	78,18	79,37	75,73	77,07	78,31
DE	22,19	24,22	23,24	19,51	18,29	19,09	18,83	21,57	18,99	19,82	18,43	17,85	19,49	20,43	15,19	18,67	16,52	13,88	19,75	18,93	14,46

SWLDA: Step-Wise Linear Discriminant Analysis, s-SVM: Single Linear SVM, e-SVM: Ensemble of 4 Linear SVMs, Me.: Media (%), DE: Desviación Estándar (%).

Nota: Se ha utilizado un parámetro de regularización de $C = 0,1$ para 4, 8, 12 y 16 muestras; y de $C = 0,01$ para 20, 24 y 28 muestras.

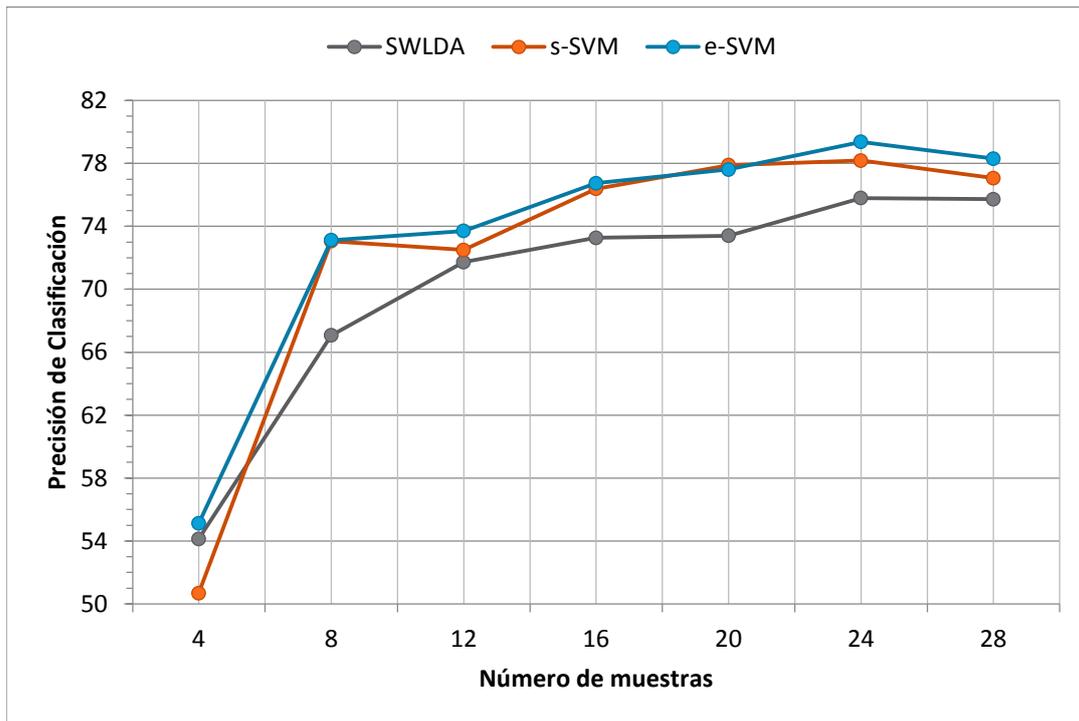


Figura 6-2. Precisiones medias para cada método de clasificación empleado variando el número de muestras finales por estímulo.

Se observa, en general, que el método más preciso es el e-SVM, seguido de s-SVM y, finalmente, SWLDA. No obstante, en ocasiones puntuales se observan casos especiales. Concretamente, para 4 muestras ($f_{sub} = 5 \text{ Hz}$) SWLDA supera a s-SVM, aunque se mantienen por debajo de e-SVM; y para 20 muestras ($f_{sub} = 25 \text{ Hz}$) s-SVM supera a e-SVM, ambos por encima de SWLDA.

El máximo valor de precisión de la clasificación lo obtiene e-SVM para un total de 24 muestras por iluminación, o lo que es lo mismo, $f_{sub} = 30 \text{ Hz}$. Dicho valor se sitúa en 79,31% de precisión media de todos los usuarios. No es sorprendente, puesto que e-SVM fue el método ganador de la III Competición de BCI en 2003 para la clasificación del *data set II*, correspondiente al *P3Speller* [51].

También se observa una mejora de la clasificación a medida que se aumentan el número de muestras, alcanzando el máximo en 24, pero disminuyendo a partir de ese punto. Sin embargo, una menor reducción de la dimensionalidad del conjunto de características (es decir, un mayor número de muestras) implica un mayor coste computacional, lo cual generaría una dificultad adicional para realizar la clasificación a tiempo-real si la frecuencia de submuestreo es demasiado elevada.

El objetivo de este capítulo es discutir los resultados presentados en el capítulo anterior. Para empezar, se analizan los resultados obtenidos para las sesiones de calibración y evaluación de la aplicación, donde se utilizó el algoritmo SWLDA. Como ya se ha introducido previamente, en las sesiones de calibración se discuten los resultados del entrenamiento del clasificador y del umbral. Posteriormente, se discuten los resultados obtenidos para los cuestionarios de satisfacción, y las sugerencias de mejora propuestas por los usuarios. A continuación se analizan los resultados obtenidos en la comparativa de precisiones de clasificación obtenidas para SWLDA, s-SVM y e-SVM. Finalmente, se comparan los resultados con otros estudios y se determinan las limitaciones de la aplicación desarrollada.

7.1. Sesiones de calibración

En las sesiones de calibración se realizaron dos tareas de suma importancia: el entrenamiento del clasificador mediante SWLDA y el entrenamiento del umbral. A continuación se discuten los resultados obtenidos para ambas.

7.1.1. Entrenamiento del clasificador con SWLDA

La Figura 7-1 muestra una comparativa de las precisiones obtenidas en la clasificación durante las dos sesiones de calibración, Cal-I y Cal-II. En la figura no se incluyen los sujetos SC, puesto que todos obtuvieron precisiones del 100%, ni tampoco las de aquellos sujetos EM que no superaron el 70%, los cuales fueron descartados del experimento.

La precisión máxima obtenida por parte de los sujetos SC representa una capacidad de clasificación perfecta para este tipo de usuarios. Es decir, teóricamente el clasificador debería detectar siempre de manera correcta el comando que desea seleccionar el usuario. No obstante, este resultado se pondrá a prueba más adelante, en las sesiones de evaluación.

Con respecto a los sujetos de EM, aquellos que sí alcanzaron una precisión superior al 70% en Cal-I o Cal-II han obtenido una precisión media del 86,15% para Cal-I y del 80,29% para Cal-II. La disminución de la precisión en la segunda sesión se debe, probablemente, a que el clasificador se entrenó en la primera. Teniendo en cuenta que el EEG varía entre sujetos y también entre sesiones, era de esperar que la precisión en Cal-II fuese inferior a la obtenida en Cal-I. Esta variabilidad se debe a cambios entre sesiones de la motivación, la predisposición, la fatiga o la atención del sujeto, así como de la hora de la sesión, o incluso pequeñas variaciones en la colocación del gorro que contiene los electrodos.

Aun así, es interesante analizar los potenciales evocados P300 de cada sujeto para poder inferir las causas que propiciaron las precisiones del clasificador obtenidas para cada uno de ellos. En la Figura 7-2 se muestra un promediado sincronizado de las muestras obtenidas en las tareas atendiendo e ignorando la matriz de estímulos durante las sesiones de calibración. Se muestran únicamente los resultados promedio

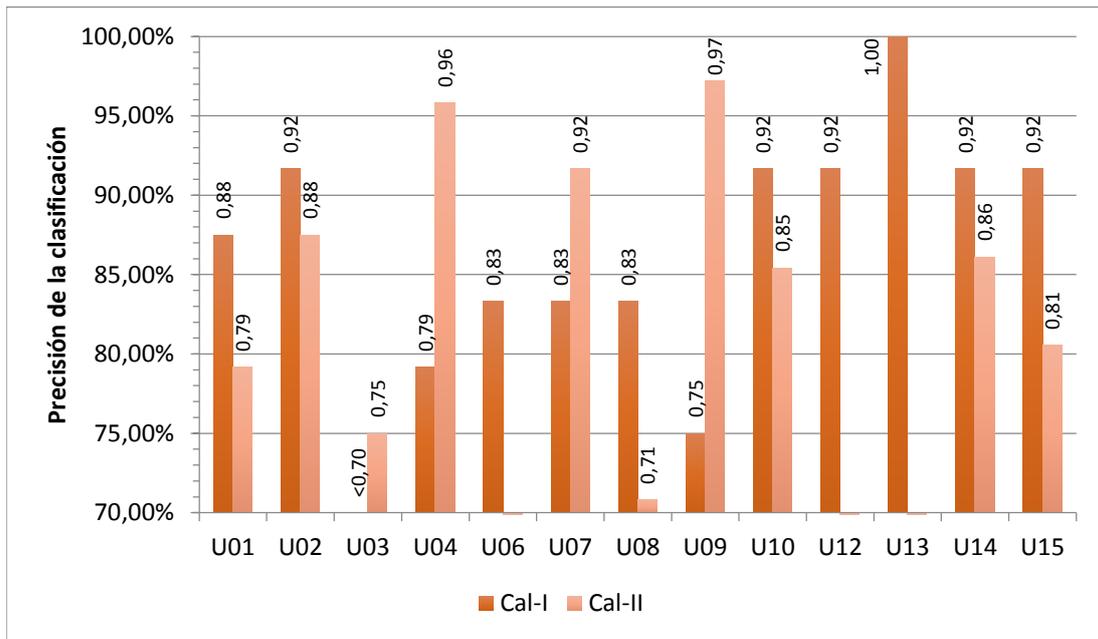


Figura 7-1. Comparación de la precisión del clasificador obtenida para los enfermos de esclerosis múltiple durante las sesiones de calibración. Se omiten de la gráfica los tres sujetos que no alcanzaron una precisión superior al 70%.

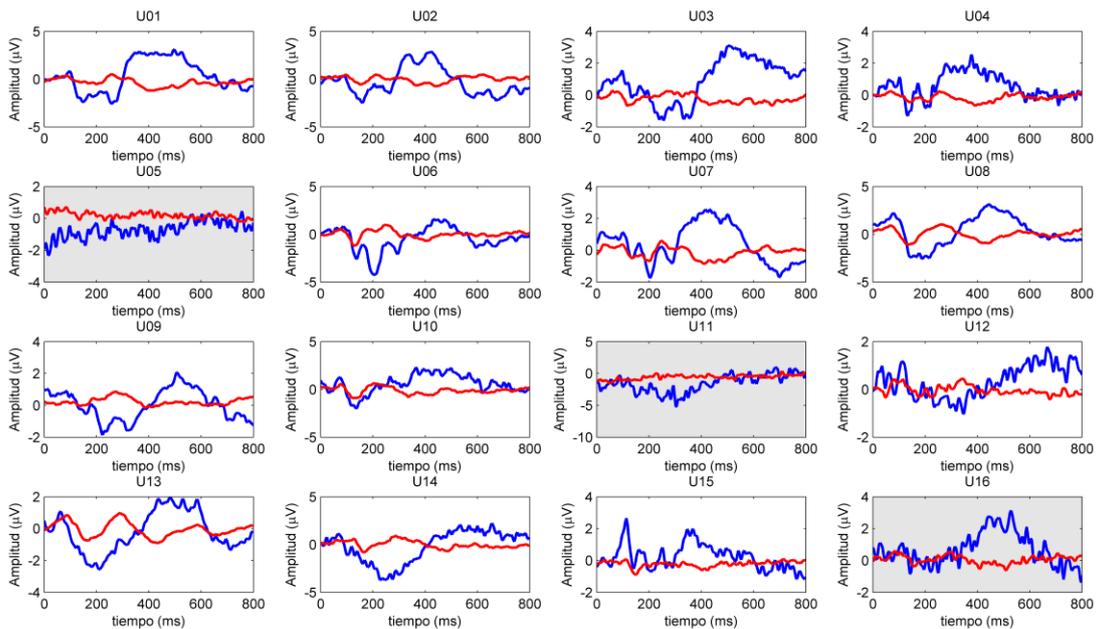


Figura 7-2. Potenciales evocados P300 captados en el electrodo Pz durante las sesiones de calibración para los enfermos de esclerosis múltiple. En azul se muestra la respuesta atendida y en rojo la ignorada. El fondo de los sujetos que no superaron las sesiones de calibración con suficiente precisión (<70%) se ha marcado con un color gris.

en una ventana de 800ms para el electrodo Pz. Además, se han marcado con un fondo gris los potenciales P300 de los sujetos que no superaron el 70% de precisión en ambas sesiones y, por lo cual, fueron descartados de la evaluación de la aplicación.

Como se puede observar, en general se pueden identificar claramente los potenciales P300 en casi todos los sujetos que superaron las sesiones de calibración. Quizás los sujetos U10, U12 y U15 muestran una respuesta más atenuada. No obstante, de los tres sujetos que se descartaron de la evaluación, claramente dos de ellos (U05 y

U11) no muestran un P300 reconocible, y su respuesta cuando atendían a la matriz de estímulos es prácticamente indiferenciable de la provocada cuando la ignoraban.

Atendiendo al perfil clínico de los sujetos EM mostrado anteriormente en Tabla 5-1, se observa que los tres sujetos EM descartados (U05, U11 y U16) poseen una discapacidad motora moderada. También es destacable que el único sujeto cuya capacidad de atención sostenida era muy mala es precisamente U05, lo cual explicaría la respuesta atenuada y prácticamente irreconocible de su potencial P300. Al no ser capaz de mantener una concentración suficiente en los estímulos no se genera correctamente el potencial. Sin embargo, no se puede decir lo mismo de los sujetos U11 y U16, cuya capacidad de atención sostenida ronda el valor medio.

7.1.2. Entrenamiento del umbral

La determinación del umbral, el cual permite distinguir entre ausencia o no de atención a la hora de seleccionar comandos de las matrices de navegación y de teclado, es una tarea de suma importancia debido a que el rendimiento de la aplicación depende directamente de éste.

Tal y como se expresó anteriormente en el capítulo 3, el área bajo la curva ROC (AUC, Area Under Curve) es una medida global e independiente del umbral óptimo seleccionado en cada sesión realizada. Por esta razón, en el ámbito sanitario las curvas ROC también se denominan curvas de rendimiento diagnóstico. Estableciendo el máximo valor (AUC=1) como una representación del valor diagnóstico perfecto, es decir, una capacidad discriminatoria inmejorable, y el mínimo valor (AUC=0,5) como una prueba sin capacidad discriminatoria alguna, se pueden comparar los valores obtenidos en ambas sesiones de determinación del umbral (Cal-I y Cal-II) para esclarecer el significado de los resultados obtenidos.

Analizando los resultados para los sujetos SC, según advierte la Figura 7-3, el AUC obtenida para los sujetos C01, C02 y C04 en la primera sesión fue máxima, representando una capacidad discriminatoria perfecta. El sujeto C05 rozó la perfección obteniendo un valor de 0,9948 y el valor más pequeño lo obtuvo el sujeto C03, con una AUC de 0,9549. Con respecto a la segunda sesión, los sujetos C02, C03 y

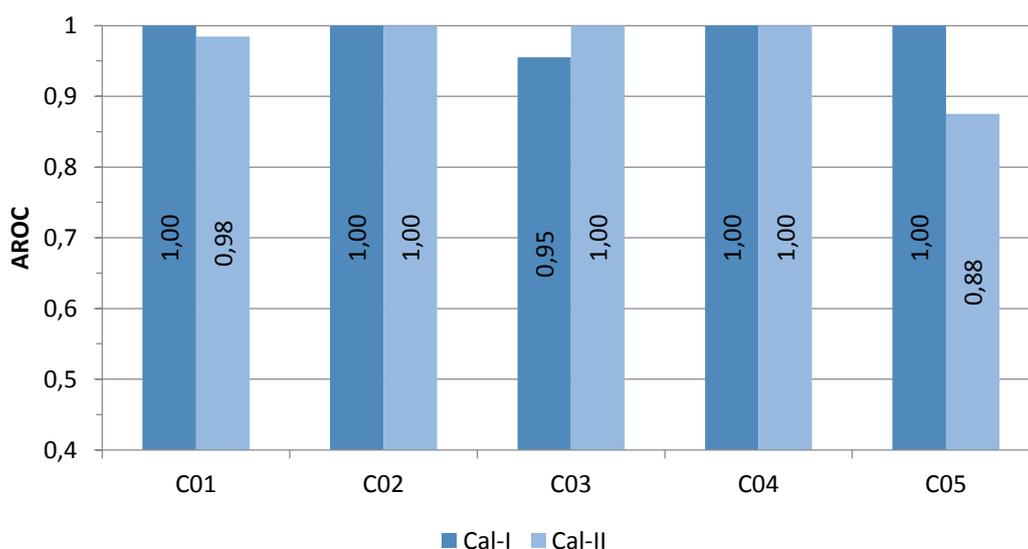


Figura 7-3. Comparación del área bajo la curva ROC obtenida para las dos sesiones de calibración por parte de los sujetos de control.

C04 obtuvieron una AUC máxima, seguidos por el sujeto C01 con una AUC de 0,9844 y el sujeto C05 con una AUC de 0,9826.

A la vista de los resultados, se concluye que el rendimiento del umbral obtenido para los sujetos C02 y C04 es inmejorable, destacando por encima del resto. Seguidamente se observa que los sujetos C01 y C05 obtuvieron valores muy altos, casi perfectos y, finalmente, se observa que el sujeto C03 se quedó por detrás, obteniendo valores AUC menores que el de sus compañeros. Aun así, el valor discriminatorio de todos los umbrales obtenidos es extraordinario.

La Figura 7-4 muestra la AUC obtenida para los sujetos EM en ambas sesiones de calibración. Se observan resultados inferiores a los obtenidos para los sujetos de control, alcanzando la máxima AUC solamente para los sujetos U10 y U13 en Cal-I. El sujeto que peor AUC ha obtenido es el U03, el cual también obtuvo malos resultados en la precisión del clasificador. Se observa una disminución del AUC en Cal-II con respecto a Cal-I, probablemente debida al comportamiento del clasificador, donde la AUC media de Cal-I es de 0,8224 y de Cal-II es de 0,7785.

Estos valores de AUC obtenidos para los sujetos EM indican que la capacidad discriminatoria del umbral será más baja que la de los controles. Es decir, las intensidades de las respuestas atendida e ignorada de este tipo de sujetos no son perfectamente separables para un umbral lineal. Como consecuencia, el umbral no es, a priori, perfecto.

La elección del umbral óptimo de cada curva ROC se realizó atendiendo al criterio de maximización del par sensibilidad-especificidad. Sin embargo, quizás podría mejorarse la aplicación si el umbral se seleccionase intentado maximizar la sensibilidad por encima de la especificidad, puesto que se pasaría a considerar más importante que la aplicación no seleccione comandos cuando el usuario está ignorando los estímulos y, por tanto, cueste más seleccionarlos al atenderlos, que clasificar correctamente los estímulos atendidos y no asegurar que no se seleccione ninguno al ignorarlos.

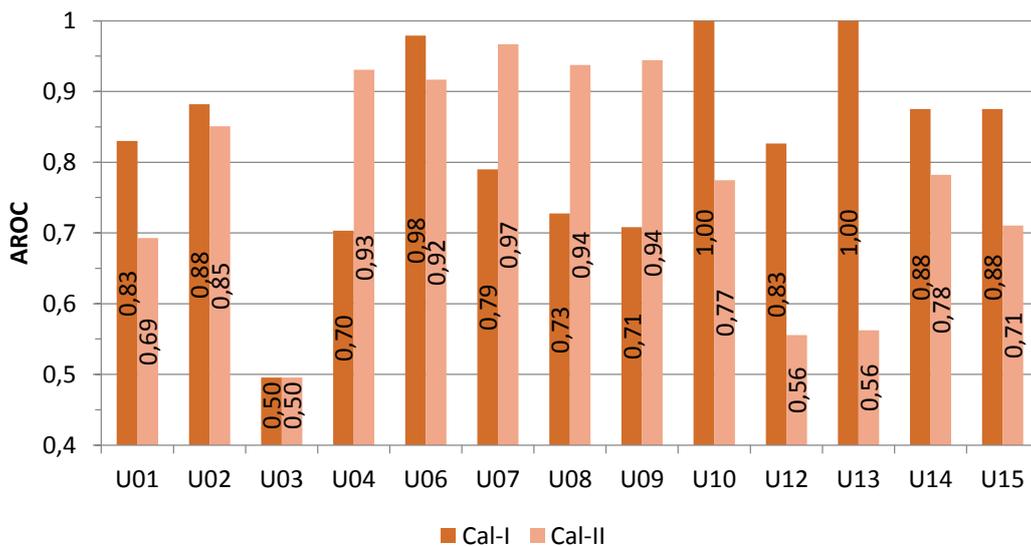


Figura 7-4. Comparación del área bajo la curva ROC obtenida para las dos sesiones de calibración por parte de los enfermos de esclerosis múltiple.

7.2. Sesiones de evaluación

A continuación se discuten los resultados obtenidos en las sesiones de evaluación tanto para los sujetos SC como para los sujetos EM.

7.2.1. Sujetos de control

Las tareas con dificultad progresiva propuestas para evaluar la aplicación por parte de los sujetos SC han puesto de manifiesto que la aplicación funciona adecuadamente para este tipo de usuarios, con un bajo porcentaje de error.

A raíz de los resultados, solamente los sujetos C01, C03 y C05 cometieron algún error. El sujeto C02 realizó las tareas de manera perfecta, sin provocar ningún *warning* o error y sin requerir selecciones adicionales. Le sigue el sujeto C04, el cual solamente produjo un *warning* al no superar el umbral en una determinada selección y el sujeto C03, el cual solamente cometió un error en todas las tareas. Los resultados con precisiones más bajas los obtuvieron el sujeto C01 y el sujeto C05, con cuatro errores cada uno.

Curiosamente, los sujetos C03 y C05 no obtuvieron ningún *warning* y en cambio, sí obtuvieron uno o varios errores. Estos resultados ponen ligeramente en duda la elección de los umbrales, pudiendo, quizás, ser mejorable si éstos se hubiesen encontrado en valores un poco más altos.

En la Figura 7-5 se muestra la precisión obtenida de cada sujeto SC para cada tarea realizada. Lo más destacable es que la cuarta tarea (lectura pasiva) se ha realizado de manera inmejorable por parte de todos los sujetos, obteniendo un 100% de precisión al no seleccionar ningún comando mientras ignoraban los estímulos de forma pasiva. Se concluye, por tanto, que la elección del umbral para los sujetos SC generalmente es correcta, puesto que ningún estímulo fue capaz de superarlo mientras el usuario visualizaba una web concreta.

Según advierten los datos, la primera tarea (navegación por *Wikipedia*) la realizaron perfectamente casi todos los sujetos, posiblemente gracias a la sencillez de la misma (exceptuando al sujeto C03). La segunda y la tercera tarea, más complicadas,

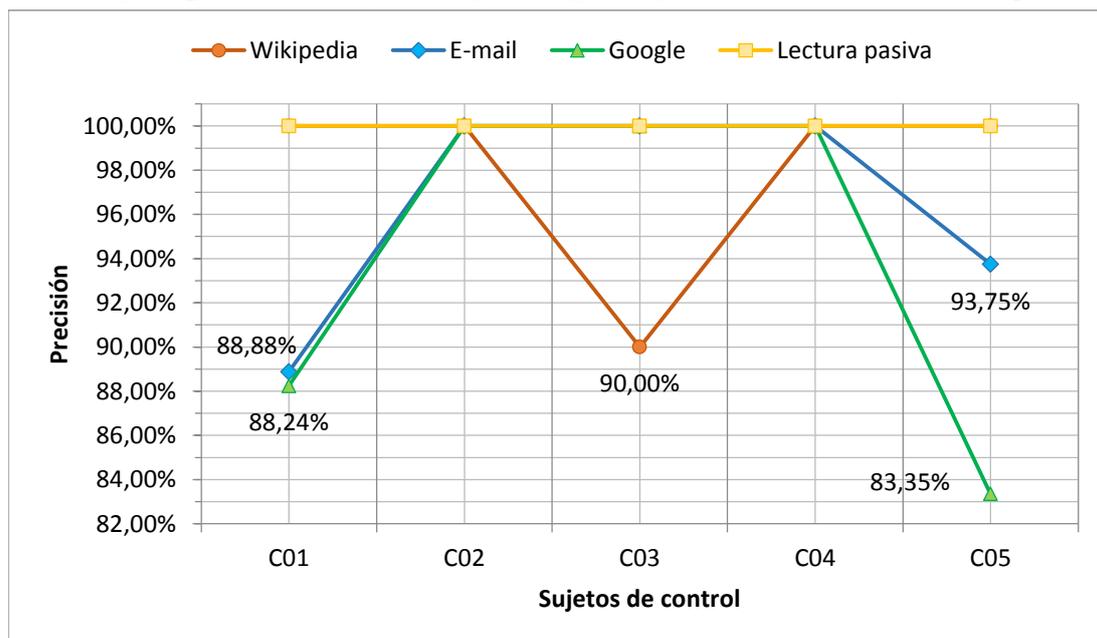


Figura 7-5. Precisión obtenida para cada tarea realizada por parte de los sujetos de control.

dieron problemas a los sujetos C01 y C05, los cuales obtuvieron precisiones bastante inferiores. Sin embargo, la precisión más baja es de 82,35%, la cual implica que más del 80% de las selecciones realizadas fueron correctas.

En términos de precisión el sujeto C02 y el sujeto C04 han obtenido resultados perfectos para todas las tareas. Estos resultados ponen de manifiesto que la elección del clasificador y del umbral para estos sujetos ha sido óptima y la aplicación se ha adaptado completamente a las características individuales de éstos sujetos.

El sujeto C03 también ha obtenido precisiones muy elevadas, siendo éstas máximas para la primera y la tercera tarea, y obteniendo el 90% de precisión para la segunda tarea. Le sigue el sujeto C01, cuya precisión ha sido máxima en la primera tarea, más sencilla, pero ha decaído en las dos tareas siguientes, obteniendo un 88,88% para la segunda y un 88,24% para la tercera. Finalmente, el sujeto C05 ha vuelto a obtener la peor precisión, obteniendo una precisión máxima para la primera tarea, pero unas precisiones del 93,75% y del 82,35% para las tareas segunda y tercera, respectivamente. En la Figura 7-6 se muestran las precisiones medias de cada usuario, donde también se observa esta apreciación.

En conclusión, los sujetos C02 y C04 quedaron completamente por encima del resto de sujetos, obteniendo los mejores resultados en todas las sesiones realizadas. No obstante, las precisiones obtenidas por el resto no son bajas y, por tanto, se concluye que el funcionamiento de la aplicación para los sujetos de control, en términos técnicos, es satisfactorio.

7.2.2. Enfermos de esclerosis múltiple

Las Figura 7-7 y 7-8 muestran las precisiones obtenidas por parte de los sujetos EM a la hora de realizar las tareas propuestas en la primera (Eval-I) y segunda (Eval-II) sesión de evaluación, respectivamente.

En Eval-I, el usuario que más destaca es U02, el cual ha obtenido una precisión máxima del 100% en absolutamente todas las tareas realizadas en Eval-I. No obstante, es una excepción. Le siguen los usuarios U04 y U08, los cuales han obtenido la precisión máxima en tres de las tareas propuestas. Posteriormente, cabe mencionar a

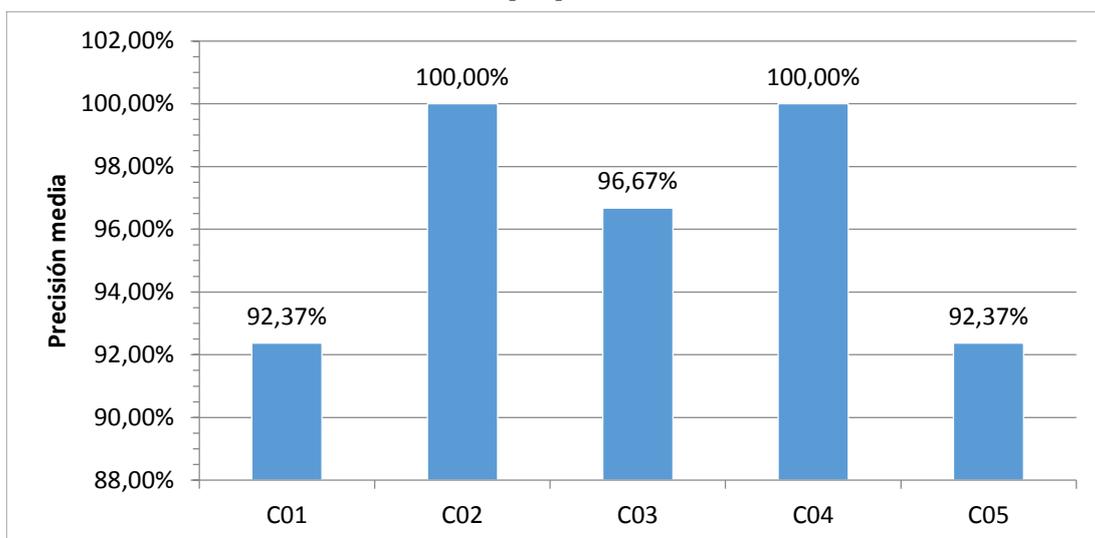


Figura 7-6. Precisión media de cada sujeto de control durante la sesión de evaluación sin considerar la tarea de lectura, puesto que su fin era solamente evaluar el umbral.

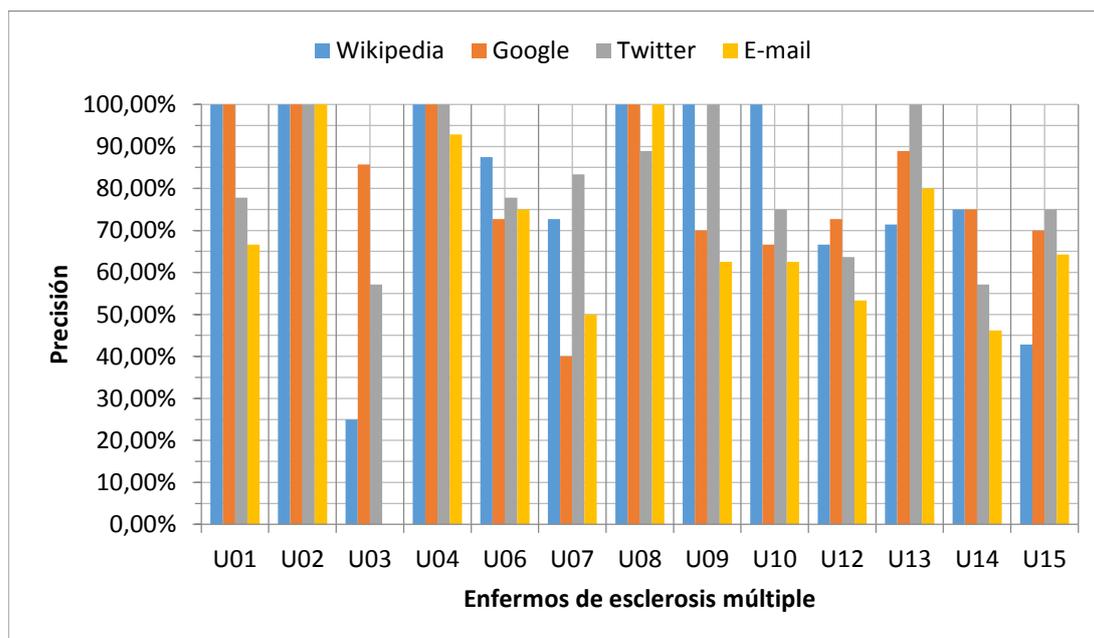


Figura 7-7. Precisión obtenida para cada tarea realizada por parte de los enfermos de esclerosis múltiple en la primera sesión de evaluación, Eval-I.

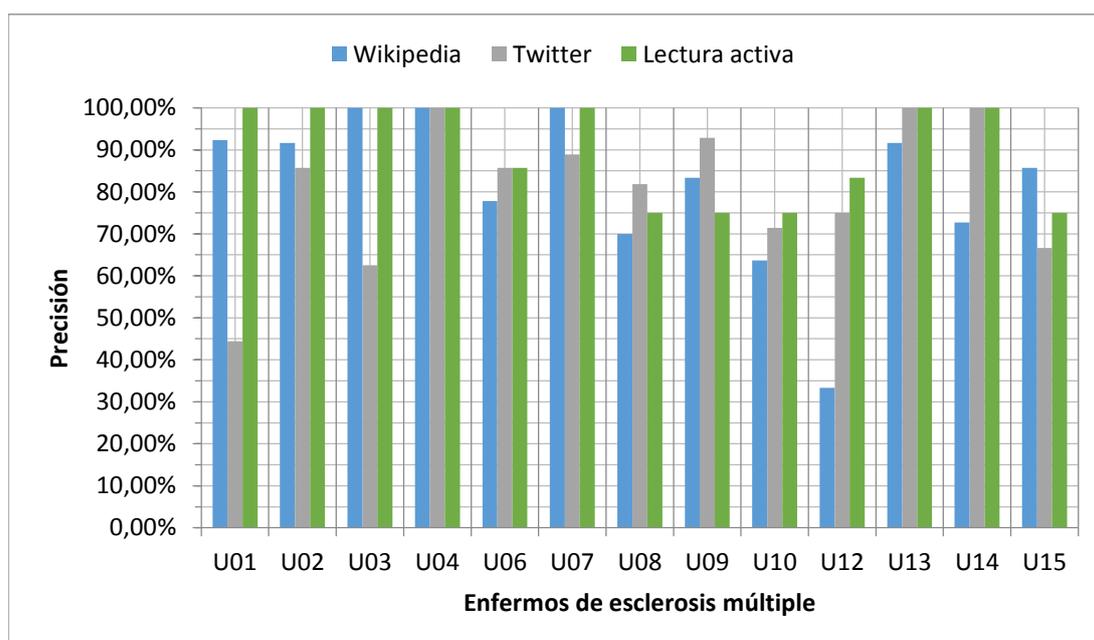


Figura 7-8. Precisión obtenida para cada tarea realizada por parte de los enfermos de esclerosis múltiple en la segunda sesión de evaluación, Eval-II.

los sujetos U01 y U09, que obtuvieron precisiones máximas en dos de las tareas. El resto de usuarios no fueron capaces de realizar las tareas sin cometer algún fallo.

De hecho, multitud de usuarios no fueron capaces de terminar las tareas, sobre todo la cuarta (visualización y respuesta de un e-mail), debido a su mayor dificultad. A raíz de los resultados observados en la discusión de las sesiones de calibración y observando la precisión obtenida en la lectura pasiva, indicada en la Figura 7-9, se determina que la mayor parte de los fallos cometidos durante la evaluación estaban causados por una mala clasificación y no por un mal comportamiento del umbral. Nótese que la precisión media de la lectura pasiva se encuentra en el 90%.

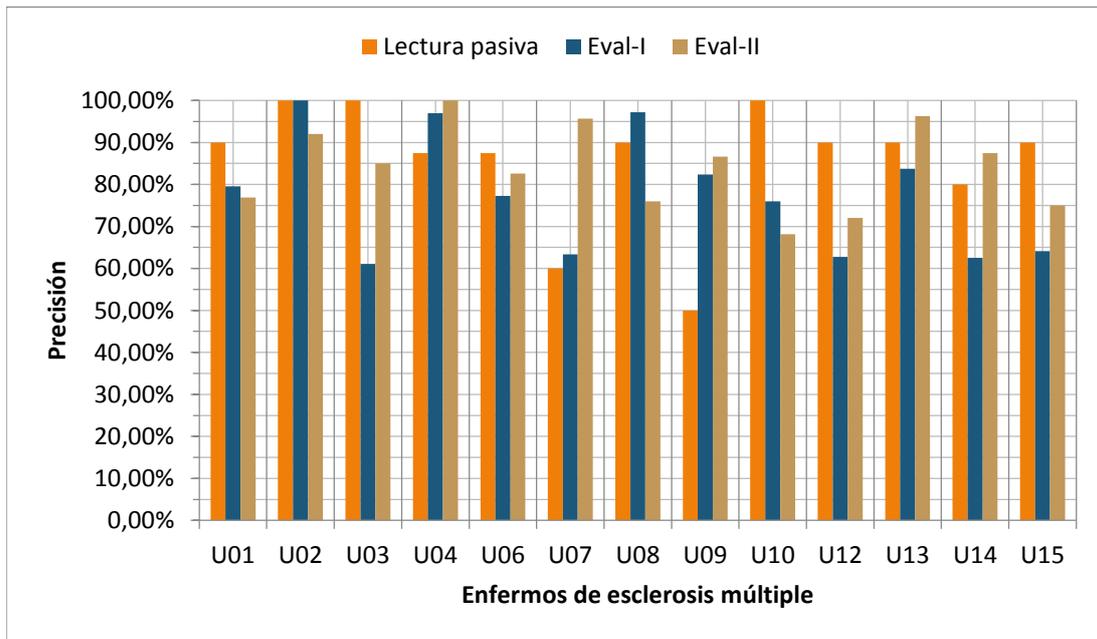


Figura 6-9. Precisión obtenida para cada sujeto en la lectura pasiva, la cual determina la calidad del umbral escogido, así como precisiones medias de cada sesión de evaluación para los enfermos de esclerosis múltiple.

Además, calculando las precisiones medias para cada tarea de Eval-I se obtiene: 80,09% para la navegación en *Wikipedia*, 80,13% para la búsqueda en *Google*, 81,21% para la publicación de un *tweet* y 71,11% para la visualización y respuesta de un e-mail. Las tres primeras tareas obtienen precisiones parecidas, sin embargo, la precisión de la cuarta disminuye hasta un 10% con respecto a las anteriores. Como ya se ha comentado, esto se puede deber a su mayor dificultad, puesto que en dicha tarea es necesario seleccionar correctamente comandos tanto de la matriz de teclado como de la matriz de navegación.

En el caso de Eval-II, el usuario que más destaca es U04, el cual obtiene una precisión máxima en todas las tareas. El resto de usuarios sobresalientes de Eval-I siguen destacando en esta sesión. Aunque la precisión media sea más alta que la de Eval-I, siguen observándose sujetos que son incapaces de terminar las sesiones por fallos en la clasificación.

Con respecto a las tareas, se obtienen precisiones medias de 81,71% para la navegación en *Wikipedia*, de 81,16% para la publicación de un *tweet* y de 89,93% para la lectura activa de una página web. Las precisiones obtenidas en las dos primeras tareas son coherentes con las obtenidas en la sesión anterior, puesto que son exactamente iguales. Sin embargo, se aprecia una precisión más alta en la tarea de lectura. Teniendo en cuenta además que las tareas de Eval-I se realizaron sin umbral, de nuevo, se pone de manifiesto que el umbral discrimina mejor que el clasificador.

A modo de resumen, viendo las precisiones generales de cada usuario para ambas sesiones de evaluación (Figura 7-9), se observa una precisión más alta en la tarea de lectura pasiva, resultando en un 85,77%; seguida por la Eval-II, con un 84,14%; y, finalmente, por Eval-I, con 77,46%.

En conclusión, se determina que el umbral funciona mejor que el clasificador, debido a las precisiones superiores de las tareas de lectura. También se observa que la inclusión de dicho umbral es beneficiosa para la aplicación, puesto que evita multitud de errores causados por el clasificador, aumentando la precisión general. Por tanto, se

pone de manifiesto que el umbral convierte la aplicación originalmente síncrona en una aplicación asíncrona satisfactoriamente. No obstante, aunque para los sujetos SC se han obtenido unas precisiones excelentes, hay que tener en cuenta que se observan muchas ocasiones en las cuales los sujetos EM no son capaces de terminar las tareas propuestas. Como consecuencia, surge la necesidad de mejorar la clasificación.

7.3. Cuestionarios de satisfacción

A continuación se discuten los resultados de los cuestionarios de satisfacción para ambas poblaciones, teniendo en cuenta no solo sus opiniones sobre las afirmaciones proporcionadas, sino también las sugerencias de mejora que ha propuesto cada usuario.

7.3.1. Sujetos de control

El cuestionario de satisfacción de los sujetos SC refleja tanto aspectos en los que todos los usuarios se ponen de acuerdo como el fenómeno contrario.

Los cinco sujetos SC están de acuerdo en que la interfaz del sistema es intuitiva y fácil de aprender, en que les ha resultado sencillo seleccionar comandos de la matriz de navegación, en que el efecto de parpadeo de las celdas de las matrices no es del todo molesto pero que acaba cansando y en que normalmente no se seleccionan comandos que no desean seleccionar.

Sin embargo, difieren en opiniones con respecto a la dificultad de seleccionar comandos de la matriz de teclado. Los sujetos C02, C04 y C05 declaran que no les ha resultado difícil seleccionarlos, mientras que los sujetos C01 y C03 indican que sí existe cierta dificultad. Estos resultados concuerdan bastante con las precisiones obtenidas, donde los sujetos C02 y C04 siempre se han encontrado por encima del resto.

Tampoco se ponen de acuerdo a la hora de determinar si el tiempo necesario para seleccionar un nodo es grande o no. Los sujetos C01, C02 y C04 reflejan en el cuestionario que el tiempo necesario no les ha resultado muy grande, sin embargo, los sujetos C03 y C05 opinan que éste tiempo es bastante grande, quizás porque los *warnings* o errores obtenidos ralentizaron las selecciones.

Con respecto a la adquisición de la señal, todos los sujetos exceptuando el sujeto C03 determinaron que la adquisición de la actividad cerebral mediante EEG con el gorro y electrodos activos es muy práctica.

Posteriormente, los sujetos C02 y C04 reflejaron que la duración de las sesiones realizadas es completamente adecuada, mientras que el resto de los usuarios reflejaron ciertas reticencias. Para finalizar, todos los sujetos estuvieron de acuerdo en que volverían a participar en un proyecto de características similares.

Adicionalmente, tres de los sujetos propusieron sugerencias para mejorar la aplicación. Las sugerencias más apropiadas son el aumento del tiempo entre intentos (propuesta por el sujeto C02), el cual podría permitir pensar mejor los comandos a seleccionar en cada momento y tener más tiempo de reacción; la inclusión de un conmutador entre mayúsculas y minúsculas, útil en sitios web que requieren contraseñas (propuesta por el sujeto C03); y finalmente, la optimización de la posición de las etiquetas de los nodos, evitando superposición entre ellas, y de la altura de la pantalla para poder recibir con la misma intensidad las distintas celdas de la matriz (propuestas por el sujeto C05).

Quizás las dos primeras sugerencias son las más importantes de cara a la mejora de las funcionalidades de la aplicación en sí. Establecer mayor tiempo entre cada intento permitiría aumentar el tiempo de reacción de cada usuario, sin embargo, reduciría la velocidad de la aplicación. Es, por tanto, un compromiso que podría adaptar el usuario en los parámetros del “Operador”. La segunda sugerencia radicaba en incluir un conmutador para intercalar entre mayúsculas y minúsculas. Esta sugerencia es de vital importancia para los sitios en los que la distinción entre este tipo de letras es fundamental, por tanto, podría implementarse en la matriz de teclado.

El sujeto C03 demandó una sesión más corta para entrenar el clasificador y una adquisición de la señal menos molesta, sin la utilización del gel conductor. Lamentablemente, estos aspectos están fuera del ámbito de la aplicación puesto que la duración de la sesión de entrenamiento determina completamente el rendimiento posterior y la adquisición de la señal con gel conductor actualmente es necesaria para reducir la impedancia del cráneo. Finalmente, el sujeto C05 sugirió la inclusión del conmutador “TAG” en la matriz de teclado. Sin embargo, la inclusión de éste botón en esa matriz haría inútil la distinción entre matriz de navegación y de teclado, y aumentaría el tiempo necesario para seleccionar un comando en ésta última.

7.3.2. Enfermos de esclerosis múltiple

Con respecto a la satisfacción de los sujetos EM, es posible afirmar que los participantes se mostraron bastante satisfechos con la aplicación. De hecho, todas las afirmaciones positivas fueron puntuadas por encima del valor medio (4, neutral) y casi todas las negativas por debajo del mismo. Las excepciones fueron las cuestiones 4 y 11, donde el valor medio no fue inferior al neutral, pero sí cercano al mismo (4,77 y 4,23, respectivamente).

En el caso de la cuestión 4, la cual evaluaba la rapidez del navegador, indica que no todos los sujetos EM estuvieron totalmente de acuerdo en que es rápido navegar por Internet con la aplicación desarrollada. En el caso de la 11, los sujetos EM manifestaron estar ligeramente de acuerdo con que se encontraban felices de que se hubieran terminado las sesiones de evaluación. Esto indica que su participación en el estudio les supone un esfuerzo que debe tenerse en cuenta a la hora de planificar y diseñar el contenido y la duración de las sesiones.

De hecho, las sugerencias de mejora recogidas apuntan hacia la misma dirección. Los usuarios U01 y U14 demandaron más rapidez en la selección de comandos. Sin embargo, la rapidez en la selección de comandos recae directamente en el número de secuencias óptimo para cada usuario y, por tanto, en la calidad de su clasificador. Reducir el número de secuencias, o lo que es lo mismo, incrementar la rapidez en la selección de comandos, implica reducir la cantidad de información que se introduce en el clasificador, lo cual aumenta las probabilidades de causar un error. En el caso de U01 y U14, si bien no eran los sujetos con menor precisión, tampoco obtuvieron unos resultados tan sorprendentes como para incrementar la velocidad de selección de comandos de manera drástica. La única solución viable radica en crear un clasificador más general y preciso, el cual requiriese menos secuencias para funcionar correctamente.

Al igual que el sujeto C03, los sujetos U03 y U08 reincidieron en que la iluminación de las filas y las columnas de la matriz se hace molesta, especialmente después de la decena de iluminaciones de cada fila y columna. No obstante, como se ha comentado anteriormente, dicha adquisición de la señal es estrictamente necesaria para la aplicación, y la sugerencia se encuentra fuera del ámbito de la misma.

El sujeto U07 indicó que sería más adecuado el disminuir el tiempo de las sesiones, aunque haya que aumentar el número de éstas. Esta realimentación hay que tenerla en cuenta, puesto que está directamente relacionada con el esfuerzo que les supone a los usuarios evaluar la aplicación.

Finalmente, el usuario U02 sugirió el incluir en la matriz de comandos un tabulador, lo cual aumentaría la rapidez para seleccionar formularios. También sugiere incluir un comando que permita crear y moverse entre pestañas. Aunque no son de vital importancia, ambas sugerencias se podrían tener en cuenta para un diseño futuro de una mejora de la aplicación, con más funcionalidades que las incluidas hasta ahora.

7.4. Comparativa en la clasificación: SWLDA, s-SVM y e-SVM

Como respuesta a la necesidad de mejorar la clasificación, se ha realizado un análisis *off-line* de los datos recogidos en las sesiones de evaluación y se han aplicado dos técnicas de entrenamiento del clasificador distintas.

En la Figura 7-10 se muestran las precisiones medias con su correspondiente desviación típica para cada uno de los usuarios. Como se puede observar, las precisiones más altas se alcanzan para las 24 muestras ($f_{sub} = 30 Hz$). Además, se observa una tendencia general que muestra cómo el conjunto de 4 SVMs (e-SVM) obtiene la mayor precisión de los tres métodos, seguido por el SVM simple (s-SVM) y finalmente el método de partida, SWLDA.

Se observa también un claro aumento de la precisión a medida que aumenta el número de muestras por estímulo. Este resultado es evidente, puesto que a mayor cantidad de información mayor capacidad para discriminar correctamente tendrá el clasificador. No obstante, para 28 muestras ($f_{sub} = 35 Hz$) comienza a decaer la precisión, alcanzando el máximo en 24 muestras, probablemente debido a algún tipo de sobre-entrenamiento.

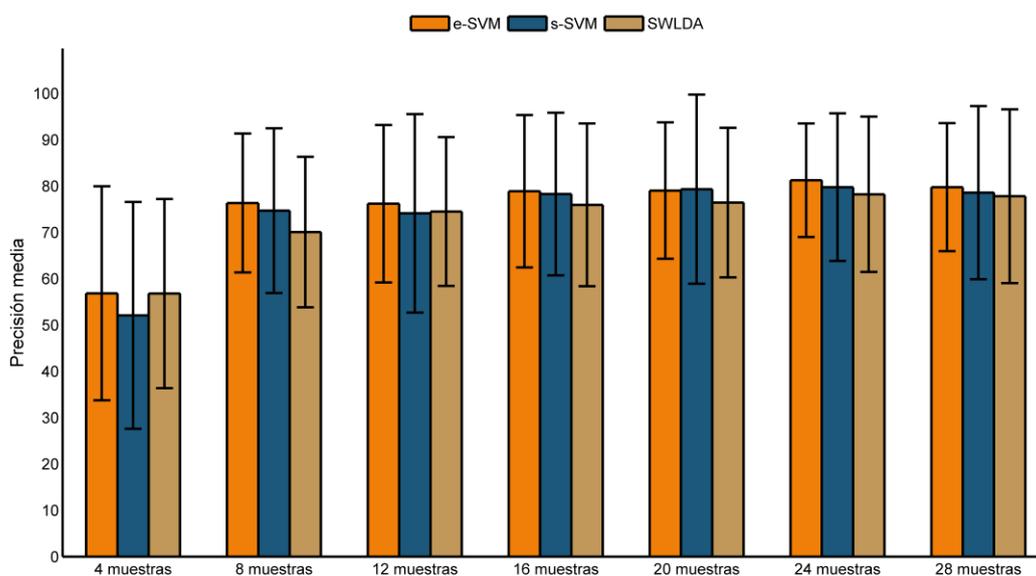


Figura 7-10. Precisiones medias y desviaciones estándar obtenidas para cada uno de los tipos de clasificación variando el submuestreo, donde: e-SVM es el conjunto de 4 SVM lineales, s-SVM es solamente un SVM lineal y SWLDA es el método original.

También hay que tener en cuenta que a medida que aumenta el número de muestras por estímulo, mayor carga computacional requerirá la aplicación. Si se incrementase demasiado el número de muestras de cada estímulo se podría perder la capacidad de realizar el análisis a tiempo-real, algo esencial en este tipo de aplicación.

Además, es necesario destacar que, aunque se realice una reducción de dimensionalidad del espacio de características gracias al submuestreo del EEG en crudo, los SVM están igualmente sobre-entrenados. Aunque se consideren solamente 16 muestras por estímulo, teniendo en cuenta que se realizan 15 secuencias aproximadamente (al menos en Cal-I), de 6 intentos en 4 rondas y con 8 canales al mismo tiempo, el número de características introducidas a cada SVM es inmenso. De hecho, por cada estímulo se introducirían $8 \times 16 = 128$ características. A pesar del sobre-entrenamiento, los mejores resultados en clasificación P300 para BCI documentados en la literatura los obtienen los SVM.

Sin embargo, aunque se aprecie una mejora en la clasificación con respecto a SWLDA, no es drástica. Solamente mejora la clasificación ligeramente, con una diferencia máxima de un 6,05% para 8 muestras con respecto a SWLDA. En el caso de las 24 muestras, se produce una mejora de 3,75%.

La ligera mejoría producida sigue poniendo de manifiesto que se requiere una mayor precisión en la clasificación, ya sea seleccionando algún tipo de método de extracción de características distinto o utilizando otros clasificadores más robustos y, quizás, más sofisticados.

7.5. Comparación con otros estudios

En la Tabla 7-1 se muestra una comparativa del presente estudio con respecto algunas aproximaciones similares desarrolladas con anterioridad, atendiendo a la señal de control empleada, las funcionalidades del navegador y la evaluación por parte de sujetos sanos y enfermos.

Atendiendo a las funcionalidades de la aplicación, la mayor similitud se encuentra con respecto al estudio de Mugler et al [26] puesto que, aunque muchos otros estudios también hayan utilizado los potenciales evocados P300 como señales de control (Sirvent Blasco et al [27] y Yu et al [28]), es el único que también selecciona los hipervínculos de una web etiquetándolos con una codificación única.

El resto de navegadores utilizan una metodología distinta para seleccionar los hipervínculos de la web. En Bensch et al [23] se rodean de un borde rectangular de dos posibles colores, y se seleccionan a través de una selección binaria mediante los potenciales SCP. En Sirvent Blasco et al [27] y en Yu et al [28] se seleccionan mediante el desplazamiento de un cursor controlado con los potenciales evocados P300 y, adicionalmente, con N2PC y ritmos sensoriomotores, respectivamente.

Sin embargo, también posee diferencias con respecto al estudio Mugler et al [26]. Entre ellas destaca el hecho de que en esta aplicación se establece un umbral para distinguir si el usuario desea seleccionar un comando determinado o, por el contrario, desea leer una página web tranquilamente, mientras que en Mugler et al [26] se establece un tiempo de lectura que no permite seleccionar nada al usuario, ralentizando la aplicación y convirtiéndose así en un navegador más rígido que el implementado en el presente Trabajo Fin de Máster. De hecho, ninguno de los estudios comparados anteriormente son aplicaciones asíncronas, ni implementan un umbral de decisión.

TABLA 7-1. COMPARATIVA ENTRE LOS NAVEGADORES WEB BCI DESARROLLADOS CON ANTERIORIDAD Y EL PRESENTE ESTUDIO.

Navegador Web	Año	Señal de control ⁽¹⁾	Tipo de señal ⁽²⁾	Funcionalidades			Evaluación	
				Selección de nodos	Implementa Umbral	Modo de lectura	Sujetos ⁽³⁾	Precisión
Bensch et al [23]	2007	SCPs	ENDO	Binaria	No	Supervisión	4 ALS	-
							2 SC	-
Mugler et al [26]	2010	P300	EXO	Etiquetado	No	Sí	3 ALS	72,00%
							10 SC	90,00%
Blasco et al [27]	2012	P300	EXO	Cursor	No	No	7 SC	93,00%
Yu et al [28]	2012	P300 y ritmos	EXO y ENDO	Cursor	No	No	12 SC	93,21%
Presente estudio	2015	P300	EXO	Etiquetado	Sí	No	16 EM	80,80%
							5 SC	96,70%

⁽¹⁾ SCP: Potenciales corticales lentos. P300: Potenciales evocados P300.

⁽²⁾ ENDO: Señal endógena (requiere entrenamiento para controlarla). EXO: Señal exógena (no requiere entrenamiento, es una respuesta natural del cerebro).

Adicionalmente, esta aplicación no requiere supervisión, a diferencia de Bensch et al [23]. No obstante, destaca el hecho de que todos los estudios implementan la funcionalidad de edición de la barra de URL, permitiendo introducir caracteres directamente en ella, funcionalidad no implementada en la aplicación desarrollada.

En términos de precisión, la aplicación desarrollada consigue precisiones bastante más altas para sujetos SC que el resto de navegadores, concretamente, se obtiene una precisión media en las tareas propuestas del 96,70% para los cinco sujetos SC, por encima del 90% de Mugler et al [26], el 93,21% de Yu et al [28] y el 93% de Sirvent Blasco et al [27].

Con respecto a la población de enfermos, en este estudio se obtiene una precisión *gran average* de 80,80% para los sujetos EM. Sigue siendo superior a la obtenida para los sujetos con esclerosis lateral amiotrófica (ELA) en Mugler et al [26], con su 72% de precisión. Nótese que el resto de navegadores web no han evaluado la aplicación con ningún tipo de población enferma o no han especificado las precisiones obtenidas.

7.6. Limitaciones de la aplicación

Dentro de las limitaciones de la aplicación destaca el hecho de que no incluye los marcadores con las webs más visitadas por el usuario o un historial para consultar qué web ha visitado anteriormente, funcionalidades prescindibles pero que dotarían al navegador de mayor complejidad.

Adicionalmente, según se ha advertido en la discusión del cuestionario, la introducción de una barra editable de URL facilitaría mucho la fluidez de la aplicación. También cabe señalar que la aplicación no diferencia entre mayúsculas y minúsculas, sin embargo, muchas páginas web (normalmente las que requieren contraseñas) lo hacen, convirtiéndose en una limitación que debe solventarse en una futura versión. También podrían añadirse un tabulador, con el fin de navegar por los formularios más rápidamente, y la posibilidad de crear pestañas.

Aunque la precisión obtenida es superior a todos los estudios realizados anteriormente, una mejora en el procesado de la señal podría mejorarlas, tanto en la extracción como en la traducción de características. Actualmente, la aplicación podría

ser adecuada para el uso de personas con grave discapacidad, pero aún necesita mejorar la clasificación para este tipo de sujetos para evitar que un pequeño error requiera ser subsanado con varias selecciones adicionales. Concretamente, se busca una mayor generalización del clasificador, lo cual permitiría discriminar la intención del usuario minimizando, en medida de lo posible, las variaciones producidas inter-sesión.

Para finalizar, surge la necesidad de evaluar la aplicación con pacientes de ELA, más habitual en la literatura que los sujetos EM. Podría especularse que se obtendrían mejores resultados, puesto que el daño cognitivo que se presenta normalmente en los sujetos EM no suele presentarse en los sujetos ELA, cuyo daño afecta exclusivamente a las neuronas motoras.

CONCLUSIONES Y LÍNEAS FUTURAS

8.1. Conclusiones

A lo largo del presente trabajo se ha llevado a cabo un estudio sobre los sistemas BCI, analizando los principales métodos para registrar la actividad cerebral y los tipos de señales de control que gobiernan dichos sistemas. Se ha considerado el método del EEG como la mejor solución para desarrollar la aplicación web debido a que se trata de un método no invasivo, portátil y de bajo coste. También se han estudiado las etapas principales del procesado de la señal EEG, empezando por la etapa de adquisición de la señal, seguida por la extracción de características y terminando por el algoritmo de traducción, también conocido como traducción de características. Adicionalmente, se ha realizado una búsqueda exhaustiva del estado del arte sobre los navegadores web diseñados anteriormente y se han comparado entre ellos para extraer las ventajas y los inconvenientes de cada uno de ellos. En base a esa comparativa se han propuesto los objetivos de la aplicación y se han elegido los potenciales evocados P300 como la señal de control más apropiada.

Posteriormente, se han detallado en profundidad las características de los potenciales evocados P300 y la variación de su forma según los aspectos psicológicos y farmacológicos de los sujetos o las diferencias individuales entre ellos. Una vez estudiada la señal de control a utilizar, se han detallado los diversos métodos de extracción de características para los potenciales evocados P300 utilizados con anterioridad, considerando un análisis espacial, temporal y espectral. Dentro del análisis espacial se han descrito el filtrado Laplaciano, los métodos de referencia de media común, el análisis de componentes independientes y el análisis de componentes principales. Con respecto a las técnicas de análisis temporal, se han tratado el promediado sincronizado, la detección de picos y el cálculo del área. En último lugar, dentro del análisis espectral se han introducido los conceptos de transformada de Fourier de tiempo corto y las transformadas *wavelet*. Después de detallar la extracción de características se han recogido los métodos principales de traducción de las mismas, entre ellos el discriminante lineal de Fisher, y se ha puesto especial énfasis en el análisis discriminante lineal paso-a-paso y las máquinas de vectores de soporte, métodos utilizados en la aplicación desarrollada. También se han introducido los conceptos de sensibilidad, especificidad y las curvas ROC con el fin de crear un umbral óptimo que discrimine entre dos poblaciones, el cual permite convertir la aplicación síncrona en una aplicación asíncrona, salvando las principales limitaciones de los navegadores desarrollados con anterioridad.

En cuanto al diseño de la aplicación de navegación web basado en la señal EEG y los potenciales evocados P300, el primer paso ha consistido en recopilar las necesidades de la aplicación y formular los objetivos de diseño. Una vez establecidos se ha estructurado la misma en dos partes principales: etapa de procesado EEG y etapa de navegación. Donde la primera ha sido desarrollada con la ayuda del sistema de propósito general BCI2000, cuya finalidad es la de facilitar el desarrollo, la investigación y la monitorización de aplicaciones en tiempo real que requieren adquirir y procesar una señal EEG.

La etapa de procesado del EEG se ha implementado en lenguaje C++ y se encarga de adquirir y procesar la señal EEG a través de BCI2000. Para ello, se ha utilizado un filtrado espacial CAR seguido de un submuestreo del EEG en crudo como métodos de extracción de características, y un algoritmo SWLDA como método de traducción. También se encarga de producir los potenciales evocados P300 necesarios para controlar la aplicación mediante el paradigma *odd-ball*, consistente en presentar una serie de estímulos objetivo infrecuentes camuflados entre estímulos frecuentes. Cuando el usuario detecta los estímulos objetivos genera un potencial evocado P300 que detectará la aplicación y determinará el comando que deseaba seleccionar el usuario. Este paradigma *odd-ball* lo controlan dos matrices, denominadas matriz de teclado y matriz de navegación, que implementan comandos distintos. Una vez determinado el comando deseado, el umbral clasifica la atención del usuario: si éste ignora los estímulos no se enviará el comando y, en caso contrario, sí se enviarán hacia la última etapa de la aplicación.

Dicha etapa se ha implementado como una extensión del navegador web a controlar, *Google Chrome*, en lenguaje JavaScript. La finalidad de esta etapa consiste en procesar los comandos de teclado recibidos de la otra parte de la aplicación y traducirlos en comandos del navegador web. Además, se encarga de implementar la interfaz gráfica del navegador, compuesta por una serie de hipervínculos codificados con ciertos caracteres alfanuméricos y un *buffer* que recoge las pulsaciones recibidas.

Una vez desarrollada la aplicación, ésta ha sido evaluada por parte de cinco sujetos sanos durante tres sesiones distintas. La disposición de los electrodos ha seguido la norma internacional 10/20, ubicando los mismos en las localizaciones Fz, Cz, Pz, P3, P4, PO7, PO8 y Oz. Al principio de la primera sesión de calibración se ha entrenado el clasificador SWLDA de cada usuario, tratando de estimar el vector de pesos adecuado. En la última parte de la primera sesión y en la segunda sesión de calibración se ha determinado el umbral óptimo para cada usuario, monitorizando la intensidad de los potenciales P300 para cuando el usuario atendía o ignoraba los estímulos. Finalmente, en la tercera sesión se han realizado cuatro pruebas con el fin de evaluar el rendimiento general de la aplicación. Al terminar ésta sesión, se ha entregado a los usuarios un cuestionario de satisfacción, donde han reflejado sus experiencias y las sugerencias de mejora.

Una vez identificadas las limitaciones y las sugerencias de mejora de la aplicación, se evaluó la aplicación por parte de dieciséis sujetos enfermos de EM, reclutados a través del CRE-DyD de San Andrés del Rabanedo (León). El procedimiento de evaluación se adaptó a dichos usuarios, aumentando una sesión pero disminuyendo la carga de cada una de ellas. Por tanto, se emplearon dos sesiones de calibración y otras dos de evaluación. Al igual que para los sujetos SC, se les proporcionó un cuestionario de satisfacción para recoger las opiniones y sugerencias de los futuros usuarios de la aplicación. Este cuestionario era más completo que el realizado con los sujetos sanos, puesto que se ha considerado más importante la opinión de los pacientes EM.

Para terminar, se han expuesto los resultados obtenidos y se han discutido. Estos resultados reflejan el buen funcionamiento del sistema para los sujetos SC, cuyas precisiones no bajan del 92,6%, lo cual significa que más del 90% de las selecciones realizadas para todos los sujetos SC en todas las sesiones han sido correctas. De hecho, dos sujetos SC han obtenido precisiones del 100% para todas las sesiones realizadas. El cuestionario de satisfacción muestra que los usuarios opinan que la interfaz del sistema es sencilla y fácil de aprender, que la selección de comandos con la matriz de navegación es sencilla y que habitualmente no se seleccionan comandos no deseados.

Sin embargo, difieren en la dificultad de selección en la matriz de teclado, más grande y complicada, y en general a los usuarios que han obtenido mejores resultados les resulta más sencillo que al resto.

No obstante, las precisiones obtenidas por parte de los sujetos EM son inferiores a las obtenidas para sujetos SC, como era de esperar. Muchos de ellos no han sido capaces de terminar las tareas, aunque la precisión media ronde el 80,80%. Tres de los sujetos EM no obtuvieron una precisión lo suficientemente alta en las sesiones de calibración como para poder continuar la evaluación, y por lo tanto, fueron descartados. Se especula que esto podría deberse a la discapacidad moderada que sufrían los tres, y a la dificultad de atención sostenida que presentaba uno de ellos. Como se ha podido observar, los potenciales P300 de cada uno de ellos eran prácticamente irreconocibles.

A raíz de estos resultados, se ha tratado de mejorar la clasificación y el submuestreo de la señal EEG en crudo, con el fin de aumentar la generalización de la clasificación para los sujetos EM. Para ello, se han utilizado un conjunto de cuatro SVMs lineales y un SVM simple. Las precisiones obtenidas muestran que los mejores resultados se obtienen para el conjunto de SVM son mayores que para el resto de algoritmos de traducción, alcanzando el máximo para 24 muestras EEG por estímulo. No obstante, aunque la mejora producida provoca que las precisiones obtenidas sean superiores a las de los navegadores web desarrollados con anterioridad, sigue estando presente la necesidad de mejorar la clasificación.

Se concluye que el sistema funciona de manera excepcional una vez se han adecuado correctamente el clasificador y el umbral de cada usuario individual para los sujetos SC, obteniendo precisiones superiores al 90%. En el caso de los sujetos EM, la aplicación funciona con una precisión en torno al 80%. Sin embargo, la adecuación de estos parámetros implica varias sesiones de entrenamiento, hecho que a algunos usuarios les resulta incómodo o demasiado tedioso. No obstante, aunque las precisiones obtenidas sean altas, la aplicación aún debe madurar e implementar muchas más funcionalidades, además de mejorar las ya existentes.

A modo de resumen, se incluye a continuación un listado de las conclusiones extraídas:

1. **Selección del EEG y potenciales evocados P300 como método de registro y señal de control utilizada, respectivamente.** Se ha seleccionado el EEG por ser un método no invasivo, portátil y de bajo coste. Los potenciales P300 se han seleccionado como señal de control puesto que son exógenos y permiten una selección entre múltiples opciones gracias al paradigma *odd-ball*.
2. **Diseño de un navegador web BCI asíncrono.** La mayor limitación de los navegadores web BCI desarrollados con anterioridad era su sincronía, es decir, las matrices de selección seleccionaban comandos continuamente. Esto obligaba a incluir un comando de “tiempo de lectura” de duración fija o a requerir supervisión. El navegador web BCI desarrollado supera esta limitación incluyendo un umbral ROC que discrimina según el nivel de atención del usuario, conformando la asincronía de la aplicación.
3. **Selección del submuestreo de la señal EEG cruda y de SWLDA como métodos de extracción y clasificación de características, respectivamente.** Atendiendo a las aproximaciones anteriores más precisas, se han utilizado un submuestreo de la señal EEG en crudo como extracción de características y un clasificador SWLDA como algoritmo de traducción de las mismas en la evaluación de la aplicación.

4. **Evaluación de la aplicación con 5 sujetos sanos y 16 enfermos de esclerosis múltiple.** Se ha evaluado la aplicación con 5 sujetos SC y 16 sujetos EM, reclutados a través del CRE-DyD de San Andrés del Rabanedo (León). El procedimiento de evaluación se ha dividido en dos partes: sesiones de calibración, necesarias para entrenar el clasificador mediante SWLDA y crear el umbral, y sesiones de evaluación, donde se han establecido una serie de tareas de dificultad progresiva. Adicionalmente, se ha creado un cuestionario de satisfacción, con el fin de recoger la experiencia y las sugerencias de cada uno de los usuarios.
5. **Discusión de los resultados y comparación con otros estudios.** Se han discutido los resultados, declarando el buen funcionamiento de la aplicación para los sujetos SC, cuya precisión media es del 96,70%, y para los EM, cuya precisión media ronda el 80,80%. Además, se concluye que ambas precisiones son más altas que las obtenidas en los navegadores web BCI desarrollados con anterioridad.
6. **Mejora de la clasificación *off-line* con s-SVM y e-SVM.** A raíz de los resultados obtenidos, se ha tratado de mejorar la clasificación *off-line* implementando un s-SVM y un conjunto e-SVM. Además, se han comparado las precisiones obtenidas con SWLDA. Se concluye que los mejores resultados de clasificación los obtiene el algoritmo e-SVM, seguido por s-SVM y, finalmente, el utilizado en la evaluación: SWLDA.
7. **Discusión de los resultados y comparación con otros estudios.** Se han discutido los resultados, declarando el buen funcionamiento de la aplicación para los sujetos SC, cuya precisión media es del 96,70%, y para los EM, cuya precisión media ronda el 80,80%. Además, se concluye que ambas precisiones son más altas que las obtenidas en los navegadores web BCI desarrollados con anterioridad.

8.2. Líneas Futuras

Las líneas futuras de la aplicación web desarrollada tratan de solventar sus limitaciones añadiendo nuevas funcionalidades o modificando las ya existentes. Como introducción de nuevas funcionalidades, se podría hablar de añadir una serie de marcadores que pueda editar el usuario. De esta manera, el usuario podrá encontrar más fácilmente sus páginas web favoritas, sin necesidad de invertir tiempo buscándolas en *Google*. Otra funcionalidad podría ser la introducción de un comando que permita modificar la barra de URL, para aumentar la velocidad a la hora de desplazarse a una web concreta, y también se podría implementar una funcionalidad que mostrase el historial reciente y permitiese visitar las webs incluidas en el mismo. Además, se podría optimizar la localización de las etiquetas que codifican los nodos de la web para evitar, a toda costa, una superposición entre ellas. Adicionalmente, un usuario determinó que sería útil poder alternar entre mayúsculas y minúsculas, sobre todo a la hora de navegar por webs que requieren la introducción de contraseñas con ciertos requisitos de seguridad; y otro usuario insistió en introducir un tiempo mayor entre cada intento en las matrices P300 para pensar mejor el comando que se debe seleccionar, sugerencias a tener en cuenta. También podría implementarse un tabulador, útil para navegar rápidamente entre formularios; o implementar la posibilidad de crear pestañas.

Atendiendo al procesado de la señal EEG, se podrían implementar técnicas de procesado diferentes, tanto para la extracción de características como para la

traducción de las mismas, siempre teniendo en cuenta que la aplicación debe trabajar en tiempo-real. Se busca una mayor generalización del clasificador, lo cual permitiría discriminar la intención de los enfermos minimizando, en medida de lo posible, las variaciones producidas inter-sesión.

Para finalizar, una futura línea de investigación sería el evaluar la aplicación con pacientes de ELA. Podría especularse que se obtendrían mejores resultados, puesto que el daño cognitivo que se presenta normalmente en los sujetos EM no suele presentarse en este tipo de sujetos, cuyo daño afecta exclusivamente a las neuronas motoras.

REFERENCIAS

- [1] J. López, y E. Martos, "Caracterización de Señales Aleatorias," in *Señales Aleatorias*, 1st ed. Malaga: Marcombo S.A, pp. 116–119, 2011.
- [2] L. Sörnmo, y P. Laguna, *Bioelectrical Signal Processing in Cardiac and Neurological Applications*, 1st ed. Sweden: Academic Press, pp. 1-24, June 2005.
- [3] S. M. Landau, "Comparing rates of change in cognitive measurements and regional glucose metabolism in Alzheimer's disease and mild cognitive impairment: Data from the Alzheimer's disease neuroimaging initiative," *Neurology*, vol. 70, no. 11, Philadelphia: Lippincott Williams & Wilkins, 2008.
- [4] H. H. Jasper, "The ten twenty electrode system of the International Federation," *Electroenceph. Clin. Neurophysiol.*, vol. 10, pp. 371–375, 1958.
- [5] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, y T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clin. Neurophysiol.*, vol. 113, pp. 767–1 79, 2002.
- [6] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks, D. J. McFarland, P. H. Peckham, G. Schalk, E. Donchin, L. A. Quatrano, C. J. Robinson, y T. M. Vaughan, "Brain-computer Interface technology: a review of the first international meeting," *IEEE Trans. Rehab. Eng.*, vol. 8, pp. 164–173, June 2000.
- [7] B. Hemmer, B. Kieseier, S. Cepok, y H. P. Hartung, "New immunopathologic insights into multiple sclerosis," *Curr. Neurol. Neurosci.*, vol. 3, no. 3, pp. 246–255, 2003.
- [8] World Health Organization, *Atlas: Multiple Sclerosis Resources in the World*, Génova, pp. 1–10, 2008.
- [9] A. Compston, y A. Coles, "Multiple Sclerosis," *The Lancet*, vol. 372, no.9648, pp. 1502–1517, 2008.
- [10] E. M. Steultjens, J. Dekker, L. M. Bouter, M. Cardol, J. C. Van de Nes, y C. H. Van den Ende, "Occupational therapy for Multiple Sclerosis," *Cochrane Database Syst. Rev.*, vol. 3, 2003.
- [11] J. J. Vidal, "Real-time detection of brain events in EEG," *Proc. IEEE*, vol. 65, pp. 633–664, 1977.
- [12] J. R. Wolpaw, G. E. Loeb, B. Z. Allison, E. Donchin, O. Feix do Nascimento, W. J. Heetderks, F. Nijboer, W. G. Shain, y J. N. Turner, "BCI meeting 2005-workshop on signals and recording methods," *IEEE Trans. Rehab. Eng.*, vol. 14, no. 2, pp.138–141, 2006.
- [13] O. Friman, I. Volosyak, y A. Gräser, "Multiple channel detection of steady-state visual evoked potentials for Brain-Computer Interfaces," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 4, pp. 742–750, 2007.
- [14] M. Middendorff, G. McMillan, G. Calhoun, y K. S. Jones, "Brain-computer interfaces based on steady-state visual evoked response," *IEEE Trans. Rehab. Eng.*, vol. 8, no.2, pp. 211–214, 2000.
- [15] J. Guan, Y. Ghen, J. Lin, Y. Yuan, y M. Huang, "N2 components as features for Brain Computer Interface," *Proc. 2005 First International Conference on Neural Interface and Control*, pp. 45–49, 2005.
- [16] N. Birbaumer, "Slow cortical potentials: their origin, meaning, and clinical use," in *Brain and behavior past, present, and future*, 1st ed. The Netherlands: Tilburg University Press, pp. 25–39, 1997.

- [17] T. Hinterberger, N. Weiskopf, R. Veit, B. Wilhelm, E. Betta, y N. Birbaumer, "An EEG-driven Brain-Computer Interface combined with functional Magnetic Resonance Imaging (fMRI)," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, pp. 971–974, 2004.
- [18] G. Pfurtscheller, y C. Neuper, "Motor imagery and direct brain-communication," *Proc. IEEE*, vol. 89, no. 7, pp. 1123–1134, 2001.
- [19] J. Hu, J. Si, B. P. Olson, y J. He, "Principle component feature detector for motor cortical control," *Proc. 26th Annual International Conference of the IEEE EMBS*, pp. 4021–4024, 2004.
- [20] D. J. McFarland, C. W. Anderson, K.R. Müller, A. Schlögl, y D. J. Krusienski, "BCI meeting 2005–workshop on BCI signal processing: feature extraction and translation," *IEEE Trans. Rehab. Eng.*, vol. 14, no. 2, pp. 135–138, 2006.
- [21] K. R. Müller, C. W. Anderson, y G. E. Birch, "Linear and nonlinear methods for Brain-Computer Interfaces," *IEEE Trans. Rehab. Eng.*, vol. 11, no. 2, pp. 165–169, 2003.
- [22] G. E. Fabiani, D. J. McFarland, J. R. Wolpaw, y G. Pfurtscheller, "Conversion of EEG activity into cursor movement by a Brain-Computer Interface (BCI)," *IEEE Trans. Rehab. Eng.*, vol. 12, no. 3, pp. 331–338, 2004.
- [23] M. Bensch, A. A. Karim, J. Mellinger, T. Hinterberger, M. Tangermann, y M. Bogdan, "Nessi: an EEG-controlled web browser for severely paralyzed patients," *Comput. Intell. Neurosci.*, vol. 2007, 2007.
- [24] J. A. Pineda, D. S. Silverman, A. Vankov, y J. Hestenes, "Learning to control brain rhythms: making a Brain-Computer Interface possible," *IEEE Trans. Rehab. Eng.*, vol. 11, no. 2, pp. 181–184, 2003.
- [25] L. J. Trejo, R. Rosipal, y B. Matthews, "Brain-Computer Interfaces for 1-D and 2-D cursor control: designs using volitional control of the EEG spectrum or steady-state Visual Evoked Potentials," *IEEE Trans. Neural. Syst. Rehabil. Eng.*, vol. 14, no 2, pp. 225–229, 2006.
- [26] Mugler E. M., C. A. Ruf, S. Halder, M. Bensch, y A. Kübler, "Design and implementation of a P300-based Brain-Computer Interface for controlling an Internet browser," *IEEE Trans. Neural. Syst. Rehabil. Eng.*, vol. 18, no 6, pp. 599–609, 2010.
- [27] J. L. Sirvent Blasco, E. Lánuez, A. Úbeda, y J. M. Azorín, "Visual Evoked Potential-based Brain-Machine Interface applications to assist disabled people," *Expert Syst. Appl.*, vol. 39, no 9, pp. 7908–7918, 2012.
- [28] T. Yu, Y. Li, J. Long, y Z. Gu, "Surfing the Internet with a BCI mouse," *J. Neural Eng.*, vol. 9, no 3, pp. 036012, 2012.
- [29] T. Liu, L. Goldberg, S. Gao, y B. Hong, "An online Brain-Computer Interface using non-flashing Visual Evoked Potentials," *J. Neural Eng.*, vol. 7, no 3, pp. 036003, 2010.
- [30] J. Yin, D. Jiang, y J. Hu, "Design and application of Brain-Computer Interface web browser based on VEP", in *Biomedical Information Engineering, FBIE 2009. International Conference on Future. IEEE*, pp. 77–80, 2009.
- [31] ITU-R Recommendation BT.709: "Parameter Values for the HDTV standards for production and international programme exchange" (4.2 Signal format: derivation of luminance signal).
- [32] A. Kübler, A. Furdea, S. Halder, E. M. Hammer, F. Nijboer, y B. Kotchoubey, "A Brain-Computer Interface controlled auditory Event-Related Potential (P300) spelling system for locked-in patients," *Annals NY Academy of Sciences*, vol. 1157, no 1, pp. 90–100, 2009.
- [33] T. W. Picton, "The P300 wave of the human event-related potential," *J. Clin. Neurophysiol.*, vol. 9, no 4, pp. 456–479, 1992.
- [34] R. M. Rangayyan, "Filtering for Removal Artifacts," in *Biomedical Signal Analysis: A Case-Study Approach*, Canada: IEEE Press & Wiley, pp. 73–176, 2002.
- [35] N. K. Squires, K. C. Squires, y S. A. Hillyard, "Two varieties of long-latency positive waves evoked by unpredictable auditory stimuli in man," *Electroencephalogr. Clin. Neurophysiol.*, vol. 8, pp. 387–401, 1975.

- [36] R. M. Stelmack, M. Houlihan, y P. A. McGarry-Roberts, "Personality, reaction time, and event-related potentials," *J. Pers. Soc. Psychol.*, vol. 65, no 2, pp. 399, 1993.
- [37] M. Klein, M. G. H. Coles, y E. Donchin, "People with absolute pitch process tones without producing a P300," *Science*, vol. 223, no 4642, pp. 1306–1309, 1984.
- [38] G. Schalk, y J. Mellinger, *A Practical Guide to Brain-Computer Interfacing with BCI2000*, London: Springer, 2010.
- [39] D. J. McFarland, L. M. McCane, S. V. David, y J. R. Wolpaw, "Spatial filter selection for EEG-based communication," *Electroenceph. Clin. Neurophysiol.*, vol. 103, pp. 386–394, 1997.
- [40] K. Li, R. Sankar, Y. Arberl, y E. Donchin, "Single trial independent component analysis for P300 BCI system," *Engineering in Medicine and Biology Society, EMBC 2009. Annual International Conference of the IEEE*, pp. 4035–4038.
- [41] R. T. C. Lee, Y. H. Chin, y S. C. Chang, "Application of Principal Component Analysis to multikey searching," *IEEE Trans. Softw. Eng.*, vol. SE-2, no.3, pp.185-193, 1976.
- [42] E. Donchin, K. M. Spencer, y R. Wijesinghe, "The mental prosthesis: assessing the speed of a P300-based Brain-Computer Interface," *IEEE Trans. Rehab. Eng.*, vol. 8, no. 2, pp. 174–179, 2000.
- [43] L. A. Farwell, y E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials," *Electroencephalogr. Clin. Neurophysiol.*, vol. 70, no 6, p. 510–523, 1988.
- [44] M. Kaur, P. Ahmed, y M. Q. Rafiq, "Analysis of extracting distinct functional components of P300 using wavelet transform," *Proceedings of 4th MMES and the 2nd ICDCC*, pp. 57–62, 2013.
- [45] D. J. Krusienski, E.W. Sellers, F. Cabestaing, S. Bayouth, D. J. McFarland, T. M. Vaughan, y J. R. Wolpaw, "A comparison of classification techniques for the P300 Speller," *J. Neural. Eng.*, vol. 3, no 4, pp. 299–305, 2006.
- [46] N. V. Manyakov, N. Chumerin, A. Combaz, y M. M. Van Hulle, "Comparison of classification methods for P300 brain-computer interface on disabled subjects," *Comput. Intell. Neurosci.*, no. 2, 2011.
- [47] D. J. Krusienski, E. W. Sellers, D. J. McFarland, T. M. Vaughan, y J. R. Wolpaw, "Toward enhanced P300 speller performance," *J. Neurosci. Methods*, vol. 167, no. 1, pp. 15–21, 2008.
- [48] S. Haykin, "Support Vector Machines", in *Neuronal networks. A comprehensive foundation*, 2nd ed. Canada: Prentice Hall International, pp. 340–372, 1999.
- [49] F. Lotte, M. Congedo, A. Lécuyer, y F. Lamarche, "A review of classification algorithms for EEG-based Brain-Computer Interfaces," *J. Neural Eng.*, vol. 4, 2007.
- [50] M. Kaper, P. Meinicke, U. Grossekaehoefer, T. Linger, y H. Ritter, "BCI competition 2003 – data set IIb: Support Vector Machines for the P300 speller paradigm," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, pp. 1073–1076, 2004.
- [51] A. Rakotomamonjy, y V. Guigue, "BCI competition III: dataset II - Ensemble of SVMs for BCI P300 speller," *IEEE Trans. Biomed. Eng.*, vol. 55, no. 3, pp. 1147–1154, 2008.
- [52] N. R. Draper, y H. Smith, "Selecting the best regression equation", in *Applied Regression Analysis*, 3rd ed. New York: John Wiley & Sons, pp. 335–339, 1981.
- [53] R. Corralejo, L. F. Nicolás-Alonso, D. Álvarez, y R. Hornero, "A P300-based Brain-Computer Interface aimed at operating electronic devices at home for severely disabled people," *Med. Biol. Eng. Comput.* vol. 52, no. 10, pp. 861–872, 2014.
- [54] A. K. Jain, R. P. W. Duin, y J. Mao, "Statistical pattern recognition: a review," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 22, no. 1, pp. 4–37, 2000.

ÍNDICE DE ACRÓNIMOS

A continuación se recogen todos los acrónimos empleados a lo largo de este Trabajo Fin de Máster por orden alfabético, acompañados de su descripción tanto en inglés como en español.

ANN	<i>Artificial Neural Networks</i> Redes Neuronales Artificiales
AR	<i>Autoregressive Models</i> Modelos Autorregresivos
AUC	<i>Area Under Curve</i> Área Bajo la Curva
BCI	<i>Brain Computer Interface</i> Interfaz Cerebro-Computadora
CAR	<i>Common Average Reference</i> Referencia de Media Común
CSP	<i>Common Spatial Patterns</i> Patrones Espaciales Comunes
CWT	<i>Continous Wavelet Transform</i> Transformada Wavelet Continua
DWT	<i>Discrete Wavelet Transform</i> Transformada Wavelet Discreta
EEG	<i>Electroencefalography</i> Electroencefalografía
ECG	<i>Electrocardiography</i> Electrocardiografía
ECoG	<i>Electrocorticography</i> Electrocorticografía
ELA	<i>Amyotrophic Lateral Sclerosis</i> Esclerosis Lateral Amiotrófica
EM	<i>Multiple Sclerosis</i> Esclerosis Múltiple
EMG	<i>Electromyography</i> Electromiografía
EOG	<i>Electrooculography</i> Electrooculografía
ERD	<i>Event-Related Desynchronization</i> Desincronización del evento relacionado

ERS	<i>Event-Related Synchronization</i> Sincronización del evento relacionado
FLD	<i>Fisher's Linear Discriminant</i> Discriminante Lineal de Fisher
fMRI	<i>Functional Magnetic Resonance Imaging</i> Imagen por Resonancia Magnética Funcional
HMM	<i>Hidden Markov Model</i> Modelo Oculto de Markov
ICA	<i>Independent Component Analysis</i> Análisis de Componentes Independientes
LDA	<i>Linear Discriminant Analysis</i> Análisis Discriminante Lineal
LMS	<i>Least Mean Square</i> Mínimos Cuadrados Promediados
LVQ	<i>Linear-Vector Quantization</i> Aprendizaje por Cuantificación Vectorial
MEG	<i>Magnetoencephalography</i> Magnetoencefalografía
MSE	<i>Mean Square Error</i> Error Cuadrático Medio
mVEP	<i>Motion-onset Visual Evoked Potentials</i> Potenciales Evocados Visuales de Movimiento
NPV	<i>Negative Predictive Value</i> Valor Predictivo Negativo
PCA	<i>Principal Component Analysis</i> Análisis de Componentes Principales
PET	<i>Positron Emission Tomography</i> Tomografía por Emisión de Positrones
PLS	<i>Partial Least Squares</i> Mínimos Cuadrados Parciales
PPV	<i>Positive Predictive Value</i> Valor Predictivo Positivo
QDA	<i>Quadratic Discriminant Analysis</i> Análisis Discriminante Cuadrático
RLS	<i>Recursive Least Squares</i> Mínimos Cuadrados Recursivos
RT	<i>Reaction Time</i> Tiempo de Reacción
SCP	<i>Slow Cortical Potentials</i> Potenciales Corticales Lentos
STFT	<i>Short-Time Fourier Transform</i> Transformada de Fourier de Tiempo Corto
SWLDA	<i>StepWise Linear Discriminant Analysis</i> Análisis Discriminante Lineal Paso-a-paso

SVM	<i>Support Vector Machines</i> Máquinas de Soporte Vectorial
TTD	<i>Thought Translation Device</i> Dispositivo de Interpretación del Pensamiento
VEP	<i>Visual Evoked Potentials</i> Potenciales Evocados Visuales
WPT	<i>Wavelet Packet Transform</i> Transformada de Paquetes Wavelet

PUBLICACIÓN DE RESULTADOS

Comunicaciones en congresos internacionales

- **V. Martínez-Cagigal**, R. Corralejo, J. Gómez-Pilar, D. Álvarez, y R. Hornero, "Diseño, Desarrollo y Evaluación de un Navegador Web basado en Potenciales P300 mediante Brain-Computer Interface Orientado a Personas con Grave Discapacidad", *V Congreso Internacional de Diseño, Redes de Investigación y Tecnología para todos, DRT4ALL*, 2015.

Comunicaciones en congresos nacionales

- **V. Martínez-Cagigal**, R. Corralejo, J. Gómez-Pilar, D. Álvarez, y R. Hornero, "Diseño, Desarrollo y Evaluación de un Navegador Web controlado mediante una Interfaz Cerebro-Ordenador para Personas con Discapacidad Motora", *V Jornadas de Innovación Docente de la Universidad a Distancia de Madrid (UDIMA)*, 2015.
- **V. Martínez-Cagigal**, "Desarrollo y Evaluación de una Aplicación para Navegar por Internet Mediante Sistemas Brain Computer Interface Orientada a Personas con Grave Discapacidad", *I Jornada de Posgrado de Investigación en TIC de la Universidad de Valladolid (UVa)*, 2015.
- J. Gomez-Pilar, R. Corralejo Palacios, **V. Martínez-Cagigal**, D. Álvarez González, R. Hornero Sánchez, "Análisis de los Cambios Espectrales del EEG Producidos por el Entrenamiento Neurocognitivo mediante una Interfaz Cerebro-Ordenador", *VII Simposio CEA de Bioingeniería 2015, Interfaces Cerebro-Computadora (BCI) y Tecnologías Asistenciales, Libro de Actas del Simposio CEA de Bioingeniería 2015*, pp. 15-21, 2015.