



UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE INGENIERÍA



Interfaces Cerebro-Computadora

TESIS PRESENTADA A LA FACULTAD DE INGENIERÍA DE LA
UNIVERSIDAD DE LA REPÚBLICA POR

Martín Patrone

EN CUMPLIMIENTO PARCIAL DE LOS REQUERIMIENTOS
PARA LA OBTENCIÓN DEL TÍTULO DE
MAGISTER EN INGENIERÍA ELÉCTRICA.

DIRECTORES DE TESIS

Dr. Ignacio Ramírez Universidad de la República
Dr. Federico Lecumberry Universidad de la República

TRIBUNAL

Dr. Ángel Caputi Instituto de Investigaciones
Biológicas Clemente Estable
Dr. Álvaro Martín Universidad de la República
MSc. Ing. Juan Cardelino Universidad de la República

DIRECTOR ACADÉMICO

Dr. Federico Lecumberry Universidad de la República

Montevideo
lunes 1 mayo, 2017

Interfaces Cerebro-Computadora, Martín Patrone.

ISSN 1688-2806

Esta tesis fue preparada en L^AT_EX usando la clase iietesis (v1.1).

Contiene un total de 115 páginas.

Compilada el lunes 1 mayo, 2017.

<http://iie.fing.edu.uy/>

Agradecimientos

Quiero agradecer a todas las personas que de una forma u otra me acompañaron en este proceso e hicieron posible la existencia de este trabajo.

En primer lugar a Pablo Iturralde, quien me introdujo en este tema que tanto me apasionó y con quien nos embarcamos en un primer acercamiento al mismo en el proyecto de fin curso de la asignatura Reconocimiento de Patrones. Este fue el punto de partida que me trajo hasta aquí.

A mis tutores, Ignacio Ramíez y Federico Lecumberry, quienes me dieron la posibilidad de realizar mi tesis en esta temática y me acompañaron durante todo el proceso, guiándome y habilitándome la exploración a la misma vez.

A la Comisión Sectorial de Investigación Científica (CSIC) de la Universidad de la República que mediante el proyecto de Iniciación a la Investigación permitió financiar algunos aspectos de esta tesis entre los que destaco la adquisición del equipo sensor de EEG.

A los integrantes del Centro de Investigación Básica en Psicología y en especial a Camila Zugarramurdi, quienes me abrieron las puertas, me permitieron conocer investigaciones afines y me ayudaron con cualquier duda presentada en cuanto a fundamentos neurológicos.

A Martín Tarragona, amigo con quien he tenido el gusto de compartir gran parte de la vida e hizo de contraparte en esos momentos donde es necesario exteriorizar y hacer catarsis, haciendo de esta maestría un trabajo menos solitario.

A toda mi familia y amigos que nunca dudan de mi y sin darse cuenta me dan la confianza y energía necesaria para siempre ir a más. Especialmente a mi madre, que siempre está ahí para apoyarme.

Finalmente quiero agradecer a mi novia Ioel por acompañarme siempre, apoyarme incondicionalmente y, con amor y paciencia, ayudarme a superar las crisis motivacionales.

Resumen

En esta tesis se investigan técnicas de Procesamiento de Señales y de Teoría de la Información para el desarrollo de Interfaces Cerebro- Computadora (BCI) no invasivas basadas en electroencefalogramas (EEG). Estos sistemas son capaces de detectar eventos relacionados con intenciones del usuario y transmitirlos a una computadora con el objetivo de realizar acciones en base a ellos, como controlar un dispositivo o escribir texto.

Los objetivos específicos de la tesis son la puesta a punto en teoría y práctica de BCIs basados en EEG y la construcción de un prototipo funcional de BCI en base a estos conocimientos. Concretamente, se plantea la construcción de un deletreador (entrada de texto) basado en señales EEG.

En primera instancia se realizó el estudio en profundidad de interfaces de deletreo tipo P300, y los mejores algoritmos existentes para este tipo de interfaz; el resultado de esta etapa es una mejora dramática en tiempos de entrenamiento del mejor algoritmo publicado a la fecha, manteniendo su desempeño.

En la segunda parte de la tesis se trabajó con un nuevo deletreador basado en otras señales cerebrales conocidas como Steady State Visual Evoked Potential (SSVEP). El resultado de esta etapa es un prototipo de BCI funcional de buenas prestaciones basado en un dispositivo de bajo costo; dicho dispositivo fue evaluado en condiciones reales en el marco de la exposición Ingeniería de Muestra, donde se obtuvo una respuesta muy positiva por parte de los usuarios.

El desempeño óptimo posible de los sistemas existentes, así como el desarrollado, fue evaluado de manera teórica mediante herramientas de Teoría de la Información, un enfoque que, a juzgar por la literatura consultada, no había sido aplicado en el área.

Tabla de contenidos

Agradecimientos	I
Resumen	III
1. Introducción	1
1.1. Motivación	1
1.2. Antecedentes	2
1.3. Objetivos	2
1.4. Estructura de la documentación	3
2. Interfaces Cerebro-computadora	5
2.1. Introducción a los BCIs	5
2.1.1. Sensado de la actividad cerebral	7
2.1.2. Procesamiento de las señales	8
2.1.3. Controlador del dispositivo	8
2.2. Fundamento Biológico	8
2.2.1. Estructuras generales del SNC	8
2.2.2. Materia gris: córtex	9
2.2.3. Potencial eléctrico en el cerebro	15
2.3. Electroencefalograma	17
2.3.1. Sistema 10-20	18
2.3.2. Emotiv Epoc	19
2.4. Señales cerebrales utilizadas en BCIs	21
2.4.1. Potenciales relacionados a eventos ERP	22
2.4.2. Ritmos sensorimotores SMR	23
2.4.3. Potenciales evocados visuales estacionarios SSVEP	23
3. Deletreador P300	27
3.1. Potencial evocado P300	27
3.1.1. Variabilidad del P300	29
3.2. El Deletreador P300	30
3.3. Capacidad del canal	31
3.4. La Competencia de Detección de P300	33
3.4.1. Base de datos	34
3.4.2. Algoritmo ganador	34

Tabla de contenidos

3.5. Análisis del algoritmo ganador	40
3.5.1. Reproducción de algoritmo	40
3.5.2. Número de SVMs a entrenar	42
3.5.3. Entrenamiento de canales	42
3.5.4. Ensamble de SVMs	45
3.5.5. Frecuencia del filtro pasabajos	46
3.5.6. Performance intersujeto	47
3.6. Análisis de las señales	48
3.6.1. Grandes Promedios	49
3.6.2. Señal de fondo	53
3.6.3. Evolución espacial del P300	53
3.6.4. Comportamiento de las distintas épocas	54
3.6.5. Comportamiento frecuencial	54
3.7. Experimentos	56
3.7.1. Filtro apareado como detector	58
3.7.2. Filtro apareado como prefiltrado	60
3.7.3. Extracción de señal de fondo SSVEP	61
3.7.4. Registro de datos propios	62
3.8. Conclusiones sobre el delectreador P300	64
4. Delectreador SSVEP	65
4.1. Potenciales SSVEP	65
4.2. BCI basadas en SSVEP	65
4.2.1. Delectreador SSVEP	66
4.3. Prototipo de BCI en tiempo real	67
4.3.1. El experimento	67
4.3.2. Presentación de estímulos	68
4.3.3. Adquisición de datos	70
4.3.4. Detector frecuencial	71
4.3.5. Clasificador	79
4.3.6. Controlador de delectreo	80
4.4. Capacidad del canal	83
4.5. Prueba de campo informal	86
4.6. Conclusiones y trabajo a futuro	89
5. Conclusiones	91
5.1. Conclusiones generales	91
5.2. Sobre la investigación de BCIs	92
5.3. Trabajo a futuro	92
Referencias	93
Índice de tablas	100
Índice de figuras	102

Capítulo 1

Introducción

1.1. Motivación

Una Interfaz Cerebro-Computadora, o BCI (Brain-Computer Interface), es un sistema que, a partir únicamente de señales cerebrales, es capaz de interpretar un comando deseado por el usuario y controlar algún dispositivo externo. Establece un camino directo entre el pensamiento de una persona y el mundo exterior. Las aplicaciones más evidentes se encuentran en el área de la medicina, para permitir a personas con limitaciones motrices severas realizar tareas como comunicarse o desplazarse, donde los BCI pueden ser utilizados por ejemplo para sustituir un dispositivo de entrada de datos como ser un mouse o un teclado.

La investigación de BCIs lleva ya décadas de desarrollo y en la actualidad existen numerosas implementaciones, en general basadas en el análisis de electroencefalograma (o EEG) [1] [2]. Un EEG consta de mediciones eléctricas realizadas a intervalos de tiempo regular (muestreo), mediante electrodos colocados sobre el cuero cabelludo de una persona. Estas mediciones reflejan, parcialmente, la actividad neuronal en el entorno de la ubicación del electrodo. En general se toman medidas de varios electrodos simultáneamente, de modo de recoger información sobre la actividad de diferentes partes del cerebro en cada instante de tiempo. A las mediciones obtenidas de cada uno de los electrodos se le denomina canal. Hoy en día es común encontrar electroencefalógrafos con decenas de canales [3].

El problema que se abordó en este trabajo consiste en el desarrollo de un sistema BCI. Un desarrollo de este tipo involucra diversas áreas, desde el procesamiento de señales hasta el conocimiento biológico sobre el funcionamiento del cerebro, pasando por el reconocimiento de patrones y la teoría de la información entre otras. En primer lugar, las señales de un EEG están inevitablemente contaminadas por ruido debido a varios tipos de interferencias. Por ejemplo, el propio cuerpo humano genera señales eléctricas que interfieren con el EEG al mover los ojos, parpadear, latir el corazón o mover otros músculos. Es necesario, por lo tanto, preprocesar adecuadamente las señales para facilitar la extracción de información útil [4]. Las señales de EEG deben luego analizarse para buscar patrones que puedan asociarse a la voluntad del usuario de realizar una determinada actividad. La elección de qué

Capítulo 1. Introducción

pensamientos se utilizan para gobernar un dispositivo externo debe realizarse de forma que sean distinguibles a través de un EEG. Para esto, tanto el conocimiento biológico sobre el funcionamiento del cerebro como las propiedades del sistema de adquisición de datos (desde un punto de vista de capacidad de transferencia de información) resultan fundamentales.

Las características de los dispositivos BCI hacen evidente su utilidad para las personas que presentan alteraciones severas del aparato locomotor y que por este motivo no han logrado desarrollar o han perdido el lenguaje articulado, a pesar de que su proceso comunicativo se encuentra intacto. El obtener acceso a todos los medios de comunicación normalmente disponibles en una computadora, pero sin necesidad de manejar otros dispositivos de entrada como el mouse/trackpad y/o el teclado, permite aumentar las posibilidades de autonomía de las personas con estas discapacidades y proporcionar más fluidez a sus actos comunicativos [5] [6] [7] [8].

1.2. Antecedentes

Al comienzo de este trabajo, no existían en nuestro país desarrollos o generación de conocimientos en el área tecnológica de BCI, más allá de que muchas de las áreas del conocimiento relacionadas, como el Procesamiento de Señales, la Neurobiología, la Fonoaudiología, la Fisiología y la rehabilitación de pacientes con discapacidades, sí existen.

Este proyecto se propone comenzar con los estudios en el área dentro del Núcleo de Teoría de la Información de la Facultad de Ingeniería, particularmente enmarcado en un proyecto CSIC “Interfaz Cerebro-Computadora de baja complejidad”.

En esta etapa se espera obtener un conocimiento adecuado del estado del arte en el área de procesamiento y clasificación de señales EEG, en particular con aplicación a las BCIs, y la implementación exitosa de algunos de los algoritmos representativos de la literatura para la clasificación de señales cerebrales.

A más largo plazo el objetivo es lograr, como producto último, un sistema BCI funcional, compuesto por un dispositivo electrónico y un conjunto de software que permita efectivamente la comunicación entre la intención del usuario y la computadora. Como tal, el dispositivo debería ser un reemplazante adecuado de los dispositivos de entrada clásicos.

Además, es de gran interés establecer un antecedente en el país de investigación en BCIs, de forma que permita continuar esta línea de investigación.

1.3. Objetivos

Objetivos generales:

- Apropiación de los conocimientos existentes sobre BCI y los dispositivos existentes.
- Desarrollo de un prototipo de sistema de Interfaz Cerebro-Computadora.

1.4. Estructura de la documentación

Se entiende aquí como prototipo un sistema funcional con el cual una persona sea capaz de deletrear una letra con cierta tasa de error.

Objetivos específicos:

1. Estudio preliminar de datos EEG disponibles para uso público y de las características de los dispositivos utilizados para adquirirlas.
2. Adquisición de datos EEG originales mediante un equipo BCI.
3. Identificación y filtrado de señales de EEG de relevancia, aplicado tanto a las señales adquiridas con un equipo BCI propio como a las disponibles en bases de datos de señales ya existentes.
4. Implementación de un clasificador prototipo.
5. Integración como dispositivo de entrada para la comunicación con una computadora.

1.4. Estructura de la documentación

Esta documentación se divide en cuatro grandes bloques. En primer lugar, en el siguiente capítulo, se realiza una introducción a las BCI en general, abordando particularmente la estructura de estos sistemas, los tipos existentes, un breve fundamento biológico que permite entender las señales involucradas y el EEG como sistema de adquisición de datos.

El capítulo 3 aborda el problema específico de una BCI que utiliza un potencial cerebral llamado P300 para detectar la intención del usuario en una aplicación de deletreo. Estas aplicaciones consisten en poder seleccionar una letra dentro de una matriz de letras posibles que se presentan en una pantalla. Se utiliza aquí una base de datos preexistente y se trabaja en base a un algoritmo del estado del arte.

El cuarto capítulo se centra en el segundo análisis de una BCI en particular. En este caso se trata de una señal cerebral llamada SSVEP y se llega a construir un prototipo funcional con un dispositivo de adquisición de EEG comercial.

Finalmente en el capítulo 5 se recopilan los aprendizajes adquiridos a lo largo de este trabajo, las conclusiones generales a las que se llegaron y el trabajo a futuro planteado.

Capítulo 2

Interfaces Cerebro-computadora

En este capítulo se hará una presentación de Interfaces Cerebro-Computadora, así como de todos los conceptos importantes asociados. Se tratará sobre el córtex del cerebro humano (fuente de las señales que se desea interpretar de alguna forma), de las señales cerebrales utilizadas para BCIs y del sistema electrónico necesario para realizar las medidas.

2.1. Introducción a los BCIs

Una Interfaz Cerebro-Computadora (o BCI) es un sistema que mide la actividad cerebral y la interpreta de alguna forma para controlar un dispositivo externo.

La actividad cerebral produce potenciales eléctricos que son detectables tanto dentro del cerebro como a nivel del cuero cabelludo. Los electrodos sensan esta señal y la traducen a un dispositivo externo, permitiendo al usuario controlar dicho dispositivo sin la participación de neuronas periféricas ni músculos. Un BCI por lo tanto crea nuevas salidas del Sistema Nervioso Central (o SNC) que son fundamentalmente diferentes a las naturales (ver figura 2.1).

Formalmente, un sistema BCI se puede definir de la siguiente manera [9]:

Sistema que mide la actividad del SNC (Sistema Nervioso Central) y la transforma en una salida artificial que reemplaza, restaura, aumenta, complementa o mejora la salida natural del SNC y, por lo tanto, modifica la interacción entre el SNC y el ambiente (exterior o interior) que se encuentra en marcha (ver figura 2.2).

Las aplicaciones más directas de esta tecnología están en el ámbito de la medicina, buscando darle a personas con discapacidades motoras nuevas herramientas de control y comunicación. Muchas discapacidades se presentan por problemas musculares o de la médula espinal, sin alteraciones del córtex, por lo que es posible capturar el comando directamente a nivel cerebral.

Ejemplos de esta tecnología son el control del movimiento de una silla de ruedas [10] o comandar el puntero de una computadora [11]. Investigaciones con primates muestran que es posible alcanzar el control de una prótesis como el movimiento de

Capítulo 2. Interfaces Cerebro-computadora

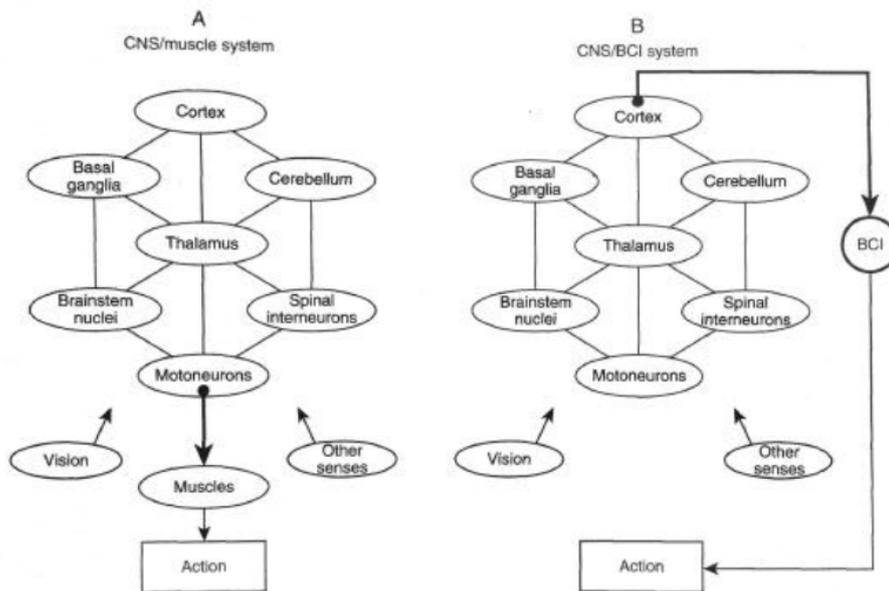


Figura 2.1: Un BCI crea nuevas salidas del SNC, permitiendo realizar una acción sobre el mundo exterior sin la participación de músculos ni neuronas periféricas, sensando únicamente la actividad del córtex. Imagen extraída del libro [9].

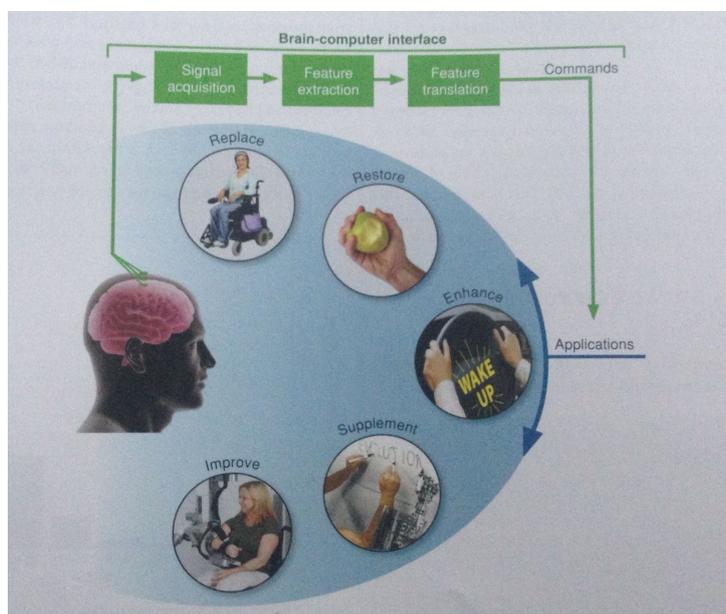


Figura 2.2: Descripción de un sistemas BCI. La señal cerebral es sensada, procesada e interpretada para poder ejecutar un comando sobre el ambiente, generando así una salida artificial del SNC que puede reemplazar, restaurar, aumentar, complementar o mejorar la salida natural del mismo. Imagen extraída del libro [9].

2.1. Introducción a los BCIs

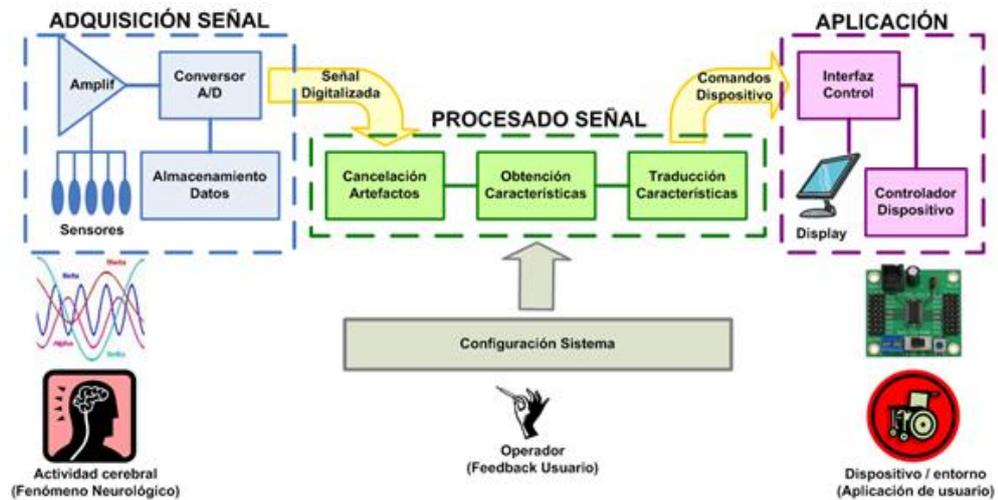


Figura 2.3: Diagrama de bloques de un sistemas BCI: sensado de la señal, procesamiento de la misma y controlador del dispositivo (o aplicación). Imagen extraída de [13].

un brazo robótico mediante técnicas invasivas [12].

Los dispositivos BCI, para poder detectar la intención del usuario y controlar un dispositivo externo, están formados por tres grandes bloques: sensado de la actividad cerebral, procesamiento de las señales y controlador del dispositivo (ver figura 2.3).

2.1.1. Sensado de la actividad cerebral

El primer paso necesario en cualquier BCI es el sensado de la actividad cerebral y posterior digitalización de la señal para su procesamiento. Dada la naturaleza eléctrica del funcionamiento del cerebro, la enorme mayoría de las BCI existentes utilizan sensores de campo eléctrico (electrodos) para registrar su actividad.

Los distintos sistemas de adquisición de los datos se separan en dos grandes tipos:

- **Invasivos:** implican algún procedimiento quirúrgico para el usuario (implantación de electrodos a nivel de córtex, llamados electrocorticograma ECoG) y se utilizan únicamente en casos extremos o en los que el paciente debió someterse al procedimiento por otras razones médicas
- **No invasivos:** el sensado se realiza desde fuera del cráneo, utilizándose principalmente técnicas de Electroencefalograma (EEG) que consiste en electrodos a nivel del cuero cabelludo.

En este trabajo se limitó el estudio a las interfaces no invasivas, utilizando únicamente señales adquiridas mediante EEG, ya sea tomada de bases de datos preexistentes como tomando datos nuevos mediante un dispositivo adquirido (ver sección 2.3).

Capítulo 2. Interfaces Cerebro-computadora

Existen sin embargo investigaciones donde se utilizan los procesos químicos o metabólicos para sensar la actividad cerebral. Ejemplo de esto es la utilización de fMRI (Functional Magnetic Resonance Imaging) para determinar el flujo de sangre a las distintas regiones del cerebro [14] [15].

2.1.2. Procesamiento de las señales

En este bloque se toma la señal medida ya digitalizada y se la procesa hasta obtener una salida que codifique de alguna forma la intención del usuario. Aquí es donde las técnicas de Procesamiento de Señales y Machine Learning tienen su mayor impacto por lo tanto es donde esta tesis hace foco. Este bloque se diseña muchas veces utilizando técnicas de Reconocimiento de Patrones por lo cual se subdivide en varias etapas: eliminación de artefactos (limpieza de la señal), obtención del vector de características y clasificación.

En este bloque es donde se centró el trabajo realizado, probando distintos mecanismos de detección de ciertas señales cerebrales en particular.

2.1.3. Controlador del dispositivo

Una vez que se cuenta con el comando deseado por el usuario, el mismo se introduce a la aplicación del sistema para que se ejecute la orden correspondiente (por ejemplo mover el mouse hacia arriba).

Para este trabajo se tomó como aplicación objetivo un *deletreador*. Dado que la motivación más clara es darle a personas con discapacidades severas un nuevo canal de comunicación, se consideró de interés elegir una aplicación para poder escribir el mensaje deseado.

2.2. Fundamento Biológico

En esta sección se presenta una introducción al funcionamiento y anatomía del cerebro humano, de donde provienen las señales que se desean detectar.

2.2.1. Estructuras generales del SNC

El Sistema Nervioso Central (SNC) es quien se encarga de recibir los estímulos del mundo exterior, procesar la información y transmitir impulsos a nervios y músculos. Es un sistema muy complejo que recibe millones de estímulos y adapta la respuesta del cuerpo según las condiciones externas e internas. En los humanos el sistema está protegido por membranas y estructuras óseas (cráneo y columna vertebral).

El SNC está formado por el encéfalo y la médula espinal (ver figura 2.4). El encéfalo (que significa “dentro de la cabeza”) está ubicado dentro del cráneo y se encarga de las funciones voluntarias. Se pueden distinguir tres secciones separadas pero interconectadas: el cerebro, el tronco encefálico y el cerebelo.

2.2. Fundamento Biológico

El cerebro humano consiste en dos hemisferios apareados (figura 2.5), cada uno cubierto por una estructura llamada córtex. El córtex es conocido coloquialmente como materia gris debido a su color proveniente de la gran cantidad de neuronas que posee. Debajo del córtex existen otras estructuras de ‘materia gris’ llamadas áreas subcorticales, entre ellas: ganglia basal, cerebelo, tronco encefálico y tálamo. La materia blanca cerebral consiste en las fibras que interconectan las distintas áreas del córtex y el córtex con las áreas subcorticales.

Si seguimos una fibra corticoespinal que comienza en el córtex motor, podemos ver que cruza al lado opuesto del cuerpo antes de entrar a la médula espinal. Por ello en general, las fibras corticoespinales de un lado del cerebro controlan los músculos del otro lado.

Debido a que el córtex es responsable de la planificación del movimiento y es de fácil acceso, es el área donde se centra mayormente todas las investigaciones relativas a los BCI.

2.2.2. Materia gris: córtex

El córtex está formado por cuatro partes o lóbulos: frontal, parietal, temporal y occipital. Las principales funciones de cada uno de los lóbulos son:

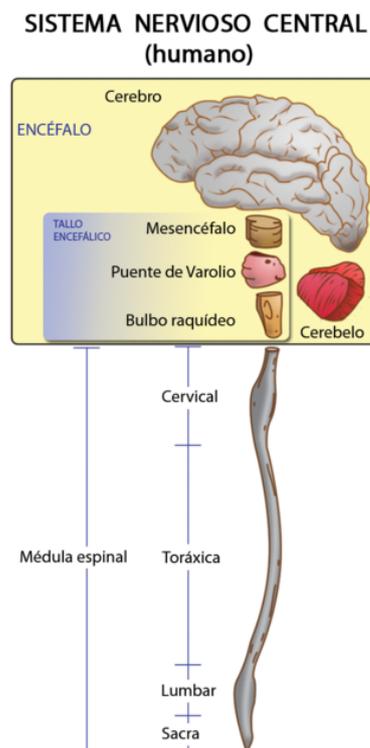


Figura 2.4: Estructura del Sistema Nervioso Central humano. Se compone de dos partes: encéfalo (cerebro, cerebelo, tallo encefálico) y médula espinal. Imagen extraída de [16].

Capítulo 2. Interfaces Cerebro-computadora

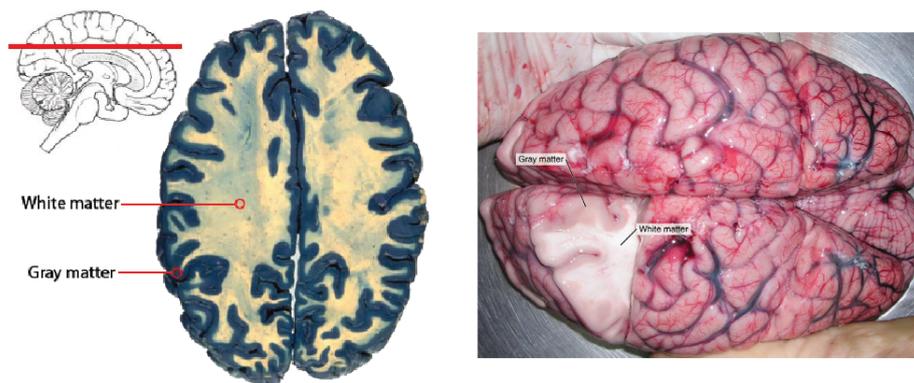
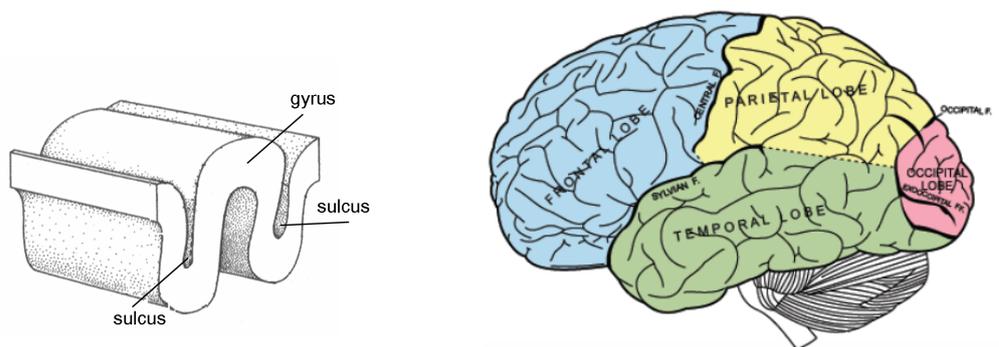


Figura 2.5: Imágenes del cerebro humano en un corte horizontal. Se puede ver el córtex o materia gris y la materia blanca dentro de cada uno de los dos hemisferios que lo componen. Imagen izquierda extraída de [17], derecha extraída de [18].

- **Frontal:** razonamiento, planificación, lenguaje, movimientos, emociones y resolución de problemas. La parte más anterior, llamada área prefrontal, está encargada de las funciones de alto nivel, comportamientos cognitivos complejos, personalidad y toma de decisiones.
- **Parietal:** movimiento, orientación, reconocimiento, percepción de estímulos y habla.
- **Occipital:** procesamiento visual.
- **Temporal:** percepción y reconocimiento de estímulos auditivos, memoria y habla.

El córtex de los mamíferos más evolucionados está formado por crestas (lla-



(a) Crestas y surcos del córtex. Imagen extraída de [19]

(b) Lóbulos cerebrales: frontal, parietal, occipital y temporal. Vista desde hemisferio izquierdo. Imagen extraída de [20]

Figura 2.6: Anatomía del córtex cerebral.

2.2. Fundamento Biológico

madas gyri) y surcos (llamados sulci) que dividen el córtex en distintas regiones anatómicas (figura 2.6), las cuales se encuentran especializadas en distintas actividades. El llamado Central Sulcus (CS), es uno de los más notorios y divide el lóbulo frontal del parietal. El gyrus en el lado anterior del CS es llamado precentral gyrus y el del lado posterior postcentral gyrus, ambos muy importantes en las funciones motoras y sensoriales, y por lo tanto muy utilizados en aplicaciones de BCI. Las regiones más destacadas en este aspecto (involucradas con el funcionamiento sensorial y motor) son:

- **M1: córtex Motor Primario.** Ubicado en el lóbulo frontal, en la pared anterior del CS y continúa en el precentral gyrus. Es de gran importancia para BCIs por su relación cercana con el control del movimiento. Se organiza somatotópicamente (por parte de cuerpo que controla, ver el Homunculus de Penfield, figura 2.8).
- **PM: córtex Premotor.** Anterior (rostral) a M1. Hay otras áreas suplementarias al control motor cercanas como la SMA (supplementary motor area) y la CMA (cingulate motor area).
- **S1: córtex Somatosensorial Primario.** Ubicado en la parte más anterior del lóbulo parietal, en la pared posterior del CS y continúa en el postcentral gyrus. Es importante para el movimiento debido a la realimentación de los sentidos del tacto, temperatura, dolor y posición de las extremidades. Los sensores del tacto y propioceptivos pasan por el tálamo antes de llegar aquí. También se organiza somatotópicamente (ver figura 2.8).
- **PPC: córtex Posterior Parietal.** También involucrado en funciones sensoriales. Combina lo visual, auditivo y somatosensorial, armándose un mapa de la posición de las extremidades respecto al mundo exterior. Lesiones aquí provocan la llamada negligencia hemiespacial, donde el sujeto no reconoce las extremidades. Las señales visuales toman dos caminos, uno que llega al PPC y se lo llama *object-location* (responde el dónde) y el otro llega al lóbulo temporal para responder el qué (*object-recognition*).
- **PFC: córtex Prefrontal.** Diferente a otras regiones involucradas en control motor por distintas razones entre las que se destaca que no provoca movimientos al estimularse y no se encuentra directamente conectado a M1. Está involucrado en las funciones motoras de alto nivel.

Histología del córtex

El córtex presenta tres partes histológicamente distinguibles (tejidos): el neocórtex, el paleocórtex y el archicórtex. El neocórtex ocupa la gran mayoría del córtex en los mamíferos. El paleocórtex y el archicórtex son evolutivamente más viejos y se encuentran por debajo del neocórtex. El paleocórtex está asociado al olfato mientras que el archicórtex juega un papel muy importante en la creación de nuevas memorias y la navegación espacial.

Capítulo 2. Interfaces Cerebro-computadora

Morfología del neocórtex

El neocórtex está formado por seis capas estructuralmente distintas y distinguibles principalmente por el tipo de células que contienen. Las células más numerosas son las llamadas piramidales y las granulosas. Las primeras son neuronas de “proyección”; su axón llega hasta otras áreas corticales o subcorticales, incluso hasta la médula espinal. Las segundas presentan una gran cantidad de dendritas que, al igual que el axón, llegan a una región restringida del córtex y se encargan de procesar la información localmente. Mayor detalle sobre la estructura de las neuronas se ve en la sección 2.2.3.

- Capa I: molecular. La más externa. Pocas neuronas, muchas dendritas.
- Capa II: granular externa. Neuronas granulosas y piramidales chicas.
- Capa III: piramidal externa. Células piramidales chicas y medianas. Fuente principal de conexiones entre diferentes áreas corticales.

Motor and Sensory Regions of the Cerebral Cortex

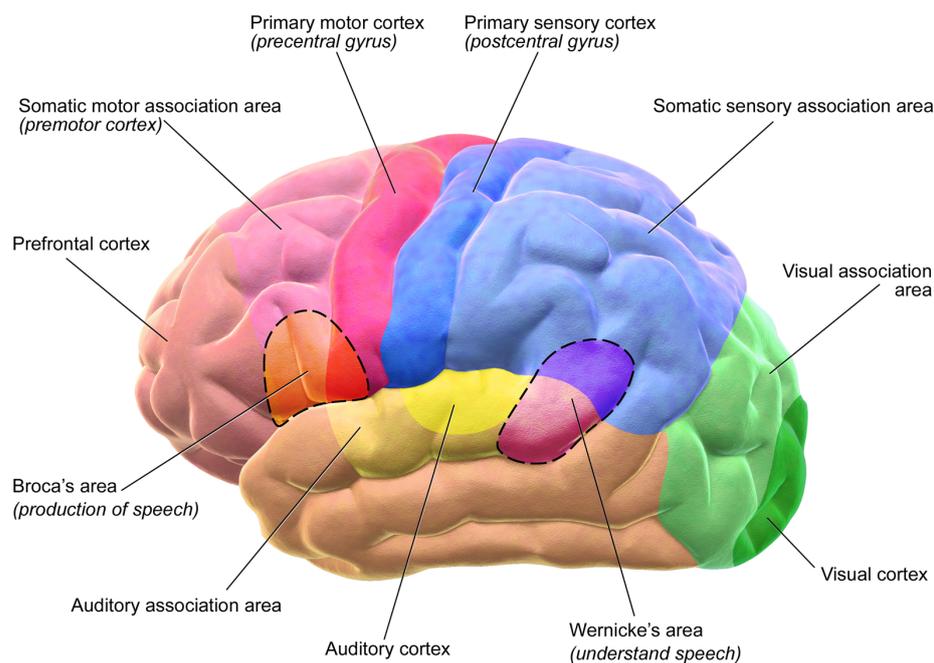


Figura 2.7: Áreas funcionales del cerebro. Se destaca el área visual en el lóbulo occipital, el córtex motor primario en el lóbulo frontal y el córtex sensorial primario junto al anterior en el lóbulo parietal. Imagen extraída de [21].

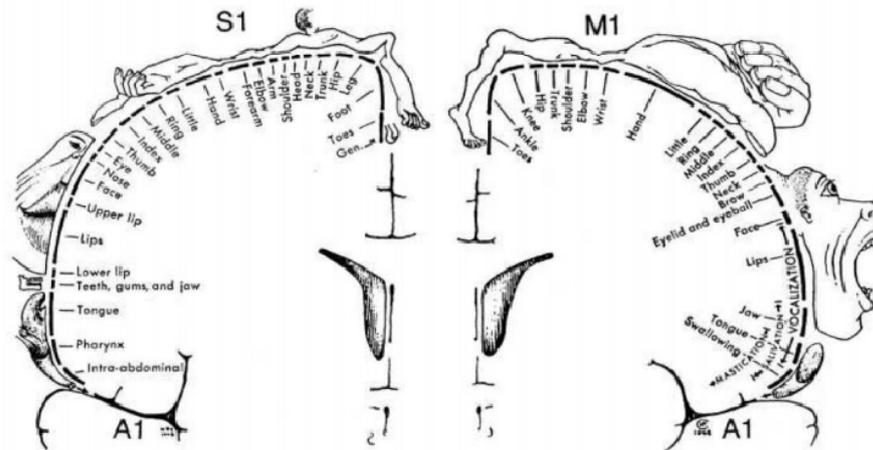


Figura 2.8: Homunculus de Penfield [22]. Se puede ver la organización de las áreas PM y S1 segun la parte del cuerpo que controlan (somatotópicamente). Para representar la diferencia de conexiones neuronales presentes para cada parte del cuerpo se dibuja la imagen deformada del mismo como se ve en la figura. De esta forma la cara y las manos se muestran de gran tamaño debido a la cantidad de conexiones neuronales asociadas a dichas partes.

- Capa IV: granular interna. Células no-piramidales. Fibras aferentes (entradas) desde hipotálamo.
- Capa V: piramidal interna. Piramidales grandes. Fibras eferentes.
- Capa VI: multiforma. Gran variedad de células. Fibras eferentes al tálamo.

Funcionalmente, las neuronas parecen estar organizadas de forma vertical en lo que se llaman *columnas corticales*, debido a que las neuronas pertenecientes a una misma columna presentan actividad similar (se activan a la vez, ver figura 2.9). Esto es sumamente importante dado que es lo que permite que los potenciales eléctricos generados por varias neuronas se complementen al estar realizando una acción en particular y por lo tanto tomen la potencia suficiente para ser detectados por fuera del cuero cabelludo mediante EEG (ver sección 2.2.3).

Áreas subcorticales

Las áreas subcorticales que interactúan fuertemente con el córtex y están involucradas en las funciones motoras y sensoriales son:

- Tálamo. Se encuentra en el centro profundo del cerebro. Es la principal puerta de entrada de las señales sensoriales y juega un importante papel regulatorio.
- Tronco Cerebral. Formado por mesencéfalo, pons y médula oblongata. Se conecta con la médula espinal y contiene fibras ascendentes y descendentes a la misma.

Capítulo 2. Interfaces Cerebro-computadora

- Ganglios Basales. Son núcleos interconectados en lo profundo del cerebro. Se encuentran muy conectados con el córtex y juegan un papel importante en el movimiento (Parkinson y Huntington están asociados a una patología en ganglios basales).
- Cerebelo. Descansa debajo de la parte posterior de los hemisferios. Se encarga de que los movimientos se realicen de forma coordinada y suave. Desórdenes en el cerebelo provocan ataxia (el movimiento es posible pero no se coordina normalmente).

La terminología utilizada para definir direcciones espaciales en el CNS se pueden ver en la figura 2.10.

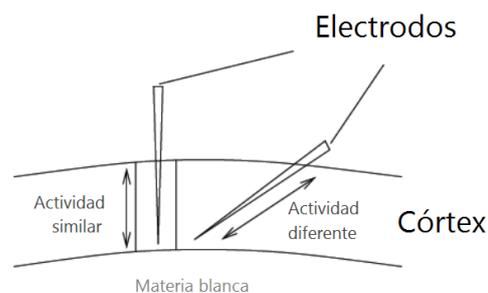


Figura 2.9: Columna cortical: agrupación vertical de las neuronas que presentan actividad similar [23].

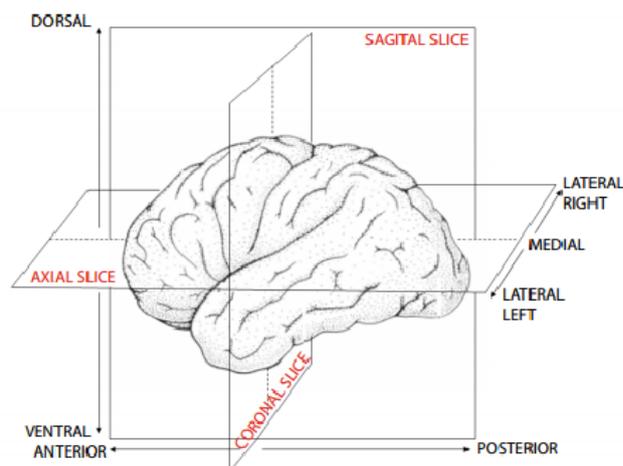


Figura 2.10: Terminología de direcciones espaciales del cerebro. Imagen tomada de [23].

2.2.3. Potencial eléctrico en el cerebro

Las BCI se basan en detectar potencial eléctrico proveniente del córtex cerebral. Este potencial es producto de la activación de miles de neuronas en conjunto.

Potenciales neuronales

La principal característica de las neuronas es permitir el paso de impulsos eléctricos a través de su membrana plasmática para poder comunicarse entre sí o con otras células del organismo. En cuanto a su morfología las mismas constan del cuerpo celular común a todas las células, de algunas prolongaciones cortas llamadas dendritas y una prolongación larga llamada axón. Los impulsos eléctricos se transmiten tanto por el axón como por las dendritas. La membrana plasmática es la estructura que define sus límites y mantiene el equilibrio entre el interior y exterior de la misma, permitiendo y regulando el pasaje de sustancias.

La neurona recibe estímulos por las dendritas a través del proceso conocido como sinapsis (el cual es químico en la mayoría de los casos) y lo transmite a través del axón. El primer proceso genera un cambio de potencial conocido como post sináptico (PSP - Post Synaptic Potential) y tiene una duración aproximada de $10ms$, mientras que el segundo es llamado potencial de acción (AP - Action Potential) y tiene una duración del orden de $1ms$.

Las señales se generan a través del paso de iones por su membrana plasmática (ver figura 2.12). El potencial de membrana (diferencia entre el potencial en el interior y exterior de la neurona) en reposo es negativo. La excitación de la neurona implica una pérdida de la polarización de la membrana, pudiendo llegar a ser positivo este potencial. Esto se logra por la existencia de los llamados canales iónicos en la membrana. Estos canales son proteínas que conectan el interior con el exterior de la célula y permiten el paso selectivo de iones a través de la membrana. La diferencia de concentración de los distintos iones a ambos lados es lo que genera la diferencia de potencial.

Para que el potencial eléctrico sea detectado desde fuera de la cabeza (con electrodos de EEG), es necesario que miles de neuronas se activen a la vez generando corrientes con la misma dirección (ver figura 2.13). Por esta razón se cree que lo que se detecta en el electroencefalograma son los potenciales post sinápticos de las

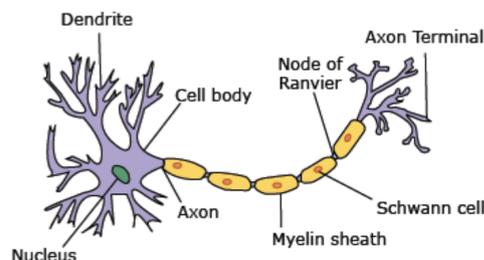


Figura 2.11: Ilustración de una neurona. Se pueden observar las terminaciones cortas (dendritas) y la terminación larga (axón). Imagen tomada de [23].

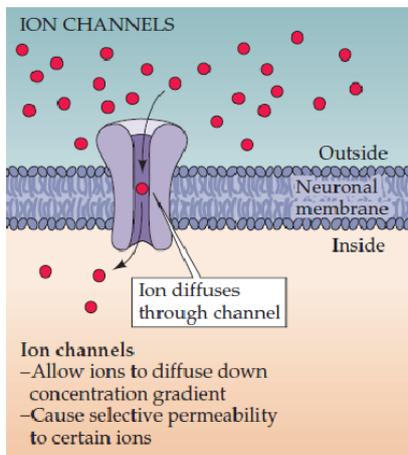
Capítulo 2. Interfaces Cerebro-computadora

neuronas piramidales. Estas neuronas tienen dendritas prominentes y en dirección perpendicular a la superficie del córtex, formando además entre el 70% y 80% del neocórtex. La distribución en columnas de las células piramidales hace que las corrientes queden alineadas en los gyros y se cancelen en los sulci.

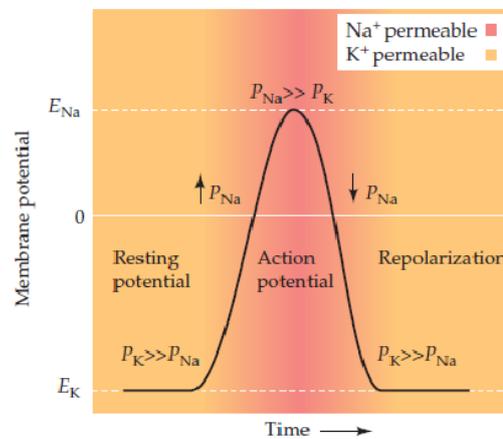
Modelos de actividad eléctrica cerebral para EEG

Los potenciales eléctricos cerebrales medidos se separan en 3 escalas diferentes:

- micro: LFP (Local Field Potentials). Esta técnica detecta actividad en el cuerpo neuronal o terminal sináptica.

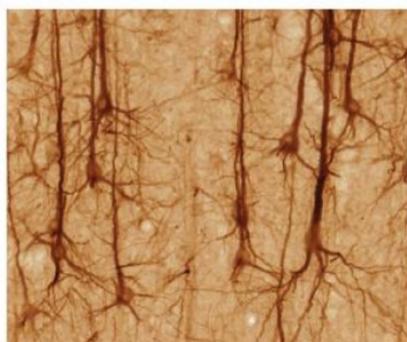


(a) Canales iónicos.

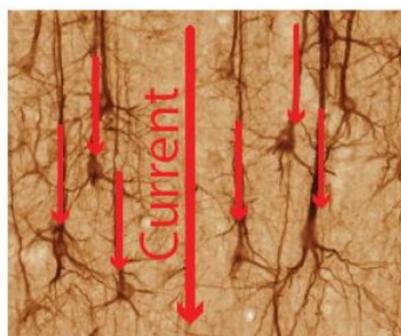


(b) Polarización de la membrana.

Figura 2.12: Polarización de la membrana neuronal debido al pasaje de iones por los canales iónicos que modifican la concentración de los mismos a ambos lados de la membrana [24].



(a) Pyramidal neurons



(b) Pyramidal neurons and the produced intracellular currents.

Figura 2.13: Activación de neuronas piramidales. Se puede ver como las corrientes generadas por estas células tienen la misma dirección. Imagen extraída de [23].

- meso: ECoG(Electrocorticograma). Corresponde a la actividad de una columna cortical o un grupo de neuronas.
- macro: EEG(Electroencefalograma). Mide la actividad promediada espacialmente de cientos de millones de neuronas, correspondiente a un área cortical.

La actividad registrada con EEG es macroscópica respecto a la actividad de una neurona. Mediante el EEG es posible distinguir la actividad de un ensamble de estructuras neuronales, más grande que una columna cortical pero menor que un área cortical. A pesar de que se han construido un gran número de modelos de estos ensamblajes como fuentes de la señal de EEG, todavía queda camino por recorrer para tener un modelo realista.

2.3. Electroencefalograma

Los primeros registros de EEG fueron tomados por el psiquiatra Alemán Hans Bergen en 1929. En la figura 2.14 se puede ver un registro de EEG ejemplo para varios canales. Los electrodos más utilizados son los metálicos de Ag/AgCl, pero existe una gran variedad disponible. Históricamente se han utilizado electrodos húmedos que precisan hidratarse varias veces en experimentos largos; en los últimos años llegaron al mercado electrodos secos pero aún no son recomendados para uso médico.

Las medidas de EEG se encuentran muy contaminadas por señales provenientes de fuentes no cerebrales, en particular la actividad muscular, la cual genera un potencial eléctrico de gran amplitud que es captado con los electrodos en el cuero

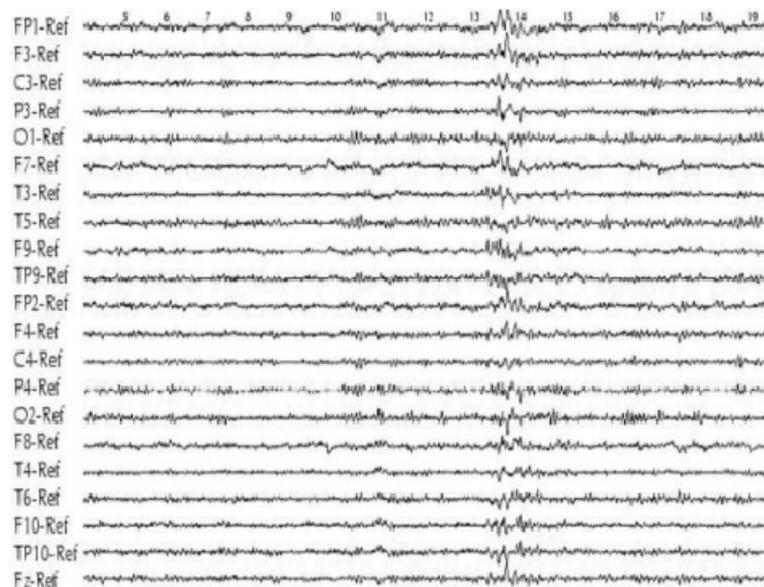


Figura 2.14: Señal de electroencefalografía. Se observan varios canales a lo largo del tiempo. Los canales llevan nombre según su ubicación espacial [25].

Capítulo 2. Interfaces Cerebro-computadora

cabelludo. Otras fuentes de ruido y artefactos son los movimientos de ojos (señal conocida como electrooculograma EOG) y el latido del corazón (electrocardiograma ECG).

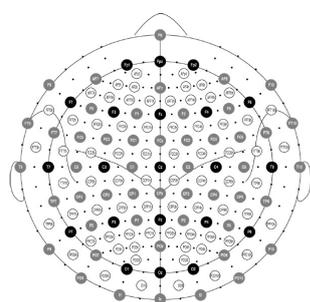
2.3.1. Sistema 10-20

El Sistema Internacional 10-20 es un método sistemático adoptado y recomendado por la Federación Internacional de Electroencefalografía para la colocación, ubicación y nomenclatura de los electrodos en el cuero cabelludo. Los números 10 y 20 hacen referencia a la distancia entre éstos, siendo un 10% o 20% del arco total de la cabeza. Se utilizan letras para identificar las distintas regiones, números pares para el hemisferio derecho e impares para el izquierdo.

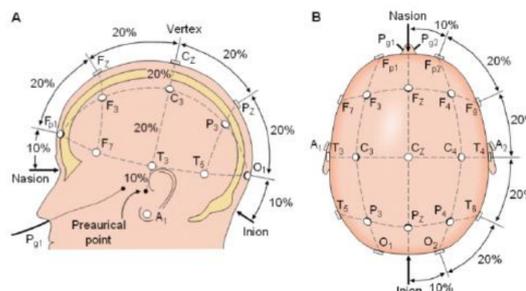
Las letras utilizadas para cada región son:

- F* : lóbulo frontal
- P* : lóbulo parietal
- T* : lóbulo temporal
- O* : lóbulo occipital
- C* : línea central
- z* : línea media
- A* : oreja
- Fp* : frontal polar
- Pg* : nasofaríngeo

Al aumentar el número de electrodos que traen los equipos de EEG se adoptó el sistema con electrodos entre los existentes (ver figura 2.15). Este sistema de mayor densidad se lo llama sistema 10-5, pero usualmente denominado 10-20 de igual forma.



(a) Distribución de los electrodos en un sistema con gran densidad.



(b) Distribución en sistema 10-20 clásico, donde se observan los 10 y 20 grados de separación entre los electrodos.

Figura 2.15: Ubicación electrodos según sistema 10-20 [25].

Referencia electrodos

La medida en los electrodos es siempre bipolar (diferencia entre el potencial en dos puntos). Cuando uno de los electrodos (el de referencia) presenta muy baja actividad se llama medida ‘monopolar’. La elección de la referencia es importante para la interpretación de las señales y en particular para los potenciales evocados (se modifican las amplitudes y los tiempos). Se busca en general que la referencia sea estable y no varíe en el tiempo; de esta forma la señal observada está asociada al electrodo en cuestión. Las técnicas más utilizadas para buscar esta estabilidad son:

- Referencia fija oreja: hipótesis de baja actividad eléctrica. Se utilizan electrodos de referencia ubicados en zonas de baja actividad (orejas o mastoides). Existen estudios que indican que esta actividad no es para nada despreciable en relación al resto de los electrodos. Por esto es cada vez menos recomendada. Aún así, es una técnica muy utilizada, en particular cuando no se cuenta con gran cantidad de electrodos.
- Common Average Reference (CAR): la referencia es el promedio de todos los electrodos. Con suficientes electrodos y despreciando el flujo de carga por el cuello, esta medida se mantiene constante en el tiempo (por ley de Gauss la integral espacial del campo eléctrico en una superficie cerrada es igual a la carga dentro de ésta).
- De Gradientes: si se desean conocer los gradientes se restan los electrodos adyacentes.

2.3.2. Emotiv Epoc

Para poder realizar toma de datos propios, se adquirió un dispositivo de adquisición de EEG: el Emotiv Epoc. Éste es un equipo de fácil y práctica usabilidad (importante para una Interfaz cerebro computadora o BCI), de bajo costo (en comparación con los dispositivos de EEG de grado médico) y validado para el registro de señales provenientes del cerebro (y no solo ruido muscular y otros artefactos) [26] [27]. Es desarrollado por la compañía Emotiv Systems [2] y apunta a ser de utilización masiva principalmente para videojuegos y monitoreo de ciertos estados mentales (concentración, relajación, etc.).

El dispositivo cuenta con 14 sensores en las ubicaciones AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF42 (ver figura 2.16), más 2 adicionales de referencia en P3 y P4. Para cada hemisferio se cuenta además con dos posiciones de referencia extra en los mastoides [28]. Al inicio de cada sesión de uso todos los electrodos se deben humedecer con una solución salina, y se debe verificar la conectividad de los mismos en el panel de control del software (figura 2.17).

El dispositivo transmite los datos de forma inalámbrica mediante Bluetooth al PC. Tiene una frecuencia de muestreo interna de $2048Hz$ que luego se submuestra a $128Hz$. El siguiente filtrado se hace directamente en el hardware: pasabajos con

Capítulo 2. Interfaces Cerebro-computadora

frecuencia de corte de $43Hz$, pasabands con frecuencia de corte de $0,2Hz$ y filtros notch a $50Hz$ y $60Hz$.

Debido a las características comerciales del producto, la licencia de software incluida en la venta del dispositivo no ofrecen acceso directo a los datos crudos sino que cuenta con 3 aplicaciones (o suites) que ofrecen ciertos datos procesados. Por un lado cuenta con la Expressiv Suite que reconoce expresiones faciales que se visualizan en un avatar (figura 2.18). La Affectiv Suite (figura 2.19) interpreta el estado consciente del usuario mediante medidas de “alegría”, “aburrimiento”, “concentración”, etc. Finalmente, mediante la Cognitive Suite el usuario puede mover una caja tridimensional luego de un entrenamiento breve de aproximadamente 10 segundos (ver figura 2.20).

Para este trabajo se desea partir de las señales crudas de EEG por lo que se debió adquirir una licencia extra que permitía el acceso a las mismas.

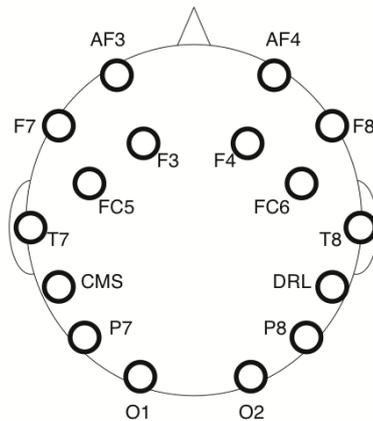


Figura 2.16: Ubicación de los electrodos del dispositivo Emotiv EPOC. [29]

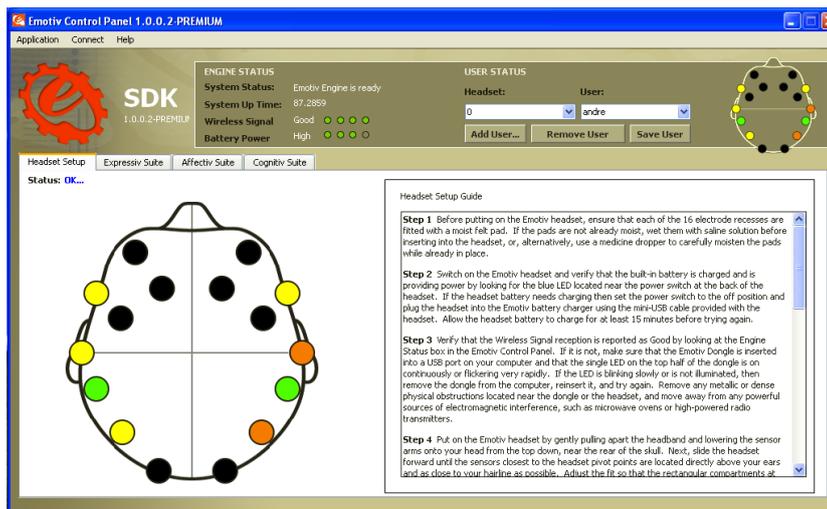


Figura 2.17: Panel de control de Emotiv. Indica con código de colores si la señal recibida de cada canal es correcta.

2.4. Señales cerebrales utilizadas en BCIs

En contraposición a todas las comodidades de uso que ofrece el Emotiv Epoc, las señales adquiridas son notoriamente más ruidosas que las adquiridas por un dispositivo de EEG etiquetado como de grado médico.

2.4. Señales cerebrales utilizadas en BCIs

La enorme mayoría de los trabajos encontrados sobre BCIs basadas en EEG buscan la detección de una de las siguientes señales cerebrales.

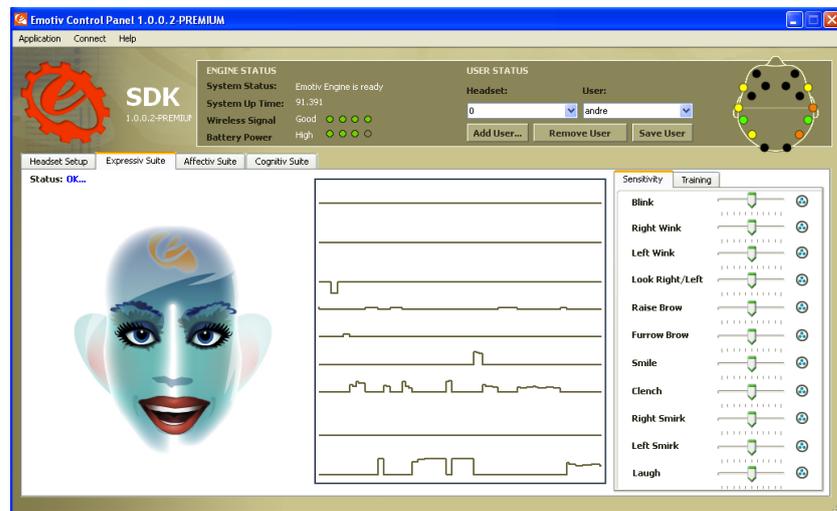


Figura 2.18: Expressiv Suite. Recoge las señales musculares faciales para indicar distintas expresiones.



Figura 2.19: Affectiv Suite. Indica distintas medidas como “nivel de concentración” y “nivel de frustración” entre otras.

Capítulo 2. Interfaces Cerebro-computadora

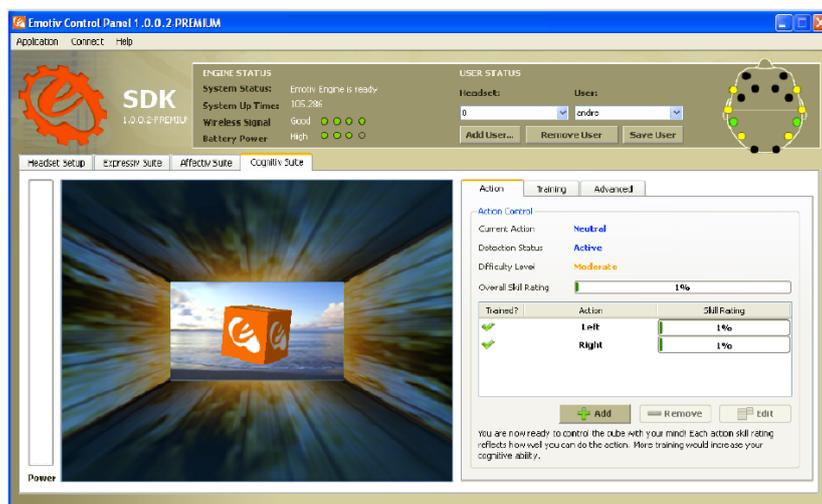


Figura 2.20: Cognitiv Suite. Permite el movimiento de un cubo virtual luego de unos segundos de entrenamiento para cada comando.

2.4.1. Potenciales relacionados a eventos ERP

Los potenciales evocados o potenciales relacionados a eventos (ERP por sus siglas en inglés) son manifestaciones de la actividad neuronal que se dispara por, y está involucrada en el proceso de, un evento específico. Dicho evento puede ser sensorial, cognitivo o motor. La señal (voltaje) que constituye el ERP está embebida en la señal EEG general y es más pequeña que la actividad de fondo.

Los ERP se encuentran ‘atados’ temporalmente al evento que los genera (a diferencia de la actividad de fondo). Por lo tanto, una técnica ampliamente utilizada para extraerlo es promediar múltiples instancias del evento generador (ver imagen 2.21).

Los ERP se clasifican en dos tipos:

- **Exógenos**

Reflejan la actividad en el sistema sensorial primario y por lo tanto corresponde a las componentes tempranas (primeros 150ms aproximadamente luego del evento). La forma de onda y distribución espacial varía con la

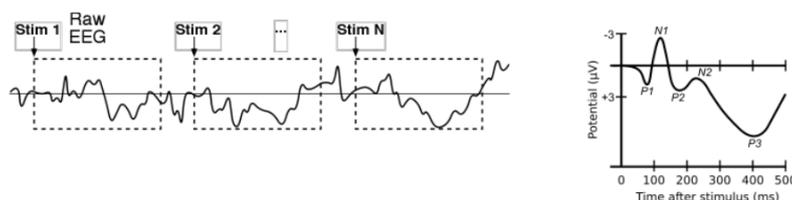


Figura 2.21: Extracción de Potenciales Evocados mediante promediación. A la izquierda se puede ver la respuesta para N estímulos presentados de forma secuencial. A la derecha se tiene el promedio de esos N intervalos, donde se puede observar el ERP. Imagen modificada de [30].

2.4. Señales cerebrales utilizadas en BCIs

modalidad del evento generador.

■ Endógenos

Son los componentes de latencia larga dado que reflejan la actividad de ‘procesamiento de la información’. Tienen una naturaleza cognitiva y por lo tanto dependen en menor medida del estímulo y están muy vinculados a la significancia para el sujeto en la tarea.

Hoy en día los BCI basados en ERP son los más usados, siendo prácticamente los únicos utilizados fuera del laboratorio por personas con discapacidades grandes y para uso prolongado en la casa.

El protocolo general consiste en presentar distintos estímulos, donde uno de ellos tiene cierta relevancia para el sujeto y por lo tanto provoca un ERP. Por lo tanto, al detectar el ERP se está detectando cierta intención del usuario. Para esto es necesario trabajar con potenciales evocados endógenos.

2.4.2. Ritmos sensorimotores SMR

Los BCI basados en ritmos sensorimotores (SMR por *sensorimotor rhythms*) han sido foco de investigación en los últimos años y se basan en la evidencia de que la ejecución (e incluso la imaginación) de un movimiento induce cambios en la ‘actividad rítmica’.

Los SMR son oscilaciones del campo eléctrico medido en el córtex sensorimotor (frontal posterior y parietal anterior -M1 y S1-). Se separan en tres bandas frecuenciales:

- mu: 8-12 Hz
- beta: 18-30Hz
- gamma: 30 -200Hz

Las estructuras cerebrales involucradas en estos procesos son tanto corticales como subcorticales.

Ya en 1930 Berges et al. [31] evidenciaban que los SMR cambian con el comportamiento motor, y en 1949 Jasper et al. [32] descubrieron que algunos cambios estaban asociados a la imaginación motora al igual que a la ejecución del movimiento.

Los BCI basados en SMR de hoy en día asocian distintas tareas a distintas acciones motoras (por ejemplo: mover cursor hacia la derecha con movimiento de pie derecho). Luego el usuario imagina el movimiento correspondiente a la acción deseada. Si se detecta el cambio en el SMR correspondiente a dicho movimiento se induce la intención del usuario para poder ejecutarla.

2.4.3. Potenciales evocados visuales estacionarios SSVEP

Los Visual Evoked Potentials (VEP) son potenciales evocados por estímulo visual (como ser un tablero alternando casillas de color) y por lo tanto se registran en el córtex occipital (donde se realiza el procesamiento visual).

Capítulo 2. Interfaces Cerebro-computadora

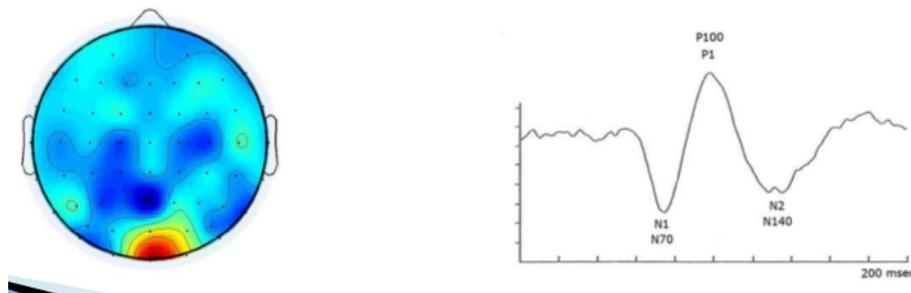


Figura 2.22: Registro de potenciales evocados visuales [33]. A la izquierda se puede ver activada el área visual en el lóbulo occipital. A la derecha se puede observar la forma de onda del ERP posterior al estímulo visual.

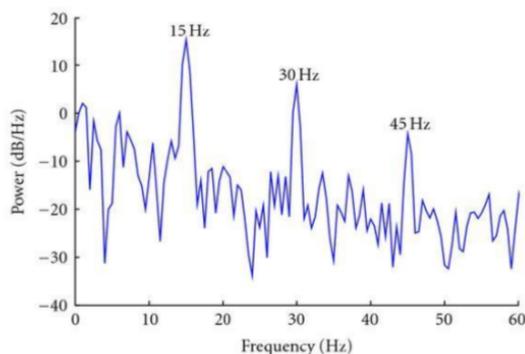


Figura 2.23: Aumento de la energía de la señal EEG en las frecuencias correspondientes a la de presentación del estímulo [34].

Cuando el estímulo visual se presenta de forma repetida, con cierta frecuencia fija, se forman lo que se conoce como Steady State Visual Evoked Potential (SSVEP), donde la respuesta del cerebro frente al estímulo se manifiesta como un aumento en amplitud de la misma frecuencia que éste (y sus armónicos), como se puede ver en la figura 2.23.

Los sistemas BCI basados en este tipo de potenciales suelen funcionar de la siguiente manera. Se presentan distintos estímulos visuales que se encuentran variando a distinta frecuencia. Cada uno de éstos está asociado a una acción a realizar en particular. El sujeto debe observar el estímulo asociado a la acción que desea ejecutar. Detectando la frecuencia a la que se acopla la respuesta cerebral del individuo se puede concluir la acción que desea.

2.4. Señales cerebrales utilizadas en BCIs

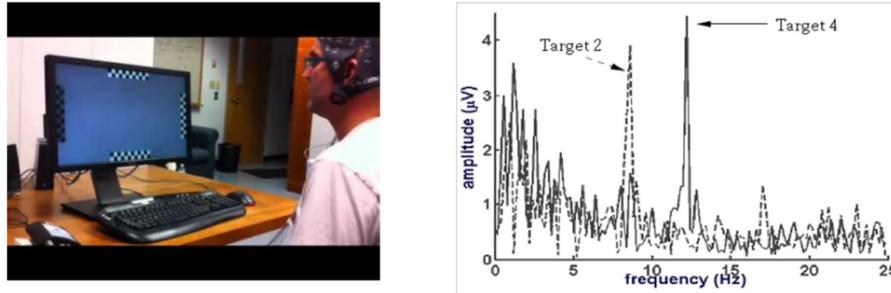


Figura 2.24: BCI basadas en SSVEP, donde se presentan distintas cuadrillas alternando a distinta frecuencia. La respuesta cerebral del individuo se acopla a la frecuencia de la cuadrilla observada. Imágenes tomadas de [35] [36].

Capítulo 3

Deletreador P300

En este capítulo se abordará el análisis de una de las aplicaciones de Interfaces Cerebro-Computadora más utilizadas: el deletreador P300. Como el nombre lo indica, consiste en una aplicación para escribir texto en una computadora detectando el potencial evocado conocido como P300. Se verá por lo tanto primero sobre este potencial evocado, el paradigma utilizado para la aplicación de deletreo, referencias sobre trabajos ya realizados sobre este tema y un análisis propio sobre una base de datos extraída de una competencia de algoritmos para detección de P300.

3.1. Potencial evocado P300

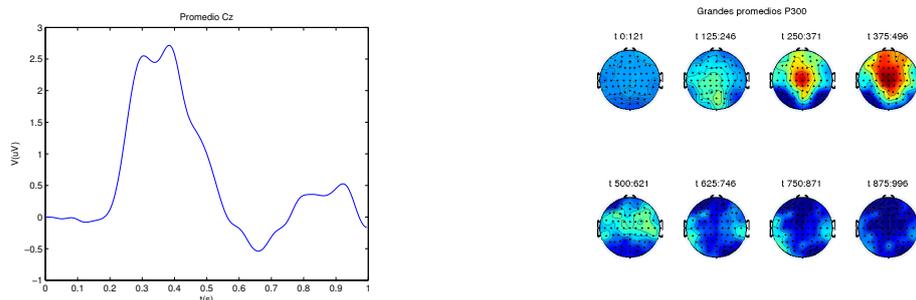
El P300 es un potencial evocado endógeno. Consiste en una desviación positiva cerca de los 300ms luego del evento que lo provoca, con amplitud máxima en electrodos centro-parietales (ver figura 3.1). Como otros ERP, su amplitud es muy pequeña en comparación con el EEG de fondo, pero al estar atado temporalmente al evento, promediando varias instancias se logra reducir la potencia del ruido y visualizar la forma de onda del ERP (ver figura 3.1). El P300 fue descrito originalmente por Sutton et al. en 1965 [37] y desde entonces ha sido muy estudiado.

Lo eventos que generan un P300 son los que cumplen el paradigma conocido como *oddball*, que indica básicamente que deben tener dos atributos: ser relevante para la tarea que se está desarrollando, y ser un evento ‘raro’ (de baja probabilidad).

En los primeros trabajos donde se presentó el P300 [37] se le mostraban al usuario dos tipos de estímulos: parpadeos de luces y números. Luego de que se presentaban dos números tenían que responder una pregunta simple sobre ellos (por ejemplo cuál número es el mayor). Encontraron, además de otros potenciales evocados asociados a estímulos visuales, que los estímulos numéricos generaban un corrimiento positivo a los 300ms que el resto de los estímulos no. Esto se debía a que dichos estímulos eran significativos para el usuario.

A partir de ese experimento, muchas configuraciones que cumplen con el para-

Capítulo 3. Deletreador P300



(a) Promedio de instancias del potencial en el electrodo Cz 1s luego del estímulo. Se puede ver la desviación positiva aproximadamente a los 300ms que vuelve a 0 cerca de los 500ms.

(b) Diagrama del potencial distribuido en toda la cabeza en distintos momentos posteriores a la presentación del estímulo. Se representa con colores el valor del potencial, yendo de azul para valores más negativos a rojo para los más positivos. Se puede observar que el potencial evocado se presenta en los electrodos centro parietales, atenuándose su potencia al alejarse hacia los electrodos más periféricos.

Figura 3.1: Visualización del P300 promediando un segundo luego del estímulo. En $t = 0$ se da el estímulo que genera el potencial evocado. Promediando varias instancias se logra anular el ruido (todas las componentes de señal que no corresponden al P300) debido a que es la única componente atada temporalmente al estímulo. Para esta figura se utilizaron 2550 instancias para el promediado, extraídas de la base de datos descrita en la sección 3.4.1

digma *oddball* se han utilizado para provocar la aparición de un P300. Un ejemplo clásico de éstos que ha sido muy utilizado se describe en la figura 3.2.

A pesar de que la latencia del P300 es de alrededor $300ms$, dado que refleja la decisión, no necesariamente consciente, de que un evento raro sucedió, esta latencia puede variar entre $250ms$ y $750ms$ dependiendo de la naturaleza de la decisión, como puede ser la dificultad de la tarea (ver siguiente sección 3.1.1).

Respecto al origen y la función del potencial P300, existen varios estudios y experimentos que abordan el problema, pero mucho queda por descubrirse. Trabajos con pacientes con daño cerebral indicarían que algunas regiones (como la unión entre los lóbulos temporal y parietales) juegan un rol importante en la generación del P300, mientras que otras no (regiones prefrontales y parietales laterales) [38] [39]. Por otro lado, la teoría respecto al rol funcional del P300 (que no tiene en cuenta la generación neuronal) más aceptada es la llamada *context-updating model* (modelo de actualización de contexto). Ésta propone que el P300 es un reflejo de la actualización del modelo que tenemos del contexto en el que se encuentra la tarea que se está realizando. Por lo tanto, cuando un evento es inconsistente con el modelo

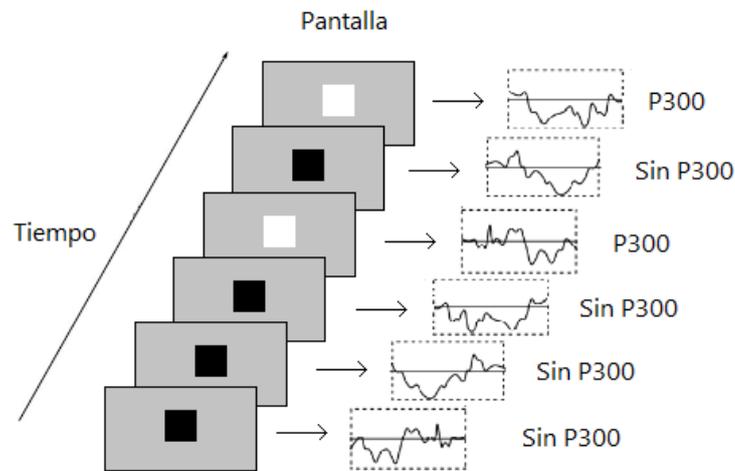


Figura 3.2: Ejemplo de experimento donde un tipo de estímulos generan un P300 en el usuario. Se utilizan dos tipos de estímulos visuales: cuadrados negros y cuadrados blancos. Los cuadrados blancos son menos comunes que los negros y aparecen intercalados al azar. Se le pide al usuario que cuente la cantidad de cuadrados blancos que aparecen. Cuando aparece uno de estos cuadrados blancos, al ser relevantes para el usuario y aparecer de forma sorpresiva, se genera un P300 en la cabeza del observador. Cada instancia corresponde al registro de EEG comenzando en el instante en que aparece el estímulo visual en pantalla. Si promediamos todas las instancias con P300 podemos observar la forma del mismo, como se puede ver en la figura 3.1

de contexto y éste precisa ser reevaluado, se genera un P300 [40]. Por ejemplo, en el experimento de la figura 3.2 en el que se presentan cuadrados blancos y negros, pero los blancos se presentan con baja probabilidad, el modelo correspondería a la aparición repetitiva de cuadrados blancos, mientras que al aparecer uno negro se debe reevaluar el modelo dado que no cumple con el mismo.

3.1.1. Variabilidad del P300

Muchos son los factores que afectan las características del P300 evocado. En primer lugar, al tratarse de un potencial endógeno, producto de un procesamiento cognitivo del cerebro, la latencia del mismo es muy variable entre personas (incluso para mismo experimento), además de ser dependiente del experimento en sí [41] [42] [43]. Es por ello que en la técnica de promediado se utilizan los datos de un único individuo durante una etapa del experimento.

Por otro lado, se han estudiado los factores que influyen en la amplitud del P300. En primera instancia está el tiempo entre los estímulos generadores. A mayor tiempo entre los mismos, mayor amplitud del P300 (al menos hasta los 8 segundos aproximadamente) [44]. Esto estaría asociado a una menor probabilidad

Capítulo 3. Deletreador P300

de aparición del estímulo generador. Una amplitud usual de P300 para cualquier experimento es de entre 10 y 20 μV , mientras que en los experimentos específicos para BCI es de entre 4 y 10 μV . Esto se debe seguramente a la presentación rápida de estímulos utilizada en las aplicaciones de BCI en búsqueda de mayor transferencia de información, que resulta en ERPs solapados. Si, por azar, dos estímulos generadores de P300 se dan consecutivamente, el segundo genera un potencial de menor amplitud que el primero. [45]

Otro factor que afecta la amplitud del P300 es el total de actividades en las que se encuentra el sujeto. Si, por ejemplo, un sujeto se encuentra realizando una tarea para provocar un P300, se le indica que debe realizar una segunda tarea, el potencial generado por la primera disminuye [46].

Por otro lado, también hay evidencia de variación de la amplitud del P300 con el tiempo para el mismo sujeto, incluso dentro de una misma sesión y más aún al pasar los días, las semanas y los meses [47].

Muchos de los estudios que hablan sobre variaciones en la amplitud del P300 no tienen en consideración las variaciones en latencia (que durante el mismo experimento las distintas instancias de P300 presenten con distinta latencia), las cuales, al promediar las instancias para obtener el ERP limpio, pueden ser la causa en la baja de amplitud [48].

3.2. El Deletreador P300

El primer BCI basado en estos potenciales fue presentado por Farwell y Donchin en 1988 [49] y consistía en un deletreador (o *speller*). Hasta ahora es la implementación más usada y estudiada, y prácticamente la única utilizada fuera de condiciones de laboratorio [9]. Esta es la razón por la cual fue el primer experimento elegido para esta investigación.

Esta aplicación funciona de la siguiente manera. El usuario se sienta frente a una pantalla (con los electrodos puestos), en la cual se muestra una matriz con todas las letras y símbolos deseados. Luego se iluminan (parpadeando) las filas y columnas de forma aleatoria, pasando varias veces por cada fila y cada columna. El usuario debe contar la cantidad de veces que se ilumina la letra deseada, lo cual genera un P300. Por lo tanto, determinando cuando se genera un P300 se puede determinar la letra deseada (fila y columna que la contienen). Este esquema se puede ver en la imagen 3.3.

En este primer experimento, Farwell y Donchin lograron los siguientes resultados:

- Para una precisión de 80 % se requerían 20,9s por selección (2,9 caracteres por minuto)
- Para una precisión del 95 % se requerían 26,0s por selección (2,3 caracteres por minuto)

Desde entonces se ha trabajado buscando diferentes variantes, tanto en el procesamiento de los datos, como en la captura de los mismos, la presentación de

3.3. Capacidad del canal

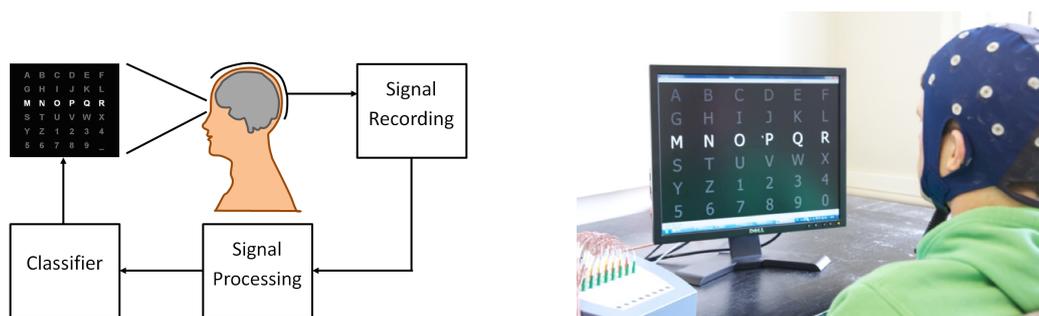
los estímulos, etc, para mejorar esos resultados. Teniendo en cuenta que todas las partes del proceso van mejorando con el avance tecnológico (mejoras en los electrodos, los amplificadores, las pantallas para presentar estímulos y los algoritmos utilizados), estas mejoras han sido modestas. Meinicke et al. [51], por ejemplo, lograron una precisión de 95 % en 15 segundos utilizando mayor cantidad de electrodos. Dolchin et al. [52] lograron en el 2000, con análisis *offline*, una tasa de 7.8 caracteres por minuto con un 80 % de precisión y 4.8 caracteres por minuto con un 90 %. Sin embargo, los resultados al trabajar *online* no fueron los esperados, al ajustar los parámetros a valores para los cuales obtenían una performance del 90 % *offline* obtuvieron un 56 % en una prueba *online*.

3.3. Capacidad del canal

Las BCI son en última instancia un sistema de comunicación que toman como entrada un estado mental que desea transmitir el usuario. Este estado va a ser reconocido por el sistema con cierta precisión un tiempo determinado posterior a la aparición del mismo y se transformará en un comando a la aplicación del BCI en particular. En otras palabras, el BCI es el medio a través del cual se transmite la información que presente en dicho estado mental. Como tal, se desea que sea capaz de transmitir la mayor cantidad de información posible.

Una medida objetiva para comparar la capacidad de los distintos dispositivos BCI es por lo tanto la tasa de transferencia de información. Este valor es la cantidad de información transmitida por unidad de tiempo, y toma en consideración tanto la rapidez con que el dispositivo da una respuesta, como la precisión del mismo y el número posible de estados que se puede transmitir.

A pesar de que Wolpaw et al. ya indicaban la importancia de utilizar este



(a) Diagrama de un sistema de deletreado con P300. Los bloques son los de cualquier sistema BCI, donde hay una dependencia con el estímulo que en este caso es la pantalla de la PC. El control accionado por el usuario también actúa sobre la PC escribiendo las opciones detectadas.

(b) Usuario utilizando el sistema. Se puede ver la matriz de letras en la pantalla y el gorro con los electrodos puestos en la cabeza [50].

Figura 3.3: Imágenes descriptivas del experimento a analizar.

Capítulo 3. Deletreador P300

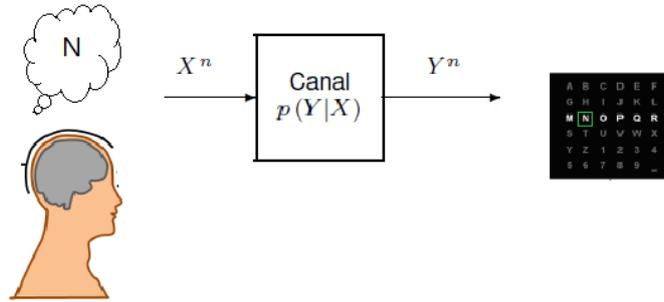


Figura 3.4: Sistema BCI como canal de comunicación. Se ejemplifica para el caso del Deletreador P300, donde se recibe de un lado la letra que el usuario desea deletrear X y del otro se obtiene la letra detectada Y . El canal está definido por la distribución de probabilidad condicional entre estas variables.

valor para evaluar las diferentes BCI en 1998 [53] y otros trabajos han abordado el tema específicamente [54] [55] [56], todavía son muchos los trabajos donde se reportan valores de velocidad, precisión y/o cantidad de símbolos por separado, dejando incluso a veces alguno de estos valores de lado. Esto dificulta el análisis y la comparación de los distintos trabajos [52] [51].

El interés por lo tanto es conocer cuál es la mayor tasa de información que se puede alcanzar en un BCI dado. A este valor se lo conoce como *capacidad de canal*.

Llamémosle X a la variable aleatoria correspondiente al estado mental que adquiere el usuario (en el caso del deletreador corresponde a una de las letras disponibles) e Y a la variable asociada al estado detectado por el sistema BCI. En otras palabras, se envía X y del otro lado del canal se recibe Y (ver Figura 3.4). La capacidad del canal de transmisión se calcula como la máxima información mutua entre estas dos variables para alguna distribución de probabilidad de entrada:

$$C = \max_{p(x)} I(X; Y); \quad I(X; Y) : \text{información mutua} \quad (3.1)$$

La información mutua es una medida de la dependencia de las dos variables, es decir, cuánto se conoce de X al observar Y .

Asumiendo las hipótesis de que todas las opciones (letras) tienen la misma probabilidad de error e y que la probabilidad de recibir cualquiera de las letras incorrectas es la misma, ($\frac{e}{N-1}$ con N la cantidad de letras posibles, dado que hay $N - 1$ letras incorrectas), entonces el canal es simétrico y la capacidad del canal se calcula como [57, Capítulo 07]:

$$C = \log_2(N) - H(e) - e \cdot \log_2(N - 1) \quad (3.2)$$

donde H es la función entropía

$$H(e) = -e \cdot \log_2(e) - (1 - e) \cdot \log_2(1 - e) \quad (3.3)$$

3.4. La Competencia de Detección de P300

Trabajo	Precisión (%)	$T_{ch}(s)$	$C_t(bits/min)$
(1) Farwell y Donchin [49]	80	20,9	9,82
(2) Farwell y Donchin [49]	95	26,0	10,68
(3) Meinicke et al. [51]	95	15,0	18,51
(4) Dolchin et al. [52]	80	7,7	26,70
(5) Dolchin et al. [52]	90	12,5	20,10

Tabla 3.1: Capacidad de canal calculada según los resultados reportados de distintos trabajos de referencia. Los valores de Precisión (%) y $T_{ch}(s)$ se extraen directamente de éstos trabajos y se calcula $C_t(bits/min)$ según la ecuación 3.4. (1) Farwell y Donchin [49] con 80% de precisión (2) Farwell y Donchin [49] con 95% de precisión (3) Meinicke et al. [51] (4) Dolchin et al. [52] con 80% de precisión (5) Dolchin et al. [52] con 90% de precisión

Para obtener la capacidad de canal por unidad de tiempo simplemente se divide por el tiempo que toma cada decisión:

$$C_t = (\log_2(N) - H(e) - e \cdot \log_2(N - 1)) \cdot \frac{1}{T_{ch}} \quad (3.4)$$

donde,

C_t : Capacidad del canal por unidad de tiempo (tasa de transferencia de información).

T_{ch} : tiempo que toma cada selección.

Los resultados reportados por los trabajos comentados equivalen entonces a las capacidades de canal reportadas en la tabla 3.1. Las tasas de transferencia de información obtenidas se encuentran entre $10bits/min$ y $27bits/min$. Estos datos servirán de referencia para el análisis a lo largo de este trabajo.

3.4. La Competencia de Detección de P300

En el 2001 varios laboratorios e investigadores del área se unieron para proponer una competencia sobre BCI con el objetivo de evaluar el interés existente en este área de investigación. Debido a las buenas repercusiones obtenidas decidieron los años siguientes proponer una segunda, tercera y cuarta competición. La tercera fue presentada en el 2004 y una de las propuestas consistía en un deletreador P300. [58]

Un aspecto importante a destacar sobre estas competiciones es la búsqueda de un estándar en los datos para poder evaluar consistentemente los distintos algoritmos presentados. La cantidad de variables que entran en juego en un sistema BCI completo son tantas, que es difícil la comparación de la detección de los

Capítulo 3. Deletreador P300

diferentes algoritmos si los datos fueron tomados por dispositivos de diferente calidad, con diferente número de electrodos utilizados por diferentes personas en diferentes circunstancias. Por lo tanto, para estas competiciones, se presentaban diferentes bases de datos y se proponía un desafío sobre estas con el objetivo de evaluar todo los algoritmos presentados sobre los mismos datos.

En esta sección se presentará la base de datos correspondiente al desafío presentado sobre un deletreador P300 en la BCI Competition III, junto con el algoritmo ganador de dicha competencia.

3.4.1. Base de datos

La base de datos presentada en la competencia para el desafío sobre el paradigma P300 Speller fue provista por el laboratorio de BCI del Centro Wadsworth del New York State Department of Health, encabezado por J. R. Wolpaw. Una descripción completa incluyendo los vínculos a la descarga de la misma se puede encontrar en [59].

La base consiste en registros de EEG de 64 canales tomados durante una sesión de deletreo utilizando el paradigma clásico descrito por Donchin et al. en el 2000 [52], y originalmente por Farwell y Donchin en 1988 [49]. En el experimento, el usuario se concentraba en un caracter de los 36 presentados; el objetivo de la competencia era predecir el caracter correcto mediante detección de P300. Los 36 caracteres se presentaban en una matriz de 6×6 y cada fila y cada columna se intensificaba aleatoriamente con una frecuencia de $5,7Hz$. Solo dos de esas 12 líneas contenían el caracter deseado y generaban por tanto un P300. En la figura 3.5 se muestra la interfaz de la pantalla que se mostraba al usuario al registrar los datos y la ubicación de los electrodos utilizada.

Los datos fueron tomados a $240Hz$ y filtrados entre $0,1 - 60Hz$.

La intensificación se repetía 15 veces para cada caracter. A este conjunto de datos (correspondientes a la selección de un caracter) se le denomina época. Para cada época, las filas y columnas se intensificaban 15 veces cada una. La intensificación duraba $100ms$, quedando la matriz apagada durante los $75ms$ restantes hasta la intensificación de la próxima fila/columna ($5,7Hz$ corresponden a $175ms$ de período).

El dataset contiene información de dos sujetos (A y B) y está separada en conjunto de *train* (85 caracteres, etiquetados) y conjunto de *test* (100 caracteres, sin etiquetar).

En las figuras 3.6 y 3.7 se muestran distintas representaciones de los grandes promedios (promedio de todas las instancias del set de entrenamiento) para el Sujeto A donde se puede observar el potencial P300.

3.4.2. Algoritmo ganador

Como referencia se describirá ahora el trabajo ganador de la competencia, sus métodos y resultados. El mismo fue realizado por Alain Rakotomamonjy y Vincent Guigue del Institut National des Sciences Appliquées de Rouen en Francia [60].

3.4. La Competencia de Detección de P300

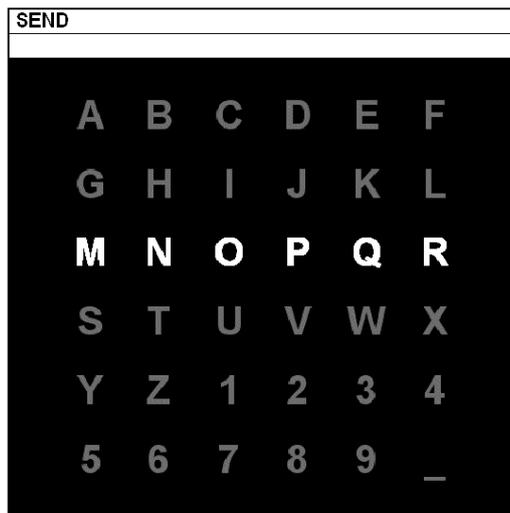
El método consiste en entrenar Support Vector Machines (ver más adelante en esta sección) con ciertas particularidades. En primer lugar, no se entrena una sino varias SVM (creando un ensamble de hasta 17 clasificadores) para cada sujeto, donde se utiliza un subconjunto del conjunto de entrenamiento para entrenar cada una.

Se propone además realizar una selección de los canales a utilizar y una búsqueda del parámetro C de las SVM que arroje mejores resultados de clasificación.

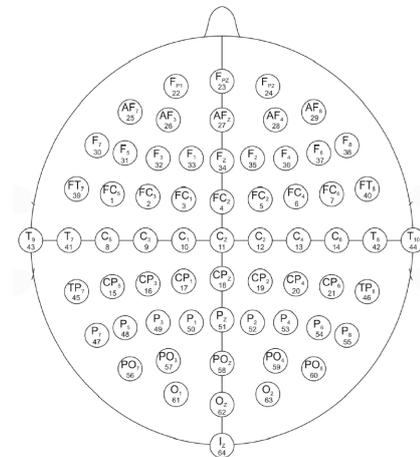
En la figura 3.8 se puede ver un diagrama del método propuesto con un resumen del mismo. En las siguientes secciones se verá cada uno de los bloques con mayor detalle.

Support Vector Machines

Las SVM son una técnica de Machine Learning muy conocida y utilizada. El espacio de decisión es un hiperplano (superficies de decisión lineal) y durante el entrenamiento se busca aquel que maximiza el margen de separación entre las clases. Para una clasificación binaria con un conjunto de datos de entrenamiento $(x_i, y_i)_{i=1, \dots, N}$, con $x_i \in R_m$, $y_i \in \{-1, +1\}$, y función de decisión de la forma $f(x) = \text{signo}(w \cdot x + b)$, este hiperplano óptimo se determina hallando el vector w que resuelve:



(a) Representación de la pantalla que se le mostraba al usuario durante la toma de datos. En este ejemplo el usuario debía deletrear la palabra *SEND* letra por letra. Para cada letra, todas las filas y columnas de la matriz eran intensificadas varias veces (en este ejemplo la tercera fila se está intensificando).



(b) Ubicación de los electrodos utilizados para la toma de datos de la base.

Figura 3.5: Display y electrodos utilizados en la toma de datos de la base de BCI Competition III [59].

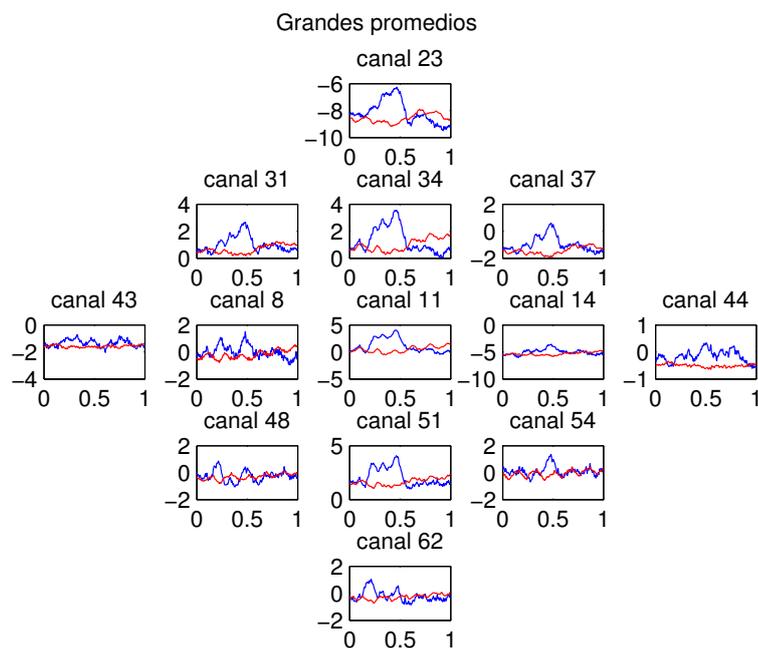


Figura 3.6: Grandes promedios para el Sujeto A en varios canales ubicados consistentemente según su ubicación en la cabeza. Se puede observar que la potencia del P300 es mayor en los canales centrales.

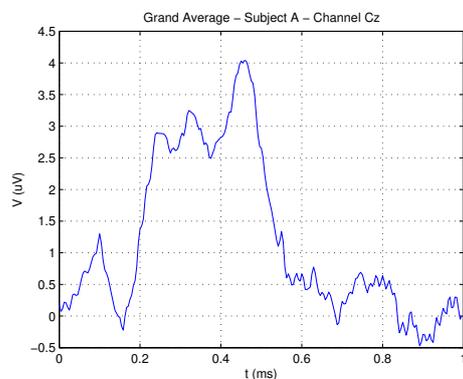


Figura 3.7: Gran promedio para el Sujeto A en el canal Cz, uno de los canales donde el P300 se da con mayor potencia. Se puede ver la desviación positiva alrededor de los 300 ms, aunque en este caso el pico mayor se da a los 450 ms aproximadamente.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \epsilon_i$$

Sujeto a:

$$y_i \cdot (w^T \cdot x_i + b) \geq 1 - \epsilon_i, \quad \epsilon_i \geq 0 \quad \forall i$$

3.4. La Competencia de Detección de P300

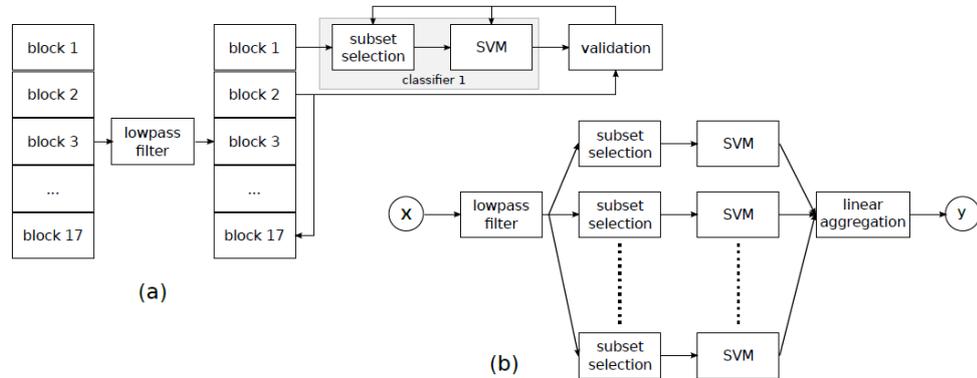


Figura 3.8: Arquitectura del clasificador propuesta en [60]. a) El dataset de entrenamiento es dividido en 17 subsets de igual tamaño, sin solapamiento, y se entrenan 17 SVMs con cada uno de ellos. Los parámetros de las SVMs, incluyendo la selección del subconjunto de canales en los que se va a aplicar la SVM, son aprendidos de forma independiente, utilizando el resto de los 16 subsets como datos de validación. b) Para la clasificación, la salida de las 17 SVMs se suma linealmente para producir una puntaje promedio, el cual es utilizado para la selección de la letra candidata.

donde:

w : vector perpendicular al hiperplano (define orientación).

b : posición del plano.

ϵ_i : variables ficticias para tener en cuenta las instancias que violan la restricción de que las clases sean separables por un hiperplano.

C : parámetro definido por el usuario que establece el compromiso entre maximizar el margen y minimizar los errores. Un valor chico de C implica darle mayor peso a la maximización del margen.

Nótese aquí que el espacio de características con el que se trabaja es la señal propiamente dicha.

Preprocesado

La primera etapa consiste en cortar el intervalo de tiempo post estímulo relevante y filtrar pasabanda la señal. Se cortan los $667ms$ luego de cada estímulo, se filtra entre $0,1Hz$ y $10Hz$ con un filtro Chebyshev tipo I de orden 8 y se realiza un submuestreo acorde. Esto implica que para cada instancia se tiene 14 muestras por canal etiquetadas con $+1$ o -1 . Las instancias corresponden a cada parpadeo, por lo tanto, sin promediar tenemos 15300 instancias para el entrenamiento ($12 \text{ líneas} \times 15 \text{ parpadeos} \times 85 \text{ épocas}$). Las dos clases se encuentran desbalanceadas, 12750 a 2550 (5 a 1).

Para generar luego el ensamble de clasificadores, se divide el conjunto de entrenamiento en 17 particiones de 900 instancias, correspondientes a 5 épocas. Cada

Capítulo 3. Deletreador P300

una de éstas se utilizará para entrenar una SVM.

Previo al entrenamiento se realiza una normalización de las características para que cada una de éstas tengan media 0 y varianza 1 para el conjunto de entrenamiento. Luego se normaliza el conjunto de test con los mismos parámetros.

Selección de modelo

El siguiente paso corresponde a la selección del modelo para cada SVM (parámetro C y canales a utilizar). Esto se realiza básicamente mediante un *greedy search*, es decir, se prueba con muchos valores y se selecciona el que mejor resultado arroja para un set de entrenamiento. Como se tiene 17 particiones, para cada una de ellas se utilizan las otras para validar cada modelo. En todos los casos se emplea un Kernel lineal(ver sección 3.4.2).

Para la selección de canales se aplica un algoritmo de eliminación recursiva. Primero se realiza el entrenamiento de una SVM con todos los canales, luego se van extrayendo de a uno y se entrena y evalúa una SVM para cada nuevo set. Se remueve el canal que se sacó en la SVM que mejor resultado arroja. Así sucesivamente se van eliminando los canales uno a uno. La performance de cada SVM para un subconjunto de entrenamiento se evalúa con el resto de los subconjuntos analizando la clasificación binaria (detecta o no P300, no la letra deletreada) utilizando el siguiente score:

$$C_{cs} = \frac{tp}{tp + fp + fn} \quad (3.5)$$

donde: *tp*: true positives. Instancias con P300 evaluadas correctamente.

fp: false positive. Instancias sin P300 evaluadas incorrectamente.

fn: false negative. Instancias con P300 evaluadas incorrectamente.

Este valor (C_{cs}) es útil también para realizar un *ranking* de los canales, el cual se utilizará más adelante para evaluar la performance con canales fijos.

Dada la cantidad de SVM a entrenar que implica este proceso (computacionalmente costoso), la eliminación de canales se realiza de a 4 para acelerar el proceso.

Para encontrar el parámetro C, se repite el proceso de entrenamiento con distintos valores de éste (0, 0,05, 0,1, 0,5 y 1,0). Luego se selecciona el par C-número de canales que mejores resultado arrojó, para cada uno de los 17 subsets de entrenamiento.

Clasificación

Una vez entrenadas todas las SVM y creado el ensamble se procede a clasificar el set de test. Para cada línea en cada parpadeo se tiene un valor de clasificación de cada SVM entrenada. Para tomar la decisión de qué letra se deseaba deletrear se promedia estas salidas para cada letra combinando las líneas correspondientes de la siguiente manera.

$$S_{r|c} = \frac{1}{J} \frac{1}{K} \sum_{j=1}^J \sum_{k=1}^K f_k^j(x_{r|c}) \quad (3.6)$$

3.4. La Competencia de Detección de P300

Donde:

k corresponde a cada SVM entrenada (K es la cantidad de SVMs)

j corresponde a cada parpadeo (J cantidad de parpadeos -15-)

x es el vector de características

f es la salida de la SVM

$r|c$ indica la fila y la columna de la letra que se esta analizando

Finalmente se selecciona la letra que arroje el mayor valor S .

Se verá a continuación cómo, al utilizar el promedio de las salidas de varios clasificadores lineales, se realiza tanto un promediado en el espacio de la señal como un promediado en el espacio de salida de las SVM, lo cual es otro método para disminuir los efectos de la variabilidad de las señales.

Dado que el kernel utilizado en las SVM es lineal, el valor de la salida viene dado por:

$$f_k(x) = \sum_{i \in P_k} y_i w_i^{(k)} \langle x, x_i \rangle + b^{(k)} \quad (3.7)$$

donde:

P_k : es la partición k -ésima.

$\{w_i^K\}_i$ y b^k : son los parámetros obtenidos en el entrenamiento de la SVM.

Sustituyendo en la ecuación de clasificación y reordenando términos tenemos,

$$S_{r|c} = \frac{1}{K} \sum_{k=1}^K \sum_{i \in P_k} y_i \alpha_i^{(k)} \left\langle \frac{1}{J} \sum_{j=1}^J x_{r|c}^{(j)}, x_i \right\rangle + b^{(k)} \quad (3.8)$$

La ecuación 3.8 deja en evidencia el doble promediado.

Resultados reportados

En este trabajo ganador de la competencia reportan un porcentaje de detección correcta de caracteres del conjunto de test de 96.5% en promedio para ambos sujetos, tomando las 15 repeticiones de cada línea (número máximo de parpadeos) y 73.5% para 5 repeticiones. El desempeño para menor cantidad de parpadeos es de interés dado que implica poder dar una respuesta en menor tiempo. En la tabla 3.2 se pueden ver los resultados para cada sujeto.

	5 parpadeos	15 parpadeos
Subj A	72%	97%
Subj B	75%	96%
Promedio	73.5	96.5

Tabla 3.2: Resultados reportados por el ganador de la BCI Competition III para la base de datos de P300 Speller. [60].

Capítulo 3. Deletreador P300

La performance es evaluada como la cantidad de épocas (o caracteres) clasificados correctamente sobre la cantidad total. Eso es, para cada época el algoritmo da una respuesta que corresponde a uno de los 36 caracteres posibles de la cuadrilla. Por lo tanto, se cuenta con 36 clases distintas y la performance de un algoritmo que de una respuesta de forma aleatoria (que no logre captar ningún tipo de información asociada a la elección del usuario) sería de 2.8 % (1/36).

Dado que el reporte de los datos es diferente entre trabajos, a veces no es posible comparar de forma precisa los resultados obtenidos sin tener valores intermedios. En la sección 3.5.1, donde se replica lo propuesto por Rakotomamonjy et al., se comparan los resultados obtenidos con este método con los de Farwell en 1988 y los de Donchin en el 2000.

3.5. Análisis del algoritmo ganador

Como primer paso en el camino a recorrer en la investigación sobre este tema se planteó reproducir el algoritmo presentado por el ganador de la competencia (descrito en la sección anterior), así como resultados intermedios bajando la complejidad de ciertos procesos, en busca de entender qué factores están jugando un rol más importante en la detección. Este análisis es el que se presenta en esta sección.

3.5.1. Reproducción de algoritmo

Lo primero que se abordó fue la reproducción del algoritmo presentado por Rakotomamonjy et al., incluyendo las etapas completas de entrenamiento (selección de canales y 5 valores para C). Para lograr esto se contó como punto de partida con el código en Matlab realizado por el propio Rakotomamonjy et al. [61]. Todas las modificaciones que hubo que realizarle al código (para poder reproducir lo descrito en el trabajo) y las nuevas implementaciones realizadas sobre el mismo fueron realizadas en Matlab.

Luego de tener el algoritmo completo funcionando se procedió con el análisis. En la figura 3.9 se puede ver la evolución de la performance del algoritmo a medida que se toman más parpadeos, mientras que en la tabla 3.3 se resumen los resultados, donde se puede ver que coinciden con los reportados por Rakotomamonjy et al..

	5 parpadeos	15 parpadeos
Subj A	72 %	97 %
Subj B	75 %	96 %
Tiempo	10s	30s

Tabla 3.3: Tabla resumen de los mejores resultados para cada sujeto para dos cantidades de parpadeos utilizadas en el procesamiento. Se agrega en la última fila el tiempo que toma la elección de cada caracter (una época) para esa cantidad de parpadeos.

3.5. Análisis del algoritmo ganador

Trabajo	Precisión (%)	$T_{ch}(s)$	$C_t(bits/min)$
(a) Farwell y Donchin [49]	80	20,9	9,82
(b) Donchin et al. [52]	80	7,7	26,70
(c) Rakotomamonjy et al. [60]	80	14,7	14,06

Tabla 3.4: Comparación de los resultados obtenidos por (a) en el experimento original por Farwell y Donchin [49], (b) Donchin et al. en el 2000 [52] y (c) Rakotomamonjy et al. en la BCI Competition III [60]. Se comparan todos para una precisión de 80 %.

Se calcula ahora la tasa de transferencia de información para los resultados de Rakotomamonjy et al. mediante la ecuación 3.4 en la sección 3.2 con los trabajos de referencia para poder compararlos como se muestra en la tabla 3.4. Allí se puede ver que la tasa de transferencia de información alcanzada por Rakotomamonjy et al. es superior a la reportada originalmente en el año 1988 por Farwell [49] pero inferior a la obtenida más adelante por Donchin en el 2000 [52]. Los factores que entran en juego (en particular en la toma de datos) son tantos que es difícil evaluar la razón de estas diferencias. Además, los datos utilizados por Farwell y por Dolchin no se encuentran disponibles. Tomaremos, por lo tanto, los resultados replicados de lo propuesto por Rakotomamonjy et al. sobre la base de datos pública como referencia para el resto del análisis del deletreador P300.

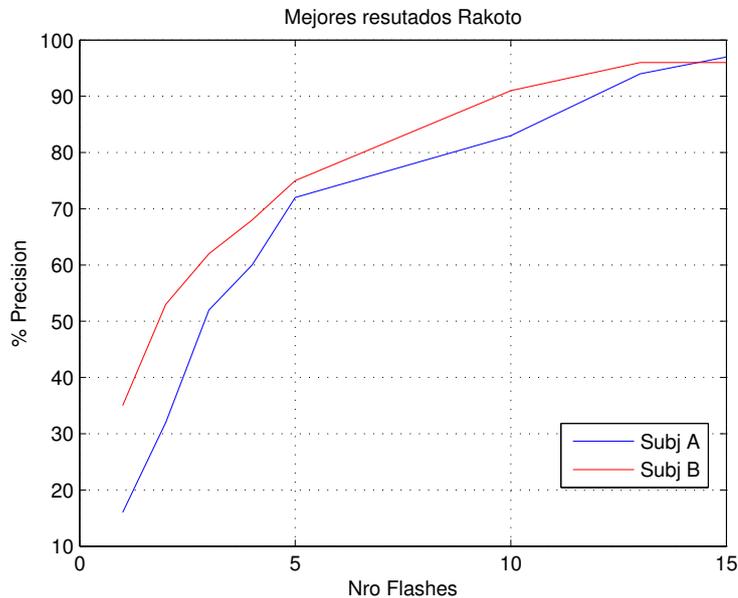


Figura 3.9: Evolución de la performance alcanzada replicando lo descrito por Rakotomamonjy et al. al variar el número de parpadeos que se toman en cuenta para el procesamiento. Se observa que con 5 parpadeos se supera el 70 % de precisión para ambos sujetos, y se pasa el 95 % incluyendo los 15 parpadeos.

Capítulo 3. Deletreador P300

Una de las desventajas del algoritmo propuesto por Rakotomamonjy et al. que quedó a la vista al reproducirlo es el alto costo computacional del proceso de entrenamiento, llevando más de un día de procesamiento para un equipo de gama media-alta (procesador Intel Core i7 de $2,60GHz$ con $12GB$ de memoria RAM corriendo Windows 8.1 de 64bits), lo cual quita mucha usabilidad para una aplicación online que precise re calibrarse en distintas sesiones. Esto es un motivo más por el cual buscar bajar la complejidad del algoritmo. En las siguientes secciones se analiza qué sucede con la performance al realizar esto.

3.5.2. Número de SVMs a entrenar

Se calculan ahora la cantidad de SVMs a entrenar en el algoritmo de Rakotomamonjy et al. como referencia de la complejidad del mismo y costo computacional del proceso de entrenamiento.

Para la selección de canales se tiene: $\#SVM_{ch} = (64 + 1) \cdot \frac{64}{2} = 2080$
El proceso se repite para cada valor de C : $\#SVM_C = 5 * \#SVM_{ch}$
Esto se realiza para cada partición del conjunto de entrenamiento: $\#SVM_P = 17 * \#SVM_C$

Por lo tanto, en total se entrenan:

$$\#SVM = (64 + 1) \times \frac{64}{2} \times 5 \times 17 = 176800$$

3.5.3. Entrenamiento de canales

Como se vió, el proceso completo del algoritmo propuesto por Rakotomamonjy et al. implica el entrenamiento de un enorme número de SVMs. Por lo tanto se analiza qué sucede al tomar ciertos canales fijos.

En primer lugar, veremos el resultado del proceso de selección de canales. En la figura 3.10 se puede ver la evolución del indicador de precisión durante el proceso de eliminación de canales para dos subconjuntos de entrenamiento para ambos sujetos. Se puede ver que existe un número óptimo de canales pero éste varía considerablemente para cada subconjunto y cada sujeto (ver también figura 3.11).

En las tablas 3.12 y 3.13 se pueden ver qué canales fueron bien posicionados más veces en las distintas particiones de entrenamiento.

Como conclusión de estos resultados se puede decir que la información relevante para la correcta clasificación de las clases está distribuida a lo largo del cuero cabelludo de distinta forma para cada sujeto (la distribución del P300). Este es el motivo por el cual un algoritmo independiente a cada sujeto casi no se encuentra en la literatura sobre P300 sino que el entrenamiento se realiza para cada usuario.

Tomando estos datos reportados por Rakotomamonjy et al., se toma distinta cantidad fija de los canales mejor posicionados en el *ranking* para saltar el proceso de selección y se analiza la performance obtenida. Se utilizan 17 SVMs y se filtra la señal a $30Hz$, tomando los mismos canales tanto para cada partición de entrenamiento como para ambos sujetos.

3.5. Análisis del algoritmo ganador

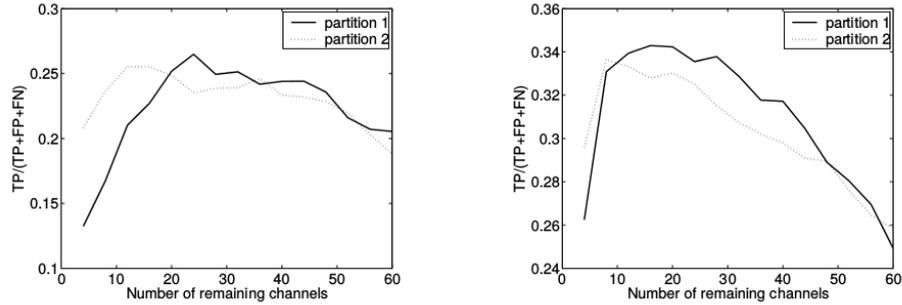


Figura 3.10: Evolución de la precisión durante el proceso de eliminación de canales para algunos subconjuntos. En la izquierda para el Sujeto A y en la derecha para B. Se puede ver que existe un número óptimo de canales pero éste varía considerablemente para cada subconjunto y cada sujeto. Imagen extraída del trabajo de Rakotomamonjy et al..

Dec. Funct f_k	Classifier index k																
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Subject A	32	32	36	20	40	24	36	40	40	24	28	12	56	16	40	16	16
Subject B	12	8	16	16	12	12	4	12	16	16	8	8	8	4	8	12	4

Figura 3.11: Cantidad de canales seleccionados por subconjunto de entrenamiento para cada sujeto. Se observa que el número de canales seleccionado para el Sujeto A es mayor que para el Sujeto B. Esto es consistente con la distribución que se observa del P300 para cada Sujeto (ver sección 3.6). Imagen extraída del trabajo de Rakotomamonjy et al..

	5 parpadeos	15 parpadeos
Seleccionando canales	73.5 %	96.5 %
64 canales fijos	64.5 %	93.0 %
32 canales fijos	65.0 %	93.5 %
16 canales fijos	55.5 %	88.5 %
8 canales fijos	53.5 %	85.0 %
4 canales fijos	47.0 %	80.0 %
3 canales fijos	44.5 %	78.0 %
2 canales fijos	26.5 %	47.0 %

Tabla 3.5: Resultados obtenidos con Rakotomamonjy et al. para canales fijos promediando los datos de ambos usuarios. Se puede ver como sin realizar selección pero tomando todos los canales se mantiene una buena performance, dándose la caída más abrupta recién cuando se consideran muy pocos canales (con 3 canales todavía se obtiene un 78 % de performance).

Capítulo 3. Deletreador P300

Observando los resultados obtenidos en tabla 3.5 se destaca que la performance con todos los canales, sin realizar selección, es alta, tomando en cuenta el enorme ahorro computacional en la etapa de entrenamiento, respecto al proceso completo de selección. Esto parece indicar que el ensamble de SVM logra captar los canales relevantes a pesar de que se aumenta considerablemente la dimensión del espacio de características.

Al bajar la cantidad de canales que se utilizan se puede ver la degradación de la performance, la cual es muy abrupta por debajo de los 3 canales para A y de

Data	12 Top Ranked Channels											
A1	FC ₁	C ₂	CP ₃	CP _z	F _z	F ₄	F ₆	P ₅	P _z	P ₈	PO ₇	PO ₈
A2	C ₁	CP _z	CP ₄	AF ₇	AF _z	F _z	F ₈	P ₅	P _z	PO ₇	PO _z	PO ₈
A3	FC ₂	CP ₅	CP ₁	F ₁	F _z	FT ₈	T ₇	P ₇	P ₅	P _z	PO ₇	PO ₈
A4	C ₃	C ₁	FP ₁	F ₂	F ₄	F ₆	TP ₇	P ₇	P ₅	P _z	PO ₇	PO ₈
A5	C _z	CP ₅	CP ₂	F ₇	F ₈	P ₇	P _z	P ₄	P ₈	PO ₇	PO ₄	PO ₈
B1	FC ₅	C ₅	C _z	CP _z	CP ₆	AF _z	T ₉	P ₁	P ₂	PO ₇	PO ₈	O ₁
B2	FC ₁	C ₃	C ₁	C _z	C ₄	CP ₃	CP _z	CP ₄	T ₉	P ₁	PO ₈	O ₁
B3	C ₁	CP _z	AF _z	T ₇	T ₉	P ₂	P ₆	PO ₇	PO _z	PO ₈	O ₁	I _z
B4	FC ₃	FC ₂	CP ₅	F ₃	T ₉	P ₇	P ₂	PO ₇	PO ₃	PO _z	PO ₈	O ₁
B5	FC ₂	C ₆	CP _z	CP ₄	CP ₆	T ₁₀	P ₃	P ₄	PO ₇	PO ₈	O ₁	I _z

Figura 3.12: Canales posicionados dentro de los primeros 12 para distintos subconjuntos de entrenamiento (particiones). Se puede ver la gran variabilidad y cómo sólo algunos canales son posicionados en los primeros 12 consistentemente (PO_7, PO_8) y que algunos canales son bien posicionados en un sujeto pero no en el otro (P_5, O_1). Estas diferencias también se pueden ver en la figura 3.13. Imagen extraída de [60].

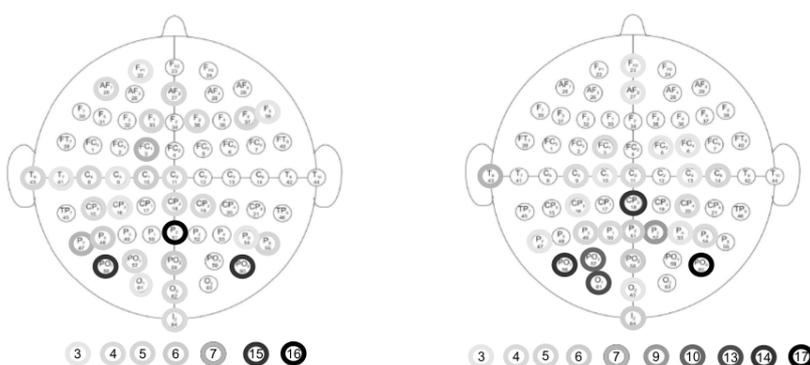


Figura 3.13: Distribución de los canales según el ranking generado durante el proceso de eliminación. A la izquierda el Sujeto A y a la derecha el Sujeto B. Se marca con gris más oscuro los canales que fueron posicionados entre los primeros 12 más veces. Imagen extraída de [60].

3.5. Análisis del algoritmo ganador

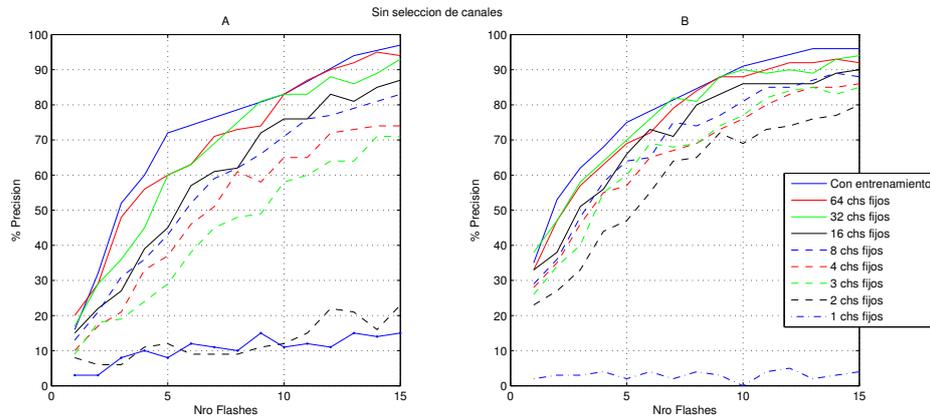


Figura 3.14: Resultados obtenidos con Rakotomamonjy et al. con canales fijos para cada usuario por separado. Se puede ver que utilizando un gran número de canales fijos se pueden obtener resultados similares a los obtenidos con el proceso de selección de canales para ambos usuarios. Se observa también que la mayor caída de performance se da recién por debajo de 3 canales para A y de 2 canales para B.

2 canales para B (ver figura 3.14). Esto implica hay cierta dinámica espacial en la formación del P300 que no se logra detectar al contar con tan pocos lugares (electrodos) de medida.

3.5.4. Ensamble de SVMs

Uno de los pilares del trabajo ganador es el promediado de los resultados arrojados por varias SVM entrenadas con distintos subsets. Veremos qué sucede al disminuir el número de SVMs en el ensamble. Se utilizan 8 canales fijos para observar cómo afecta la cantidad de SVMs utilizadas, dado que se tiene una muy buena performance con bajo tiempo de entrenamiento.

Los resultados para cada sujeto se pueden ver en la figura 3.15, y un resumen en la tabla 3.6. Se observa que para ambos sujetos, hasta 4 SVMs no se degrada la performance del clasificador. Sin embargo, por debajo de 4 SVM presentan comportamiento dispar, para A la performance cae notoriamente mientras que para B bajando incluso hasta 4 SVMs no se degrada la performance.

Dado que en todos los casos el modelo de SVM es el mismo y lo único que cambia es el conjunto de los datos sobre el cual se entrena, los resultados parecen indicar que en el caso del Sujeto A las SVM se sobreajustan a éstos y no logran una buena performance sobre el conjunto de test. Esto se soluciona tomando varias SVM y promediando las salidas, pero también se podría resolver entrenando con validación cruzada dentro del mismo conjunto de entrenamiento.

3.5.5. Frecuencia del filtro pasabajos

Para obtener un indicador de en qué rangos de frecuencia se encuentra la información útil, se utiliza ahora el clasificador de Rakotomamonjy et al. con 17 SVMs y los 64 canales para distintas frecuencias de corte del filtro pasabajos utilizado en el preprocesado. Los resultados se pueden ver en la figura 3.16 y en la tabla 3.7.

Se puede observar que filtrando la señal a $30Hz$ se obtienen mejores resultados que si se considera todo el espectro (hasta $60Hz$), lo cual indica que se está mejorando la SNR al eliminar ruido. Por encima de los $20Hz$ parece haber muy poca información de la señal, encontrándose la mayoría de ésta por debajo de los

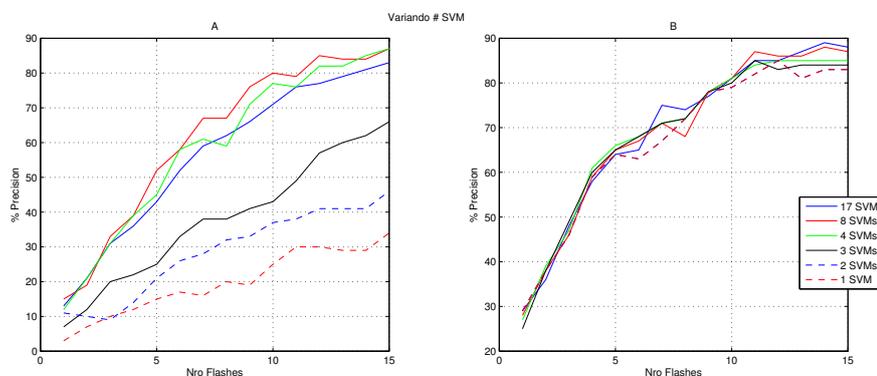


Figura 3.15: Algoritmo de Rakotomamonjy et al. con distinta cantidad de subconjuntos de entrenamiento, es decir cantidad de SVM distintas utilizadas. Se puede ver como bajando la cantidad hasta 4 SVMs no se degrada la performance para ninguno de los sujetos. Por debajo de 4 SVMs presentan un comportamiento desperejo, para A cae la performance notoriamente mientras que B mantiene una performance similar incluso al utilizar una única SVM.

	5 parpadeos	15 parpadeos
17 SVMs	53.5 %	85.0 %
8 SVMs	58.5 %	87.0 %
4 SVMs	55.5 %	86.0 %
3 SVMs	45.0 %	75.0 %
2 SVMs	42.5 %	63.0 %
1 SVMs	35.0 %	58.5 %

Tabla 3.6: Algoritmo de Rakotomamonjy et al. con distinta cantidad de SVMs utilizadas, promediando los resultados de ambos usuarios. Se utilizan 8 canales fijos. Se observa que bajando la cantidad hasta 4 SVMs, no se compromete la performance del algoritmo.

3.5. Análisis del algoritmo ganador

5Hz. Estos resultados son consistentes con el análisis de la señal realizada en la sección 3.6.

3.5.6. Performance intersujeto

Una de las desventajas que presenta la propuesta del trabajo de Rakotomamonjy et al. es que parece ser muy sujeto dependiente, lo cual no es deseable para una aplicación funcional de BCI dado que implica una sesión extensa de entrenamiento para cada sujeto. Se analiza por tanto cómo se comporta cada clasificador entrenado con el conjunto de test del otro sujeto. Los clasificadores que se prueban son el original propuesto (con entrenamiento de canales y 17 subconjuntos de entrenamiento) y los que presentan entrenamiento más sencillo con canales fijos y menos cantidad de subconjuntos de entrenamiento.

Se puede ver como ambos clasificadores colapsan cuando se utilizan para cla-

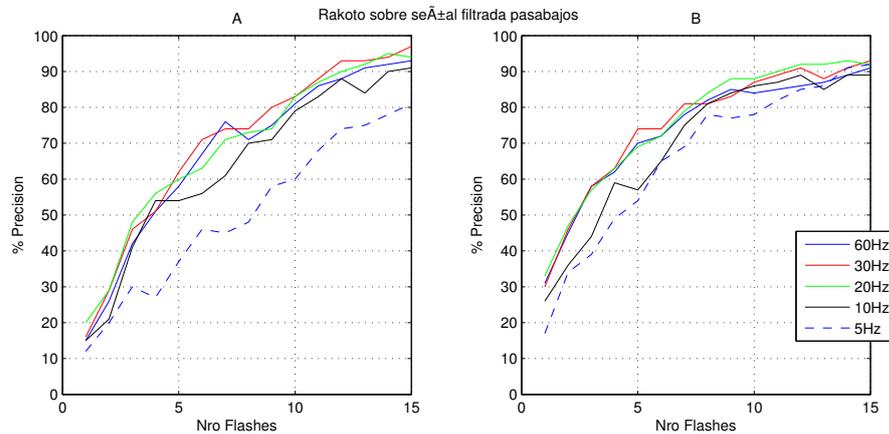


Figura 3.16: Algoritmo de Rakotomamonjy et al. variando frecuencia de corte pasabajos en etapa de preprocesamiento. Se puede ver que la performance decae notoriamente recién por debajo de los 10Hz, lo cual indicaría que la mayor información de la señal se encuentra en las frecuencias más bajas.

	5 parpadeos	15 parpadeos
60 Hz	64.0 %	92.0 %
30 Hz	68.0 %	5.0 %
20 Hz	64.5 %	93.0 %
10 Hz	55.5 %	90.0 %
5Hz	45.5 %	86.5 %

Tabla 3.7: Promedio entre sujetos del algoritmo de Rakotomamonjy et al. variando frecuencia de corte de pasabajos. Se puede observar que al filtrar a 30Hz mejora la performance de las SVM y recién por utilizando 10 Hz como frecuencia de corte del filtro pasabajos se obtiene una performance por debajo del 90 %.

sificar al sujeto con el que no fue entrenado. En particular, cuando se utiliza el entrenado con A para clasificar a B se obtienen mejores resultados que viceversa, lo cual sigue la línea de los resultados anteriores, indicando que la dinámica presente en el Sujeto A es más compleja y con mayor variabilidad que en el Sujeto B.

3.6. Análisis de las señales

Luego de reproducir el algoritmo propuesto por Rakotomamonjy et al. y analizar qué sucede si limitamos algunos de los procesos allí planteados, pasamos a analizar las señales de la base de datos en sí, para entenderlas mejor y poder aplicar luego conocimiento a priori de las señales para realizar una clasificación más sencilla y robusta y en lo posible no tan dependiente para cada usuario.

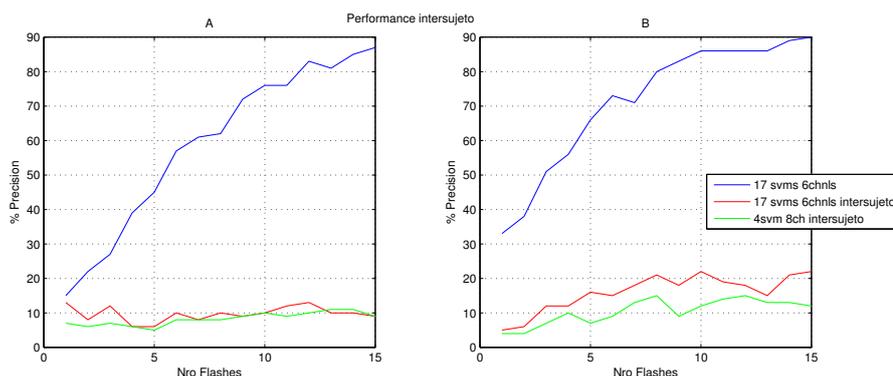


Figura 3.17: Algoritmo de Rakotomamonjy et al. aplicado al sujeto con el que no fue entrenado. Se puede ver como el algoritmo se encuentra completamente adaptado al usuario con el que fue entrenado y la performance cae de arriba del 90 % a abajo del 30 % cuando es utilizado con el usuario con el que no fue entrenado.

	A en B	B en A
17SVMs -16canales	22 %	9 %
4SVMs - 8 canales	12 %	9 %

Tabla 3.8: Promedio entre usuarios de los resultados de Rakotomamonjy et al. aplicado al sujeto con el que no fue entrenado. Ambos clasificadores colapsan con porcentajes de clasificación correcta muy bajos, a pesar de que el clasificador entrenado con A aplicado a B logra mayor detección que el entrenado con B utilizado con A.

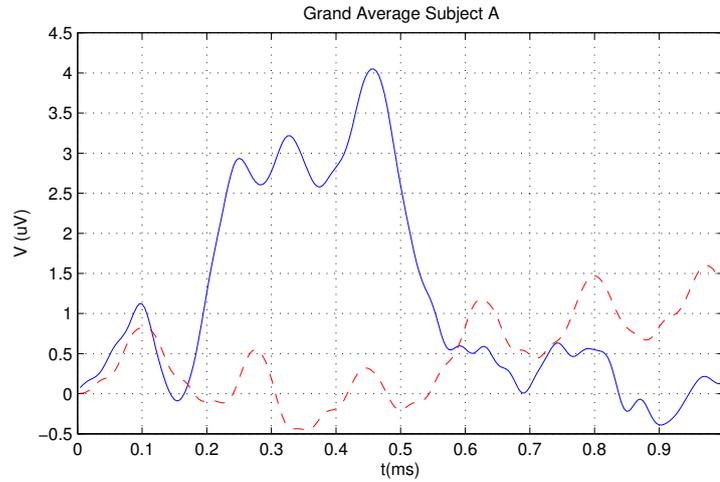


Figura 3.18: Grandes promedios de ambas clases para el Sujeto A. En rojo la clases sin P300 (background) y en azul con P300. Se puede observar el SSVEP muy visible en el gran promedio de las clases sin P300.

3.6.1. Grandes Promedios

En las figuras 3.18 y 3.21 se puede ver el gran promedio de cada clase (con y sin P300) para el conjunto de entrenamiento del sujeto A (se le llama gran promedio al promedio realizado utilizando todas las instancias de la base correspondiente a esa clase). Lo primero que se puede observar allí es que en la actividad de fondo (instancias en las que no hay P300) hay una oscilación de aproximadamente $6Hz$ que se encuentra atada al estímulo, dado que no desaparece con el promediado. Esto corresponde a la actividad cerebral generada por el parpadeo a $5,7Hz$ de las distintas líneas y es conocida como SSVEP (ver sección 2.4.3). Para observar únicamente el P300 hacemos la resta con el potencial de fondo (background); el resultado se puede observar en las figuras 3.19 y 3.20.

De esta forma se logra visualizar el P300 clásico, potencial positivo en la región centroparietal alrededor de $300ms$ luego del estímulo. Sin embargo, las características de éste dependen del sujeto; en particular, para el Sujeto A el ancho del ‘pulso’ es mayor que para el Sujeto B. Esto puede deberse a que el potencial evocado tiene mayor duración para un sujeto que para otro, o bien que el primer sujeto presenta mayor variabilidad en la latencia y por lo tanto, al promediar, se obtiene un pulso de mayor duración.

Capítulo 3. Deletreador P300

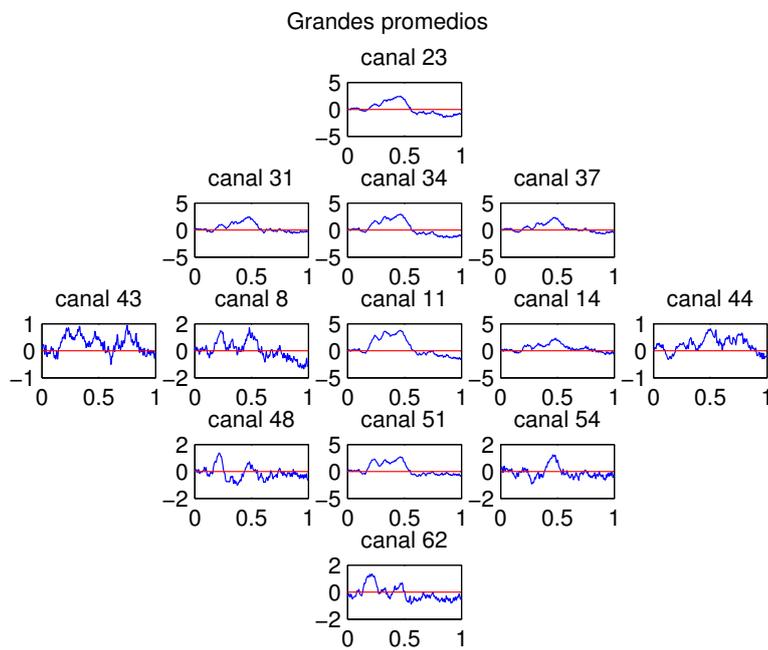
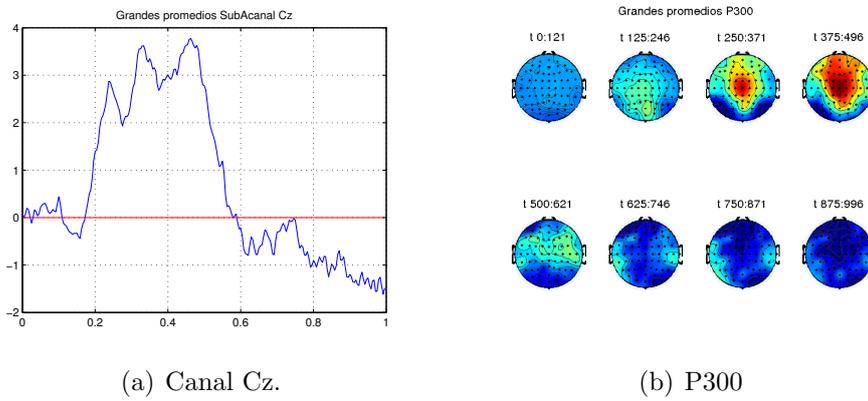


Figura 3.19: Potenciales para Sujeto A con y sin P300 en grandes promedios una vez extraída la señal de fondo. Se observa con mayor claridad el aumento de potencial correspondiente al P300.

3.6. Análisis de las señales

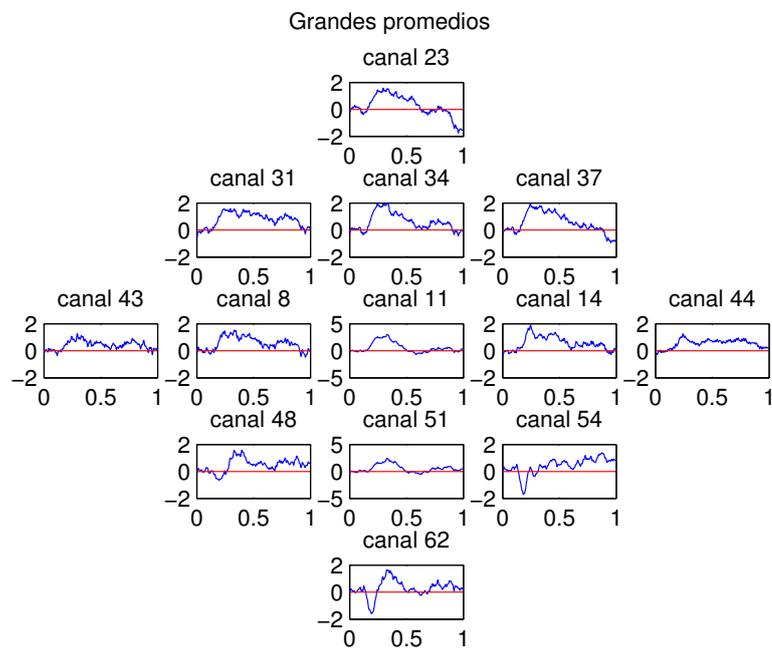
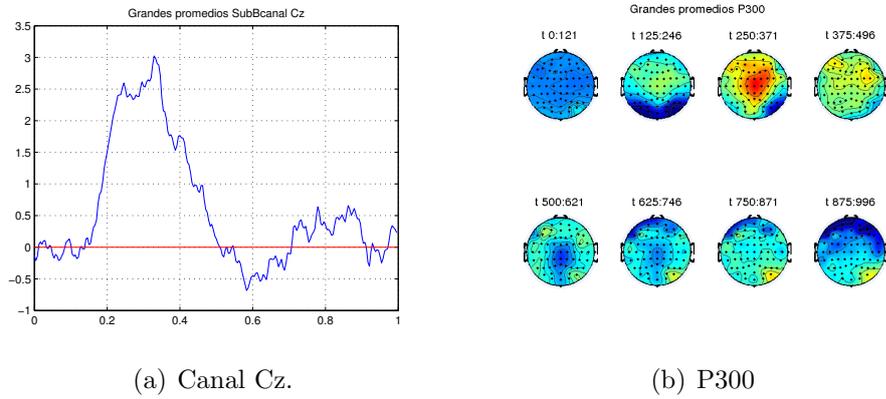
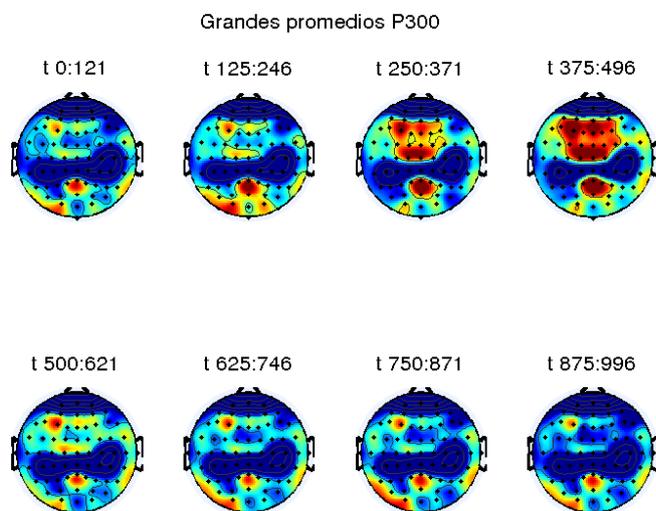
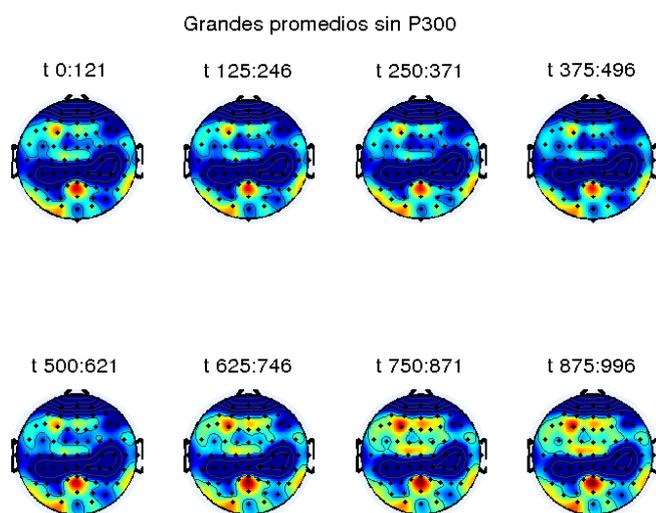


Figura 3.20: Potenciales para Sujeto B con y sin P300 en grandes promedios una vez extraída la señal de fondo. Se puede ver que el ancho del P300 es menor que el presente en el Sujeto A (Figura 3.19).

Capítulo 3. Deletreador P300



(a) Gran promedio con P300



(b) Gran promedio Sin P300

Figura 3.21: Grandes promedios para el sujeto A, para ambas clases, representando todos los canales distribuidos según ubicación. Se ordena temporalmente de arriba a la izquierda a abajo a la derecha, representando con azul los valores más bajos y con rojo los más altos. Se observa que en ambas clases aparece señal de fondo que no se anula con el promediado pero tampoco está asociada al P300. Se puede ver el aumento de potencial en los electrodos centrales cerca de los 300ms luego del estímulo, correspondiente al P300

3.6.2. Señal de fondo

Si en lugar de hacer la resta entre el promedio de las instancias con P300 y sin P300, sólo realizamos la extracción de la oscilación de fondo se obtienen los resultados que se muestran en la figura 3.22.

Para extraer esta oscilación se realiza lo siguiente: se corta toda la señal de entrenamiento en períodos de $1/5,7Hz$ obteniendo así un template de un período del SSVEP y luego se resta esta señal periodizada a la señal completa. Esto se realiza para cada canal.

Se observa en los resultados que para el promedio de las clases sin P300 aparece un potencial negativo prácticamente al mismo momento que el P300 pero de mucho menor amplitud que este. Esto es un efecto del promediado de las instancias superpuestas. Cada instancia consiste en 1 segundo de señal posterior al parpadeo de una línea, pero el parpadeo se da cada $175ms$. Por lo tanto, entre dos instancias seguidas coincide gran parte de la señal pero desfasada. Esto implica que al realizar el promediado de todas las instancias que no presentan P300, muchas en realidad incluyen al menos una parte de un P300, asociado a una instancia cercana (cada 6 instancias una es de clase P300). Por lo tanto, dado que las líneas se van parpadeando de forma aleatoria, el P300 aparecerá con corrimiento de $+175ms$, $-175ms$, $+350ms$, $-350ms$, y todos los múltiplos de $175ms$, pero nunca sincronizado en $0ms$ dado que esas son las clases etiquetadas como P300. En gran promedio esto provoca que aparezca que es como un *P300 negativo* sincronizado con el P300 real.

3.6.3. Evolución espacial del P300

Se analiza ahora la evolución de la activación de los electrodos para cada sujeto. Para ello se grafican todos los canales a lo largo del tiempo y se observa la figura formada para cada Sujeto (ver figura 3.23). Se concluye a partir de esto que ambos Sujetos presentan diferencias en la evolución espacial de la activación.

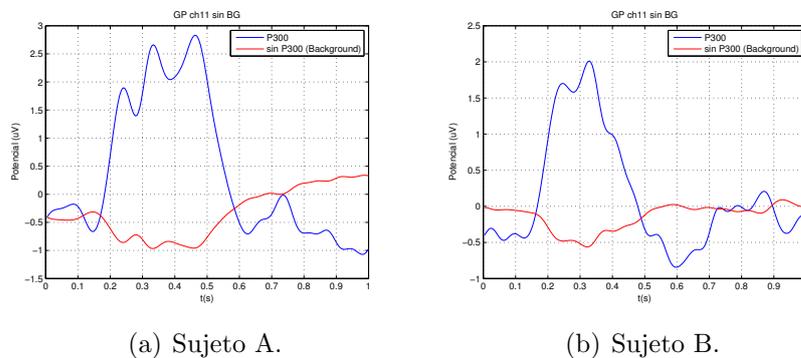


Figura 3.22: Potenciales en grandes promedios restando la oscilación de fondo.

Capítulo 3. Deletreador P300

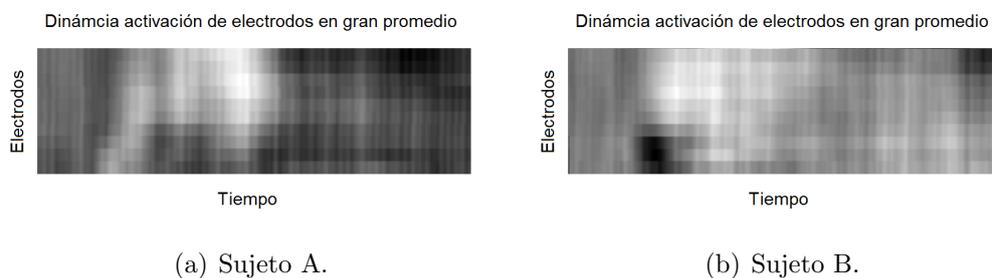


Figura 3.23: Electrodo agrupados verticalmente evolucionando en el tiempo para P300. Se muestran en blanco las potencias mayores (electrodos activados). Se observa que la dinámica de activación para cada sujeto es diferente: para el Sujeto A se activan primero los electrodos occipitales y luego los centro parietales, mientras que para el Sujeto B se activan directamente los electrodos centro parietales.

3.6.4. Comportamiento de las distintas épocas

Veamos ahora cómo se comportan las distintas épocas (cada letra deletreada) promediando los 15 parpadeos correspondientes a cada una. Para ello se toman las líneas correspondientes a cada letra y se promedia un segundo de las señales correspondientes a todos los (30) parpadeos de las dos líneas a la que pertenece cada letra. En la figura 3.24 se pueden ver los resultados para algunas épocas. Para cada una se muestra, junto con las señales del electrodo Cz, una matriz con el valor correspondiente a este canal en $t = 300ms$ y una matriz de referencia que muestra la letra correcta en cada caso.

En la Figura 3.24 se pueden observar distintos comportamientos. En el caso de la época 4 se puede ver algo parecido a lo esperado, un potencial positivo cerca de los $300ms$ que distinga al promedio correspondiente a la letra correcta y señal inactiva para las líneas que no poseen la letra deseada. Sin embargo, en la época 2 se puede ver que la columna correcta se destaca, pero no así la fila. Por otro lado tenemos el ejemplo de la época 12, donde nada parece distinguir las líneas correctas. Y finalmente la época 27, donde parecería darse un P300 tardío, más bien cerca de los $450ms$. Únicamente un 20%, aproximadamente, se clasifica correctamente tomando el valor del canal C_z a los $300ms$.

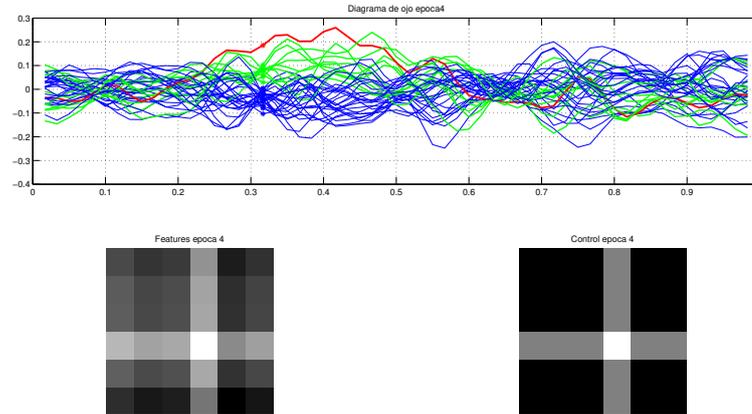
3.6.5. Comportamiento frecuencial

Veamos ahora el comportamiento de la señal en el dominio de la frecuencia. Todas las señales vienen prefiltradas pasabanda entre $0,1 - 60Hz$. La frecuencia de muestreo es de $240Hz$. En la figura 3.25 se puede ver el espectro del gran promedio para cada sujeto del canal Cz. La señal que se utiliza es la resta de los grandes promedios de las dos clases (con y sin P300) para extraer la actividad de fondo. Se puede ver que la energía se concentra debajo de los $5Hz$.

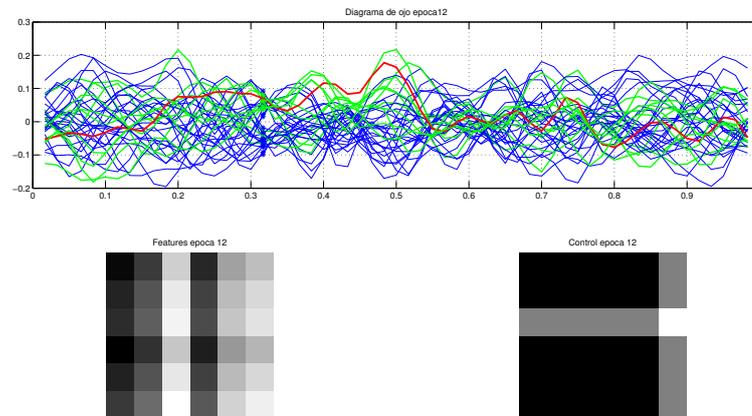
Si filtramos la señal a distintas frecuencias y observamos la salida y la com-

3.6. Análisis de las señales

ponente que se elimina se obtiene lo que se muestra en la figura 3.26, donde se puede apreciar aún mejor que la energía se concentra por debajo de los $5Hz$. Esto es consistente con los resultados obtenidos con Rakotomamonjy et al. al variar la



(a) Época 4



(b) Época 12

Figura 3.24: Visualización de las señales de distintas épocas en promedio de todos los parpadeos y sin oscilación de fondo. Para cada una se muestra: a) Gráfica del canal C_z promediando las instancias correspondientes a cada letra candidata. En rojo, la señal correspondiente a la letra que estaba observando el sujeto. En verde las correspondientes a las letras que comparen fila o columna con la anterior. En azul las correspondientes al resto de las letras. b) Matriz de la izquierda con el valor de C_z a los $30ms$ para cada letra candidata. c) Matriz de referencia que muestra la fila y la columna correspondiente a la letra correcta.

frecuencia de corte del filtro pasabajos (ver tabla 3.7) También se destaca que la latencia mínima (tiempo entre el estímulo y el potencial evocado) es prácticamente igual para ambos sujetos.

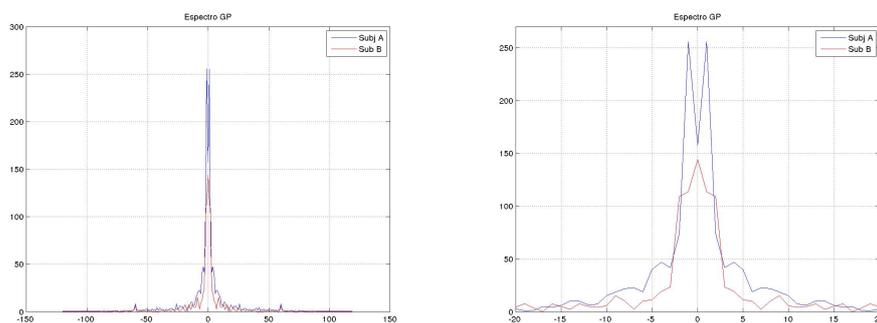
3.7. Experimentos

Una vez reproducido el algoritmo de Rakotomamonjy et al. y analizado junto con las señales involucradas, se plantean modificaciones al mismo con el objetivo de mejorar los resultados, ya sea en precisión de la detección como en costo computacional. Finalmente se intentó aplicar estos algoritmos a datos propios tomados con el dispositivo Emotiv Epoc.

La pregunta que sirve de guía es la siguiente: ¿cuánto podemos simplificar y dotar de robustez la detección del P300 al aplicar conocimiento a priori de las señales de EEG involucradas? En esta línea, se plantearon 3 experimentos: realizar una detección con un detector sincrónico, prefiltrar las señales utilizando la forma de onda del P300 como un filtro apareado y utilizar la salida como entrada para el algoritmo presentado por Rakotomamonjy et al., y finalmente extraer la señal de fondo SSVEP de todas las señales y nuevamente utilizar la salida como entrada para el algoritmo de Rakotomamonjy et al..

A continuación algunas definiciones que serán de utilidad durante esta sección:

- \mathcal{Y} : conjunto de letras posibles a deletrear
- $\mathbf{X} = \{x_{ij}\}$: conjunto de datos registrados
- x_{ij} : voltaje medido en canal k en tiempo i (relativo al comienzo del parpadeo)
- \mathbf{X}_j : instancia j -ésima correspondiente a un parpadeo



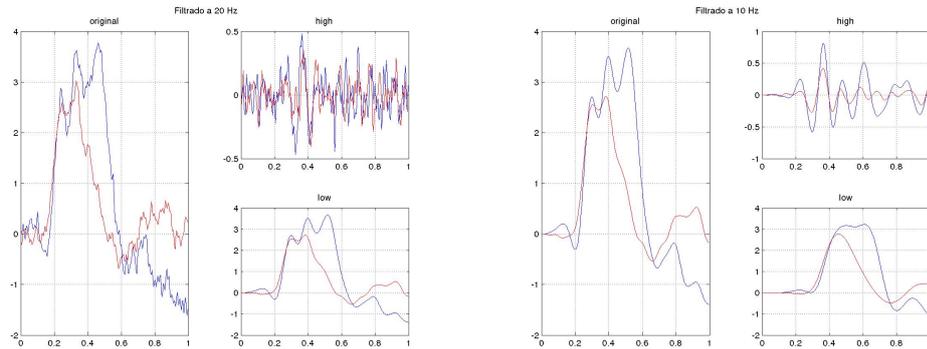
(a) Espectro grandes promedios.

(b) Zoom del espectro.

Figura 3.25: Espectro de los grandes promedios sin señal de fondo (se resta el gran promedio de la clase sin P300) para cada Sujeto.

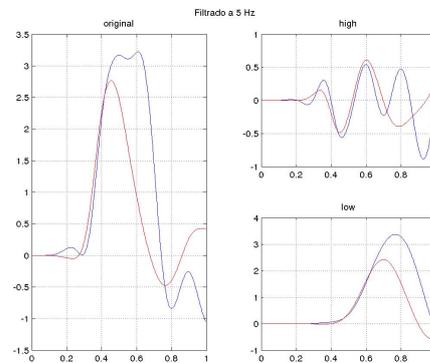
3.7. Experimentos

- $Y_j \in \mathcal{Y}$: etiqueta de letra correspondiente a la instancia \mathbf{X}_j
- \mathcal{Y}^r : letras de la fila r
- \mathcal{Y}^c : letras de la columna c
- $r_j \in 0, 1, 2, \dots, 6$: fila parpadeada en la instancia j ($r_j = 0$ si corresponde a una columna)



(a) Filtrada a 20Hz. Se observa que el residuo filtrado es básicamente ruido.

(b) Filtrada a 10Hz.



(c) Filtrada a 5Hz. Se observa que la señal filtrada contiene la mayor potencia del P300. Además, el tiempo en el que se dispara el potencial evocado para ambos sujetos es el mismo a pesar de que el ancho de pulso sea mayor para el Sujeto A.

Figura 3.26: Grandes promedios filtrados pasabajo a distintas frecuencias. Azul: Sujeto A. Rojo: Sujeto B. En cada figura se muestra: (izquierda) señal a filtrar (derecha arriba) residuo del filtrado pasabajos (derecha abajo) resultado del filtrado pasabajos. En cada paso se filtra la señal de salida del paso anterior.

Capítulo 3. Deletreador P300

- $c_j \in 0, 1, 2, \dots, 6$: columna parpadeada en la instancia j ($c_j = 0$ si corresponde a una fila)

3.7.1. Filtro apareado como detector

Si trabajamos sobre la hipótesis de que el pulso P300 para cada usuario tiene la misma forma y latencia en cada instancia, podemos utilizar un filtro sincrónico para su detección [62]. Este filtro consiste en correlacionar la instancia a evaluar con un *template* de la señal a detectar (P300) y es óptimo para maximizar la relación señal a ruido (SNR) en el caso de ruido blanco aditivo y gaussiano.

El proceso entonces es el siguiente. En primer lugar se precisa conocer la forma de onda de la señal que se desea detectar, es decir, tener un *template* del P300. Como estimación del mismo se tomó el gran promedio de las instancias de clase positiva para cada usuario para cada canal:

$$\mathbf{Z} = \sum_j \mathbf{X}_j \mathbf{1}(\{Y_j \in \mathcal{Y}^{r_j}\} \cup \{Y_j \in \mathcal{Y}_{c_j}\}) \quad (3.9)$$

donde:

j : es cada una de las instancias.

$\mathbf{1}(\cdot)$: función indicatriz asociada a un evento. Es decir, vale 1 cuando la línea parpadeada contiene la letra deseada y 0 en otro caso.

Por lo tanto, \mathbf{Z} corresponde al gran promedio de las instancias con P300.

Este filtro (\mathbf{Z}) es multicanal, siendo cada columna un filtro apareado clásico unidimensional. Para la detección sincrónica se realiza la medida de la respuesta del filtro en el pico del apareo. Por lo tanto para cada instancia j tenemos el siguiente valor:

$$\zeta_j = \sum_k \sum_{i=1} (\mathbf{X}_j)_{ik} \mathbf{Z}_{ik} \quad (3.10)$$

donde:

i corresponde a cada muestra temporal.

j corresponde a cada canal.

Luego, para cada letra candidata Y de la época j tenemos un *puntaje* que corresponde al promedio de estos valores de todas las instancias que correspondan a la fila y columna a la que pertenecen:

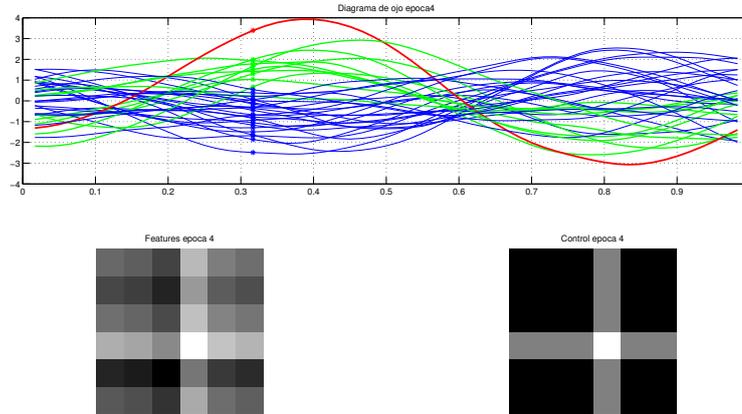
$$\zeta(Y) = \sum_{j \in J} \zeta_j \mathbf{1}(\{Y_j \in \mathcal{Y}^{r_j}\} \cup \{Y_j \in \mathcal{Y}_{c_j}\}) \quad (3.11)$$

Para cada época j el detector arroja la letra Y con mayor *puntaje* $\zeta(Y)$.

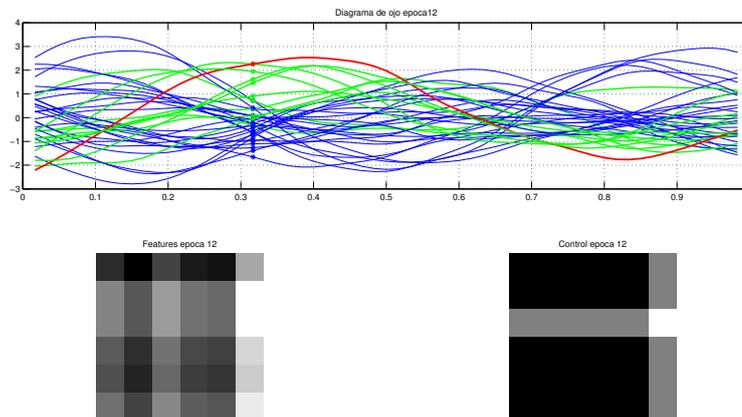
En la figura 3.27 se puede ver la salida de las distintas etapas de este proceso para algunas épocas en el canal C_z (donde el P300 presenta mayor potencia).

A pesar de que para algunas épocas este método funciona muy bien y se puede observar como el filtrado se comporta como esperado, la precisión en la detección

3.7. Experimentos



(a) Época 4



(b) Época 12

Figura 3.27: Visualización del filtro apareado para algunas épocas. Para cada una se muestra: a) Gráfica del canal C_z filtrado con el *template* de P300 y promediando las instancias correspondientes a cada letra candidata. En rojo, la señal correspondiente a la letra que estaba observando el sujeto. En verde las correspondientes a las letras que comparen fila o columna con la anterior. En azul las correspondientes al resto de las letras. Se marca además el instante en el cual se mide la salida del filtro. b) Matriz de la izquierda con el puntaje $\zeta(Y)$ para cada letra candidata. c) Matriz de referencia que muestra la fila y la columna correspondiente a la letra correcta.

general obtenida sobre el conjunto de test es muy baja: 33% para A y 34% para B.

Los resultados de la tabla 3.9 parecen indicar entonces la debilidad de las

Capítulo 3. Deletreador P300

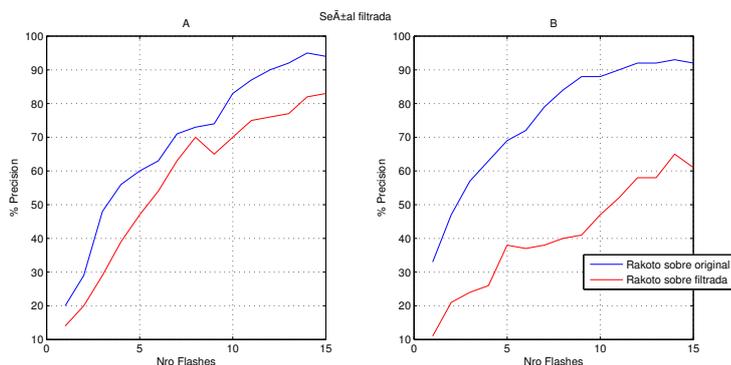


Figura 3.28: Resultados del algoritmo de Rakotomamonjy et al. aplicado a las señales filtradas con el *template* P300 promedio. Para ambos sujetos, la performance es mayor al utilizar los datos sin filtrar, a pesar de que para A se obtienen mejores resultados.

hipótesis asumidas. Esto se puede dar en dos niveles: o el P300 es muy variable en sí, tanto en forma como en distribución espacial, como para que el gran promedio lo represente, o bien hay más información relevante involucrada en las clases positivas que el P300.

3.7.2. Filtro apareado como prefiltrado

Para investigar un poco más las razones por las cuales el detector sincrónico arroja resultados tan pobres, se plantea lo siguiente: se prefiltran las señales originales con el *template* de P300 al igual que en el caso anterior, pero en lugar de muestrear esta salida y armar un puntaje por letra, se alimenta el algoritmo propuesto por Rakotomamonjy et al. con las señales filtradas. Los resultados se pueden ver en la figura 3.28 y la tabla 3.10.

Se puede ver que la performance, lejos de mejorar, cae notoriamente. Este resultado respalda la conclusión del experimento anterior, dado que a pesar de que la sincronización en este caso no es requerida, variaciones en la presentación del P300 pueden introducir un *blur* al correr el filtro apareado, afectando negativamente el resultado final del proceso.

	A	B
Filtro Apareado	33 %	34 %
Rakotomamonjy et al.	97 %	96 %

Tabla 3.9: Resultados obtenidos con el filtro sincrónico comparados con los obtenidos por Rakotomamonjy et al.. Los primeros muy bajos respecto a los segundos, lo cual indica que alguna hipótesis planteada para el filtro sincrónico no se cumple.

3.7.3. Extracción de señal de fondo SSVEP

Finalmente, se analiza el quitar la señal de fondo que aparece durante el experimento completo, independiente si existe un P300 o no, y es la oscilación generada debido al parpadeo periódico de $5,7Hz$.

La extracción de esta señal se realiza de la misma forma que fue explicado en la sección 3.6.2: se estima un período de la señal realizando un gran promedio (cortando la señal con el período correspondiente) con todos los datos, y luego se resta esa señal a la original.

Una vez que se quita la oscilación SSVEP, se corre el algoritmo de Rakotomamonjy et al. sobre esta nueva señal sin componente SSVEP. Se corre tanto el algoritmo completo (con selección de canales) como el algoritmo sin selección de canales pero utilizando la totalidad de los mismos. Los resultados se pueden ver en la figura 3.29 y la tabla 3.11.

Realizando la extracción del SSVEP se observan ganancias en algunos sentidos. En primer lugar, se logra mejorar la performance algunos puntos porcentuales para el algoritmo de Rakotomamonjy et al. sin selección de canales (utilizando igualmente la totalidad de los mismos), llegando incluso a superar el mejor resultado que se pudo obtener para el sujeto A luego de todo el procedimiento de selección de canales. Esto es de gran interés dado que, como se describió en la sección 3.5.3, el tiempo de entrenamiento pasa de más de un día de procesamiento a unos pocos minutos al saltar el proceso de selección de canales.

Si combinamos el prefiltrado con el entrenamiento completo de Rakotoma-

Datos	5 parpadeos	15 parpadeos
Originales	73.5 %	96.5 %
Pre filtrados con matched	42.5 %	72 %

Tabla 3.10: Promedio entre sujetos del algoritmo de Rakotomamonjy et al. sobre la señal filtrada con el *template* P300 promedio.

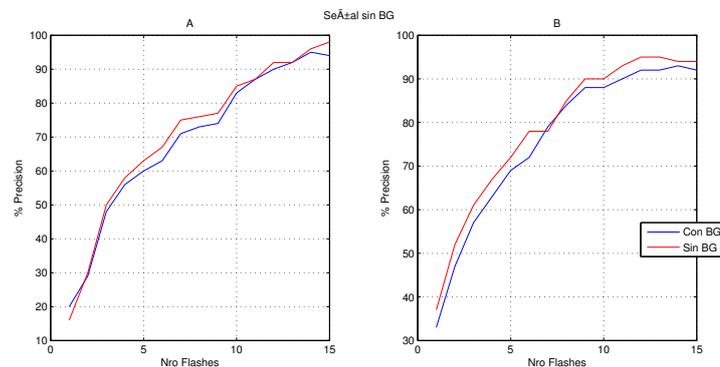
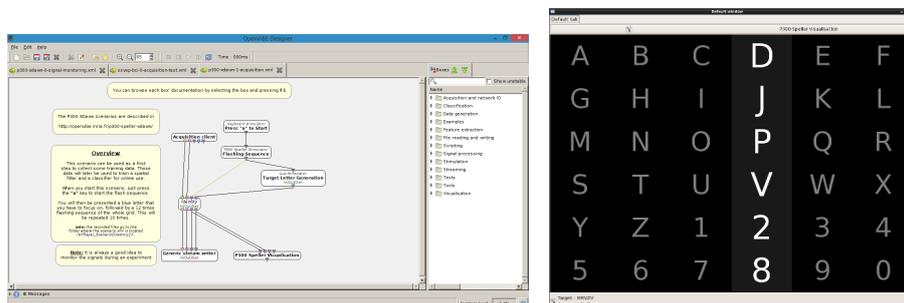


Figura 3.29: Algoritmo de Rakotomamonjy et al. sobre señal sin oscilación SSVEP en comparación con los resultados originales de Rakotomamonjy et al., sin realizar entrenamiento de canales. Se observa una pequeña mejora en ambos sujetos.

Capítulo 3. Deletreador P300



(a) Vista del editor de escenario.

(b) Vista de la pantalla del escenario de deletreador P300.

Figura 3.30: Vistas de OpenViBE, software utilizado para obtener registros propios para el deletreador P300.

monjy et al., incluyendo la selección de canales, obtenemos resultados muy similares a los originales, bajando un punto porcentual en cada sujeto.

3.7.4. Registro de datos propios

Se buscó finalmente realizar una prueba capturando datos propios. Para ello se utilizó el dispositivo Emotiv (ver capítulo 2.3.2) y el software OpenViBE [63]. Este último es una plataforma para diseñar y correr BCIs, que incluye además escenarios de prueba pre armados, entre los cuales ofrece uno de P300 Speller [64]. Existe además un driver para levantar los datos del Emotiv desde OpenViBE.

La prueba se realizó con un usuario y se registraron datos de 15 épocas. Dado que la colocación clásica del Emotiv Epoc todos los canales quedan en zonas donde el P300 tiene menor amplitud, se colocó tomando esto en cuenta, llevando los electrodos occipitales hacia zonas parietales. Los grandes promedios para las dos clases (con y sin P300) se pueden ver en la figura 3.31.

Como se puede ver en los grandes promedios, no se logró visualizar el P300 con los datos extraídos. A priori hay dos opciones de lo que podría estar pasando: o bien el experimento generó P300 en los momentos correspondientes y no se pudo capturar o bien no se generó P300 alguno. A pesar de que el dispositivo

Datos	A	B
a) Rakotomamonjy et al. original	97 %	96 %
b) Rakotomamonjy et al. sin SSVEP	96 %	95 %
c) Rakotomamonjy et al. 64ch fijos	94 %	92 %
d) Rakotomamonjy et al. 64ch fijos sin SSVEP	98 %	94 %

Tabla 3.11: Promedio entre sujetos del algoritmo de Rakotomamonjy et al. sobre la señal sin oscilación SSVEP.

3.7. Experimentos

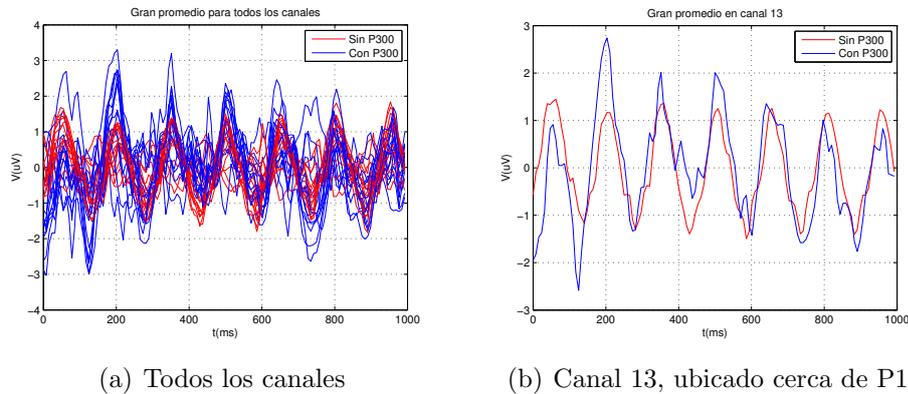


Figura 3.31: Gran promedio de los datos extraídos utilizando el escenario de deletreador P300 de OpenViBE y el dispositivo Emotiv Epoc. En rojo gran promedio para la clase con P300 y en azul sin. Se puede observar la oscilación provocada por el parpadeo pero no así el pulso P300.

utilizado no es de grado médico y presenta una relación señal a ruido muy pobre, se logra visualizar claramente la oscilación asociada al parpadeo a frecuencia fija (el SSVEP), el cual supone ser menor en amplitud que el P300, por lo que no se trataría de un problema de precisión del dispositivo. Además, la misma presencia del SSVEP descartaría cualquier problema de sincronismo entre la presentación de los datos y la adquisición de los mismos. Por lo tanto, todo parece indicar que no se logró inducir un P300 en los momentos deseados con el experimento, lo cual indicaría que las condiciones para hacerlo (iluminación, pantalla, posición de electrodos, concentración del usuario, condiciones particulares del usuario en si, etc) deben ser más estrictas de lo esperado.

Para poder concluir el factor determinante en la no aparición del P300 en los datos adquiridos con el Emotiv Epoc hace falta mayor análisis, en particular pruebas con mayor número de usuarios buscando además un ambiente de mayor concentración en la tarea realizada. Sin embargo, debido a los escasos resultados obtenidos trabajado con el P300 speller, sumado al hecho de que el potencial SSVEP si fue detectado claramente con el Emotiv, se decidió terminar aquí con el análisis para pasar a trabajar con estas otras señales.

Como se mencionó anteriormente, el dispositivo utilizado no es de grado médico y presenta una relación señal a ruido muy pobre. Sin embargo, sí se visualiza claramente la oscilación asociada al parpadeo a frecuencia fija (el SSVEP). Este potencial supone ser menor en amplitud que el P300, por lo que no sería un problema de precisión del dispositivo. Además, la presencia del SSVEP descarta cualquier problema de sincronismo entre la presentación de datos y la adquisición de los mismos.

3.8. Conclusiones sobre el deletreador P300

Las Interfaces Cerebro-Computadora basadas en potenciales evocados y particularmente en P300, son unas de las más investigadas desde hace casi tres décadas, pero recién en los últimos años se constatan intentos de probarlas en condiciones reales de uso [65] [66]. Desde la primera publicación de un deletreador P300 en 1988 [49], muchas variantes se han presentado, especialmente en cuanto a la presentación de los estímulos y las herramientas de procesamiento de las señales.

Aquí, se logró reproducir la propuesta presentada por Rakotomamonjy et al. en la BCI Competition III sobre un deletreador P300 clásico [60]. Además, luego de analizar y entender las señales de la base de datos disponible para la competencia, se propuso una mejora al procesamiento del algoritmo de Rakotomamonjy et al..

A partir de todos los experimentos realizados sobre la base de datos, concluimos que hay más información relevante para la detección que la forma de onda promedio del P300 para cada usuario. El P300 presenta variaciones para cada instancia que provoca que el P300, como gran promedio, no sea un representante fiel del potencial presente en cada instancia. Esto parece razonable en particular por tratarse de un potencial evocado endógeno, lo cual implica que sea muy dependiente no solo del usuario sino de la tarea presentada y las condiciones en la que se realiza.

Parece imprescindible contar con más bases de datos abiertas con las cuales se puedan comparar distintos algoritmos de detección. Este era uno de los objetivos de la competencia de BCI, el cual sirvió como primer paso para resolver la reproducibilidad de los trabajos. Sin embargo, debido a la gran dependencia interusuario y de calidad de las características de los dispositivos adquirentes, es necesario seguir avanzando en esta línea dado que dicha base de datos sólo incluye dos usuarios y los datos son tomados con un único dispositivo.

Por otro lado, a pesar de que se encuentran mejores referencias en cuanto al uso de BCIs basadas en ERP en lugar de SSVEP (en especial por el hecho de que los estímulos para generar SSVEP pueden ser molestos e incluso generar episodios de epilepsia en personas que padecen esta enfermedad), en el P300 Speller se utilizan estímulos que también generan SSVEP, lo cual no es mencionado en las publicaciones estudiadas.

Por último, el no haber podido observar el P300 en los datos adquiridos con el Emotiv Epoc, incluso para grandes promedios y pudiendo visualizar el SSVEP de fondo, indica que las condiciones del experimento para provocar el P300 no son tan robustas como se esperaba. El poder tener una forma para adquirir señales propias es de gran importancia para continuar una investigación en esta línea, pudiendo abordar la variabilidad interusuario y de no estacionariedad de las señales (que son dos de los temas más problemáticos que aparecen) con mayor capacidad y pudiendo realizar pruebas en cuanto a la variación del experimento en sí (presentación de estímulos, tarea a realizar durante el mismo, etc).

Capítulo 4

Deletreador SSVEP

Luego de analizar el deletreador P300 y concluir que las señales SSVEP indican ser más robustas, se analizó una segunda aplicación de BCI de deletreo, pero basada en estas otras señales cerebrales. En este capítulo veremos sobre esta señal (qué la provoca, sus características, etc), la aplicación de deletreo basada en ellas, se analiza un algoritmo propuesto para la detección tanto sobre datos sintéticos como datos reales capturados con el Emotiv Epoc. Finalmente se llega a un prototipo de interfaz cerebro computadora funcional con esta aplicación y utilizando el Emotiv, con el cual se es capaz de transmitir $5,4\text{bits}/\text{min}$ de información.

4.1. Potenciales SSVEP

Los VEP en estado estacionario (o SSVEP) son oscilaciones estables del voltaje que son producidas por un rápido estímulo repetitivo como puede ser una luz estroboscópica o un patrón en un monitor alternando a una frecuencia dada. Los estímulos sucesivos evocan respuestas similares que al superponerse producen una oscilación estable. Una de las ventajas de estas señales es que se pueden analizar mediante técnicas de promediado como cualquier potencial evocado o con técnicas de análisis en frecuencia. En el espectro de estas señales generalmente se puede ver un pico en la frecuencia del estímulo y en los armónicos de mayor frecuencia.

4.2. BCI basadas en SSVEP

En un BCI basado en señales SSVEP estándar, al usuario se le presentan varios estímulos visuales repetitivos a diferentes frecuencias fijas en distintos lugares del campo visual. Cada estímulo representa una opción disponible para el usuario (salida del BCI) como puede ser elegir una letra, mover algo en cierta dirección, etc. Para elegir la opción deseada el usuario debe fijar la mirada en el estímulo que la representa. Como el EEG presenta un pico en la frecuencia del estímulo que se está observando, detectándolo se puede deducir la opción deseada por el usuario.

En la última década, una gran variedad de estudios han aplicado este paradigma para distintas aplicaciones de BCI, desde el movimiento de una prótesis

Capítulo 4. Deletreador SSVEP

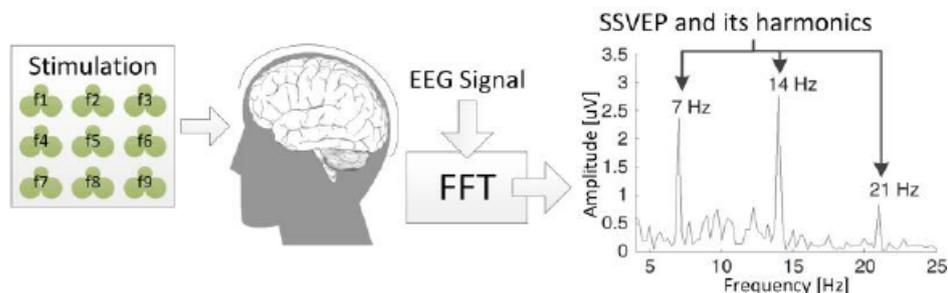


Figura 4.1: Diagrama de una BCI basada en SSVEP. Se le presenta al usuario varios estímulos parpadeando a distintas frecuencias. Al hacer foco en el estímulo que cambia a 7Hz, provoca la aparición de un pico en 7Hz, y sus armónicos, en el EEG. Imagen extraída de [67]

de rodilla [68] hasta el movimiento de un avatar en un ambiente de realidad virtual [69].

Varias son las razones por las cuales este tipo de BCI se han vuelto más populares y se cree tienen un futuro prometedor [9]: alta tasa de transferencia de información (o ITR), poca necesidad de entrenamiento para cada usuario y de fácil usabilidad [70] [71] [72].

Por otro lado, una de las desventajas de trabajar con este tipo de estímulos visuales es que pueden ser muy molestos para el usuario, particularmente para gente mayor [73]. Las frecuencias más altas parecen ser menos molestas para los usuarios (frecuencias por encima de 35Hz), sin embargo, la amplitud de los picos frecuenciales es menor y por lo tanto más difícil de detectar. Además, como ya se mencionó, muchos de estos estímulos son capaces de generar un episodio de epilepsia a las personas que padecen esta enfermedad.

4.2.1. Deletreador SSVEP

Siguiendo la línea de trabajo con el deletreador P300, se buscó investigar sobre los SSVEP pero mantener de cierta forma la aplicación de deletreo debido al interés de contar con un dispositivo para comunicación.

Existen muchos trabajos publicados que abordan este problema, con muchas variaciones tanto en presentación de los estímulos como en dispositivos utilizados y procesamiento realizado sobre los datos para la detección de intención del usuario.

Entre los trabajos más destacados en la literatura se encuentra el de Hwang et al. en 2012 [74], donde se armó un teclado QWERTY con 30 leds parpadeando a distinta frecuencia, logrando una rapidez de deletreo *online* de 9.39 letras por minuto (LPM) con un porcentaje de precisión del 87%, lo cual corresponde a una tasa de transferencia de información de $40,72\text{bits}/\text{min}$.

Otra publicación muy referenciada es la de Parini et al. en 2009 [75], donde lograron una tasa de transferencia de información de $51,47\text{bits}/\text{min}$ en promedio para los usuarios (con un mínimo de $17\text{bits}/\text{min}$ y máximo de $70\text{bits}/\text{min}$, lo cual refleja una gran variación interusuario generalmente presente en todos los trabajos

4.3. Prototipo de BCI en tiempo real

de BCI). En dicho trabajo se utiliza un sistema con 4 clases (4 estímulos a distinta frecuencia) y la detección sirve de entrada a un teclado virtual que se adaptaba según las selecciones anteriores.

En este trabajo se busca el desarrollo de un prototipo básico funcional de deletreador basado en SSVEP, que sirva como punto de partida para futuras investigaciones. Para ello en primer lugar se analiza el algoritmo utilizado para la detección de la frecuencia presente en el EEG para luego armar el deletreador en sí junto a la presentación de estímulos, para finalmente realizar una prueba con el equipo Emotiv Epoc en tiempo real.

4.3. Prototipo de BCI en tiempo real

Se propuso llegar a un prototipo funcional de Interfaz Cerebro Computadora basada en los potenciales SSVEP con aplicación de deletreo. A continuación se irán abordando los diferentes módulos que fueron necesarios para contar con la misma.

4.3.1. El experimento

La dinámica de uso planteada es la siguiente. El usuario se enfrenta a la pantalla de una PC utilizando el dispositivo de adquisición de EEG. En la pantalla se muestran dos estímulos distintos asociados a dos opciones posibles. Un estímulo es un rectángulo alternando entre blanco y negro a una frecuencia f_1 y corresponde a un conjunto de letras (A, B, C, D, etc), mientras que el otro estímulo consiste en otro rectángulo parpadeando a f_2 y corresponde al resto de las letras (M, N, O, P, etc), dividiendo así todo el abecedario en dos conjuntos. Se posiciona un estímulo a la izquierda de la pantalla y otro a la derecha.

El usuario debe observar el estímulo que corresponde al conjunto de letras que contiene la letra deseada. Por ejemplo, en caso de querer deletrear la letra B debe observar el estímulo de frecuencia f_1 que se encuentra a la izquierda en el ejemplo de la figura 4.2.

Se registran las señales de EEG durante 30 segundos, lo cual corresponderá a una instancia. A partir de estos datos, el sistema debe clasificar la instancia para detectar cual estímulo estaba observando el usuario. La instancia se clasificará entonces como de una de las dos clases (clase 1 correspondiente al estímulo a f_1 y clase 2 correspondiente al estímulo a f_2).

Una vez detectada la opción deseada por el usuario, el sistema partirá el conjunto de letras seleccionado en 2 subconjuntos que se repartirán nuevamente entre los dos estímulos (ver figura 4.2). El usuario debe observar nuevamente el estímulo que contiene la letra deseada. Se repite el proceso hasta que la clase detectada contenga una única letra, la cual es tomada como la letra deseada por el usuario. Luego comienza nuevamente el proceso con todo el abecedario.

Capítulo 4. Deletreador SSVEP

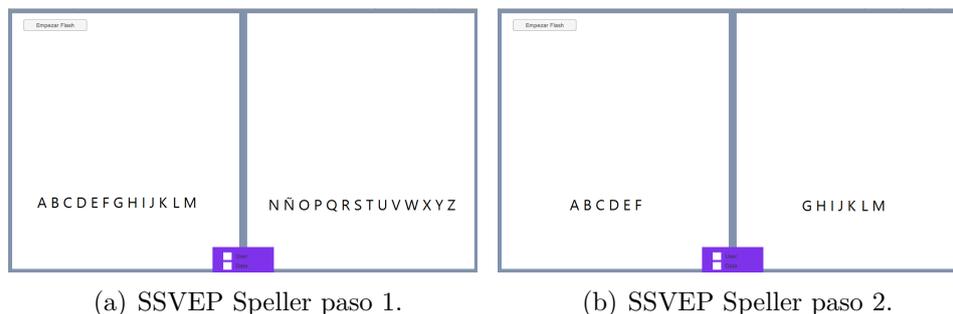


Figura 4.2: Pantalla que se le presenta al usuario del deletreador SSVEP. Se comienza con todo el abecedario dividido en 2 subconjuntos (imagen de la izquierda). Una vez detectada la opción elegida por el usuario se parte el conjunto en dos nuevos subconjuntos. El proceso se repite hasta que la opción corresponda a una única letra y luego se vuelve a comenzar. El usuario debe observar al rectángulo correspondiente a la letra deseada para elegirla. Los dos rectángulos se encontrarán parpadeando a distinta frecuencia.

4.3.2. Presentación de estímulos

La generación de estímulos es un paso clave dado que los mismos deben estar sincronizados para poder generar señales SSVEP. Como se verá en la sección 4.3.4, es importante que la frecuencia presente en la señal sea estable para que el detector funcione como se desea. Por lo tanto, los estímulos deben presentarse a la frecuencia deseada de forma estable para que en la señal de EEG se generen los SSVEP de igual manera.

Para generar los estímulos se decidió trabajar con el entorno de desarrollo Unity [76] debido a que ya se tenía experiencia con el mismo. Este entorno cuenta con un manejo sencillo de los elementos gráficos a presentar en pantalla (está diseñado para el desarrollo de videojuegos) y todos los scripts de lógica se pueden programar en lenguaje C#.

La PC utilizada fue una ASUS X555L [77] cuya pantalla tiene una frecuencia de refresco de 60Hz , lo cual es común en las laptops. El comando para cambiar los elementos de pantalla se realiza en un hilo disponible en Unity llamado *fixed update* que asegura que el código se correrá a la frecuencia deseada. Aún así, el refresco real de la pantalla se da en el hilo *update* el cual corre una vez por frame; por lo tanto es importante verificar que el programa corra lo suficientemente rápido para que el framerate esté por encima de la frecuencia deseada. Unity cuenta con una herramienta de análisis para esto. Además, debido a que la orden igual corre en el *fixed update*, en el caso de que se pierda algún frame, el cambio de estímulo no se corre sino que directamente no se realiza. Esto es importante para mantener la sincronización con la fase debido a que si la misma se va corriendo el detector no funciona adecuadamente (ver sección 4.3.4).

En la figura 4.3 se puede ver el layout utilizado para el caso en el que se

4.3. Prototipo de BCI en tiempo real

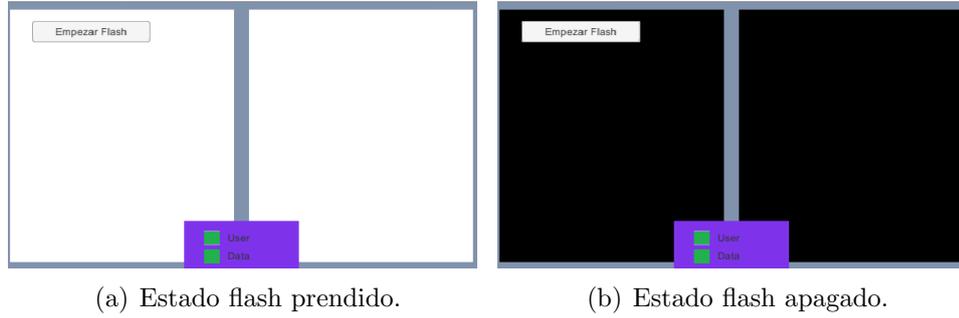


Figura 4.3: Layout de los estímulos presentados en pantalla en el caso de dos opciones que parpadean a dos frecuencias distintas. El parpadeo corresponde a un cambio en el color del rectángulo entre blanco y negro. El tamaño de los rectángulos se tomó lo más grande posible.

presentan dos opciones al usuario.

Un aspecto importante en el diseño de la presentación de estímulos es la selección de las frecuencias de repetición que se utilizarán. En primer lugar hay que tener en cuenta la frecuencia de refresco de pantalla para lograr una buena sincronización, asegurando que los períodos de repetición de los estímulos sean un múltiplo entero del período de refresco de pantalla. Es decir, para la pantalla con frecuencia de refresco de $60Hz$ como la que fue utilizada ($1/60s$ de período) sólo deberían utilizarse frecuencias:

$$f = 60Hz/n \text{ con } n = 1, 2, 3, \dots \text{ (correspondientes a períodos } T = n/60Hz\text{).}$$

$$f = \{30Hz, 20Hz, 15Hz, 12Hz, 10Hz, 8,57Hz, 7,5Hz, 6,67Hz, \dots\}$$

Para saber cuáles de estas frecuencias son mejores para utilizar, se realizó una estimación de la relación señal a ruido registrando datos de un usuario observando un estímulo parpadeando a estas frecuencias.

Para ello se tomaron 8 instancias de 15 segundos de observación del estímulo para cada frecuencia además de instancias de observación sin parpadeo (para estimación del ruido). Se saca la potencia de la componente de interés mediante el detector frecuencial Goertzel (ver sección 4.3.4) y se estima el SNR para cada frecuencia de la siguiente manera:

$$SNR(f) = \frac{\sum_i G_{[x,f]}^2(t_{final})}{\sum_i G_{[x_{ref},f]}^2(t_{final})}$$

donde:

$G_{[x,f]}^2(t)$: es la salida del detector frecuencial aplicado a la señal x para la frecuencia f en el instante t .

En el valor calculado como estimador del SNR influyen varios factores, en particular: la respuesta frecuencial del dispositivo de adquisición y la respuesta frecuencial del cerebro como sistema. Los resultados del relevamiento realizado se pueden ver en la figura 4.4.

Capítulo 4. Deletreador SSVEP

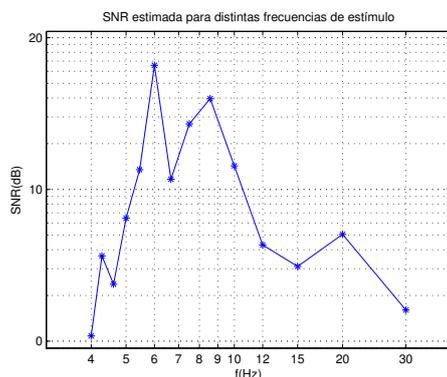


Figura 4.4: Estimación SNR para distintas frecuencias de estímulo.

Se puede ver que las frecuencias para las cuales se obtiene una mejor SNR se encuentran entre 5 y 12 Hz aproximadamente. Se eligió trabajar en un principio con las frecuencias $f_1 = 10\text{Hz}$ y $f_2 = 7,5\text{Hz}$ para los estímulos. La primera corresponde a 3 frames prendidos y 3 apagados y la segunda a 4 frames prendidos y 4 frames apagados. Estas frecuencias se encuentran dentro de la zona de mayor SNR, tienen ciclos de prendido y apagado de igual cantidad de frames y la distancia entre ellas es de $2,5\text{Hz}$ (más que satisfactoria para la resolución del detector, ver sección 4.3.4).

4.3.3. Adquisición de datos

Para levantar los datos capturados por el Emotiv desde Unity se trabajó con un wrapper disponible en la tienda de aplicaciones de Emotiv [78], el cual implementa los llamados necesarios a las librerías de Emotiv para obtener las señales sensadas. Para ello es necesario también contar con la SDK premium de Emotiv [79] debido a que se desea trabajar con las señales crudas (la SDK gratuita no permite acceso a las mismas).

El sistema funciona con un bucle que levanta los datos crudos de EEG de todos los canales almacenados en un buffer cada 100ms y se escriben en un archivo CSV. En primera instancia estos datos se almacenan en dicho archivo el cual se levanta luego en Matlab para realizar el análisis *offline*. Posteriormente, estos datos, además de guardarse, se van procesando por el clasificador a medida que se van obteniendo.

A continuación se realiza un análisis de los datos reales recopilados para un usuario mientras observaba estímulos parpadeando a dos frecuencias distintas.

Se toma ahora una instancia de cada clase para entender sus diferencias. En la figura 4.5 se puede ver el espectro de ambas clases donde queda en evidencia la presencia de las componentes correspondientes a la frecuencia del estímulo.

Para poder visualizar la forma de onda del SSVEP, se corta la señal en secciones de longitud 400ms y se realiza un promedio de éstas. Dado que se está trabajando con estímulos de 10Hz y $7,5\text{Hz}$ esto corresponde a 4 y 3 períodos de las señales

4.3. Prototipo de BCI en tiempo real

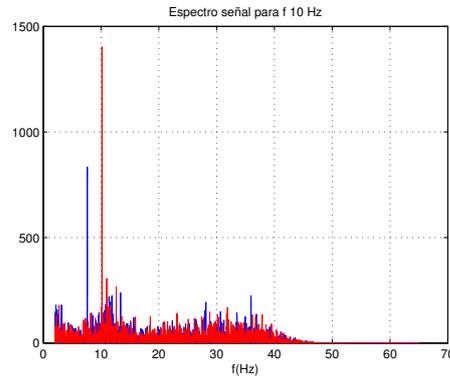


Figura 4.5: Espectro de una instancia de cada clase. Se puede ver en rojo la clase que llamamos SSVEP que corresponde a un estímulo de $10Hz$ y se observa una componente de gran amplitud en dicha frecuencia. En azul se muestra el espectro de una de las instancias etiquetadas como noSSVEP que corresponde en realidad a un estímulo de $7,5Hz$, por lo que se puede visualizar una componente de gran amplitud en dicha frecuencia.

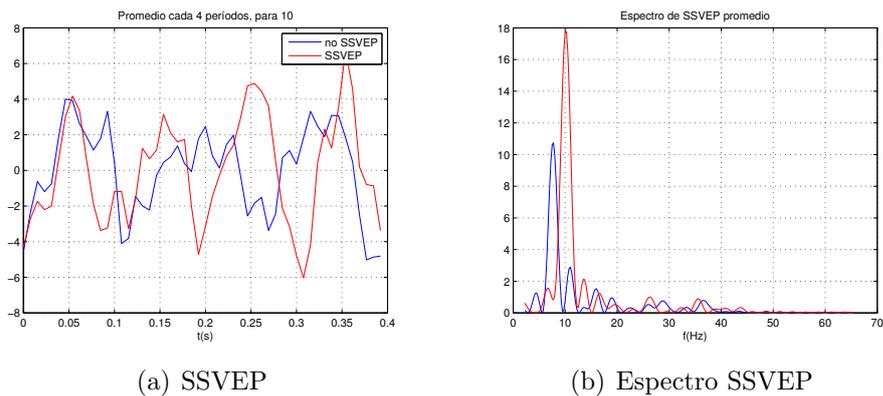


Figura 4.6: SSVEP Promedio. A la izquierda se muestra el promedio a lo largo de una instancia de secciones de largo $400ms$ para poder observar la forma del SSVEP. Se observan 4 periodos en la instancia de clase SSVEP dado el estímulo de $10Hz$ y 3 periodos en la instancia de clase noSSVEP dado que corresponde a un estímulo de $7,5Hz$. A la derecha se puede ver el espectro de estos promedios donde se visualiza nuevamente las componentes de $10Hz$ y $7,5Hz$ predominantes.

SSVEP. En la figura 4.6 se puede la señal promedio junto con su espectro.

4.3.4. Detector frecuencial

Un bloque fundamental del sistema es la detección de la presencia de la frecuencia del estímulo en la señal de EEG o detector frecuencial. Para esto se decidió trabajar con un algoritmo diseñado para detectar componentes frecuenciales de forma eficiente llamado algoritmo de Goertzel [80]. En este capítulo se analizará

Capítulo 4. Deletreador SSVEP

su implementación y el comportamiento al variar distintos parámetros de la señal de entrada.

El algoritmo de Goertzel es una técnica que permite el cálculo de términos individuales de la transformada discreta de Fourier de una señal (DFT) de forma eficiente. Para el cálculo de un número pequeño de términos de la transformada, Goertzel es más eficiente que los algoritmos más conocidos como Fast Fourier Transform (FFT), por lo que se utiliza mucho para reconocimiento de tonos particularmente en implementaciones embebidas con procesadores de baja complejidad funcionando en tiempo real.

El algoritmo es recursivo y se puede calcular la salida deseada para cada muestra a medida que se recibe.

Implementación

A continuación se muestra la implementación del algoritmo de Goertzel. La derivación del mismo se puede encontrar en [80].

Dados

- Frecuencia de muestro: F_s
- Señal de entrada discreta, muestreada a $F_s : x(n) \ n = 1, 2, \dots, N$
- Frecuencia del componente que se desea analizar: f_{det}

Inicialización

$$\begin{aligned} K &= 2 \cos\left(\frac{2\pi f_{det}}{F_s}\right) \\ Q_0 &= 0 \\ Q_1 &= 0 \end{aligned} \tag{4.1}$$

Bucle principal

$$\begin{aligned} &for \ n = 1 : N \\ &\quad Q_2 = Q_1 \\ &\quad Q_1 = Q_0 \\ &\quad Q_0 = KQ_1 - Q_2 + x(n); \\ &\quad Gs(n) = 2\sqrt{Q_1^2 + Q_2^2 - Q_1Q_2K} \\ &\quad end \end{aligned} \tag{4.2}$$

La salida Gs en tiempo n es equivalente a la componente de la frecuencia f_{det} de la transformada de la señal hasta ese tiempo. Es decir, la última muestra $Gs(N)$ de la salida para el bloque completo de N muestras, es equivalente al valor de la

4.3. Prototipo de BCI en tiempo real

DFT del *bin* en el que cae la frecuencia buscada f_{det} . Este *bin* tiene una resolución de F_s/N . Por ejemplo, en el caso de una instancia de observación de 5 segundos de la señal a una frecuencia de muestreo de $128Hz$ se tiene una resolución de $\Delta f = 0,2Hz$.

Para optimizar el costo computacional, si se desea tener el valor únicamente luego de procesar todas las muestras ($G_s(N)$), el último paso (cálculo de G_s) se puede realizar fuera del bucle.

Análisis del comportamiento

Se desea estudiar el comportamiento del detector para conocer las limitaciones a tener en cuenta para el diseño del sistema completo. Para ello es necesario conocer cómo varía la salida del detector al variar las distintas características de la señal de entrada, principalmente la frecuencia del componente a detectar, variaciones de esta frecuencia en el tiempo y la relación señal a ruido.

Para estudiar el comportamiento se trabajará en principio con señales sintéticas que repliquen las señales de EEG con las que se va a trabajar luego. Hay dos clases de señales posibles, las que presentan SSVEP (clase 1) y las que no (clase 0). Como primera aproximación se plantea el uso de una senoide de cierta frecuencia f con ruido blanco gaussiano aditivo de cierta potencia P_N para las señales de clase 1 (lo que correspondería a la señal SSVEP inmersa en el resto del EEG), y solo ruido blanco para las de clase 0 (ambas se crean con la misma potencia de ruido).

- Clase 1: $x_1(t) = \text{sen}(f.t) + N(t)$
- Clase 0: $x_0(t) = N(t)$

Se utiliza en todos los casos una frecuencia de la senoide de $10Hz$ y una frecuencia de muestreo de $128Hz$ (correspondiente a la frecuencia de muestreo F_s del Emotiv).

En la figura 4.7 se puede ver la salida del algoritmo en función del tiempo para una señal de cada clase, para cierto nivel de ruido. Se puede observar allí que a mayor tiempo de observación mayor confianza para indicar la presencia de la componente frecuencial buscada (las salidas del algoritmo para cada clase se separan cada vez más).

Se utiliza el valor de salida del Goertzel (considerando cierto largo temporal de la señal) para clasificar cada instancia. Se compara este valor con un umbral calculado con un conjunto de instancias de entrenamiento, con un promedio entre los valores de una clase y de otra. De esta manera se cuenta con un indicador de performance para variar los parámetros de las señales de entrada.

Llamémosle $g_x(t)$ a la salida de Goertzel aplicada a la señal x en el tiempo t . C_1 a la clase 1 y C_0 a la clase 0. El valor del umbral U se calcula entonces:

$$U = \frac{\sum_{x \in C_1} g_x(T) + \sum_{x \in C_2} g_x(T)}{2} \quad (4.3)$$

La clasificación de una instancia $x(t)$ cualquiera será entonces:

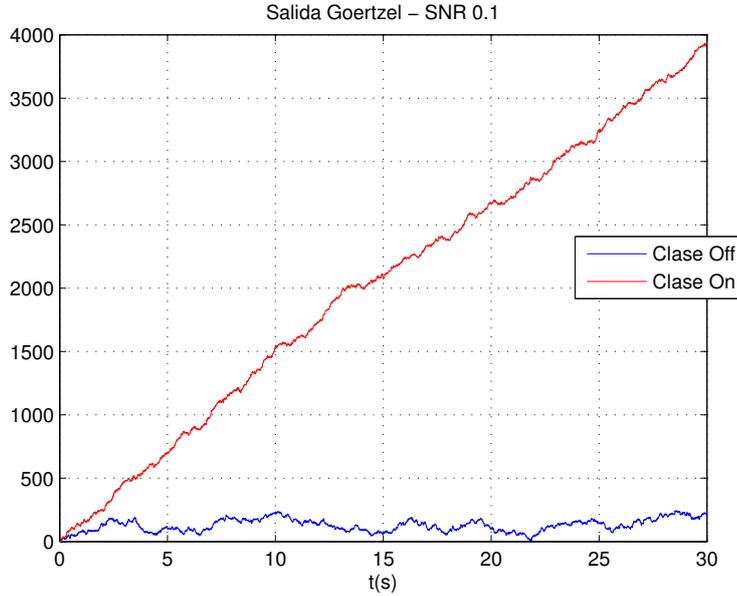


Figura 4.7: Salida de Goertzel para ambas clases

$$\begin{cases} g_x(T) > U & \rightarrow x \in C1 \\ g_x(T) < U & \rightarrow x \in C0 \end{cases} \quad (4.4)$$

En la figura 4.8 se puede ver este proceso para el caso de una relación señal a ruido de $-20db$.

El comportamiento del algoritmo indica que el mismo puede ser muy bueno como detector de frecuencia. Veremos ahora qué sucede al variar algunos de los parámetros involucrados.

Comportamiento frente a variaciones de la frecuencia de la señal

Se desea ahora observar el comportamiento del detector al variar la frecuencia a detectar. Para ello, primero se introducen señales sinusoidales cuya frecuencia difiere(mínimamente) de la frecuencia buscada por el detector. Es decir, se varía la frecuencia de las señales de entrada pero no el parámetro del detector. Los resultados de este experimento para uno de los niveles de ruido analizados se pueden ver en la figura 4.9.

Otro experimento planteado para analizar la respuesta en frecuencia del detector, consistió en introducir ruido directamente en la frecuencia de la sinusoide de entrada. Los resultados se pueden ver en la figura 4.10 con los cuales se concluye lo mismo que en el caso anterior: la performance se degrada completamente si la frecuencia de la señal y el parámetro del detector difieren en más de $0,1Hz$.

La caída en performance al variar la frecuencia de la señal respecto a la del detector es tan abrupta que básicamente determina si el mismo funciona o no. Por lo tanto, la frecuencia de la señal de EEG debe tener gran precisión, para lo cual es necesario entonces presentar los estímulos con la misma precisión.

4.3. Prototipo de BCI en tiempo real

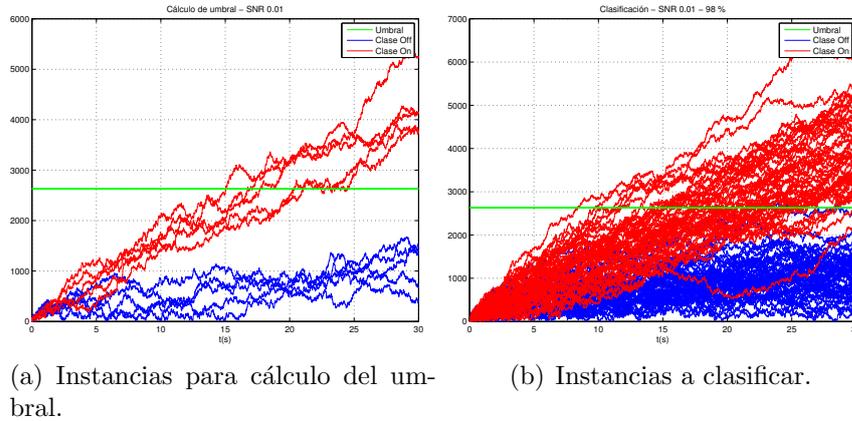


Figura 4.8: Salida del Goertzel para señales con $SNR = 0.01$ (-20dB). A a izquierda se muestran las instancias utilizadas para el cálculo de umbral, y a la derecha las instancias clasificadas con dicho umbral. A estos niveles de ruido se visualiza que es necesario tomar períodos más largos de la señal para poder clasificarla correctamente. A los 5s ambas clases están completamente mezcladas, pero a los 30s se diferencian claramente.

Comportamiento frente a variaciones de la SNR de la señal

Como se vió en los experimentos anteriores, para una SNR dado, a mayor tiempo de observación de la señal, mayor performance del detector. Se desea ahora relevar este comportamiento al variar la SNR. Los resultados se pueden ver en la figura 4.11.

Al variar la relación señal a ruido de la señal de entrada se observa el comportamiento esperado: a mayor amplitud del ruido, más tiempo de señal se precisa observar para obtener una misma performance.

Parametrización de la curva SNR vs t

A partir del análisis descrito en la figura 4.11 se puede ver que la curva tiene forma de una sigmoide de la suma de los dos parámetros, por lo que se puede parametrizar de la siguiente manera:

$$\text{Perf}(t_{\text{senal}}, \text{SNR}) = 50 + 50 \cdot \text{Sigmoide}(a \cdot (\log(\text{SNR}) + \log(t_{\text{senal}})) + b) \quad (4.5)$$

Se hayan los parámetros a y b para ajustar la curva a los datos reales y se obtiene:

$$a = 4,0$$

$$b = 4,8$$

Por lo tanto la parametrización queda de la siguiente manera:

Capítulo 4. Deletreador SSVEP

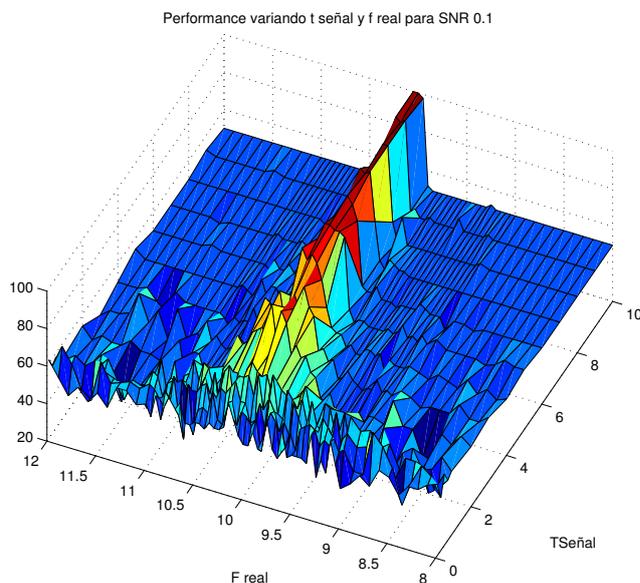


Figura 4.9: Análisis de la performance del detector al variar la frecuencia de la señal de entrada, pero no el parámetro de búsqueda del detector. El detector sigue “buscando” la componente de 10Hz, pero la señal se desvía. Se observa que a pequeños desvíos (menores a 0.2Hz) la performance se degrada notoriamente, incluso para niveles de ruido bajos y tiempos de observación de la señal altos.

$$Perf(t_{señal}, SNR) = 50 + 50 \cdot \text{Sigmoide}(4 \cdot (\log(SNR) + \log(t_{señal}) + 1, 2)) \quad (4.6)$$

En la figura 4.12 se puede ver la curva de esta función y las dos curvas superpuestas.

Conclusiones sobre detector

El algoritmo de Goertzel permite encontrar la presencia de cierta frecuencia en una señal. Cuanto más tiempo se observa la señal, con más confianza se puede decir si dicha componente se encuentra en la señal o no. Es importante que la frecuencia buscada y la frecuencia de la componente en la señal no difieran en gran medida dado que el algoritmo es sensible a estas variaciones. Hay un compromiso entre el tiempo de observación de la señal de entrada y la precisión de la detección, dependiendo esta relación del nivel de ruido de la señal. Si se desea cierto valor de precisión, se deberá observar más tiempo la señal para niveles de ruido más altos.

Detector frecuencial con datos reales

Veremos ahora el comportamiento del detector frecuencial cuando se utilizan los datos reales relevados. La salida del mismo a lo largo del tiempo frente a

4.3. Prototipo de BCI en tiempo real

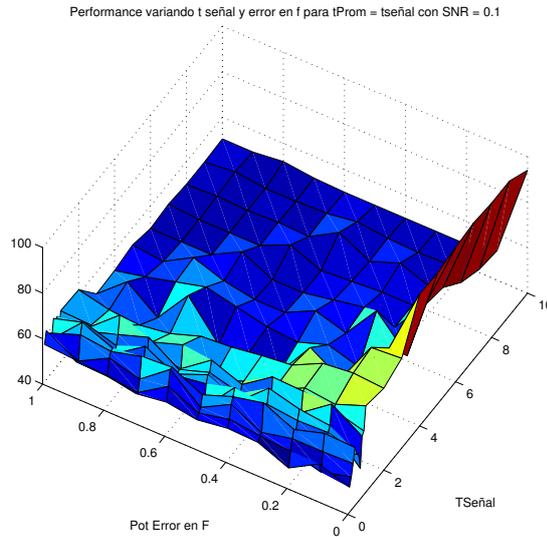
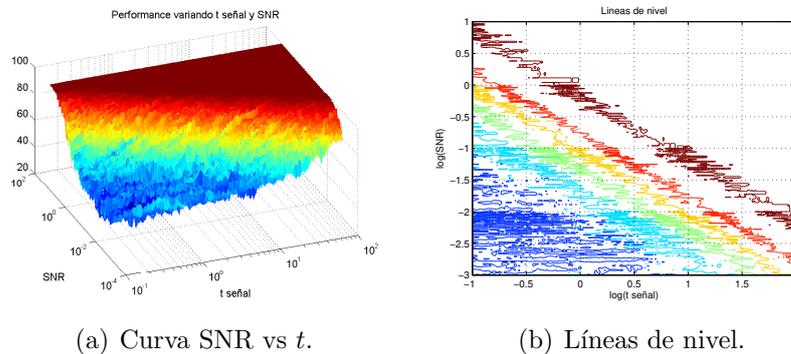


Figura 4.10: Comportamiento del detector al variar potencia del ruido en frecuencia de la señal. Se observa el mismo fenómeno que en las gráficas 4.9: la performance cae drásticamente con potencias de ruido muy bajas (menores a 0.1Hz).



(a) Curva SNR vs t .

(b) Líneas de nivel.

Figura 4.11: Comportamiento del detector al variar SNR y tiempo de señal. Ambos ejes se encuentran en escala logarítmica. Se puede ver que al fijar el valor de SNR, la performance tiene el comportamiento de una función sigmoide frente al logaritmo de $t_{señal}$, donde la variación del valor de SNR provoca un corrimiento en las abscisas. Este mismo comportamiento se observa fijando un valor de $t_{señal}$ y variando SNR. Las curvas de nivel parecen ser rectas paralelas.

distintas instancias de las dos clases (una con la componente frecuencial que se desea detectar y la otra sin) se puede ver en la figura 4.13.

Se puede ver que hay una gran variabilidad en cuanto al valor de la salida del detector para las clases positivas (SSVEP), lo cual hace que incluso alguna de dichas instancias sean indistinguibles de las instancias de la otra clase (noSSVEP).

Capítulo 4. Deletreador SSVEP

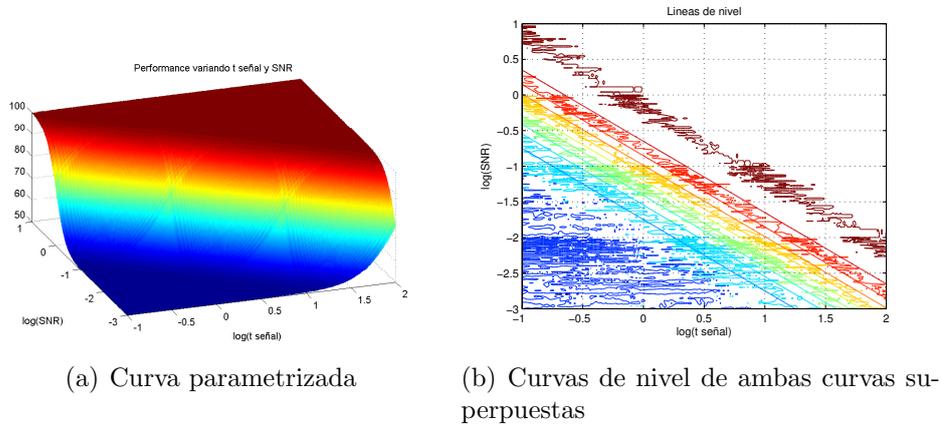


Figura 4.12: Respuesta de la función 4.6, parametrización de la curva 4.11. En la figura de la derecha se observan las curvas de nivel de las dos curvas superpuestas donde se puede apreciar la gran aproximación de la parametrización a la respuesta real.

Para analizar por qué sucede esto se toman tres instancias de la clase SSVEP (todas deberían presentar una componente en $10Hz$ marcada que debería detectar Goertzel) con diferentes valores de salida de Goertzel (ver figura 4.14). Se muestra

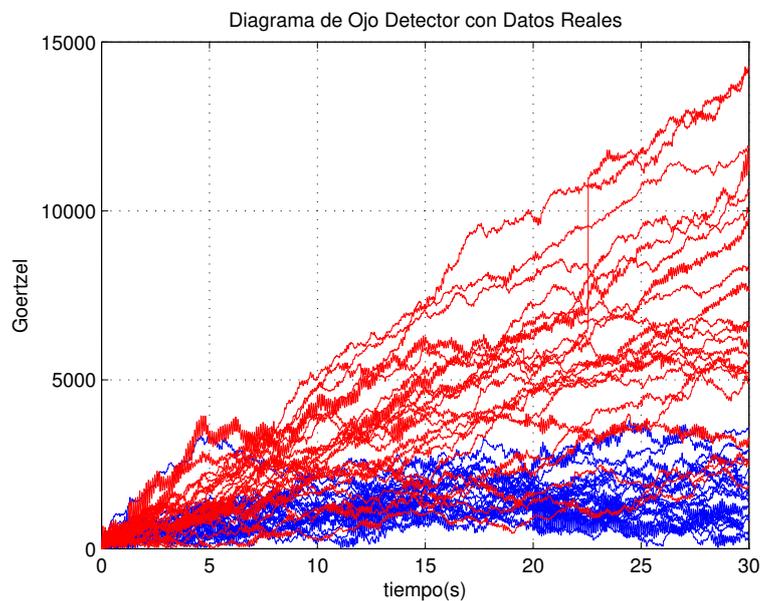


Figura 4.13: Respuesta del detector frente a datos reales. Se observa que las clases se diferencian más al aumentar el tiempo de observación de la señal como era esperado. Aún así, el detector no es capaz de separar ambas clases por completo, quedando algunas instancias de la clase SSVEP en zonas de la clase a la que no pertenece.

4.3. Prototipo de BCI en tiempo real

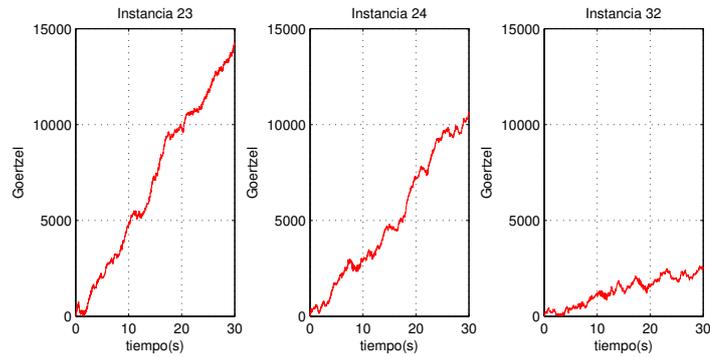


Figura 4.14: Salida del detector frecuencial para instancias pares dentro de la clase SSVEP. El detector indica que la potencia de la componente de frecuencia buscada es mayor en la instancia de la izquierda y menos en la de la derecha, lo cual hará que la de la derecha sea más difícil de clasificar.

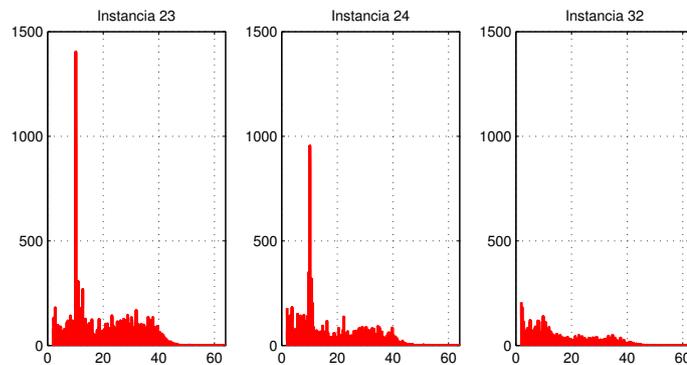


Figura 4.15: Espectro de señales de la figura 4.14 que provocan salidas dispares en el detector. Se puede ver que efectivamente la componente de frecuencia buscada presenta distintos niveles de potencia acorde a lo indicado por el detector.

luego el espectro de dichas instancias en la figura 4.15.

Se observa que el ruido no es el único causante de esto, sino que efectivamente en algunas instancias la señal no presenta una componente frecuencial marcada a $10Hz$ (no se logra un SSVEP de gran magnitud). Estas diferencias entre instancias de la misma clase se debe estar generando en las etapas previas a la detección (usuario, presentación de estímulos o dispositivo de adquisición).

4.3.5. Clasificador

Sobre el detector frecuencial, se arma ahora un clasificador que indique a qué clase pertenece una instancia en base a la salida del anterior.

Cada instancia consiste en 30 segundos de los 14 canales de EEG tomados con el Emotiv Epoc de un único sujeto observando una pantalla parpadeando a $10Hz$ o a $7,5Hz$. Para el siguiente análisis se toma únicamente el promedio entre los canales O1 y O2 correspondientes a la corteza visual (zona occipital). Se tiene un

Capítulo 4. Deletreador SSVEP

total de 88 instancias balanceadas.

Se cuenta con dos detectores frecuenciales, cada uno “buscando” la frecuencia de uno de los estímulos visuales. Para realizar la detección, se aplica estos detectores sobre cada instancia y se observa la diferencia entre las salidas de cada uno:

$$Y_{diff} = Y_{det10Hz} - Y_{det7,5Hz}$$

Si la diferencia es positiva clasificamos la instancia como de $10Hz$ (llamémosle clase 1) y si es negativa como de $7,5Hz$ (llamémosle clase 0). De esta forma, no importa el valor de cada detector sino la diferencia entre ellos, por lo tanto tampoco precisamos del cálculo de un umbral (el umbral natural es 0).

En la figura 4.16 se puede ver la salida de este clasificador para todas las instancias de ambas clases al variar el tiempo de observación.

Se observa una buena respuesta del clasificador, alcanzando un 80 % de performance a los 5s y 90 % a los 10s.

4.3.6. Controlador de deletreo

Una vez que se tiene la instancia clasificada, se utiliza este dato para actualizar las opciones de letras a presentar al usuario. Como se explicó anteriormente, al usuario en el inicio se le presenta el abecedario dividido en dos grupos. El usuario

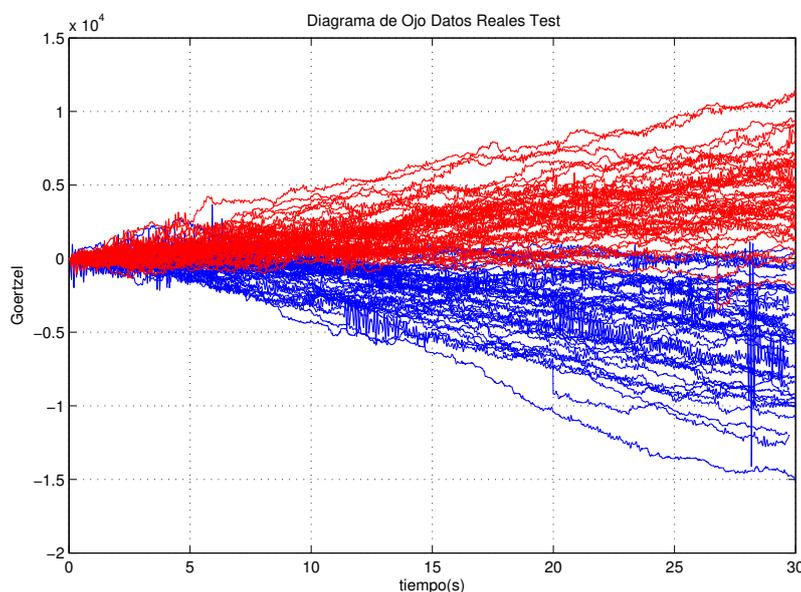


Figura 4.16: Respuesta del detector “diferencia” frente a datos reales. Se observa que las clases pertenecientes a $10Hz$ quedan por encima del 0, indicando que el valor de salida del detector de $10Hz$ es mayor que el indicado por el detector de $7,5Hz$. Lo análogo pasa para las clases de la otra frecuencia. Se puede observar que las clases quedan más separables que usando un único detector (menos instancias mezcladas).

4.3. Prototipo de BCI en tiempo real

debe observar el estímulo que corresponde al grupo de letras que contiene la letra deseada. Luego que el sistema detecta el conjunto que desea elegir el usuario, el controlador deberá tomar dicho conjunto y dividirlo en dos nuevos subconjuntos, para repetir luego el proceso anterior. Esto continúa hasta que el conjunto elegido consiste en una única letra y por lo tanto es tomada como *deletreada* y se comienza nuevamente con todo el abecedario para deletrear la siguiente letra.

Para maximizar la tasa de transferencia de información, los conjuntos entre los que se separan las opciones a presentar al usuario deberían de ser equiprobables (ver sección 4.4). Para limitar el alcance, se optó por utilizar únicamente la frecuencia de aparición de cada letra en el español para el cálculo de esta probabilidad (sin tener en cuenta las letras anteriores por ejemplo) [81] [82]. Complejizar este aspecto teniendo en cuenta la información de lo que se viene escribiendo, mejoraría la tasa de transferencia de información del sistema dado que la estimación de la probabilidad de elección de la siguiente letra sería más precisa. Además, para una buena usabilidad de la aplicación, es necesario presentar las letras en orden alfabético para facilitar la búsqueda al usuario (las búsqueda de si la letra deseada pertenece a un conjunto o no por más sencilla que sea se torna notoriamente molesta). Por lo tanto, para separar un conjunto de letras en dos subconjuntos se

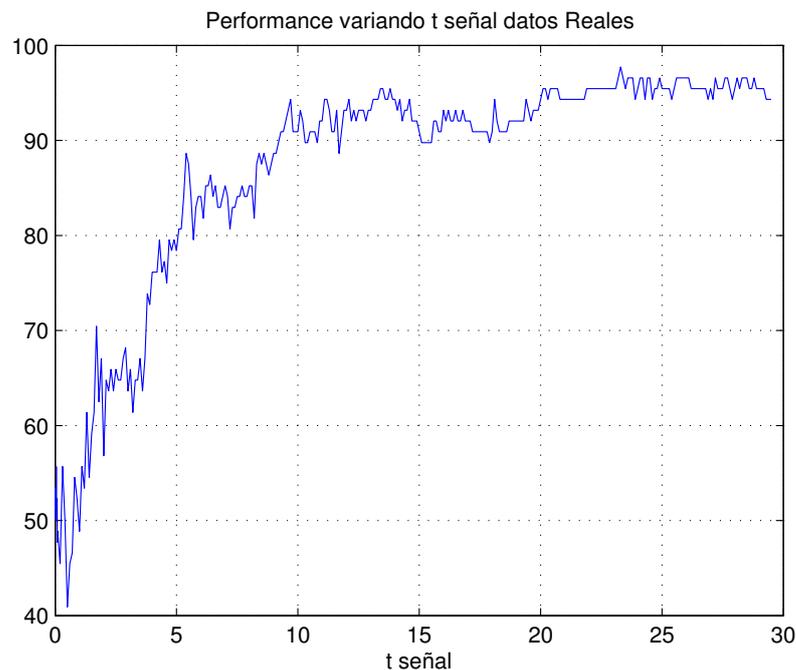


Figura 4.17: Performance para detector “diferencia” frente a datos reales, variando el tiempo de observación de la señal. Se observa una mejora en la performance frente a los detectores individuales, alcanzando un 80% de performance a los 5s y 90% a los 10s. Además, más instancias son posibles de clasificar dado que se alcanza un máximo de aproximadamente 95% a los 30s, mientras que los detectores individuales alcanzaban un máximo de 80% y 85% de detección correcta.

Capítulo 4. Deletreador SSVEP

va acumulando la probabilidad de cada letra en orden hasta llegar a la mitad del valor de la suma de la probabilidad de todas las letras del conjunto, momento en el cual se marca la separación. Se agrega la lógica además de asegurar que cada subconjunto cuente siempre con un mínimo de una letra.

Pseudocódigo para separar conjunto de letras

$$L : \text{conjunto de letras a separar} \quad (4.7)$$

$$L^I : \text{subconjunto de letras izquierdo} \quad (4.8)$$

$$L^D : \text{subconjunto de letras derecho} \quad (4.9)$$

$$p_{\text{acum}} = 0; j = 0; \quad (4.10)$$

$$p_{\text{limite}} = \left(\frac{\sum_{l_i \in L} p(l_i)}{2} \right) \quad (4.11)$$

$$\text{while } (p_{\text{acum}} \leq p_{\text{limite}} \text{ and } j \leq N - 1) \quad (4.12)$$

$$l_j \rightarrow L^I \quad (4.13)$$

$$j+ = 1 \quad (4.14)$$

$$\text{end} \quad (4.15)$$

$$l_{j:N} \rightarrow L^D \quad (4.16)$$

En la figura 4.18 se puede ver como ejemplo los pasos del sistema para deletrear la letra H, asumiendo una detección correcta de conjunto que se desea seleccionar en cada paso.

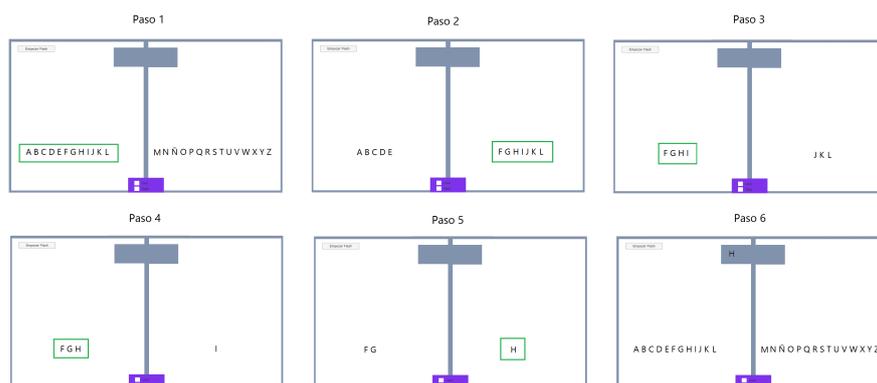


Figura 4.18: Pasos para deletrear la letra H. Se comienza con todo el abecedario dividido en dos conjuntos y luego se va dividiendo el conjunto seleccionado en dos subconjuntos hasta tener una única letra en el conjunto seleccionado. Una vez deletreada una letras, se vuelve a comenzar con todo el abecedario. En cada paso, los conjuntos se arman buscando que sean equiprobables según la probabilidad de aparición de cada letra en el español.

4.4. Capacidad del canal

Se desea maximizar el flujo de información que permite transmitir el sistema. Para ello abordamos el problema con herramientas de la Teoría de la Información y calculamos la capacidad de canal por unidad de tiempo. Maximizando esta función maximizamos el flujo de información [57].

El sistema analizado se puede considerar un canal binario simétrico dado que posee una entrada binaria y una salida también binaria con probabilidad de error p . Si se transmite la variable aleatoria X y recibimos la variable aleatoria Y , entonces:

$$\begin{aligned} P(Y = 0|X = 0) &= 1 - p \\ P(Y = 0|X = 1) &= p \\ P(Y = 1|X = 0) &= p \\ P(Y = 1|X = 1) &= 1 - p \end{aligned} \tag{4.17}$$

La probabilidad de error la sacamos directamente de la performance:

$$p = 1 - \frac{Perf}{100} \tag{4.18}$$

La capacidad C de este tipo de canal se puede calcular de la misma forma que se realizó en la sección 3.3 para el caso $N = 2$:

$$C = 1 - H(p) \tag{4.19}$$

Para calcular la capacidad por unidad de tiempo nuevamente dividimos por el tiempo que lleva recibir un dato (que corresponde al tiempo de observación de la señal previo a dar una respuesta).

$$C_t = \frac{C}{t} \tag{4.20}$$

Además, la capacidad de canal en este caso se alcanza cuando la distribución de entrada es uniforme y por ello se distribuyen las letras para que así sea como se vió en la sección anterior.

En la figura 4.19 se puede observar los resultados con los datos reales.

La máxima tasa de transferencia de información alcanzada según los datos registrados para este usuario es de $0,09bits/s$ ($5,4bits/min$). Este resultado se compara con los obtenidos en los otros trabajos aquí referidos en la tabla 4.1.

Se destaca en primera instancia el que el hecho de utilizar el análisis de capacidad de canal como criterio de diseño es algo novedoso para sistemas de este tipo. En este caso, se logra determinar el tiempo óptimo de observación para maximizar la transferencia de información del sistema.

A pesar de que la tasa de transferencia de información aquí alcanzada se encuentra por debajo de las reportadas en dichos trabajos, creemos que es un muy buen resultado dado que se trata de un primer prototipo que trabaja con un dispositivo que no es de grado médico, utiliza únicamente dos frecuencias de estímulo

Capítulo 4. Deletreador SSVEP

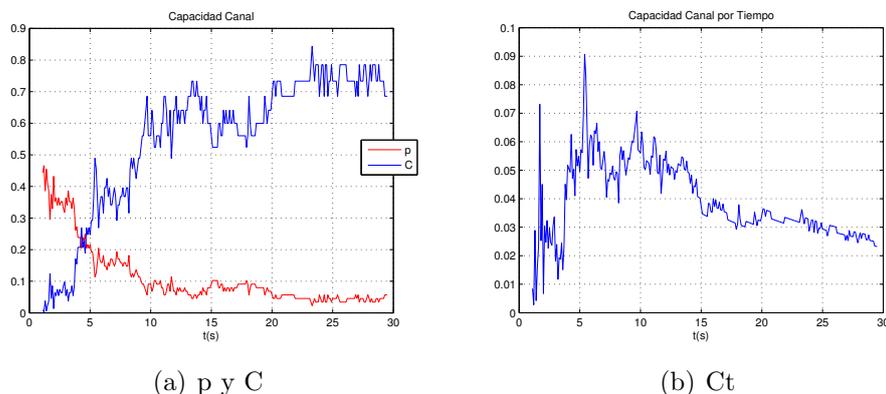


Figura 4.19: Capacidad del canal. A la izquierda se muestra el cálculo de la probabilidad de error p y capacidad de canal C para cada valor de tiempo de observación de la señal t . Se puede ver que el error disminuye al aumentar t mientras que la capacidad aumenta, como era esperado. A la derecha se muestra el cálculo de C_t . Se observa que ésta presenta un máximo entre 5 y 10 segundos.

Trabajo	$C_t(\text{bits}/\text{min})$
(1) Rakotomamonjy et al. [60]	14,06
(2) Hwang et al. [74]	40,1
(3) Parini et al. [75]	51,6
(4) Prototipo actual	5,4

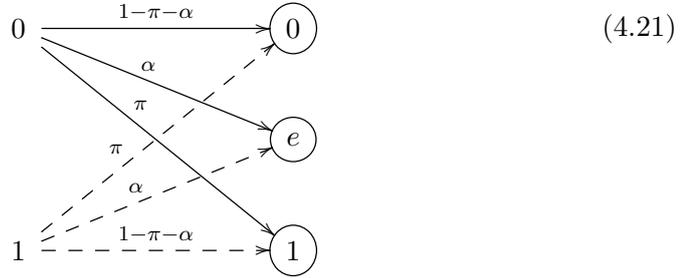
Tabla 4.1: Tasa de transferencia de información comparada entre distintos trabajos. (1) Rakotomamonjy et al. para P300 Speller [60] (2) Hwang et al. para SSVEP Speller [74] (3) Parini et al. [75] para SSVEP Speller (4) Prototipo creado en este trabajo.

y permite otras tantas mejoras como se discuten en detalle en la sección 4.6. Los tres trabajos de referencia utilizan un dispositivo de grado médico para la toma de datos, lo cual implica una SNR mayor en los datos de entrada. Por otro lado, Rakotomamonjy et al. trabajan de forma offline, Hwang et al. utilizan 30 estímulos distintos y Parini et al. proponen un procesamiento que precisa calibrarse para cada usuario (filtro espacial CSP con un clasificador RLDA). Estos son aspectos que sirven de guía para mejorar el desempeño del actual prototipo en futuras investigaciones, quedando fuera del alcance de este trabajo.

Canal binario con borradura

Se analiza ahora la posibilidad de agregar la lógica de borradura, es decir, tomar un valor umbral que debe superar la salida del detector para clasificar la instancia en una de las dos clases, de lo contrario se clasifica la instancia como *error*. El diagrama del canal simétrico con borradura es el siguiente.

4.4. Capacidad del canal



Donde, como se muestra en el diagrama, tenemos para el alfabeto de entrada X y el alfabeto de salida Y :

$$\begin{aligned} P(Y = 0|X = 0) &= P(Y = 1|X = 1) = 1 - \pi - \alpha \\ P(Y = e|X = 0) &= P(Y = e|X = 1) = \alpha \\ P(Y = 1|X = 0) &= P(Y = 0|X = 1) = \pi \end{aligned}$$

La capacidad de canal para este caso queda de la forma:

$$C = 1 + (1 - \pi - \alpha) \log_2 \left(\frac{1 - \pi - \alpha}{1 - \alpha} \right) + \pi \log_2 \left(\frac{\pi}{1 - \alpha} \right) - \alpha$$

La cual se obtiene para una distribución de probabilidad uniforme para el alfabeto de entrada. Se puede verificar que para el caso de $\alpha = 0$ obtenemos el resultado del canal binario simétrico sin borradura.

La probabilidad de borradura es dependiente del umbral establecido para considerar un símbolo como perdido. Se busca maximizar el valor de la capacidad variando este parámetro para los distintos tiempos de observación de la señal de entrada.

Para cada valor de umbral se calculan las probabilidades empíricas de la siguiente manera:

$$\begin{aligned} \alpha &= \frac{\#(Y = e)}{\#Y} \\ \pi &= \frac{\#(Y = 0|X = 1) + \#(Y = 1|X = 0)}{\#Y} \end{aligned}$$

En la figura 4.20 se puede observar los valores de capacidad obtenidos para distintos valores del umbral al variar el tiempo de observación de la señal. Para el valor del umbral = 0 obtenemos el caso analizado anteriormente.

Se toma el valor máximo de capacidad alcanzado variando el umbral de borrado, para cada valor de tiempo de observación de la señal. El resultado se puede ver en la figura 4.21, donde se compara con la capacidad del canal sin borradura.

Capítulo 4. Deletreador SSVEP

Se observa una mejora en general de la tasa de transferencia de información para todos los tiempos de observación, a pesar de que para 5 segundos, donde se da el máximo, ambos valores prácticamente no difieren.

4.5. Prueba de campo informal

Se probó el dispositivo en la muestra de fin de año Ingeniería de Muestra 2016 con el público general. Las condiciones del experimento presentan gran variabilidad impidiendo cierto grado de sistematización en un ambiente de esas características: mucho ruido ambiente, varias personas observando a cada usuario (lo cual genera desconcentración en el mismo), luces muy fuertes que provocan que el cambio brusco en el estímulo visual no sea tan notorio, variabilidad en la colocación del dispositivo incluyendo el nivel de líquido conductor en cada electrodo, etc.

A pesar de que estas condiciones de prueba impiden un análisis sistemático de los factores determinantes en los diferentes problemas que pueden aparecer, se asemejan en mayor medida a las condiciones de uso que se pretende tenga un producto de esta línea de investigación una vez que salga del laboratorio. Por lo tanto, es interesante la prueba y el análisis de la misma para tener una noción de cuán lejos se está de tener un dispositivo atractivo para el público general.

Para disminuir la frustración durante el uso por parte del usuario en caso de una clasificación errónea, se agregó una opción de borrado que permite deshacer el último paso.

La colocación del casco presenta ciertas dificultades según el usuario dado que no debe quedar mucho cabello entre el electrodo y el cuero cabelludo para un buen sensado de las señales. También se debe asegurar que los electrodos queden presionando contra la cabeza asegurando un buen contacto y bien húmedos con una solución salina durante todo la sesión de uso.

La dinámica de uso fue la siguiente. El interesado se sienta en una silla frente al monitor del PC donde corría el software. Se le colocaba el casco sensor con

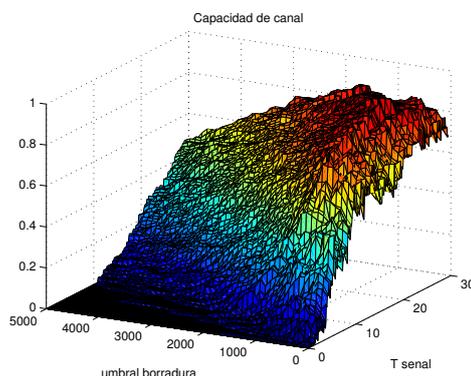


Figura 4.20: Capacidad del canal con borradura para distintos valores de observación de la señal y de umbral de borrado. Se observa que los valores más grandes de capacidad se encuentran para valores de umbral cercanos a 0, pero el máximo no se da exactamente en este punto.

4.5. Prueba de campo informal

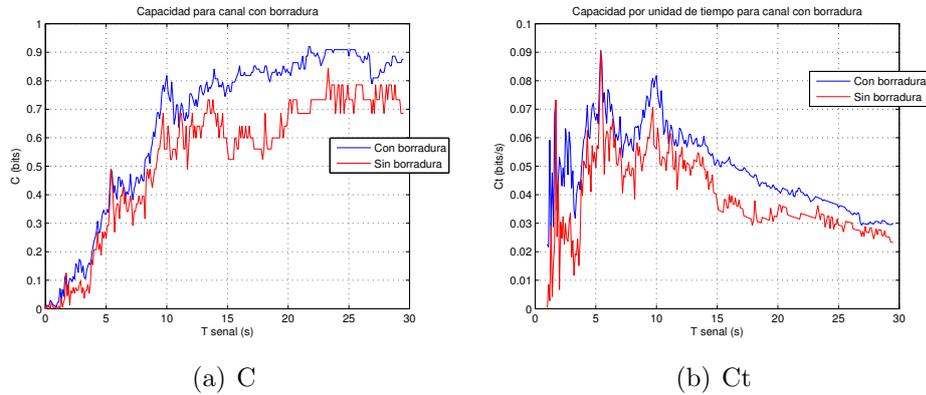


Figura 4.21: Capacidad del canal con borradura y sin borradura. A la izquierda se muestra la capacidad de canal C y a la derecha la capacidad de canal por unidad de tiempo C_t . Se observa que se alcanza valores mayores de capacidad para el caso con borradura, por ejemplo alrededor de tiempos de observación de la señal de $10s$ se aumenta en aproximadamente $0,01 \text{ bit/s}$ el valor de C_t (15% aproximadamente). Sin embargo, el valor máximo alcanzado para C_t es el mismo para ambos casos ($0,09 \text{ bit/s}$ a los $5,4s$).

los electrodos húmedos y se verificaba mediante el software brindado por Emotiv que los electrodos se encontraran sensando correctamente (el software indica con colores la calidad del contacto de cada electrodo). Una vez que se lograba colocar el casco correctamente se realizaba una prueba de la detección donde se le indicaba al usuario que observe uno de tres rectángulos flasheando. El sistema calculaba un detector frecuencial por cada frecuencia utilizada en los estímulos y clasificaba la instancia según el detector que arrojará un valor mayor. Si se constataba que el sistema estaba funcionando correctamente para las tres frecuencias se procedía a utilizar el deletreador indicándole al usuario que elija una letra (en general la

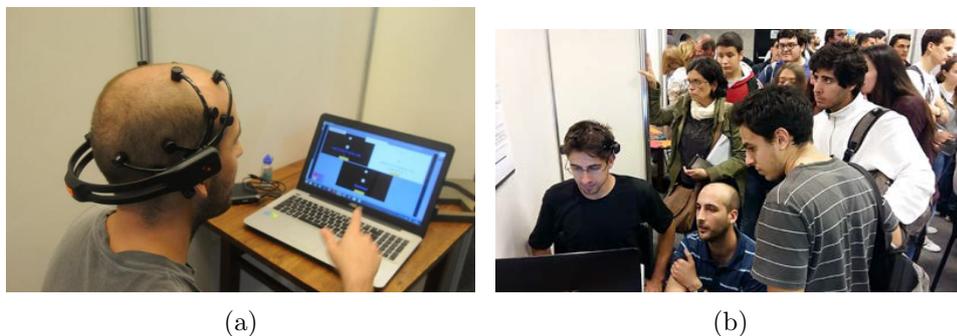


Figura 4.22: Imágenes durante el evento en el cual se probó el prototipo con el público general.

Capítulo 4. Deletreador SSVEP

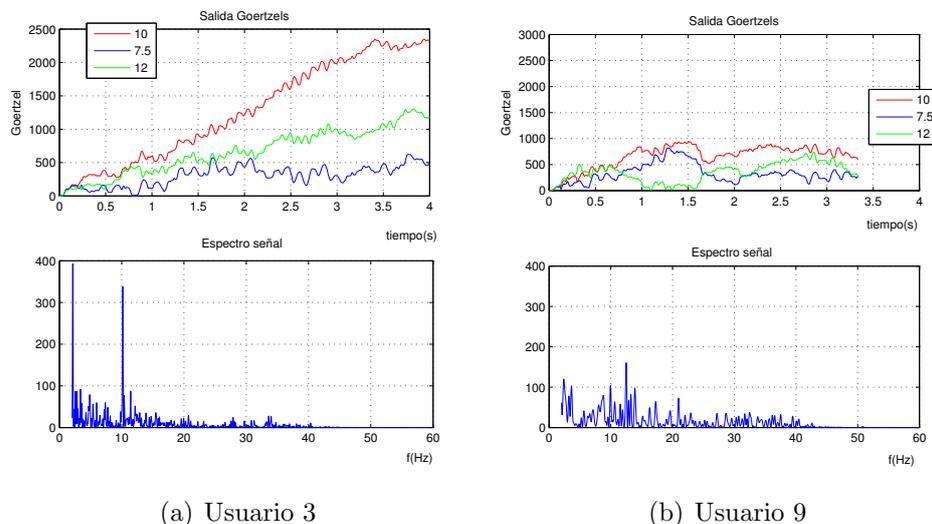


Figura 4.23: Señales registradas para dos usuarios distintos que ejemplifican la diferencia interusuario. Para el usuario de la izquierda se puede ver que las señales muestran una gran componente de 10 Hz en el espectro, lo cual permitió deletrear una letra sin que el sistema cometiera ningún error. Por otro lado, el espectro de las señales registradas para el usuario de la derecha no muestran ninguna preferencia clara por alguna de las frecuencias de los estímulos. Esto impidió que el usuario utilice el sistema.

primer letra de su nombre) e intentara deletrearla.

De los 20 usuarios a los que se le logró colocar el sensor sin que el propio software de Emotiv de error, sólo la mitad logró deletrear al menos una letra. Esto era esperable dado que la variabilidad interusuario es uno de los temas más recurrentes en las interfaces cerebro computadora.

Esta gran variabilidad interusuario se observaba además en el hecho de que para algunos usuarios el sistema no se equivocaba nunca mientras que otros debían realizar varias pruebas o utilizar mucho la opción de deshacer para lograr llegar a la letra deseada. Esto se daba incluso para usuarios que volvían a utilizar el dispositivo en distintas ocasiones (lo cual indicaría que la diferencia está más asociada al usuario en sí que a las condiciones de cada sesión como puede ser la humedad de los electrodos).

Observando el espectro de las señales, en particular para los usuarios con los cuales el sistema no funcionaba correctamente, se veía claramente una diferencia en la potencia de la componente frecuencial buscada. En algunos usuarios directamente no era distinguible dicha componente del ruido (ver figura 4.23).

Una peculiaridad es que con los niños el dispositivo parecía funcionar especialmente bien. Consultado un médico al respecto comentó que era razonable dado que los mismos tienen un cráneo más delgado y menos cantidad de líquido cefalorraquídeo.

Otra sorpresa encontrada fue un usuario calvo para el cual el casco quedo

4.6. Conclusiones y trabajo a futuro

fácilmente colocado y de forma correcta, pero en el espectro de las señales no se lograba visualizar una componente de frecuencia destacada.

En líneas generales fue una experiencia muy satisfactoria dado que no se había probado el dispositivo con tal variedad de usuarios y muchos pudieron utilizarlo correctamente quedando conformes con el mismo.

Quedó en evidencia la necesidad de investigar la variabilidad interusuario para entender los factores que participan en la misma y poder llevar el prototipo más cerca de un producto utilizable.

4.6. Conclusiones y trabajo a futuro

Como primera conclusión de esta sección del trabajo se destaca que se obtuvo un prototipo funcional de interfaz cerebro computadora lo cual era uno de los objetivos principales planteados inicialmente.

Con este prototipo básico se logró una tasa de transferencia de información de $5,4\text{bits}/\text{min}$, valor que, a pesar de encontrarse por debajo de los reportados como estado del arte en otros trabajos, [74] [75], es muy satisfactorio para esta instancia dado que el prototipo cuenta con capacidad para mejorar en casi todos los distintos bloques que conforman este BCI:

- **Sensor EEG.** En primer lugar se propone como trabajo a futuro probar el sistema implementado con un sensor de grado médico. Esto no solo provocaría una mejora por tener electrodos de mayor calidad, sino que también permite mejor y más sistemática colocación de los mismos. Todo esto implica obtener señales con mayor relación señal a ruido, característica con la cual tiene mayor dependencia cualquier clasificador. Se destaca como experiencia adquirida la importancia de la colocación de los electrodos para un buen sensado. Es necesario que los mismos se encuentren húmedos con el líquido adecuado durante todo el proceso. En la práctica además se deben verificar las señales y ajustar la colocación del casco sensor hasta que las mismas se vean adecuadas (amplitud y ruido razonable, potenciales asociados a los movimientos oculares visibles).
- **Canales.** En este prototipo se dejó de lado el análisis de la utilización de los distintos canales para mejorar la performance. Se utilizaron sólo los canales donde las señales buscadas tienen mayor potencia, pero hay información útil al menos en los canales cercanos, que se puede extraer utilizando filtros espaciales u otras técnicas.
- **Estímulos.** Una forma de mejorar la tasa de transferencia de información más fácil y rápida es aumentar la cantidad de opciones presentadas al usuario. Esto implica un análisis de otras frecuencias posibles para los estímulos, cuidando de mantener la performance del software y el framerate del mismo. También implicaría un análisis de qué sucede con la potencia de las componentes frecuenciales generadas en las señales cuando se presentan más

Capítulo 4. Deletreador SSVEP

estímulos de menor tamaño. Hay líneas de investigación que se centran en mejorar los estímulos, variando colores, frecuencias, formas, etc [83] [84] [34].

- **Detector y clasificador.** Otro bloque que permite varias modificaciones para mejorar el sistema es la detección frecuencial y la posterior clasificación de las instancias. Aquí se trabajó con un detector y clasificador muy sencillos que permitieron el análisis en tiempo real (características muy importante para una BCI). Aún así, junto al análisis de la utilización de más canales disponibles, se debería investigar el uso de clasificadores más complejos que puedan mejorar la performance.
- **Condiciones experimentales.** Viendo la dependencia que puede presentar el sistema según las condiciones de uso, para una futura investigación, sería de gran utilidad contar con un espacio experimental con condiciones más fijas y controladas que permitan descartar factores que pueden estar introduciendo variabilidad. Igualmente, debe tenerse siempre en mente el objetivo último que es la utilización de estos dispositivos por parte de personas con discapacidad motoras en condiciones reales, para la cual es necesario salir del laboratorio cuanto antes para no terminar sobreajustado a las condiciones controladas.
- **Usuarios.** El punto más importante sobre el cual debe hacerse foco es la variabilidad interusuario. Un buen paso siguiente en esta línea de investigación sería contar con una base de datos que incluya muchos usuarios distintos utilizando el sistema en diferentes secciones para poder realizar un análisis más profundo. Por supuesto que en alguna etapa más avanzada es necesario realizar pruebas con usuarios con discapacidades motoras severas dado que son los usuarios para los cuales se piensa este sistema.
- **Fijación de la mirada.** Siguiendo con la línea del punto anterior, otro aspecto a investigar es qué sucede cuando el sujeto no tiene control visual suficiente como para hacer foco en la opción deseada (personas para las cuales es de mayor interés contar con un dispositivo de estas características). Varios estudios indican que un SSVEP BCI puede funcionar incluso si el usuario no está fijando la mirada en el estímulo pero sí prestándole atención, a pesar de que la performance se ve comprometida [85] [86]. En la práctica, el usuario tiende a mirar el estímulo deseado salvo que presente una discapacidad que se lo impida. En este caso, el sistema funciona básicamente como un *eye tracker* o seguidor de mirada, para lo cual existen métodos más eficientes y cómodos [87]. Por todo esto es de gran interés abordar esta problemática en futuras investigaciones.

Por otro lado, es importante destacar que las señales SSVEP verdaderamente demostraron ser más robustas en cuanto a la generación de las mismas que el P300. Por lo cual indican ser un buen camino para continuar la investigación sobre interfaces cerebro-computadora.

Capítulo 5

Conclusiones

5.1. Conclusiones generales

Se logró diseñar, desarrollar e implementar exitosamente un prototipo funcional de interfaz cerebro computadora con el cual es posible escribir en una PC a través del sensado de la actividad cerebral.

En el camino hacia la obtención de dicho prototipo se fue obteniendo información sobre el estado del arte en la investigación sobre interfaces cerebro computadora, los fundamentos biológicos, los dispositivos existentes, las señales involucradas, los algoritmos utilizados y las aplicaciones más destacadas.

Además, se establecieron lazos con otros grupos de distinta disciplina que se encuentran investigando temáticas similares. Entre estos se destaca el vínculo con el CibPsi, donde cuentan con un laboratorio con un equipo de EEG de grado médico. Este es un punto importante para futuras investigaciones, no sólo para realizar experimentos con mayor precisión sino también porque las interfaces cerebro computadora son naturalmente una problemática que precisa ser abordada de forma interdisciplinaria.

Se trabajó con 2 de las 3 señales cerebrales utilizadas para desarrollar BCIs: el potencial evocado P300 y las oscilaciones SSVEP. En el trabajo con los P300 se logró reproducir la propuesta presentada por el equipo ganador de la BCI Competition III sobre un deletreador P300 clásico y luego de analizar y entender las señales de la base de datos disponible para la competencia, se propuso una mejora al preprocesamiento del algoritmo ganador. Por otro lado, utilizando las señales SSVEP fue que se logró obtener el prototipo funcional de interfaz cerebro computadora.

La tasa de transferencia de información lograda fue de $5,4\text{bits}/\text{min}$, valor que, a pesar de encontrarse muy por debajo del estado del arte (alrededor de $50\text{bits}/\text{min}$), es un muy buen punto de partida para futuras investigaciones dado que ya se tienen identificadas varias opciones de mejora para los distintos bloques involucrados, como se verá en la sección 5.3.

Por todo esto, se cumplió con los dos objetivos generales del proyecto: se apropió de los conocimientos existentes sobre las interfaces cerebro computador y los dispositivos existentes y se desarrolló un prototipo de Interfaz Cerebro-

Computadora propio.

5.2. Sobre la investigación de BCIs

En lo personal, creo que hace falta mayor acercamiento entre las distintas disciplinas involucradas. Por un lado, en la mayoría de los trabajos publicados provenientes desde la ingeniería, se ataca el problema con herramientas de reconocimientos de patrones sin interpretación de lo que está sucediendo de fondo, ni buscando un entendimiento mayor de las señales involucradas que pueden llevarnos a mejores resultados. Sin embargo, por otro lado se tienen investigaciones provenientes del área neurobiológica que analizan las señales en grandes promedios, interesados en las características de las mismas, sin ahondar en las instancias *single trial* o en la clasificación de las mismas.

También se hace notoria la necesidad de contar con más bases de datos públicas que incluyan diversidad de usuarios y dispositivos de adquisición. Es muy difícil y costosa la reproducción de resultados reportados en los distintos artículos y la comparación de los mismos debido a las diferencias entre sensores y variabilidad interusuario.

A pesar de esto, es motivante ver el avance existente en esta área de investigación que se encuentra en pleno auge, donde la enorme mayoría de los artículos científicos sobre esta temática fueron publicados en los últimos 10 años [9].

5.3. Trabajo a futuro

Debido a que este trabajo abordó la temática de Interfaz Cerebro Computadora en general, como una primera aproximación a la investigación en esta temática, hay varias líneas que permiten una continuación en la investigación con mayor profundidad.

En primer lugar, quedaron por fuera del alcance las Interfaces Cerebro Computadora basadas en potenciales sensorimotor. Estas son el tercer gran grupo de señales cerebrales utilizadas hoy en día en BCIs. Es de gran interés abordar estas señales en trabajos futuros dado que no necesitan de estímulos para funcionar, permitiendo que el usuario dispare una acción concreta en el momento que desee, sin tener que atarse a los tiempos de estímulos.

Por otro lado, a pesar de que no se logró observar el potencial P300 en los datos adquiridos con el Emotiv Epoc, es de interés continuar con la investigación de BCIs basadas en este potencial debido a que son las más referenciadas en la literatura. En esta línea se propone realizar pruebas con otro dispositivo y un mayor número de usuarios como primer paso en la búsqueda de visualizar el P300.

Finalmente, el trabajo con BCIs basadas en oscilaciones SSVEP fue el que dió mayores frutos, lográndose desarrollar el prototipo de BCI en base a ellas. Por lo tanto, es la primera línea de investigación a continuar. Se cuenta con un prototipo funcional pero todas las partes del mismo permiten un abordaje específico para lograr optimizar cada una de las etapas involucradas (ver sección 4.6 por detalles).

Referencias

- [1] J. Lehtonen, “Eeg-based brain computer interfaces,” Master’s thesis, Helsinki University of Technology, 2002.
- [2] EMOTIV. (2010) Epoc neuroheadset. [Online]. Available: <http://www.emotiv.com/store/hardware/299/>
- [3] J. Wolpaw, N. Birbaumer, W. Heetderks, D. McFarland, P. Peckham, G. Schalk, E. Donchin, L. a Quatrano, C. Robinson, and T. Vaughan, “Brain-computer interface technology: a review of the first international meeting.” *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 8, pp. 164–73, 2000.
- [4] S. Complejos. (2004) Interfaz cerebro-computadora. [Online]. Available: <http://casnew.iti.upv.es/>
- [5] J. Wolpaw, D. McFarland, and T. Vaughan, “Brain-computer interface research at the wadsworth center.” *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 8, pp. 222–6, 2000.
- [6] X. Gao, D. Xu, M. Cheng, and S. Gao, “A bci-based environmental controller for the motion-disabled.” *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 11, pp. 137–40, 2003.
- [7] J. Vidal, “Toward direct brain-computer communication.” *Annual Review of Biophysics and Bioengineering*, vol. 2, pp. 157–180, 1973.
- [8] J. Hohne, M. Schreuder, B. Blankertz, and M. Tangermann, “Two-dimensional auditory p300 speller with predictive text system.” *Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society*, pp. 4185–8, 2010.
- [9] J. Wolpaw and E. Winter, *Brain-Computer Interfaces: Principles and Practic.* Oxford University Press.
- [10] Y. Li, J. Pan, F. Wang, and Z. Yu, “A hybrid bci system combining p300 and ssvep and its application to wheelchair control,” *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 11, pp. 3156–3166, 2013.

Referencias

- [11] D. J. McFarland, D. J. Krusienski, W. A. Sarnacki, and J. R. Wolpaw, “Emulation of computer mouse control with a noninvasive brain–computer interface,” *Journal of neural engineering*, vol. 5, no. 2, p. 101, 2008.
- [12] J. J. Shih, D. J. Krusienski, and J. R. Wolpaw, “Brain-computer interfaces in medicine,” in *Mayo Clinic Proceedings*, vol. 87, no. 3. Elsevier, 2012, pp. 268–279.
- [13] D. G. Merchán. Introduccion a los sistemas brain-computer interface. [Online]. Available: <https://lacofa.fundaciontelefonica.com/general/introduccion-a-los-sistemas-brain-computer-interface>
- [14] N. Weiskopf, K. Mathiak, S. W. Bock, F. Scharnowski, R. Veit, W. Grodd, R. Goebel, and N. Birbaumer, “Principles of a brain-computer interface (bci) based on real-time functional magnetic resonance imaging (fmri),” *IEEE transactions on biomedical engineering*, vol. 51, no. 6, pp. 966–970, 2004.
- [15] R. Sitaram, A. Caria, R. Veit, T. Gaber, G. Rota, A. Kuebler, and N. Birbaumer, “Fmri brain-computer interface: a tool for neuroscientific research and treatment,” *Computational intelligence and neuroscience*, vol. 2007, 2007.
- [16] Wikimedia Commons. (2010) Sistema nervioso central. Esquema está basado en: Snell RS (2003) Neuroanatomía clínica: Panamericana. 554 p. [Online]. Available: https://es.wikipedia.org/wiki/Sistema_nervioso_central
- [17] Dartmouth Medical School. Atlas of the brain. [Online]. Available: <http://www.dartmouth.edu/~rswenson/Atlas/AxialSlice/AxialSlice2A.html>
- [18] Wikimedia Commons. (2007) Human brain taken from autopsy. Work by Suseno. [Online]. Available: https://commons.wikimedia.org/wiki/File:Human_Brain.jpg
- [19] K. Alberto, “*Gyrus*. [on line].[consulta: 3 marzo 2017]. disponible en: <https://en.wikipedia.org/wiki/gyrus>.”
- [20] H. Gray, *Anatomy of the human body*. Lea & Febiger, 1918.
- [21] B. Staff, “Blausen gallery 2014,” *Wikiversity Journal of Medicine*, vol. 1, 2014.
- [22] W. Penfield and T. Rasmussen, “The cerebral cortex of man; a clinical study of localization of function.” 1950.
- [23] A. Gramfort, “Mapping, timing and tracking cortical activations with meg and eeg: Methods and application to human vision,” Ph.D. dissertation, Ecole nationale supérieure des telecommunications-ENST, 2009.
- [24] D. Purves, G. J. Augustine, D. Fitzpatrick, W. Hall, A. LaMantia, J. McNamara, and L. White, “Neuroscience, 2008,” *De Boeck, Sinauer, Sunderland, Mass*, 2014.

- [25] F. Sharbrough, G. Chatrian, R. Lesser, H. Lüders, M. Nuwer, and T. Picton, “American electroencephalographic society guidelines for standard electrode position nomenclature,” *J. clin. Neurophysiol.*, vol. 8, no. 2, pp. 200–202, 1991.
- [26] M. Duvinage, T. Castermans, M. Petieau, T. Hoellinger, G. Cheron, and T. Dutoit, “Performance of the emotiv epoc headset for p300-based applications,” *BioMedical Engineering OnLine*, vol. 12, no. 1, p. 56, 2013. [Online]. Available: <http://dx.doi.org/10.1186/1475-925X-12-56>
- [27] H. Ekanayake, “P300 and emotiv epoc: Does emotiv epoc capture real eeg?” *Web publication <http://neurofeedback.visaduma.info/emotivresearch.htm>*, 2010.
- [28] Emotiv. (2004) Foro emotiv epoc. [Online]. Available: <https://github.com/openyou/emokit/issues/78>
- [29] A. Campbell, T. Choudhury, S. Hu, H. Lu, M. Mukerjee, M. Rabbi, and R. Raizada, “Neurophone: Brain-mobile phone interface using a wireless eeg headset,” *Proceedings of The Second ACM SIGCOMM Workshop on Networking, Systems, and Applications on Mobile Handhelds (MobiHeld’10)*, 2010.
- [30] Wikimedia Commons. (2008) Components of erp. [Online]. Available: <https://en.wikipedia.org/wiki/File:ComponentsofERP.svg>
- [31] B. H., “Über das elektrenkephalogramm des menschen ii,” *Psychol Neurol*, vol. 40, pp. 160–179, 1930.
- [32] H. Jasper and W. Penfield, “Electrocorticograms in man: effect of voluntary movement upon the electrical activity of the precentral gyrus,” *European Archives of Psychiatry and Clinical Neuroscience*, vol. 183, no. 1, pp. 163–174, 1949.
- [33] D. J. Creel, “Visually evoked potentials by donnell j. creel,” *Webvision: The Organization of the Retina and Visual System*.
- [34] D. Zhu, J. Bieger, G. G. Molina, and R. M. Aarts, “A survey of stimulation methods used in ssvep-based bcis,” *Computational intelligence and neuroscience*, vol. 2010, p. 1, 2010.
- [35] M. Alhaddad. (Setiembre 2012) Components of ssvep. [Online]. Available: Obtenidode:<http://malhaddad.kau.edu.sa/Pages-BCI-Research-En.aspx>
- [36] S. Lorenz. (Julio 5 del 2011) 4-choice ssvep bci [archivo de video]. [Online]. Available: <https://www.youtube.com/watch?v=uvuIzz57k9g>
- [37] S. Sutton, M. Braren, J. Zubin, and E. John, “Evoked-potential correlates of stimulus uncertainty,” *Science*, vol. 150, no. 3700, pp. 1187–1188, 1965.
- [38] R. T. Knight and D. Scabini, “Relationship to novelty detection in humans,” *J Clin Neurophysiol*, vol. 15, no. 0, p. 1, 1998.

Referencias

- [39] S. Yamaguchi and R. T. Knight, “Effects of temporal-parietal lesions on the somatosensory p3 to lower limb stimulation,” *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, vol. 84, no. 2, pp. 139–148, 1992.
- [40] D. Adrover-Roig and F. Barceló, “Individual differences in aging and cognitive control modulate the neural indexes of context updating and maintenance during task switching,” *Cortex*, vol. 46, no. 4, pp. 434–450, 2010.
- [41] M.D.Comerchero and J. Polich, “P3a and p3b from typical auditory and visual stimuli,” *Clinical Neurophysiology*, vol. 110, no. 1, pp. 24–30, 1999.
- [42] A. Magliero, T. Bashore, M. Coles, and E. Donchin, “On the dependence of p300 latency on stimulus evaluation processes,” *Psychophysiology*, vol. 21, no. 2, pp. 171–186, 1984.
- [43] J. Polich, “Updating p300: an integrative theory of p3a and p3b,” *Clinical neurophysiology*, vol. 118, no. 10, pp. 2128–2148, 2007.
- [44] J. Polich and C. Margala, “P300 and probability: comparison of oddball and single-stimulus paradigms,” *International Journal of Psychophysiology*, vol. 25, no. 2, pp. 169–176, 1997.
- [45] S. Martens, N. Hill, J. Farquhar *et al.*, “Overlap and refractory effects in a brain? computer interface speller based on the visual p300 event-related potential,” *Journal of neural engineering*, vol. 6, no. 2, p. 026003, 2009.
- [46] J. B. Isreal, G. L. Chesney, C. D. Wickens, and E. Donchin, “P300 and tracking difficulty: Evidence for multiple resources in dual-task performance,” *Psychophysiology*, vol. 17, no. 3, pp. 259–273, 1980.
- [47] E. Lin and J. Polich, “P300 habituation patterns: individual differences from ultradian rhythms,” *Perceptual and motor skills*, vol. 88, no. 3 suppl, pp. 1111–1125, 1999.
- [48] M. Kutas, G. McCarthy, and E. Donchin, “Augmenting mental chronometry: the p300 as a measure of stimulus evaluation time,” *Science*, vol. 197, no. 4305, pp. 792–795, 1977.
- [49] L. Farwell and E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials,” *Electroencephalography and clinical Neurophysiology*, vol. 70, no. 6, pp. 510–523, 1988.
- [50] G. Milsap. P300 spelling package in the bci2000. [Online]. Available: <https://www.youtube.com/watch?v=08GNE6OdNcs>
- [51] P. Meinicke, M. Kaper, F. Hoppe, M. Heumann, and H. Ritter, “Improving transfer rates in brain computer interfacing: a case study,” in *Advances in Neural Information Processing Systems*, 2002, pp. 1107–1114.

- [52] E. Donchin, K. M. Spencer, and R. Wijesinghe, “The mental prosthesis: assessing the speed of a p300-based brain-computer interface,” *IEEE transactions on rehabilitation engineering*, vol. 8, no. 2, pp. 174–179, 2000.
- [53] J. R. Wolpaw, H. Ramoser, D. J. McFarland, and G. Pfurtscheller, “Eeg-based communication: improved accuracy by response verification,” *IEEE transactions on Rehabilitation Engineering*, vol. 6, no. 3, pp. 326–333, 1998.
- [54] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, “Brain–computer interfaces for communication and control,” *Clinical neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [55] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks, D. J. McFarland, P. H. Peckham, G. Schalk, E. Donchin, L. A. Quatrano, C. J. Robinson, T. M. Vaughan *et al.*, “Brain-computer interface technology: a review of the first international meeting,” *IEEE transactions on rehabilitation engineering*, vol. 8, no. 2, pp. 164–173, 2000.
- [56] J. Kronegg, S. Voloshynovskyy, and T. Pun, “Analysis of bit-rate definitions for brain-computer interfaces,” 2005.
- [57] T. M. Cover and J. A. Thomas, *Elements of information theory*. John Wiley & Sons, 2012.
- [58] B. Blankertz, K.-R. Muller, D. J. Krusienski, G. Schalk, J. R. Wolpaw, A. Schlögl, G. Pfurtscheller, J. R. Millan, M. Schroder, and N. Birbaumer, “The bci competition iii: Validating alternative approaches to actual bci problems,” *IEEE transactions on neural systems and rehabilitation engineering*, vol. 14, no. 2, pp. 153–159, 2006.
- [59] B. Blankertz. (2004) Bci dataset for p300 evoked potentials. [Online]. Available: http://www.bbci.de/competition/iii/desc_II.pdf
- [60] A. Rakotomamonjy and V. Guigue, “Bci competition iii : Dataset ii - ensemble of svms for bci p300 speller.” *IEEE Transactions Biomedical Engineer*, 2007.
- [61] S. Canu, Y. Grandvalet, V. Guigue, and A. Rakotomamonjy, “Svm and kernel methods matlab toolbox,” Perception Systemes et Information, INSA de Rouen, Rouen, France, 2005.
- [62] B. Sklar, *Digital communications*. Prentice Hall Upper Saddle River, 2001, vol. 2.
- [63] OpenViBE. (2015) Software for brain computer interfaces and real time neuroscience. [Online]. Available: <http://openvibe.inria.fr/>
- [64] ——. (2015) P300 speller scenario. [Online]. Available: <http://openvibe.inria.fr/p300-speller-xdawn/>

Referencias

- [65] M. Spüler, M. Bensch, S. Kleih, W. Rosenstiel, M. Bogdan, and A. Kübler, “Online use of error-related potentials in healthy users and people with severe motor impairment increases performance of a p300-bci,” *Clinical Neurophysiology*, vol. 123, no. 7, pp. 1328–1337, 2012.
- [66] E. García Cossio, C. Fernandez, M. E. Gaviria, C. Palacio, L. Alvarán, and R. A. Torres Villa, “P300 based brain computer interface for alternative communication: a case study with two teenagers with motor disabilities,” *Revista Facultad de Ingeniería Universidad de Antioquia*, no. 60, pp. 223–231, 2011.
- [67] A. Materka and P. Poryzała, “A robust asynchronous ssvep brain-computer interface based on cluster analysis of canonical correlation coefficients,” in *Human-Computer Systems Interaction: Backgrounds and Applications 3*. Springer, 2014, pp. 3–14.
- [68] M. Middendorf, G. McMillan, G. Calhoun, K. S. Jones *et al.*, “Brain-computer interfaces based on the steady-state visual-evoked response,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 211–214, 2000.
- [69] J. Faller, R. Leeb, G. Pfurtscheller, and R. Scherer, “Avatar navigation in virtual and augmented reality environments using an ssvep bci,” in *International Conference on Applied Bionics and Biomechanics (ICABB)*, 2010, pp. 1–4.
- [70] Y. Wang, X. Gao, B. Hong, C. Jia, and S. Gao, “Brain-computer interfaces based on visual evoked potentials,” *IEEE Engineering in medicine and biology magazine*, vol. 27, no. 5, pp. 64–71, 2008.
- [71] P.-L. Lee, C.-H. Wu, J.-C. Hsieh, and Y.-T. Wu, “Visual evoked potential actuated brain computer interface: a brain-actuated cursor system,” *Electronics letters*, vol. 41, no. 15, pp. 832–834, 2005.
- [72] A. Materka and M. Byczuk, “Alternate half-field stimulation technique for ssvep-based brain-computer interfaces,” *Electronics Letters*, vol. 42, no. 6, pp. 321–322, 2006.
- [73] B. Allison, T. Luth, D. Valbuena, A. Teymourian, I. Volosyak, and A. Graser, “Bci demographics: how many (and what kinds of) people can use an ssvep bci?” *IEEE transactions on neural systems and rehabilitation engineering*, vol. 18, no. 2, pp. 107–116, 2010.
- [74] H.-J. Hwang, J.-H. Lim, Y.-J. Jung, H. Choi, S. W. Lee, and C.-H. Im, “Development of an ssvep-based bci spelling system adopting a qwerty-style led keyboard,” *Journal of neuroscience methods*, vol. 208, no. 1, pp. 59–65, 2012.
- [75] S. Parini, L. Maggi, A. C. Turconi, and G. Andreoni, “A robust and self-paced bci system based on a four class ssvep paradigm: algorithms and protocols for a high-transfer-rate direct brain communication,” *Computational Intelligence and Neuroscience*, vol. 2009, 2009.

- [76] Unity. (2016) Entorno de desarrollo unity. [Online]. Available: <https://unity3d.com>
- [77] ASUS. (Febrero 2017) Laptop utilizada. [Online]. Available: <https://www.asus.com/Notebooks/X555LN/>
- [78] EMOTIV. (2016) Emotiv unity 3d support pack. [Online]. Available: <https://www.emotiv.com/product/unity3d-support-pack/>
- [79] ——. (2016) Emotiv sdk for raw data. [Online]. Available: <https://www.emotiv.com/sdk-premium-edition-application-form/>
- [80] P. Sysel and P. Rajmic, “Goertzel algorithm generalized to non-integer multiples of fundamental frequency,” *EURASIP Journal on Advances in Signal Processing*, vol. 2012, no. 1, p. 56, 2012. [Online]. Available: <http://dx.doi.org/10.1186/1687-6180-2012-56>
- [81] F. S. Pratt, “Urgent, the story of codes and ciphers blue ribbon books,” *Garden City, New York*, 1939.
- [82] Wikipedia. (Febrero 2017) Frecuencia de aparicion de letras. [Online]. Available: https://es.wikipedia.org/wiki/Frecuencia_de_aparicion_de_letras
- [83] Y. Wang, Y. Wang, and T. Jung, “Visual stimulus design for high-rate ssvep bci,” *Electronics letters*, vol. 46, no. 15, p. 1, 2010.
- [84] H. Cecotti, I. Volosyak, and A. Gräser, “Reliable visual stimuli on lcd screens for ssvep based bci,” in *Signal Processing Conference, 2010 18th European*. IEEE, 2010, pp. 919–923.
- [85] S. P. Kelly, E. C. Lalor, R. B. Reilly, and J. J. Foxe, “Visual spatial attention tracking using high-density ssvep data for independent brain-computer communication,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 13, no. 2, pp. 172–178, 2005.
- [86] B. Z. Allison, D. J. McFarland, G. Schalk, S. D. Zheng, M. M. Jackson, and J. R. Wolpaw, “Towards an independent brain-computer interface using steady state visual evoked potentials,” *Clinical neurophysiology*, vol. 119, no. 2, pp. 399–408, 2008.
- [87] M. Wedel and R. Pieters, “A review of eye-tracking research in marketing,” in *Review of marketing research*. Emerald Group Publishing Limited, 2008, pp. 123–147.

Índice de tablas

3.1. Capacidad de canal calculada según los resultados reportados de distintos trabajos de referencia.	33
3.2. Resultados reportados por ganador de competencia.	39
3.3. Tabla resumen de los mejores resultados obtenidos por Rakotomamonjy et al..	40
3.4. Tasa de transferencia de información comparativa.	41
3.5. Resultados obtenidos con Rakotomamonjy et al. para canales fijos promediando los datos de ambos usuarios	43
3.6. Algoritmo de Rakotomamonjy et al. con distinta cantidad de SVMs promediando usuarios.	46
3.7. Promedio entre sujetos del algoritmo de Rakotomamonjy et al. variando frecuencia de corte de pasabajos.	47
3.8. Promedio entre usuarios de los resultados de Rakotomamonjy et al. aplicado al sujeto con el que no fue entrenado.	48
3.9. Resultados del Filtro sincrónico.	60
3.10. Promedio entre sujetos del algoritmo de Rakotomamonjy et al. sobre la señal filtrada con el <i>template</i> P300 promedio.	61
3.11. Promedio entre sujetos del algoritmo de Rakotomamonjy et al. sobre la señal sin oscilación SSVEP.	62
4.1. Tasa de transferencia de información comparada entre distintos trabajos.	84

Índice de figuras

2.1. Un BCI crea nuevas salidas del SNC.	6
2.2. Descripción de un sistemas BCI.	6
2.3. Diagrama de bloques de un sistemas BCI.	7
2.4. Estructura del Sistema Nervioso Central humano.	9
2.5. Cerebro humano.	10
2.6. Anatomía del córtex cerebral.	10
2.7. Áreas funcionales del cerebro.	12
2.8. Homunculus de Penfield.	13
2.9. Columna cortical.	14
2.10. Terminología de direcciones espaciales del cerebro.	14
2.11. Ilustración de una neurona.	15
2.12. Polarización de la membrana neuronal.	16
2.13. Activación de neuronas piramidales.	16
2.14. Señal de electroencefalografía.	17
2.15. Ubicación electrodos según sistema 10-20 [25].	18
2.16. Ubicación de los electrodos del dispositivo Emotiv Epoc. [29] . . .	20
2.17. Panel de control de Emotiv.	20
2.18. Expressiv Suite.	21
2.19. Affectiv Suite.	21
2.20. Cognitiv Suite.	22
2.21. Extracción de Potenciales Evocados mediante promediación.	22
2.22. Registro de potenciales evocados visuales.	24
2.23. Aumento de la energía de la señal EEG en las frecuencias corres- pondientes a la de presentación del estímulo [34].	24
2.24. BCI basadas en SSVEP	25
3.1. Visualización del P300 promediando un segundo luego del estímulo.	28
3.2. Ejemplo de experimento donde un tipo de estímulos generan un P300 en el usuario.	29
3.3. Imágenes descriptivas del experimento a analizar.	31
3.4. Sistema BCI como canal de comunicación.	32
3.5. Display y electrodos utilizados en la toma de datos de la base de BCI Competition III [59].	35
3.6. Grandes promedios en varios canales ubicados consistentemente según su ubicación en la cabeza.	36

Índice de figuras

3.7. Grandes promedios en varios canales ubicados consistentemente según su ubicación en la cabeza.	36
3.8. Arquitectura del clasificador propuesta en [60].	37
3.9. Evolución de la performance alcanzada replicando lo descrito por Rakotomamonjy et al. al variar el número de parpadeos.	41
3.10. Evolución de la precisión durante el proceso de eliminación de canales para algunos subconjuntos.	43
3.11. Cantidad de canales seleccionados por subconjunto de entrenamiento para cada sujeto.	43
3.12. Canales posicionados dentro de los primeros 12 para distintos subconjuntos de entrenamiento (particiones)	44
3.13. Distribución de los canales según el <i>ranking</i> generado durante el proceso de eliminación.	44
3.14. Resultados obtenidos con Rakotomamonjy et al. con canales fijos para cada usuario por separado.	45
3.15. Algoritmo de Rakotomamonjy et al. con distinta cantidad de SVMs para ambos usuarios.	46
3.16. Algoritmo de Rakotomamonjy et al. variando frecuencia de corte pasabajos en etapa de preprocesamiento.	47
3.17. Algoritmo de Rakotomamonjy et al. aplicado al sujeto con el que no fue entrenado.	48
3.18. Grandes promedios de ambas clases para el Sujeto A.	49
3.19. Potenciales para Sujeto A con y sin P300 en grandes promedios.	50
3.20. Potenciales para Sujeto A con y sin P300 en grandes promedios.	51
3.21. Grandes promedios para el sujeto A, para ambas clases.	52
3.22. Potenciales en grandes promedios restando la oscilación de fondo.	53
3.23. Electrodo agrupados verticalmente evolucionando en el tiempo para P300.	54
3.24. Visualización de las señales de distintas épocas en promedio de todos los parpadeos y sin oscilación de fondo. Para cada una se muestra: a) Gráfica del canal C_z promediando las instancias correspondientes a cada letra candidata. En rojo, la señal correspondiente a la letra que estaba observando el sujeto. En verde las correspondientes a las letras que comparen fila o columna con la anterior. En azul las correspondientes al resto de las letras. b) Matriz de la izquierda con el valor de C_z a los 30ms para cada letra candidata. c) Matriz de referencia que muestra la fila y la columna correspondiente a la letra correcta.	55
3.25. Espectro de los grandes promedios sin señal de fondo para cada sujeto.	56
3.26. Grandes promedios filtrados pasabajo a distintas frecuencias.	57
3.27. Filtro apareado para distintas épocas.	59
3.28. Algoritmo de Rakotomamonjy et al. sobre señal filtrada con el <i>template</i> P300 promedio.	60
3.29. Algoritmo de Rakotomamonjy et al. sobre señal sin oscilación SS-VEP sin entrenamiento de canales.	61

3.30. Vistas de OpenViBE, software utilizado para obtener registros propios para el deletreador P300.	62
3.31. Gran promedio de los datos extraídos utilizando el escenario de deletreador P300 de OpenViBE y el dispositivo Emotiv Eloc.	63
4.1. Diagrama de una BCI basada en SSVEP.	66
4.2. Deletreador SSVEP.	68
4.3. Layout de los estímulos presentados en pantalla en el caso de dos opciones que parpadean a dos frecuencias distintas.	69
4.4. Estimación SNR para distintas frecuencias de estímulo.	70
4.5. Espectro de una instancia de cada clase.	71
4.6. SSVEP Promedio	71
4.7. Salida de Goertzel para ambas clases	74
4.8. Salida del Goertzel para señales con SNR = 0.01 (-20dB).	75
4.9. Análisis de la performance del detector al variar la frecuencia de la señal de entrada.	76
4.10. Comportamiento del detector al variar potencia del ruido en frecuencia de la señal.	77
4.11. Comportamiento del detector al variar SNR y tiempo de señal.	77
4.12. Respuesta de la función 4.6	78
4.13. Respuesta del detector frente a datos reales.	78
4.14. Salida del detector para instancias dispares.	79
4.15. Espectro de señales que provocan salidas dispares en el detector.	79
4.16. Respuesta del detector diferencia frente a datos reales.	80
4.17. Performance para detector diferencia frente a datos reales, variando el tiempo de observación de la señal.	81
4.18. Deletreo de letra H.	82
4.19. Capacidad del canal.	84
4.20. Capacidad del canal con borradura.	86
4.21. Capacidad del canal con borradura y sin borradura.	87
4.22. Imágenes durante el evento en el cual se probó el prototipo con el público general.	87
4.23. Señales registradas para dos usuarios distintos.	88

Esta es la última página.
Compilado el lunes 1 mayo, 2017.
<http://iie.fing.edu.uy/>