



Casa abierta al tiempo
UNIVERSIDAD AUTÓNOMA METROPOLITANA

ACTA DE DISERTACIÓN PÚBLICA

No. 00022
Matrícula: 205181251

UTILIZACION DE UN EXPONENTE DE ESCALAMIENTO EN INTERFACES CEREBRO COMPUTADORA ASINCRONICAS

En la Ciudad de México, se presentaron a las 16:00 horas del día 6 del mes de abril del año 2016 en la Unidad Iztapalapa de la Universidad Autónoma Metropolitana, los suscritos miembros del jurado:

DR. JUAN CARLOS ECHEVERRIA ARJONILLA
DR. ANGEL TOMAS ALJAMA CORRALES
DR. DAVID GUTIERREZ RUIZ
DR. FRANCISCO ALFONSO ALBA CADENA
DRA. VERONICA MEDINA BAÑUELOS



ERIK RENE BOJORGES VALDEZ
ALUMNO

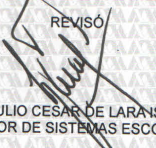
Bajo la Presidencia del primero y con carácter de Secretaria la última, se reunieron a la presentación de la Disertación Pública cuya denominación aparece al margen, para la obtención del grado de:

DOCTOR EN CIENCIAS (INGENIERIA BIOMEDICA)

DE: ERIK RENE BOJORGES VALDEZ

y de acuerdo con el artículo 78 fracción IV del Reglamento de Estudios Superiores de la Universidad Autónoma Metropolitana, los miembros del jurado resolvieron:

REVISÓ




LIC. JULIO CESAR DE LARANSASSI
DIRECTOR DE SISTEMAS ESCOLARES

— APROBAR —

Acto continuo, el presidente del jurado comunicó al interesado el resultado de la evaluación y, en caso aprobatorio, le fue tomada la protesta.

DIRECTOR DE LA DIVISIÓN DE CBI




DR. JOSE GILBERTO CORDOBA HERRERA

PRESIDENTE




DR. JUAN CARLOS ECHEVERRIA ARJONILLA

VOCAL




DR. ANGEL TOMAS ALJAMA CORRALES

VOCAL



DR. DAVID GUTIERREZ RUIZ

VOCAL



DR. FRANCISCO ALFONSO ALBA CADENA

SECRETARIA



DRA. VERONICA MEDINA BAÑUELOS

División de Ciencias Básicas e Ingeniería

Posgrado en Ingeniería Biomédica

Tesis que presenta para obtener el grado de:

Doctor en Ciencias (Ingeniería Biomédica)

M.C. Erik René Bojorges Valdez

**UTILIZACIÓN DE UN EXPONENTE DE ESCALAMIENTO
EN INTERFACES CEREBRO COMPUTADORA ASINCRÓNICAS**

6 de abril de 2016

Asesores:

Dr. Juan Carlos Echeverría Arjonilla

M.I. Óscar Yáñez Suárez

Sinodales:

Dr. Juan Carlos Echeverría Arjonilla

Dra. Verónica Medina Bañuelos

Dr. Ángel Tomás Aljama Corrales

Dr. Francisco Alfonso Alba Cadena

Dr. David Gutiérrez Ruiz

Agradecimientos

Este trabajo doctoral contó con el apoyo del CONACyT mediante la beca no. 19648. Se le da un encarecido agradecimiento al pueblo de México que a la fecha ha sostenido a las universidades públicas que son los lugares donde se realiza la ciencia en el país. Siendo necesarios los centros de investigación para la formación de profesionistas que aman a la patria, y que con su trabajo e inteligencia logren rescatarla del borde del precipicio en que se encuentra.

A Oscar y Juan Carlos, gracias por las charlas, ideas, sugerencias y vicisitudes que surgieron durante todos estos años de amistad y trabajo.

José María, Jezabel, Hugo, Nery y en especial a Margarita, muchas gracias por darme su amor, su apoyo y sentido a mi vida.

Pensamiento

¿Es que en verdad se vive aquí en la tierra?

¡No para siempre aquí!

Un momento en la tierra, si es de jade se hace astillas,

si es de oro se destruye,

si es plumaje de quetzalli se rasga,

¡No para siempre aquí!

Un momento en la tierra.

-Nezahualcóyotl

Resumen

El desarrollo y restricciones de uso de las Interfaces Cerebro Computadora (BCI) han traído como consecuencia la necesidad de indagar sobre técnicas de procesamiento de señales electroencefalográficas y la incorporación de índices que permitan una mejor identificación de la intención del sujeto para controlar los actuadores involucrados. En este trabajo se evaluó la utilización de un índice de escalamiento como rasgo de entrada para BCI, comparando su desempeño con el de un índice clásico como lo es la potencia espectral.

Las evaluaciones se hicieron al analizar los datos de dos experimentos diseñados para generar cambios en la dinámica de las señales similares a los acontecidos en las interfaces de imaginación de movimiento actuales. El primero consistió en la identificación de las épocas en las que los sujetos presionaron un botón ante un estímulo visual, contando con la participación de cuarenta sujetos sanos. En el segundo se identificaron los periodos asociados con la realización de una serie de cálculos mentales; se contó con quince sujetos sanos quienes realizaron la prueba durante tres sesiones experimentales en distintos días. Para este segundo experimento se evaluó la identificación de la tarea calibrando el clasificador con los datos de las otras sesiones experimentales. En ambos experimentos se exploró la incorporación del índice derivado del análisis de fluctuaciones sin tendencia (DFA, propuesto por Peng *et al.*), debido a las ventajas metodológicas y de implementación que posee. Adicionalmente a la evaluación de este índice, el trabajo doctoral incluyó el diseño de un paradigma de cálculo aritmético que permite una evaluación objetiva de la identificación de periodos de actividad contra reposo. También se presenta un esquema sencillo de selección de canales de EEG de los cuales se obtienen las características o rasgos de entrada para una BCI.

Los resultados obtenidos, en términos del área bajo la curva (AUC), muestran que el índice de escalamiento tiene un desempeño similar, en términos poblacionales, a la utilización de la potencia espectral. La utilización combinada de los índices mejoró significativamente la identificación de los periodos de actividad *vs* reposo. El desempeño obtenido para el paradigma de cálculo aritmético fue mejor ($AUC > 0.86$) al reportado para evaluaciones de interfaces basadas en imaginación de movimiento, mostrando que es posible un desempeño eficiente aun para los sujetos novatos desde la primera sesión. Esto puede ser consecuencia de que las características que describen los índices de escalamiento son complementarias a la potencia espectral, lo que sugiere seguir incorporándolas al análisis del EEG

incluso en el ambiente clínico. Se plantea así la conveniencia del uso combinado de las características de escalamiento y potencia espectral, así como del desarrollo de nuevos paradigmas de control con una identificación inequívoca de tareas para su incorporación en el desarrollo de nuevas BCI.

Índice general

1. Introducción	11
1.1. BCI	11
1.2. Usos clínicos de las BCI	15
1.3. Retos de las interfaces asincrónicas	16
1.4. Objetivos	17
1.5. Exponentes de Escalamiento	18
1.5.1. Análisis de Fluctuaciones sin Tendencia	21
1.6. SE con EEG	22
1.7. Ideas Generales	26
2. Ejecución de Movimiento	29
2.1. Descripción	29
2.2. Registros y Métodos	30
2.2.1. Descripción de los registros	30
2.2.2. Análisis de los registros	31
2.3. Resultados	32
2.3.1. Descripción Estadística de los índices	32
2.3.2. Pruebas de Identificación de Tarea	34
2.4. Discusión y conclusiones	37
2.5. Síntesis y Puntos Relevantes	40
3. Cálculo Mental	43
3.1. Introducción	43
3.2. Registros	44

3.2.1. Sujetos	44
3.2.2. Descripción del Paradigma	45
3.3. Métodos	47
3.3.1. Análisis Estadístico	48
3.3.2. Simulación BCI	49
3.4. Resultados	52
3.4.1. Descripción estadística	52
3.4.2. Simulación BCI	54
3.5. Discusión	59
3.6. Conclusión	62
3.7. Síntesis y Puntos Relevantes	63
4. Discusión y Conclusiones	65
4.1. Recapitulación	65
4.2. Sobre los cambios de valor de los índices	66
4.3. Sobre los canales de detección	68
4.4. Sobre la identificación de las tareas	69
4.5. Perspectivas	71
4.6. Conclusiones	73
Apéndice A. Estimación del índice de escalamiento con ventanas de tiempo cortas	75
Apéndice B. Máquinas de Soporte Vectorial	77
Apéndice C. Área Bajo la Curva de operación ROC (AUC)	83
Índice de figuras	87
Índice de cuadros	91
Bibliografía	93

Capítulo 1

Introducción

1.1. Interfaces Cerebro Computadora

Las Interfaces Cerebro Computadora (BCI, por sus siglas en inglés), son sistemas que traducen las intenciones o actividad cognitiva del sujeto a comandos o acciones que son ejecutadas por un actuador. Esta traducción debe ser directa entre la voluntad del sujeto y el actuador, sin la utilización de las vías neuro-musculares [1]. Desde la propuesta hecha por Vidal en 1973 [2], se han ideado distintos tipos de mecanismos para lograr esta comunicación. Se han propuesto diferentes paradigmas o tareas que modifiquen la dinámica cerebral y que sean esencialmente un reflejo de la voluntad del usuario. Los estudios neurofisiológicos han mostrado que la presentación de distintos estímulos de distintas características o bien la realización de tareas mentales pueden introducir cambios a esta dinámica [3]. Existen varias técnicas de registro de la actividad cerebral que podrían ser utilizadas como canal de entrada para las BCI. Debido a su resolución espacio-temporal, el registro de la actividad electrocortical (ECoG) es el método más eficiente para dicho registro; sin embargo, la necesidad de implantar electrodos directamente en la masa encefálica se contrapone con su utilización por periodos prolongados. Por otro lado, el registro en la superficie del cuero cabelludo de la actividad electroencefalográfica o EEG, aunque tiene menor resolución espacial, permite que la utilización de una BCI a largo plazo sea potencialmente posible. El procesamiento de estas últimas señales es lo que considera el presente trabajo, por lo que todo lo aquí dicho se referirá exclusivamente al tratamiento de señales de EEG. Otras técnicas como pueden ser la magnetoencefalografía (MEG) o la resonancia magnética funcional resultan poco prácticas fuera de un ambiente clínico, dadas las características de los instrumentos necesarios para hacer la

Introducción

adquisición. Una posibilidad más que ha sido explorada es la utilización de la espectroscopía en el infrarrojo cercano (NIRS). Pero su resolución temporal es menor que la del EEG además de presentar un retraso entre el inicio de la ejecución de la tarea y la detección de cambios en la señal.

Las BCI pueden ser conceptualizadas como sistemas e inclusive cajas negras que tienen como entrada un cúmulo de canales de EEG y como salida las líneas de control hacia el actuador. A su vez, las BCI, están divididas en distintas secciones interconectadas entre sí. Siguiendo las propuestas de Wolpaw *et al.* [1] y Mason *et al.* [4] los tres componentes principales de la BCI, y su interconexión, pueden esquematizarse en la figura 1.1, cada uno de los componentes tiene una función específica que se describe a continuación:

Adquisición de Señal Este módulo realiza la digitalización y acondicionamiento de las señales por medio de un filtrado, escalamiento u obtención del laplaciano de un conjunto de electrodos. El módulo proporciona la o las señales generalmente de forma digital.

Extracción de características Dependiendo del tipo de interfaz a desarrollar este módulo se encarga de estimar distintos rasgos de las series de tiempo, que se modifican o portan la intención del sujeto para comunicarse. Así, traducen las señales de EEG a un conjunto de características o rasgos que son reflejo de la ejecución de alguna tarea mental. Cada interfaz utiliza rasgos que dependen del tipo de característica que se considera como relevante; más adelante en el texto se ampliará sobre estos detalles. Esta etapa puede estar conformada por diferentes módulos dispuestos en paralelo, de tal forma que de una o varias señales se extraigan características diferentes para ser entregadas a módulos siguientes que pueden tener distintas configuraciones.

Reconocimiento de Patrones Esta sección tiene en su interior una regla de decisión para discriminar si un segmento particular de EEG contiene información que permita la selección de un comando para el actuador. Puede ser un clasificador, como una máquina de soporte vectorial, o un perceptrón multicapa, o bien otra arquitectura para implementar un algoritmo que use los rasgos de la etapa previa para tomar una decisión sobre la intención del usuario de comunicar un comando.

El funcionamiento de una BCI se centra en el análisis de segmentos de EEG y la subsecuente identificación del comando a transmitir al actuador. Lo cual puede traducirse en activar motores, desplegar caracteres, o cualesquiera otras acciones que hayan sido consideradas para el funcionamiento de la interfaz. A su vez el actuador puede ser también utilizado para estimular al sujeto cuando sea necesario. Haciendo con ello un lazo cerrado, que se puede aprovechar para que la respuesta del usuario

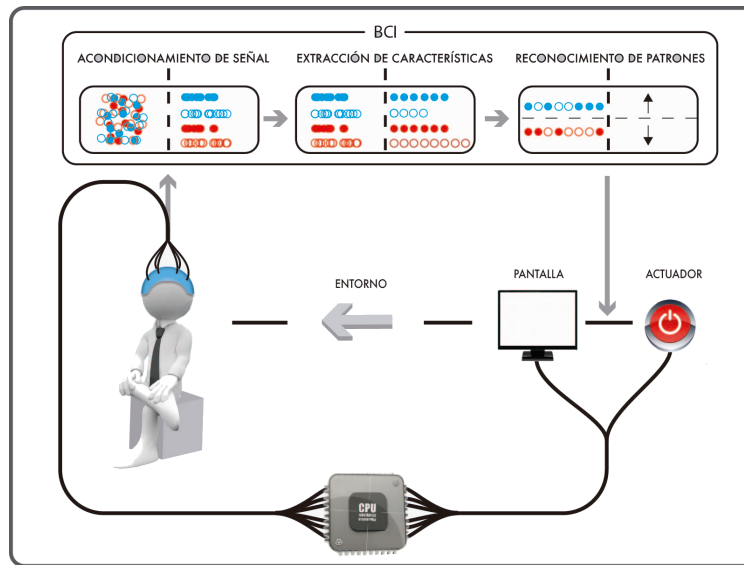


Figura 1.1: Esquema de relaciones de una interfaz cerebro computadora

sea evaluada en los periodos determinados por el sistema. El actuador además de la ejecución de las acciones puede ofrecer una sección para toma de decisiones que permita la ejecución de acciones finas evitando un sobreflujo de información al usuario. Así, el actuador está siendo retroalimentado por las condiciones de entorno, e identificando los comandos dictados por el usuario quien es el que debe decidir cuál es la siguiente tarea a ejecutar.

Las BCI pueden dividirse en dos grandes categorías de acuerdo con su modo de operación: *sincrónicas* y *asincrónicas*. Para las primeras, el sistema señala cuando espera recibir una respuesta por parte del usuario, mientras que para las segundas el usuario es el que determina cuando se quiere transmitir un comando a la interfaz. En ambas se buscan cambios en alguna característica de la señal del EEG como la aparición de un transitorio o *potencial provocado*. O incluso pueden detectarse cambios en la dinámica que afectan las características espectrales como la potencia, la fase o la presencia de autocorrelaciones [3]. Bajo esta definición cualquier paradigma puede ser utilizado para el control de las BCI independientemente del tipo de respuesta fisiológica; sin embargo, aquellos que utilizan detección de potenciales provocados son los mayormente usados para las interfaces sincrónicas y aquellos para los que el cambio en la dinámica es endógeno al sujeto (no se requiere de estimulación) están mayormente asociados con las interfaces asincrónicas. Actualmente existen tres paradigmas que dominan la escena de las BCI referidos por el proceso neurofisiológico que se considera.

P300 Interfaces que se enfocan en la detección de un potencial provocado relacionado al evento o estímulo-

Introducción

lo (ERP, por sus siglas en inglés). La más utilizada es el deletreador de Donchin [5] que muestra un conjunto de símbolos en una pantalla, posteriormente esos símbolos cambian de intensidad o color de manera aleatoria. El sujeto está atento al símbolo a comunicar, y cuando el símbolo objetivo es encendido, el sujeto presenta una respuesta conocida como P300. La máquina está entrenada para poder discriminar las características de la señal en caso de que el potencial esté presente, y con ello hace una diferenciación entre símbolo objetivo versus los otros. Usualmente se necesitan promediar coherentemente N repeticiones a fin de aumentar la certidumbre de que el símbolo a comunicar es el correcto. La zona cortical en la cual se hace una mejor detección de estos potenciales es desde la zona central hacia la región occipital. Sin embargo, para conocer los electrodos en los que esta detección se maximiza, es necesario realizar una valoración individualizada [1, 5].

SSEP Es el acrónimo en inglés para Steady-State Evoked Potential (Potenciales Provocados de Estado-Estacionario). Este tipo de potenciales, que pueden ser de tipo auditivo, visual o somatosensorial, se generan al fijar la atención a un estímulo repetitivo a frecuencia constante. Por ejemplo, un identificador luminoso, una imagen que cambia, un sonido que aparece a cierta frecuencia, o la estimulación rítmica en algún punto del cuerpo. Al estar estimulándose por el estímulo objetivo, las regiones sensoriales de la corteza respectivas se sincronizan con la estimulación. Respuesta por la que la potencia espectral alrededor de la frecuencia de estimulación, así como sus armónicos, aumenta. Esto es detectable al hacer un análisis espectral de la señal de EEG y con ello se puede determinar el estímulo al cual está atento el sujeto. Estas interfaces han tenido un desarrollo amplio y han generado un interés en la comunidad dado que los algoritmos para su detección, así como el desarrollo de los estimuladores, son más simples que para otros tipos de interfaces. Además, el tiempo de entrenamiento suele ser más corto y el registro puede hacerse con pocos canales [6, 7].

ERD/ERS Es el acrónimo en inglés para Event Related Desynchronization/Synchronization (Sincronización/Desincronización Relacionada al Evento). Son interfaces cuyo objetivo es medir el nivel de desincronización o sincronización entre diferentes zonas de la corteza cerebral, estimada como un cambio en la potencia en bandas específicas del EEG. En diferentes estudios se ha demostrado que tareas como el movimiento de las extremidades generan modificaciones en la potencia espectral de las bandas *alfa* y *beta* [8, 9]. Algunos investigadores han sugerido que con el entrenamiento suficiente un sujeto incluso podría generar cambios similares únicamente imaginando o planeando el movimiento, por lo que existen interfaces y paradigmas que reciben específicamente el nombre

de *imaginación de movimiento* **MI**. Este paradigma permite incrementar los grados de libertad de una BCI al aumentar el número de tareas gracias a las diferentes distribuciones espaciales y frecuenciales de la respuesta de los distintos miembros o extremidades. De esta manera, podría plantearse que en una misma sesión el usuario imagine el movimiento de la lengua, los pies y/o las manos. Pero esto dificulta la identificación de las respuestas y es necesario un mayor tiempo de entrenamiento. Pese a estas dificultades, este tipo de interfaces se han considerado como promisorias para controlar dispositivos navegadores como robots, sillas de ruedas, cursores, u otros ya que por cada tarea se puede lograr un control de tipo continuo que favorece a la BCI implementada. Sin embargo, no todos los sujetos son capaces de ejecutar estas tarea ni consiguen el control fino de la interfaz aun para un sólo grado de libertad [1, 10, 11].

1.2. Usos clínicos de las BCI

El desarrollo de las BCI ha permitido pasar de su utilización en únicamente sujetos sanos a intentar ser un auxiliar para pacientes que sufren de algún tipo de padecimiento neurológico. Este salto no ha sido del todo propicio, y en los contados casos de éxito el montaje de la BCI está lejos de poder ser completamente independiente y de fácil utilización. Tal es el caso presentado por Sellers *et al.* [12], en el que un paciente que sufrió un derrame cerebral fue capaz, después de varias sesiones de entrenamiento, de controlar un deletreador P300, pero necesitando de 45 a 60 minutos para escribir una frase.

Además de las complicaciones inherentes a las BCI, los pacientes presentan problemas asociados con cada tipo de patología. Entre los más comunes están la dificultad para poder fijar la vista en la pantalla, lo que afecta principalmente a los paradigmas basados en ERP o SSVEP. El trabajo de Marchetti *et al.* [13], muestra que en pacientes con esclerosis lateral amiotrófica la utilización del paradigma P300 no alcanza los niveles de certeza que se tienen para sujetos sanos, y en muchos casos no es posible evaluar su utilización debido a las dificultades presentadas por la condición de los pacientes. Esto genera polémica acerca de cómo evaluar el desempeño de las BCI en comparación con otras tecnologías de asistencia más sencillas con las que se cuenta actualmente en la clínica.

No obstante estos argumentos acerca del desempeño, otros trabajos han mostrado que las BCI pueden ser útiles no sólo en el tratamiento sino también para una mejor comprensión de los padecimientos. Los trabajos de Friedrich *et al.* [14] y Pineda *et al.* [15], están orientados a la utilización de BCI para atender problemas de autismo, permitiendo a estos pacientes una forma de comunicación no verbal a través de

Introducción

la computadora. Además de lograr la comunicación, la BCI ha sido probada como sistema terapéutico mediante la modulación del EEG al utilizar el movimiento corporal, el ritmo cardiaco y otros elementos lúdicos.

Daly *et al.* [16], trabajaron con pacientes con parálisis cerebral usando una BCI basada en ERD/ERS. Sus resultados apuntan a que la incapacidad en la utilización de estos sistemas puede deberse a los bajos niveles de activación de la corteza, y a la poca posibilidad de suprimir voluntariamente los ritmos *mu*, lo que resulta un indicio de una menor conectividad. Al igual que Sellers, Ono *et al.* [17] trabajaron con pacientes con derrame, pero utilizando una interfaz de **MI**; los pacientes realizaron trabajo con la BCI de 12 a 20 días por una hora. Los resultados apuntan a que la utilización del paradigma, en combinación con retroalimentación, puede mejorar la rehabilitación y llegar a ser un tratamiento para la recuperación de la hemiplejía. Song *et al.* [18], en el mismo sentido, mostraron mediante las técnicas de tensores de difusión y resonancia magnética funcional, que existe una mejoría en la reconexión y activación de neuronas con pacientes en tratamiento de recuperación del movimiento. Por su parte, Young *et al.* [19] también reportaron que existen cambios en los patrones de activación, tanto del hemisferio con lesión y del sano, al dejar que los pacientes utilicen una BCI.

Además, Xu *et al.* [20] al estudiar pacientes parapléjicos encontraron anomalías relacionadas con los potenciales corticales. Pfurtscheller *et al.* [21] mostraron que los pacientes que sufren de lesión de médula espinal, pueden llegar a usar una BCI basada en **MI** de manera satisfactoria, con niveles alrededor de 65 % en la certeza; y que los pacientes que sufren tetraplejía necesitan un mayor tiempo de entrenamiento. De acuerdo con Rupp [22], estos pacientes son más proclives a la utilización de las BCI que requieren fijar la mirada como es el caso de SSVEP o P300, dejando a las basadas en ERD/ERS con un menor nivel de desempeño. Por lo que todas éstas son tecnologías promisorias de tratamiento, pero no son un estándar de uso clínico en la actualidad.

1.3. Retos de las interfaces asincrónicas

Las interfaces asincrónicas son de particular interés ya que permiten que el usuario se comunique de manera más “natural” con la BCI. Es el usuario quien decide cuando necesita la actuación del sistema, lo que implica que la realización de la tarea mental puede suceder en cualquier momento. Estas interfaces deben ser capaces de identificar y activar el control pertinente. Pero por la naturaleza de esta activación pueden existir un número grande de falsos positivos en la detección, activándose la

interfaz cuando el usuario no lo desea. En el desarrollo de estas interfaces los paradigmas de ERD/ERS son los más utilizados y en particular los de **MI**. La principal problemática de estas interfaces es su bajo desempeño poblacional. Entre el 10 y 30 % de los sujetos no pueden alcanzar un control eficiente [23]; y en alrededor del 48 % de las sesiones los sujetos logran un desempeño de entre 50 a 69 % [11, 24]. Para alcanzar un control eficiente los usuarios deben pasar por un largo periodo de entrenamiento y/o utilizar modalidades complejas para la retroalimentación [25]. Por lo que se necesitan de técnicas que mejoren la identificación de las características o bien que los rasgos a utilizar sean discriminables entre el reposo y la(s) activación(es). No existe un consenso sobre las causas de este bajo desempeño; sin embargo, la incomprendibilidad acerca de la ejecución de la tarea o la utilización de épocas de incorrecta realización durante la calibración del sistema pueden ser algunas de las razones.

El proceso de calibración de este tipo de interfaces suele pasar por tres etapas que son: 1) la utilización física de las extremidades, *movimiento real*; 2) imaginación del movimiento; y 3) retroalimentación con imaginación de movimiento. Esto bajo la idea de que tanto la imaginación como la ejecución del movimiento activan zonas motoras similares y con rasgos frecuenciales parecidos [8, 9, 26]. Este proceso de calibración funciona básicamente para la operación de una BCI en la misma sesión experimental, por lo que es necesario repetirlo cada vez que se desee volver a operar. Esto puede tomar tiempo considerable, lo que genera fatiga o fastidio por parte del usuario y un bajo nivel de desempeño.

1.4. Objetivos

Con el propósito de mejorar el desempeño de las BCI, se han explorado distintas técnicas del procesamiento de EEG, tanto en el tiempo como en la frecuencia. Recientemente se ha propuesto el análisis basado en índices de escalamiento como una manera de detectar componentes irregulares que no se determina con los métodos tradicionales en los dominios temporal y espectral [27]. Estos métodos permiten mostrar características de las series de tiempo que no son evaluadas por los métodos espectrales [28-30]. El análisis de escalamiento ha tenido un fuerte impulso en el estudio de la variabilidad del ritmo cardiaco, y también ha incursionado en el estudio del EEG [31-33]. Es por ello que en este trabajo se explora la incorporación de un índice de escalamiento como rasgo de entrada para las BCI. Esto bajo la consideración de que la incorporación de un rasgo que describa al fenómeno (EEG) de manera complementaria, puede mejorar la detección de cambios en la dinámica.

Por otro lado, la utilización de paradigmas diferentes que generen cambios en la dinámica del EEG

puede ser otra vía de incrementar el desempeño de las interfaces al facilitar o acoplar las tareas a las preferencias de cada usuario. Otros paradigmas que pueden generar cambios en la potencia y que han sido usados con las BCI son: imaginar la rotación de objetos tridimensionales, la lectura, el canto silente, o el cálculo mental [34-36]. Resulta relevante que esta última es una tarea cuya realización puede ser verificada al momento de conocer el resultado de la operación. Fue sugerida por primera vez por Keirn y Auñón [35], quienes clasificaron segmentos de EEG asociados con la realización de cinco tareas diferentes. Así, la ventaja de utilizar un paradigma como el cálculo aritmético es que es posible verificar la correcta realización de la tarea en determinado momento. Esto permite evaluar objetivamente los métodos de procesamiento y detección usados para las BCI. Esta ventaja también fue aprovechada en este trabajo al proponer e implementar un paradigma basado en el cálculo mental.

1.5. Exponentes de Escalamiento

Los procesos fisiológicos tales como la respiración, el ritmo cardiaco, o la marcha, no son procesos estables ya que fluctúan en un cierto rango. Estas fluctuaciones pueden ser generadas por la interacción de diferentes procesos y/o por la presencia de perturbaciones débiles que alteran la dinámica de los procesos, lo que hace que, en el mejor de los casos, las señales involucradas sean cuasi-periódicas. Pueden ser estudiadas adoptando modelos estocásticos o caóticos; inclusive mediante la utilización de *modelos fractales*. La característica más importante para la descripción de un modelo fractal es la autosimilitud a diferentes escalas. Similarmente a lo que ocurre con los fractales geométricos, los procesos temporales también guardan presuntas características que son invariantes con la escala de observación. Es decir, que los procesos parecen una versión escalada de ellos mismos en función de la ventana de observación. Esta dependencia, entre las características medidas y la ventana de observación, tiene un comportamiento del tipo ley de potencia [37]. Por ejemplo, una característica cuantitativa q , es función de la escala o ventana de observación s :

$$q = f(s) \tag{1.1}$$

Cuando el proceso no es fractal al hacer más pequeña la escala s el valor de q convergerá a un valor único. En cambio, un proceso tipo fractal el valor de q no convergerá, sino que exhibe una relación de ley

de potencia respecto a s :

$$q = p \cdot s^\epsilon \quad (1.2)$$

Donde el valor de ϵ puede ser estimado al convertir la ecuación anterior con una transformación logarítmica.

$$\log(q) = \log(p) + \epsilon \cdot \log(s) \quad (1.3)$$

El valor de ϵ es conocido como el exponente de escalamiento (**SE**, *scaling exponent*), y puede ser estimado como la pendiente de la regresión lineal que ajusta los puntos $\log(q)$ y $\log(s)$. Para los fractales exactos esta regresión tiene un ajuste perfecto, pero para los fractales estadísticos es necesario utilizar un ajuste de mínimos cuadrados, como se observa en la figura 1.2. Incluso, el valor del exponente ϵ puede cambiar en función de la escala dando pie a que la serie de tiempo tenga valores de exponente que dependen del rango de análisis. Tal es el caso de algunas señales fisiológicas que por su comportamiento temporal son consideradas como prefractales ya que poseen la característica fractal en un rango restringido [37]. Debido a que el índice ϵ se utiliza para evaluar o caracterizar rasgos de las series de tiempo a distintas escalas, es que recibe el nombre de índice o exponente de escalamiento.

Las series de tiempo, dado su comportamiento, pueden clasificarse en dos grupos, las llamadas Ruido Gaussiano fractal (rGf) o bien movimiento Browniano fractal (mBf). Las primeras son aquellas cuyas propiedades estadísticas (media y varianza u otros momentos estadísticos) no cambian con el tiempo, mientras que para las segundas esta condición no se cumple. El análisis del índice de escalamiento ha demostrado que lo que antes era considerado como ruido estocástico puede tener estructura, causado por la existencia de escalamiento o correlaciones a largo plazo. Se ha encontrado que las series de tiempo como la variabilidad de la frecuencia cardiaca o la marcha sufren modificaciones en este tipo de índices por efectos de la edad o alguna patología [29, 38].

El índice ϵ está relacionada con el modelo de probabilidad que da origen al proceso y de ello derivan características morfológicas como la suavidad del trazo o su irregularidad. Esto sugiere también la existencia de una dependencia de la serie hacia valores pasados que permite evaluar rasgos de autocorrelación [40]. Una serie de tiempo que posee autocorrelaciones de largo plazo, o auto-afinidad,

Introducción




Figura 1.2: Ejemplo de cambios en los valores de la fluctuación cuadrática media (F) en función del tamaño de la escala de observación (s), para una señal sintética tomada de [39] con un exponente $\epsilon = 0.8$.

presenta además una densidad espectral del tipo:

$$F(f) \propto A f^\beta \quad (1.4)$$

De tal manera que dependiendo del valor de β el proceso puede manifestar características diferentes, como las propias del ruido blanco ($\beta = 0$), o del ruido $1/f$ de tipo fractal. La existencia de periodicidades o frecuencias fundamentales modificarán el valor de β [37, 41].

Las diferentes técnicas de estimación del índice ϵ se basan en la observación de distintas características estadísticas de la serie de tiempo, pero todas están orientadas a la estimación de un **SE** que es adimensional. Por lo cual no hay una dependencia estricta sobre la característica de medición; es decir la estimación del nivel de autosimilitud no será función de los valores o rangos de las características medidas. Sin embargo, la estimación del **SE** a partir de diferentes características, puede impactar en términos prácticos en el valor calculado. Existen diferentes métodos de análisis de escalamiento, todos ellos basados en la búsqueda de un exponente del tipo ϵ , que permita un ajuste como el mostrado en la figura 1.2. Algunos métodos de análisis para series de tiempo son: Análisis de Autocorrelación, Análisis de Varianza en Ventanas Escaladas, Análisis de Dispersión [37], Análisis de Fluctuaciones sin Tendencia (DFA, Detrended Fluctuation Analysis) [29, 30, 37], Exponente de Higuchi [37, 42], Análisis del periodograma (PSD), Análisis Espectral a Baja Resolución (CGSA, Coarse Grained Spectral Analysis),

Análisis Fractal Wavelet [37]. Estos no son los únicos métodos de análisis, pero sí los más utilizados para el análisis de diferentes condiciones fisiológicas, como la marcha, variabilidad de la frecuencia cardiaca, isquemia o epilepsia [29, 37, 43]. Existen otros tipos de análisis basados en modelos caóticos que son métodos geométricos derivados de los *Diagramas de Fase*, como son los atractores extraños, secciones de Poincaré, exponente de Lyapunov, mapas de bifurcaciones o bien mapas de retorno. Dichos métodos están asociados a la dinámica de los sistemas caóticos deterministas [44, 45]. Sin embargo, no parece conveniente utilizarlos para aplicaciones de tiempo real como una BCI, posiblemente por la corta duración de las épocas para el análisis y por que no corresponden estrictamente con la dinámica de los procesos que originan la actividad electrofisiológica [32].

1.5.1. Análisis de Fluctuaciones sin Tendencia

El Análisis de Fluctuaciones sin Tendencia (DFA, Detrended Fluctuation Analysis), fue propuesto por Peng *et al.* [30]. Es un método usado para la detección de correlaciones de largo alcance o escalamiento, que considera el análisis de señales no estacionarias. La implementación y sensibilidad para la detección de cambios en el exponente de tipo ϵ son parte de sus ventajas metodológicas consideradas [46]. El procedimiento se puede resumir de la siguiente manera:

Dada una serie de tiempo $x[i], i = 1, 2, \dots, N$, se crea una nueva serie mediante la suma acumulativa de sus muestras:

$$y[j] = \sum_{i=1}^{i=j} (x[i] - \hat{x}) \quad (1.5)$$

Donde \hat{x} es el valor medio de la serie $x[i]$. Luego, la serie $y[j]$ es dividida en subsecuencias de la misma longitud o escala n . Cada una de estas subsecuencias es ajustada con un polinomio de orden k generando la nueva serie y_n . Un caso especial es cuando $k = 1$, que elimina la tendencia lineal en cada subsecuencia. El valor RMS de la fluctuación F de la serie $y[j]$ es estimado en función de n :

$$F[n] = \sqrt{\frac{1}{N} \sum_{j=1}^N (y[j] - y_n[j])^2} \quad (1.6)$$

Estos valores $F[n]$ son analizados mediante una relación de ley de potencia respecto a n , y el valor del exponente de escala es el mejor ajuste para $F[n] \sim n^\alpha$. En la figura 1.3 se ejemplifica de manera gráfica la metodología del DFA. A lo largo del texto, y para evitar confusión con el valor de la potencia espectral en la banda *alfa*, el exponente de escalamiento estimado mediante el método DFA será conocido como

α_{SE} .

1.6. Antecedentes de la Utilización de Medidas de Exponente de Escalamiento en EEG

La medición del **SE** ha sido previamente usada en el análisis del EEG para diferentes estudios, como la medición de la profundidad anestésica, valoración de un estado de mínima actividad consciente, o simplemente para evaluar cambios durante la ejecución de distintas actividades mentales [32, 43, 45, 47-57].

El EEG, dada su estructura, parece similar a una señal estocástica pero con componentes determinísticos y sin estructuras o correlaciones aparentes a corto o largo plazo. Por ello estas señales se han estudiado con una gran variedad de métodos, tanto en el tiempo como en la frecuencia. En el dominio temporal se busca la aparición de transitorios como respuesta ante la presentación de un estímulo, reconociendo que su localización en tiempo y amplitud sean siempre similares (variando con una distribución normal alrededor de una media), esto es llamado latencia [3]. Con la edad y con algunas patologías dichas transitorios cambian su latencia y amplitud, e incluso de distribución en la corteza cerebral. En lo que cabe al análisis en frecuencia, se espera que el contenido espectral cambie dependiendo de la realización o abstención de ciertas tareas, como pueden ser observar un estímulo, hacer operaciones matemáticas, leer un texto, mover un miembro del cuerpo o inclusive imaginar que éste se mueve. El análisis en frecuencia de la actividad del EEG, hace una valoración de la sincronía en un grupo de células. Algunos investigadores han sugerido que el procesamiento de la información, se ve reflejado como un cambio en los patrones frecuenciales de un sector de la corteza cerebral o bien como un reajuste de la fase del EEG [58]. Un ejemplo típico es el que se observa en la corteza visual cuando a un sujeto se le pide cerrar o abrir los ojos, el cambio de valor en la potencia de la banda *alfa* (8 a 12 Hz) incrementa o disminuye respectivamente al hacer estas maniobras. Un comportamiento similar se ha observado en la corteza motora, aunque no tan claro, al momento de mover un miembro como un brazo, pierna o lengua. Este cambio se ha observado en la banda *beta* (12 a 30 Hz).

Se ha considerado la utilización de los **SE** con el EEG, principalmente por que éste presenta un comportamiento espectral en forma de ley de potencia $1/f$ [28, 33, 37, 44, 45], lo cual sugiere la existencia de correlaciones estadísticas de largo alcance. Aunado a la consideración de que el EEG es el resultado de la interacción de distintos procesos sincrónicos, o bien de la interacción de distintos grupos de

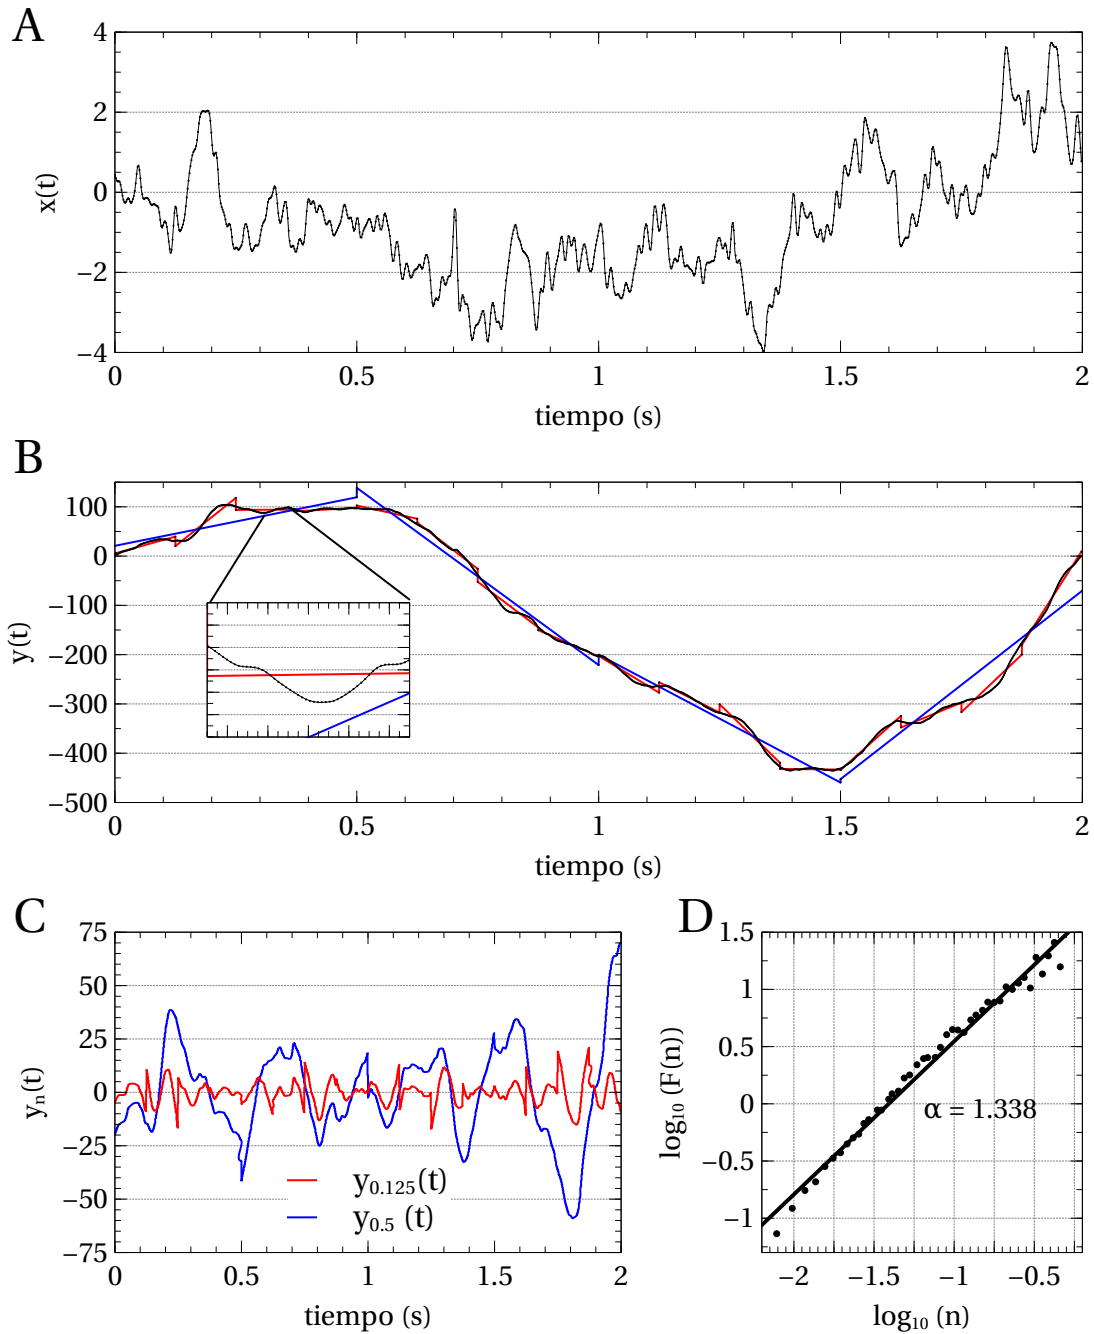


Figura 1.3: Pasos para la estimación del exponente de escalamiento, mediante el uso del método de Fluctuaciones sin Tendencia. Se muestra un ejemplo de una señal de EEG adquirida en el canal Cz de un sujeto en reposo (paso A). Posteriormente se estima una nueva serie mediante la acumulación descrita por la ecuación 1.5 (paso B). Esta nueva serie es dividida en ventanas o segmentos a los cuales se les elimina su tendencia y se construyen nuevas series. Para las distintas longitudes o escalas se estima el valor medio de las fluctuaciones con la ecuación 1.6 (paso C). Finalmente, se consideran en una escala logarítmica los distintos tamaños de ventana contra los valores medios de fluctuación y se estima el coeficiente α_{SE} , que es el valor de la pendiente en una regresión lineal de esta gráfica. Este índice α_{SE} correspondería a un exponente del tipo ϵ que se muestra en la ecuación 1.3.

Introducción

neuronas. Claramente, se considera que estas células por si solas no realizan tareas complejas como la memoria o la imaginación, pero en conjunto e interacción logran este objetivo superior. En otras palabras, las funciones cognitivas superiores que son generadas por el conjunto de neuronas, pueden considerarse como un estado emergente [59]; cualidad que también abona a su estudio con herramientas de escalamiento como la que aquí se evalúa.

Los primeros estudios usando **SE**, tuvieron como objetivo comprobar la validez en este contexto. Hwa y Ferre [55] sugirieron que el análisis del EEG usando el método DFA, debe dividirse en dos rangos de ajuste y proponen una medida para simplificar su análisis. Sugieren la utilización de un sólo índice que resuma la información de un número grande de canales, pero no hacen alusión a un significado fisiológico de los índices. Estudios como los de Stam y de Bruin [54] y Gao *et al.* [60] usaron el método DFA y encontraron diferencias significativas entre las condiciones de ojos cerrados y ojos abiertos. Este índice también ha sido empleado para pruebas de profundidad anestésica [47], y los resultados sugieren la pertinencia de su uso en el medio clínico. También ha sido utilizado para el estudio de patologías de sueño [49], estudios de epilepsia [48], estudios de Potenciales Relacionados a Eventos (PRE) [32, 45], o durante la ejecución de tareas sencillas como observar un péndulo o recordar experiencias [61].

El DFA es un método de análisis de escalamiento que presenta ventajas tanto en su implementación como en sensibilidad, y que permite estudiar señales que cambian de media y varianza a lo largo del tiempo. Además de ser factible su estimación en periodos de tiempo cortos o ventanas con pocos datos [56, 62], justo como se sugiere sea el análisis del EEG en una BCI. Además permite la identificación de correlaciones de largo alcance para señales no estacionarias y evita la detección espuria de aparentes correlaciones causadas por la misma condición no estacionaria de las señales [41, 63]. Por estas razones es que éste fue el método para el análisis de las características de escalamiento que se utilizó en este trabajo.

En BCI se ha estudiado la plausibilidad del uso de índices de escalamiento principalmente para aquellas interfaces que tienen como base las técnicas ERD/ERS. Phothisonothai, utilizó el método llamado del Exponente Crítico, registrando 15 canales de EEG; los resultados del estudio sugieren que su uso es factible para la detección de estos eventos. Dicho estudio tiene resultados que muestran el cambio del índice en función de la tarea mental; sin embargo, el índice no presentó un comportamiento similar en la población, ni por cada canal de registro [64]. Bashashati *et al.* evaluaron la capacidad de un sujeto para cambiar dicho índice a voluntad; los resultados sugieren la factibilidad de dicha suposición: 3 de 5 sujetos lograron el control, uno más tuvo un control discreto y el último no lo logró [51]. Wang *et al.*

[42], usaron también el índice de Higuchi para controlar el “avatar” de diversos videojuegos. Utilizando únicamente un canal en la parte frontal se obtuvo un alto desempeño, que además mejoró con el uso constante de la interfaz.

El uso de índices de escalamiento para el estudio del EEG ha sido objetado, principalmente por la gran cantidad de datos que se requieren para hacer una medición de los exponentes estadísticamente confiables. Se ha cuestionado la confianza que debe darse a los valores de estos índices, de tal forma que las conclusiones fisiológicas que se desprendan deben ser tomadas con cautela [32, 65]. De manera muy general, los valores de los índices revelan si el proceso que se está estudiando tiene un comportamiento completamente aleatorio, o bien, es el resultado de las interacciones a largo o corto plazo de un conjunto más amplio de procesos. Las características temporales del EEG, hacen necesario su estudio en ventanas de tiempo cortas, sobretodo en aplicaciones BCI donde el flujo de información es continuo. Los estados mentales (contar números, imaginar movimiento, hacer operaciones matemáticas, poner atención a un discurso) cambian con regularidad y la duración de estos estados por lo general es corta (de fracciones a unos cuantos segundos). Preißl ha abordado este tema, usando diferentes tamaños de ventana y con la ejecución de dos tareas [65]. Este estudio muestra que el valor medio, para el exponente de escala no permanece constante a través de la longitud de la ventana. No obstante, la relación que guardan los exponentes estimados, se conserva. Es decir, que la tarea con exponente mayor mantiene esa condición sin importar el tamaño de la ventana de análisis. Este mismo estudio hace una proyección estadística sobre la cantidad de datos necesarios para obtener un exponente de escalamiento certero, que es de aproximadamente un millón de datos. En la práctica no es factible la obtención de tal cantidad de datos, como tampoco lo es el procesarlos para una aplicación en tiempo real.

Pero a pesar de las limitaciones dichas sobre el tamaño de la ventana, y dejando de lado una interpretación fisiológica, los resultados de diferentes investigaciones parecen sugerir que la utilización de los **SE** como herramienta auxiliar para el EEG es plausible, y que su uso en sistemas como una BCI puede ser de utilidad [65].

La medición de un **SE** ha llevado a preguntar si este valor permanece constante a través del tiempo, por lo que se han hecho mediciones de este exponente en diferentes condiciones. Como ya se ha mencionado, el valor de ϵ cambia en función de la tarea mental que el sujeto esté llevando a cabo. Sin embargo, no hay consenso en lo que ese cambio significa. Gao *et al.* [60], hicieron una estimación del índice de escala en dos regiones de ajuste (como lo propone [55]); y compararon las medias de ambos valores sujeto a dos condiciones, con ojos abiertos y cerrados; obteniendo así cuatro estimaciones del

Introducción

índice, cada una asociada a las combinaciones de condición y región de ajuste. Sus resultados muestran diferencias estadísticas por la realización de la tarea, pero mientras que el valor del índice aumentó en una región en la otra ocurrió lo opuesto. Stam *et al.* [54], estimaron el valor de un exponente tipo ϵ en las bandas *alfa*, *beta*, *theta* y *delta*, y al igual que Gao, compararon el valor de los índices con ojos abiertos y cerrados. Encontraron un valor menor en la condición de ojos cerrados, y esta disminución la asocian al hecho de que la sincronización de las neuronas se pierde por el procesamiento de la información visual. Preißl *et al.* [65], compararon el valor del índice de escala en dos condiciones, i.e. exploración táctil y durante relajación (imaginando una condición placentera). El estudio muestra un valor mayor para la condición de relajación. Lutzenberger *et al.* [61], midieron el valor del índice de escala en la ejecución de diferentes tareas que involucran procesamiento visual, respuesta táctil y la evocación de un recuerdo; los valores del índice son mayores al recordar, seguidos de los valores para la respuesta táctil y finalmente los de la observación. Otros experimentos realizados en el contexto de las BCI, consisten en mover un cursor o “avatar” en un ambiente virtual, así como identificar una tarea mental que realiza un sujeto [42, 51, 66]. Aunque los resultados no fueron consistentes en cuanto a incremento o disminución del índice de escala durante la ejecución de la tarea, confirman que éste puede ser usado para controlar la interfaz.

1.7. Ideas Generales

Un mejor desempeño en la utilización de las BCI, podría implicar una mejoría para considerar éstas como medio de comunicación o impactar en el tratamiento y rehabilitación de algunos padecimientos. Para lograrlo puede avanzarse en distintas direcciones, desde la utilización de otros rasgos de las señales, generación de nuevos paradigmas de uso, nuevas técnicas de procesamiento, clasificadores más robustos, nuevas modalidades de retroalimentación, hardware más preciso, entre otros. El análisis de los exponentes de escalamiento es una herramienta novedosa que puede brindar información adicional al análisis del EEG. Estas técnicas evalúan la presencia de invariancia o correlaciones de largo plazo, dando una descripción acerca de la estructura de las series de tiempo. La incorporación de índices de este tipo, como rasgos de entrada a una BCI, podría mejorar su desempeño. En este sentido se exploró en esta tesis la utilización del índice α_{SE} obtenido mediante el método DFA como un rasgo adicional al análisis espectral de las señales de EEG.

Así, en el [capítulo 2](#) se presenta y evalúa la inclusión del índice de escalamiento para la detección

de épocas de EEG durante las cuales se realizó una actividad motora. En este primer análisis se enfoca únicamente al efecto que causa la incorporación del **SE** (α_{SE}), sin realizar la optimización del clasificador. En su lugar se hace una identificación de épocas usando un método estandarizado, pero cambiando los rasgos de entrada. En el [capítulo 3](#), se presenta y explora un paradigma de cálculo mental con la finalidad de evaluar el desempeño en un contexto similar a la operación de una BCI. El paradigma de cálculo mental, es una nueva propuesta de control adaptable a una BCI en tiempo real, que alterna la ejecución continua de la tarea de cálculo con periodos de reposo. En ésta, a diferencia de los paradigmas clásicos de **MI**, los periodos de correcta realización de la tarea son verificables lo cual apunta a una evaluación objetiva del desempeño en la identificación de tareas. En este segundo experimento se incorporan aspectos metodológicos como lo son la optimización de los hiperparámetros del clasificador y la selección de canales para cada uno de los sujetos estudiados. También la evaluación de la estabilidad de los modelos de clasificación, que se construyeron a partir de los datos de una sesión experimental y se probaron con datos registrados varios días después. En cada uno de los capítulos se encuentran discusiones acerca de los cambios de los valores de los índices así como de las implicaciones de los resultados. Finalmente en el [capítulo 4](#), se hace una recapitulación de los hallazgos, se discute acerca de las implicaciones y se muestra una perspectiva de las nuevas preguntas que surgen a raíz de los resultados de este trabajo.

Introducción

Capítulo 2

Análisis en tareas de ejecución de movimiento

2.1. Descripción

Si bien distintos exponentes de escalamiento han sido sugeridos para el estudio de las dinámicas del EEG [51, 54, 55, 67-72], la utilización del índice derivado del método DFA no ha sido evaluada en el contexto de las BCI. Es por ello que antes de intentar usar el índice directamente como control de estos sistemas se requería evaluar su desempeño en la identificación de tareas. Para ello se utilizó un paradigma con una actividad de rutina que permita constatar su realización. La propuesta que se abordó fue la utilización de una tarea motora, como es el caso de presionar un botón, ya que se podría registrar la ejecución del movimiento y compararse con los cambios en la dinámica del EEG. Ésta permitía comprobar la existencia de cambios en el EEG asociados a la ejecución de la tarea. Por lo que se consideró como un escenario propicio para evaluar el desempeño en la identificación o etiquetado de épocas de EEG. Así, este capítulo se encuentra orientado a la evaluación del desempeño para la identificación de épocas de EEG. Para ello se utilizaron diferentes rasgos de entrada, como la potencia espectral y la utilización de un **SE**.

2.2. Registros y Métodos

2.2.1. Descripción de los registros

Se utilizaron experimentos que habían sido realizados para valorar la *atención* de 40 sujetos (38 mujeres), cuya edad promedio fue de 20.32 (1.52) años. Estos estudios formaron parte de una investigación, en el Instituto Nacional de Rehabilitación (INR) [73]. Los sujetos hicieron una rutina de atención con los ojos cerrados que fue dividida en dos etapas. La primera, llamada *Condición 1* (C1, condición pasiva) consistió únicamente en la presentación de estímulos visuales (“flashes” de alta intensidad), sin que el sujeto realizara ninguna acción. Para la *Condición 2* (C2, condición pasiva), el usuario presionó un botón cada vez que la serie de estímulos visuales le fue presentada. En ambos casos los estímulos fueron presentados a una frecuencia de 12 Hz, por periodos de 2 segundos con un intervalo interestímulo (IIE) de 4 segundos. Los registros de EEG fueron tomados de 22 canales, cuya localización se muestra en la figura 2.1. Los datos fueron digitalizados usando un equipo Nicolet a una frecuencia de muestreo de 256 Hz, con un filtrado analógico cuyo ancho de banda es (0.3 a 70) Hz.




Figura 2.1: Montaje de electrodos (en rojo) para los registros en el INR

Las señales adquiridas fueron acondicionadas siguiendo los pasos que se indican:

1. Se realizó un filtrado digital con un IIR tipo butterworth de ancho de banda (0.1 a 30) Hz.
2. Los registros fueron ajustados a la referencia del promedio común (CAR), y cada canal fue normalizado para tener media cero y varianza uno.

2.2.2. Análisis de los registros

Para una primer etapa de análisis, las señales de EEG fueron analizadas usando ventanas (épocas) de dos segundos coincidentes con la presentación del estímulo, tanto de $C1$ como de $C2$. De tal forma que fue formado un par de conjuntos: todas las épocas fueron consideradas $C1$, mientras que para $C2$ se tomaron en cuenta únicamente aquellas donde el sujeto presionó el botón al menos un cuarto de segundo.

Por cada época y canal, tres índices fueron estimados: el exponente de escalamiento α_{SE} , y los índices de potencia espectral sobre las bandas alfa [(8 a 14) Hz, α_{PSD}] y beta [(14 a 35) Hz, β_{PSD}] [74]. Para la estimación del índice α_{SE} , se utilizó el software disponible en [39], usando ventanas no-deslizantes y 10 muestras como la longitud mínima de análisis. Las estimaciones de la potencia espectral fueron hechas usando el método del periodograma de Welch implementado en Octave [75], con ventana de análisis tipo Hamming de un segundo de longitud y con traslape del 90 %.

Se realizó un análisis estadístico por cada uno de los índices descritos y por cada uno de los canales de EEG registrados. Debido a que los datos no presentaban una distribución normal, se hicieron pruebas de igualdad de medianas para inferir si el valor del índice cambia en función de la condición, y además el área bajo la curva ROC (AUC, ver [apéndice C](#) para detalles acerca de este índice) fue estimada usando el valor del índice al considerarse como un clasificador sencillo por umbral. Por cada sujeto se hicieron un total de 66 comparaciones y fueron calculadas la misma cantidad de valores AUC, es decir que este proceso fue hecho para cada uno de los canales de registro. Los resultados se muestran de manera sintética como la proporción de población (**PP**) para los cuales se obtuvo una diferencia estadísticamente significativa con respecto a las medianas de los índices ($p < 0.05$) y el valor promedio de AUC. Adicionalmente, por cada canal se estimó el valor de la correlación de Pearson entre las distintas combinaciones de índices con el fin de conocer la asociación potencial entre ellos. Debido a la dispersión de los datos de potencia espectral, para estos índices fue utilizado el valor de su logaritmo en los análisis descritos.

Con los resultados del análisis estadístico, los canales fueron acomodados de mayor a menor con relación al valor medio de AUC y **PP** estimados para la población completa. Los cinco canales con mayor AUC y **PP** fueron seleccionados para formar un conjunto de canales a ser usados para una etapa de clasificación de épocas. El conjunto de canales seleccionados, que fue usado para todos los sujetos, fue: C3, C4, P3, T3 y T4. Los índices α_{PSD} , β_{PSD} y α_{SE} fueron usados como rasgos de entrada del proceso de clasificación por lo que se evaluaron las siete posibles combinaciones de rasgos. Las primeras

Ejecución de Movimiento

tres corresponden a la utilización de los índices de forma independiente (α_{PSD} , β_{PSD} y α_{SE}), tres a las distintas combinaciones por pares de índices ($\alpha_{PSD}-\beta_{PSD}$, $\alpha_{PSD}-\alpha_{SE}$ y $\beta_{PSD}-\alpha_{SE}$) y finalmente la combinación de los tres índices formando un solo vector ($\alpha_{PSD}-\beta_{PSD}-\alpha_{SE}$). Los clasificadores que se implementaron fueron máquinas de soporte vectorial (SVM) de *kernel* Gaussiano y no se realizó un proceso de optimización de sus hiperparámetros (en el [apéndice B](#) se dan detalles acerca de las SVM y los pasos para la optimización de los hiperparámetros), dado que en este capítulo únicamente se buscaba comparar la sensibilidad de los índices para identificar la ejecución de las tareas. El desempeño de cada clasificador fue medido en términos de certeza y AUC, las cuales fueron tomadas como el valor medio después de un proceso repetitivo de submuestreo aleatorio, usando 20 vías. Por cada vía el 70 % del conjunto de datos fue utilizado para el entrenamiento y el resto para probar el clasificador. Este proceso fue hecho para cada uno de los sujetos, y se estimaron el valor medio de AUC por sujeto y de la población en general. Este procedimiento fue repetido también para cada una de las combinaciones mencionadas, por lo que se obtuvo al final una estimación del desempeño en la identificación de épocas en función de la combinación explorada.

Finalmente, para comprobar que las distintas combinaciones arrojaban resultados con diferencias estadísticamente significativas, se compararon los resultados obtenidos usando como conjunto de pruebas los resultados de cada una de las vías. Dado que la distribución de los datos no fue normal, las pruebas estadísticas se realizaron con relación a la igualdad de medianas (Wilcoxon de rango).

2.3. Resultados

2.3.1. Descripción Estadística de los índices

La figura [2.2](#) muestra los resultados del análisis estadístico, resumidos con los valores de **PP**. Tanto para α_{PSD} como para α_{SE} , las regiones que muestran el valor más alto, cercanas a 0.6, están ubicadas dentro de las áreas motoras; aunque cada índice presenta su valor máximo en distintos electrodos. Para α_{PSD} el área más grande asociada con cambios en el comportamiento del índice está ubicada en el hemisferio derecho, contrario a lo que sucede con α_{SE} . Mientras que para el índice β_{PSD} pocos canales muestran cambios estadísticamente significativos. En la figura [2.3](#) se muestra la distribución por canales de los valores medios poblacionales de AUC. Estos resultados son similares a los identificados para la **PP** en su distribución espacial. Los índices α_{PSD} y α_{SE} también obtuvieron los valores máximos de AUC, mientras que β_{PSD} muestra menor capacidad de discriminación entre las tareas del experimento.




Figura 2.2: Distribución sobre los canales de la proporción de la población (**PP**), que mostró diferencias estadísticamente significativas $p < 0.05$ entre las condiciones $C1$ (pasiva) y $C2$ (activa). Se muestra por separado el resultado asociado a cada uno de los índices




Figura 2.3: Valor medio por canal de los valores de AUC para todos los sujetos. Se muestra por separado el resultado de cada uno de los índices.

Como ya se ha mencionado, α_{PSD} y α_{SE} muestran una mayor similitud en la distribución de sus valores de **PP** y AUC. Pero el índice espectral presenta una distribución con mayor dispersión y extensión, que aquella descrita por α_{SE} . Los índices espectrales tuvieron una distribución aparentemente más simétrica, y sus valores están localizados dentro del área motora con cambios suaves hacia las regiones central y occipital. Para el exponente de escalamiento, las áreas con diferencias estadísticas también están ubicadas en la corteza motora pero con menor dispersión hacia otras regiones. Un área más extensa significa que más canales mostraron diferencias entre ambas condiciones experimentales, lo cual sugeriría que una mayor área de la corteza está involucrada en la ejecución de la tarea.

El sentido del cambio en los valores de la mediana de cada una de las condiciones está ejemplificado en la figura 2.4. Se aprecia que los valores de α_{PSD} tienden a ser menores para la condición activa $C2$ que con respecto a la condición de reposo $C1$. Este comportamiento coincide con lo descrito por Pfurtscheller y Aranibar [8], quienes asociaron una disminución de la potencia espectral por la ejecución

Ejecución de Movimiento




Figura 2.4: Valores de las medianas para cada sujeto bajo las condiciones: activa ($C2$, caja blanca) y pasiva ($C1$, caja gris). Estos valores fueron estimados para el canal $C3$, que es donde se aprecia el mayor valor de PP . En rojo están marcados los sujetos para los cuales se hallaron diferencias estadísticamente significativas ($p < 0.05$) y las cruces corresponden a los puntos atípicos en la distribución. Las líneas sirven de ayuda para evaluar el sentido del cambio en función de la tarea.

del movimiento voluntario. Para el índice α_{SE} sucede lo opuesto y es la tarea activa $C2$ la que tiende a presentar los valores más altos. Aunque no todos los sujetos siguen estas tendencias, como se puede ver en la figura referida, existen sujetos con diferencias estadísticamente significativas que tienen un comportamiento en el sentido contrario.

En la figura 2.5 se muestran los valores obtenidos del coeficiente de correlación de Pearson entre los distintos índices. Tal como se ha mencionado, para la potencia espectral se utilizaron sus valores logarítmicos debido al amplio rango existente. La figura muestra que la correlación entre los índices espectrales es mayor (y positiva) que la mostrada entre el exponente de escalamiento y cualquiera de los otros dos índices estudiados. Tal y como era de esperarse estas correlaciones son negativas, lo que confirma el sentido del cambio de valores de la figura 2.4, así como la relación teórica existente entre el espectro y el SE .

2.3.2. Pruebas de Identificación de Tarea

La capacidad de cada índice para identificar la pertenencia de la época a alguna de las dos tareas realizadas fue evaluada mediante el proceso de *Identificación de Tarea (IT)*. Los clasificadores fueron construidos tomando como entradas los estimados de cada uno de los índices en los canales: $P3$, $C4$, $C3$,




Figura 2.5: Valores del coeficiente de correlación para cada canal, y combinación de índices. La correlación entre los índices de potencia espectral fueron calculados sobre el logaritmo de sus valores.

T3 y T4. Estos canales fueron seleccionados porque presentaron la mayor **PP** de las pruebas estadísticas y los valores más altos de AUC. La localización de los canales mencionados se ubica sobre la región motora cubriendo ambos hemisferios, tal como se aprecia en las figuras 2.2 y 2.3. Los mejores canales para β_{PSD} no fueron incluidos debido a la baja sensibilidad reportada para la discriminación de las tareas tal y como se estableció con las pruebas estadísticas.

Se comparó el desempeño de las distintas combinaciones de los índices al usarse como entradas al proceso de clasificación. Estas comparaciones fueron hechas usando el AUC y la certeza. Dado que estos índices no poseen una distribución Gaussiana, las pruebas estadísticas se hicieron para la igualdad de medianas. Estos resultados se encuentran sintetizados en los cuadros 2.1 y 2.2 y en la figura 2.6 se muestra una gráfica de cajas que resume los resultados de la **IT**. Los índices α_{PSD} y α_{SE} poseen valores de AUC y certeza con medianas similares, mientras que β_{PSD} muestra los valores más bajos. Estos resultados son coincidentes con aquellos mostrados en las gráficas topográficas (figuras 2.3 y 2.2). La combinación de índices parece mejorar la identificación de las épocas, ya que los valores de AUC y de certeza estimados aumentan al hacer este cambio en los rasgos de entrada. Una pequeña diferencia entre el desempeño de α_{PSD} y α_{SE} consiste en que para el segundo, la distribución de los valores de certeza parecen menos dispersos, pero la distribución de los valores de AUC luce similar.

Las comparaciones estadísticas del cuadro 2.1 utilizan las salidas obtenidas de todas las vías y todos

Ejecución de Movimiento

los sujetos, es decir, ochocientos valores por cada una de las combinaciones de rasgos de entrada. Cada entrada exhibe la comparación hecha de la combinación referida en columna vs la del renglón. La tabla está dividida en dos secciones: 1) la triangular superior muestra el resultado de las comparaciones sobre el valor de AUC y 2) la triangular inferior corresponde a las comparaciones sobre el índice de certeza. Las pruebas que obtuvieron un valor $p < 0.008$ están marcadas con un “1”, que corresponde al ajuste del estadístico de prueba para comparaciones múltiples con resultados significativos.

El cuadro 2.2, resume los porcentajes de población con mejor desempeño comparando las distintas combinaciones de los rasgos de entrada. Los valores expresados en dicho cuadro, indican la proporción de la población que en las pruebas de una sola cola obtuvo un valor de $p < 0.004$ ($H_0: AUC_{index\ renglón} \leq AUC_{index\ columna}$). Estas comparaciones fueron realizadas por cada sujeto utilizando las veinte salidas del proceso de **IT**. Es decir, se compararon los resultados de la clasificación obtenidas por cada una de las distintas combinaciones de rasgos de entrada para el mismo sujeto. De esta forma se puede saber si la combinación de rasgos x resulta en un mejor desempeño para un sujeto en particular, que la combinación y .

De acuerdo con los resultados mostrados en el cuadro 2.1 los índices α_{PSD} y α_{SE} muestran capacidades similares para realizar el proceso de **IT**. La **PP** (ver cuadro 2.2) para la cual se identificó un mejor desempeño en la comparación de este par de índices está por debajo de la mitad de la población (0.375 para α_{PSD} –renglón 1, columna 2– y 0.275 para α_{SE} –renglón 2, columna 1–). Y las comparaciones con β_{PSD} mostraron el mismo valor de **PP**, lo cual reafirma que tanto α_{SE} como α_{PSD} muestran un desempeño similar para realizar la **IT**. Por otra parte el índice β_{PSD} mostró el desempeño más bajo para la clasificación de las épocas. En términos de la **PP**, este índice se desempeñó mejor que α_{SE} en 0.200 (renglón 3, columna 1) y que α_{PSD} en 0.175 (renglón 3, columna 2), mientras que la comparación opuesta, para ambos casos es de 0.450.

En el cuadro 2.1 se aprecia que las combinaciones que contienen a los índices α_{SE} y α_{PSD} mostraron ser distintas a todas las demás combinaciones $p < 0.008$ (ver la columna 3 y también el renglón 3). Para esta combinación, la **PP** que mostró una mejoría en la clasificación fue de 0.275 (haciendo una lectura del renglón), mientras que para la comparación opuesta, aquellas combinaciones que obtuvieron mejor desempeño son de 0.150.

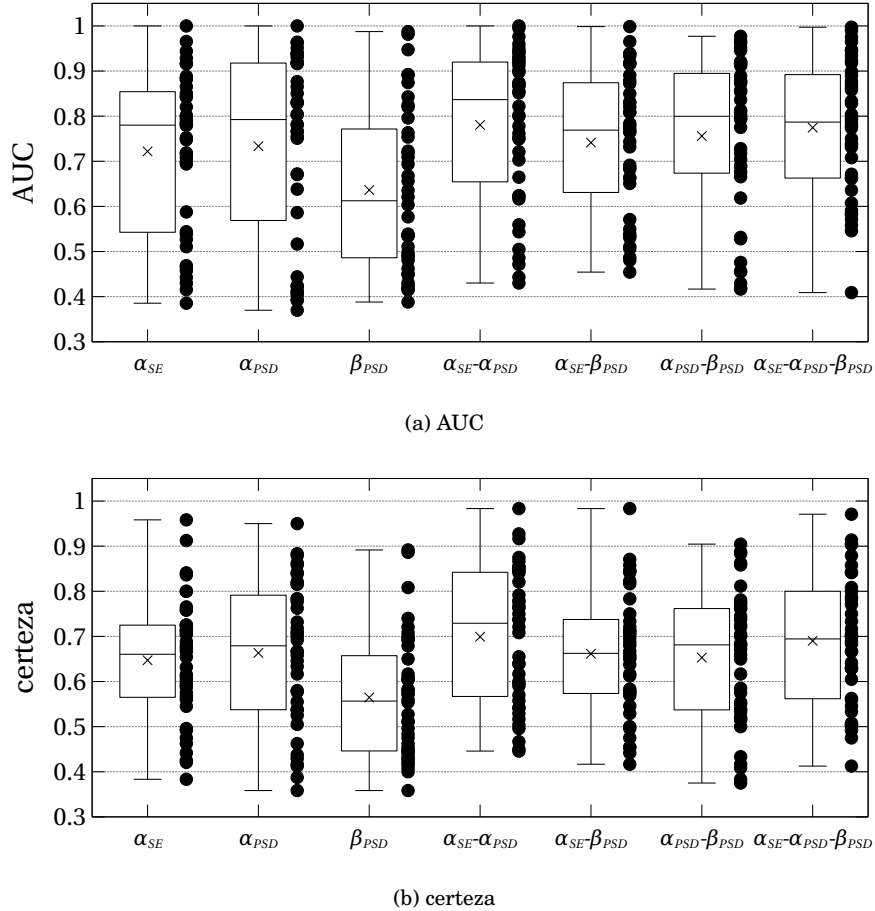


Figura 2.6: Gráficas de cajas para el valor de AUC (a) y certeza (b), estimadas para las siete combinaciones de índices. Usando los canales C3, C4, T3, T4 y P3.

2.4. Discusión y conclusiones

Las pruebas efectuadas en este capítulo muestran indicios de que con el exponente de escalamiento (α_{SE}) es posible detectar cambios de la actividad neuronal asociados con la ejecución de tareas motoras, lo cual concuerda con trabajos previos [51, 54, 60]. Y que al parecer el índice α_{SE} tiene una capacidad de discriminar estas tareas comparable con un índice que ha sido ampliamente utilizado en este contexto, α_{PSD} [9, 74]. Las comparaciones del exponente de escalamiento contra las medidas estándar (potencia espectral) resultan necesarias con el fin de evaluar su capacidad de describir los cambios en la dinámica del EEG. Estas evaluaciones hechas sobre una base de datos amplia (cuarenta sujetos), sugieren que el índice de escalamiento (α_{SE}) posee una sensibilidad similar a la de la potencia espectral (α_{PSD}) para la detección de cambios en la dinámica del EEG asociada con la ejecución de una tarea motora. Las distribuciones sobre los canales de EEG de los índices **PP** (proporción de población) y AUC son similares.

Ejecución de Movimiento

Cuadro 2.1: Comparativo del desempeño en la clasificación al utilizar las distintas combinaciones de índices. Las entradas marcadas con “1” indican que la comparación (renglón - columna) obtuvo un valor $p < 0.008$. El cuadro está dividido en dos secciones: la triangular superior para la comparación de los valores de AUC y la inferior para los de certeza.

	α_{SE}	α_{PSD}	β_{PSD}	α_{SE} - α_{PSD}	α_{SE} - β_{PSD}	α_{PSD} - β_{PSD}	α_{SE} - α_{PSD} - β_{PSD}
α_{SE}			1	1		1	1
α_{PSD}			1	1			
β_{PSD}	1	1		1	1	1	1
α_{SE} - α_{PSD}	1	1	1		1		
α_{SE} - β_{PSD}			1	1			1
α_{PSD} - β_{PSD}			1	1			
α_{SE} - α_{PSD} - β_{PSD}	1		1		1	1	

Cuadro 2.2: Valores de proporción de población que obtuvieron valor de $p < 0.004$ para las pruebas de una sola cola en las pruebas de Wilcoxon, con hipótesis alterna $AUC_{index\ fila} > AUC_{index\ columna}$. La lectura de renglones indica la proporción de población para la cual la combinación seleccionada mejora la *Identificación de Actividad*.

	α_{SE}	α_{PSD}	β_{PSD}	α_{SE} - α_{PSD}	α_{SE} - β_{PSD}	α_{PSD} - β_{PSD}	α_{SE} - α_{PSD} - β_{PSD}
α_{SE}	0.000	0.275	0.450	0.050	0.100	0.250	0.100
α_{PSD}	0.375	0.000	0.450	0.075	0.300	0.075	0.175
β_{PSD}	0.200	0.175	0.000	0.075	0.050	0.050	0.025
α_{SE} - α_{PSD}	0.350	0.275	0.550	0.000	0.275	0.300	0.050
α_{SE} - β_{PSD}	0.200	0.275	0.400	0.050	0.000	0.225	0.025
α_{PSD} - β_{PSD}	0.350	0.075	0.550	0.150	0.325	0.000	0.050
α_{SE} - α_{PSD} - β_{PSD}	0.325	0.275	0.575	0.075	0.250	0.200	0.000

Tal como era esperado los electrodos tempo-parietales, que están ubicados sobre la corteza motora, fueron los que mostraron una mayor **PP** y valores de AUC más altos para los índices α_{SE} y α_{PSD} (ver figuras 2.2 y 2.3). Pero la distribución de estas medidas son más homogéneas para α_{SE} que para α_{PSD} , sobre todo en lo que respecta a la estimación de AUC (ver figura 2.3). Para α_{SE} la dispersión mostrada hacia otras regiones es menor que la observada para el índice espectral, que muestra una extensión hacia la región occipital. Un área más grande implica que para una mayor cantidad de canales se hallaron diferencias estadísticas, lo cual sugeriría que una mayor región cerebral está involucrada en la realización de la tarea, o bien que los canales vecinos se “contaminan” dificultando la localización del foco donde se está efectuando el procesamiento de la tarea. Otra diferencia entre la distribución de los índices está relacionada con la lateralización de la respuesta, mientras para α_{PSD} se muestra más sesgada hacia la derecha sucede lo opuesto con α_{SE} . Desafortunadamente, no se contó con la información sobre la lateralidad de cada uno de los sujetos; sin embargo, por rasgos de la población se puede suponer una mayoría diestra, por lo que la corteza motora izquierda debiera ser la más activa durante la tarea

(contralateral al movimiento). Esta suposición concordaría entonces con la región identificada con el índice α_{SE} .

El valor medio sobre todos los canales de la correlación $\alpha_{SE}-\alpha_{PSD}$ es de -0.36 (0.083), como se observa en la figura 2.5. Este valor negativo era esperado, debido a la asociación reportada entre el exponente de escalamiento y la potencia espectral [28]. Por las condiciones experimentales de este experimento, el valor de α_{PSD} tiende a disminuir durante la realización de la tarea motora (ver figura 2.4b) mientras que α_{SE} muestra un comportamiento contrario (ver figura 2.4a). Un descenso en el exponente de escala está relacionado con un proceso menos correlacionado y más parecido al ruido blanco; lo cual también implica una señal con mayor irregularidad. Los cambios en la dinámica del EEG generados por la ejecución de la tarea motora sugieren una disminución de la potencia en la banda alfa, pero con mayores correlaciones de largo alcance. Es decir, se convierte en un proceso con disminución de algunos componentes periódicos pero también más auto-correlacionado. Esto diferenciándose de lo considerado por Gao et al. [60] y Jospin *et al.* [47], quienes identificaron un crecimiento en el exponente asociado con los ojos cerrados y con estados de anestesia más profundos, respectivamente. En ambos estudios, las mediciones de los índices de escalamiento fueron hechas usando escalas de tiempo más amplias y no fue probado para ventanas de tiempo cortas como las presentadas en este trabajo. Esto puede ser un indicio de que la dinámica del EEG está constituida por procesos que tienen comportamientos distintos a diferentes escalas de tiempo. En particular para el caso de estudio presentado en este trabajo, una posible explicación en el aumento del índice de escalamiento es que al realizar el movimiento se conduce al ensamble neuronal a un estado de interacción más correlacionado, al menos en el corto plazo (alrededor de dos segundos).

El valor absoluto de la correlación $\alpha_{SE}-\alpha_{PSD}$ (0.36), indica una asociación con valor bajo aunque estadísticamente significativa entre estas variables, lo cual soporta la consideración de que cada índice refleja características diferentes de los datos de EEG. Esta idea también está soportada por los experimentos de **IT** (identificación de tarea), con los que se mostró que las capacidades de los índices de escala y espectrales para identificar cambios en actividad neuronal son similares y su combinación favorece esta identificación. En estos experimentos, el procedimiento de clasificación consistió en identificar la pertenencia de cada época a una de las dos actividades. Aun cuando la optimización de los hiperparámetros de los clasificadores no fue hecha, ambos índices mostraron un desempeño distinto al trivial (o esperado por azar). Las combinaciones que usaron de manera conjunta tanto α_{PSD} como α_{SE} , mejoraron el desempeño de la **IT** tal como se muestra en los cuadros 2.1 y 2.2. Estos hechos refuerzan

Ejecución de Movimiento

la hipótesis de que, en la práctica, α_{SE} y α_{PSD} ofrecen información diferente acerca del EEG. Con lo cual, cada uno provee información del proceso que puede ser usada de forma combinada para lograr una mejor caracterización de los cambios en el EEG.

La utilización de una base de datos con cuarenta sujetos, permitió alcanzar un mejor entendimiento del comportamiento de estos índices. El cuadro 2.2, muestra otro hecho importante: en 37.5 % de la población la **IT** fue más acertada usando α_{PSD} , mientras que para otro 27.5 % ocurrió lo mismo pero con α_{SE} y en el 35 % restante ambos índices tuvieron un comportamiento similar. Esto indica que para cada sujeto en particular alguno de los dos índices puede resultar más sensible para describir la dinámica del EEG durante la realización de la tarea motora. El cuadro 2.2, muestra que las combinaciones que contienen α_{SE} y α_{PSD} , en casi todos los casos alcanzan los valores de **PP** más altos. Lo cual hace suponer que tanto índice el espectral como de escalamiento son complementarios para la descripción de los cambios en la dinámica del EEG, circunstancia que fue explorada con mayor detalle en el siguiente capítulo. Por lo cual, la estimación de ambos, puede llegar a ser útil para la identificación de los llamados *estados mentales*, o para guiar la operación de una BCI.

La principal restricción para el uso de exponentes de escalamiento en las neurociencias, puede ser (teóricamente) la gran cantidad de datos necesarios para lograr una estimación certera [61]. Para la descripción exacta de la naturaleza de una señal este podría ser un punto importante. Pero en el sentido en el que el exponente de escalamiento fue usado en este trabajo, esta restricción puede ser omitida ya que los resultados sustentan que es posible la **IT** con un nivel de desempeño similar a lo obtenido usando un índice espectral clásico.

2.5. Síntesis y Puntos Relevantes

Este capítulo puede sintetizarse en lo siguiente:

- La utilización del exponente de escalamiento (α_{SE}) y la potencia espectral en la banda alfa (α_{PSD}) muestra capacidades similares para describir los cambios en la dinámica del EEG durante la realización de una tarea motora.
- El índice α_{SE} parece identificar de mejor manera los canales donde se realiza el proceso mental asociado con la ejecución del movimiento.
- El uso combinado del exponente de escalamiento α_{SE} y la potencia espectral α_{PSD} mejora en

2.5 Síntesis y Puntos Relevantes

términos poblacionales la identificación de cambios en la dinámica del EEG, asociándose esto al hecho de que cada uno de ellos provee distinta información del proceso.

- Los resultados muestran que la sensibilidad de los índices para describir la tarea motora es dependiente de cada sujeto.

Ejecución de Movimiento

Capítulo 3

Análisis en tareas de cálculo mental

3.1. Introducción

En el capítulo anterior se observa que la inclusión del rasgo α_{SE} mejoró en términos poblacionales la identificación de épocas, *reposo vs actividad*. Se muestra también que la sensibilidad de éste en la detección de los cambios es similar a la de la potencia espectral. Pero los resultados de la clasificación y de la correlación sugieren que las características de cada uno de los índices aportan diferente información acerca de la dinámica del EEG. Así fue necesario evaluar esta ventaja metodológica para la identificación de la ejecución de una tarea mental. El haber utilizado la **MI** como la tarea a ejecutar podría conllevar a caer en los dilemas que se han descrito para tal paradigma. Por lo que en este capítulo se propuso e implementó un paradigma diferente, que genera cambios en la dinámica del EEG y que puede ser adaptado fácilmente a una BCI.

Algunos paradigmas que pueden generar cambios del tipo ERD/ERS y que han sido usados en BCI son: imaginar la rotación de objetos tridimensionales, la lectura, el canto silente, o el cálculo mental [34-36]. Esta última es una tarea que es verificable, al conocerse el resultado de la operación, y ha sido utilizada en el contexto de las BCI. Fue sugerida por primera vez por Keirn y Auñón [35], quienes clasificaron segmentos de EEG asociados con la realización de cinco tareas diferentes. Su experimentación no permitió la realización intercalada de tareas, dejando que cada una de las tareas experimentales se repitiera cinco veces consecutivas. Un trabajo siguiente realizado por Anderson *et al.* [76], utilizó los datos de Keirn y Auñón pero usaron una red neuronal como clasificador. Por su parte Obermaier *et al.* [77] experimentaron con un paradigma similar que también incluyó la tarea aritmética.

Una aproximación más fue hecha por Penny *et al.* [78], quienes identificaron aritmética mental versus **MI**, y el comportamiento en la línea de base (reposo) versus **MI**. Su paradigma consistió en periodos sucesivos intercalados con las tareas; usando como rasgos los coeficientes de un modelo autorregresivo y el análisis de potencia espectral. Roberts *et al.* [79] usaron un paradigma similar al de Penny, pero con un distinto tamaño de los bloques. En un trabajo posterior, este último grupo, sugiere que la utilización de características no-lineales, en particular la descomposición del espacio-envolvente (ESD –Embedding-Space Decomposition–), puede mejorar el desempeño de la clasificación [80]. Ambos diseños experimentales (Penny *et al.* [78] y Roberts *et al.* [79]) señalan que el cálculo mental es más factible de ser distinguido cuando se compara con **MI**. En todos estos trabajos la tarea mental usada fue la misma: “la resta sucesiva del número siete a un número grande”. Estos experimentos realizaron la clasificación con segmentos de EEG libre de artefactos, lo cual se contrapone con la implementación de una BCI en tiempo real.

La utilización de una aritmética más compleja podría mejorar el desempeño de un sistema que utilice esta tarea. Los estudios realizados por Fernández *et al.* [81], muestran que la realización de la aritmética mental produce cambios significativos de potencia espectral en todas las bandas clásicas y en distintos canales de registro. En este contexto Dehane *et al.* [82, 83], mostraron que la realización de una tarea aritmética involucra numerosas redes o regiones neuronales, localizadas principalmente en el lóbulo parietal y el giro angular, y que dependiendo de la operación que se presente, diferentes mecanismos pueden ser activados.

Así, en este capítulo se evalúa el desempeño de la clasificación de tramos de EEG continuos durante la realización episódica de tareas aritméticas. Se compara el desempeño obtenido al usar como rasgos de clasificación la potencia espectral y el **SE** asociado a cada ventana de análisis. El esquema que se utilizó es fácilmente adaptable a una BCI de tiempo real, por ello se hizo una detección continua usando una ventana deslizante de dos segundos de duración.

3.2. Registros

3.2.1. Sujetos

Para este estudio se pidió la participación voluntaria a 15 sujetos sanos (8 mujeres), cuya edad promedio fue de 25.3 (3.47) años, todos con estudios a nivel preparatoria completos. Los sujetos asistieron a tres sesiones de registro en días distintos acorde con su disponibilidad de tiempo. Por lo que entre cada

sesión se tuvo de entre 6 a 110 días de diferencia. Por cada una de las sesiones, los sujetos realizaron de dos a tres realizaciones experimentales, dependiendo del nivel de fatiga expresado. Una realización experimental consistió en la presentación sucesiva de catorce conjuntos de tres a cinco operaciones mentales, previamente agrupadas y seleccionados al azar de una base de 96 conjuntos posibles. Se impidió la repetición de conjuntos durante la misma realización. En todos estos conjuntos de operaciones se usaron números positivos menores a cien, tanto para operandos como para resultados (más adelante se detallará el paradigma empleado).

Se registraron treinta y dos señales de EEG en diversas posiciones del sistema 10-20. Los canales de registro fueron: Fp[z,1,2], AF[7,3,z,4,8], F[7,3,z,4,8], Fc[3,4], T[7,8] C[3,z,4], Cp[3,4], PO[3,4], P[7,3,z,4,8] y O[1,2,z] (ver figura 3.1). La tierra fue colocada en el mastoides derecho. Para la referencia se utilizaron ambos lóbulos de las orejas. Los registros fueron adquiridos usando un amplificador g.USBamp (g.TEC, Austria) con frecuencia de muestreo de 512 Hz, con un filtro pasabanda de (0.1 a 60) Hz y un rechazabanda centrado en 60 Hz. Se pidió a los sujetos que redujeran lo más posible sus movimientos para disminuir los efectos causados por la actividad muscular y/o desplazamientos oculares, dejando que el participante descansara lo suficiente entre cada una de las realizaciones [84, 85].




Figura 3.1: Montaje de canales usados para las pruebas de cálculo mental.

3.2.2. Descripción del Paradigma

Los sujetos estuvieron sentados cómodamente frente a un monitor y se les pidió que calcularan mentalmente las operaciones que se mostraban en pantalla. Al final de cada conjunto verbalizaron

Cálculo Mental

el resultado de la operación en el momento señalado por el monitor. Con base a la verbalización de las respuestas, los conjuntos con respuestas incorrectas o que no pudieron ser completadas, fueron descartadas del análisis posterior. Esta decisión fue tomada con la finalidad de evitar la inclusión de épocas de EEG con “falsa” realización de la tarea, tal como puede ocurrir con los paradigmas de **MI**.

Una realización experimental consistió de 20 s de reposo (pantalla en blanco), la presentación de 14 conjuntos de operación-reposo y otros 20 s de reposo. El lapso de tiempo entre la presentación consecutiva de operación fue aleatorio, por lo que la duración total de la prueba resultó de 406 a 425 segundos. Los conjuntos de operación-reposo consistieron en la presentación consecutiva de cinco tipos de ventana, cuya intención fue la generación de bloques de actividad y reposo de distinta duración para evitar la habituación de los sujetos a la prueba. Se mostraron 5 tipos de ventana siempre en el mismo orden:

1. **Atento.** Marcado con una “X”, avisa al sujeto que comenzará la presentación de las operaciones.
2. **Inicio.** Se presenta un número menor a 20 que es el primer operando que debe memorizar y utilizar.
3. **Operar.** Se muestra un símbolo de operación aritmética acompañado por el segundo operando. En la primer ventana de este tipo, la operación se realiza entre el número presentado en **Inicio** y el actual. Para las ventanas posteriores la operación se realiza entre el operando actual y el resultado de la ventana anterior. Se presentan de 3 a 5 ventanas de este tipo consecutivamente, dependiendo del conjunto seleccionado.
4. **Respuesta.** Se muestra el símbolo “=” y es el momento en el que el sujeto verbaliza su respuesta. Los sujetos siempre recibían retroalimentación, se les decía que la respuesta que dieron fue correcta. Esto se hizo con la finalidad de motivarlos para continuar con la prueba y no distraerse por una mala ejecución.
5. **Reposo.** Se muestran de 2 a 4 ventanas en blanco dependiendo del conjunto seleccionado y posterior a esto comienza la presentación de un nuevo conjunto, que inicia con otra ventana **Atento**.

En la figura 3.2 se muestra un ejemplo de la secuencia de pantallas para un conjunto ejemplo. Todas las ventanas tienen una duración de dos segundos y un intervalo inter-estímulo (IIE) que varía de entre

625 ms a 725 ms. Un conjunto de operación está definido desde la aparición de la ventana **Atento** hasta el instante que termina la última ventana de **Reposo**.

Para evitar que las operaciones tuvieran resultados numéricos racionales, se construyeron 96 conjuntos de los cuales antes de cada realización se seleccionaron al azar catorce sin permitir repeticiones. Los conjuntos estuvieron formados por la ejecución de 3, 4 ó 5 cálculos mentales, y de 4, 3 ó 2 ventanas de **Reposo**, respectivamente; por lo que todos los conjuntos presentaron exactamente la misma cantidad de ventanas, pero distinta duración de periodos de actividad y reposo. Un conjunto completo tenía una duración de 26.2 a 27.5 segundos, que corresponde a la presentación de 11 ventanas de dos segundos además de los IIE. Con esta disposición de ventanas los sujetos atendieron bloques continuos de actividad **Operar** y bloques de **Reposo**, los cuales fueron usados para el análisis de los datos. La duración de estos bloques fue adecuada para detectar cambios en la dinámica del EEG similar a lo que ocurre en un paradigma de **MI** [8].




Figura 3.2: Ejemplo de una conjunto de operaciones usado para el paradigma de cálculo mental.

3.3. Métodos

El análisis de estos datos se dividió en dos etapas. Primero una etapa estadística que brinda información acerca del comportamiento de los índices en los distintos canales. Con esta información se eligen aquellos cuatro que muestran una mayor capacidad de discriminación entre la actividad y el reposo. Esto reduce la dimensionalidad de los datos para el problema de clasificación y hace posible que el esquema pueda ser puesto en práctica para una BCI en tiempo real. La segunda parte del análisis consistió en la evaluación del desempeño para la identificación de épocas usando segmentos de EEG que no fueron usados para construir el modelo de clasificación, simulando las condiciones de una BCI real.

3.3.1. Análisis Estadístico

En todos los registros de EEG la referencia fue ajustada usando el promedio común (CAR) para incrementar la relación señal-a-ruido [1]. Las señales fueron filtradas con un pasa-bajas Butterworth a 40 Hz para atenuar los efectos causados por los artefactos musculares [84, 85]. Se usaron los datos obtenidos del amplificador sin escalamiento. Estas consideraciones para el acondicionamiento de la señal fueron contempladas para disminuir la carga computacional y siguiendo un procedimiento *ad hoc* para la puesta en marcha de un sistema en tiempo real. Los datos de cada sesión fueron segmentados en épocas de 2 segundos de duración sincronizados con la presentación de las ventanas **Operar** y **Reposo**. Estas épocas fueron acomodadas en dos grupos acordes con el tipo de ventana, así por cada conjunto de operaciones 4 a 6 épocas fueron colocadas en el estado **Operar** y de 2 a 4 en **Reposo**. Por cada una de las épocas se estimaron tanto el valor del exponente de escalamiento (α_{SE}) y la potencia espectral en la banda *beta* (β_{PSD}). Esta banda fue seleccionada por cuestiones fisiológicas, ya que estudios previos muestran que este tipo de tareas tienen una mayor afectación en ella [74, 81]. Los parámetros de estimación de los índices fueron los siguientes:

- **Potencia espectral sobre la banda beta** (β_{PSD} [14 a 35] Hz) [74]: Usando el método del periodograma de Welch, con una longitud de ventana de 1 segundo, traslape de 90 % y una resolución de 1024 puntos.
- **Exponente de Escalamiento** (α_{SE}): Estimado usando el método propuesto por Peng [30, 54, 86], para las escalas con un rango de 20 a 500 ms (n de 10 a 256 muestras y ajuste lineal).

Con cada uno de los índices y canales se hizo un proceso de identificación de estado mediante umbral y se estimó el valor de AUC para cada uno de ellos. La evaluación del desempeño se hizo con esta medida, dado el número desigual de elementos que conforman cada uno de los grupos [87-89]. De esta manera por cada índice los canales fueron ordenados para identificar cuáles de ellos presentan la mayor capacidad de discriminar entre ambos estados, y los dos más altos por cada índice fueron seleccionados como los canales a utilizar en la siguiente etapa de análisis. Debido a consideraciones fisiológicas la selección de estos canales se restringió a la utilización de : AF[3,z,4], F[7,3,z,4,8], FC[3,4], C[3,z,4], CP[3,4] y P[3,z,4] [74, 82, 83, 90, 91]. Además de esta identificación, se hicieron pruebas estadísticas sobre la mediana para encontrar diferencias en el valor de los índices en función del estado mental. Esto fue hecho por cada uno de los treinta y dos canales, similar a lo que se hizo en el capítulo [Ejecución de movimiento](#). De la misma manera el valor de **PP** fue estimado para identificar aquellos canales donde

el valor del índice cambiaba en función de la tarea.

Este análisis, hecho para cada uno de los sujetos, permitió seleccionar los canales que podrían ser usados por una BCI de una manera sencilla, sin hacer una búsqueda exhaustiva. El método aquí propuesto incorporó la idea de seleccionar rasgos (canales o índices) que tienen la mayor separación entre los grupos de datos a clasificar. Al mapear en un espacio n -dimensional estos puntos, cada una de las dimensiones corresponde a uno de los rasgos de entrada. De tal forma que la separación por umbral divide los puntos con un hiperplano perpendicular al rasgo (dimensión) que se evalúa. Al seleccionar los rasgos con mayor sensibilidad para separar los conjuntos de puntos, se están eliminando las dimensiones para las cuales los puntos son menos discriminables. Con esta lógica el mínimo nivel de sensibilidad sería el que se obtiene con el hiperplano ortogonal a la dimensión con mayor capacidad para discriminar los datos.

3.3.2. Simulación BCI

Con los mismos registros se hizo un segundo análisis que simula las condiciones de identificación de estados en un sistema BCI. Para ello se implementaron dos esquemas el primer esquema sirve para construir el modelo de clasificación con una validación cruzada (**CV**) y el segundo evalúa el desempeño en la discriminación de nuevos datos haciendo una validación inter-sesiones (**vIS**). En este segundo esquema los datos que se clasificaron fueron registrados con un lapso de entre 6 a 110 días de diferencia, que implicó analizar el comportamiento usando datos pasados (lo cual es habitual) o del futuro (usando para entrenamiento datos de sesiones posteriores). Con lo cual se pudo evaluar la estabilidad de los modelos de clasificación a través del tiempo.

Los registros de EEG fueron analizados usando una ventana deslizante de 2 segundos de duración, con un traslape del 70%; es decir, una ventana y su contigua comparten 1.4 segundos con lo que se obtuvo una salida (comando) de la BCI cada 600 ms. El acondicionamiento de las señales, así como los parámetros para la estimación de los índices fueron los mismos que se emplearon en el [análisis estadístico](#), pero la utilización de una ventana deslizante hace que ahora las épocas no estén sincronizadas con la presentación de los estímulos, concepto que pudo ser aprovechado para la construcción de una BCI asincrónica. Los índices conforman entonces una señal con muestras cada 600 ms y debido a la incertidumbre asociada con su estimación, estas señales se observaron contaminadas por ruido. Para atenuar este artefacto se utilizó un filtro Kalman simplificado (llamado *alpha-beta* que ha sido descrito en [92-94]), usando los mismos coeficientes para todos los sujetos ($\alpha=0.2$ and $\beta=0.01$,

Cálculo Mental

estos valores fueron seleccionados de manera empírica). Las épocas fueron etiquetadas dependiendo del tipo de bloque que las contiene. El bloque **Operar** contiene a las ventanas **Inicio** y **Operar** mientras que el bloque **Reposo** está formado por las ventanas de dicho tipo. Los periodos de **Atento** y **Respuesta** fueron descartados tanto para la construcción del modelo como para la evaluación del desempeño **vIS**. Debido a la distinta duración de los bloques, existe nuevamente una diferencia en la cantidad de datos de cada una de las clases. En cada conjunto el bloque **Operar** contiene de 17 a 26 épocas mientras que la longitud de **Reposo** es de 8 a 17 épocas. Para la clasificación de las épocas se utilizaron las estimaciones de α_{SE} y β_{PSD} en los 4 canales seleccionados del [análisis estadístico](#). Esto formó un vector característico de dimensión ocho ($[\beta_{PSD,canal1,t_n} \dots \beta_{PSD,canal4,t_n} \alpha_{SE,canal1,t_n} \dots \alpha_{SE,canal4,t_n}]$) que fue la entrada a una máquina de soporte vectorial (SVM), para cuya implementación se utilizó la biblioteca LIBSVM [\[95\]](#).

En la construcción del modelo de clasificación se siguieron los siguientes pasos:

1. Los índices fueron escalados en un rango (0 a 1) usando una transformación sigmoidea. Se tuvo ocho conjuntos de parámetros de transformación, cada uno asociado con cada elemento de entrada del clasificador.
2. Se optimizaron los hiperparámetros de la SVM de núcleo radial [\[96\]](#), mediante el proceso de **CV**. El *corpus* de épocas es dividido aleatoriamente en dos, 70 % son usadas para entrenar y el resto es usado para evaluar la clasificación [\[95, 97\]](#). Esta división es repetida 20 veces y por cada una de estas vías, el valor de AUC es medido en función del valor de probabilidad posterior (**SVMpp**). El conjunto óptimo de hiperparámetros es aquel que obtiene el mayor valor medio de AUC.

El proceso descrito fue hecho variando la conformación del vector de rasgos. Se evaluó la utilización de los índices por separado así como su combinación. Estos resultados se muestran en la sección siguiente. Con los hiperparámetros óptimos de la SVM, se construyó el modelo de clasificación usando la totalidad del conjunto de datos por sesión. Así, por cada sujeto se tuvo tres modelos correspondientes a cada una de las sesiones que fueron usados para clasificar los datos de las dos sesiones restantes. En total por cada sujeto se tienen 6 evaluaciones que conforman la **vIS**.

En la figura [3.3](#) se muestra el diagrama de flujo usado para el análisis de estos experimentos.

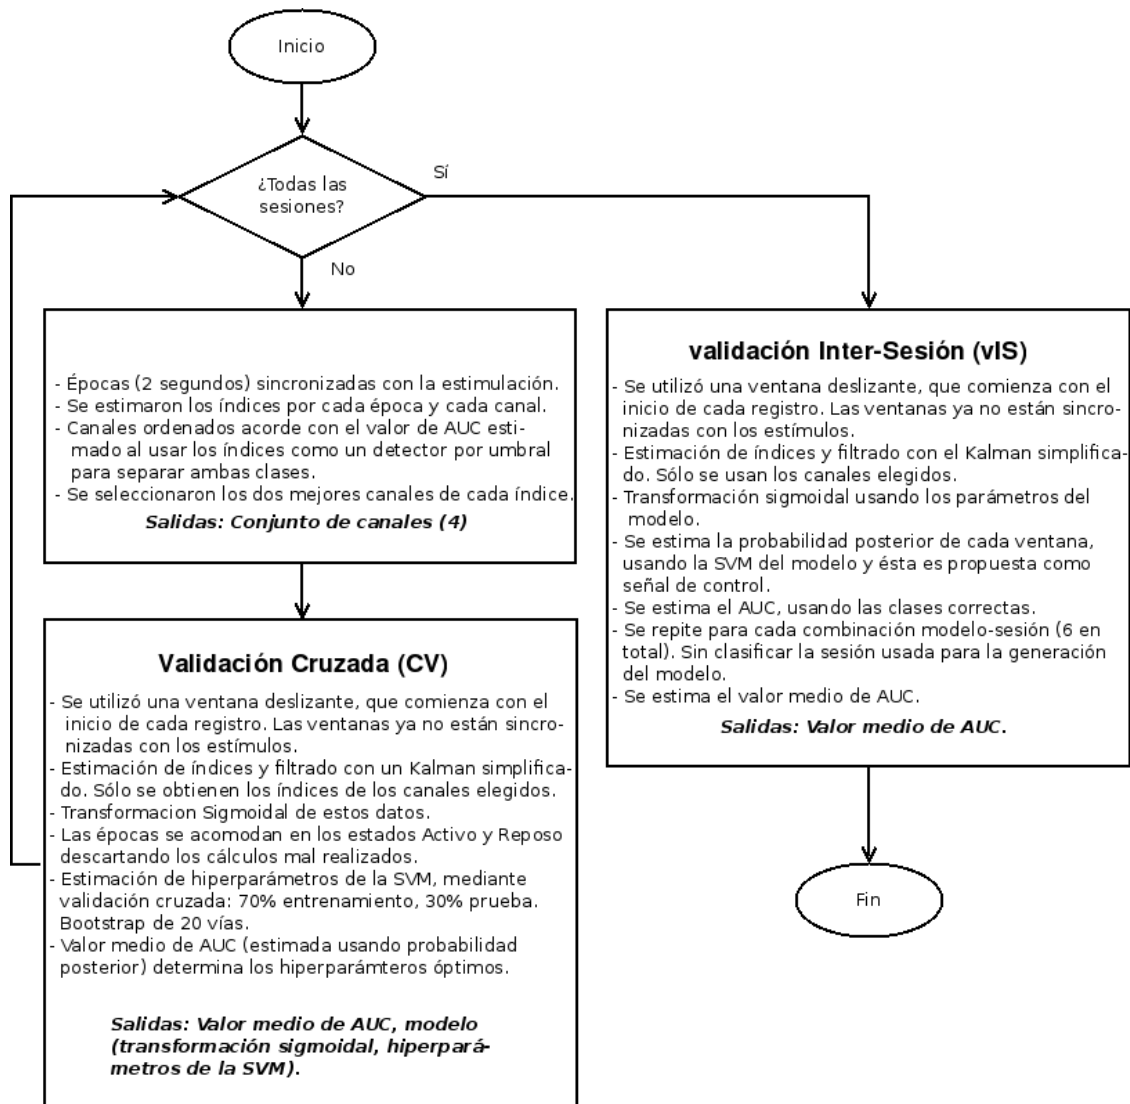


Figura 3.3: Diagrama de flujo del procedimiento seguido en esta sección.

3.4. Resultados

3.4.1. Descripción estadística

Los resultados de las pruebas para igualdad de medianas, al comparar los grupos *Operar* y *Reposo* pueden ser observados en las figuras: 3.4 para el índice β_{PSD} y 3.5 para α_{SE} . Los resultados se muestran en términos de la **PP** que obtuvo diferencias estadísticamente significativas entre ambas condiciones.

El índice β_{PSD} muestra diferencias significativas en las regiones occipital, parietal y central para más del 80 % de los sujetos para el análisis de la sesión S001 (figura 3.4a).¹ Tanto el porcentaje como la amplitud en la distribución disminuyen en las otras dos sesiones. En la sesión S002 (figura 3.4b) se destacan 3 canales: P3, PO4 y O1, que tienen un porcentaje superior al 80 % y una dispersión hacia la región central, con valores por debajo del 75 %. Para la última sesión, S003 (figura 3.4c), la distribución de **PP** muestra máximos en tres canales: PO3, Pz y F3, y la mayoría de los canales restantes alcanzan niveles por encima del 70 %. La dispersión de los valores **PP** para este índice parece distinta en las tres sesiones, a pesar de que los sujetos hicieron exactamente el mismo tipo de tarea en todos los experimentos.




Figura 3.4: Valores de Proporción de Población (**PP**), obtenidos para el índice β_{PSD} . Estos valores son la razón de sujetos que mostraron diferencias estadísticas $p < 0.05$ al comparar los estados *Operar* contra *Reposo*.

Al analizar los valores estimados de α_{SE} se observa un comportamiento distinto. En la sesión S001 (figura 3.5a); los valores de **PP** están por debajo de 65 % para todos los canales, con máximos en los canales C4, P4 y PO3; y una concentración de la dispersión alrededor de estos. Casi ningún canal frontal supera el 40 % de **PP**, y la región occipital logra valores cercanos al 60 %. Para la sesión siguiente

¹Aunque la figura muestra una posible superficie mayor en la región occipital, esta observación deberá hacerse con reservas ya que puede deberse a un artefacto asociado con la interpolación hecha para la generación de la figura.

(figura 3.5b), los porcentajes son más altos y muestran mayor participación de las regiones frontales y centrales, y una mayor simetría sagital. Para esta sesión los canales que destacan son Cz, Pz y P3. En la sesión S003 (figura 3.5c), los porcentajes tienen una distribución claramente distinta, la mayoría de los canales tienen valores por encima del 70 % con una concentración hacia las regiones parietal y occipital. En este caso, los resultados sugieren una tendencia parecida al aprendizaje de tareas. Ya que en las primeras sesiones las regiones con cambios significativos son de menor tamaño y menor valor, respecto a las posteriores.




Figura 3.5: Valores de Proporción de Población (**PP**), obtenidos para el índice α_{SE} . Estos valores son la razón de sujetos que mostraron diferencias estadísticas $p < 0.05$ al comparar los estados **Operar** contra **Reposo**.

La figura 3.6 muestra la frecuencia de cada canal para ser seleccionado como entrada de la **vIS**. Esta selección está basada en los valores de AUC estimados al usar cada índice para separar los grupos **Operar** y **Reposo**, mediante un umbral. Por cada índice se seleccionaron los dos canales con más altos valores de AUC, pero con la restricción de usar la máscara mencionada en [Análisis estadístico](#). Al igual que en las figuras anteriores los resultados se muestran por cada una de las sesiones experimentales. La selección de canales en las tres sesiones estuvo concentrada hacia la región parietal y el valor máximo de frecuencia o repetición obtenida fue para el canal Pz con casi 10 sujetos. Esto coincide con lo reportado por Dehaene *et al.* [82, 83] y Vuokko *et al.* [90] quienes señalan a la región parietal como aquella en la que reside la representación numérica y la aritmética. El resto de los canales de la máscara se repartieron la presencia de forma equitativa con pocos cambios entre las sesiones.

La figura 3.7 muestra los valores medios de β_{PSD} (en dB) y α_{SE} en el electrodo Pz en ambas tareas mentales. Las líneas que unen los puntos de ambos bloques sirven de guía para analizar los cambios asociados a la tarea. Los puntos en color rojo señalan aquellos sujetos para los cuales se halló una

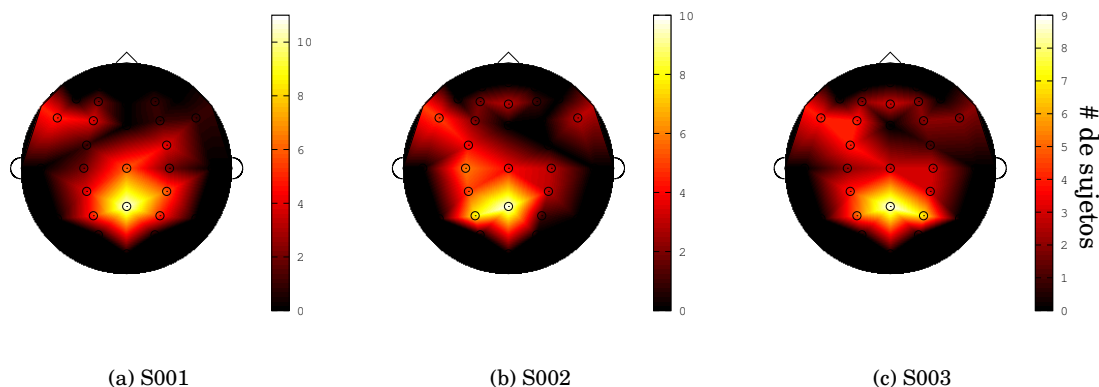


Figura 3.6: Histograma de frecuencias para la selección de cada canal en la conformación del conjunto de entrada de la etapa de clasificación de acuerdo con los valores de AUC (el valor máximo posible a obtener es 15). En cada gráfica se observa el comportamiento por sesión experimental.

diferencia significativa entre ambos estados ($p < 0.05$). En estas gráficas se observa que el valor de los índices tiene un comportamiento opuesto; mientras que el valor de β_{PSD} tiende a disminuir durante el cálculo mental, α_{SE} tiende a incrementar. Esto es consistente para todos aquellos sujetos que mostraron diferencias entre ambos estados, y también con los resultados obtenidos en el capítulo de [Ejecución de Movimiento](#).

3.4.2. Simulación BCI

3.4.2.1. Validación Cruzada (CV)

Una vez que fueron seleccionados, por cada sujeto, los canales que serán utilizados para estimar los rasgos de entrada del proceso de clasificación, se continuó con la fase de evaluación del paradigma haciendo uso de una ventana deslizante en los dos esquemas antes dichos, **CV** y **vIS**. En la figura 3.8 y cuadro 3.1 se muestran los valores medios de estos procesos. Se hicieron pruebas estadísticas t entre los resultados de la clasificación al usar las distintas combinaciones. Estas pruebas arrojaron lo siguiente:

1. La combinación $[\alpha_{SE} \beta_{PSD}]$ vs un único índice, obtiene un valor $p < 0.015$ en todas las sesiones.
2. La comparación α_{SE} vs β_{PSD} obtiene un valor $p < 0.015$ para la sesión S003.

Los valores de AUC son mayores cuando se utiliza la combinación de los índices, alcanzando niveles superiores a 0.87. En todas las sesiones, el valor medio de AUC obtenido para el índice α_{SE} (~ 0.8) es mayor que el de β_{PSD} (~ 0.76); pero, sólo en la sesión S003 se encontraron diferencias significativas

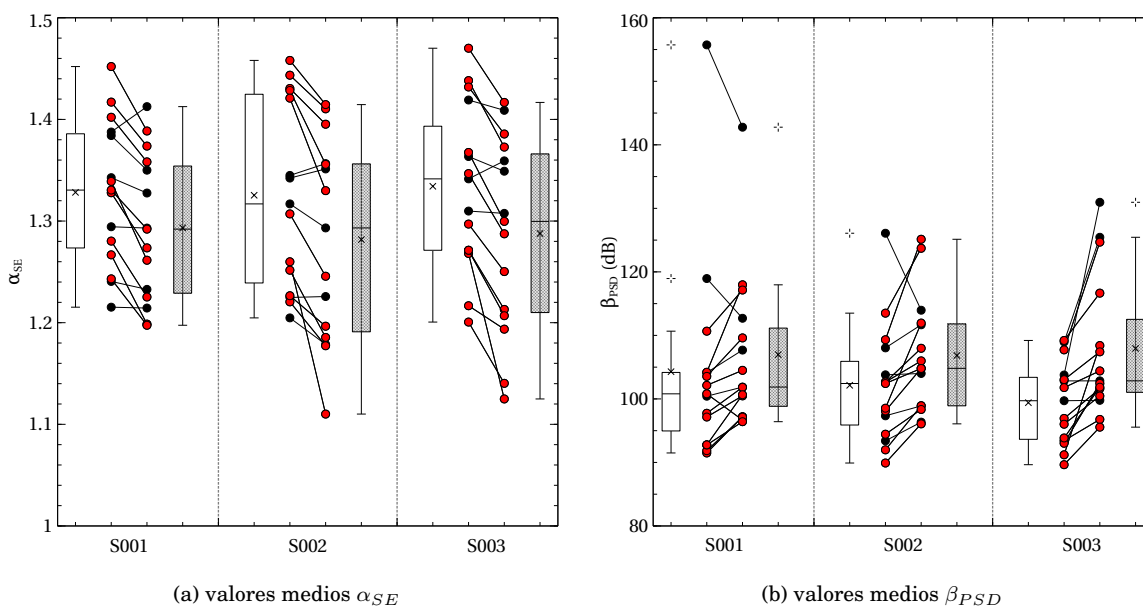


Figura 3.7: Valores medios de los índices α_{SE} y β_{PSD} , medidos en el canal Pz para ambas tareas, las cajas de dispersión blancas corresponden a la tarea **Operar** y las grises a **Reposo**. Debido a la gran varianza de los valores de potencia espectral, ésta se muestra en una escala de dB. Los puntos rojos muestran aquellos sujetos para los cuales $p < 0.05$, y las cruces corresponden a los valores atípicos en la distribución. Las líneas unen los valores de cada sujeto en cada una de los estados.

($p < 0.015$). Esto sugiere que α_{SE} tiene un mejor desempeño, desde una perspectiva poblacional, para identificar los grupos de este paradigma. Sin embargo, considerando los resultados obtenidos en el capítulo [Ejecución de Movimiento](#), este comportamiento parece depender de cada uno de los sujetos. La figura 3.9 muestra sujeto a sujeto los valores medios de AUC para las distintas combinaciones y sesiones. En todos los sujetos la combinación de los índices obtuvo los valores más altos. En la misma figura se aprecia que las marcas de α_{SE} y β_{PSD} cambian de orden para un mismo sujeto a lo largo de las sesiones. Este es un resultado nuevo con relación a las observaciones presentadas en el capítulo [Ejecución de Movimiento](#) que sugiere que la preferencia hacia cada uno de los índices cambia en función del tiempo de realización del experimento.

Se hicieron tres pruebas ANOVA, una por cada renglón del cuadro 3.1, en todos los casos se obtuvo $p > 0.05$. Lo cual sugiere que no hay un efecto significativo de aprendizaje, es decir, una mejoría en la clasificación en función del número de pruebas realizadas. Aunque en el cuadro y la figura se aprecia una reducción en la varianza de AUC.




Figura 3.8: Diagrama de cajas de los valores de AUC para la evaluación de **CV** y **vIS**.

Cuadro 3.1: Valores medios de AUC para la población ($N = 15$) estimados para la utilización de cada índice y su combinación. Se muestran también los valores medios de **vIS** para las tres sesiones.

combinación	Sesión		
	S001	S002	S003
$[\beta_{PSD} \alpha_{SE}]$	0.87 ± 0.067	0.89 ± 0.056	0.88 ± 0.040
β_{PSD}	0.75 ± 0.085	0.78 ± 0.073	0.75 ± 0.073
α_{SE}	0.77 ± 0.087	0.82 ± 0.057	0.81 ± 0.059
vIS	0.67 ± 0.111	0.62 ± 0.092	0.70 ± 0.095

3.4.2.2. Validación Inter Sesion (vIS)

La intención de utilizar un esquema de cálculo mental como el presentado en este capítulo obedece a la necesidad de tener un paradigma que permita al sujeto un manejo de la BCI con un control continuo, y cuya activación pueda ser completamente a voluntad del usuario. La evaluación **vIS** muestra el resultado de la detección continua de actividad, simulando lo que sucedería en un escenario en tiempo real. Del cuadro 3.1, se aprecia que los valores medios de AUC están por encima de 0.6 con un rango que va de 0.45 a 0.9 (ver figura 3.9). Al analizar el comportamiento del esquema **vIS** se observa que es muy variable incluso para un mismo sujeto. Esto mismo puede observarse en la figura 3.10 donde se aprecia que la varianza de la prueba cambia en función del sujeto, pero no se aprecia alguna relación respecto a su valor medio.

Mientras mejor sea el desempeño en la clasificación, más certera será la selección de comandos




Figura 3.9: Valores medios de AUC obtenidos para las distintas pruebas que se realizaron. Se muestran los valores individualizados por sujeto y sesión.

por parte del usuario. Se define que un sujeto es operador “competente” o bueno si en la elección de los comandos se supera el nivel del azar, el cual es estimado en función del número de comandos y épocas que se analicen [98]. Al usar las interfaces de **MI** se reporta la menor cantidad de sujetos en esta condición [11], por lo que resulta necesario evaluar el desempeño de los usuarios utilizando este tipo de interfaces. En la figura 3.10, se muestra el valor medio de AUC junto con su desviación estándar para el análisis **vIS** obtenido por cada sujeto, ordenados de menor a mayor. Estos valores tienen una distribución similar a los reportados para pruebas de **MI** [11]; nueve sujetos están por encima del umbral de “competencia” (i.e. 0.65 [98]). Pero a diferencia de los estudios hechos para ese paradigma, los datos de evaluación difieren de entre 6 a 110 días con los del entrenamiento. Lo que implica que la necesidad de calibrar al sistema podría postergarse por más tiempo.

Dado el propósito de un sistema BCI, es necesario que la señal de control cambie a voluntad del usuario. En las figuras 3.13, 3.11, 3.12 y 3.14 se muestran cuatro ejemplos del comportamiento de la señal **SVMpp** que aquí es propuesta entonces como un posible control de una BCI. Los bloques de color indican los periodos **Operar**, las barras rojas la aparición de las ventanas **Atento** y **Respuesta**. Los segmentos marcados con color verde muestran periodos **Operar** para los cuales el sujeto erró al realizar la serie de operaciones. En las cuatro gráficas se aprecia que la señal **SVMpp**, presenta oscilaciones que pueden asociarse con la presentación alternada de los periodos de actividad y reposo. Los cuatro

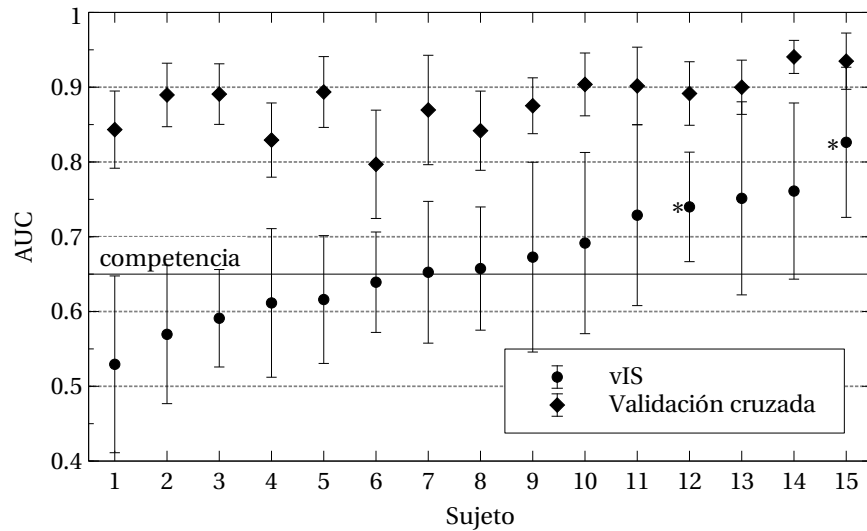


Figura 3.10: Valores de **vIS** ordenados de manera ascendente. El umbral de competencia que se marca es indicativo del mínimo requerido para considerarse un operador eficiente de una BCI [98].

sujetos mostrados, obtuvieron valores distintos de AUC, en función de los cuales se aprecia una mayor correlación entre las oscilaciones de **SVMpp** y la aparición de los bloques. Con el diseño del paradigma mostrado aquí, la salida ideal de **SVMpp** tendría la forma de una señal binaria, con la parte alta en los bloques azules y la baja en los periodos de reposo. El comportamiento que se muestra los sujetos # 10 (figura 3.13) y #3 (figura 3.14) es indicativo de un buen manejo de una interfaz ya que se asemeja a la señal ideal. En los otros dos sujetos es más difícil asociar este comportamiento con la secuencia de los bloques. Sin embargo, para el sujeto #11 (figura 3.11) los picos de señal parecen ocurrir en los bloques azules. Y para el sujeto #12 (figura 3.12), aunque la excursión de **SVMpp** es menor en comparación con el rango total (0 a 1) los cambios tienen una alta correlación con la ejecución del cálculo mental.




Figura 3.11: Ejemplo de cambios en el valor de **SVMpp** para el sujeto #11, AUC=0.61. Los bloques azules y verdes indican los periodos durante los cuales se realizó la tarea aritmética, para los primeros se dió una respuesta correcta mientras que para los segundos no lo fue. Las franjas rojas indican la presentación de las ventanas **Inicio** y **Respuesta**.




Figura 3.12: Ejemplo de cambios en el valor de **SVMpp** para el sujeto #12, $AUC=0.79$. Los bloques azules y verdes indican los periodos durante los cuales se realizó la tarea aritmética, para los primeros se dió una respuesta correcta mientras que para los segundos no lo fue. Las franjas rojas indican la presentación de las ventanas **Inicio** y **Respuesta**.




Figura 3.13: Ejemplo de cambios en el valor de **SVMpp** para el sujeto #10, $AUC=0.82$. Los bloques azules y verdes indican los periodos durante los cuales se realizó la tarea aritmética, para los primeros se dió una respuesta correcta mientras que para los segundos no lo fue. Las franjas rojas indican la presentación de las ventanas **Inicio** y **Respuesta**.

3.5. Discusión

Los valores medios de AUC obtenidos tanto para **CV** como **vis** muestran que es posible el uso del paradigma de cálculo mental, como esquema de control para una BCI. Era de esperarse que la identificación de los periodos **Operar** y **Reposo** fuera posible, dados los cambios en la dinámica del EEG que se llevan a cabo acorde con los resultados mostrados en distintos trabajos [81-83, 91, 99]. Además, tal y como se demostró en un artículo publicado recientemente [100], los sujetos que sufren de algún tipo de parálisis cerebral son usuarios potenciales de una BCI basada en paradigmas de este tipo. Otros trabajos han utilizado cálculo mental; sin embargo, una comparación directa con esos trabajos no puede hacerse debido a las diferencias en el paradigma experimental y los parámetros de medición del desempeño. Los trabajos previos obtienen valores de certeza, para la evaluación de la población de: 0.613 [78] y de 0.865 [79] con rechazo de épocas (0.532 sin rechazo); para la identificación en un escenario de cinco clases se obtuvo un valor ajustado a dos clases de 0.53 (0.526 sin ajuste) [77]; y 0.577




Figura 3.14: Ejemplo de cambios en el valor de **SVMpp** para el sujeto #3, AUC=0.90. Los bloques azules indican los periodos durante los cuales se realizó la tarea aritmética. Las franjas rojas indican la presentación de las ventanas **Inicio** y **Respuesta**.

para la identificación en un escenario de cuatro clases (0.61 sin ajuste) [36]. Todos estos resultados están más cerca del nivel del azar que los presentados en este trabajo, i.e. AUC=0.88. Esta mejoría puede ser producto de que el paradigma de cálculo aquí presentado involucra varios procesos mentales (memoria y realización de distintas operaciones con y sin acarreo), a diferencia de usar únicamente la resta consecutiva del número siete. La utilización combinada de características espectrales y de escalamiento también puede ser otra explicación a dicha mejoría. De esta manera, se confirman los resultados de Roberts *et al.* [80] y los presentados en el [Capítulo 2](#). No obstante, quedan pendientes la evaluación del paradigma cuando hay interferencia causada por la retroalimentación, el efecto de no usar estimulación ni guía para la realización de la prueba, así como evaluar otras posibles distracciones del usuario que entorpezcan el funcionamiento de la BCI.

Debido a la utilización de estímulos visuales para guiar al sujeto durante la realización de la tarea, éstos pueden generar potenciales provocados. Así, es probable que ésa sea la razón por la cual en las figuras 3.4 y 3.5 los canales occipitales muestran valores tan altos de **PP**. Aunque este efecto se atenúa al usar la máscara de canales, además de que el índice α_{SE} es un índice que se utiliza para señales que presentan no estacionaridades [30] y que el potencial provocado tiene poca energía en la banda de estudio [58, 101]. Sin embargo, es necesario hacer más experimentos que contemplen esta posible fuente de artefactos.

Cabe resaltar que la utilización de un exponente de escalamiento (α_{SE}), el cual está relacionado con la dinámica de la señal y sus correlaciones a distintas escalas de tiempo, mejora la detección de las tareas mentales. La combinación de los índices en todos los sujetos y en todas las sesiones obtuvo un mejor desempeño, esto se observa en las figuras 3.8 y 3.9. Las pruebas *t* realizadas obtuvieron valores de $p < 0.015$, esto puede ser resultado de evaluar tanto características espectrales y de escalamiento en la

identificación de los estados, situación que tiene correspondencia con el capítulo previo. La comparación de cuál índice resultó mejor para identificar los estados mentales, no muestra diferencias estadísticas para este paradigma, salvo en el caso de la sesión S003; no obstante, los valores medios de AUC obtenidos para α_{SE} en todas las sesiones son superiores a los de β_{PSD} . El estudio individualizado de estas comparaciones, corrobora que no en todos los casos esta tendencia se mantiene y además puede llegar a cambiar de sesión a sesión (ver figura 3.9). La evaluación **CV** y **vIS** muestran que un número aceptable de sujetos pueden considerarse como “competentes” al usar este paradigma de estimulación, aun cuando la calibración y la prueba del sistema se realizaron con varios días de diferencia. Esta situación no es realizable para las BCI basadas en **MI**, donde a pesar de que la calibración es realizada el mismo día de la prueba, se obtienen valores similares a los reportados en el cuadro 3.1 [11, 23, 102, 103]. Las diferencias en el desempeño obtenidas entre **CV** y **vIS** pueden ser resultado de cambios en el valor medio de β_{PSD} [23, 104], y esto también puede suceder con α_{SE} . Estos cambios influyen de dos maneras, modificando los parámetros de la transformación sigmoïdal, y cambiando la distribución de los datos en el nuevo espacio; ambas razones explican un cambio en las fronteras previamente aprendidas para cada clase. La confirmación de estas ideas requiere de una mayor experimentación. La obtención de $p > 0.05$ para las pruebas ANOVA realizadas comparando el resultado de la clasificación por sesiones, indica que no hay un efecto claro de aprendizaje asociado con la realización de la tarea. Esto puede tener dos consideraciones contrapuestas: 1) que los resultados obtenidos no pueden ser mejorados, ó 2) que un usuario podrá utilizar la BCI desde la primer sesión.

El esquema de procesamiento presentado en este capítulo no requiere de la búsqueda exhaustiva de la banda de frecuencia específica que mejor separe ambas clases, ni de la evaluación de todas las combinaciones posibles de canales, que son estrategias indispensables para el uso del paradigma de **MI** [105, 106]. Esta característica reduciría el tiempo de calibración sin sacrificar desempeño del sistema. La utilización de cálculo mental, brinda una ventaja adicional que es la capacidad de hacer una identificación correcta o etiquetado de las épocas; situación de vital importancia durante el proceso de calibración, ya que descarta la utilización de épocas de falsa realización de la tarea. Para el paradigma presentado aquí, parece ser indispensable la utilización de estímulos visuales; pero para situaciones reales, esta estimulación puede ser sustituida pidiendo al usuario completar series como: 3, 6, 9, 18, 21, 42,... Ya que para completar la serie mentalmente, el usuario requeriría no sólo la capacidad de sumar y multiplicar, sino que también deberá recordar para determinar qué operación sigue y con qué operandos se tiene que resolver la operación.

Los valores medios de los índices asociados con la realización de la tarea (ver figura 3.7), parecen mostrar que ocurre un fenómeno tipo ERD/ERS para este paradigma. Mientras que el valor de β_{PSD} disminuye durante la actividad mental [8, 9], el valor de α_{SE} aumenta [28]. Esto sugiere que las áreas corticales relacionadas con la ejecución de la tarea cambian a partir del estado desincronizado (irregular u “ocioso”), y que dicho cambio se refleja con variaciones en los valores de la potencia espectral y del exponente de escalamiento. Estos cambios son detectables en las señales de EEG y pueden asociarse con cada uno de los estados mentales. La **PSD** está relacionada con la energía de la señal y el **SE** con su estructura, por lo que en principio ambos índices ofrecen descripciones distintas de las series de tiempo (en coincidencia con los hallazgos del capítulo 2). Lo que aporta nuevamente indicios hacia el hecho de que la utilización en conjunto de ambos índices mejora la identificación del estado mental

3.6. Conclusión

Los valores medios de AUC obtenidos para **CV** y **vIS** sugieren que un paradigma de cálculo mental como el mostrado, puede ser utilizado para el control de un sistema BCI. Los valores medios de los índices (α_{SE} y β_{PSD}) estimados en el electrodo Pz (figura 3.7) son indicativos de que se está llevando a cabo un proceso ERD/ERS, similar a lo que se ha reportado en la **MI**. Incluso los valores de AUC alcanzados sugieren una mejoría respecto a lo reportado en el estado del arte para paradigmas de **MI**. De hecho, el valor de **vIS** muestra un desempeño aceptable aun cuando existen días de diferencia entre los datos de calibración y prueba, lo cual no parece posible de realizarse en una BCI basada en **MI**. Los resultados incluso muestran que no hay un efecto real asociado con la práctica del paradigma, lo que sugiere que incluso los sujetos primerizos pueden alcanzar buenos niveles de control desde la primer sesión de operación. A pesar de que los resultados mostrados apuntan a un mejor desempeño, es necesaria una evaluación en un ambiente más complejo aumentando los grados de libertad y por el efecto causado por la retroalimentación.

La utilización de características de los exponentes de escalamiento (α_{SE}) en conjunto con las características espectrales contribuyó a un mejoramiento en la detección del estado mental. La combinación de estos logró valores AUC mayores que los obtenidos al utilizar únicamente uno de los índices. Adicionalmente, la evaluación **CV** muestra que ningún sujeto cae en la condición de “no competentes” cuando se utilizan ambos índices como rasgos de entrada. Lo que confirma que la utilización combinada de estas características puede mejorar el desempeño de una BCI.

3.7. Síntesis y Puntos Relevantes

- La comparación entre los índices no mostró diferencias significativas, por lo que se puede asumir que el **SE** tiene la misma sensibilidad para discriminar cambios en la dinámica del EEG.
- Los valores medios de la potencia espectral y de **SE** indican que el cálculo mental genera un cambio en la dinámica del EEG, similar al utilizado para la **MI**.
- Se confirma que la combinación de los índices espectrales y de escalamiento mejora la identificación de cambios en la dinámica del EEG. En estos experimentos la combinación de índices tuvo diferencias estadísticamente significativas, respecto a la utilización de únicamente uno u otro tipo de índices.
- Los resultados **vIS** sugieren que es factible la utilización de modelos de clasificación, obtenidos en días previos, para inicializar una BCI basada en este paradigma.

Capítulo 4

Discusión y Conclusiones

4.1. Recapitulación

Las BCI de control continuo, y en especial asincrónico, son de particular interés ya que establecen un canal de comunicación más “natural”. La incorporación de otras características o rasgos de la señales de EEG al proceso de clasificación en conjunto con nuevos paradigmas puede mejorar el desempeño, así como permitir la utilización de una BCI en sujetos que no logran un control eficiente con las estrategias que se tienen hoy día [11, 13, 25, 36, 100]. En este trabajo se evaluó la utilización de un índice de escalamiento (α_{SE}) como rasgo para la detección de la ejecución de tareas mentales a partir del procesamiento de registros de EEG. Este tipo de índices están asociados con el estudio de sistemas dinámicos y evalúan propiedades que tienen relación con la estructura temporal de las señales, tales como las que presentan los sistemas críticamente auto-organizados [27, 37]. Se evaluaron los cambios de valor de la métrica propuesta en función de la realización de una tarea activa y otra de reposo. En un escenario de inclusión a una BCI de índices de este tipo, los cambios de valor pudieron ser detectados, y al estar asociados a la ejecución de una tarea mental, podrían traducirse en la orden de ejecución de un comando cumpliendo con la definición dada por Wolpaw *et al.* [1].

Además, se propuso y evaluó un nuevo paradigma para la tarea activa, el cual consiste en la ejecución continua de cálculos mentales. Durante el que se realizan cuatro operaciones básicas que involucra la utilización de memoria de corto plazo para su correcta ejecución. La ventaja de la utilización de un paradigma de este tipo es que se puede hacer un correcto etiquetado de los segmentos de EEG durante los cuales se estuvo ejecutando la tarea. Los resultados sugieren que una persona sin entrenamiento

Discusión y Conclusiones

podría ser capaz de operar una BCI con un nivel de desempeño superior al azar desde la primera vez.

En este trabajo se presentaron dos partes experimentales. En la primera, se analizaron los datos de una población de sujetos al realizar una prueba rutinaria de atención que consistió en presionar un botón ante la presencia de un estímulo visual ([Capítulo 2](#)); y para la segunda, se analizaron los datos de otra población al realizar la tarea mental de cálculo mental ([Capítulo 3](#)). Estas tareas fueron escogidas debido a la posibilidad de hacer un correcto etiquetado de su ejecución, a diferencia de los paradigmas de imaginación de movimiento para los que este etiquetado no es del todo fiable. Además de la evaluación del índice de escalamiento y la propuesta de un paradigma para la tarea activa se abarcan en la investigación otros temas, tales como:

- (a) El sentido del cambio en los valores medios de índices espectrales y de escalamiento en función de la ejecución de la tarea.
- (b) La distribución de canales con diferencias significativas, así como un método sencillo de selección de canales ajustable para cada usuario.
- (c) Las observaciones acerca de la identificación de los estados de actividad y reposo.
- (d) Y el relato de consideraciones finales incluyendo perspectivas de trabajo a futuro.

4.2. Sobre los cambios de valor de los índices (a)

El incorporar información nueva que permita una descripción más detallada de las señales de EEG estudiadas, puede resultar en un mejor desempeño para la identificación de la ejecución de la(s) tareas mentales. Así, mientras que la potencia espectral brinda información acerca de la energía de las señales, el índice de escalamiento da información acerca de su estructura en función a las escalas temporales [[37](#)]. Ambos índices muestran cambios en sus valores, asociados con la ejecución de tarea y reposo, similar a lo descrito durante los procesos ERD/ERS [[9](#)]. En los experimentos realizados, la potencia de la señal cambió de valor durante la ejecución de las tareas, hecho que ha sido explicado como una modificación en la sincronía de las redes neuronales encargadas del procesamiento de la información [[8](#)]. Los resultados coinciden con lo reportado por otros trabajos, mostrando una disminución de la potencia espectral durante la ejecución de la tarea activa que se acompaña de un aumento en el valor del índice de escalamiento (α_{SE}). En ambas tareas y en términos generales la relación entre los índices es la esperada, es decir, que mientras los valores de potencia aumentan, los del índice de escalamiento

4.2 Sobre los cambios de valor de los índices

disminuyen. De acuerdo con Pfurtscheller *et al.* [8] el procesamiento de información se ve reflejado como una disminución en el valor de la potencia, que consecuentemente debe implicar un aumento en el valor del exponente de escalamiento; tal como sucedió en ambas tareas. Un valor más alto de α_{SE} indica una mayor presencia de correlaciones de largo alcance asociado a un proceso de mayor “estructura” o regularidad, mientras que los valores del exponente cercanos a 0.5 refieren a una señal que tiene pocas correlaciones y es más parecida a la generada por un proceso de ruido blanco [29, 56, 107]. Los valores del índice podrían sugerir entonces que las redes cambian su dinámica, alterando sus interacciones debido a la existencia de correlaciones temporales [37, 56, 107]. Siendo así procesos que disminuyen su potencia en ciertas bandas espectrales pero presentando un comportamiento más correlacionado. Así, estas dos explicaciones concordarían con lo esperado para una tarea como la realización de la aritmética mental, que involucra un trabajo de memoria y procesamiento de información que en principio se relaciona con una mayor sincronía o regularidad que el reposo [108].

Un cambio en la dinámica o en la energía de la señal, supondría un ajuste en la otra característica de regularidad; sin embargo, es probable que la amplitud de dicho ajuste dependa del usuario y del estado mental actual. El cuadro 2.2 (actividad motora) muestra que en la identificación de los estados mentales con uno u otro índice se obtienen resultados distintos para algunos sujetos; y la figura 3.9 (cálculo mental) indica que esta preferencia potencial de índice no es consistente en todas las sesiones experimentales. Estos resultados sugieren que la realización de la tarea activa puede reflejar una afectación en la energía o en el índice de la dinámica de diferente manera, lo que podría explicar el mejor desempeño cuando ambos índices son utilizados. No obstante, el análisis de la tarea aritmética en la figura 3.7, muestra que en aquellos sujetos con diferencias estadísticamente significativas, el sentido del cambio de valor fue consistente para todos los casos; es decir, una disminución del valor de β_{PSD} y un aumento de α_{SE} asociado con la realización de la tarea activa. Los resultados presentados para la tarea motora no muestran este tipo de comportamiento de manera tan clara, al menos no en términos poblacionales. Ya que hubo sujetos con diferencias estadísticamente significativas que mostraron un comportamiento opuesto al relatado, es decir una disminución de la potencia espectral y aumento de índice de escalamiento para el reposo. Esto se vuelve interesante sobre todo al comparar los resultados con los presentados por Gao *et al.* [60] y de Jospin *et al.* [47], en ambos trabajos el índice DFA tiene un aumento de valor asociado con tareas que implican “reposo” como lo son los ojos cerrados y mayor profundidad anestésica. Sin embargo, en ambos trabajos la longitud de las series de tiempo es mayor a las analizadas en esta tesis. Lo que invita a pensar que el comportamiento de los **SE** cambia en

función de la escala de análisis, que podría implicar la existencia de distintos regímenes temporales de funcionamiento de diversos ensambles neuronales.

4.3. Sobre los canales de detección (b)

La variable **PP** expresa el porcentaje de sujetos en los que se detectaron cambios significativos para cada uno de los canales de EEG. Debido a la naturaleza de los experimentos se esperaba que las regiones de mayor actividad serían distintas para cada paradigma experimental. Con relación al primer experimento (actividad motora), los canales C3 y C4 han sido particularmente señalados como aquellos más sensibles a los cambios ya que están sobre la región motora [3, 8]. Mientras que para el segundo experimento, la región cortical ha sido identificada como la zona donde reside la representación numérica [82, 91, 99, 109, 110]. En esta investigación, los canales de las zonas mencionadas conformaron el pico de detección en ambos experimentos; pero existen diferencias en cuanto a la distribución de canales obtenida por cada índice que resulta conveniente discutir con detenimiento.

El análisis de la actividad motora que se resume en la figura 2.2 muestra que las regiones alrededor de los canales C3 y C4 alcanzan un valor de **PP** por encima del 50% tanto para α_{PSD} como para α_{SE} . Sin embargo, la distribución de **PP** usando α_{PSD} tiene una dispersión hacia las regiones centrales y occipitales más marcada que la observada con la utilización de α_{SE} . Este efecto es observado también para la tarea de cálculo mental; en la figura 3.4 se aprecia que la potencia espectral tiene niveles altos de **PP** en casi todos los canales, situación similar a lo presentado por Fernández *et al.* [81]. En cambio, la figura 3.5 muestra valores más bajos y un menor número de canales rebasan el 65%. Esta última figura muestra además que la distribución **PP** cambia dependiendo de la sesión experimental, lo cual en parte podría explicar la disminución del AUC para el análisis **vIS**, al no conservarse las regiones de mayor discriminación entre las clases. Para el caso de α_{SE} , la progresión en la distribución de los canales parece coincidir con un comportamiento de aprendizaje de la tarea dada la tendencia a incrementar el valor de **PP** alrededor de una misma zona. Esta misma idea sugieren los resultados del cuadro 3.1 al observarse aumento en el valor medio del AUC y una disminución en su varianza, ambos en correspondencia al número de sesión. Esta situación no se presenta para el índice espectral ya que el cuadro 3.1 así como la figura 3.4 no muestran una situación aparente de aprendizaje. Lo que sugiere que la potencia espectral es un índice más sensible a ser modificado por artefactos que ocurren de manera concurrente con la tarea y no tanto por la propia ejecución de ésta. Es necesario hacer más

experimentación, ya que se muestran indicios de que la existencia de diferencias estadísticas en los índices no necesariamente significa que esa región sea la dedicada a la realización de la tarea, sobre todo si se tienen en cuenta que el EEG es resultado de la integración de la actividad en varias regiones neuronales. Una comparación con una técnica de imagenología como la resonancia magnética funcional podría ser de gran utilidad para aclarar este punto.

En lo que respecta a la identificación de tareas, la figura 3.9 y el cuadro 2.2 muestran situaciones particulares. Para el cálculo mental, la combinación de índices logra un desempeño por encima de su utilización individual en todos los casos, mientras que para la ejecución de movimiento esto no sucede así. No obstante, cabe recordar que para el experimento de cálculo mental, los canales de análisis fueron escogidos *ad hoc*, en función del valor AUC obtenido por cada canal al ser usado como clasificador por umbral; mientras que para el experimento de ejecución de movimiento se usó un conjunto cerrado de canales. Esto refuerza la conveniencia del método de selección de canales propuesto, el cual tiene como base seleccionar aquellos canales para los cuales los datos pertenecientes a cada una de las clases son más separables por un umbral. Esto es similar a tener un agregado de puntos y separar los datos usando, para cada caso, un plano normal al eje de cada una de las características. De esta manera, al proyectarse los puntos en el hiperespacio que generarán las características seleccionadas, su distribución garantiza una tasa de clasificación mínima igual a la máxima tasa obtenida por los planos normales. En el [apéndice C](#) se muestra un ejemplo gráfico de esta idea. Se observan las ROC de la separación usando un método por umbral par ambos índices y cómo esta curva cambia en función de la utilización de una SVM que tiene como entrada esos mismos índices.

4.4. Sobre la identificación de las tareas (c)

El funcionamiento de una BCI no invasiva está basado en la posibilidad de detectar los cambios en el valor de índices que se derivan a partir de las señales del EEG. Estos cambios están asociados con la realización o conclusión, al libre albedrío del sujeto, de alguna tarea mental. El desempeño medido en los experimentos realizados es comparable con el obtenido para interfaces de imaginación de movimiento actuales, pero presenta algunas características adicionales deseables como:

- I. La consistencia en la clasificación a pesar del paso del tiempo.
- II. Un desempeño aceptable desde la primer evaluación de la tarea.

Discusión y Conclusiones

III. La utilización de las bandas clásicas de EEG, por lo que la búsqueda de bandas *ad hoc* para cada uno de los sujetos no sería necesaria.

La estabilidad del modelo de clasificación es parte importante para una BCI, ya que el proceso de calibración puede ser extenuante y causar fatiga incluso antes de la puesta en marcha del sistema. Los valores del análisis **vIS** mostrados para el experimento de cálculo mental muestran que inclusive con la utilización de modelos de clasificación, calculados con varios días de diferencia, se obtiene un desempeño en un rango que sobrepasa el umbral de competencia para cerca de la mitad de la población. Esto permitiría iniciar un sistema BCI con un modelo de clasificación adecuado, que podría ser modificado en tiempo real con información de la nueva sesión, para que la etapa de calibración pueda ser obviada [111-114]. El análisis **vIS** (ver figuras 3.9 y 3.10) muestra también la estabilidad de las características a lo largo del tiempo; ya que los modelos al ser construidos con los datos de cada una de las sesiones y probados con los de otras permiten evaluar esta característica. Así, los modelos creados con la primer sesión, se usaron únicamente para evaluar datos que sucedieron en el futuro (puntos negros); los modelos de la última para evaluar datos del pasado (puntos azules), y los modelos de la sesión intermedia para evaluar en ambos sentidos (puntos rojos). En la figura 3.9, no se aprecia una tendencia a que alguno de los modelos obtenga un desempeño por encima de los otros; lo cual refuerza la idea de cierta estabilidad al obtener desempeños similares. Sin embargo, la evaluación **vIS** es estadísticamente distinta a la validación cruzada (ver cuadro 3.1). Se ha mencionado que esta diferencia entre los valores de la validación cruzada y **vIS** puede deberse a cambios en los valores medios de las características que modifican el mapeo utilizado por el clasificador (transformación sigmoideal) y con ello, el espacio usado para la generación de las fronteras de clase. Esta situación sería intrínseca al método usado y no a los datos *per se*. Esto amerita el estudio de los mismos datos ya que al confirmarse esta idea se permitiría hacer ajustes al procesamiento para lograr los niveles de clasificación obtenidos para la validación cruzada. Otra posibilidad es que la distribución de los valores de los índices en los canales seleccionados para la construcción del modelo cambia en función de la sesión. Es decir que los canales seleccionados para el modelo, en la actual sesión no muestran un comportamiento similar, lo que dificulta la identificación de las tareas mentales. Esta idea la sugieren las figuras 3.4 y 3.5 donde se aprecia que a nivel poblacional las distribuciones de canales con diferencias significativas van cambiando en función de la sesión. Por lo que la incorporación de un método de selección automatizada y en línea de los canales también podría mejorar el desempeño de la BCI.

Por último, para la experimentación de cálculo mental, todos los sujetos conocieron y realizaron el paradigma por primera vez. Así, la evaluación del desempeño para una población que en su totalidad está constituida por “novatos” es el resultado del análisis de la sesión S001. Para esta sesión el desempeño obtenido tiene un nivel similar a las otras dos sesiones, tanto para **vIS** como para la validación cruzada en todas las combinaciones. Esto es indicativo de que una BCI basada en la utilización de un paradigma de cálculo mental puede ser usada eficientemente desde la primera ocasión, lo cual puede contribuir para disminuir la frustración que genera en los sujetos, y como consecuencia, su no utilización por no tener un control eficiente de estas tecnologías.

4.5. Perspectivas (d)

El trabajo doctoral presentado abre perspectivas sobre diferentes temas relacionados no sólo con el desarrollo de las BCI. Tal como se ha mencionado los resultados presentados por Gao *et al.* [60] y Jospin *et al.* [47], indican un incremento del exponente α_{SE} relacionado con tareas de reposo como es los ojos cerrados y la anestesia. Esto es contrario a lo que se mostró en esta tesis donde son las tareas de actividad las que tuvieron índices más elevados. Trabajos previos que utilizaron un **SE** como entrada de distintas BCI [42, 51, 68] no muestran estabilidad en cuanto a este aspecto se refiere, ya que el comportamiento de los índices cambia en función del sujeto. Sin embargo, esta discordancia da pie a pensar que la región de ajuste es un punto importante para la evaluación de la dinámica. Esta idea coincide con lo presentado por Hwa y Ferre [55], quienes describen que la relación entre los exponentes de escalamiento medidos en distintas escalas puede ser utilizada para la identificación de pacientes que han tenido un accidente cerebrovascular. Hardstone *et al.* [46] observaron que los pacientes con enfermedad de Alzheimer presentan una reducción del estimado de α_{SE} , que implica una menor presencia de correlaciones de largo plazo. Por lo que el estudio de la dinámica del EEG con índices de este tipo aporta nuevas herramientas para identificar las relaciones temporales subyacentes en la dinámica cerebral.

Tal y como se ha mostrado en esta tesis, la incorporación de los índices de escalamiento puede contribuir a mejorar el desempeño de las BCI. Los resultados apuntan a que su utilización puede ser aprovechada en interfaces como las de **MI**, ya que se basan en la identificación del cambio en la dinámica asociada con la ejecución de una tarea mental. Incluso las interfaces basadas en SSEP podrían incorporar medidas de este tipo, ya que la presencia de periodicidades, como las que se generan

Discusión y Conclusiones

con este paradigma, provocan deflexiones detectables en la gráfica log-log (ver figura 1.2) [41, 63]. El paradigma de cálculo mental, puede proporcionar un nuevo grado de libertad en interfaces actualmente desarrolladas. O bien podría ser considerado para la sustitución de tareas en interfaces que utilizan una sola tarea. La aplicación SSVEP-Dasher [115] es un buen ejemplo donde podría ser incluido el cálculo mental, sustituyendo a la identificación del potencial de estado estacionario. Otra aplicación similar es el Hex-O-Spell [116], donde el cálculo mental puede ser usado en vez de la **MI**. Incluso el cálculo mental puede ser usado como señal de activación para el “switch” o interruptor de una BCI; el sistema estaría en un estado de espera y la detección del cálculo mental podría cambiar esta condición ya que se asociaría a que el usuario está intentando establecer la comunicación.

4.6. Conclusiones

Los resultados mostrados en este trabajo corroboran que el índice de escalamiento (α_{SE}) es un descriptor propicio de la actividad neuronal que permite detectar la ejecución de una tarea mental [47, 51, 69, 70, 86, 117]; por lo que puede ser usado como rasgo de entrada de BCI. Las mediciones realizadas muestran que la utilización de α_{SE} , como rasgo de entrada de estos sistemas, tendrá un desempeño similar al de utilizar los rasgos del análisis tiempo-frecuencia clásicos. Pero los indicios experimentales sugieren también que este índice aporta información distinta a la obtenida por el análisis clásico [33], ya que con algunos sujetos la utilización de uno u otro índice produce un mejor desempeño en la identificación de tareas; mientras que su uso combinado supera a ambos, en términos poblacionales. Esto se observa en los dos experimentos analizados que involucraron diferentes tareas mentales y la utilización de dos bandas de potencia espectral. Mientras que para el experimento motor con la combinación de índices se obtuvo un mejor desempeño poblacional únicamente en términos estadísticos, para el experimento de cálculo mental la mejoría estuvo presente en todos los sujetos y en todos los modelos analizados. Ambos índices mostraron una distribución distinta de los canales con mejor respuesta para diferenciar ambas tareas. El índice de escalamiento muestra zonas con diferencias estadísticas entre las tareas de reposo y actividad más reducida que el análisis espectral. Inclusive para la tarea de cálculo mental este índice muestra una tendencia parecida al aprendizaje que no se observa para el análisis en frecuencia. Esto contribuye con la idea de que ambos índices muestran características distintas que pueden complementarse al lograr un mejor desempeño en la identificación de tareas, y sugieren que el índice de escalamiento puede llegar a ser de utilidad clínica para el análisis del EEG. Los resultados obtenidos en conjunto con los antecedentes de la literatura abonan a la idea de que los índices de escalamiento aportan información que debe ser estudiada usando diferentes modelos como la multifractalidad o los patrones de escalamiento.

Se mostró que la tarea mental propuesta para el control de la BCI basada en la ejecución de aritmética mental puede ser utilizada desde la primera vez aún para los sujetos primerizos con un desempeño por encima del umbral de competencia. Aunque falta medir el desempeño bajo condiciones normales de la operación de la BCI, los resultados muestran la factibilidad de su utilización dado el nivel de desempeño que aquí se reporta.

Apéndice A

Estimación del índice de escalamiento con ventanas de tiempo cortas

Con el fin de evaluar si el índice α_{SE} puede ser estimado en ventanas cortas de tiempo, para ser utilizado en un contexto de BCI, se hicieron pruebas de estimación de dicho índice usando ventanas que corresponderían a unos tiempos muy cortos de análisis a la frecuencia de muestreo convencionalmente empleada para la adquisición del EEG. Las señales sintéticas utilizadas para este análisis fueron tomadas de PhysioNet [39] (8 de septiembre del 2011), para las cuales se reporta el valor de su índice α_{SE} . En el cuadro A.1 se resumen los valores obtenidos y el tamaño de ventana empleado.

Cuadro A.1: Cuadro de estimación de índice α_{SE} en ventanas cortas, usando señales sintéticas con tres diferentes valores (1.5, 0.8 y 0.5). El índice α_{SE} fue estimado usando un tamaño mínimo de ventana de 3 y máximo de un cuarto del tamaño de la ventana (n). La estimación se realizó usando el algoritmo DFA de PhysioNet [39] (8 de septiembre del 2011)

n	α_{SE}		
	1.5	0.8	0.5
256	1.500 ± 0.091	0.798 ± 0.074	0.528 ± 0.060
512	1.497 ± 0.073	0.796 ± 0.059	0.518 ± 0.047
1024	1.496 ± 0.061	0.79 ± 0.048	0.511 ± 0.038
2048	1.499 ± 0.048	0.79 ± 0.038	0.508 ± 0.031
p	0.7377	0.2910	$< 10^{-14}$

Estimación del índice de escalamiento con ventanas de tiempo cortas

Las mediciones del cuadro A.1 fueron hechas con una compilación del código DFA descargado de PhysioNet [39] (8 de septiembre del 2011). Se hicieron pruebas ANOVA para comprobar que las medias de las estimaciones no resultaban diferentes al cambiar el tamaño de ventana. Del cuadro A.1 se aprecia que cuando el índice original de la serie es mayor o igual a 0.8 no se puede rechazar la hipótesis nula de igualdad de medias, pero no ocurre lo mismo cuando el valor del índice es 0.5. Este comportamiento indica que existe un sesgo en la medición de α_{SE} para señales con valores cercanos a 0.5, por lo que se tendría que tomar las precauciones necesarias al momento de hacer las mediciones de EEG. Aunque hay que resaltar que los valores estimados de α_{SE} para registros de EEG (capítulos 2 y 3), en todos los casos fueron mayores de 0.5. Las longitudes de ventanas usadas para este estudio corresponden a ventanas de medio, uno, dos y cuatro segundos a una frecuencia de muestreo de 512 Hz. Con ello se consideraría factible la construcción de un sistema en tiempo real y por las pruebas una estimación correcta de α_{SE} , por lo que el compromiso entre desempeño y tiempo de procesamiento sería resuelto.

Apéndice B

Máquinas de Soporte Vectorial *

Las Máquinas de Soporte Vectorial (Support Vector Machines, SVM) son métodos de aprendizaje maquina que estiman un hiperplano de separación entre dos conjuntos de datos, provenientes de clases distintas. Este puede ser visto como una frontera que determina la pertenencia de los puntos a alguna de las clases. En los casos de datos linealmente separables existen un infinito de hiperplanos que logran esta separación, tal como sucede en la figura B.1. Las SVM estiman aquel hiperplano que maximiza la distancia entre los puntos o vectores más próximos entre dos clases. Estos puntos son conocidos como los vectores soporte y es a partir de ellos que se estima la orientación del hiperplano.




Figura B.1: Ejemplo de dos conjuntos de puntos linealmente separables. En la gráfica se marca los puntos más cercanos al hiperplano de separación, que constituyen el conjunto de vectores soporte. El hiperplano H_1 aunque separa los datos no maximiza el margen, mientras que H_2 sí lo hace.

*La notación y desarrollo matemático de este apéndice fueron adaptadas de [97]

Máquinas de Soporte Vectorial

La idea principal parte de la construcción de un modelo lineal de la forma:

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b \quad (\text{B.1})$$

en donde \mathbf{x} es el vector de rasgos de entrada; la función vectorial $\phi(\cdot)$ describe una transformación de las características de entrada y b es un sesgo de entrada. De tal forma que para el caso de dos clases, la función signo determina la pertenencia a una de las clases

$$t(\mathbf{x}) = \begin{cases} -1, & \text{si } y(\mathbf{x}) < 0 \\ +1, & \text{otro caso} \end{cases} \quad (\text{B.2})$$

A partir de las ecuaciones B.1 y B.2, la distancia perpendicular de cualquier punto \mathbf{x}_n al plano de separación (\mathbf{w}) está definida por:

$$\frac{t_n y_n(\mathbf{x}_n)}{\|\mathbf{w}\|} = \frac{t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)}{\|\mathbf{w}\|} \quad (\text{B.3})$$

Con esto se puede definir el margen del clasificador como la distancia del plano al punto más cercano \mathbf{x}_n . Por lo que el problema consiste ahora en optimizar los valores de \mathbf{w} y b , para maximizar la distancia de los puntos al plano, esto se logra resolviendo:

$$\arg \max_{\mathbf{w}, b} \left\{ \frac{1}{\|\mathbf{w}\|} \min_n [t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)] \right\} \quad (\text{B.4})$$

Para obtener los valores de \mathbf{w} y b , se sigue un algoritmo iterativo que involucra la utilización de multiplicadores de Lagrange, la definición completa del procedimiento puede ser encontrada en [97, 118].

La función $\phi(\mathbf{x})$, puede ser sustituida por otra que permita la separación de conjuntos de datos. Esta función recibe también el nombre de *kernel* o núcleo. Cuyo requisito consiste en que corresponda a un producto punto en el nuevo espacio de características. Por ejemplo, si se considera que se propone como *kernel* a la función dada por:

$$k(\mathbf{x}, \mathbf{z}) = (\mathbf{x}^T \mathbf{z})^2 \quad (\text{B.5})$$

en donde \mathbf{x} y \mathbf{z} son dos vectores cualesquiera de las mismas dimensiones. Al hacer la expansión de los términos y considerando que los vectores de entrada están definidos en un espacio bidimensional del

tipo $\mathbf{x} = (x_1, x_2)$, la función *kernel* puede expandirse como

$$\begin{aligned} k(\mathbf{x}, \mathbf{z}) &= (\mathbf{x}^T \mathbf{z})^2 = (x_1 z_1 + x_2 z_2)^2 \\ &= x_1^2 z_1^2 + 2x_1 z_1 x_2 z_2 + x_2^2 z_2^2 \end{aligned}$$

Esta última función puede ser expresada en término del producto interno entre dos vectores formados por $\phi(\mathbf{x}) = (x_1^2, \sqrt{2}x_1 x_2, x_2^2)$, tal que:

$$\begin{aligned} k(\mathbf{x}, \mathbf{z}) &= (x_1^2, \sqrt{2}x_1 x_2, x_2^2)(z_1^2, \sqrt{2}z_1 z_2, z_2^2)^T \\ &= x_1^2 z_1^2 + 2x_1 z_1 x_2 z_2 + x_2^2 z_2^2 \\ &= \phi(\mathbf{x})^T \phi(\mathbf{z}) \end{aligned} \tag{B.6}$$

Así la función $\phi(\mathbf{x})$ permite mapear los datos en un espacio que ahora tiene 3 dimensiones; y en ese nuevo espacio los datos pueden ser separados por un hiperplano. Por lo que en conjunto con la utilización del kernel, se pueden separar datos que en las dimensiones originales no son linealmente separables (ver figura B.2). Uno de los núcleos más utilizados es el llamado *kernel* Gaussiano, que se define como:

$$k(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|\mathbf{x} - \mathbf{y}\|^2) \tag{B.7}$$

Las SVM son métodos de clasificación que construyen un modelo a partir de un conjunto de datos, de los cuales se conoce *a priori* su clase. Por lo que es necesario hacer una fase de entrenamiento o de construcción del modelo y luego probar el desempeño ante datos no vistos. Tanto los puntos o vectores soporte, así como los valores de los multiplicadores de Lagrange que maximizan la distancia al hiperplano conforman el modelo de clasificación. Al incorporar estos elementos a la regla de decisión, esta queda expresada como:

$$y(\mathbf{x}) = \sum_{n=1}^N a_n t_n k(\mathbf{x}, \mathbf{x}_n) + b \tag{B.8}$$

Cada *kernel* tiene sus parámetros internos, como es el caso del término $\sqrt{2}$ que aparece en la segunda entrada en la ecuación B.6 o el valor de γ de la ecuación B.7. Estas variables en conjunto con el valor

Máquinas de Soporte Vectorial

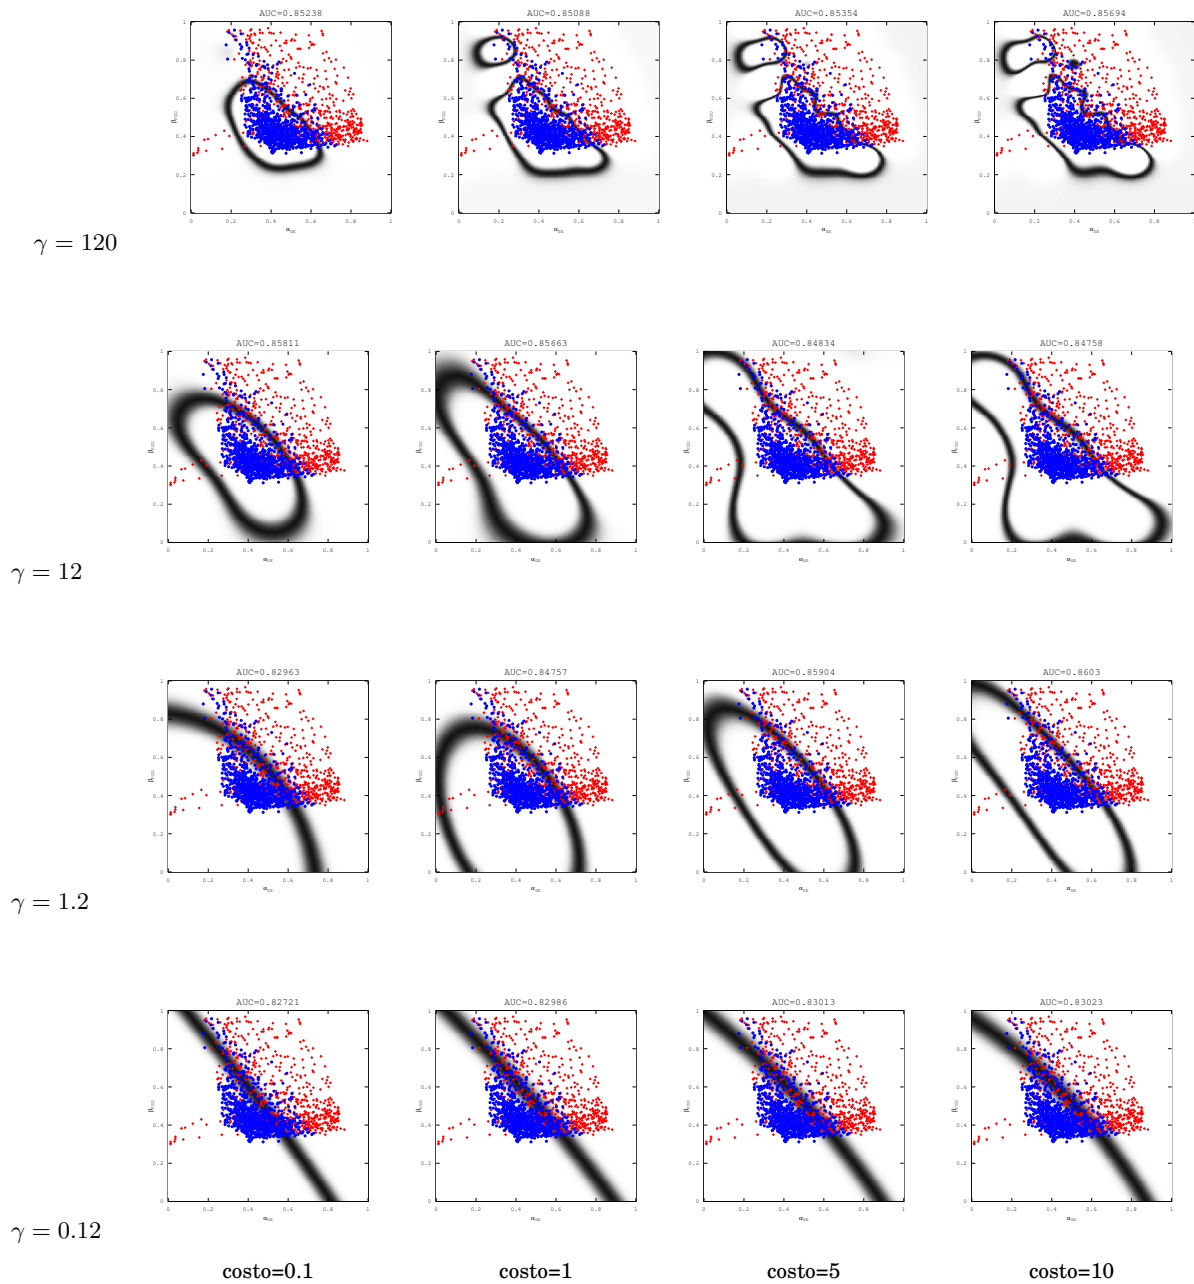


Figura B.2: Efecto de los cambios en los hiperparámetros utilizando un *kernel* gaussiano como el descrito en la ecuación B.7. En este ejemplo se usaron las estimaciones de α_{SE} y β_{PSD} para un sujeto. Los valores de los índices están escalados para ajustarse en el rango de 0 a 1. Los puntos rojos están asociados con la ejecución de la tarea *activa* y los azules con *reposo*.

de b , conforman los *hiperparámetros* del clasificador. Cambios en estas variables afectan la frontera de decisión y esto afecta el desempeño del clasificador, por lo tanto es necesario hacer un proceso de optimización para encontrar el conjunto que logre el mejor desempeño. La metodología que se sigue para hacerlo consiste en hacer una serie de pruebas dividiendo el conjunto de datos en dos, uno para construir los modelos y el otro para probarlo, de tal forma que se van variando los hiperparámetros hasta encontrar el valor óptimo de desempeño. Por cada uno de los valores de los hiperparámetros se realizan distintas evaluaciones seleccionando de forma aleatoria, los datos que serán usados para entrenar y validar el modelo de clasificación. Cada una de estas particiones se les denomina *vía*, y la estimación del desempeño del clasificador se obtiene al promediar la salida de cada una de estas vías. Por ello es que se recomienda hacer una prueba estadística con el fin de encontrar si las variaciones de los hiperparámetros realmente lograron una diferencia en el desempeño del clasificador.

En este trabajo los datos de entrada del clasificador \mathbf{x} estuvieron formados por los valores de los índices α_{PSD} , β_{PSD} y α_{SE} , obtenidos de los distintos canales. Por ejemplo para el caso del [capítulo 2](#) uno de los vectores de entrada evaluados estuvo formado por:

$$\mathbf{x} = \begin{bmatrix} \alpha_{PSD,C3} \\ \alpha_{PSD,P3} \\ \alpha_{PSD,C4} \\ \alpha_{PSD,P4} \\ \alpha_{PSD,T3} \\ \alpha_{SE,C3} \\ \alpha_{SE,P3} \\ \alpha_{SE,C4} \\ \alpha_{SE,P4} \\ \alpha_{SE,T3} \end{bmatrix} \quad (\text{B.9})$$

en el que $\alpha_{PSD,C3}$ corresponde a la potencia espectral en la banda alfa (8 a 14) Hz estimada en el canal C3. En las distintas evaluaciones que se hicieron para ambos experimentos, estos vectores de entrada cambiaron en función de la combinación a evaluar o de los canales seleccionados. Todos los clasificadores que se construyeron en este trabajo usaron como función *kernel* la expresada por la ecuación [B.7](#), esto dado que ha demostrado ser útil en la identificación de las épocas de EEG en particular en el contexto de las BCI [\[96\]](#).

Apéndice C

Área Bajo la Curva de operación ROC (AUC)

El desempeño de un clasificador se mide con términos que reflejen la correcta asignación de la clase a un conjunto de datos. El índice clásico de evaluación es la *certeza* que es el porcentaje de datos que fueron clasificados correctamente. Sin embargo, este resultado algunas veces puede ser engañoso, ya que está sesgado por la prevalencia de las clases. Principalmente en el campo médico se han usado diferentes índices para medir el desempeño de los clasificadores, uno de los más socorridos es la llamada área bajo la curva Característica Operativa del Receptor (ROC, *Receiver Operating Characteristic*) que se conoce como AUC [119].

Cuando se cuenta con un clasificador de sólo 2 clases (+ y -), se puede generar una matriz como la que se muestra en el cuadro C.1 en la que se resumen los errores y aciertos que son posibles.

Cuadro C.1: Matriz de confusión para un clasificador cualquiera

		Clase verdadera	
		+	-
Clase asignada	+	TP	FP
	-	FN	TN

Donde:

- TP: Verdadero positivo (un positivo clasificado correctamente)
- TN: Verdadero negativo (un negativo clasificado correctamente)

Área Bajo la Curva de operación ROC (AUC)

- FN: Falso negativo (un positivo mal clasificado)
- FP: Falso positivo (un negativo mal clasificado)

Tanto TP y TN son aciertos o datos clasificados correctamente, mientras que FN y FP son datos mal clasificados.

$$TPR = \frac{TP}{P} = \frac{TP}{TP + FN} \quad (C.1)$$

$$FPR = \frac{FP}{N} = \frac{FP}{FP + TN} \quad (C.2)$$

Con estos índices se puede generar una gráfica que tenga en el eje x a FPR y en el eje y a TPR. En esta gráfica el punto ubicado en $(0, 1)$ es el resultado del clasificador ideal; ya que este punto indica que todos los positivos fueron clasificados correctamente y que ningún negativo fue tomado como positivo. La recta que va desde $(0, 0)$ a $(1, 1)$, es conocida como *Línea del azar* y cualquier punto que se ubique en esta línea indica que simplemente el clasificador asigna la clase de manera aleatoria. Si la pertenencia a una clase está dada por el valor de algún parámetro y la clase $t_n(x) \in \{+1, -1\}$ se asigna como:

$$t_n(x) = \begin{cases} +1 & \text{si } x \geq \lambda \\ -1 & \text{otro caso} \end{cases} \quad (C.3)$$

El valor de λ define el umbral de decisión y al cambiarlo de posición afectará el valor de la certeza. Si el valor de λ se va moviendo, las entradas de la matriz de confusión cambiarán modificando los valores de FPR y TPR. Al colocarse en un gráfico estos valores, generan una curva ROC como las que se muestran en la figura C.2. En el caso del presente trabajo, la selección de canales se realizó haciendo una exploración en el valor del índice similar a la que se ejemplifica en la figura C.1. En el caso de las SVM, el AUC se estima haciendo un análisis de la probabilidad posterior, o sea este estimado es una variable tipo λ .

Para calcular el AUC se pueden utilizar desde métodos geométricos, o incluso métodos que hacen una estimación del área, sin importar la forma de la curva. Dentro de los primeros están métodos como el trapezoidal, medir el área del polígono formado por algunos puntos; y dentro de los segundos están Wilcoxon, Kernel, Maxima verosimilitud, etc. Para los primeros es necesario estimar la forma de la

curva, mientras que para los segundo el valor de la área ROC se obtiene de manera directa [119].




Figura C.1: Ejemplos de la asignación de clases usando el valor de las variables β_{PSD} y α_{SE} como umbral. El AUC de cada variable se estima al cambiar el umbral de posición. Los datos son los mismos de la figura B.2, el umbral se pinta como si fuera una frontera de probabilidad posterior para ilustrar la similitud con el hiperplano de decisión de las SVM.

Área Bajo la Curva de operación ROC (AUC)




Figura C.2: Ejemplos de curvas ROC generadas a partir de la utilización de los índices β_{PSD} , α_{SE} y la probabilidad posterior de tres SVM cuyos hiperparámetros se muestran en la leyenda. Las 5 curvas fueron construidas con el mismo conjunto de datos, que se muestran en las figuras C.1 y B.2. Al costado de la figura se muestran los valores de AUC estimados con la regla del trapecio. Estas estimaciones muestran que la mejor separación de datos se logra con la SVM de hiperparámetros $\gamma = 120$ y $costo = 1$.

Índice de figuras

1.1. Esquema de relaciones de una interfaz cerebro computadora	13
1.2. Ejemplo de cambios en los valores de la fluctuación cuadrática media (F) en función del tamaño de la escala de observación (s), para una señal sintética tomada de [39] con un exponente $\epsilon = 0.8$	20
1.3. Pasos para la estimación del exponente de escalamiento, mediante el uso del método de Fluctuaciones sin Tendencia. Se muestra un ejemplo de una señal de EEG adquirida en el canal Cz de un sujeto en reposo (paso A). Posteriormente se estima una nueva serie mediante la acumulación descrita por la ecuación 1.5 (paso B). Esta nueva serie es dividida en ventanas o segmentos a los cuales se les elimina su tendencia y se construyen nuevas series. Para las distintas longitudes o escalas se estima el valor medio de las fluctuaciones con la ecuación 1.6 (paso C). Finalmente, se consideran en una escala logarítmica los distintos tamaños de ventana contra los valores medios de fluctuación y se estima el coeficiente α_{SE} , que es el valor de la pendiente en una regresión lineal de esta gráfica. Este índice α_{SE} correspondería a un exponente del tipo ϵ que se muestra en la ecuación 1.3.	23
2.1. Montaje de electrodos para los registros en el INR.	30
2.2. Distribución sobre los canales de la proporción de la población (PP), que mostró diferencias estadísticamente significativas $p < 0.05$ entre las condiciones $C1$ (pasiva) y $C2$ (activa). Se muestra por separado el resultado asociado a cada uno de los índices	33
2.3. Valor medio por canal de los valores de AUC para todos los sujetos. Se muestra por separado el resultado de cada uno de los índices.	33
2.4. Valores de las medianas para cada sujeto bajo las condiciones: activa ($C2$, caja blanca) y pasiva ($C1$, caja gris). Estos valores fueron estimados para el canal C3, que es donde se aprecia el mayor valor de PP . En rojo están marcados los sujetos para los cuales se hallaron diferencias estadísticamente significativas ($p < 0.05$) y las cruces corresponden a los puntos atípicos en la distribución. Las líneas sirven de ayuda para evaluar el sentido del cambio en función de la tarea.	34
2.5. Valores del coeficiente de correlación para cada canal, y combinación de índices. La correlación entre los índices de potencia espectral fueron calculados sobre el logaritmo de sus valores.	35
2.6. Gráficas de cajas para el valor de AUC (a) y certeza (b), estimadas para las siete combinaciones de índices. Usando los canales C3, C4, T3, T4 y P3.	37
3.1. Montaje de canales usados para las pruebas de cálculo mental.	45
3.2. Ejemplo de una conjunto de operaciones usado para el paradigma de cálculo mental.	47

ÍNDICE DE FIGURAS

3.3. Diagrama de flujo del procedimiento seguido en esta sección.	51
3.4. Valores de Proporción de Población (PP), obtenidos para el índice β_{PSD} . Estos valores son la razón de sujetos que mostraron diferencias estadísticas $p < 0.05$ al comparar los estados Operar contra Reposo	52
3.5. Valores de Proporción de Población (PP), obtenidos para el índice α_{SE} . Estos valores son la razón de sujetos que mostraron diferencias estadísticas $p < 0.05$ al comparar los estados Operar contra Reposo	53
3.6. Histograma de frecuencias para la selección de cada canal en la conformación del conjunto de entrada de la etapa de clasificación de acuerdo con los valores de AUC (el valor máximo posible a obtener es 15). En cada gráfica se observa el comportamiento por sesión experimental.	54
3.7. Valores medios de los índices α_{SE} y β_{PSD} , medidos en el canal Pz para ambas tareas, las cajas de dispersión blancas corresponden a la tarea Operar y las grises a Reposo . Debido a la gran varianza de los valores de potencia espectral, ésta se muestra en una escala de dB. Los puntos rojos muestran aquellos sujetos para los cuales $p < 0.05$, y las cruces corresponden a los valores atípicos en la distribución. Las líneas unen los valores de cada sujeto en cada una de los estados.	55
3.8. Diagrama de cajas de los valores de AUC para la evaluación de CV y vIS	56
3.9. Valores medios de AUC obtenidos para las distintas pruebas que se realizaron. Se muestran los valores individualizados por sujeto y sesión.	57
3.10. Valores de vIS ordenados de manera ascendente. El umbral de competencia que se marca es indicativo del mínimo requerido para considerarse un operador eficiente de una BCI [98].	58
3.11. Ejemplo de cambios en el valor de SVMpp para el sujeto #11, AUC=0.61. Los bloques azules y verdes indican los periodos durante los cuales se realizó la tarea aritmética, para los primeros se dió una respuesta correcta mientras que para los segundos no lo fue. Las franjas rojas indican la presentación de las ventanas Inicio y Respuesta	58
3.12. Ejemplo de cambios en el valor de SVMpp para el sujeto #12, AUC=0.79. Los bloques azules y verdes indican los periodos durante los cuales se realizó la tarea aritmética, para los primeros se dió una respuesta correcta mientras que para los segundos no lo fue. Las franjas rojas indican la presentación de las ventanas Inicio y Respuesta	59
3.13. Ejemplo de cambios en el valor de SVMpp para el sujeto #10, AUC=0.82. Los bloques azules y verdes indican los periodos durante los cuales se realizó la tarea aritmética, para los primeros se dió una respuesta correcta mientras que para los segundos no lo fue. Las franjas rojas indican la presentación de las ventanas Inicio y Respuesta	59
3.14. Ejemplo de cambios en el valor de SVMpp para el sujeto #3, AUC=0.90. Los bloques azules indican los periodos durante los cuales se realizó la tarea aritmética. Las franjas rojas indican la presentación de las ventanas Inicio y Respuesta	60
B.1. Ejemplo de dos conjuntos de puntos linealmente separables. En la gráfica se marca los puntos más cercanos al hiperplano de separación, que constituyen el conjunto de vectores soporte. El hiperplano H_1 aunque separa los datos no maximiza el margen, mientras que H_2 sí lo hace.	77
B.2. Efecto de los cambios en los hiperparámetros utilizando un <i>kernel</i> gaussiano como el descrito en la ecuación B.7. En este ejemplo se usaron las estimaciones de α_{SE} y β_{PSD} para un sujeto. Los valores de los índices están escalados para ajustarse en el rango de 0 a 1. Los puntos rojos están asociados con la ejecución de la tarea <i>activa</i> y los azules con <i>reposo</i>	80

C.1. Ejemplos de la asignación de clases usando el valor de las variables β_{PSD} y α_{SE} como umbral. El AUC de cada variable se estima al cambiar el umbral de posición. Los datos son los mismos de la figura B.2, el umbral se pinta como si fuera una frontera de probabilidad posterior para ilustrar la similitud con el hiperplano de decisión de las SVM.	85
C.2. Ejemplos de curvas ROC generadas a partir de la utilización de los índices β_{PSD} , α_{SE} y la probabilidad posterior de tres SVM cuyos hiperparámetros se muestran en la leyenda. Las 5 curvas fueron construidas con el mismo conjunto de datos, que se muestran en las figuras C.1 y B.2. Al costado de la figura se muestran los valores de AUC estimados con la regla del trapecio. Estas estimaciones muestran que la mejor separación de datos se logra con la SVM de hiperparámetros $\gamma = 120$ y $costo = 1$	86

ÍNDICE DE FIGURAS

Índice de cuadros

2.1. Comparativo del desempeño en la clasificación al utilizar las distintas combinaciones de índices. Las entradas marcadas con “1” indican que la comparación (renglón - columna) obtuvo un valor $p < 0.008$. El cuadro está dividido en dos secciones: la triangular superior para la comparación de los valores de AUC y la inferior para los de certeza.	38
2.2. Valores de proporción de población que obtuvieron valor de $p < 0.004$ para las pruebas de una sola cola en las pruebas de Wilcoxon, con hipótesis alterna $A\hat{U}C_{index\ fila} > A\hat{U}C_{index\ columna}$. La lectura de renglones indica la proporción de población para la cual la combinación seleccionada mejora la <i>Identificación de Actividad</i> .	38
3.1. Valores medios de AUC para la población ($N = 15$) estimados para la utilización de cada índice y su combinación. Se muestran también los valores medios de vis para las tres sesiones.	56
A.1. Cuadro de estimación de índice α_{SE} en ventanas cortas, usando señales sintéticas con tres diferentes valores (1.5, 0.8 y 0.5). El índice α_{SE} fue estimado usando un tamaño mínimo de ventana de 3 y máximo de un cuarto del tamaño de la ventana (n). La estimación se realizó usando el algoritmo DFA de PhysioNet [39] (8 de septiembre del 2011)	75
C.1. Matriz de confusión para un clasificador cualquiera	83

ÍNDICE DE CUADROS

Bibliografía

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller y T. Vaughan. “Brain-computer interfaces for communication and control”. *Clinical Neurophysiology* 113 (2002), págs. 767-791.
- [2] J. J. Vidal. “Toward Direct Brain-Computer Communication”. *Annual Review of Biophysics and Bioengineering* 2 (1973), págs. 157-180.
- [3] D. Regan. *Human Brain Electrophysiology evoked potentials and evoked magnetic fields in science and medicine*. Ed. por N. R. Galloway. Elsevier, 1989, pág. 195.
- [4] S. G. Mason y G. E. Birch. “A General Framework for Brain-Computer Interface Design”. *IEEE Transaction on Neural Systems and Rehabilitation Engineering II* (2003), págs. 70-85. DOI: [10.1109/TNSRE.2003.810426](https://doi.org/10.1109/TNSRE.2003.810426).
- [5] L. Farwell y E. Donchin. “Talking off the top of your head - toward a mental prosthesis utilizing event-related brain potentials”. *Electroencephalography and Clinical Neurophysiology* 70 (1988), págs. 510-523.
- [6] G. Muller-Putz y G. Pfurtscheller. “Control of an Electrical Prosthesis With an SSVEP-Based BCI”. *IEEE Transactions on Biomedical Engineering* 55 (1 2008), págs. 361-364.
- [7] G. Müller-Putz, R. Scherer, C. Neuper y G. Pfurtscheller. “Steady-State Somatosensory Evoked Potentials: Suitable Brain Signals for Brain-Computer Interfaces?": *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 14.1 (2006), págs. 30-37. DOI: [10.1109/TNSRE.2005.863842](https://doi.org/10.1109/TNSRE.2005.863842).
- [8] G. Pfurtscheller y A Aranibar. “Evaluation of event-related desynchronization (ERD) preceding and following voluntary self-paced movement”. *Electroencephalography and Clinical Neurophysiology* 2.46 (1979), págs. 138-146.

BIBLIOGRAFÍA

- [9] G. Pfurtscheller y A. Aranibar. "Occipital rhythmic activity within the alpha band during conditioned externally paced movement". *Electroencephalography and Clinical Neurophysiology* 2.45 (1978), págs. 226-235.
- [10] G. Pfurtscheller, C. Neuper, C. Brunner y F. L. da Silva. "Beta rebound after different types of motor imagery in man". *Neuroscience Letters* 378 (2005), págs. 156-159.
- [11] C. Guger, G. Edlinger, W. Harkam, I. Niedermayer y G. Pfurtscheller. "How Many People are Able to Operate an EEG-Based Brain-Computer Interface (BCI)?: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11 (2003), págs. 145-147.
- [12] E. W. Sellers, D. B. Ryan y C. K. Hauser. "Noninvasive brain-computer interface enables communication after brainstem stroke". *Science Translational Medicine* 6.257 (2014), 8 pp. DOI: [10.1126/scitranslmed.3007801](https://doi.org/10.1126/scitranslmed.3007801).
- [13] M. Marchetti y K. Priftis. "Effectiveness of the P3-speller in brain-computer interfaces for amyotrophic lateral sclerosis patients: a systematic review and meta-analysis". *Frontiers in Neuroengineering* 7 (2014), 6 pp. DOI: [10.3389/fneng.2014.00012](https://doi.org/10.3389/fneng.2014.00012).
- [14] E. V. C. Friedrich, N. Suttie, A. Sivanathan, T. Lim, S. Louchart *et al.* "Brain-computer interface game applications for combined neurofeedback and biofeedback treatment for children on the autism spectrum". *Frontiers in Neuroengineering* 7 (2014), 7 pp. DOI: [10.3389/fneng.2014.00021](https://doi.org/10.3389/fneng.2014.00021).
- [15] J. A. Pineda, E. V. C. Friedrich y K. LaMarca. "Neurorehabilitation of social dysfunctions: a model-based neurofeedback approach for low and high-functioning autism". *Frontiers in Neuroengineering* 7 (2014), 6 pp. DOI: [10.3389/fneng.2014.00029](https://doi.org/10.3389/fneng.2014.00029).
- [16] I. Daly, J. Faller, R. Scherer, C. M. Sweeney-Reed, S. J. Nasuto *et al.* "Exploration of the neural correlates of cerebral palsy for sensorimotor BCI control". *Frontiers in Neuroengineering* 7 (2014), 11 pp. DOI: [10.3389/fneng.2014.00020](https://doi.org/10.3389/fneng.2014.00020).
- [17] T. Ono, K. Shindo, K. Kawashima, N. Ota, M. Ito *et al.* "Brain-computer interface with somatosensory feedback improves functional recovery from severe hemiplegia due to chronic stroke". *Frontiers in Neuroengineering* 7 (2014), 9 pp. DOI: [10.3389/fneng.2014.00019](https://doi.org/10.3389/fneng.2014.00019).
- [18] J. Song, B. M. Young, Z. Nigogosyan, L. M. Walton, V. A. Nair *et al.* "Characterizing relationships of DTI, fMRI, and motor recovery in stroke rehabilitation utilizing brain-computer interface

- technology". *Frontiers in Neuroengineering* 7 (2014), pág. 11. DOI: [10.3389/fneng.2014.00031](https://doi.org/10.3389/fneng.2014.00031).
- [19] B. M. Young, Z. Nigogosyan, L. M. Walton, J. Song, V. A. Nair *et al.* "Changes in functional brain organization and behavioral correlations after rehabilitative therapy using a brain-computer interface". *Frontiers in Neuroengineering* 7 (2014), 15 pp. DOI: [10.3389/fneng.2014.00026](https://doi.org/10.3389/fneng.2014.00026).
- [20] R. Xu, N. Jiang, A. Vuckovic, M. Hasan, N. Mrachacz-Kersting *et al.* "Movement-related cortical potentials in paraplegic patients: abnormal patterns and considerations for BCI-rehabilitation". *Frontiers in Neuroengineering* 7 (2014), 9 pp. DOI: [10.3389/fneng.2014.00035](https://doi.org/10.3389/fneng.2014.00035).
- [21] G. Pfurtscheller, P. Linortner, R. Winkler, G. Korisekand y G. Müller-Putz. "Discrimination of Motor Imagery-Induced EEG Patterns in Patients with Complete Spinal Cord Injury". *Computational Intelligence and Neuroscience* 2009, Article ID 104180 (2009), 6 pp. DOI: [10.1155/2009/104180](https://doi.org/10.1155/2009/104180).
- [22] R. Rupp. "Challenges in clinical applications of brain computer interfaces in individuals with spinal cord injury". *Frontiers in Neuroengineering* 7 (2014), pág. 15. DOI: [10.3389/fneng.2014.00038](https://doi.org/10.3389/fneng.2014.00038).
- [23] B. Blankertz, C. Sannelli, S. Halder, E. M. Hammer, A. Kübler *et al.* "Neurophysiological predictor of SMR-based BCI performance". *NeuroImage* 51.4 (2010), págs. 1303-1309. DOI: [10.1016/j.neuroimage.2010.03.022](https://doi.org/10.1016/j.neuroimage.2010.03.022).
- [24] C. Guger, G. Edlinger, W. Harkam, I. Niedermayer y G. Pfurtcheller. "How Many People are Able to Operate an EEG-Based Brain-Computer Interface (BCI)?: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11 (2003), págs. 145-147.
- [25] T. Ono, A. Kimura y J. Ushiba. "Daily training with realistic visual feedback improves reproducibility of event-related desynchronisation following hand motor imagery". *Clinical Neurophysiology* 124 (2013), págs. 1779-1786. DOI: [10.1016/j.clinph.2011.03.031](https://doi.org/10.1016/j.clinph.2011.03.031).
- [26] G. Pfurtcheller. "Functional brain imaging based on ERD/ERS". *Vision Research* 41 (2001), 1257 – 1260.
- [27] P. Bak, C. Tang y K. Wiesenfeld. "Self-Organized criticality An explanation of $1/f$ Noise". *Physical Review Letters* 54 (1987), págs. 381-384.
- [28] D. Gilden, T. Thornton y M. Mallon. " $1/f$ Noise in Human Cognition". *Science* 267 (1995), págs. 1837-1839.

BIBLIOGRAFÍA

- [29] C.-K. Peng, S. Havlin, H. E. Stanley y A. L. Goldberger. “Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series”. *Chaos* 5.1 (1995), págs. 82-87.
- [30] C.-K. Peng, S. V. Buldyrev, S. Havlin, M. Simons, H. E. Stanley *et al.* “Mosaic organization of DNA nucleotides”. *Phys. Rev. E* 49 (2 1994), págs. 1685-1689. DOI: [10.1103/PhysRevE.49.1685](https://doi.org/10.1103/PhysRevE.49.1685). URL: <http://link.aps.org/doi/10.1103/PhysRevE.49.1685>.
- [31] P. Allegrini, D. Menicucci, R. Bedini, L. Fronzino, A. Genignani *et al.* “Spontaneous brain activity as source of ideal $1/f$ noise”. *Physical Review E* 80 (2009), págs. 061914-1-13.
- [32] R. Q. Quiroga. “Quantitative analysis of EEG signals: Time-frequency methods and Chaos theory”. Tesis doct. Institute of Physiology e Institute of Signal Processing - Medical University Lübeck, 1998.
- [33] B. J. He, J. M. Zempel, A. Z. Snyder y M. E. Raichle. “The Temporal Structures and Functional Significance of Scale-free Brain Activity”. *Neuron* 66 (2010), págs. 353-369. DOI: [10.1016/j.neuron.2010.04.020](https://doi.org/10.1016/j.neuron.2010.04.020).
- [34] B. Kleber, N. Birbaumer, R. Veit, T. Trevorrow y M. Lotze. “Overt and imagined singing of an Italian aria”. *Neuroimage* 36 (2007), págs. 889-900. DOI: [10.1016/j.neuroimage.2007.02.053](https://doi.org/10.1016/j.neuroimage.2007.02.053).
- [35] Z. A. Keirn y J. I. Aunon. “A New Mode of Communication Between Man and His Surroundings”. *IEEE Transactions on Biomedical Engineering* 37.12 (1990), págs. 1209-1214.
- [36] E. V. Friedrich, C. Neuper y R. Scherer. “Whatever Works A Systematic User-Centered Training Protocol to Optimize Brain-Computer Interfacing Individually”. *PLoS One* 8 (2013), e76214.
- [37] A Eke, L Kocsis y L. R. Kozak. “Fractal characterization of complexity in temporal physiological signals”. *Physiological Measurements* 23 (2002), R1-R38. DOI: [10.1088/0967-3334/23/1/201](https://doi.org/10.1088/0967-3334/23/1/201).
- [38] Y. Ashkenazy, P. C. Ivanov, S. Havlin, C.-K. Peng, A. L. Goldberger *et al.* “Magnitude and Sign Correlations in Heartbeat Fluctuations”. *Physical Review Letters* 86.9 (2001), págs. 1900-1903.
- [39] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov *et al.* “PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals”. *Circulation* 101 (2000), e215-e220. DOI: [10.1161/01.CIR.101.23.e215](https://doi.org/10.1161/01.CIR.101.23.e215).
- [40] B. Mandelbrot y B. Mandelbrot. *Los Objetos fractales: forma, azar y dimensión*. Libros para pensar la ciencia. Tusquets, 1987. ISBN: 9788472234581. URL: <https://books.google.com.mx/books?id=nu5wSwAACAAJ>.

-
- [41] K. Hu, P. C. Ivanov, Z. Chen, P. Carpena y H. E. Stanley. "Effect of trends on detrended fluctuation analysis". *Physical Review E* 64 (2001), págs. 011114-1-19.
- [42] Q. Wang, O. Sourina y M. K. Nguyen. "Fractal dimension based neurofeedback in serious games". *The Visual Computer* 27 (4 2011), págs. 299-309.
- [43] M. L. V. Quyen, J. Martinierie, C. Adam y F. J. Varela. "Nonlinear analyses of interictal EEG map the brain interdependences in human focal epilepsy". *Physica D* 127 (1999), págs. 250-266.
- [44] P. Faure y H. Korn. "Is there chaos in the brain? I. Concepts of nonlinear dynamics and methods of investigation". *Life Sciences* 324 (2001), págs. 773-793.
- [45] H. Korn y P. Faure. "Is there chaos in the brain? II. Experimental evidence and related models". *Comptes Rendus Biologies* 326 (2003), págs. 787-840.
- [46] R. Hardstone, S.-S. Poil, G. Schiavone, R. Jansen, V. V. Nikulin *et al.* "Detrended fluctuation analysis: a scale-free view on neuronal oscillations". *Frontiers in Physiology* 3 (2012), pág. 460. DOI: [10.3389/fphys.2012.00450](https://doi.org/10.3389/fphys.2012.00450).
- [47] M. Jospin, P. Caminal, E. W. Jensen, H. Litvan, M. Vallverdú *et al.* "Detrended Fluctuation Analysis of EEG as a Measure of Depth of Anesthesia". *IEEE Transactions on biomedical Engineering* 54.5 (2007), págs. 840-846.
- [48] H. Jing y S. Chen. *Chaos Theory in EEG Analysis*. Inf. téc. Department of Clinical Neurophysiology, Tianjin Institute of Neurology, 1998, págs. 193-202.
- [49] S. Leistedt, M. Dumont, J.-P. Lanquart, F. Jurysta y P. Linkowski. "Characterization of the sleep EEG in acutely depressed men using detrended fluctuation analysis". *Clinical Neurophysiology* 118 (2007), págs. 940-950.
- [50] J.-S. Lee, B.-H. Yang, J.-H. Lee, J.-H. Choi, I.-G. Choi *et al.* "Detrended fluctuation analysis of resting EEG in depressed outpatients and healthy controls". *clinical Neurophysiology* 118 (2007), págs. 2489-2496.
- [51] A. Bashashati, R. Ward, G. Birch, M. Hashemi y M. Khalilzadeh. "Fractal Dimension-Based EEG Biofeedback System". En: *Proceedings of the 25th International Conference of the IEEE EMBS*. 2003.
- [52] S. Karkare, G. Saha y joydeep Bhattacharya. "Investigating long-range Correlations properties in EEG during complex cognitive tasks". *Chaos, Solitions and fractals* 42 (2009), págs. 2067-2073.

BIBLIOGRAFÍA

- [53] X.-M. Pei, C.-X. Zheng, W.-X. He y J. Hu. “Quantitative measure of complexity of the dynamic event-related EEG data”. *Neurocomputing* 70 (2006), págs. 263-272.
- [54] C. J. Stam y E. A. de Bruin. “Scale-Free Dynamics of Global Functional Connectivity in the Human Brain”. *Human Brain Mapping* 22 (2004), págs. 97-109.
- [55] R. C. Hwa y T. C. Ferree. “Scaling properties of fluctuations in the human electroencephalogram”. *Physical Review E* 66 (2002), 021901:1-8. DOI: [10.1103/PhysRevE.66.021901](https://doi.org/10.1103/PhysRevE.66.021901).
- [56] B. R. Pittman-Polletta, F. A. J. L. Scheer, M. P. Butler, S. A. Shea y K. Hu. “The role of the circadian system in fractal neurophysiological control”. *Biological Reviews of the Cambridge Philosophical Society* 88 (2013), págs. 873-894. DOI: [10.1111/brv.12032](https://doi.org/10.1111/brv.12032).
- [57] Z. Chen, J. Cao, Y. Cao, Y. Zhang, F. Gu *et al.* “An empirical EEG analysis in brain death diagnosis for adults”. *Cognitive Neurodynamics* 2 (2008), págs. 257-271. DOI: [10.1007/s11571-008-9047-z](https://doi.org/10.1007/s11571-008-9047-z).
- [58] S. Makeig, M. Westerfield, T.-P. Jung, S. Enghoff, J. Townsend *et al.* “Dynamic Brain Sources of Visual Evoked Responses”. *Science* 295:5555 (2002), págs. 690-694. DOI: [10.1126/science.1066168](https://doi.org/10.1126/science.1066168). eprint: <http://www.sciencemag.org/content/295/5555/690.full.pdf>. URL: <http://www.sciencemag.org/content/295/5555/690.abstract>.
- [59] V. Aboites. “Caos, Emergentismo y Estados Mentales: Un Análisis de la Frontera entre la Física y la Mente”. *Acta Universitaria* 19.Septiembre (2009), págs. 53-58.
- [60] T. Gao, D. Wu y D. Yao. “EEG Scaling Difference Between Eyes-Closed and Eyes-Open Conditions by Detrended Fluctuation Analysis”. *Advances in Cognitive Neurodynamics ICCN 2007*. Ed. por R. Wang, E. Shen y F. Gu. Springer Netherlands, 2008, págs. 501-504. ISBN: 978-1-4020-8387-7.
- [61] W. Lutzenberger, T. Elbert, N. Birbaumer, W. Ray y H. Schupp. “The Scalp distribution of the Fractal Dimension of the EEG and Its Variation with Mental Tasks”. *Brain topology* 5.1 (1992), págs. 27-34.
- [62] P. M. Angel, E. J. Carlos, G. M. Teresa y G.-C. Ramón. “Applying fractal analysis to short sets of heart rate variability data”. *Medical & Biological Engineering & Computing* 47 (7 2009), págs. 709-717.
- [63] Z. Chen, P. C. Ivanov, K. hu y H. E. Stanley. “Effect of nonstationarities on detrended fluctuation analysis”. *Physical Review E* 65 (2002), págs. 041107-1-15.

-
- [64] M. Phothisonothai y M. Nakagawa. "EEG-Based Fractal analysis of different Motor Imagery Tasks using Critical Exponent Method". *International Journal of Biological and Life Sciences* 1.3 (2005), págs. 175-180.
- [65] H. Preißl, W. Lutzenberger, F. Pulvermüller y N. Birbaumer. "Fractal dimension of short EEG time series in humans". *Neuroscience Letters* 255 (1997), págs. 77-80.
- [66] Z. Jiang, Y. Ning, B. An y H. F. Ao Li. "Detecting mental EEG properties using detrended fluctuation analysis". En: *Proceedings of the 2005 IEEE Engineering in Medicine and biology 27th Annual conference*. 2005.
- [67] T. Nguyen-Ky, P. Wen e Y. Li. "Theoretical basis for identification of different anesthetic states based on routinely recorded EEG during operation". *Computers in biology and Medicine* 39 (2009), págs. 40-45.
- [68] S. D. Power, T. H. Falk y T. Chau. "Classification of prefrontal activity due to mental arithmetic and music imagery using hidden Markov models and frequency domain near-infrared spectroscopy". *Journal of Neural Engineering* 7 (2010), 9 pp. DOI: [10.1088/1741-2560/7/2/026002](https://doi.org/10.1088/1741-2560/7/2/026002).
- [69] R. Acharya, O. Faust, N. Kannathal, T. Chua y S. Laxminarayan. "Non-linear analysis of EEG signals at various sleep stages". *Computer Methods and Programs in Biomedicine* 80.80 (2005), págs. 37-45.
- [70] A. Babloyantz, J. Salazar y C. Nicolis. "Evidence of chaotic dynamics of brain activity during the sleep cycle". *Physics Letters* 111A.3 (1985), págs. 152-156.
- [71] P. Paramanathan y R. Uthayakumar. "Application of fractal theory in analysis of human electroencephalographic signals". *Computers in Biology and Medicine* 38.38 (2008), págs. 372-378.
- [72] V. Kulish, A. Sourin y O. Sourina. "Human electroencephalograms seen as a fractal time series: Mathematical analysis and visualization". *Computers in Biology and Medicine* 36 (2006), págs. 291-302.
- [73] H Brust-Carmona, G Valadez, B Flores-Avalos, J. Martinez, A Sanchez *et al.* "Absolute power of cortical oscillations and their topographical distribution in a sample of young adults during resting wakefulness and unspecific attention". *Revista de Investigación Clínica* 65 (1 2013), págs. 52-64.
- [74] E. Niedemeyer y F. L. D. Silva. "Electroencephalography Basic Principles, clinical applications and related fields". 5.^a ed. Lippincott Williams y Wilkins, 2005. Cap. 8.

BIBLIOGRAFÍA

- [75] J. W. Eaton y J. B. Rawlings. “Ten Years of Octave-Recent Developments and Plans for the Future”. En: *Proceedings of the 3rd International Workshop on Distributed Statistical Computing (DSC 2003)*. 2003.
- [76] C. W. Anderson y Z. Sijercic. “Classification of EEG signals from four subjects during five mental tasks”. En: *Proceedings of the conference on engineering applications in neural networks (EANN)*. EANN. 1996, págs. 407-414.
- [77] B. Obermaier, C. Neuper, C. Guger y G. Pfurtscheller. “Information Transfer Rate in a Five-Class Brain-Computer Interface”. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 9.3 (2001), págs. 283-288.
- [78] W. D. Penny y S. J. Roberts. *Experiments with an EEG-based computer interface*. Inf. téc. Imperial College, 1999.
- [79] S. J. Roberts y W. D. Penny. “Real-time brain-computer interfacing: a preliminary study using Bayesian learning”. *Medical & Biological Engineering & Computing* 38 (2000), págs. 56-61.
- [80] S. J. Roberts, W. D. Penny e I. Rezek. “Temporal and spatial complexity measures for electroencephalogram based brain-computer interfacing”. *Medical & Biological Engineering & Computing* 37 (1999), págs. 93-98.
- [81] T. Fernández, T. Harmony, M. Rodríguez, J. Bernal, J. Silva *et al.* “EEG activation patterns during the performance of tasks involving different components of mental calculation”. *Electroencephalography and Clinical Neurophysiology* 94 (1995), págs. 175-182.
- [82] S. Dehaene y L. Cohen. “Cerebral Pathways for Calculation: Double Dissociation Between Rote Verbal and Quantitative Knowledge of Arithmetic”. *Cortex* 33 (1997), págs. 219-250.
- [83] S. Dehaene, M. Piazza, P. Pinel y L. Cohen. “Three Parietal Circuits for Number Processing”. *Cognitive Neuropsychology* 20 (3/4/5/6) (2003), págs. 487-506. DOI: [10.1080/02643290244000239](https://doi.org/10.1080/02643290244000239).
- [84] M. Fatourechi, A. Bashashati, R. K. Ward y G. E. Birch. “EMG and EOG artifacts in brain computer interface systems: A survey”. *Clinical Neurophysiology* 118 (2007), págs. 480-494. DOI: [10.1016/j.clinph.2006.10.019](https://doi.org/10.1016/j.clinph.2006.10.019).
- [85] L. F. Nicolas-Alonso y J. Gomez-Gil. “Brain Computer Interfaces, a Review”. *Sensors* 12 (2012), págs. 1211-1279. DOI: [10.3390/s120201211](https://doi.org/10.3390/s120201211).

- [86] Y. L. T. Nguyen-Ky Peng Wen. "Improving the accuracy of depth of anaesthesia using modified detrended fluctuation analysis method". *Biomedical Signal Processing and Control* 5 (2010), págs. 59-65. DOI: [10.1016/j.bspc.2009.03.001](https://doi.org/10.1016/j.bspc.2009.03.001).
- [87] M. A. Maloof. "Learning When Data Sets are Imbalanced and When Costs are Unequal and Unknown". En: *Workshop on Learning from Imbalanced Data Sets II*. ICML. 2003.
- [88] C. Ling, J. Huang y H. Zhang. "AUC a Statistically Consistent and more Discriminating Measure than Accuracy". En: *Proceedings of 18th International Conference on Artificial Intelligence (IJCAI-2003)*. 2003, págs. 519-524.
- [89] N. V. Chawla, N. Japkowicz y A. Kolcz. "Editorial: Special Issue on Learning from Imbalanced Data Sets". *Sigkdd Explorations* 6 (2004), págs. 1-6.
- [90] E. Vuokko, M. Niemivirta y P. Helenius. "Cortical activation patterns during subitizing and counting". *Brain Research* 1487 (2013), págs. 40-52. DOI: <http://dx.doi.org/10.1016/j.brainres.2012.12.019>.
- [91] L. Zamarian, A. Ischebeck y M. Delazer. "Neuroscience of learning arithmetic - Evidence from brain imaging studies". *Neuroscience and Biobehavioral Reviews* 33 (2009), págs. 909-925. DOI: [10.1016/j.neubiorev.2009.03.005](https://doi.org/10.1016/j.neubiorev.2009.03.005).
- [92] M. S. Woolfson. "An evaluation of manoeuvre detector algorithms". *GEC J. Res.* 3 (1985), págs. 181-190.
- [93] S. Kingsley y S. Quegan. *Understanding Radar Systems*. McGraw-Hill, 1992. DOI: [10.1088/0967-3334/28/6/010](https://doi.org/10.1088/0967-3334/28/6/010).
- [94] E. R. Bojorges-Valdez, J. C. Echeverría, R Valdés-Cristerna y M a Peña. "Scaling patterns of heart rate variability data". *Physiological Measurement* 28 (2007), págs. 721-730.
- [95] C.-C. Chang y C.-J. Lin. "LIBSVM: A library for support vector machines". *ACM Transactions on Intelligent Systems and Technology* 2 (3 2011). Software disponible en <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 27:1-27:27.
- [96] F Lotte, M Congedo, A Lecuyer, F Lamarche y B Arnaldi. "A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces". *Journal of Neural Engineering* 4 (2007), R1.
- [97] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN: 0387310738.

BIBLIOGRAFÍA

- [98] G. Müller-Putz, R. Scherer, C. Brunner, R. Leeb y G. Pfurtscheller. “Better than random? A closer look on BCI Results”. *International Journal of Bioelectromagnetism* 10.1 (2008), págs. 52-55.
- [99] S. Dehaene, M. Piazza, P. Pinel y L. Cohen. “Three parietal circuits for number processing”. *Cognitive Neuropsychology* 20 (3/4/5/6) (2003), págs. 487-596.
- [100] R. Scherer, M. Billinger, J. Wagner, A. Schwarz, D. T. Hettich *et al.* “Thought-based row-column scanning communication board for individuals with cerebral palsy”. *Annals of Physical and Rehabilitation Medicine* 58 (2015), págs. 14-22. DOI: [10.1016/j.rehab.2014.11.005](https://doi.org/10.1016/j.rehab.2014.11.005).
- [101] J. Yordanova y V. Kolev. “Event-Related Brain Oscillations: Developmental Effects on Power and Synchronization”. *Journal of Psychophysiology* 23 (2009), págs. 174-184. DOI: [10.1027/0269-8803.23.4.174](https://doi.org/10.1027/0269-8803.23.4.174).
- [102] M. Ahn, H. Cho, S. Ahn y S. C. Jun. “High Theta and Low Alpha Powers May Be Indicative of BCI-Illiteracy in Motor Imagery”. *PLoS One* 8.11 (2013), e80886. DOI: [10.1371/journal.pone.0080886](https://doi.org/10.1371/journal.pone.0080886).
- [103] E. Thomas, M. Dyson y M. Clerc. “An analysis of performance evaluation for motor-imagery based BCI”. *Journal of Neural Engineering* 10 031001 (2013), 15 pp. DOI: [10.1088/1741-2560/10/3/031001](https://doi.org/10.1088/1741-2560/10/3/031001).
- [104] C. Tangwiriyasakul, R. Verhagen, M. J. A. M. van Putten y WimLCRutten. “Importance of baseline in event-related desynchronization during a combination task of motor imagery and motor observation”. *Journal of Neural Engineering* 10 (2013), 026009 (9pp). DOI: [10.1088/1741-2560/10/2/026009](https://doi.org/10.1088/1741-2560/10/2/026009).
- [105] G. Pfurtscheller y F. L. D. Silva. “Event-related EEG/MEG synchronization and desynchronization: basic principles”. *Clinical Neurophysiology* 110 (1999), págs. 1842-1857.
- [106] C. Neuper y G. Pfurtscheller. “Event-related dynamics of cortical rhythms: frequency-specific features and functional correlates”. *International Journal of Psychophysiology* 43 (2001), págs. 41-58. DOI: [http://dx.doi.org/10.1016/S0167-8760\(01\)00178-7](http://dx.doi.org/10.1016/S0167-8760(01)00178-7).
- [107] P. Bak, C. Tang y K. Wiesenfeld. “Self-organized criticality”. *Physical Review A* 38 (1988), págs. 364-374.
- [108] A. M. Owen, K. M. McMillan, A. R. Laird y E. Bullmore. “N-Back Working Memory Paradigm: A Meta-Analysis of Normative Functional Neuroimaging Studies”. *Human Brain Mapping* 25 (2005), págs. 46-59. DOI: [10.1002/hbm.20131](https://doi.org/10.1002/hbm.20131).

- [109] M. Dyson, F. Sepulveda y J. Gan. “Localisation of cognitive tasks used in EEG-based BCIs”. *Clinical Neurophysiology* 121 (2010), págs. 1481-1493. DOI: [10.1016/j.clinph.2010.03.011](https://doi.org/10.1016/j.clinph.2010.03.011).
- [110] J. Whalen, M. McCloskey, R. P. Lesser y B. Gordon. “Localizing Arithmetic Processes in the Brain: Evidence from a Transient Deficit During Cortical Stimulation”. *Journal of Cognitive Neuroscience* 9:3 (1997), págs. 409-417.
- [111] M. Spüler, W. Rosenstiel y M. Bogdan. “Online Adaptation of a c-VEP Brain-Computer Interface(BCI) Based on Error-Related Potentials and Unsupervised Learning”. *PLoS One* 7.12 (2012), e51077. DOI: [10.1371/journal.pone.0051077](https://doi.org/10.1371/journal.pone.0051077).
- [112] M. Spüler, W. Rosenstiel y M. Bogdan. “Unsupervised BCI Calibration as Possibility for Communication in CLIS Patients?”: En: *Proceedings of the Fifth International Brain-Computer Interface Meeting 2013*. Article ID: 122. 2013. DOI: [10.3217/978-3-85125-260-6-122](https://doi.org/10.3217/978-3-85125-260-6-122).
- [113] P.-J. Kindermans y B. Schrauwen. “Dynamic Stopping in a Calibration-less P300 Speller”. En: *Proceedings of the Fifth International Brain-Computer Interface Meeting 2013*. Article ID: 075. 2013. DOI: [10.3217/978-3-85125-260-6-75](https://doi.org/10.3217/978-3-85125-260-6-75).
- [114] P.-J. Kindermans, B. Schrauwen, B. Blankertz, K.-R. Müller y M. Tangermann. “Transferring Unsupervised Adaptive Classifiers Between Users of a Spatial Auditory Brain-Computer Interface”. En: *Proceedings of the 6th International Brain-Computer Interface Conference 2014*. Article ID 063-1. 2014, págs. 252-255. DOI: [10.3217/978-3-85125-378-8-63](https://doi.org/10.3217/978-3-85125-378-8-63).
- [115] P. Garrido-del Angel, E. Bojorges-Valdez y O. Yanez-Suarez. “SSVEP-based BCI control of the DASHER writing system”. En: *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on*. 2011, págs. 446-448. DOI: [10.1109/NER.2011.5910582](https://doi.org/10.1109/NER.2011.5910582).
- [116] B. Blankertz, G. Dornhege, M Krauledat, M Schröder, R Murray-Smith *et al.* “The Berlin brain-computer interface presents the novel mental typewriter Hex-o-Spell.” En: *Proceedings of the 3rd International BCI workshop and Training Course*. 2006, págs. 108-109.
- [117] H. Hinrikus, M. Bachmann, D. Karai, W. Klonowski, J. Lass *et al.* “Higuchi’s fractal dimension for analysis of the effect of external periodic stressor on electrical oscillations in the brain”. *Medical and Biological Engineering and Computing* 49 (2011), págs. 585-591.
- [118] R. O. Duda, P. E. Hart y D. G. Stork. *Pattern Classification*. John Wiley y Sons, 2001, pág. 634.

BIBLIOGRAFÍA

- [119] J. A. Hanley y B. McNeil. "The Meaning and Use of the Area under Receiver Operating Characteristic (ROC) Curve". *Radiology* 143 (1982), págs. 29-34.