

Diseño e implementación de una Interfaz
Cerebro-Computadora basada en Potenciales
Evocados Visuales de Estado Estacionario

tesis que para obtener el grado de
Maestro en Ciencias (Ingeniería Biomédica)

presenta

Ing. Biom. Teodoro Solis-Escalante

Julio de 2007

Asesor: M. en I. Oscar Yáñez Suárez

Sinodales:

Dr. Rogelio Alcántara Silva

Dr. Tomás Aljama Corrales

M. en I. Oscar Yáñez Suárez

Universidad Autónoma Metropolitana

Unidad Iztapalapa

Ciudad de México

Agradecimientos¹

En primer lugar al **CONACyT** por la beca para estudios de posgrado y la beca mixta para estancias en el extranjero otorgadas para el desarrollo de este trabajo.

Principalmente, a mi familia por todo.

A el LINI-staff o LINI-o's.

A mis compañeros del Posgrado y la Licenciatura en Ingeniería Biomédica.

A la UAM-I y la fi-UNER.

A (Herr) M. en I. Oscar Yañez Suárez por la dirección de este trabajo.

A M.en C. Gerardo Gabriel Gentiletti (3G) por el ejemplo y la colaboración.

A ambos y a sus familias por la amistad.

A mis colegas de BCI.

Y a mis amigas y amigos (como en el Cantinflas Show) en todos lados.

¹Hecho en México con \LaTeX y una iBook

Resumen

En este trabajo se presenta el proceso de diseño e implementación de una interfaz cerebro-computadora basada en los potenciales evocados visuales de estado estacionario. El sistema desarrollado se denomina LINI-BCI : SSVEP y permite la adquisición de señales electroencefalográficas para la investigación de métodos de procesamiento y clasificación fuera de línea. Incluye también la flexibilidad para probar nuevos paradigmas de estimulación visual. Como parte fundamental del desarrollo de este trabajo, se propone un nuevo método de detección de los potenciales evocados basado en el algoritmo de clasificación multiseñal y la aplicación de clasificadores del tipo máquinas de soporte vectorial.

El método se validó con señales sintéticas y con señales reales de experimentos de identificación de dos, tres y cuatro condiciones de estimulación traducibles a comandos para alguna aplicación de la interfaz. Para la evaluación del desempeño del método se utilizaron estimaciones de la tasa de clasificación (certeza) y del área bajo la curva de características relativas de operación. La clasificación de épocas de un segundo arrojó una certeza superior a 85 % en la identificación de dos estímulos presentados a un sujeto entrenado en el uso de las interfaces cerebro-computadora, con una muestra de diez sujetos no entrenados se alcanzó una tasa de clasificación superior al 80 % (0.8 en área bajo la curva de características relativas de operación) para la identificación de un potencial evocado y alrededor de 60 % (0.6 en área bajo la curva de características relativas de operación) para la discriminación entre dos tipos de estímulo; por último, para la clasificación de cuatro clases con una muestra de nueve sujetos no entrenados se obtuvieron valores del área bajo la curva de características relativas de operación superiores a 0.6 en todos los casos.

Los resultados muestran la ventaja de utilizar el método propuesto en comparación con los resultados reportados en otros trabajos que utilizan la Transformada Discreta de Fourier y discriminantes lineales, entre otros. Además, el sistema LINI-BCI permite la inclusión de otros paradigmas y el registro de señales cerebrales distintas de los potenciales visuales.

Índice general

1. Introducción	9
1.1. Esquema de una BCI	9
1.2. Clasificación de BCI	10
1.2.1. De acuerdo con la técnica de registro	11
1.2.2. De acuerdo con el paradigma en que están basadas	13
1.3. Potenciales Evocados, EP	14
1.3.1. Potenciales evocados de estado estacionario, SSEP	14
1.3.2. Potenciales evocados visuales de estado estacionario, SSVEP	15
2. Objetivos	17
2.1. Hipótesis de Trabajo	17
2.2. Objetivos generales	17
2.3. Objetivos particulares	17
3. Estado-del-arte	19
3.1. Evocación de los SSVEP	19
3.1.1. Respuesta humana a estímulos intermitentes	19
3.1.2. Modulación en amplitud y fase, sensibilidad al estímulo	20
3.1.3. Presentación de estímulos	20
3.2. Técnica de registro	22
3.2.1. Sistema de registro	22
3.2.2. Electrodo de registro	22
3.3. Detección: extracción de características	23
3.3.1. Análisis en tiempo	23
3.3.2. Análisis en frecuencia	23
3.3.3. Tiempo-frecuencia y otros análisis	24
3.4. Detección: clasificadores	24
3.4.1. Detección por umbral	24

3.4.2. Discriminantes lineales	24
4. Metodología	27
4.1. Estímulo y paradigma	27
4.2. Adquisición y almacenamiento	28
4.3. Reconocimiento de Patrones	29
4.3.1. Preprocesamiento	29
4.3.2. Método para detección de SSVEP: MUSIC + SVM	29
4.3.3. Medidas de desempeño	34
4.4. Experimentos	36
4.4.1. Validación de MUSIC I: Señales sintéticas	36
4.4.2. Validación de MUSIC II: Senoidales puras	37
4.4.3. Método de detección para SSVEP: dos clases	37
4.4.4. Método de detección para SSVEP: tres clases	38
4.4.5. Método de detección para SSVEP: cuatro clases	39
5. Resultados	45
5.1. Validación de MUSIC I: Señales sintéticas	45
5.2. Validación de MUSIC II: Senoidales puras	47
5.3. Detección de SSVEP: dos clases	47
5.4. Detección de SSVEP: tres clases	49
5.5. Detección de SSVEP: cuatro clases	51
6. Discusión	55
6.1. Validación de MUSIC	55
6.1.1. Detección de la frecuencia ω_0	55
6.1.2. Selectividad mediante el parámetro u	56
6.1.3. Simplicidad de cálculo	56
6.1.4. Resolución infinita	56
6.2. Detección de SSVEP: dos clases	57
6.3. Detección de SSVEP: tres clases	57
6.4. Detección de SSVEP: cuatro clases	58
6.5. Detección de SSVEP: n clases	59
6.5.1. Uso de núcleos lineales, lin-SVM	59
6.5.2. Electrodo de registro	59
6.5.3. Concatenación de características	60
6.5.4. Frecuencias óptimas	60

6.5.5. Entrenamiento y retroalimentación	60
7. Conclusiones	61
7.1. Trabajo futuro	62
7.1.1. Materiales y métodos	62
7.1.2. Aplicaciones en BCI	62
7.1.3. Soluciones adicionales	62
7.1.4. Futuro del sistema LINI-BCI	62
Referencias	64
A. Código en Presentation®	69
A.1. Introducción a Presentation®	69
A.2. Estímulo para tres clases	69
A.3. Estímulo para cuatro clases	72
A.4. Compilador para Presentation®	87
A.5. Compilador para la descripción utilizada	90
B. Implementación de MUSIC en Octave	91
B.1. Función utilizada para dos y tres clases	91
B.2. Extensión a cuatro clases	94
C. Compilación de resultados	97
C.1. Validación de MUSIC I: Señales sintéticas	97
C.2. Validación de MUSIC II: Senoidales puras	97
C.3. Detección de SSVEP: dos clases	104
C.4. Detección de SSVEP: tres clases	104
C.4.1. Área bajo la curva ROC, A_z	106
C.5. Detección de SSVEP: cuatro clases	108
D. Experimentos adicionales	117
D.1. Adaptación a corto plazo: tres clases	117
D.2. Método alternativos de detección para SSVEP: detección de fase	117

Capítulo 1

Introducción

El campo de las interfaces cerebro-computadora (BCI) es un área nueva de investigación que tiene como principal objetivo proporcionar una vía de comunicación a los pacientes que se encuentran inhabilitados para hacerlo por medios naturales, ya sea por lesiones tales como la sección espinal como consecuencia de algún accidente o enfermedades como la esclerosis lateral amiotrófica (ELA). La también llamada enfermedad de Lou Gehrig es una enfermedad neurológica degenerativa que ataca a las neuronas encargadas de controlar los músculos voluntarios y cuyo desenlace siempre es fatal.

El uso de una BCI pretende mejorar la calidad de vida de este tipo de pacientes (usuarios), permitiéndoles interactuar con su entorno. Además existe un gran interés por el desarrollo de nuevas tecnologías de control y comunicación por parte de la industria del entretenimiento, lo que ha impulsado un incremento en la inversión para realizar este tipo de trabajos de investigación, sobrepasando el objetivo principal de una BCI.

1.1. Esquema de una BCI

En términos generales una BCI es un sistema complejo compuesto por subsistemas que resuelven tres problemas específicos:

- Adquisición y acondicionamiento de información cerebral
- Reconocimiento de patrones
 - Preprocesamiento
 - Extracción de características
 - Clasificación

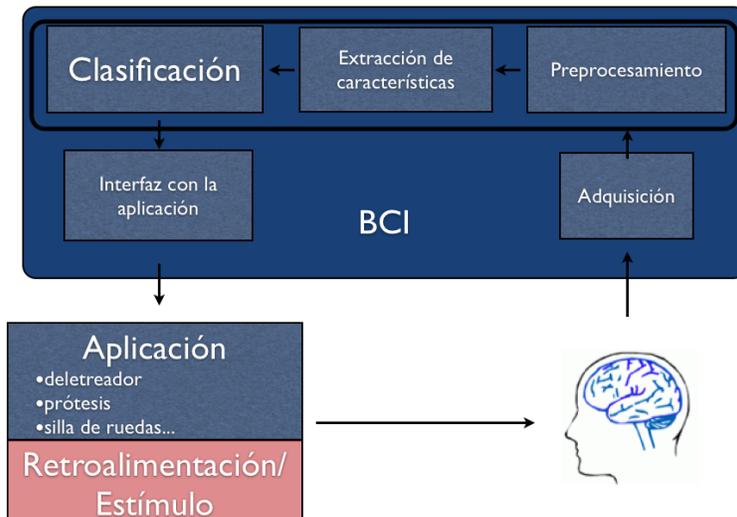


Figura 1.1: Esquema de una Interface Cerebro-Computadora

- Interfaz con la aplicación

La figura 1.1 muestra un esquema de esta descripción.

La conjunción de estas soluciones define a una BCI, por lo que es indispensable resolver cada uno de ellos para una implementación de BCI específica. En la actualidad existen muchos sistemas que pueden integrarse para solucionar cada una de las tareas sin necesidad de abordar el problema desde cero. En general, existen ya sistemas de adquisición, software y hardware dedicado al preprocesamiento de señales y aplicaciones de propósito general que pueden ser integradas en una BCI.

1.2. Clasificación de BCI

La variedad misma de soluciones para cada uno de los problemas, en particular la adquisición y el procesamiento de señales para la tarea de reconocimiento de patrones, permiten clasificar a las BCI de acuerdo al tipo de problemas técnicos con los que se enfrentan. El problema de adquisición es indirectamente afectado por la técnica de registro que se utiliza para obtener información del cerebro del paciente. Así, tenemos interfaces basadas en imágenes o diferentes tipos de señales obtenidas por medio de técnicas con diferentes niveles de invasividad. De igual forma el problema de reconocimiento de patrones es modulado en *complejidad* por el tipo de paradigma que se utiliza para observar algún fenómeno o evocar

un potencial y la información que este contiene. En los siguientes apartados se presenta la clasificación de las BCI de acuerdo con la técnica de registro y el paradigma en que están basadas.

1.2.1. De acuerdo con la técnica de registro

Actualmente existe un gran número de técnicas de registro que permiten observar y medir cambios electromagnéticos, metabólicos y estructurales en el cerebro de un paciente con diversos grados de intervención o invasividad. Resulta obvio pensar que la invasividad de cierta técnica tiene que ver con la complejidad de llevar a cabo un registro y los riesgos que comprende. De esta forma para los usuarios de una BCI es necesaria una técnica de registro no invasiva (o mínimamente invasiva) que permita obtener la suficiente resolución temporal y espacial para que la aplicación sea controlada de forma correcta y eficiente.

Principalmente, las técnicas que pueden utilizarse son:

- *Imagenología funcional por Resonancia Magnética (fMRI)*, utilizada para observar los cambios metabólicos que ocurren durante un proceso mental. Posee una buena resolución espacial y una alta resolución temporal pero, al depender de los cambios metabólicos que ocurren durante la ejecución de tareas mentales, un cambio en la imagen puede requerir de un tiempo considerable. Para obtener información funcional por fMRI se requiere de equipo especializado de grandes dimensiones, por lo que su uso en una BCI práctica está limitado por espacio y el costo elevado de esta tecnología.
- *Magnetoencefalografía (MEG)*, mide los fenómenos electromagnéticos que ocurren durante un paradigma de estímulo o tarea mental. El uso de esta tecnología otorga una resolución espacial de hasta 3 mm y buena resolución temporal. La instrumentación requerida para el registro de MEG es similar en costo y dimensiones al equipo de fMRI, encontrando las mismas limitaciones en su uso.
- *Electroencefalografía (EEG)*, el registro de la actividad eléctrica del cerebro con electrodos en la superficie del cuero cabelludo ha sido utilizado desde el inicio de la neurología y constituye una herramienta muy bien conocida e implementada. El equipo de adquisición es pequeño y portátil, la resolución temporal del EEG es alta y a pesar de que la resolución espacial es pobre, debido al efecto de dispersión provocado por el volumen conductor y las interfaces presentes en él, arreglos de electrodos y fenómenos bien localizados pueden sobreponerse a estas desventajas. Estas características junto con la simplicidad de adquisición hacen del EEG la técnica preferida para aplicaciones e investigación en BCI.

- *Electrocorticografía (ECoG)*, al igual que el EEG registra la actividad eléctrica del cerebro con la diferencia de que los electrodos se localizan directamente en la superficie de la corteza cerebral, haciendo necesaria una intervención quirúrgica para la colocación de los electrodos, exponiendo al paciente al riesgo que comprende toda técnica de registro invasiva. Sin embargo, las características de resolución son las mejores en el espacio-tiempo, pero el implante de electrodos y la respuesta de defensa del organismo hace que existan variaciones si se utiliza la técnica en corto, mediano y largo plazo.

El cuadro 1.2.1 contiene información comparativa sobre las técnicas descritas y las variedades de tomografía.

Recientemente ha crecido el interés por técnicas de registro *cercanas-al-infrarrojo (NIR)*, que utilizan el principio de absorbancia y transmitancia de una onda luminosa para medir cambios metabólicos a diferentes niveles de la masa encefálica. Ya se han presentado los primeros intentos para integrar esta tecnología a una BCI [2] pero al ser una técnica nueva, se desconocen sus efectos sobre el cerebro a corto, mediano y largo plazo; por lo tanto se excluye de esta lista pero es importante mencionar su existencia y considerar la investigación de esta nueva técnica.

1.2.2. De acuerdo con el paradigma en que están basadas

El sistema de reconocimiento de patrones que se integra a una BCI debe ser capaz de identificar un estado o actividad mental específica para producir un comando o control de una aplicación. Estas respuestas pueden ser generadas por el sujeto de forma espontánea o ser evocadas y requerir de un estímulo para que ocurran. A la tarea realizada por el sujeto o el estímulo que se presenta lo llamaremos paradigma.

Se pueden identificar diferentes tipos de paradigmas y entre ellos podemos citar a los siguientes como los más usados o específicos para BCI.

- *Cambios metabólicos*, todas las actividades cognitivas y sensoriales están mapeadas a regiones específicas de la corteza cerebral, lo cual implica que un cambio en la actividad de un área particular correspondiente al desempeño de una tarea mental o la ocurrencia de un estímulo. El incremento de la actividad neuronal se ve reflejado en un mayor gasto energético, en el mayor consumo de oxígeno y glucosa así como en un aumento en el riego sanguíneo. Para observar estos cambios puede monitorearse el nivel de cualquiera de ellos mediante una técnica específica. En general, los cambios metabólicos son voluntarios y no requieren de ninguna clase de estímulo para ocurrir.
- *Ritmos*, de la misma forma que con los cambios metabólicos el sujeto puede cambiar el contenido espectral de la señal de EEG a voluntad, luego de haber aprendido en una

Cuadro 1.1: Técnicas de registro de actividad cerebral (mapeo e imagenología) y sus características, adaptado de [1]. \mathbf{R}_t = Resolución temporal, \mathbf{R}_{xyz} = Resolución espacial.

Técnica	Propiedad física medida	\mathbf{R}_t	\mathbf{R}_{xyz}	Invasividad
<i>EEG</i>	electrofisiología cerebral macroscópica	alta	pobre	NO
<i>ECoG</i>	electrofisiología de corrientes extracelulares	alta	alta	SI
<i>MEG</i>	campo magnético cortical asociado con actividad eléctrica	buena	alta	NO
<i>CT</i>	densidad de tejido relacionada con absorción de rayos X	-	alta	SI
<i>SPECT</i>	rastreo de trazadores radioactivos en flujo sanguíneo	pobre	pobre	SI
<i>PET</i>	rastreo de decaimiento de radiación gamma	buena	pobre	SI
<i>MRI</i>	variación en ondas de radio por actividad electro-magnética	pobre	alta	NO
<i>fMRI</i>	propiedades electro-magnéticas de flujo sanguíneo	buena	buena	NO
<i>NIR</i>	cambios en absorción y dispersión óptica en tejido cortical	buena	buena	NO

etapa de entrenamiento. Estos cambios se observan con ayuda de un análisis tiempo-frecuencia de la señal de EEG por bandas; estas bandas también están asociadas a estados de conciencia.

- *Potenciales corticales lentos (SCP)*, al igual que los ritmos, los SCP son cambios en las características de la señal de EEG que se producen voluntariamente. Los cambios que se presentan en este paradigma son cambios en el nivel promedio del EEG y como su nombre lo indica, estos cambios ocurren lentamente y requieren de un alto nivel de concentración para lograr su control. Otra desventaja de este paradigma es que solo un tercio de los sujetos pueden aprender a controlar los SCP.
- *Imaginación de movimiento*, en conjunto con los paradigmas descritos anteriormente la imaginación de movimiento utiliza los hechos de que: i) toda actividad se mapea al cerebro, principalmente a la corteza y ii) los cambios en frecuencia para tareas específicas. En particular se observa el fenómeno de sincronía/desincronía (ERS/ERD) que ocurre en la corteza motora al imaginar el movimiento de alguna extremidad. De la misma forma puede realizarse a voluntad y para sujetos sanos requiere una fase de entrenamiento en la cual se aprende a imaginar la realización de un movimiento sin realmente ejecutarlo.
- *Potenciales evocados*, este tipo de fenómenos tienen dependencia con un estímulo o evento y pueden constituir respuestas primarias o complejas dependiendo del tipo de evento. Los eventos que comúnmente se utilizan en BCI son:
 - Evento raro (odd-ball).

El paradigma de evento raro se caracteriza por la ocurrencia de un complejo de ondas que están relacionadas con los procesos de actualización de la memoria de trabajo (estímulo visual, reconocimiento del evento, reconocimiento del objetivo y actualización de memoria [3]). Este complejo lo conforman las ondas: P100, N100, P200, N200, P300, N400. De las cuales la onda más importante y fácilmente identificable una vez desenmascarado el potencial es la P300.
 - Visuales.

Se puede dividir a los potenciales visuales como transitorios y estacionarios, siendo estos últimos los más utilizados en las aplicaciones de BCI. Los potenciales evocados visuales transitorios son aquellos que se presentan cuando la retina o partes de ella son estimuladas con un cambio en las características de una imagen (intensidad, color y forma), la característica que cambia depende del tipo de células (conos o bastones) que se desea excitar. Los potenciales evocados visuales de estado estacionario son patrones que se evocan a partir de la presentación de un

estímulo periódico. Al tratarse de un potencial evocado, la respuesta se presenta siempre y cuando exista un estímulo por lo que no requiere de entrenamiento.

1.3. Potenciales Evocados, EP

En el apartado anterior se utilizó el término *potenciales evocados* (EP) para incluir a los potenciales relacionados a eventos (ERP) sin embargo, sus definiciones son diferentes. Un ERP es un potencial generado junto con eventos sensoriales, motores o cognitivos y se asocia con un intercambio informacional en el cerebro. Los EP incluyen a fenómenos que no corresponden a esta definición, por ejemplo, pueden estar correlacionados con algún estímulo pero no estar asociados con eventos sensoriales, motores o cognitivos; de forma que los experimentos de EP pueden realizarse por debajo del umbral de percepción o en estado de anestesia.

1.3.1. Potenciales evocados de estado estacionario, SSEP

Un caso especial de los EP son los *potenciales evocados de estado estacionario* (SSEP), término acuñado para la respuesta ideal de un EP que se repite durante un largo tiempo y cuyos componentes discretos de frecuencia se mantienen constantes en amplitud y fase [4]. Esto no quiere decir que un SSEP sea un tren infinito de ondas idénticas, es mejor pensar en una señal que mantiene constante su contenido en frecuencia.

En esta definición la frecuencia del estímulo o del potencial no están consideradas debido a que sólo afecta al número de componentes presentes en la señal. Es decir un estímulo de alta frecuencia generará respuestas en frecuencias altas y posiblemente fuera del ancho de banda del EEG, por el contrario un estímulo a menor frecuencia evocará más armónicos. Particularmente, los SSEP generados por estímulos visuales a 32 Hz y 48 Hz son señales débiles por lo que el armónico de 16 Hz domina el espectro y no permite observar claramente otros componentes.

1.3.2. Potenciales evocados visuales de estado estacionario, SSVEP

Los SSVEP son potenciales cuasi-senoidales que se generan en la corteza visual al presentar un estímulo que oscila a una frecuencia fija. Estos potenciales son fácilmente descritos en términos de sus componentes de frecuencia ya que presentan una mayor potencia en la frecuencia de estímulo y sus armónicos que en el resto de la banda de la señal de EEG. A pesar del ancho de banda acotado la respuesta de los SSVEP se presenta en un rango de frecuencias cercano a los 100 Hz, incluso la frecuencia de barrido de un monitor de LCD

(75 Hz) genera una respuesta pequeña pero detectable por encima del umbral de percepción humano [4, 5].

En la siguiente sección se presenta el estado-del-arte de las BCI basadas en SSVEP, los fundamentos de la comunicación, los estímulos que se presentan y las técnicas utilizadas para la solución al reconocimiento de patrones.

Capítulo 2

Objetivos

2.1. Hipótesis de Trabajo

El estado actual de la tecnología otorga soluciones al registro de señales de EEG, el procesamiento de señales y el reconocimiento de patrones. Estas soluciones pueden integrarse en el diseño de una BCI basada en SSVEP que permita recolectar datos en condiciones controladas para validar nuevas técnicas de procesamiento que permitan mejorar la detección de los SSVEP e incrementar el bit-rate de la BCI.

2.2. Objetivos generales

- Diseñar una BCI basada en SSVEP contemplando los aspectos de registro, estimulación y clasificación.
- Obtener una muestra significativa de registros de sujetos sanos para la valoración estadística de los métodos y técnicas utilizadas.

2.3. Objetivos particulares

- Generar un protocolo de adquisición de señales para una BCI basada en SSVEP.
- Explorar (fuera de línea) técnicas de extracción de características que sean adecuadas para las BCI basadas en SSVEP.
- Explorar el rango de frecuencias del estímulo para aumentar la capacidad expresiva del método y disminuir la fatiga del sujeto.

Capítulo 3

Estado-del-arte

En este capítulo se presenta un resumen de las técnicas utilizadas en los diferentes subsistemas de las BCI basadas en SSVEP; este resumen comprende los aspectos de estímulo/evocación del potencial, el sistema de registro y sus características, métodos reportados para la detección y la clasificación.

3.1. Evocación de los SSVEP

3.1.1. Respuesta humana a estímulos intermitentes

Se han reportado los resultados de estudios neurofisiológicos que indican la evocación de los SSVEP en la corteza visual del cerebro humano y muestran la respuesta de éste como un sistema. Parte de estos resultados incluyen la posibilidad de evocar un SSVEP durante la presentación de un estímulo intermitente de frecuencia constante en la banda de 1 a 100 Hz con intervalos de 1 Hz entre estímulos [5]. Se encontró una respuesta lineal del cerebro (corteza visual) en el ancho de banda analizado, con una importante disminución de la amplitud de la respuesta evocada para las frecuencias de estímulo más altas. Además una hipótesis de este trabajo incluía la búsqueda de *frecuencias de resonancia* en las cuales la amplitud del potencial es mayor que en las frecuencias vecinas (p. ejem. a 36 Hz se obtuvo una respuesta de mayor amplitud que a 35 y 37 Hz). En el trabajo citado se plantea un fundamento fisiológico o anatómico que explica este fenómeno. En adición a la respuesta lineal y las frecuencias de resonancia se observan respuestas constantes alrededor de los 10 Hz (banda alfa) y la aparición de hasta tres armónicos y un subarmónico.

3.1.2. Modulación en amplitud y fase, sensibilidad al estímulo

Debido al alto nivel de integración de la información que se realiza en la corteza del cerebro, particularmente en la corteza visual, varios estudios fisiológicos han determinado qué características del estímulo generan cada una de las partes de la respuesta compleja del SSVEP [4]. Los cambios en la amplitud de la respuesta de estado estacionario como resultado de la atención selectiva son investigados en [6]. Con este fin un experimento fue conducido registrando la señal de EEG durante la presentación de dos estímulos simultáneos distintos al tiempo que se ejecuta una *tarea de atención* (identificación de un caracter/número). Los resultados muestran que dicho cambio existe y que es posible que los usuarios de una BCI basada en SSVEP aprendan a controlar la amplitud de la respuesta.

Por otra parte el control de un estimulador eléctrico funcional (FES) para modificar el ángulo de flexión en la articulación de la rodilla, fue exitosamente implementado con la detección de dos umbrales de amplitud para la respuesta evocada por un único estímulo visual intermitente [7]. Los resultados de ese trabajo muestran que los sujetos participantes lograron desarrollar estrategias para la atenuación conciente y voluntaria de la respuesta evocada e incluso utilizar una combinación de corrimientos en fase (entre los electrodos O1 y O2) para lograr esta modulación.

3.1.3. Presentación de estímulos

Esta tarea es importante dentro de una BCI basada en SSVEP pues comprende la mitad de la vía de comunicación cerebro-computadora, por lo tanto es importante prestar especial atención a la frecuencia de estímulo y la precisión con que se muestra al sujeto, para poder detectar las diferentes respuestas y traducirlas en comandos. Se pueden dividir las técnicas de estímulo en dos tipos: soluciones de hardware específico y soluciones de propósito general. Como su nombre lo indica, las primeras son las técnicas que hacen uso de un hardware específicamente diseñado para el control y presentación del estímulo y las segundas utilizan el hardware ya existente, principalmente de una PC, para mostrar el estímulo al usuario de la BCI.

- Soluciones de hardware específico
 - *LED controlados por generadores de funciones.* La forma clásica de presentar un estímulo visual es con el uso de anteojos especiales con diodos emisores de luz (LED) en cada una de las piezas oculares. Esta solución ha sido utilizada para la investigación de los SSVEP y otros tipos de VEP fuera del contexto de las BCI. Un sistema de este tipo fue utilizado para generar la respuesta de estado estacionario

durante el experimento reportado en [5]. Esta es una forma efectiva de generar los SSVEP, sin embargo para su uso como parte de una BCI este sistema no es práctico.

- *Tableros LED.* El uso de LED y el control con un *generador de funciones* fue adaptada a las BCI. Manteniendo la idea de evocar un SSVEP con LED, no depender de los anteojos e incrementar el número de objetivos (frecuencias de estímulo asociadas con un comando) se han utilizado tableros con arreglos de LED. Este tipo de estimuladores controlados aún por generadores (PIC, FPGA, ROM, etc) se utilizan en [8, 9, 10, 11], además una variante que utiliza lámparas fluorescentes moduladas en intensidad y colocadas detrás de paneles difusores se utiliza en [7].
- Soluciones de propósito general
 - *Desarrollo propio.* Estas implementaciones hacen uso del hardware estándar de una computadora personal y por lo tanto pueden ejecutarse en cualquier PC que cumpla con los requisitos mínimos específicos. En general cada trabajo desarrolla una aplicación para la presentación de estímulos junto con el paradigma o la aplicación de la BCI. Estas aplicaciones incluyen a un estimulador escrito en C++ como parte de una BCI en tiempo real [12], el código para un juego de video controlado por la BCI incluyendo el despliegue de estímulos a bajas frecuencias dentro de un ambiente 3D [13], un teclado telefónico virtual que permite realizar llamadas a través del modem de una PC [14] y el control de un simulador de vuelo [7].
 - *Plataformas de propósito general.* El desarrollo de una aplicación específica o la escritura de código eficiente para el control de una PC puede ser una tarea difícil y actuar como un distractor del objetivo principal. Es por lo tanto útil contar con programas o plataformas que ofrezcan un lenguaje de alto nivel para el diseño de paradigmas y se encarguen del control del hardware. Una plataforma para desarrollo rápido de BCI basada en Matlab se reporta en [15]. También se encontraron referencias al programa para descripción de paradigmas Presentation [16] fuera del contexto de BCI.
 - *Desarrollo propio de soluciones de propósito general.* La presentación de frecuencias de estímulo certeras con el hardware estándar de una PC es el objetivo del trabajo presentado en [17]. Este trabajo presenta el desarrollo de un estimulador de este tipo y las pruebas de eficiencia del código resultante. Un resultado poste-

rior indica la posibilidad de evocar dos respuestas simultáneas con la presentación de un solo estímulo [18] .

3.2. Técnica de registro

3.2.1. Sistema de registro

El procesamiento de señales que identifica un estado mental y lo interpreta como un comando se ve beneficiado de utilizar señales de EEG o registros de la actividad eléctrica del cerebro con la mejor calidad posible. El avance de la instrumentación y la definición de estándares y la regulación de los sistemas de registro han generado numerosas soluciones al problema de la adquisición de datos de este tipo. Por lo tanto, se puede elegir de entre varias opciones un sistema de registro comercial que permita la fácil adquisición de estas señales con un buen nivel de SNR. Teniendo el suficiente cuidado de cubrir los requisitos de muestreo y de ancho de banda para evitar el *aliasing* cualquier sistema de registro existente puede utilizarse. Varios sistemas comerciales se han utilizado en experimentos o aplicaciones de BCI [5, 9, 11, 13, 19].

Otros trabajos en donde el objetivo es el desarrollo de tales sistemas, dedican gran parte de su esfuerzo en la validación del sistema [10]. El resto de los trabajos no especifica un sistema de registro, pero enumera los parámetros de registro utilizados, reforzando la hipótesis de que cualquier sistema que posea las características adecuadas puede ser utilizado.

3.2.2. Electrodo de registro

Debido a la localización anatómica de los SSVEP se utilizan electrodos sobre la región occipital de la cabeza. Específicamente se utilizan los electrodos O1 y O2 del estándar internacional 10–20 en configuraciones monopolares o bipolares. En la búsqueda de una mejor localización de las fuentes que intervienen en la generación de la respuesta de estado estacionario, un número elevado de electrodos es utilizado:

- 2 electrodos {Oz-A1} en configuración bipolar fueron utilizados para comprobar la evocación de un SSVEP [18]
- 3 electrodos en la configuración bipolar Oz-O2-P08 fueron utilizados para detectar la evocación del SSVEP [19]
- 13 electrodos del sistema 10–20 para investigar el cambio en amplitud cuando se realiza una tarea de atención [6]

- 19 electrodos para investigar la respuesta del cerebro humano en un amplio rango de SSVEP [5]
- 32 canales distribuidos en la cabeza con una mayor concentración en la región occipital (13 de 32 electrodos) se realizaron para determinar la configuración bipolar que maximiza la SNR[11].
- 64 o más electrodos pueden utilizarse en sistemas BCI de propósito general [15, 20]

En los trabajos citados se utilizan otros electrodos además del par O1-O2 para los diferentes objetivos de cada uno de ellos. Es notable que la BCI basada en SSVEP requiere solo uno de dos electrodos *estándar* para establecer la vía de comunicación.

3.3. Detección: extracción de características

3.3.1. Análisis en tiempo

Respecto a la descripción en el curso temporal de las épocas de EEG obtenidas durante el registro de cada sujeto, los modelos autorregresivos y autorregresivos adaptivos (AR y AAR, respectivamente) se han utilizado en trabajos previos [5, 13, 15]. El uso de modelos AR y AAR sobre las épocas de EEG que se analizan obtiene un conjunto de n coeficientes que describen la relación de las n muestras anteriores y la muestra actual de una señal discreta. Estos coeficientes representan a un filtro que se encarga de separar la señal del ruido. Por sus características, los SSVEP pueden representarse mejor en el dominio de la frecuencia.

3.3.2. Análisis en frecuencia

La mayoría de los trabajos relativos al análisis de SSVEP utilizan la Transformada Discreta de Fourier (DFT) en su implementación rápida (Fast Fourier Transform, FFT) para la detección de los picos relacionados con la frecuencia de estímulo. Debido a las posibles diferencias en fase y los cambios fisiológicos, como el tiempo de latencia cuando se evoca un SSVEP a partir de un estado basal o una diferente frecuencia, no se realiza una promediación en tiempo para evitar la interferencia destructiva. En cambio se analizan las épocas en el dominio de la frecuencia y se utilizan filtros para limitar la banda de análisis.

En general el espectro de potencia es calculado de las épocas de EEG obtenidas durante algún periodo de registro. Las épocas son preprocesadas con un banco de filtros con ancho de banda centrado en cada una de las frecuencias de estímulo y sus armónicos (si se incorporan) y los espectros son promediados. De esta forma el nivel de potencia en la banda del EEG basal se reduce en comparación con el ancho de banda del SSVEP.

3.3.3. Tiempo-frecuencia y otros análisis

Otro tipo de técnicas encontradas utilizan wavelets o átomos de wavelets (chirplets, específicamente) para describir a los potenciales visuales y caracterizarlos en tiempo y frecuencia a través del algoritmo de *matching pursuit* [21]. En otro caso se utilizan métodos de subespacios para encontrar un par de electrodos con la mayor correlación de ruido y la menor correlación de señal haciendo uso del análisis de componentes independientes (ICA) [11]. Métodos sofisticados de filtrado como el sistema *lock-in amplifier system* (LAS) es utilizado para extraer la amplitud del SSVEP e identificar su presencia en términos de la cantidad de potencia en el ancho de banda correspondiente. El sistema LAS es útil para extraer información de una señal en un ancho de banda muy pequeño donde además el ruido está relacionado con la frecuencia, considerando al EEG diferente del ruido blanco.

3.4. Detección: clasificadores

3.4.1. Detección por umbral

La forma más común de detectar la presencia de un SSVEP en una época de EEG a partir de su descripción en el dominio de la frecuencia, es el uso de un umbral de potencia. Partiendo de la detección de una potencia superior al umbral se sigue un conjunto de reglas de decisión que consideran un número de épocas identificadas por arriba del umbral, la relación potencia/potencia promedio y en ocasiones las detecciones anteriores [7, 8, 14, 12, 19, 22].

Este método de detección por umbral puede aplicarse a los casos donde se usa la FFT para la descripción espectral, la amplitud en μV si se utiliza promediación coherente y otros métodos (como LAS) donde se obtiene una medida de amplitud o distancia respecto a alguna referencia.

3.4.2. Discriminantes lineales

El clasificador que se utiliza con mayor frecuencia en las BCI basadas en SSVEP es el discriminante lineal. Una vez que se tienen los patrones que representan a cada época de EEG, un análisis de discriminante lineal (LDA) es realizado para encontrar el hiperplano que separa a las características de diferentes clases [9, 13, 15]. Como se sabe, el LDA sirve para dos clases solamente por lo que un conjunto de clasificadores debe entrenarse para los casos en que existen más de dos clases. Las variaciones de los LDA en los trabajos consultados corresponden a la forma en que estos son entrenados; encontrando como mejor entrenamiento el reportado en [9] donde se utilizan varias realizaciones de un algoritmo

(DSLVM) de agrupamiento (*clustering*) antes de entrenar al LDA. De esta forma se obtiene un clasificador más general que minimiza el problema de sobreajuste. Además se utilizan variantes como el discriminante multiclase canónico [10].

Capítulo 4

Metodología

En este capítulo se presenta la descripción del sistema implementado, nombrado LINI-BCI : SSVEP, los subsistemas que lo conforman y cómo se relacionan con el esquema general de una BCI. Se presenta también el método propuesto para la detección de los SSVEP y los experimentos realizados para validar el algoritmo con señales sintéticas, con señales puras y con varios registros de SSVEP de un sujeto entrenado y diecinueve sujetos sin entrenamiento¹. La figura 1.1 muestra el diagrama a bloques de una BCI en general, en este capítulo podemos observar un esquema similar en la figura 4.2 correspondiente al sistema LINI-BCI : SSVEP.

4.1. Estímulo y paradigma

El sistema LINI-BCI : SSVEP utiliza n comandos codificados en frecuencia, por lo que es necesario presentar $n - 1$ patrones de tablero (cuadros negros y blancos, aludiendo a los tableros de ajedrez) con $n - 1$ frecuencias de cambio de color diferentes que no sean armónicos, el n -ésimo comando es el EEG sin estímulo, también incluido como control de encendido o apagado para la BCI asincrónica. En general, el sistema utiliza un monitor (LCD o CRT) para la presentación de los estímulos, teniendo como limitantes las características técnicas del monitor, entre ellas la más importante la frecuencia de barrido vertical.

Para cada experimento y las futuras aplicaciones del sistema, se diseña un paradigma de estímulo diferente que esté relacionado de manera directa con los comandos necesarios para el control de la aplicación. Cada paradigma se programa y se despliega en el monitor utilizando el software Presentation[®] [16]. Como se menciona en el capítulo 3, Presentation[®] permite el control del hardware mediante un lenguaje de alto nivel.

¹Otros experimentos de SSVEP fueron realizados al mismo tiempo que este trabajo para explorar alternativas de procesamiento o paradigmas que no se incluyen en los objetivos de esta tesis. La descripción de estos experimentos se incluye en el apéndice D

Debido a las consideraciones necesarias de frecuencia de barrido, o frecuencia fundamental para las frecuencias de estímulo y la restricción de los armónicos, se escribió un compilador de Presentation[®] para la parte de la estimulación. Este compilador hace uso de la técnica *loop-unrolling* para escribir la secuencia de imágenes que resulta en un periodo de estímulo de $n - 1$ frecuencias y permite repetir el periodo escrito dentro de una estructura de control *for* reduciendo las variaciones en las frecuencias de estímulo.

El compilador referido en el párrafo anterior recibe como parámetros de entrada un vector con $n - 1$ frecuencias que se desean utilizar y la frecuencia de barrido vertical del monitor. El algoritmo de escritura aproxima las frecuencias a múltiplos de la frecuencia de barrido y encuentra la secuencia periodica que comprende la sincronía de los periodos de las $n - 1$ frecuencias. Una vez encontrada esta secuencia se genera un archivo de texto que contiene la descripción de la secuencia de imágenes resultante en el lenguaje de descripción de escenarios de Presentation[®].

El uso de este compilador permite obtener frecuencias muy cercanas a las reales. Un análisis de las frecuencias reales, medidas sobre el monitor y con un osciloscopio a la salida del puerto paralelo (LPT1) identificó un retardo debido al tiempo que toma al hardware para actualizar las salidas del puerto y en aproximar el tiempo de presentación descrito por el compilador. Considerando que estos retardos son determinísticos se escribió una secuencia de presentación de las imágenes donde cada frecuencia es un múltiplo primo de la frecuencia fundamental (frecuencia de barrido), evitando el aliasing en los armónicos y mejorando la periodicidad del estímulo visual.

Los paradigmas utilizados en cada uno de los experimentos se encuentran descritos en la sección correspondiente a cada experimento, el código de los escenarios escritos para Presentation[®] se muestra en el apéndice A

4.2. Adquisición y almacenamiento

El diseño de LINI-BCI : SSVEP considera que una BCI necesita ser portátil y fácil de usar. Además, se debe tomar en cuenta que la tarea de colocar correctamente los electrodos de registro es larga y tediosa para un número grande de electrodos. Estas consideraciones guiaron el diseño del sistema hacia el uso de pocos electrodos para el registro y de un tipo de amplificadores pequeños que permitan obtener señales útiles y libres de ruido de forma sencilla.

Se utilizan los electrodos O_1 y O_2 del estándar internacional 10 – 20 y un amplificador g.USBamp [23] para la digitalización de la señal. De esta forma, el subsistema básico de adquisición (utilizando sólo un amplificador) puede adquirir señales de 16 fuentes de forma

independiente durante la ejecución de una tarea o control de una aplicación. Los amplificadores se configuran utilizando el software BCI2000 [24], que a su vez se encarga de realizar el almacenamiento de los datos en el disco duro de la PC que corre el programa.

La configuración en particular que se utilizó para cada experimento está descrita en la sección correspondiente a cada experimento y en el resumen de el cuadro 4.1.

4.3. Reconocimiento de Patrones

En el desarrollo de esta tesis así como en la etapa actual del sistema LINI-BCI el análisis de los datos y por lo tanto el reconocimiento de patrones, se realiza fuera de línea. El sistema permite realizar registros de diferentes paradigmas y probar los algoritmos propuestos para su solución. En el caso de LINI-BCI : SSVEP, el subsistema de reconocimiento de patrones comprende los siguientes procesos.

4.3.1. Preprocesamiento

Ningún tipo de preprocesamiento es aplicado además del filtrado durante la adquisición, es decir, no existe filtrado por bandas, submuestreo o rechazo de artefactos de ningún tipo. Esta decisión fue tomada debido a que una BCI debe simplificarse para el uso diario y el funcionamiento de esta debe ser robusto para tener un buen desempeño aún en condiciones adversas de ruido. La adición de métodos automáticos de preprocesamiento no está excluida para futuras versiones.

4.3.2. Método para detección de SSVEP: MUSIC + SVM

El sistema LINI-BCI : SSVEP implementa un nuevo algoritmo para la detección de los SSVEP haciendo uso del algoritmo MUSIC [25, 26] para generar la representación de cada nuevo registro de EEG en el dominio de la frecuencia y clasificando esta representación mediante Máquinas de Soporte Vectorial (SVM). A continuación se describe el algoritmo de MUSIC y su implementación fuera-de-línea, las SVM y su uso en LINI-BCI : SSVEP.

MUSIC

El algoritmo MUSIC es un método de proyección a subespacios que utiliza el hecho de que para una señal observada $x[n]$ compuesta por una senoidal $s[n] = Ae^{j\omega_s n}$ de frecuencia ω_s , embebida en ruido blanco $\eta[n]$

$$x[n] = s[n] + \eta[n] \quad (4.1)$$

la senoidal $e^{j\omega_s n}$ es un eigenvector de la matriz de correlación $R_x = E\{\mathbf{x}\mathbf{x}'\}$ de la secuencia observada.

$$R_x \mathbf{s} = \lambda \mathbf{s} \quad (4.2)$$

donde $\mathbf{s} = [1, e^{j\omega_s}, e^{j2\omega_s}, \dots, e^{j(N-1)\omega_s}]'$.

Debido a que el resto del eigenespacio (*subespacio de ruido*) es ortogonal a la senoidal observada, así como para cualquier senoidal de diferente frecuencia, ω_k , la proyección de $x[n]$ sobre el subespacio de ruido tendrá un valor muy cercano a cero. Cualquier señal que no contenga a la senoidal a la frecuencia de referencia tendrá una proyección diferente de cero en el mismo subespacio de ruido.

Basado en el hecho anterior, se realiza una descomposición en componentes principales (PCA) $R_x \nu = \Lambda \nu$, para encontrar los eigenvectores, $\nu = [\mathbf{e}_0 \dots \mathbf{e}_{N-1}]$, de la matriz de correlación estimada y sus correspondientes eigenvalores, $\Lambda = \text{diag}(\lambda_i)$.

Aquellos eigenvectores asociados con los eigenvalores menores o iguales a algún umbral elegido, σ_0 , son seleccionados para formar la base del subespacio de ruido, E_{ruido} :

$$E_{ruido} = [\mathbf{e}_{N-(M+1)} \dots \mathbf{e}_{N-1}] \quad (4.3)$$

donde

$$\lambda_k \leq \sigma_0, k \in \{N - (M + 1) : N - 1\}. \quad (4.4)$$

Para probar si la senoidal a la frecuencia de interés ω está contenida en la señal se genera un vector de prueba W :

$$W = [1 \ e^{j\omega} \dots e^{j(N-1)\omega}]' \quad (4.5)$$

El siguiente paso en el algoritmo es calcular el pseudo-espectro de $x[n]$, evaluando la función:

$$\hat{P}(e^{j\omega}) = \frac{1}{W^{*'} E_{ruido} E_{ruido}^{*'} W} \quad (4.6)$$

que estima la inversa de la norma de la proyección de W en el subespacio de ruido. Cuando $\omega = \omega_s$, debido a que W es ortogonal al subespacio de ruido, su proyección sobre E_{ruido} es cercana o igual a cero, por lo tanto la función $\hat{P}(e^{j\omega})$ mostrará un pico a la frecuencia ω_s . Es importante remarcar que $\hat{P}(e^{j\omega})$ no es un estimador espectral debido a que no proporciona información acerca de la potencia de la señal, sin embargo es útil para identificar las frecuencias contenidas en una señal. Valores del pseudospectro en frecuencias seleccionadas pueden

ser utilizadas para describir el contenido de una señal observada. La figura 4.1 muestra un diagrama del algoritmo MUSIC.

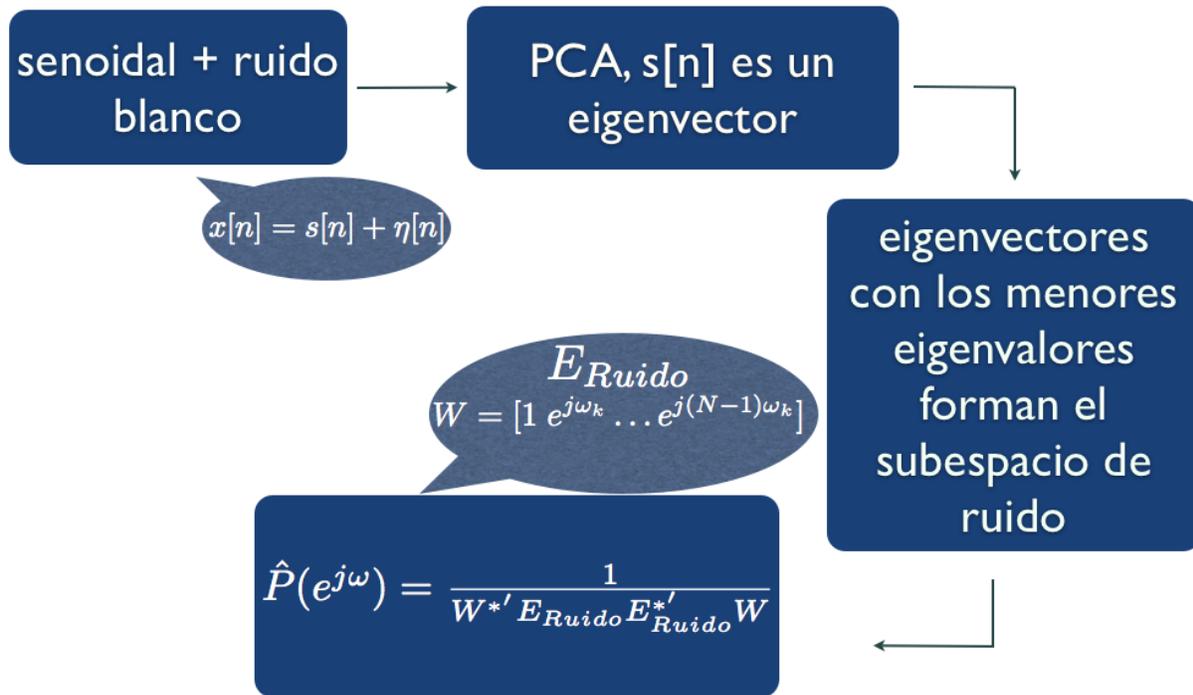


Figura 4.1: Algoritmo MUSIC. Asumiendo un modelo de la señal $x[n] = s[n] + \eta[n]$, donde $s[n] = Ae^{j\omega_i}$ y $\eta = ruido\ blanco$, se aplica un análisis de componentes principales (PCA) para obtener los eigenvalores y eigenvectores de la matriz de correlación de $x[n]$. Se selecciona el subespacio de ruido formado por los eigenvectores asociados con eigenvalores menores o iguales a un umbral determinado y se genera un vector de prueba W para obtener el valor del pseudo-espectro en la frecuencia ω_k . Si la frecuencia ω_k está presente en la señal, $\hat{P}(e^{j\omega})$ mostrará una espiga en ese valor.

Implementación

La extracción de características para cada una de las épocas de EEG bajo análisis es realizada por una función escrita en Octave [27], en la cual por cada segundo de registro se estima la matriz de correlación generando una matriz Toeplitz a partir de los coeficientes de autocorrelación. Se obtienen luego los eigenvalores y eigenvectores de esta matriz y se selecciona el subespacio de ruido de acuerdo a un umbral determinado por el usuario. El parámetro de salida de la implementación es un vector que contiene los valores del pseudo-

espectro a los valores de $[0.5, 1, 2, 3] * f_i \forall i$ donde f_i es cada una de las frecuencias de estímulo. La implementación del algoritmo fue probada con señales sintéticas y senoidales puras digitalizadas. Las pruebas del algoritmo se encuentran en el apartado de experimentos.

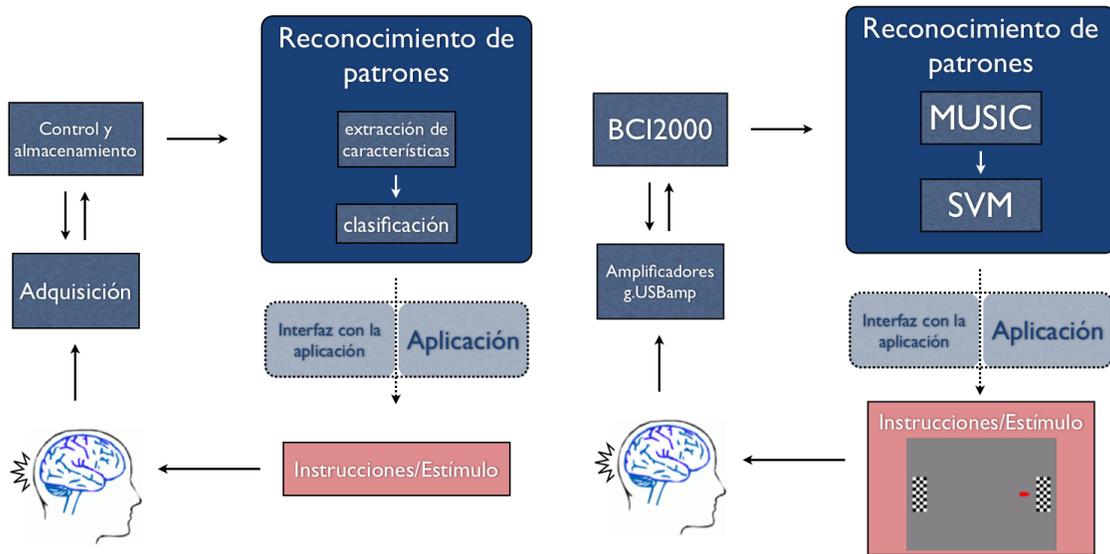


Figura 4.2: Diagrama a bloques del diseño de LINI-BCI : SSVEP (izq.) y la solución al diseño (der.) NOTA: Los bloques en líneas punteadas no son relevantes para la implementación fuera de línea y no forman parte de este diseño.

SVM

Una Máquina de Soporte Vectorial (SVM) [28] es un clasificador binario definido por un hiperplano descrito mediante un vector de pesos \mathbf{w} y un término de sesgo (bias) b . Basado en un conjunto de l patrones descritos por los vectores \mathbf{x}_i y sus correspondientes etiquetas y_i :

$$(\mathbf{x}_1, y_1) \dots (\mathbf{x}_l, y_l) \in \mathbb{R}^N \times \{-1, 1\} \quad (4.7)$$

los algoritmos de reconocimiento de patrones encuentran tal hiperplano siguiendo algún criterio de optimización. En este trabajo la minimización es resuelta con un método basado en la minimización secuencial óptima (SMO) [29]. Con esta información la etiqueta de un nuevo patrón \mathbf{x} se encuentra verificando el signo de la proyección de \mathbf{x} sobre \mathbf{w} :

$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b \quad (4.8)$$

esta proyección indica la pertenencia a las clases $\{C_1, C_{-1}\}$. Como puede deducirse existen múltiples soluciones para la división entre clases pero las SVM encuentran el hiperplano de margen máximo que corresponde al hiperplano con el mayor margen de separación γ (fig. 4.3). Para describir a este hiperplano, solo se necesitan los patrones que forman la frontera entre las clases, llamados *vectores de soporte*.

La representación canónica del hiperplano tiene la siguiente restricción $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \leq 1$ para encontrar el margen $\gamma = 2/\|\mathbf{w}\|$, por lo tanto, maximizar γ es equivalente a minimizar $(1/2)\|\mathbf{w}\|^2$.

Las restricciones definidas no permiten la convergencia del algoritmo para clases no linealmente separables. Para permitir violaciones a estas restricciones se define el problema de optimización de *margen suave* y se introducen las variables de relajación (*slack-variables*) ξ_i y de regularización C :

$$\min \frac{1}{2}\|\mathbf{w}\|^2 + C \sum_i \xi_i \quad (4.9)$$

con la restricción $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \leq 1 - \xi_i$, $\xi_i > 0 \forall i$. Un valor alto de C corresponde a una mayor penalización de las violaciones. El problema de la minimización de la ec. 4.9 puede reescribirse haciendo uso de los multiplicadores de Lagrange (positivos) α_i . La representación lleva a:

$$L_D = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (4.10)$$

con las restricciones $0 < \alpha_i < C$ y $\sum_i \alpha_i y_i = 0$ nos lleva a:

$$\mathbf{w} = \sum_i^{N_s} y_i \alpha_i \mathbf{x}_i \quad (4.11)$$

donde N_s representa el número de vectores de soporte. Sustituyendo la ec. 4.11 en la ec.4.8 obtenemos:

$$f(\mathbf{x}) = \sum_i^{N_s} y_i \alpha_i (\mathbf{x} \cdot \mathbf{x}_i) + b. \quad (4.12)$$

Se ha demostrado [30] que la sustitución del producto punto $\mathbf{x} \cdot \mathbf{x}_i$ por la función núcleo, positiva definida y simétrica, $K(\mathbf{x}, \mathbf{x}_i)$ lleva a una transformación implícita del espacio de

características, normalmente de mayor dimensión, donde puede obtenerse una tasa de clasificación más alta al aumentar la posibilidad de separar linealmente las clases con menor error. Esto resulta en un discriminante no lineal:

$$S(\mathbf{x}) = \sum_i^{N_s} y_i \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (4.13)$$

Este desarrollo lleva a una frontera de decisión no lineal en el espacio de características original, pudiendo incrementar la tasa de clasificación.

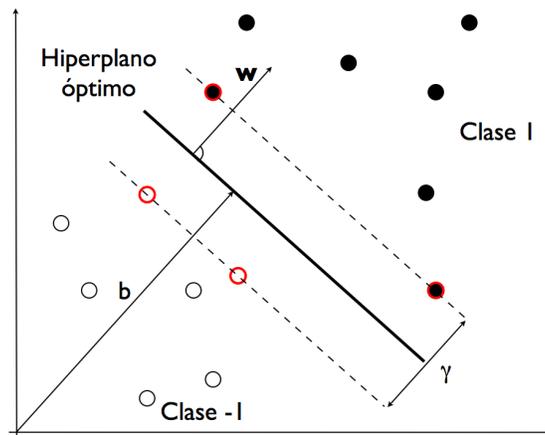


Figura 4.3: Las SVM encuentran el hiperplano óptimo (línea sólida) que separa a dos clases mediante la maximización del margen γ . El hiperplano puede describirse en términos del vector \mathbf{w} y el sesgo b , sólo los *vectores de soporte* (borde rojo) son necesarios para encontrar \mathbf{w} y b . (adaptado de [28])

4.3.3. Medidas de desempeño

Matrices de confusión

Los resultados del entrenamiento de un clasificador binario asocian una clase a cada patrón del conjunto de entrenamiento (en la clasificación supervisada) mediante la evaluación de la regla de decisión, en este caso descrita por la ec. 4.13. De estos resultados pueden identificarse cuatro casos:

- Verdaderos positivos (TP), patrones que se etiquetan como C_1 y pertenecen C_1
- Verdaderos negativos (TN), patrones que se etiquetan como C_{-1} y pertenecen C_{-1}
- Falsos positivos (FP), patrones que se etiquetan como C_1 y pertenecen C_{-1}

- Falsos negativos (FN), patrones que se etiquetan como C_{-1} y pertenecen C_1

Estos valores pueden acomodarse en una matriz para su visualización

$$\begin{pmatrix} TP & FP \\ FN & TN \end{pmatrix}$$

esta matriz se denomina *matriz de confusión*. Con esta matriz podemos definir las siguientes medidas:

- Certeza, $ACC = (TP + TN)/(TP + FN + TN + FP)$
- Tasa de TP, $TPR = TP/P = TP/(TP + FN)$
- Tasa de FP, $FPR = FP/N = FP/(FP + TN)$

Estos valores indican qué tan bien se identifica a los patrones de las clases C_1 y C_{-1} con un clasificador específico. Donde ACC sirve como resumen de esta información pues presenta el promedio de los patrones correctamente clasificados. Sin embargo este valor puede sesgarse si se consideran clases con prevalencias diferentes,

$$P(\mathbf{x} \in C_1) \neq P(\mathbf{x} \in C_{-1}) \quad (4.14)$$

En general, la prevalencia en una BCI no es la misma para todas las clases por lo que se requiere de una medida además de la certeza. Por otra parte, podemos observar que TPR indica la relación de patrones que fueron identificados en C_1 entre todos los patrones pertenecientes a esa clase y FPR indica la relación de patrones en C_{-1} que fueron mal clasificados entre todos los que pertenecen a C_{-1} . Por lo tanto es obvio que un clasificador minimizará el valor de FPR y maximizará el valor de TPR.

ROC y A_z

Podemos definir un punto de operación en el plano descrito por FPR y TPR, y su comportamiento al variar el umbral de clasificación. Para evaluar el comportamiento del clasificador y localizar el mejor punto (valor del umbral) para su operación. De esta forma definimos la *curva de características relativas de operación* (ROC) para un clasificador [31, 32]. En un enfoque Bayesiano, podemos observar que la ROC ideal es aquella que sigue los márgenes izquierdo y superior del plano descrito por FPR y TPR. También podemos encontrar que la recta que pasa por (0,0) y (1,1) con pendiente igual a 1 indica la línea de azar, el comportamiento aleatorio de un clasificador binario.

Para un clasificador binario cualquiera se puede obtener una medida de su desempeño (que tanto se aproxima a la curva ideal) si se compara el área bajo su ROC (A_z) con el valor ideal 1. La fig. 4.4 muestra el espacio de la curva ROC y las definiciones citadas arriba. Una herramienta para comparar el comportamiento de un clasificador con la ROC ideal es el estadístico de Wilcoxon, que mide la similitud de las etiquetas asignadas por el clasificador y la pertenencia real de cada patrón a las clases C_1 y C_{-1} [33].

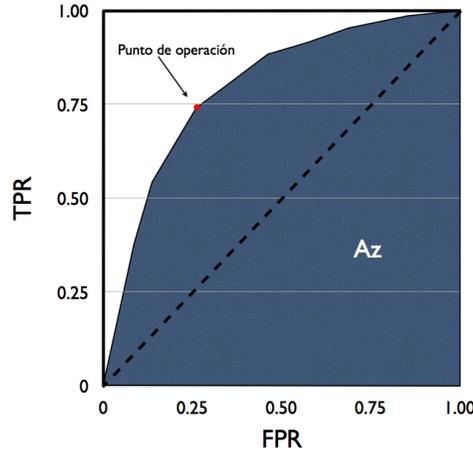


Figura 4.4: ROC y A_z . En el plano descrito por FPR y TPR se define la curva de características relativas de operación, en la figura se muestra la línea de azar (línea punteada), la ROC ideal (línea sólida), un ejemplo de punto de operación (punto rojo) y el área asociada a un clasificador (área sombreada).

4.4. Experimentos

4.4.1. Validación de MUSIC I: Señales sintéticas

Para probar la implementación del algoritmo MUSIC, se generó un conjunto de senoidales discretas $s[n]$, a 25, 38, 40 y 75 Hz con una frecuencia de muestreo de 256 Hz. Se obtuvieron treinta épocas de un segundo para cada una de las frecuencias y se mezclaron de forma aditiva con ruido blanco $\eta[n]$. Los valores de ruido y las senoidales fueron escalados al intervalo $[-1,1]$ antes de ser sumadas. Se probaron diez valores de relación señal a ruido (SNR) en el rango $\{33.68, -57.55\}$ dB. Para todas las épocas se obtuvieron los pseudo-espectros utilizando MUSIC y los espectros de potencia para la Transformada Discreta de Fourier (DFT) de 1024 puntos. Los valores de SNR fueron estimados como el cociente de las varianzas de las señales $SNR = 20 * \log(\text{var}(s[n])/\text{var}(\eta))$.

Un segundo conjunto de prueba fue generado sumando aleatoriamente las 30 señales de

cada frecuencia, de forma que cada miembro $t_i[n]$ del nuevo conjunto de prueba contuviera información de las cuatro frecuencias investigadas. La información frecuencial fue extraída utilizando MUSIC y DFT de la misma forma que para el primer conjunto.

4.4.2. Validación de MUSIC II: Senoidales puras

Utilizando una configuración básica del sistema BCI2000-g.USBamp se digitalizaron quince segundos de ondas senoidales directamente de la salida de un generador de funciones. La adquisición de las señales se realizó con una frecuencia de muestreo de 256 Hz con los filtros de los amplificadores como un pasa-banda entre $\{0.1-30\}$ Hz y un rechaza-banda entre $\{50-70\}$ Hz, ambos filtros Butterworth de segundo orden. Las frecuencias seleccionadas fueron $\{0.4, 1.2, 2.2, 3.1, 4.0\}$, $\{4, 13, 18, 22, 27, 32, 37, 42, 47\}$ y $\{42, 60, 76, 88, 126\}$ Hz de acuerdo con las características del generador. Todas las senoidales fueron generadas con la misma amplitud; los valores de frecuencia que caen en la banda de rechazo de los filtros fueron adquiridas para probar el desempeño de cada algoritmo de descripción espectral.

Una vez adquiridas, las señales fueron concatenadas y convertidas utilizando la herramienta BCI2ASCII. Un conjunto de 306 épocas de un segundo de duración fue formado y se calculó la DFT de 1024 puntos luego de remover la tendencia de cada época; el pseudo-espectro de MUSIC fue obtenido sin ningún tipo de preprocesamiento.

4.4.3. Método de detección para SSVEP: dos clases

Datos

Doce registros de los SSVEP de un sujeto entrenado fueron proporcionados por el Dr. Brendan Allison del Scripps Research Institute en La Jolla, California y el Dr. Jonathan Wolpaw del Wadsworth Center en Albany, Nueva York. Los registros fueron obtenidos con una gorra de EEG de 64 electrodos, todos los canales fueron referenciados a un electrodo colocado en el lóbulo de la oreja derecha y un electrodo detrás del mastoideo derecho fue tomado como tierra. La frecuencia de muestreo fue de 160 Hz y los datos se filtraron con un pasa-banda entre $\{0.1-50\}$ Hz. El registro se realizó en un área de trabajo con condiciones de distracción no controladas. Los SSVEP fueron inducidos con dos patrones de inversión de tablero oscilando a $f_1 = 6$ Hz y $f_2 = 15$ Hz.

Extracción de características

Los patrones se representaron como los valores del pseudo-espectro MUSIC a $[0.5, 1, 2, 3] * f_i$ para cada frecuencia de interés. La separación del subespacio de señal y de ruido se

logró con la división de los eigenvectores de acuerdo a su varianza explicada (eigenvalores). El umbral de selección σ_0 se determinó experimentalmente como

$$\sigma_0 = u \sum_{i=0}^{N-1} \lambda_i \quad (4.15)$$

donde $u = 0.1$

Clasificación

Se formó un conjunto de 240 épocas de un segundo registradas en los electrodos $O1$ y $O2$ del estándar internacional 10-20 a partir de los datos disponibles (64 canales). Todas las épocas se procesaron con MUSIC para obtener los patrones que las representan en frecuencia, estos patrones se promediaron en diferente número para observar el desempeño de la clasificación como función del número de épocas utilizadas. SVM [29] con núcleo lineal (lin-SVM) y de función de base radial (rbf-SVM) fueron entrenadas y su desempeño fue medido por estimaciones de certeza en un esquema *leave-one-out*.

4.4.4. Método de detección para SSVEP: tres clases

Datos

Las señales de los electrodos $O1$ y $O2$ fueron adquiridas con el sistema LINI-BCI : SSVEP con los filtros configurados como pasa-banda entre $\{0.1-30\}$ Hz y rechaza-banda entre $\{50-70\}$ Hz. Los electrodos de referencia y tierra se mantuvieron en el lóbulo de la oreja derecha y el mastoideo derecho, respectivamente. La respuesta de diez sujetos fue adquirida a 256 Hz mientras recibían estímulo visual con un monitor LCD que desplegaba patrones de tablero oscilando a 25 y 38 Hz.

El registro de todos los sujetos fue realizado en un área de trabajo bien iluminada. Durante los registros existieron distracciones ocasionales, como personas hablando y al menos dos personas en la misma área; además hubo música en el fondo con un volumen bajo pero audible. A todos los sujetos se les explicó el paradigma y recibieron instrucciones de lo que debían hacer. Ninguno tenía antecedentes de participar en un registro similar.

Paradigma de estímulo

Se definieron dos comandos codificados en frecuencia: C_1 y C_{-1} ; y un tercer comando: C_0 , sin estímulo presente considerado como EEG espontáneo. Los estímulos oscilatorios fueron

presentados a todos los sujetos de acuerdo con el paradigma experimental comprendido por los siguientes estados:

i Espera, periodo antes del inicio de la adquisición.

Repetir seis veces:

ii Descanso, (10 s) registro sin estímulo.

iii Indicación de objetivo, (5 s) una flecha indica el objetivo a atender, sin estímulo

iv Estímulo, (30 s) todos los objetivos oscilando a diferentes frecuencias

v Descanso, (10 s) registro sin estímulo

La figura 4.5 contiene un diagrama de los estados del paradigma descrito en este apartado y la figura 4.7 el diagrama de tiempo la ejecución de uno de los ciclos.

Extracción de características

Mismo esquema que el detallado en la sección 4.4.3, valores del pseudo-espectro MUSIC calculados en $[0.5, 1, 2, 3] * f_i$, con los valores de umbral: $u = 0.1$ y $u = 0.05$ (ec. (4.15)).

Clasificación

Se utilizaron tres representaciones de los patrones en función del electrodo utilizado durante la extracción de características: características extraídas del electrodo $O1$ (F_{O1}), características extraídas del electrodo $O2$ (F_{O2}) y la concatenación de F_{O1} y F_{O2} ($F_{[O1O2]}$). SVM para decisión binaria fueron entrenadas para cada par de clases: C_1 vs C_{-1} , C_1 vs C_0 y C_{-1} vs C_0 y para cada valor de σ_0 . Para medir el desempeño se realizaron estimaciones de la certeza de clasificación (ACC) y el área bajo la curva ROC (A_z) utilizando validación cruzada (CV) de 6 vías.

4.4.5. Método de detección para SSVEP: cuatro clases

Datos

Se adquirió la respuesta de nueve sujetos con 15 electrodos del estándar 10 – 20 mientras atendían a un estímulo de cuatro clases que simulará el control de una aplicación específica². La adquisición de los datos se realizó con una implementación del sistema LINI-BCI : SSVEP,

²En este caso una silla de ruedas en un ambiente virtual en un trabajo posterior a realizarse en colaboración con la Universidad Nacional de Entre Rios en Argentina

utilizando un monitor de CRT los sujetos atendieron a uno de cuatro estímulos a la vez. La digitalización fue realizada a 256 Hz con los filtros de los amplificadores en configuración pasa-banda entre $\{0,1 - 50\}$ Hz y un rechaza-banda entre $\{40 - 60\}$ Hz. Todos los registros se realizaron en un lugar de trabajo con buena iluminación y sin aislamiento acústico.

Paradigma de estímulo

Se definieron cuatro estímulos codificados en frecuencia $\{C_I, C_D, C_A, C_S\}$ correspondientes a cuatro comandos para controlar una silla de ruedas robótica: izquierda, derecha, avanzar y detener, respectivamente. Las frecuencias de estos comandos fueron $\{6, 8.5, 14.2, 42.5\}$. En esta aplicación la BCI permite al usuario utilizar comandos de alto nivel y el sistema robótico se encarga de tomar las decisiones sobre la viabilidad del curso y la mejor estrategia para cubrirlo. Este experimento corresponde a la primera etapa de la aplicación y solamente incluye la detección de uno de los cuatro estímulos fuera de línea.

El paradigma presentado a los sujetos comprende los siguientes estados:

i Descanso, (10 s) registro sin estímulo.

Repetir ocho veces :

ii Indicación de objetivo, (3-5 s) sin estímulo

iii Estímulo, (15 s) todos los objetivos oscilando a diferentes frecuencias

iv Reposo, (3-5 s) sin estímulo

v Descanso, (10 s) de registro sin estímulo

La figura 4.6 contiene diagrama de los estados de este paradigma y la figura 4.8 el diagrama de tiempo de la ejecución del primer ciclo.

Extracción de características

Mismo esquema que el detallado en la sección 4.4.3, valores del pseudo-espectro MUSIC calculados en $[0.5, 1, 2, 3] * f_i$, con los valores de umbral: $u = 0.1$ y $u = 0.5$ (ec. (4.15)).

Clasificación

Se utilizaron los electrodos O_1 , O_2 y O_z del estándar 10 – 20 para la extracción de características, generando tres representaciones de cada patrón: F_{O_1} , F_{O_2} y F_{O_z} . Estas representaciones fueron clasificadas por una lin-SVM por clase en un esquema de clasificación uno contra todos. Medidas de ACC y A_z fueron estimadas por CV de 3 vías.

Cuadro 4.1: Resumen de los parámetros de cada experimento: frecuencia de muestreo (Hz), frecuencias de corte (Hz) de los filtros, pasa-banda y rechaza-banda, número de clases en cada experimento, número de épocas por conjunto de datos, número de frecuencias de estímulo, tamaño del vector de características obtenido para cada época, electrodos utilizados en el registro de EEG, valor del umbral de MUSIC, tipo de SVM entrenadas, medidas de desempeño utilizadas (ACC , A_z) y número de vías de la CV.

	MUSIC I	MUSIC II	SSVEP 2	SSVEP 3	SSVEP 4
f_s	256	256	160	256	256
$Filtro_1$	-	0.1-30	0.1-50	0.1-30	0.1-50
$Filtro_2$	-	50-70	-	50-70	40-60
clases	4	-	2	3	4
épocas	$x_i[n]: 30$ $t_i[n]: 30$	$x_j[n]: 306$	$C_1: 120$ $C_{-1}: 120$	$C_1: 90$ $C_0: 60$ $C_{-1}: 90$	$C_I: 60$ $C_D: 60$ $C_A: 60$ $C_S: 60$
i, f_i	4	19	2	2	4
patrón	$\{v_1 : v_4\}$	-	$\{v_1 : v_8\}$	$\{v_1 : v_8\}$	$\{v_1 : v_{16}\}$
electrodos	-	-	$O1$ $O2$	$O1$ $O2$	$O1$ $O2$ Oz
u_{MUSIC}	0.04 0.1 0.9	0.1 0.5	0.1	0.05 0.1	0.1 0.5
SVM	-	-	lin- rbf-	lin-	lin-
ACC	-	-	SI	SI	SI
A_z	-	-	NO	SI	SI
CV	-	-	<i>leave-one-out</i>	6	3

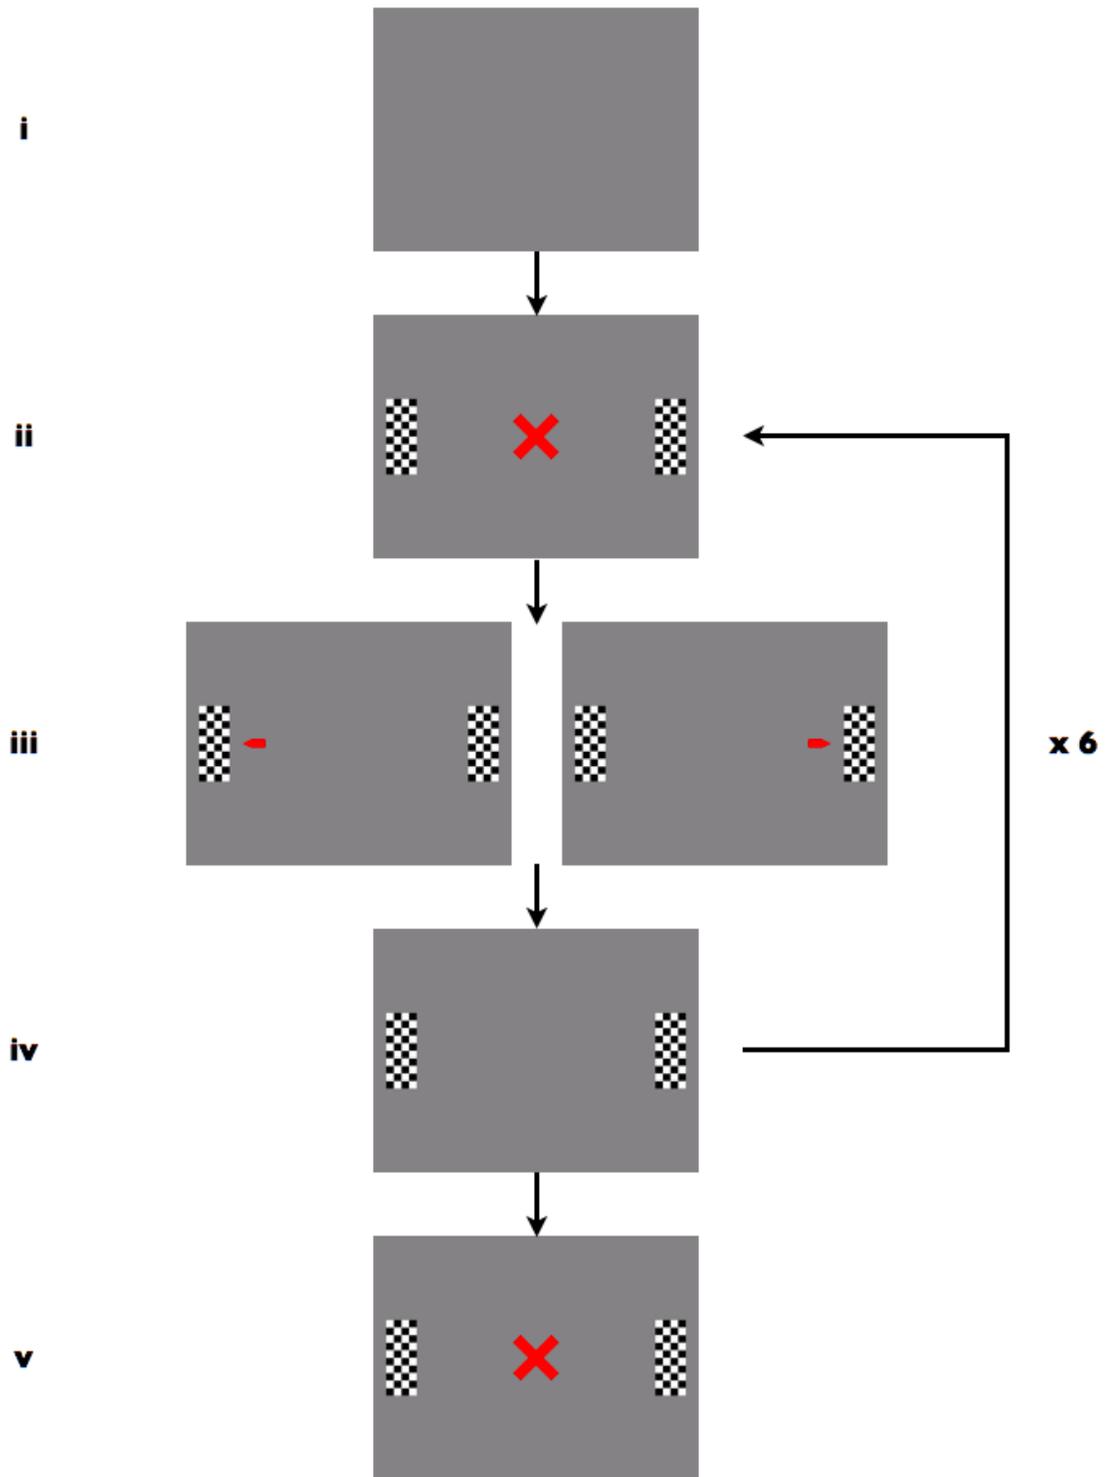


Figura 4.5: Estados del paradigma de estímulo para tres clases.

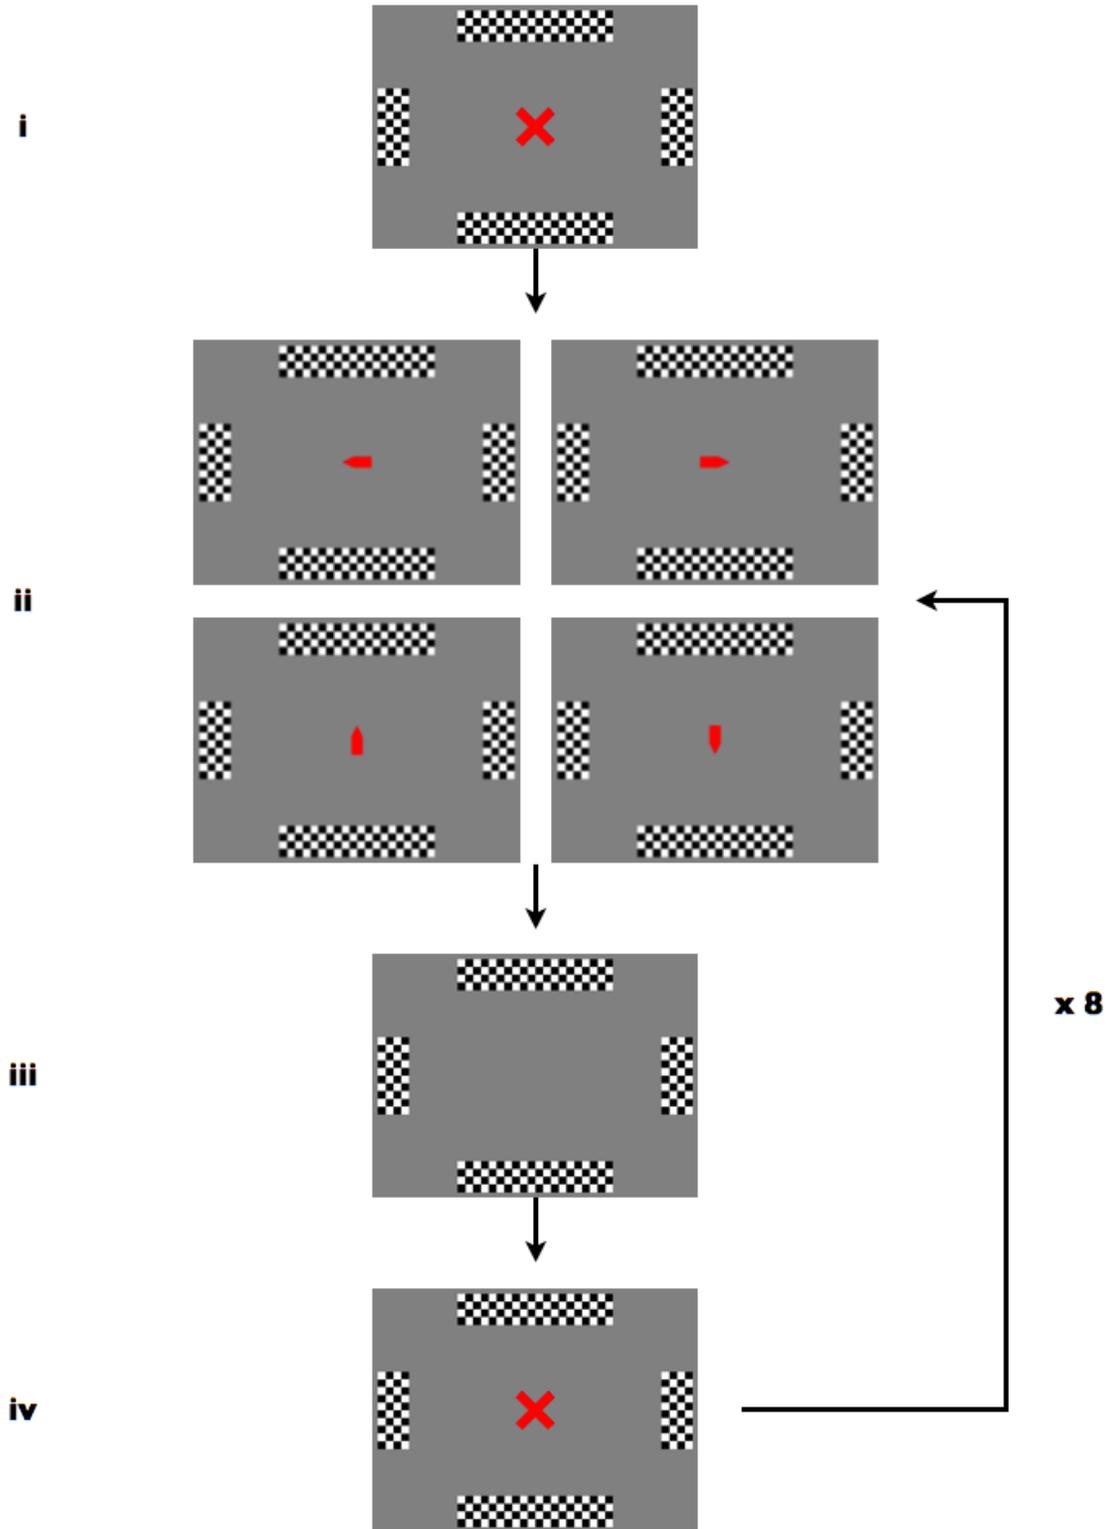


Figura 4.6: Estados del paradigma de estímulo para cuatro clases.

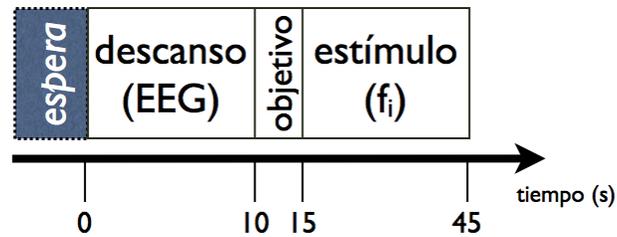


Figura 4.7: Diagrama de tiempo del paradigma de estímulo para tres clases. Al inicio del paradigma existe un periodo en el cual no se registra la actividad del sujeto, después, de forma secuencial se presentan los estados de descanso, indicación del objetivo y estímulo. Esta serie de estados ocurre seis veces y el paradigma finaliza con un estado de adicional de descanso.

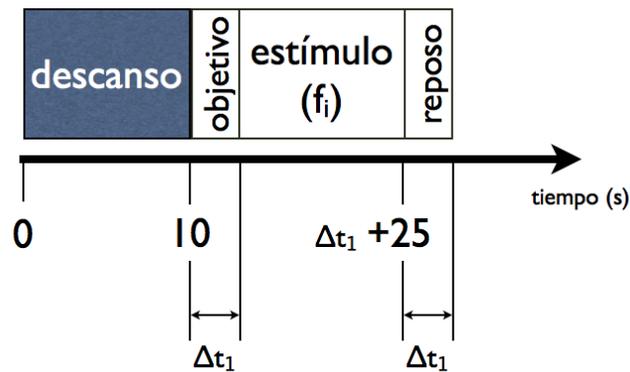


Figura 4.8: Diagrama de tiempo del paradigma de estímulo para cuatro clases. En $t = 0$, el inicio del registro y del paradigma, ocurre un estado de descanso y después una secuencia de estados similar a la descrita en el paradigma para tres clases, es decir: indicación del objetivo, estímulo y reposo. En este paradigma la duración de los estados de indicación y reposo es aleatoria, con un valor Δt_1 de entre 3 y 5 s. Esta secuencia se repite ocho veces y el paradigma termina con un último estado de descanso.

Capítulo 5

Resultados

5.1. Validación de MUSIC I: Señales sintéticas

Las fig. 5.1-5.4 muestran la representación en frecuencia de uno de los ensambles, x_1 , de señales sintetizadas (primer y segundo conjunto) con la DFT de 1024 puntos y con la implementación en Octave de MUSIC utilizando valores para el umbral $u \in \{0.1, 0.4, 0.9\}$. Recordando, cada uno de los ensambles del primer conjunto consisten en treinta senoidales a una frecuencia fija sumadas con ruido blanco para obtener un rango de valores de SNR. El segundo conjunto se forma con la suma aleatoria de un miembro de cada ensamble (cuatro ensambles con cuatro frecuencias diferentes). Los valores de estas frecuencias y el rango de SNR pueden leerse en el capítulo 4.

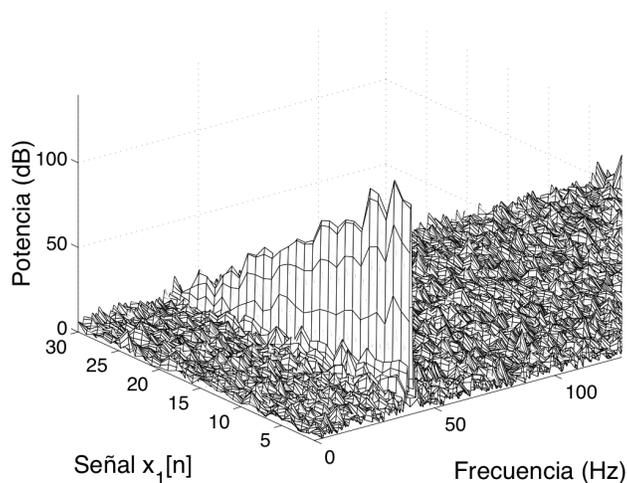


Figura 5.1: Transformada Discreta de Fourier (DFT) de 1024 puntos para las señales sintéticas del ensamble x_1 , senoidales a 38 Hz con diferentes valores de SNR.

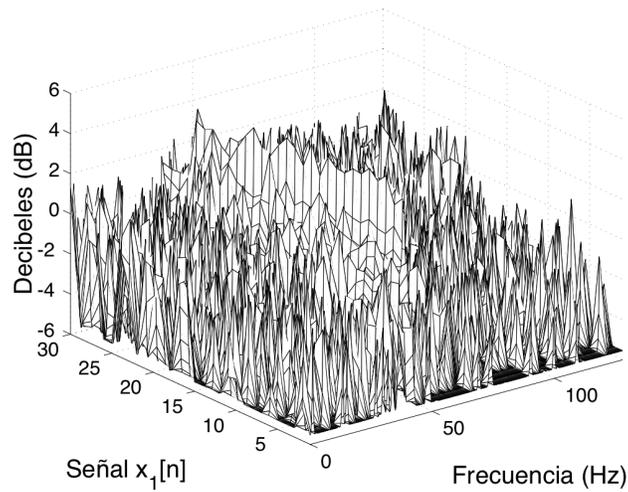


Figura 5.2: Pseudo-espectros para las señales sintéticas del ensamble x_1 , senoidales a 38 Hz con diferentes valores de SNR. El valor del umbral de MUSIC es $u = 0.1$, se observa una estabilidad relativa del componente de 38 Hz a lo largo de todo el ensamble y la aparición de componentes de ruido en todo el rango de 0 a 128 Hz.

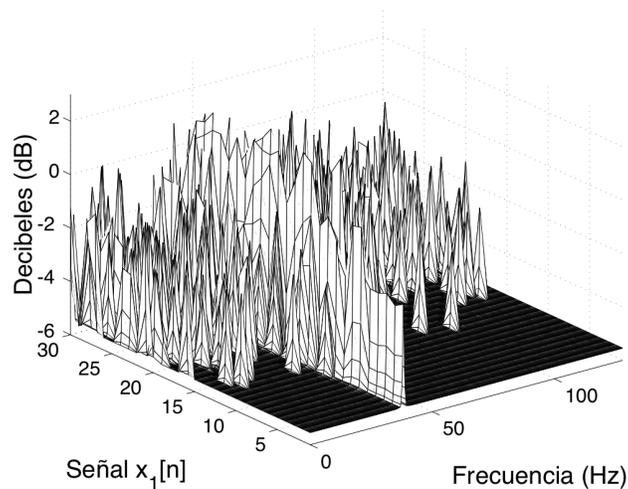


Figura 5.3: Pseudo-espectros para las señales sintéticas del ensamble x_1 , senoidales a 38 Hz con diferentes valores de SNR. El valor del umbral de MUSIC es $u = 0.4$, mayor que en la fig. 5.2. En esta representación los componentes de la frecuencia de interés (38 Hz) presentan una amplitud variable a lo largo del ensamble, manteniendo un valor superior al promedio. Obsérvese la desaparición o filtrado de los componentes de ruido ($\omega_i \neq 38$ Hz) en las señales con mayor SNR.

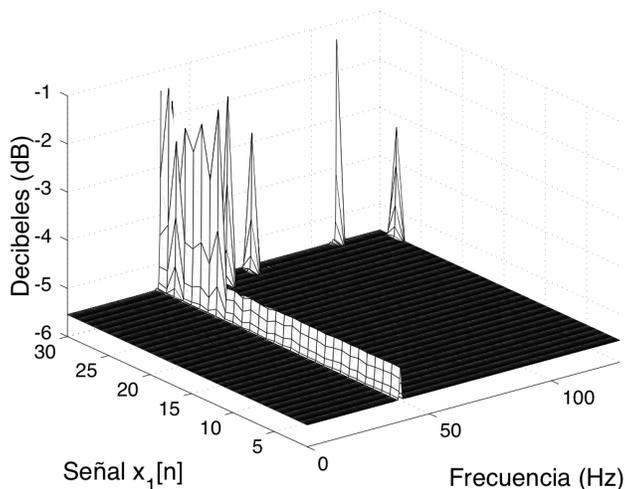


Figura 5.4: Pseudo-espectros para las señales sintéticas del ensemble x_1 , senoidales a 38 Hz con diferentes valores de SNR. El valor del umbral de MUSIC es $u = 0.9$, solo los eigenvalores mayores a este umbral (después de la normalización en el rango $(0,1]$) son considerados espacio de señal. Con la eliminación de componentes de frecuencia en el espacio de señal, el pseudo-espectro de cada señal del ensemble x_1 mantiene el componente de 38 Hz incluso para los valores de SNR muy bajos.

5.2. Validación de MUSIC II: Senoidales puras

Los espectros y pseudo-espectros de las senoidales digitalizadas con el sistema BCI2000-g.USBamp, fueron promediadas en el dominio de la frecuencia para facilitar su visualización. El resultado se presenta en la fig. 5.5. Obsérvense los efectos de la aplicación de filtros sobre cada uno de los métodos de descripción frecuencial (DFT y MUSIC). La amplitud de los componentes del espectro obtenido con DFT muestra claramente la atenuación de los componentes y la eliminación del valor de *corriente directa* (CD), por otra parte, los distintos umbrales de MUSIC permiten una mejor identificación del contenido espectral, manteniendo las frecuencias relevantes aún en la banda de rechazo. Para ambos métodos la severa atenuación de la frecuencia de 126 Hz no permite detectar su presencia.

5.3. Detección de SSVEP: dos clases

Los valores de certeza para lin-SVM y rbf-SVM sobre cada uno de los electrodos de análisis del sujeto que participó en el registro de la respuesta evocada para dos diferentes frecuencias se muestran en la gráfica de la fig. 5.6. En esta gráfica se puede apreciar el desempeño del uso de MUSIC para extraer características de una sola época de SSVEP evocado en un sujeto

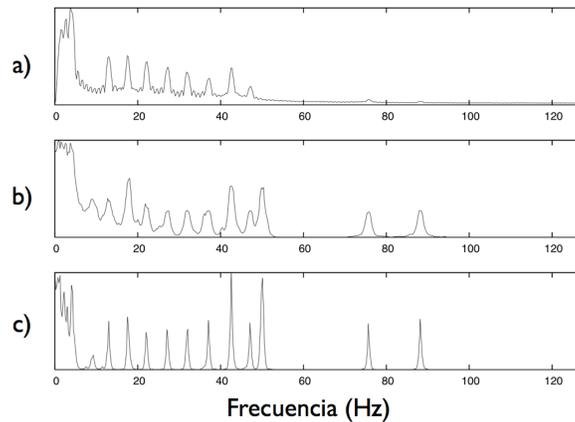


Figura 5.5: Promedio de las representaciones en frecuencia de las senoidales puras (el componente de 50 Hz corresponde a ruido de línea) adquiridas con BCI2000-g.USBamp: a) Espectro promedio obtenido con la DFT de 1024 puntos, b) Pseudo-espectro promedio utilizando un umbral MUSIC de $u = 0.1$ y c) Pseudo-espectro promedio utilizando un umbral MUSIC de $u = 0.5$. Los valores de amplitud no son relevantes para la detección, por lo tanto no se incluyen en la figura.

entrenado.

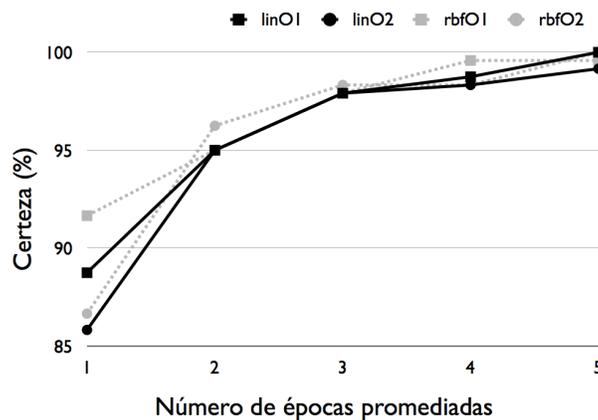


Figura 5.6: Curva de certeza de clasificación para el promedio de las características de 1 a 5 épocas. Es notable el valor mayor a 85 % para la clasificación de época simple y la rápida convergencia. Se entrenaron clasificadores para el promedio de 10 y 15 épocas alcanzando 100 % en todos los casos y por eso se excluyen de este gráfico. Las curvas de la gráfica corresponden a los clasificadores entrenados para la discriminación de dos SSVEP evocados a diferentes frecuencias, se entrenaron Máquinas de Soporte Vectorial (SVM) con núcleo lineal (lin-SVM, línea sólida) y núcleo gaussiano (rbf-SVM, línea punteada) utilizando las características extraídas de los electrodos O1 (cuadrados) y O2 (círculos).

5.4. Detección de SSVEP: tres clases

Los cuadros 5.1-5.4 contienen la información de certeza (ACC) y área bajo la curva ROC (A_z), respectivamente, obtenidos para la discriminación de tres clases: C_1 (f_1), C_0 (EEG) y C_{-1} (f_2), en todos los sujetos registrados con este paradigma. Las características utilizadas en los cuadros corresponden a la representación $F_{[O1O2]}$. Los cuadros para ambos electrodos y ambas medidas de desempeño con los diferentes valores del parámetro u pueden encontrarse en el apéndice C.

Las fig. 5.7-5.8 muestran los valores de A_z correspondientes a los cuadros. 5.3 y 5.4.

Cuadro 5.1: Medidas de ACC para los sujetos registrados con el paradigma de dos clases. Parámetros: lin-SVM, $F_{[O1O2]}$, $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	55.00 ± 1.67	58.33 ± 3.82	58.33 ± 1.44	50.00 ± 3.82	63.06 ± 1.73
C_1 vs C_0	64.00 ± 1.00	89.33 ± 1.15	86.67 ± 4.73	89.00 ± 2.00	82.00 ± 3.00
C_{-1} vs C_0	61.33 ± 1.15	83.67 ± 1.53	86.67 ± 3.51	91.33 ± 3.06	80.67 ± 2.89
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	50.00 ± 0.00	51.94 ± 3.47	58.89 ± 0.96	59.17 ± 0.83	83.89 ± 2.93
C_1 vs C_0	92.67 ± 2.08	84.67 ± 4.73	76.67 ± 3.21	89.33 ± 2.08	65.67 ± 1.53
C_{-1} vs C_0	90.00 ± 3.61	81.00 ± 5.20	75.00 ± 2.65	80.33 ± 3.06	85.67 ± 5.51

Cuadro 5.2: Medidas de ACC para los sujetos registrados con el paradigma de dos clases. Parámetros: lin-SVM, $F_{[O1O2]}$, $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	56.67 ± 3.33	58.33 ± 2.20	51.11 ± 3.94	58.61 ± 4.81	60.56 ± 0.96
C_1 vs C_0	73.33 ± 2.52	94.33 ± 3.06	82.67 ± 3.51	83.00 ± 2.65	80.00 ± 2.65
C_{-1} vs C_0	70.00 ± 2.65	89.00 ± 3.61	85.33 ± 4.93	85.67 ± 1.53	81.33 ± 1.53
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	51.11 ± 3.76	55.83 ± 8.78	58.33 ± 4.33	59.44 ± 2.55	79.17 ± 2.50
C_1 vs C_0	95.67 ± 1.53	89.67 ± 2.08	73.00 ± 4.00	87.67 ± 3.06	78.67 ± 4.51
C_{-1} vs C_0	93.67 ± 1.53	87.67 ± 1.53	70.00 ± 4.36	80.33 ± 1.53	92.00 ± 2.65

Cuadro 5.3: Medidas de A_z para los sujetos registrados con el paradigma de dos clases. Parámetros: lin-SVM, $F_{[O1O2]}$, $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.59 ± 0.03	0.62 ± 0.04	0.60 ± 0.01	0.50 ± 0.03	0.68 ± 0.02
C_1 vs C_0	0.70 ± 0.03	0.96 ± 0.01	0.93 ± 0.03	0.93 ± 0.03	0.88 ± 0.03
C_{-1} vs C_0	0.69 ± 0.05	0.91 ± 0.04	0.94 ± 0.02	0.95 ± 0.03	0.88 ± 0.00
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.50 ± 0.03	0.50 ± 0.03	0.63 ± 0.01	0.62 ± 0.04	0.89 ± 0.03
C_1 vs C_0	0.97 ± 0.01	0.93 ± 0.02	0.81 ± 0.01	0.94 ± 0.01	0.71 ± 0.05
C_{-1} vs C_0	0.97 ± 0.01	0.90 ± 0.04	0.78 ± 0.03	0.87 ± 0.03	0.92 ± 0.04

Cuadro 5.4: Medidas de A_z para los sujetos registrados con el paradigma de dos clases. Parámetros: lin-SVM, $F_{[O1O2]}$, $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.59 ± 0.05	0.60 ± 0.03	0.51 ± 0.05	0.60 ± 0.02	0.64 ± 0.04
C_1 vs C_0	0.82 ± 0.04	0.98 ± 0.00	0.89 ± 0.02	0.86 ± 0.03	0.86 ± 0.02
C_{-1} vs C_0	0.78 ± 0.02	0.95 ± 0.01	0.92 ± 0.02	0.90 ± 0.02	0.89 ± 0.01
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.51 ± 0.03	0.57 ± 0.01	0.62 ± 0.04	0.61 ± 0.01	0.88 ± 0.02
C_1 vs C_0	0.99 ± 0.01	0.94 ± 0.01	0.76 ± 0.07	0.93 ± 0.01	0.88 ± 0.04
C_{-1} vs C_0	0.98 ± 0.01	0.94 ± 0.02	0.73 ± 0.07	0.88 ± 0.03	0.96 ± 0.01

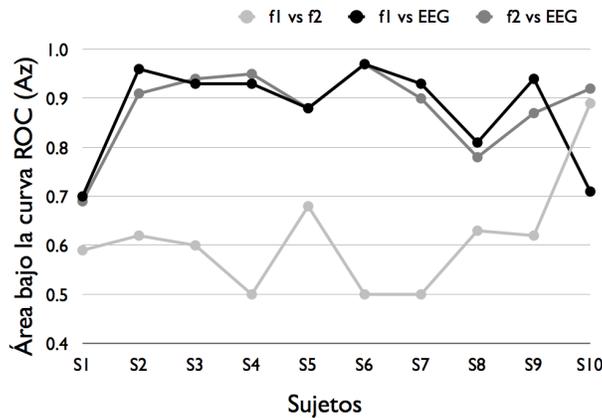


Figura 5.7: Valores de A_z para los diez sujetos registrados durante el estímulo con tres clases. El análisis fuera de línea fue realizado con un umbral $u = 0.1$, se entrenaron lin-SVM para discriminar entre cada par de clases: C_1 vs C_{-1} (f1 vs f2, gris claro), C_1 vs C_0 (f1 vs EEG, negro) y C_{-1} vs C_0 (f2 vs EEG, gris oscuro) para el entrenamiento de estos clasificadores se utilizaron las características definidas como $F_{[O1O2]}$.

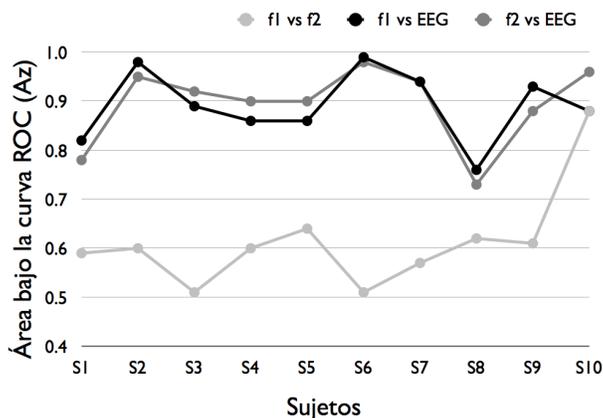


Figura 5.8: Valores de A_z para los diez sujetos registrados durante el estímulo con tres clases. El análisis fuera de línea fue realizado con un umbral $u = 0.05$, se entrenaron lin-SVM para discriminar entre cada par de clases: C_1 vs C_{-1} (f1 vs f2, gris claro), C_1 vs C_0 (f1 vs EEG, negro) y C_{-1} vs C_0 (f2 vs EEG, gris oscuro) para el entrenamiento de estos clasificadores se utilizaron las características definidas como $F_{[O1O2]}$.

5.5. Detección de SSVEP: cuatro clases

Las fig. 5.9 y 5.10 muestran el comportamiento de los sujetos¹ registrados durante la presentación del paradigma de cuatro clases, en este experimento, la clase de EEG no se consideró como tal para el entrenamiento de los clasificadores puesto que en pruebas anteriores se ha demostrado que clasificar EEG vs f_i siempre resulta en un valor $A_z > 0.7$. En este conjunto de registros se busca discriminar entre diferentes frecuencias; considerando que una de ellas puede corresponder a un comando nulo, consideración realizada para el paradigma de tres clases (identificación de una época como EEG \rightarrow comando nulo). Los mismos valores se pueden encontrar en los cuadros 5.5 y 5.6.

¹Los sujetos marcados con un * corresponden a la segunda presentación del paradigma, inmediata a la primera con un intervalo de descanso no menor a 5 min. Al ser la segunda repetición de una sola sesión se habían considerado independientes, sin embargo pueden notarse diferencias en el desempeño.

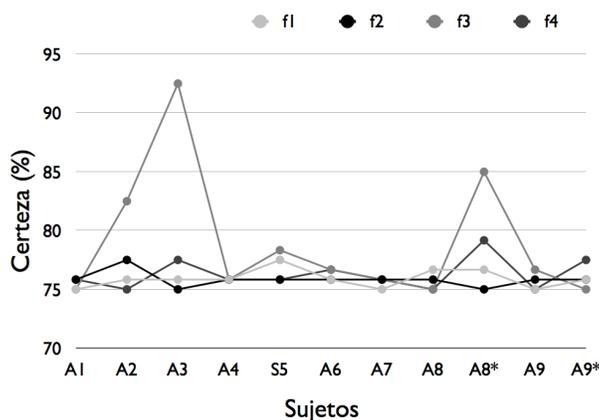


Figura 5.9: Valores de ACC para los sujetos registrados durante el paradigma de 4 clases. Se entrenaron Máquinas de Soporte Vectorial con núcleo lineal (lin-SVM) para realizar la clasificación. Todas las lin-SVM fueron entrenadas por validación cruzada de 3 vías (3-CV) y en un esquema *uno contra todos*, donde la prevalencia de las clases son: 25 % y 75 % por lo que la línea de azar es ahora 75 %. Todos los valores de ACC son mayores o iguales a 75 %, esto significa que existe una discriminación apenas perceptible, en la fig. 5.10 se presenta el gráfico de los valores de A_z , como se mencionó en el capítulo 4 esta medida es menos sensible a la prevalencia.

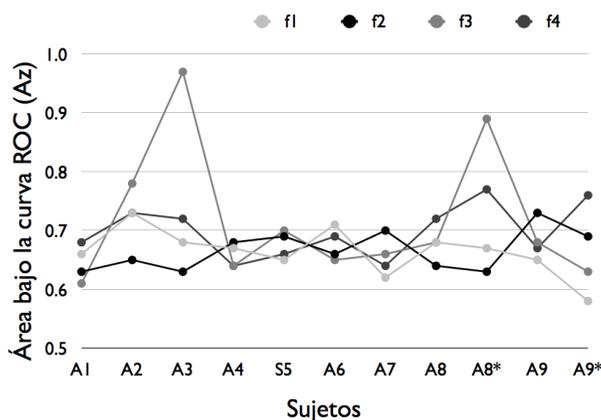


Figura 5.10: Valores de A_z para los sujetos registrados durante el paradigma de 4 clases. lin-SVM entrenadas por 3-CV fueron utilizadas en este análisis. Los valores por encima de 0.5 indican que se logra la discriminación entre las diferentes frecuencias con demasiado error. Posibles causas son el diseño del paradigma, la calidad de la señal adquirida y la exactitud en la presentación de los estímulos. Además puede atribuirse a la inexperiencia de los sujetos registrados, este factor se comprueba con la segunda presentación del paradigma en los sujetos A8 y A9, puesto que para el segundo registro presentan una diferencia notable en los valores de A_z (incluso ACC).

Cuadro 5.5: Mejores medidas de ACC para el problema de discriminación de 4 clases.

Sujeto	C_1	C_2	C_3	C_4
A1	75.00 \pm 0.00	75.83 \pm 1.18	75.00 \pm 0.00	75.83 \pm 1.18
A2	75.83 \pm 1.18	77.50 \pm 2.04	82.50 \pm 3.54	75.00 \pm 0.00
A3	75.83 \pm 1.18	75.00 \pm 0.00	92.50 \pm 3.54	77.50 \pm 3.54
A4	75.83 \pm 1.18	75.83 \pm 1.18	75.83 \pm 1.18	75.83 \pm 1.18
A5	77.50 \pm 3.54	75.83 \pm 1.18	78.33 \pm 2.36	75.83 \pm 1.18
A6	75.83 \pm 1.18	75.83 \pm 1.18	76.67 \pm 4.25	76.67 \pm 1.18
A7	75.00 \pm 0.00	75.83 \pm 1.18	75.83 \pm 1.18	75.83 \pm 1.18
A8	76.67 \pm 2.36	75.83 \pm 1.18	75.00 \pm 0.00	75.00 \pm 0.00
A8*	76.67 \pm 2.36	75.00 \pm 0.00	85.00 \pm 2.04	79.17 \pm 4.25
A9	75.00 \pm 0.00	75.83 \pm 1.18	76.67 \pm 2.36	75.00 \pm 0.00
A9*	75.83 \pm 1.18	75.83 \pm 1.18	75.00 \pm 0.00	77.50 \pm 3.54

Cuadro 5.6: Mejores medidas de A_z para el problema de discriminación de 4 clases.

Sujeto	C_1	C_2	C_3	C_4
A1	0.66 \pm 0.03	0.63 \pm 0.08	0.61 \pm 0.00	0.68 \pm 0.04
A2	0.73 \pm 0.05	0.65 \pm 0.01	0.78 \pm 0.03	0.73 \pm 0.01
A3	0.68 \pm 0.02	0.63 \pm 0.04	0.97 \pm 0.01	0.72 \pm 0.07
A4	0.67 \pm 0.10	0.68 \pm 0.03	0.64 \pm 0.05	0.64 \pm 0.08
A5	0.65 \pm 0.09	0.69 \pm 0.13	0.70 \pm 0.08	0.66 \pm 0.04
A6	0.71 \pm 0.06	0.66 \pm 0.03	0.65 \pm 0.04	0.69 \pm 0.06
A7	0.62 \pm 0.03	0.70 \pm 0.08	0.66 \pm 0.08	0.64 \pm 0.06
A8	0.68 \pm 0.04	0.64 \pm 0.05	0.68 \pm 0.07	0.72 \pm 0.06
A8*	0.67 \pm 0.06	0.63 \pm 0.06	0.89 \pm 0.04	0.77 \pm 0.05
A9	0.65 \pm 0.07	0.73 \pm 0.02	0.68 \pm 0.01	0.67 \pm 0.13
A9*	0.58 \pm 0.08	0.69 \pm 0.01	0.63 \pm 0.07	0.76 \pm 0.06

Capítulo 6

Discusión

6.1. Validación de MUSIC

Como puede observarse en las gráficas del capítulo 5, MUSIC presenta un mejor desempeño que DFT para determinar la pertenencia de una frecuencia específica ω_0 al espacio de señal de una observación aún con un valor muy bajo de SNR o atenuación por efecto de filtros. El uso de señales sintéticas permite el control de los valores de SNR para probar las características de los algoritmos propuestos así como su implementación. En el primer conjunto de experimentos con los ensambles $\{x_1 : x_4\}$ se demostró la ventaja de poder seleccionar un umbral para la separación de los subespacios (parámetro u , ec. 4.15) además de poder cambiar la resolución o número de vectores que se utilizan para el pseudo-espectro, siendo que en el caso del espectro obtenido con la DFT solo puede cambiarse la resolución en frecuencia.

La segunda parte de la validación de MUSIC, el procesamiento u obtención de los pseudo-espectros de señales senoidales puras con condiciones de ruido reales, muestra la capacidad de MUSIC para detectar frecuencias atenuadas severamente, como el ruido y las señales más allá de la frecuencia de corte de los filtros de adquisición. Logrando identificar frecuencias que sufren la atenuación de los filtros (nótese el decaimiento en amplitud del espectro promedio fig. 5.5 equivalentes a un menor SNR). Pueden identificarse las propiedades de MUSIC observadas durante esta serie de experimentos y su impacto en la detección de SSVEP como se discute en las siguientes apartados.

6.1.1. Detección de la frecuencia ω_0

Debido a que MUSIC puede detectar las frecuencias que presentan un SNR bajo, se puede inferir que la detección de un SSVEP en condiciones de ruido por falta de atención

o interferencias durante la adquisición no representa un problema serio. Sin embargo, esto puede dificultar la discriminación de frecuencias simultáneas que se encuentren dentro del campo visual y sean moduladas por la atención del sujeto.

6.1.2. Selectividad mediante el parámetro u

En las figuras de los pseudo-espectros de señales sintéticas y senoidales puras (fig. 5.1-5.5) es notoria la influencia y la utilidad de seleccionar cuidadosamente el umbral u para la separación de los subespacios de señal y ruido. Se observa que al incrementar el valor de este umbral las frecuencias que no están bien representadas por los eigenvectores, van siendo eliminadas para dar paso a las frecuencias que mejor explican la varianza de la señal original (aquellas con los eigenvalores mayores). El ajuste de este parámetro es fundamental para la correcta separación de espacios y por tanto, la optimización de la selección de características. Respecto a la DFT es una ventaja el poder variar otro parámetro además de la resolución en frecuencia, discutida más adelante.

6.1.3. Simplicidad de cálculo

Para poder observar una respuesta en frecuencia de MUSIC respecto a la señal bajo análisis y poder identificar cuáles frecuencias son identificadas como señal y cuáles como ruido, se calculó el pseudo-espectro completo de 512 puntos para obtener la misma resolución en frecuencia que la DFT de 1024 puntos. Es posible inferir que se generaron 512 vectores de prueba W_i para la evaluación del pseudo-espectro en cada uno de estos puntos. Sin embargo durante el esquema de extracción de características propuesto en esta tesis, son necesarios solo 4 vectores por frecuencia de interés, pudiendo reducir el número de características hasta una sola determinada por la proyección del único vector W_i en la frecuencia ω_i . De la misma forma que para la implementación de la FFT, podrían determinarse de antemano los coeficientes para la proyección de los eigenvalores, reduciendo dramáticamente el tiempo de cálculo a un tiempo equivalente al de la FFT.

6.1.4. Resolución infinita

El algoritmo de MUSIC no tiene restricciones respecto a la resolución pudiendo decir que posee una resolución infinita puesto que en la formulación se puede utilizar cualquier frecuencia para generar el vector W . Notando que existe el problema de la resolución con que se pueden presentar los estímulos (dependiente del hardware como sistema) y de la resolución con que el cerebro de cada uno de los sujetos pueda distinguir las frecuencias

que se desean evocar (dependiente del cerebro, también como sistema). En los trabajos [8, 18] se determinan valores experimentales para la frecuencia a presentar con el hardware dedicado. La formulación de MUSIC le permite incorporarse a esquemas predefinidos con resoluciones determinadas, sin ningún problema, excepto la resolución numérica del hardware (de propósito general o específico) que se haya determinado en cada aplicación.

En los siguientes apartados se aborda la discusión del comportamiento de MUSIC con señales reales y se discuten los resultados mostrados en los cuadros y figuras del capítulo 5.

6.2. Detección de SSVEP: dos clases

Una vez implementado MUSIC se procedió a analizar señales reales de SSVEP, limpias y de un sujeto entrenado. Como se ha mencionado antes el conjunto de datos de este experimento fue adquirido fuera del LINI por investigadores experimentados¹ en la adquisición de este tipo de registros y en el procesamiento de SSVEP para BCI. El sujeto analizado fue entrenado durante varias sesiones y poseía experiencia previa en el uso de sistemas BCI. En este sujeto se encontraron las tasas de clasificación más altas para épocas de un segundo de duración, superando la certeza de 85% para ambos tipos de núcleo utilizado dentro de las SVM. Durante este primer experimento, tampoco se encontraron diferencias significativas en el uso de lin-SVM y de rbf-SVM en términos de desempeño, encontrando grandes diferencias en el tiempo de entrenamiento de los clasificadores y restringiendo el entrenamiento de nuevos clasificadores a los núcleos lineales.

La discriminación efectiva de las épocas de SSVEP a diferentes frecuencias depende de varios factores, de la extracción de características y del entrenamiento de los clasificadores. Es indispensable que el sujeto atienda a los estímulos y que concientemente minimice la atención de uno de ambos estímulos. Esto se logra solamente a través del entrenamiento y de incrementar el interés del sujeto en la tarea de la BCI. Este experimento, siendo el primero del procesamiento propuesto con señales reales muestra que es posible utilizar MUSIC en la detección de SSVEP y que otorga un desempeño superior a la DFT.

6.3. Detección de SSVEP: tres clases

El análisis fuera de línea de los datos adquiridos durante la fase de registro para la detección de dos clases mostró que MUSIC puede identificar la presencia de una frecuencia de estímulo de una condición de EEG basal con gran facilidad, debido a la topología de los espacios de señal y de ruido. Con este resultado podemos implementar un control binario

¹Ver capítulo 4

de “encendido/apagado” para alguna aplicación sencilla, fácilmente controlable por sujetos que utilizan una BCI por primera vez. Un controlador de este tipo sería poco práctico y no ofrecería demasiada ayuda o control sobre una aplicación compleja como escribir (a través de deletrear) o controlar un dispositivo móvil como una silla de ruedas, por lo tanto, es necesario revisar los resultados de identificar la ocurrencia de dos diferentes SSVEP para distintas frecuencias.

El conjunto de registros de este experimento incluyó dos diferentes frecuencias y un estado sin estímulo como clases a determinar con la ayuda de las SVM y MUSIC para extraer características. Los resultados de las lin-SVM para la clasificación de las épocas correspondientes a las frecuencias de estímulo f_1 y f_2 , clases C_1 y C_{-1} no presentaron una tasa de clasificación o valor de A_z tan alto como para el análisis del sujeto entrenado. Esto indica que si bien existe una separabilidad de las clases C_1 y C_{-1} , no es evidente para sujetos no entrenados (*naive subjects*). Puede deberse al factor del entrenamiento, a la disposición de los elementos de estímulo en la pantalla de LCD o en la detección de MUSIC de frecuencias atenuadas, detectando ambas frecuencias sin importar cada clase a la que pertenece la época. Este resultado y el hecho de que el sujeto *S10* tenga un alto valor de A_z en los tres clasificadores utilizados indica que el entrenamiento o atención son relevantes para el buen uso de la BCI, para incrementar su utilidad y maximizar el desempeño del sistema. El sujeto *S10* recibió las instrucciones del paradigma más de una vez e incluso estuvo presente durante al menos dos sesiones anteriores a la suya, durante las cuales pudo desarrollar (sin retroalimentación) alguna técnica para atender mejor a los estímulos. Es importante mencionar que la inclusión de los armónicos permite identificar frecuencias de estímulo de otro tipo de frecuencias inducidas por ruido o algún artefacto, por ejemplo, el ruido de línea y las oscilaciones en el EEG (con y sin estímulo) provocadas por la tasa de refresco de la pantalla de LCD.

6.4. Detección de SSVEP: cuatro clases

El segundo conjunto de registros fue analizado para determinar una de cuatro clases objetivo, sin considerar el periodo sin estímulo como otra clase. Para este análisis se entrenaron clasificadores uno contra todos, con el objetivo de observar cuan diferente es una clase de las demás o que tan única es su respuesta en el cerebro. En este caso la prevalencia de las clases es 25% y 75% por lo que los cuadros de certeza con valores cercanos a 75% indican que no son muy discriminables. El valor de A_z es más útil para indicar el desempeño de los clasificadores y podemos observar que los valores están por encima de $A_z = 0.5$

En este experimento es notable el uso de clasificadores uno contra todos para la decisión de pertenencia o no a cada clase puesto que de esta forma se busca el hiperplano de separación

que generalice el comportamiento de una de las clases respecto de las demás. Además de esta forma se entrenan menos clasificadores y se evalúan durante la ejecución del análisis, el uso de clasificadores binarios y la cuidadosa selección de un método para combinarlos puede llevar a tasas de clasificación mayores.

De la misma forma que en la evaluación para tres clases, se observa la dificultad para discriminar entre diferentes frecuencias y se pueden relacionar con los mismos factores que se mencionaron anteriormente. También se puede observar un efecto a corto plazo de acondicionamiento al paradigma con la inclusión de los resultados para la segunda corrida de los sujetos $A8$ y $A9$.

6.5. Detección de SSVEP: n clases

En cada uno de los experimentos con señales reales se pudieron identificar aspectos importantes que son relevantes para la implementación en línea y la incorporación del método propuesto a alguna aplicación ya existente.

6.5.1. Uso de núcleos lineales, lin-SVM

Durante el análisis del primer conjunto de datos se entrenaron SVM con núcleos lineales y Gaussianos, encontrando que no existían diferencias significativas en su comportamiento para los datos utilizados. Donde la diferencia es importante en cuanto al tipo de clasificador que se entrena, lin-SVM o rbf-SVM, es en el tiempo de cómputo. Por este motivo se decidió acotar el uso de núcleos a lineales. Aún así, algunas rbf-SVM fueron entrenadas durante los análisis de tres y cuatro clases, confirmando que el tiempo de entrenamiento era mayor y las tasas de clasificación muy similares comparadas con las correspondientes a lin-SVM. Se puede decir que el uso de lin-SVM otorga un rápido entrenamiento y un desempeño equiparable con el de los núcleos Gaussianos, los cuales pueden explorarse si las respuestas del sujeto requieren mapearse a otro espacio o se desea descartar que se logre un incremento en la tasa de clasificación con el uso de núcleos diferentes a los lineales.

6.5.2. Electrodo de registro

Los electrodos de registro que se utilizaron corresponden en estándar 10–20 a los electrodos de la corteza occipital. Para todos los sujetos se hicieron registros en $O1$ y $O2$ como indica el estado-del-arte (capítulo 3) y se agregó el electrodo Oz para el último conjunto de registros. En general la unión de las características extraídas de $O1$ y $O2$ fueron las que otorgaron el mejor desempeño. En algunos casos, no incluidos en las gráficas de resultados,

los sujetos presentaron una tasa de clasificación ligeramente mayor para el uso de un solo electrodo. En todo caso, debe realizarse un ajuste para verificar que el sistema logra el mejor desempeño para un sujeto en particular. Los resultados del análisis de tres clases, muestran la tasa de clasificación más alta, sin indicar que electrodo fue el que la otorgó.

6.5.3. Concatenación de características

En conjunto con el apartado anterior, la concatenación de características es un factor que influye en el resultado final de la clasificación pero no siempre de manera favorable. Para cualquier aplicación del algoritmo propuesto o de una BCI en general, las características deben seleccionarse cuidadosamente para maximizar la diferenciación de las clases, simplificar el cálculo y el costo computacional. Para la implementación final de una BCI, debe utilizarse algún método de teoría de reconocimiento de patrones o minado de datos (data mining) con estos objetivos. En este trabajo el uso de estos métodos se encuentra más allá de los objetivos propuestos, pero su importancia es notable.

6.5.4. Frecuencias óptimas

Se comprobó la evocación de SSVEP en el rango de 6 a 40 Hz para sujetos no entrenados. No obstante se sabe que existen *frecuencias de resonancia* en las cuales la respuesta de los SSVEP es de mayor amplitud, además de considerar la habituación del sujeto al estímulo y a la facilidad con que su cerebro lo registra; por lo que es necesario buscar el conjunto de frecuencias o el rango de ellas que sea mejor para cada sujeto como paso adicional para incrementar el desempeño.

6.5.5. Entrenamiento y retroalimentación

No se consideró durante este trabajo pero existen antecedentes (ver capítulo 3) que indican que la retroalimentación durante la fase de entrenamiento permite al sujeto desarrollar estrategias de control que lo lleven a mejorar el desempeño del sistema.

Estos puntos deberán considerarse para futuras implementaciones del sistema LINI-BCI y para extensiones de este trabajo.

Capítulo 7

Conclusiones

En este trabajo se ha presentado el uso de MUSIC como método para la extracción de características en una BCI basada en SSVEP. Los experimentos realizados muestran las ventajas del método propuesto (MUSIC+lin-SVM) sobre la DFT y los resultados obtenidos indican la obtención de un buen desempeño para BCI basadas en SSVEP que incorporen MUSIC para la detección de las respuestas evocadas. El sistema descrito en esta tesis es un sistema de experimentación sencillo y robusto: sólo requiere de un electrodo de registro para establecer la comunicación, no necesita preprocesamiento de la señal de EEG más allá del acondicionamiento del sistema de registro y otorga altas tasas de clasificación para tiempos cortos de registro ($>85\%$ para épocas de 1 s) lo cual puede incrementar el bit rate en una aplicación en línea. La incorporación de pasos de procesamiento pueden llevar a una mejor detección de los SSVEP y una mayor discriminación entre frecuencias distintas para sujetos no entrenados.

La arquitectura básica de una BCI fue diseñada y puesta en marcha para la adquisición de las señales reales de SSVEP. Con el sistema resultante, LINI-BCI, pueden realizarse registros de EEG durante la ejecución de diferentes paradigmas además de SSVEP (P300 y ERD/ERS, por ejemplo) permitiendo la propuesta y evaluación de paradigmas de estímulo y métodos de procesamiento de señales reales.

Durante el desarrollo de este proyecto se identificaron aspectos relevantes que deben considerarse en trabajos futuros sobre la línea de investigación en BCI en el Laboratorio de Investigación en Neuroimagenología. En particular para BCI basadas en SSVEP se identificó la importancia de la retroalimentación y el entrenamiento de los sujetos para mejorar el desempeño del sistema. Otros puntos interesantes se presentan en el siguiente apartado.

7.1. Trabajo futuro

7.1.1. Materiales y métodos

Este trabajo tuvo como objetivo probar si MUSIC podía incrementar el desempeño de la BCI basada en SSVEP, los trabajos futuros deberán enfocarse en optimizar los subsistemas que rodean al bloque de reconocimiento de patrones (como se definió en el capítulo 4) sin olvidar la afinación o puesta a punto de este trabajo teórico/experimental, para llevarlo a la práctica, dentro de una aplicación del sistema LINI-BCI.

7.1.2. Aplicaciones en BCI

Con los alcances de este trabajo de tesis, queda pendiente como objetivo inmediato, la implementación en línea del algoritmo y la clasificación. Así como la retroalimentación y la incorporación a aplicaciones ya existentes. Como es el caso de deletreadores como el sistema Dasher [34], el deletreador Hex-o-Spell [35], teclados telefónicos [22], control remoto programable [8] o juegos de video [13] y el control de simulaciones robóticas en colaboración con la Universidad Nacional de Entre Ríos en Argentina. Además existen otros paradigmas y posibles aplicaciones que serán discutidas en los correspondientes documentos de tesis.

7.1.3. Soluciones adicionales

Actualmente se trabaja ya en una solución de hardware para la implementación de los clasificadores con ambos tipos de núcleo utilizados en este trabajo (lin-SVM y rbf-SVM) en un FPGA y de la presentación de estímulos. Al interior del LINI se tienen soluciones de adquisición que podrían utilizarse con una interfaz apropiada *stand-alone* o incorporada a BCI2000. Rutinas para MUSIC en C/C++ podrían codificarse y agregarse al mismo sistema. Así como planear la creación de una agenda de entrenamiento para voluntarios de BCI.

7.1.4. Futuro del sistema LINI-BCI

En este punto se cuenta dentro del LINI con un sistema básico para BCI en el cual no solo se pueden hacer registros de SSVEP sino de P300 y ERD/ERS, permitiendo la apertura y la facilidad de la expansión de la línea de investigación en Interfaces Cerebro-Computadora. Este sistema debe evolucionar para ser más pequeño y portátil, para contar con más canales e incorporar la clasificación y la presentación de retroalimentación durante la ejecución en línea. Además de implementar el procesamiento distribuido y generalizado

en la red interna del laboratorio para poder utilizar cualquier terminal como módulo de adquisición, procesamiento e interfaz con la aplicación.

En este momento se ha ingresado a la comunidad de usuarios de BCI2000. Se deberá utilizar el convenio de transferencia de conocimiento/tecnología para avanzar rápidamente hacia un sistema autónomo y contribuir a la comunidad con modificaciones al código o escritura de plug-ins. Además de adquirir experiencia en la preparación de sujetos para registro y en el almacenamiento y visualización de los datos. Deberán incorporarse alumnos de todos los niveles para que el sistema prospere y podamos avanzar en tanto en investigación/procesamiento de señales/reconocimiento de patrones como en las aplicaciones y la ingeniería en BCI.

Bibliografía

- [1] R. Smith, “Electroencephalograph based Brain-Computer Interfaces,” Master of Engineering Science, University College Dublin (NUI), Febrero 2004.
- [2] R. Leeb, G. Bauernfeind, S. Wriesnegger, H. Scharfetter, and G. Pfurtscheller, “First steps towards the NIRS-based GRAZ-BCI,” *Proceedings of the 3rd International Brain-Computer Interface Workshop and Training Course*, pp. 102–103, Septiembre 2006.
- [3] L. Farewell and E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials,” *Electroencephalography and clinical Neurophysiology*, no. 70, pp. 510–523, 1988.
- [4] D. Regan, *Human Brain Electrophysiology: Evoked Potentials and Evoked Magnetic Fields in Science and Medicine*. Elsevier, 1989.
- [5] C. Herrmann, “Human EEG Responses to 1-100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena,” *Experimental Brain Research*, no. 137, pp. 346–353, Abril 2001.
- [6] S. T. Morgan, J. C. Hansen, and A. Hillyard, “Selective attention to stimulus location modulates the steady-state visual evoked potential,” *Proc. Natl. Acad. Sci. USA*, vol. 93, pp. 4770–4774, 1996.
- [7] M. Middendorf, G. McMillan, G. Calhoun, and K. Jones, “Brain-Computer Interfaces Based on the Steady-State Visual-Evoked Response,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 211–214, Junio 2000.
- [8] X. Gao, D. Xu, M. Cheng, and S. Gao, “A BCI-Based Enviromental Controller for the Motion-Disabled,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 137–140, Junio 2003.

- [9] G. Müller Putz, R. Scherer, C. Brauneis, and G. Pfurtscheller, “Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components,” *Journal of Neural Engineering*, no. 2, pp. 123–130, 2005.
- [10] L. Piccini, S. Parini, L. Maggi, and G. Andreoni, “A Wearable Home BCI system: preliminary results with SSVEP protocol,” *Proceedings of the 27th Annual International Conference of the IEEE EMBS*, Septiembre 2005.
- [11] Y. Wang, Z. Zhang, X. Gao, and S. Gao, “Lead Selection for SSVEP-based brain-computer interface,” *Proceedings of the 26th Annual International Conference of the IEEE EMBS*, Septiembre 2004.
- [12] R. Wahnoun, R. Saigal, Y. Gu, N. Paquet, S. DePauw, A. Chen, S. Sami, and K. Dremstrup, “A Real-Time Brain-Computer Interface Based on Steady-State Visual Evoked Potentials,” *Proceedings of the IFESS Conference*, 2002.
- [13] S. Kelly, E. Lalor, C. Finucane, and R. Reilly, “EEG-based Brain Computer Interface Control in an Immersive 3-D Gaming Environment,” *2nd International BCI Workshop and Training Course*, Septiembre 2004.
- [14] M. Cheng and S. Gao, “An EEG-based cursor control system,” *Proceedings of the 1st Joint BMES/EMBS*, Octubre 1999.
- [15] C. Guger, A. Schlögl, C. Neuper, D. Walterspacher, T. Strein, and G. Pfurtscheller, “Rapid Prototyping of an EEG-Based Brain-Computer Interface (BCI),” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 9, no. 1, pp. 49–58, Marzo 2001.
- [16] Presentation, Neurobehavioral Systems. [Online]. Available: <http://www.neurobs.com/presentation>
- [17] V. Jaganathan, T. M. Srihari Mukesh, and M. Ramasubba Reddy, “Design and Implementation of High Performance Visual Stimulator for Brain Computer Interfaces,” *Proceedings of the 27th Annual International Conference of the IEEE EMBS*, Septiembre 2005.
- [18] T. Shrihari Mukesh, V. Jaganathan, and M. Ramasubba Reddy, “A novel multiple frequency stimulation method for steady state VEP based brain-computer interfaces,” *Physiological Measurement*, no. 27, pp. 61–71, 2006.

- [19] G. Andreoni, F. D. B. Beverina, G. Palmas, S. Silvoni, Ventura G, and F. Piccione, “BCI based on SSVEP: Methodological Basis,” *2nd International BCI Workshop and Training Course*, Septiembre 2004.
- [20] R. Krepki, B. Blankertz, G. Curio, and K. Müller, “The Berlin Brain-Computer Interface (BBCI) towards a new communication channel for online control of multimedia applications and computer games,” *9th International Conference on Distributed Multimedia Systems*, 2003.
- [21] J. Cui, W. Wong, and S. Mann, “Time-frequency analysis of visual evoked potentials using chirplet transform,” *Electronics Letters*, vol. 41, no. 4, Febrero 2005.
- [22] M. Cheng, X. Gao, S. Gao, and D. Xu, “Design and Implementation of a Brain-Computer Interface with High Transfer Rates,” *IEEE Transactions on Biomedical Engineering*, vol. 49, no. 10, pp. 1181–1186, Octubre 2002.
- [23] (2005, Marzo) g.tec, Guger Technologies. [Online]. Available: <http://www.gtec.at>
- [24] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, “BCI2000: A general-purpose brain-computer interface,” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1034–1043, 2004. [Online]. Available: <http://bci2000.org/BCI2000/Home.html>
- [25] R. Schmidt, “Multiple emitter location and signal parameter estimation.” *IEEE Transactions on Antennas and Propagation*, vol. 34, no. 3, pp. 276–280, March 1986.
- [26] C. Therrien, *Discrete Random Signal and Statistical Processing*. Prentice-Hall Signal Processing Series, 1992.
- [27] (2005, Enero) Octave. [Online]. Available: <http://www.neurobs.com/presentation>
- [28] M. Kaper, P. Meinicke, U. Grossekhoefer, T. Lingner, and H. Ritter, “BCI competition 2003-Data Set IIb: Support Vector Machines for the P300 Speller Paradigm,” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1073–1076, Junio 2004.
- [29] (2005, Marzo) LIBSVM – a library for support vector machines. [Online]. Available: <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>
- [30] C. J. C. Burges. A tutorial on support vector machines for pattern recognition. [Online]. Available: citeseer.nj.nec.com/burges98tutorial.html

-
- [31] C. E. Metz, “Basic principles of ROC analysis,” *Seminars on Nuclear Medicine*, vol. 8, no. 4, pp. 283–298, 1978.
- [32] T. Wickens, *Elementary Signal Detection Theory*. Oxford University Press, 2001.
- [33] A. Rakotomamonjy, “Support Vector Machines and Area Under ROC curve,” PSI-INSA de Rouen, Tech. Rep., Septiembre 2004.
- [34] D. MacKay. The Dasher Project. [Online]. Available: <http://www.inference.phy.cam.ac.uk/dasher/>
- [35] B. Blankertz, G. Dornhege, M. Krauledat, M. Schröder, and J. Williamson, “The Berlin Brain-Computer Interface presents the novel mental typewriter Hex-O-Spell,” *Proceedings of the 3rd International Brain-Computer Interface Workshop and Training Course*, pp. 108–109, Septiembre 2006.


```

begin;

##### BITMAPS #####
bitmap{
filename = "checkboxON.bmp";
scale_factor=0.5;
preload = true;
}on;

bitmap{
filename = "checkboxOFF.bmp";
scale_factor=0.5;
preload = true;
}off;

bitmap{
filename = "Larrow.bmp";
scale_factor = 0.3;
preload = true;
trans_src_color = 0,0,0;
}Larrow;

bitmap{
filename = "Rarrow.bmp";
scale_factor = 0.3;
preload = true;
trans_src_color = 0,0,0;
}Rarrow;

bitmap{
filename = "none.bmp";
scale_factor = 0.6;
preload = true;
trans_src_color = 0,0,0;
}cross;

##### PICTURES #####
picture{
bitmap cross;
x = 0; y = 0;

bitmap on;
x = -425; y = 0;

bitmap on;
x = 425; y = 0;
}none;

picture{
bitmap on;
x = -425; y = 0;

bitmap on;
x = 425; y = 0;

bitmap Larrow;
x = -300; y = 0;
}Ltarget;

picture{
bitmap on;
x = -425; y = 0;

bitmap on;
x = 425; y = 0;

bitmap Rarrow;
x = 300; y = 0;
}Rtarget;

##### TRIALS #####

```

```

trial {
    trial_duration = 5000;
    trial_type = first_response;
    picture{}default;
}gueit;

trial{
    picture Ltarget;
    duration = 10000;
    code="izq";
}Ltrial;

trial{
    picture Rtarget;
    duration = 10000;
    code="der";
}Rtrial;

trial{
    picture none;
    duration = 10000;
    code="rest";
}resttrial;

trial{

    picture{bitmap on; x=-425; y=0;};
    time = 15;
    port_code = 1;

    picture{bitmap off; x=-425;y=0;};
    time = 30;

    picture{bitmap on; x=425; y=0;};
    time = 6;
    port_code = 2;

    picture{bitmap off; x=425; y=0;};
    time = 12;

    picture{bitmap on; x=425; y=0;};
    time = 18;
    port_code = 2;

    picture{bitmap off; x=425; y=0;};
    time = 24;
    #code="exec";

}pics;

## ARREGLO PARA SELECCION ALEATORIA ##
array{
    trial Ltrial;
    trial Rtrial;
    trial Ltrial;
    trial Rtrial;
    trial Ltrial;
    trial Rtrial;
}arrais;

##### INICIO PCL #####
begin_pcl;

arrais.shuffle();

gueit.present();

loop
int j = 1
until
j > 6
begin

```



```

bitmap{
filename = "offV.bmp";
scale_factor=0.4;
preload = true;
}offV;

bitmap{
filename = "blankH.bmp";
scale_factor = 0.4;
preload = true;
trans_src_color = 255,255,255;
}winH;

bitmap{
filename = "blankV.bmp";
scale_factor = 0.4;
preload = true;
trans_src_color = 255,255,255;
}winV;

bitmap{
filename = "Darrow.bmp";
scale_factor = 0.3;
preload = true;
trans_src_color = 0,0,0;
}Darrow;

bitmap{
filename = "Uarrow.bmp";
scale_factor = 0.3;
preload = true;
trans_src_color = 0,0,0;
}Uarrow;

bitmap{
filename = "Rarrow.bmp";
scale_factor = 0.3;
preload = true;
trans_src_color = 0,0,0;
}Rarrow;

bitmap{
filename = "Larrow.bmp";
scale_factor = 0.3;
preload = true;
trans_src_color = 0,0,0;
}Larrow;

bitmap{
filename = "none.bmp";
scale_factor = 0.4;
preload = true;
trans_src_color = 0,0,0;
}cross;

##### PICTURES #####
picture{
bitmap cross;
x = 0; y = 0;

bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

```

```

}none;

picture{
bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

bitmap Darrow;
x = 0; y = -0;
}Dtarget;

picture{
bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

bitmap Uarrow;
x = 0; y = 0;
}Utarget;

picture{
bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

bitmap Rarrow;
x = 0; y = 0;
}Rtarget;

picture{
bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

bitmap Larrow;
x = -0; y = 0;
}Ltarget;

picture{
bitmap onH;

```

```
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0000;

picture{
bitmap offH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0001;

picture{
bitmap onH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap onV;

}Osc0100;

x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0010;

picture{
bitmap offH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0011;

picture{
bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap offV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0100;
```

```

x = 0; y = -250;

picture{
bitmap offH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap offV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0101;

picture{
bitmap onH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap offV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0110;

picture{
bitmap offH;
x = 0; y = 250;

bitmap offH;

```

```

x = 0; y = -250;

bitmap offV;
x = 350; y = 0;

bitmap onV;
x = -350; y = 0;

}Osc0111;

picture{
bitmap onH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap offV;
x = -350; y = 0;

}Osc1000;

picture{
bitmap offH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap offV;

```

```
x = -350; y = 0;

}Osc1001;

picture{
bitmap onH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap offV;
x = -350; y = 0;

}Osc1010;

picture{
bitmap offH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap onV;
x = 350; y = 0;

bitmap offV;
x = -350; y = 0;

}Osc1011;

picture{
bitmap onH;

x = 0; y = 250;

bitmap offV;
x = 350; y = 0;

}Osc1100;

picture{
bitmap offH;
x = 0; y = 250;

bitmap onH;
x = 0; y = -250;

bitmap offV;
x = 350; y = 0;

bitmap offV;
x = -350; y = 0;

}Osc1101;

picture{
bitmap onH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap offV;

x = 0; y = 250;
```

```

x = 350; y = 0;

bitmap offV;
x = -350; y = 0;

}Osc1110;

picture{
bitmap offH;
x = 0; y = 250;

bitmap offH;
x = 0; y = -250;

bitmap offV;
x = 350; y = 0;

bitmap offV;
x = -350; y = 0;

}Osc1111;

##### TRIALS #####
trial {
    trial_duration = 2000;
    picture{}default;
    code = "pausa";
    port_code = 15;
}gueit;

trial {
trial_duration = 1000;
picture none;
code = "null";
}habas;

trial {
    trial_duration = 500;
    picture Ltarget;
    code = "Izquierda";
}Lobj;

trial {
    trial_duration = 500;
    picture Utarget;
    code = "Arriba";
}Uobj;

trial {
    trial_duration = 500;
    picture Rtarget;
    code = "Derecha";
}Robj;

trial {
    trial_duration = 500;
    picture Dtarget;
    code = "Abajo";
}Dobj;

trial{
    trial_duration = 300;
    picture none;
    code = "espera1";
}espera1;

trial{
    trial_duration = 400;
    picture none;
    code = "espera2";
}espera2;

```

```
trial{
trial_duration = 500;
picture none;
code = "espera3";
}espera3;

trial{
trial_duration = 600;
picture none;
code = "espera4";
}espera4;

### TRIAL OZZY ###

trial{
picture Osc0000;
port_code = 0;
}tr0000;

trial{
picture Osc0001;
port_code = 1;
}tr0001;

trial{
picture Osc0010;
port_code = 2;
}tr0010;

trial{
picture Osc0011;
port_code = 3;
}tr0011;

trial{
picture Osc0100;
port_code = 4;
}tr0100;

trial{
picture Osc0101;
port_code = 5;
}tr0101;

trial{
picture Osc0110;
port_code = 6;
}tr0110;

trial{
picture Osc0111;
port_code = 7;
}tr0111;

trial{
picture Osc1000;
port_code = 8;
}tr1000;

trial{
picture Osc1001;
port_code = 9;
}tr1001;

trial{
picture Osc1010;
port_code = 10;
}tr1010;

trial{
picture Osc1011;
port_code = 11;
}tr1011;
```

```

}tr1011;

trial{
picture Osc1100;
port_code = 12;
}tr1100;

trial{
picture Osc1101;
port_code = 13;
}tr1101;

trial{
picture Osc1110;
port_code = 14;
}tr1110;

trial{
picture Osc1111;
port_code = 15;
}tr1111;

##### P C L #####

array{
trial Uobj;
trial Dobj;
trial Lobj;
trial Robj;
trial Uobj;
trial Dobj;
trial Lobj;
trial Robj;
}ovejotas;

array{
trial espera1;
trial espera1;
trial espera2;
trial espera2;
trial espera3;
trial espera3;
trial espera4;
trial espera4;
}aguanta;

#####
begin_pcl;

ovejotas.shuffle();
aguanta.shuffle();

habas.present();

loop
int j = 1
until
j > 8
begin
## Objetivo aleatorio ##

ovejotas[j].present();

## Estimulo evocador de SSVEP ##

loop
int k = 0
until
k > 5
begin

tr0000.present();

```

```
tr0001.present();
tr0000.present();
tr0101.present();
tr0100.present();
tr0111.present();
tr0010.present();
tr1011.present();
tr1010.present();
tr1111.present();
tr1100.present();
tr1101.present();
tr1000.present();
tr1001.present();
tr0000.present();
tr0111.present();
tr0110.present();
tr0111.present();
tr0010.present();
tr0011.present();
tr0000.present();
tr1101.present();
tr1100.present();
tr1101.present();
tr1000.present();
tr1011.present();
tr1010.present();
tr1111.present();
tr0110.present();
tr0111.present();
tr0000.present();
tr0001.present();
tr0000.present();
tr0101.present();
tr0100.present();
tr1111.present();
tr1010.present();
tr1011.present();
tr1010.present();
tr1111.present();
tr0100.present();
tr0101.present();
tr0000.present();
tr1011.present();
tr1010.present();
tr1111.present();
tr0100.present();
tr0101.present();
tr0000.present();
```

```
tr0001.present();
tr0000.present();
tr0111.present();
tr0110.present();
tr1111.present();
tr1010.present();
tr1011.present();
tr1000.present();
tr1101.present();
tr1100.present();
tr1101.present();
tr0000.present();
tr0011.present();
tr0010.present();
tr0111.present();
tr0110.present();
tr0111.present();
tr0000.present();
tr1001.present();
tr1000.present();
tr1101.present();
tr1100.present();
tr1111.present();
tr1010.present();
tr1011.present();
tr0010.present();
tr0111.present();
tr0100.present();
tr0101.present();
tr0000.present();
tr0001.present();
tr0000.present();
tr1111.present();
tr1110.present();
tr1111.present();
tr1010.present();
tr1011.present();
tr0000.present();
tr0101.present();
tr0100.present();
tr0101.present();
tr0000.present();
```



```

aguanta[j].present();
j = j+1;

end;

ovejotas.shuffle();
aguanta.shuffle();

habas.present();
habas.present();

loop
int j = 1
until
j > 8
begin
## Objetivo aleatorio ##

ovejotas[j].present();

## Estimulo evocador de SSVEP ##

loop
int k = 0
until
k > 5
begin

tr1000.present();
tr1001.present();
tr0001.present();
tr0011.present();
tr0010.present();
tr0110.present();
tr0100.present();
tr1101.present();

tr1101.present();
tr1111.present();
tr1010.present();
tr1010.present();
tr0000.present();
tr0001.present();

tr1000.present();
tr1001.present();
tr0001.present();
tr0011.present();
tr0010.present();
tr0110.present();
tr0100.present();
tr1101.present();
tr1101.present();
tr1111.present();
tr1010.present();
tr1010.present();
tr0000.present();
tr0001.present();

```

```
tr0001.present();
tr0111.present();
tr0110.present();
tr1110.present();
tr1100.present();
tr1101.present();
tr1001.present();
tr1011.present();
tr0010.present();
tr0010.present();
tr0000.present();
tr0101.present();
tr0101.present();
tr1111.present();
tr1110.present();
tr1110.present();
tr1000.present();
tr1001.present();
tr0001.present();
tr0011.present();
tr0010.present();
tr0110.present();
tr0100.present();
tr1101.present();
tr1101.present();
tr1111.present();
tr1010.present();
tr1010.present();
tr0000.present();
tr0001.present();
tr0001.present();
tr0111.present();
tr0110.present();
tr1110.present();
tr1100.present();
tr1101.present();
tr1001.present();
tr1011.present();
tr0010.present();
tr0010.present();
tr0000.present();
tr0101.present();
```

```
tr0101.present();
tr1111.present();
tr1110.present();
tr1110.present();
tr1000.present();
tr1001.present();
tr0001.present();
tr0011.present();
tr0010.present();
tr0110.present();
tr0100.present();
tr1101.present();
tr1101.present();
tr1111.present();
tr1010.present();
tr1010.present();
tr0000.present();
tr0001.present();
tr0001.present();
tr0111.present();
tr0110.present();
tr1110.present();
tr1100.present();
tr1101.present();
tr1001.present();
tr1011.present();
tr0010.present();
tr0010.present();
tr0000.present();
tr0101.present();
tr0101.present();
tr1111.present();
tr1110.present();
tr1110.present();
tr1000.present();
tr1001.present();
tr0001.present();
tr0011.present();
tr0010.present();
tr0110.present();
tr0100.present();
tr1101.present();
```

```

tr1101.present();
tr1111.present();
tr1010.present();
tr1010.present();
tr0000.present();
tr0001.present();
tr0001.present();
tr0111.present();
tr0110.present();
tr1110.present();
tr1100.present();
tr1101.present();
tr1001.present();
tr1011.present();
tr0010.present();
tr0010.present();
tr0000.present();
tr0101.present();
tr0101.present();

tr1111.present();
tr1110.present();
tr1110.present();

k = k + 1;
end;

## Periodo aleatorio de cambio ##

aguanta[j].present();
j = j+1;

end;

habas.present();

```

A.4. Compilador para Presentation®

A continuación se incluye el código del compilador descrito en la metodología, este compilador esta escrito para Octave [27] pero es completamente compatible con Matlab. En la descripción definitiva no se utilizó el archivo generado por este compilador pues no contempla los retrasos del hardware. Una computadora más potente o una solución específica para la presentación de estímulos podría representar el código resultante sin retrasos o artefactos.

```

%%% COMPILADOR PARA PRESENTATION
%% f_i son las frecuencias deseadas en Hz
%% arch es la cadena del archivo donde se escribira la descripcion
%% t es el tiempo en segundos que se desea presentar el estimulo
%% fb es la frecuencia de barrido en Hz
%%% elTEO@BCI-LIRINS.060

function [aux ind] = ssvepUNERrel(f1,f2,f3,f4,arch,t,fb);

```

```
if nargin < 7
fb = 85;
end;

c1 = round(fb/f1);
c2 = round(fb/f2);
c3 = round(fb/f3);
c4 = round(fb/f4);

w1 = fb / c1 % minima [Hz]
w2 = fb / c2 % [Hz]
w3 = fb / c3 % [Hz]
w4 = fb / c4 % [Hz]

pause;

t = [0:1/(10*fb):t];

fr1 = square(w1*2*pi*t);
fr2 = square(w2*2*pi*t);
fr3 = square(w3*2*pi*t);
fr4 = square(w4*2*pi*t);

c_1 = diff([-1 fr1]/2);
c_2 = diff([-1 fr2]/2);
c_3 = diff([-1 fr3]/2);
c_4 = diff([-1 fr4]/2);

cambios = abs(c_1)+abs(c_2)+abs(c_3)+abs(c_4);
plot(cambios);

ind = find(cambios != 0);

fid = fopen(arch,'w');
```

```
s1 = '0';
s2 = '0';
s3 = '0';
s4 = '0';

fprintf(fid,['\n trial{ \n'}]);

for k = 2:length(ind);
if (abs(c_1(ind(k))) == 1)
s1 = not(s1);
end;
if (abs(c_2(ind(k))) == 1)
s2 = not(s2);
end;
if (abs(c_3(ind(k))) == 1)
s3 = not(s3);
end;
if (abs(c_4(ind(k))) == 1)
s4 = not(s4);
end;
fprintf(fid, ['\t picture Osc' num2str(s1) num2str(s2) num2str(s3) num2str(s4) ' ';
            '\n \t deltat = ' num2str(round((ind(k)-ind(k-1))/(10*fb)/1e-3)) ' ';
            '\n \t port_code = ' num2str(sum([2^3 2^2 2^1 2^0].*[abs(c_4(ind(k)))
            abs(c_3(ind(k))) abs(c_2(ind(k))) abs(c_1(ind(k)))])) ' ';
            '\n \n']);
aux(k) = sum([2^3 2^2 2^1 2^0].*[abs(c_4(ind(k))) abs(c_3(ind(k)))
abs(c_2(ind(k))) abs(c_1(ind(k)))]);

end;

fprintf(fid,['}ozzy;\n']);

fclose(fid);
```

```
endfunction;
```

A.5. Compilador para la descripción utilizada

Debido a la regularidad de la presentación de los escenarios en la descripción definitiva, un segundo compilador fue escrito para el *loop-unrolling*. El código siguiente escribe las secuencias mostradas en los experimentos de 4 clases y de fase.

```
%%% FUNCION PARA LOOP-UNROLLING %%%  
% f_i es la secuencia que se quiere presentar, descrita como una onda cuadrada  
% de entre 1 y 0.  
% arch es el nombre del archivo al que se escribira la secuencia.  
%%%  
%%% e1TEO@BCI-LIRINS.060  
  
function stimfreqARG(f1,f2,f3,f4,arch);  
  
fid = fopen(arch,'w');  
  
for k = 1:length(f1);  
fprintf(fid,['\t tr' num2str(f1(k)) num2str(f2(k))  
num2str(f3(k)) num2str(f4(k)) '.present(); \n']);  
end;  
  
fclose(fid);  
  
endfunction;
```

Apéndice B

Implementación de MUSIC en Octave

En este apéndice se muestra el código de la función escrita para la extracción de características en el análisis fuera de línea. En general, se calcula el pseudospectro para observar el contenido en frecuencia y se calculan los valores del mismo a las frecuencias seleccionadas y sus armónicos. Una extensión a cuatro clases, que incluye las frecuencias de estímulo c y d , fue utilizada para la extracción de características de las épocas del experimento de cuatro clases. Dicha extensión se presenta inmediatamente después de la función formal.

B.1. Función utilizada para dos y tres clases

```
function [ps car] = smusicu(s,n,fs,a,b,u);

%
% funcion para calcular MUSIC sobre un ensamble de registros de eeg,
% determina el pseudospectro y su valor en [0.5 1 2 3]*{A, B} como
% características para su clasificacion
%
% [PS CAR] = SMUSICU(S,N,FS,A,B,U)
%
% parametros de entrada
%
% S ensamble de registros de eeg, matriz K x L con L registros de
%     K muestras
%
% N numero de se;ales que se generan para obtener el pseudoespectro,
```

```

%     aunque el metodo tiene resolucion infinita, su calculo requiere de un
%     numero finito de frecuencias para llevarse a cabo
%
% FS frecuencia de muestreo del ensamble, se utiliza para generar las
%     se~nales que se proyectaran sobre el subespacio de se;al
%
% A,B frecuencias en Hertz que se quieren clasificar
%
% U umbral de para la generacion del subespacio de proyeccion,
%      $U \in \{0, 1\}$ 
%
% parametros de salida
%
% PS ensamble de pseudoespectros correspondiente a aplicar MUSIC a S
%
% CAR ensamble de vectores de caracteristicas para clasificar las epocas de S
%
% elTEO@BCI-LINI.06P
%

%% inicializacion de la matriz PS
ps = zeros(n/2,size(s,2));

%% ciclo para aplicar MUSIC a cada epoca del ensamble
for k = 1:size(s,2);
waitbar(k/size(s,2));

%% se aplica MUSIC sobre una copia de cada epoca
aux = s(:,k);

%% estimacion de la matriz de correlacion
corr = xcorr(aux,'biased');
m_corr = toeplitz(corr(size(aux,1):(2*(size(aux,1)))-1));

%% descomposicion en eigenvectores y eigenvalores

```



```

%% generacion del espacio conjunto de características para ambas frecuencias
car = log(abs([psa;psb]));

endfunction;

```

B.2. Extensión a cuatro clases

```

% e1TE0@BCI-LIRINS.060

function [ps car] = smusicARG(s,n,fs,a,b,c,d,u);

%% inicializacion de la matriz PS, no es necesario pero
% de esta forma se ejecuta mas rapido la funcion
ps = zeros(n/2,size(s,2));

%% ciclo para aplicar MUSIC a cada epoca del ensamble,
% asi hasta que no se encuentre una mejor forma
for k = 1:size(s,2);
waitbar(k/size(s,2));

%% se aplica MUSIC sobre una copia de cada epoca
% y el resultado se pasa a PS
aux = s(:,k);

%% estimacion de la matriz de correlacion
corr = xcorr(aux,'biased');
m_corr = toeplitz(corr(size(aux,1):(2*(size(aux,1)))-1));

%% descomposicion en eigenvectores y eigenvalores
[e l] = eig(m_corr);
l = diag(1/max(max(l)));

%% generacion del subespacio de proyeccion

```

```

E = e(:,find(cumsum(1)<=u*sum(1)));

%% generacion de los vectores de prueba para la proyeccion
% sobre el subespacio
w = [0:pi/(n/2-1):pi];
Z =j*w'*[0:fs-1];
S = exp(Z);

%% proyeccion y calculo del pseudospectro
pw = E*E'*S';
ps(:,k) = log(abs([1./sum(pw.*conj(pw))]''));

%% generacion de los vectores de prueba para la extraccion
% de caracteristicas
wa = (a*2.^[-1:2])*pi/(fs/2);
wb = (b*2.^[-1:2])*pi/(fs/2);
wc = (c*2.^[-1:2])*pi/(fs/2);
wd = (d*2.^[-1:2])*pi/(fs/2);

%% Extraccion de caracteristicas
%%%%%% INICIO %%%%%%
Za =j*wa'*[0:fs-1];
Sa = exp(Za);

pwa = E*E'*Sa';
psa(:,k) = [1./sum(pwa.*conj(pwa))]'';

Zb =j*wb'*[0:fs-1];
Sb = exp(Zb);

pwb = E*E'*Sb';
psb(:,k) = [1./sum(pwb.*conj(pwb))]'';

Zc =j*wc'*[0:fs-1];
Sc = exp(Zc);

```

```
pwc = E*E'*Sc';
psc(:,k) = [1./sum(pwc.*conj(pwc))]' ;

Zd =j*wd'*[0:fs-1];
Sd = exp(Zd);

pwd = E*E'*Sd';
psd(:,k) = [1./sum(pwd.*conj(pwd))]' ;
%%%%%% FIN %%%%%%%%%

end;

%% generacion del espacio conjunto de caracteristicas
% para todas las frecuencias
car = log(abs([psa;psb;psc;psd]));

endfunction;
```

Apéndice C

Compilación de resultados

C.1. Validación de MUSIC I: Señales sintéticas

Las figuras (C.1-C.4) muestran los resultados de calcular el espectro con la DFT y el pseudo-espectro con tres diferentes umbrales de MUSIC en cada uno de los conjuntos de señales sintéticas. En el capítulo 5 se muestran las gráficas contenidas en fig. C.1 como ejemplo. La figura C.5 muestra el resultado de calcular el pseudo-espectro con un umbral $u = 0.9$ para el ensamble $t[n]$, donde cada uno de los elementos se forma con la suma aleatoria de un elemento de cada uno de los ensambles originales $x_1 : x_4$.

C.2. Validación de MUSIC II: Senoidales puras

Recordando que para esta parte de la validación se adquirieron 15 s de ondas senoidales puras directamente de la salida de un generador de funciones en un amplio rango de frecuencias (ver capítulo 4). Este apéndice contiene las gráficas del espectro promedio obtenido con la DFT de 1024 puntos (figura C.6), del pseudo-espectro con un valor umbral de 0.1 (figura C.7) y con un umbral de 0.5 (figura C.8). Note la diferencia en amplitud de cada una de las representaciones en frecuencia y la capacidad del algoritmo MUSIC para identificar la presencia de frecuencias de interés atenuadas por efectos de los filtros.

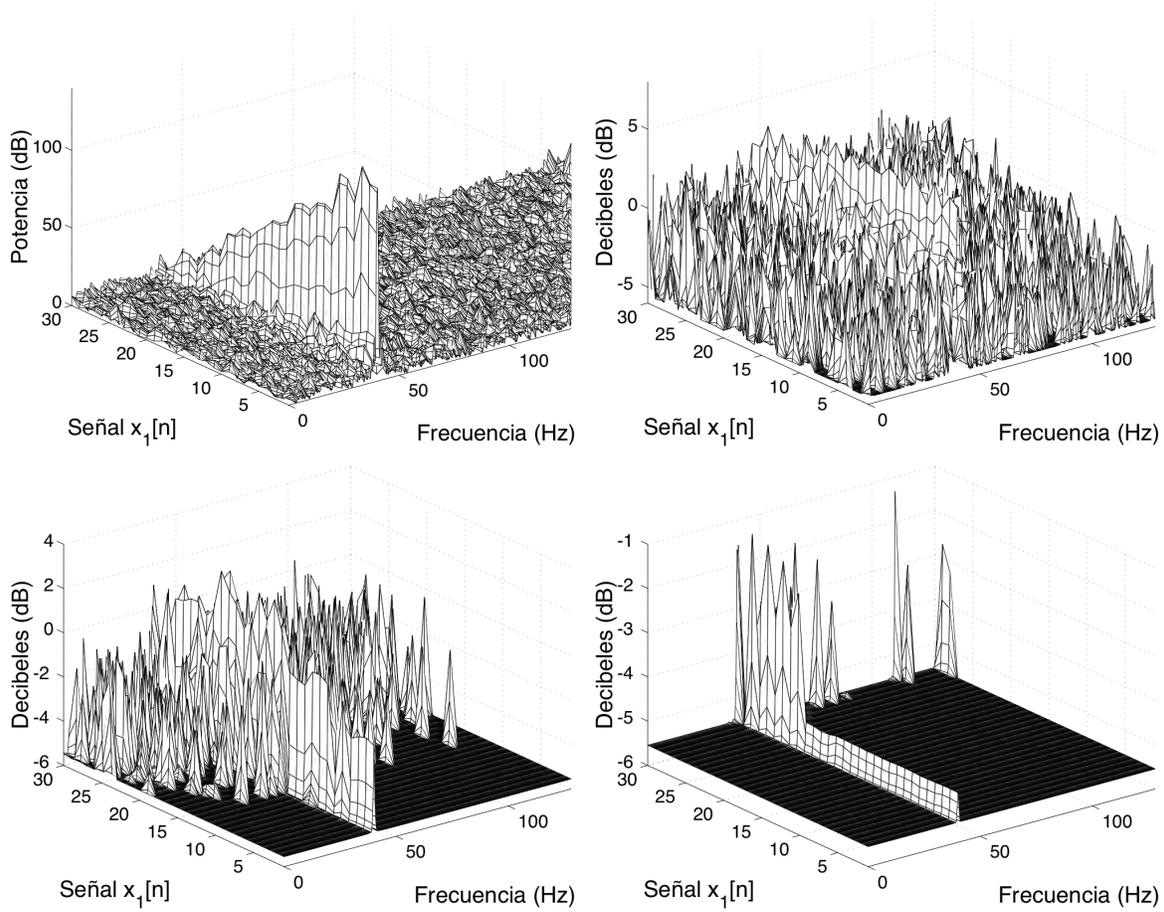


Figura C.1: Espectro y pseudo-espectros de las señales sintéticas a 38 Hz, conjunto x_1 . Los umbrales de MUSIC utilizados para obtener estos pseudo-espectros son $u = \{0.1, 0.4, 0.9\}$, todas las representaciones en frecuencia se obtuvieron con 512 puntos en el rango de 0 a 128 Hz.

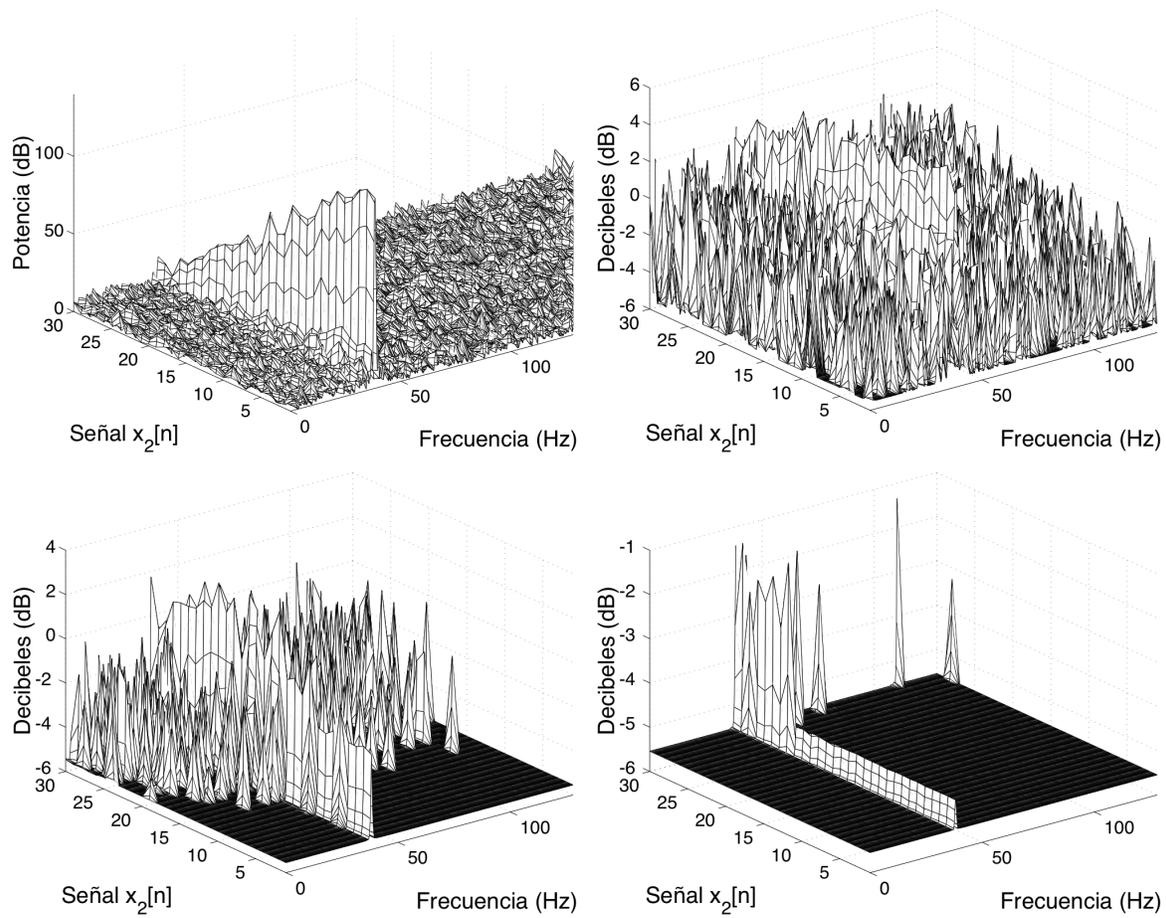


Figura C.2: Espectro y pseudo-espectros de las señales sintéticas a 40 Hz, conjunto x_2 . Los umbrales de MUSIC utilizados para obtener estos pseudo-espectros son $u = \{0.1, 0.4, 0.9\}$, todas las representaciones en frecuencia se obtuvieron con 512 puntos en el rango de 0 a 128 Hz.

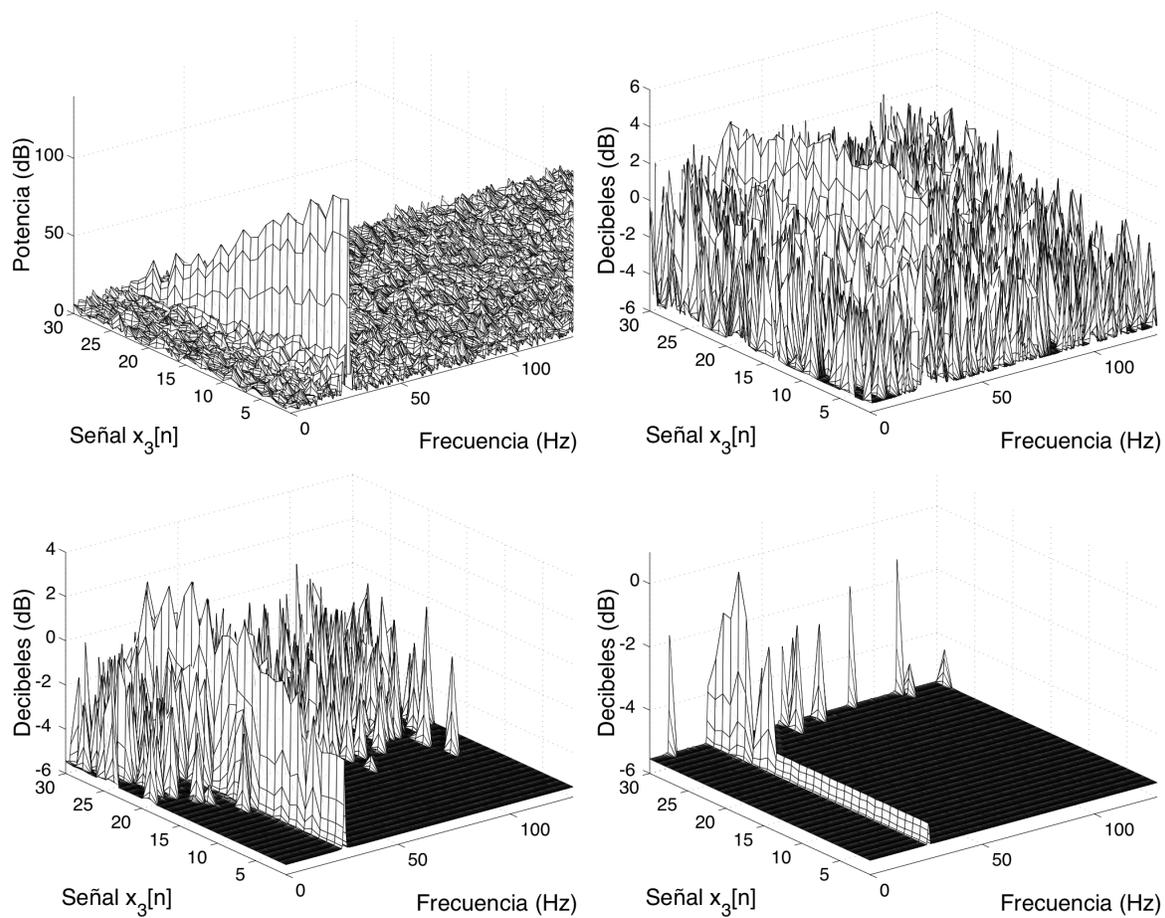


Figura C.3: Espectro y pseudo-espectros de las señales sintéticas a 25 Hz, conjunto x_3 . Los umbrales de MUSIC utilizados para obtener estos pseudo-espectros son $u = \{0.1, 0.4, 0.9\}$, todas las representaciones en frecuencia se obtuvieron con 512 puntos en el rango de 0 a 128 Hz.

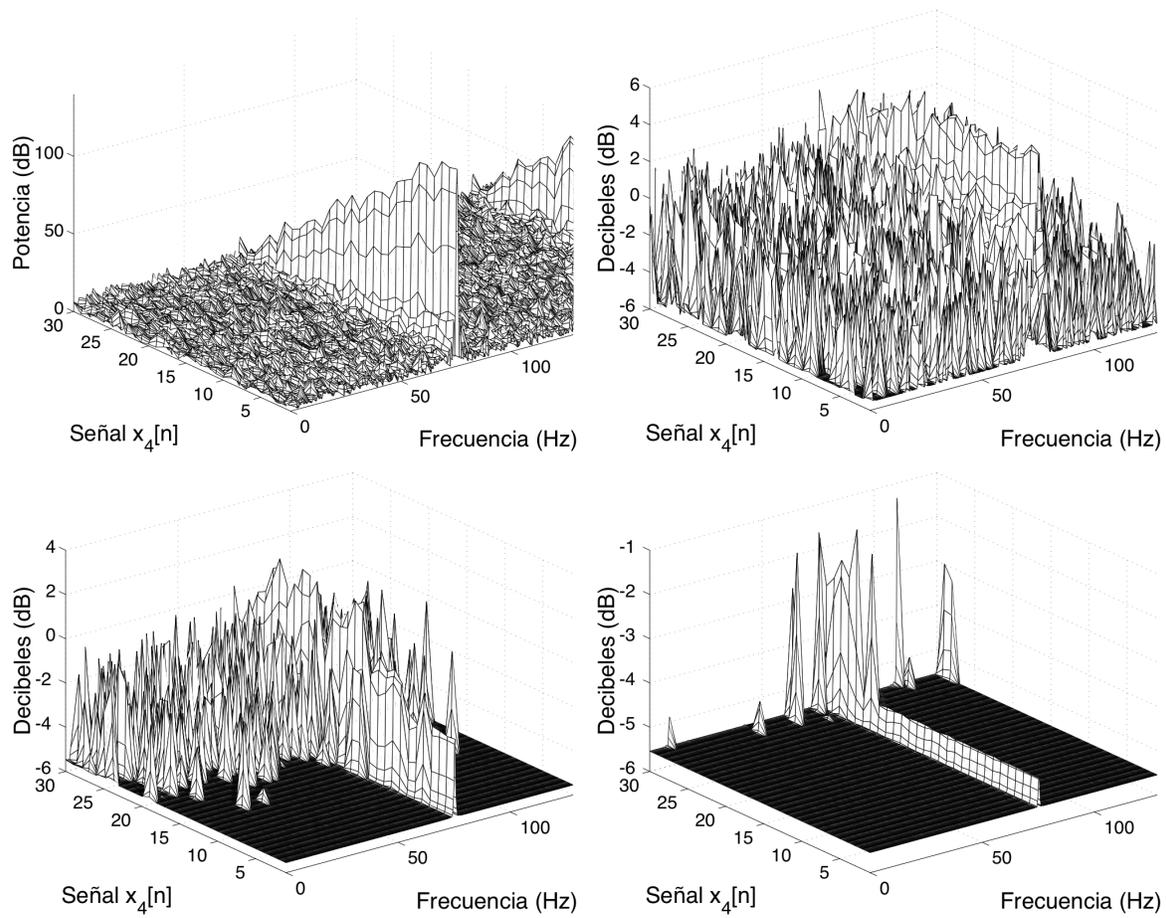


Figura C.4: Espectro y pseudo-espectros de las señales sintéticas a 75 Hz, conjunto x_4 . Los umbrales de MUSIC utilizados para obtener estos pseudo-espectros son $u = \{0.1, 0.4, 0.9\}$, todas las representaciones en frecuencia se obtuvieron con 512 puntos en el rango de 0 a 128 Hz.

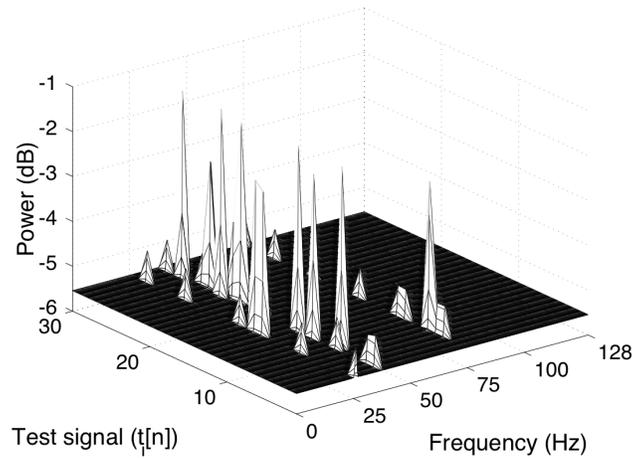


Figura C.5: Pseudo-espectro del conjunto de señales sintéticas $t_i[n]$ formado por la suma aleatoria de los elementos de $x_1 : x_4$. En este caso el umbral de MUSIC es $u = 0.9$, en esta demostración los niveles de SNR de los componentes x_i pueden o no ser iguales debido a la suma aleatoria.

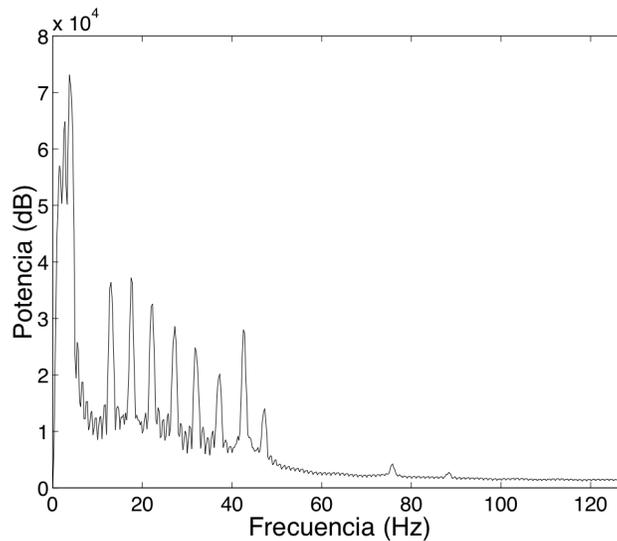


Figura C.6: Espectro de potencia promedio para las senoidales puras adquiridas con el sistema prototipo de adquisición para la BCI diseñada en esta tesis. Note los lóbulos en las frecuencias atenuadas o de ruido. Además observe la atenuación debida a la aplicación de los filtros, visible en la amplitud de las componentes de frecuencia antes de la banda de rechazo.

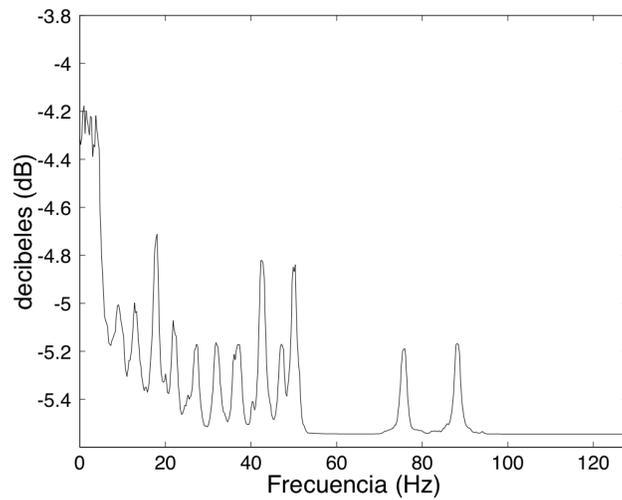


Figura C.7: Pseudo-espectro promedio de las senoidales digitalizadas obtenido con un umbral para MUSIC $u = 0.1$, observe el mantenimiento de la amplitud y cómo esta se ve afectada solo por la promediación. El componente de 50 Hz está asociado con el ruido de línea.

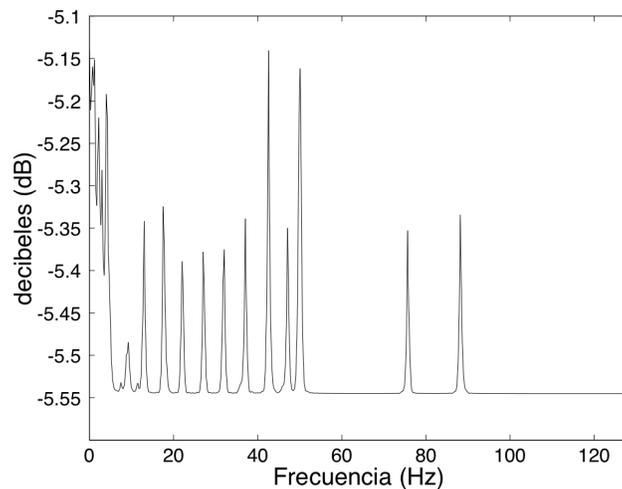


Figura C.8: Pseudo-espectro promedio de las senoidales digitalizadas obtenido con un umbral para MUSIC $u = 0.5$, nótese la definición de los picos y los valores en las frecuencias asociadas con ruido.

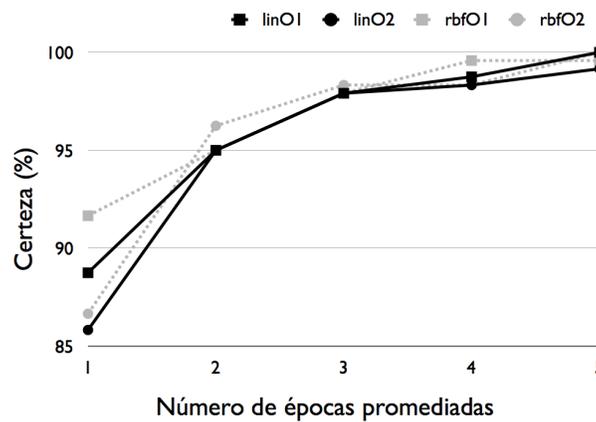


Figura C.9: Tasa de clasificación (ACC) para el promedio de las características extraídas de k épocas. Los análisis incluyeron SVM con núcleo lineal (lin-SVM, línea sólida) y núcleo gaussiano (rbf-SVM, línea punteada) utilizando las características extraídas de los electrodos O1 (cuadrados) y O2 (círculos).

C.3. Detección de SSVEP: dos clases

La evaluación del desempeño para la clasificación de dos clases diferentes de SSVEP (evocados a 28 Hz y 35 Hz) se realizó con mediciones de valores de certeza mediante la validación cruzada otorgada por la librería lib-SVM [29]. Se presenta el valor promedio debido a que la desviación estándar es muy pequeña. La figura C.9 muestra el valor promedio de la clasificación para cada uno de los electrodos y las arquitecturas de SVM como función del número de épocas promediadas.

C.4. Detección de SSVEP: tres clases

En los siguientes cuadros se muestran los resultados completos del entrenamiento para las lin-SVM con los datos de tres clases. Las medidas de desempeño fueron la certeza (ACC) y el área bajo la curva de características relativas de operación (A_z), para extraer características se utilizaron los electrodos O1 y O2 y la concatenación de las características de ambos electrodos.

Los cuadros C.1, C.3, C.9 muestran las tasas de clasificación obtenidas para un umbral $u = 0.1$, los cuadros C.2, C.4, C.10 para $u = 0.05$ y los cuadros C.5, C.7, C.11 muestran el valor de A_z para $u = 0.1$ y C.6, C.8, C.12 para $u = 0.05$. Los datos presentados en el capítulo 5 corresponden a los cuadros C.9, C.10, C.11 y C.12, dado que en la mayoría de los casos ayuda a incrementar la tasa de clasificación y/o disminuir la desviación estándar.

Cuadro C.1: Valores de certeza obtenidos con el uso de características extraídas de épocas del electrodo O1 con un umbral $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	53.89 ± 0.96	51.67 ± 10.00	53.33 ± 6.01	50.00 ± 0.00	62.78 ± 5.09
C_1 vs C_0	60.67 ± 1.15	86.00 ± 4.00	85.33 ± 9.87	88.00 ± 2.00	78.67 ± 8.08
C_{-1} vs C_0	60.67 ± 3.06	79.33 ± 5.03	86.67 ± 4.16	90.00 ± 4.00	84.67 ± 1.15
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	53.33 ± 3.33	53.33 ± 6.01	62.78 ± 8.39	56.67 ± 3.33	96.67 ± 2.89
C_1 vs C_0	95.33 ± 2.31	87.33 ± 2.31	65.33 ± 5.03	84.00 ± 4.00	68.00 ± 9.17
C_{-1} vs C_0	92.00 ± 2.00	82.00 ± 4.00	64.00 ± 4.00	81.33 ± 2.31	97.33 ± 3.06

Cuadro C.2: Valores de certeza obtenidos con el uso de características extraídas de épocas del electrodo O1 con un umbral $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	57.22 ± 5.85	51.11 ± 1.92	50.00 ± 0.00	53.89 ± 1.92	62.78 ± 2.55
C_1 vs C_0	67.33 ± 3.06	90.67 ± 5.03	81.33 ± 3.06	82.00 ± 6.00	78.67 ± 3.06
C_{-1} vs C_0	62.67 ± 3.06	86.67 ± 6.11	82.67 ± 1.15	88.67 ± 6.11	80.67 ± 3.06
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	52.78 ± 9.48	51.67 ± 8.33	62.22 ± 0.96	57.78 ± 3.47	91.67 ± 2.89
C_1 vs C_0	95.33 ± 3.06	90.00 ± 3.46	66.00 ± 2.00	85.33 ± 1.15	76.67 ± 9.87
C_{-1} vs C_0	94.00 ± 3.46	89.33 ± 5.03	62.00 ± 2.00	82.67 ± 4.16	98.00 ± 0.00

Cuadro C.3: Valores de certeza obtenidos con el uso de características extraídas de épocas del electrodo O2 con un umbral $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	53.33 ± 1.67	59.44 ± 3.47	62.78 ± 1.92	51.11 ± 1.92	57.22 ± 8.55
C_1 vs C_0	62.00 ± 10.58	93.33 ± 5.77	90.67 ± 2.31	88.00 ± 2.00	80.00 ± 2.00
C_{-1} vs C_0	60.00 ± 0.00	83.33 ± 1.15	88.00 ± 5.29	91.33 ± 5.03	79.33 ± 4.16
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	53.89 ± 2.55	50.56 ± 2.55	54.44 ± 1.92	67.22 ± 5.09	72.78 ± 6.94
C_1 vs C_0	89.33 ± 4.62	82.00 ± 2.00	80.00 ± 2.00	91.33 ± 2.31	60.00 ± 0.00
C_{-1} vs C_0	87.33 ± 2.31	81.33 ± 3.06	84.00 ± 6.93	80.67 ± 1.15	72.00 ± 8.00

Cuadro C.4: Valores de certeza obtenidos con el uso de características extraídas de épocas del electrodo $O2$ con un umbral $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	54.44 ± 6.74	57.78 ± 1.92	53.33 ± 7.26	55.00 ± 5.00	50.56 ± 0.96
C_1 vs C_0	70.67 ± 2.31	96.67 ± 2.31	84.67 ± 1.15	83.33 ± 8.33	82.67 ± 3.06
C_{-1} vs C_0	69.33 ± 6.11	90.00 ± 5.29	86.00 ± 7.21	86.00 ± 5.29	82.67 ± 5.77
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	54.44 ± 0.96	57.22 ± 0.96	55.00 ± 7.26	70.56 ± 3.47	65.56 ± 0.96
C_1 vs C_0	93.33 ± 4.16	88.67 ± 4.16	77.33 ± 3.06	87.33 ± 2.31	76.00 ± 5.29
C_{-1} vs C_0	91.33 ± 3.06	86.00 ± 3.46	77.33 ± 9.02	80.67 ± 1.15	82.67 ± 5.77

C.4.1. Área bajo la curva ROC, A_z

Los cuadros de este apartado corresponden a las medidas de A_z obtenidas durante los mismos experimentos de los cuadros de ACC. En esta tesis se incluye el uso de esta medida para representar mejor la información de la matriz de confusión. En este caso la prevalencia de las clases es 50% pero se utiliza este conjunto de experimentos para mostrar la relación entre ACC y A_z . Las gráficas de los datos contenidos en los cuadros C.11 y C.12 se muestran en el capítulo 5.

Cuadro C.5: Valores de A_z obtenidos con el uso de características extraídas de épocas del electrodo $O1$ con un umbral $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.59 ± 0.05	0.52 ± 0.08	0.52 ± 0.07	0.54 ± 0.03	0.65 ± 0.04
C_1 vs C_0	0.69 ± 0.06	0.94 ± 0.03	0.92 ± 0.07	0.92 ± 0.04	0.85 ± 0.05
C_{-1} vs C_0	0.61 ± 0.17	0.91 ± 0.03	0.92 ± 0.05	0.95 ± 0.02	0.89 ± 0.03
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.55 ± 0.05	0.60 ± 0.13	0.67 ± 0.07	0.57 ± 0.03	0.99 ± 0.01
C_1 vs C_0	0.99 ± 0.00	0.96 ± 0.02	0.73 ± 0.07	0.90 ± 0.05	0.75 ± 0.10
C_{-1} vs C_0	0.96 ± 0.03	0.89 ± 0.02	0.66 ± 0.07	0.88 ± 0.04	1.00 ± 0.00

Cuadro C.6: Valores de A_z obtenidos con el uso de características extraídas de épocas del electrodo $O1$ con un umbral $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.61 ± 0.04	0.58 ± 0.04	0.52 ± 0.06	0.58 ± 0.01	0.68 ± 0.06
C_1 vs C_0	0.76 ± 0.05	0.96 ± 0.03	0.89 ± 0.03	0.88 ± 0.09	0.82 ± 0.05
C_{-1} vs C_0	0.68 ± 0.08	0.95 ± 0.01	0.89 ± 0.06	0.92 ± 0.06	0.85 ± 0.06
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.54 ± 0.04	0.57 ± 0.13	0.65 ± 0.03	0.57 ± 0.05	0.97 ± 0.02
C_1 vs C_0	1.00 ± 0.01	0.94 ± 0.04	0.68 ± 0.02	0.91 ± 0.03	0.87 ± 0.05
C_{-1} vs C_0	0.98 ± 0.03	0.94 ± 0.03	0.63 ± 0.02	0.89 ± 0.07	1.00 ± 0.00

Cuadro C.7: Valores de A_z obtenidos con el uso de características extraídas de épocas del electrodo $O2$ con un umbral $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.57 ± 0.02	0.64 ± 0.08	0.67 ± 0.01	0.59 ± 0.12	0.60 ± 0.10
C_1 vs C_0	0.64 ± 0.08	0.98 ± 0.02	0.96 ± 0.04	0.93 ± 0.04	0.90 ± 0.02
C_{-1} vs C_0	0.70 ± 0.07	0.92 ± 0.02	0.94 ± 0.03	0.94 ± 0.04	0.88 ± 0.03
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.60 ± 0.12	0.53 ± 0.02	0.54 ± 0.02	0.73 ± 0.06	0.75 ± 0.14
C_1 vs C_0	0.97 ± 0.02	0.91 ± 0.01	0.83 ± 0.01	0.96 ± 0.03	0.55 ± 0.16
C_{-1} vs C_0	0.96 ± 0.03	0.88 ± 0.05	0.88 ± 0.04	0.89 ± 0.01	0.79 ± 0.08

Cuadro C.8: Valores de A_z obtenidos con el uso de características extraídas de épocas del electrodo $O2$ con un umbral $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.53 ± 0.05	0.62 ± 0.05	0.57 ± 0.09	0.54 ± 0.08	0.51 ± 0.04
C_1 vs C_0	0.78 ± 0.08	0.99 ± 0.01	0.91 ± 0.05	0.86 ± 0.06	0.88 ± 0.04
C_{-1} vs C_0	0.77 ± 0.04	0.97 ± 0.01	0.93 ± 0.02	0.88 ± 0.07	0.89 ± 0.10
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.52 ± 0.07	0.58 ± 0.05	0.54 ± 0.09	0.71 ± 0.09	0.76 ± 0.12
C_1 vs C_0	0.98 ± 0.03	0.95 ± 0.01	0.81 ± 0.04	0.94 ± 0.01	0.83 ± 0.05
C_{-1} vs C_0	0.97 ± 0.02	0.91 ± 0.07	0.81 ± 0.09	0.88 ± 0.03	0.90 ± 0.08

Cuadro C.9: Valores de certeza obtenidos con la concatenación de características extraídas de los electrodos $O1$ y $O2$ con un umbral $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	55.00 ± 1.67	58.33 ± 3.82	58.33 ± 1.44	50.00 ± 3.82	63.06 ± 1.73
C_1 vs C_0	64.00 ± 1.00	89.33 ± 1.15	86.67 ± 4.73	89.00 ± 2.00	82.00 ± 3.00
C_{-1} vs C_0	61.33 ± 1.15	83.67 ± 1.53	86.67 ± 3.51	91.33 ± 3.06	80.67 ± 2.89
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	50.00 ± 0.00	51.94 ± 3.47	58.89 ± 0.96	59.17 ± 0.83	83.89 ± 2.93
C_1 vs C_0	92.67 ± 2.08	84.67 ± 4.73	76.67 ± 3.21	89.33 ± 2.08	65.67 ± 1.53
C_{-1} vs C_0	90.00 ± 3.61	81.00 ± 5.20	75.00 ± 2.65	80.33 ± 3.06	85.67 ± 5.51

Cuadro C.10: Valores de certeza obtenidos con la concatenación de características extraídas de los electrodos $O1$ y $O2$ con un umbral $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	56.67 ± 3.33	58.33 ± 2.20	51.11 ± 3.94	58.61 ± 4.81	60.56 ± 0.96
C_1 vs C_0	73.33 ± 2.52	94.33 ± 3.06	82.67 ± 3.51	83.00 ± 2.65	80.00 ± 2.65
C_{-1} vs C_0	70.00 ± 2.65	89.00 ± 3.61	85.33 ± 4.93	85.67 ± 1.53	81.33 ± 1.53
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	51.11 ± 3.76	55.83 ± 8.78	58.33 ± 4.33	59.44 ± 2.55	79.17 ± 2.50
C_1 vs C_0	95.67 ± 1.53	89.67 ± 2.08	73.00 ± 4.00	87.67 ± 3.06	78.67 ± 4.51
C_{-1} vs C_0	93.67 ± 1.53	87.67 ± 1.53	70.00 ± 4.36	80.33 ± 1.53	92.00 ± 2.65

C.5. Detección de SSVEP: cuatro clases

El último conjunto de sujetos¹ registrados atendieron a un experimento donde se evocan cuatro diferentes SSVEP con cuatro frecuencias distintas. Para abordar la clasificación de estas clases se entrenaron cuatro lin-SVM para la clasificación binaria uno contra todos. De esta forma la prevalencia de las clases C_1 es 25% y $\{C_2, C_3, C_4\}$ es 75% por lo tanto los valores de ACC estan sesgados por la prevalencia. Por lo tanto las medidas de A_z (cuadros C.19-C.24) son mejores para observar el desempeño de los clasificadores. Los electrodos $O1$, $O2$ y Oz fueron utilizados durante los registros y los datos mostrados en el capítulo 5 fueron extraídos de estos cuadros, seleccionando los máximos para cada sujeto y cada clase.

¹Los sujetos marcados con un * corresponden a la segunda presentación del paradigma, inmediata a la primera con un intervalo de descanso no menor a 5 min. Al ser la segunda repetición de una sola sesión se habían considerado independientes, sin embargo pueden notarse diferencias en el desempeño.

Cuadro C.11: Valores de A_z obtenidos con la concatenación de características extraídas de los electrodos $O1$ y $O2$ con un umbral $u = 0.1$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.59 ± 0.03	0.62 ± 0.04	0.60 ± 0.01	0.50 ± 0.03	0.68 ± 0.02
C_1 vs C_0	0.70 ± 0.03	0.96 ± 0.01	0.93 ± 0.03	0.93 ± 0.03	0.88 ± 0.03
C_{-1} vs C_0	0.69 ± 0.05	0.91 ± 0.04	0.94 ± 0.02	0.95 ± 0.03	0.88 ± 0.00
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.50 ± 0.03	0.50 ± 0.03	0.63 ± 0.01	0.62 ± 0.04	0.89 ± 0.03
C_1 vs C_0	0.97 ± 0.01	0.93 ± 0.02	0.81 ± 0.01	0.94 ± 0.01	0.71 ± 0.05
C_{-1} vs C_0	0.97 ± 0.01	0.90 ± 0.04	0.78 ± 0.03	0.87 ± 0.03	0.92 ± 0.04

Cuadro C.12: Valores de A_z obtenidos con la concatenación de características extraídas de los electrodos $O1$ y $O2$ con un umbral $u = 0.05$

Clasificador	S1	S2	S3	S4	S5
C_1 vs C_{-1}	0.59 ± 0.05	0.60 ± 0.03	0.51 ± 0.05	0.60 ± 0.02	0.64 ± 0.04
C_1 vs C_0	0.82 ± 0.04	0.98 ± 0.00	0.89 ± 0.02	0.86 ± 0.03	0.86 ± 0.02
C_{-1} vs C_0	0.78 ± 0.02	0.95 ± 0.01	0.92 ± 0.02	0.90 ± 0.02	0.89 ± 0.01
Clasificador	S6	S7	S8	S9	S10
C_1 vs C_{-1}	0.51 ± 0.03	0.57 ± 0.01	0.62 ± 0.04	0.61 ± 0.01	0.88 ± 0.02
C_1 vs C_0	0.99 ± 0.01	0.94 ± 0.01	0.76 ± 0.07	0.93 ± 0.01	0.88 ± 0.04
C_{-1} vs C_0	0.98 ± 0.01	0.94 ± 0.02	0.73 ± 0.07	0.88 ± 0.03	0.96 ± 0.01

Cuadro C.13: Medidas de ACC para el electrodo $O1$ y un umbral de 0.1

Sujeto	C_1	C_2	C_3	C_4
A1	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A2	75.00±0.00	75.00±0.00	76.67±2.89	75.00±0.00
A3	75.00±0.00	75.00±0.00	77.50±2.50	75.00±0.00
A4	75.83±1.44	75.00±0.00	75.00±0.00	75.83±1.44
A5	75.00±0.00	75.00±0.00	78.33±2.89	75.83±1.44
A6	75.00±0.00	75.00±0.00	75.83±1.44	75.00±0.00
A7	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A8	75.83±6.29	75.00±0.00	75.00±0.00	75.00±0.00
A8*	75.00±0.00	75.00±0.00	82.50±6.61	75.00±0.00
A9	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A9*	75.00±0.00	75.00±0.00	75.00±0.00	75.83±1.44

Cuadro C.14: Medidas de ACC para el electrodo *O1* y un umbral de 0.05

Sujeto	C_1	C_2	C_3	C_4
A1	75.00±0.00	75.00±0.00	75.00±0.00	75.83±1.44
A2	75.83±1.44	75.00±0.00	75.00±0.00	75.00±0.00
A3	75.00±0.00	75.00±0.00	75.83±1.44	77.50±4.33
A4	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A5	75.00±0.00	75.83±1.44	75.00±0.00	75.83±1.44
A6	75.83±1.44	75.00±0.00	75.00±0.00	75.00±0.00
A7	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A8	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A8*	75.00±0.00	75.00±0.00	75.00±0.00	79.17±5.20
A9	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A9*	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00

Cuadro C.15: Medidas de ACC para el electrodo *O2* y un umbral de 0.1

Sujeto	C_1	C_2	C_3	C_4
A1	75.00±0.00	75.00±0.00	75.00±0.00	75.83±1.44
A2	75.00±0.00	77.50±2.50	82.50±2.50	75.00±0.00
A3	75.83±1.44	75.00±0.00	92.50±4.33	77.50±0.00
A4	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A5	75.00±0.00	75.00±0.00	75.00±0.00	75.83±1.44
A6	75.83±1.44	75.00±0.00	75.83±1.44	75.00±0.00
A7	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A8	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A8*	75.83±1.44	75.00±0.00	79.17±1.44	75.00±0.00
A9	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A9*	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00

Cuadro C.16: Medidas de ACC para el electrodo O_2 y un umbral de 0.05

Sujeto	C_1	C_2	C_3	C_4
A1	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A2	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A3	75.83±1.44	75.00±0.00	80.00±4.33	75.83±1.44
A4	75.83±1.44	75.83±1.44	75.00±0.00	75.00±0.00
A5	75.00±0.00	75.83±3.82	75.00±0.00	75.00±0.00
A6	75.83±1.44	75.00±0.00	75.00±0.00	76.67±2.89
A7	75.00±0.00	75.00±0.00	75.83±1.44	75.00±0.00
A8	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A8*	75.83±1.44	75.00±0.00	77.50±2.50	75.00±0.00
A9	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A9*	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00

Cuadro C.17: Medidas de ACC para el electrodo O_z y un umbral de 0.1

Sujeto	C_1	C_2	C_3	C_4
A1	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A2	75.00±0.00	75.83±1.44	80.83±1.44	75.00±0.00
A3	75.00±0.00	75.00±0.00	78.33±1.44	76.67±2.89
A4	75.83±1.44	75.00±0.00	75.00±0.00	75.83±1.44
A5	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A6	75.00±0.00	75.00±0.00	76.67±5.20	75.83±1.44
A7	75.00±0.00	75.83±0.00	75.00±0.00	75.83±1.44
A8	76.67±2.89	75.00±0.00	75.00±0.00	75.00±0.00
A8*	75.00±0.00	75.00±0.00	85.00±6.61	75.00±0.00
A9	75.00±0.00	75.00±0.00	76.67±2.89	75.00±0.00
A9*	75.83±1.44	75.00±0.00	75.00±0.00	77.50±4.33

Cuadro C.18: Medidas de ACC para el electrodo Oz y un umbral de 0.05

Sujeto	C_1	C_2	C_3	C_4
A1	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A2	75.83±1.44	75.83±1.44	75.00±2.50	75.00±0.00
A3	75.00±0.00	75.00±0.00	75.83±1.44	75.00±0.00
A4	75.00±0.00	75.00±0.00	75.83±1.44	75.00±0.00
A5	77.50±4.33	75.83±1.44	75.83±1.44	75.00±0.00
A6	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A7	75.00±0.00	75.83±1.44	75.00±0.00	75.00±0.00
A8	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A8*	76.67±2.89	75.00±0.00	75.00±0.00	75.00±0.00
A9	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00
A9*	75.00±0.00	75.00±0.00	75.00±0.00	75.00±0.00

Cuadro C.19: Medidas de A_z para el electrodo $O1$ y un umbral de 0.1

Sujeto	C_1	C_2	C_3	C_4
A1	0.66±0.03	0.63±0.10	0.59±0.07	0.68±0.05
A2	0.69±0.05	0.63±0.08	0.71±0.06	0.55±0.14
A3	0.53±0.08	0.55±0.08	0.71±0.13	0.67±0.08
A4	0.63±0.08	0.66±0.16	0.59±0.09	0.64±0.10
A5	0.59±0.08	0.53±0.14	0.67±0.11	0.53±0.04
A6	0.55±0.08	0.58±0.03	0.56±0.04	0.52±0.09
A7	0.51±0.15	0.64±0.04	0.60±0.05	0.59±0.05
A8	0.62±0.05	0.63±0.05	0.68±0.08	0.72±0.08
A8*	0.57±0.04	0.57±0.05	0.87±0.04	0.55±0.09
A9	0.64±0.15	0.71±0.08	0.65±0.10	0.58±0.08
A9*	0.56±0.07	0.69±0.01	0.60±0.10	0.76±0.07

Cuadro C.20: Medidas de A_z para el electrodo $O1$ y un umbral de 0.05

Sujeto	C_1	C_2	C_3	C_4
A1	0.57 ± 0.10	0.57 ± 0.01	0.57 ± 0.05	0.60 ± 0.15
A2	0.60 ± 0.03	0.63 ± 0.09	0.56 ± 0.10	0.73 ± 0.02
A3	0.63 ± 0.10	0.59 ± 0.03	0.62 ± 0.10	0.72 ± 0.09
A4	0.52 ± 0.07	0.62 ± 0.05	0.57 ± 0.07	0.58 ± 0.05
A5	0.63 ± 0.08	0.57 ± 0.09	0.59 ± 0.09	0.61 ± 0.08
A6	0.70 ± 0.09	0.56 ± 0.18	0.59 ± 0.04	0.55 ± 0.10
A7	0.54 ± 0.02	0.59 ± 0.05	0.50 ± 0.10	0.56 ± 0.15
A8	0.63 ± 0.11	0.56 ± 0.15	0.56 ± 0.05	0.56 ± 0.02
A8*	0.56 ± 0.07	0.57 ± 0.07	0.65 ± 0.09	0.77 ± 0.06
A9	0.63 ± 0.07	0.73 ± 0.03	0.56 ± 0.07	0.57 ± 0.06
A9*	0.58 ± 0.10	0.60 ± 0.13	0.62 ± 0.08	0.63 ± 0.10

Cuadro C.21: Medidas de A_z para el electrodo $O2$ y un umbral de 0.1

Sujeto	C_1	C_2	C_3	C_4
A1	0.57 ± 0.08	0.60 ± 0.02	0.61 ± 0.00	0.68 ± 0.03
A2	0.73 ± 0.06	0.65 ± 0.02	0.78 ± 0.04	0.55 ± 0.05
A3	0.68 ± 0.03	0.49 ± 0.09	0.97 ± 0.01	0.71 ± 0.11
A4	0.66 ± 0.04	0.62 ± 0.06	0.61 ± 0.10	0.55 ± 0.10
A5	0.59 ± 0.07	0.55 ± 0.08	0.60 ± 0.14	0.63 ± 0.08
A6	0.58 ± 0.10	0.56 ± 0.11	0.61 ± 0.15	0.59 ± 0.01
A7	0.62 ± 0.04	0.58 ± 0.06	0.59 ± 0.02	0.64 ± 0.08
A8	0.68 ± 0.05	0.64 ± 0.06	0.56 ± 0.09	0.53 ± 0.09
A8*	0.67 ± 0.08	0.55 ± 0.03	0.81 ± 0.10	0.62 ± 0.08
A9	0.56 ± 0.08	0.67 ± 0.04	0.54 ± 0.01	0.60 ± 0.13
A9*	0.52 ± 0.03	0.53 ± 0.02	0.61 ± 0.02	0.59 ± 0.05

Cuadro C.22: Medidas de A_z para el electrodo $O2$ y un umbral de 0.05

Sujeto	C_1	C_2	C_3	C_4
A1	0.57 ± 0.20	0.53 ± 0.08	0.57 ± 0.11	0.62 ± 0.15
A2	0.58 ± 0.12	0.58 ± 0.08	0.65 ± 0.10	0.58 ± 0.09
A3	0.50 ± 0.13	0.51 ± 0.14	0.84 ± 0.07	0.69 ± 0.05
A4	0.67 ± 0.12	0.65 ± 0.02	0.64 ± 0.06	0.62 ± 0.09
A5	0.63 ± 0.13	0.69 ± 0.16	0.59 ± 0.09	0.66 ± 0.05
A6	0.71 ± 0.08	0.59 ± 0.06	0.63 ± 0.02	0.69 ± 0.07
A7	0.61 ± 0.10	0.58 ± 0.02	0.66 ± 0.10	0.63 ± 0.07
A8	0.57 ± 0.07	0.59 ± 0.16	0.58 ± 0.11	0.69 ± 0.01
A8*	0.54 ± 0.02	0.56 ± 0.12	0.74 ± 0.10	0.60 ± 0.02
A9	0.55 ± 0.10	0.57 ± 0.12	0.58 ± 0.04	0.58 ± 0.07
A9*	0.56 ± 0.12	0.53 ± 0.05	0.60 ± 0.12	0.61 ± 0.07

Cuadro C.23: Medidas de A_z para el electrodo Oz y un umbral de 0.1

Sujeto	C_1	C_2	C_3	C_4
A1	0.58 ± 0.11	0.57 ± 0.10	0.57 ± 0.07	0.54 ± 0.07
A2	0.61 ± 0.07	0.63 ± 0.04	0.76 ± 0.07	0.50 ± 0.02
A3	0.63 ± 0.09	0.63 ± 0.05	0.61 ± 0.03	0.63 ± 0.11
A4	0.55 ± 0.10	0.68 ± 0.04	0.61 ± 0.09	0.57 ± 0.17
A5	0.54 ± 0.05	0.57 ± 0.15	0.61 ± 0.07	0.58 ± 0.09
A6	0.55 ± 0.05	0.56 ± 0.04	0.65 ± 0.05	0.56 ± 0.18
A7	0.62 ± 0.15	0.67 ± 0.07	0.60 ± 0.04	0.58 ± 0.08
A8	0.52 ± 0.09	0.52 ± 0.08	0.56 ± 0.19	0.55 ± 0.10
A8*	0.56 ± 0.14	0.55 ± 0.07	0.89 ± 0.05	0.61 ± 0.02
A9	0.57 ± 0.06	0.69 ± 0.04	0.68 ± 0.01	0.67 ± 0.15
A9*	0.56 ± 0.09	0.58 ± 0.07	0.55 ± 0.05	0.60 ± 0.11

Cuadro C.24: Medidas de A_z para el electrodo Oz y un umbral de 0.05

Sujeto	C_1	C_2	C_3	C_4
A1	0.62 ± 0.15	0.53 ± 0.08	0.54 ± 0.17	0.57 ± 0.12
A2	0.60 ± 0.06	0.56 ± 0.14	0.67 ± 0.07	0.52 ± 0.07
A3	0.52 ± 0.12	0.59 ± 0.03	0.65 ± 0.03	0.60 ± 0.14
A4	0.56 ± 0.19	0.60 ± 0.14	0.60 ± 0.09	0.57 ± 0.13
A5	0.65 ± 0.11	0.62 ± 0.15	0.70 ± 0.09	0.63 ± 0.13
A6	0.54 ± 0.05	0.66 ± 0.04	0.56 ± 0.03	0.51 ± 0.06
A7	0.55 ± 0.03	0.70 ± 0.10	0.56 ± 0.12	0.54 ± 0.10
A8	0.62 ± 0.08	0.55 ± 0.07	0.57 ± 0.12	0.55 ± 0.01
A8*	0.56 ± 0.02	0.63 ± 0.07	0.53 ± 0.06	0.54 ± 0.07
A9	0.65 ± 0.08	0.60 ± 0.06	0.60 ± 0.12	0.53 ± 0.15
A9*	0.56 ± 0.16	0.54 ± 0.15	0.63 ± 0.09	0.58 ± 0.16

Apéndice D

Experimentos adicionales

Durante el desarrollo de los experimentos de tres y cuatro clases, una segunda vuelta en los registros o un paradigma alterno fueron utilizados para generar más datos y probar otros esquemas de detección. Estos experimentos están más allá del alcance de esta tesis pero deben mencionarse como trabajo paralelo o posterior al desarrollo de LINI-BCI : SSVEP.

D.1. Adaptación a corto plazo: tres clases

Adicionalmente al conjunto de datos utilizado en esta tesis, todos los sujetos que participaron en los registros realizados en el LINI atendieron a una segunda etapa de estímulos. Esto se realizó para observar si existían cambios significativos en el desempeño de los clasificadores y para obtener datos de una segunda realización y poder utilizarlos en un esquema de clasificación semi-supervisada, utilizando el clasificador entrenado con el primer conjunto de datos para clasificar a la segunda muestra y obtener un ajuste sobre la frontera de decisión para mejorar la generalización del clasificador.

D.2. Método alternativo de detección para SSVEP: detección de fase

Como se mencionó en el capítulo 1 la definición de SSVEP indica que están relacionados en frecuencia y fase con los estímulos que los evocan. Partiendo de la hipótesis:

- Los SSVEP están relacionados en fase con los estímulos que los evocan

un paradigma de estímulos codificados en fase fue diseñado y escrito en Presentation. Este paradigma fue atendido por los sujetos que participaron en los registros de cuatro clases

y es una modificación del paradigma utilizado para cuatro clases 4.6. Las modificaciones realizadas consisten en la reducción de las frecuencias de oscilación a sólo dos frecuencias y la adición de dos fases diferentes, manteniendo los cuatro objetivos. Las frecuencias utilizadas son $\{8.5, 14.2\}$ Hz y las diferencias de fase son $\{1.25, 2.07\}$ radianes.