



***Trabajo final presentado  
en opción al Título de  
Máster en Automática***

Autor: Magdalen Bazán de los Santos

Tutora: Msc. Daily Milanés Hermosilla

**Santiago de Cuba**

**2021**



**UNIVERSIDAD  
DE ORIENTE**

**Facultad de Ingeniería Eléctrica**

**Departamento de Ingeniería en Automática**

***Trabajo final presentado  
en opción al Título de  
Máster en Automática***

Autor: Magdalen Bazán de los Santos

Tutora : MSc. Daily Milanés Hermosilla

**Título:** Clasificación de señales electroencefalográficas basadas en eventos sensorimotores para una interfaz cerebro computador.

---

## *Pensamiento*

*“Al venir a la tierra, todo hombre tiene derecho a que se le eduque, y después en pago, el deber de contribuir a la educación de los demás.”*

***Dedicatoria***

*A mi madre por siempre exigirme e inspirarme.*

## *Agradecimientos*

*A todos mis compañeros de trabajo que de una forma u otra han colaborado con la  
realización de este trabajo.*

*A mi familia por brindarme su apoyo en las largas jornadas laborales.*

*A mi tutora por su larga paciencia.*

## *Resumen*

Un interfaz cerebro-máquina (BCI) es un modo de comunicación directa entre el cerebro y un dispositivo externo. En este trabajo se han investigado varios métodos para clasificar las señales cerebrales generadas por el usuario y de este modo interpretar su intención. Para ello, previamente se ha realizado un estudio de las investigaciones en el campo de los BCI en las dos últimas décadas., se analizaron las diferentes técnicas que los BCI emplean para adquirir la actividad cerebral y los tipos de señales de control que se pueden encontrar en la misma y que pueden ser moduladas voluntariamente por los usuarios. Se hizo una revisión de los distintos dispositivos que la comunidad científica ha controlado mediante sistemas basados en BCI. A continuación, se estudiaron diferentes métodos de clasificación aplicados a las señales EEG del conjunto de datos 2b de la competición BCI de 2008.

La futura implementación del sistema BCI propuesto será utilizado en un exoesqueleto pasivo de 4 GDL, orientado a tareas de rehabilitación desarrollado por la Universidad de Oriente en Cuba, que se encuentra en funcionamiento en la sala de rehabilitación del Hospital General Dr. Juan Bruno Zayas Alfonso de la ciudad de Santiago de Cuba y que se pretende pase a modo activo. Para evaluar los resultados se han empleado las señales electroencefalográficas (EEG) del conjunto de datos 2b de la competición BCI de 2008. En esta investigación se emplean cuatro métodos de clasificación de características: análisis discriminante lineal (LDA), máquina de soporte vectorial (SVM), perceptrón multicapa (MLP) y red probabilística de Parzen. Los resultados indican que la red probabilística de Parzen y SVM consiguen mejorar el rendimiento en la clasificación de señales en 3.8%, el

LDA en 1.9% y el perceptrón multicapa no consigue superar el rendimiento del método tomado como referencia.

## ***Abstract***

A brain-machine interface (BCI) is a direct communication mode between the brain and an external device. In this work, several methods have been investigated to classify the brain signals generated by the user and thus interpret their intention. To do this, a study of research in the field of BCI has previously been carried out in the last two decades. The different techniques that BCI use to acquire brain activity and the types of control signals that can be found were analyzed. In the same way, those that can be modulated voluntarily by the users. A review was made of the different devices that the scientific community has controlled using BCI-based systems. Next, different classification methods applied to the EEG signals from data set 2b from the 2008 BCI competition were studied.

The future implementation of the proposed BCI system will be used in a 4 DOF passive exoskeleton, oriented to rehabilitation tasks developed by the Universidad de Oriente in Cuba, which is operating in the rehabilitation room of the General Hospital Dr. Juan Bruno Zayas Alfonso from the city of Santiago de Cuba and that it is intended to go into active mode. To evaluate the results, the electroencephalographic (EEG) signals from data set 2b of the 2008 BCI competition were used. In this research, four characteristics classification methods are used: linear discriminant analysis (LDA), vector support machine (SVM), multilayer perceptron (MLP) and Parzen probabilistic network. The results indicate that the probabilistic network of Parzen and SVM manage to improve the performance in the classification of signals in 3.8%, the LDA in 1.9% and the multilayer perceptron does not manage to surpass the performance of the method taken as reference.



---

## ***Índice***

Introducción.....	1
Capítulo1.Estado del arte de los sistemas BCIs e imaginación motora .....	10
Introducción .....	10
1.1 Modelos y Arquitectura de la Interfaz Cerebro Computador.....	10
1.1.1 Aplicaciones de los sistemas BCI.....	16
1.2 Rendimiento de las BCI basadas en imaginación motora .....	20
1.3 Uso de métodos de clasificación de características en sistemas BCI en la actualidad. ....	21
Conclusiones .....	27
Capítulo 2. Descripción del sistema BCI y Métodos.....	29
Introducción .....	29
2.1 Experimento. Base de datos .....	29
2.1 Descripción del sistema BCI propuesto. ....	32
2.2 Métodos de clasificación empleados.....	34
2.3 Corroboración de los resultados alcanzados .....	40
2.3.1 Análisis valorativo de los aspectos económicos y medioambientales. ....	49
Conclusiones del capítulo .....	50
Conclusiones generales .....	51
Líneas futuras de trabajo .....	53

---

Bibliografía .....	54
Anexos .....	63
Anexo 1 .....	63
Anuario Estadístico de Salud, en su edición 2020.....	63

## ***INTRODUCCIÓN***

---

---

Las enfermedades cerebrovasculares (ECV) son uno de los padecimientos más estudiados entre las enfermedades crónicas no transmisibles. La incidencia promedio mundial es de 200 casos por cada 100 000 habitantes cada año, y una prevalencia de 600 casos por cada 100 000 habitantes[1].

En Cuba la incidencia de la enfermedad se calcula en unos 22 mil casos anuales de los cuales fallecen unos 9725 pacientes [2]. Se estima que ocurren 70 nuevos ictus por día en Cuba. Entre el 50-70% de los casos quedan secuelas, alrededor de un tercio de los sobrevivientes de un ictus son incapaces de valerse por sí mismos y aproximadamente el 75% pierde sus facultades para reincorporarse al trabajo [3].

Muchas de estas ECV involucran principalmente la capacidad de comunicarse o moverse por sus propios medios, por lo que requieren de un canal de comunicación alternativo que les permita exteriorizar sus pensamientos, sentimientos, emociones e interactuar con el medio físico por medio de la capacidad de controlar dispositivos externos. Entre este tipo de dispositivos destacan las Interfaces Cerebro Computador (BCI) por sus siglas en inglés.

Un dispositivo BCI puede registrar señales eléctricas (señales electroencefalográficas o EEG) pero también otro tipo de señales como la irrigación sanguínea de cerebro. Los dispositivos BCI se pueden clasificar como invasivos y no invasivos. En los invasivos, se colocan los sensores dentro del cráneo por lo que es necesaria una intervención quirúrgica. En los no invasivos, el sensor es externo al cráneo. Los dispositivos BCI invasivos tienen un uso limitado debido a los riesgos de una cirugía

[1], mientras que los no invasivos se utilizan más ampliamente por su portabilidad y facilidad de uso, sin embargo, estos últimos tienen un ancho de banda limitado y por tal la información que puede ser extraída también es limitada [2].

Las investigaciones hechas en BCI no invasivas basadas en señales EEG indican la posibilidad de su uso en pacientes con daños neurológicos; se ha probado su éxito en el control de un cursor, de sillas de ruedas, de movimientos básicos de prótesis, deletreadores, rehabilitación motora, entre otros. Estos sistemas pueden ser de ayuda en sujetos con diversos trastornos motores como esclerosis lateral amiotrófica, parálisis cerebral, accidente cerebrovascular y amputación. [4].

En la actualidad, la mayoría de las terapias de rehabilitación se realizan en forma manual involucrando rutinas de movimientos en las que se requiere esfuerzo físico por parte del fisioterapeuta, lo que puede provocar que al final de una jornada el fisioterapeuta, por los efectos del cansancio físico, no realice los procedimientos adecuadamente. Adicionalmente, en algunos tipos de terapia el fisioterapeuta debe aplicar una resistencia al movimiento del paciente, la fuerza aplicada debe ser controlada para evitar generar una lesión mayor, además si esta no es aplicada correctamente se puede provocar un temor en el paciente a las terapias y por ende una tensión de los músculos afectados, lo que conlleva a un retraso significativo en la evolución del tratamiento

Hace algún tiempo ha emergido la robótica de rehabilitación con el objetivo de aplicar tecnologías médicas que permiten la recuperación parcial o total de los pacientes de forma más efectiva. Entre estas tecnologías se encuentran las máquinas de rehabilitación motora para la restauración de la marcha, los exoesqueletos para

miembros inferiores y superiores, y los equipos de retroalimentación con señales de electromiografía, electroencefalografía y sensores propioceptivos.

Los exoesqueletos son estructuras externas rígidas que proporcionan soporte a las funciones motoras de las personas [5]. La clasificación de estos dispositivos los diferencia en exoesqueletos pasivos o activos. Los exoesqueletos pasivos ayudan el movimiento del miembro del paciente a partir de rutinas definidas con movimientos específicos. Los exoesqueletos activos contribuyen a la ejecución del movimiento del paciente si este no es capaz de realizarlo a partir de patrones de intencionalidad estimados con sensores de electromiografía, electroencefalografía y propioceptivos [6,7].

Estos dispositivos brindan mayor flexibilidad para su transportación y manejo. Los mismos, incorporan actuadores que permiten movimientos controlados y precisos. Muchos de los sensores incorporados en estos dispositivos brindan información del movimiento relacionada con el ángulo, la velocidad y la aceleración. En la actualidad los equipos en desarrollo, incorporan sensores que permiten capturar la actividad cerebral del paciente (señales EEG), la cual posibilita conocer la información relacionada con la intencionalidad del movimiento.[7].

Una de las estrategias frecuentemente usada en los sistemas BCI es la denominada imaginación motora (MI), (del inglés motor imagery); que es un proceso mental en el cual el individuo ensaya, simula o imagina una acción dada. Imaginar un movimiento genera los mismos procesos mentales que el realizarlo, por tanto MI puede ser considerado como un método más natural [8]. MI induce cambios medibles en los componentes de las señales EEG sobre las áreas sensorimotoras, conocidos como

desincronización/sincronización relacionada a eventos, en inglés *event-related desynchronization/synchronization* (ERD/ERS) [8,9].

Aunque la mayor parte de los estudios sugieren que la realización de la acción produce mejores resultados que la simple imaginación motora, en [10] se observó un éxito ligeramente mayor cuando se trataba de movimientos imaginarios versus movimientos reales. Se pueden encontrar señales de interés en MI en las ondas beta y mu. También se puede obtener información adicional de 8 señales de baja frecuencia ( $< 1$  Hz), como en [11], donde las usaron para decodificar la velocidad del miembro superior, ya que estas señales llevan información sobre el inicio del movimiento, dirección y velocidad. El uso práctico de aplicaciones basadas en ERD está limitado por la gran variabilidad que existe de sujeto a sujeto, una de las posibles razones para esta variabilidad es la variada capacidad de las neuronas para trabajar en sincronía en el córtex sensorimotor [12]. El electroencefalógrafo obtiene las señales del cerebro mediante electrodos. Una forma de seleccionar los electrodos a usar es identificando cuales cambian en potencia cuando varían ciertas condiciones, como de movimiento a reposo [13]. Los resultados de un sistema BCI pueden depender del estado mental actual del usuario y de la posición exacta de los electrodos, por tanto, antes de la sesión se debe regular con retroalimentación, previo llevar a cabo una sesión de selección (*screening*) sin retroalimentación en donde se determinan qué montaje y qué banda de frecuencia usar [14].

Los estudios realizados sobre el control de dispositivos mediante la decodificación de señales EEG pueden distinguirse entre online (en línea o en tiempo real) y offline (fuera de línea). Los primeros generalmente se utilizan para estudiar la interacción entre sujeto y máquina, casi siempre con retroalimentación. En el caso offline, los datos se

analizan después del proceso de toma de datos, el foco está mayormente en la decodificación de las señales EEG, es decir, en la capacidad del sistema de diferenciar diversos patrones mentales.

La revolución cubana desde sus inicios en 1959 ha venido prestando un especial interés a los servicios médicos convirtiendo a nuestro país en una potencia médica, que la ubica en estas prestaciones entre los países más desarrollados del mundo. En Cuba la utilización de la terapia de rehabilitación robótica puede considerarse incipiente dada su escaso empleo en estudios clínicos. Sin embargo en el año 2017 se implementó un exoesqueleto de 4 GDL, en el Hospital General Dr. Juan Bruno Zayas Alfonso de la ciudad de Santiago de Cuba. Éste se encuentra en funcionamiento en la sala de rehabilitación del hospital mencionado, y se ha empleado en el tratamiento del hombro doloroso en pacientes hemipléjicos de rasgo isquémico.

Los resultados de la aplicación de este proyecto fueron satisfactorios, se comprobó la marcha del proceso teniendo como referencia 2 grupos de pacientes, el primer grupo recibiendo terapia de rehabilitación robótica, y el 2do grupo terapia de rehabilitación de manera convencional. [15,16]. Los resultados fueron alentadores para nuestro país, puesto que actualmente esta terapia se realiza de forma manual en la mayoría de las salas de rehabilitación excepto en el Centro Internacional de Salud “La Pradera”.

Aunque los resultados de la aplicación de la terapia robótica fueron satisfactorios es importante aclarar que el paciente no participaba de forma activa, es decir, los ejercicios realizados eran orientados desde una PC por parte del fisioterapeuta, y enviados a una tarjeta electrónica, para el control de los movimientos realizados por el exoesqueleto.

**Problema de investigación :**

Necesidad de la participación activa de pacientes en el proceso de rehabilitación a partir de su intencionalidad de movimiento.

**Objeto de investigación:** Métodos de clasificación de señales de electroencefalografías basados en imaginación motora para sistemas BCI.

**Campo de acción:** Las técnicas de aprendizaje automático para la detección de la intención de movimientos en los métodos de clasificación de las señales de electroencefalografías.

**Objetivo general**

Diseñar el sistema BCI para el control del exoesqueleto en modo activo a través del uso de las señales EEG mediante métodos de clasificación de intencionalidad de movimientos basados en imaginación motora.

**Hipótesis:** Si se diseña el sistema BCI para el control del exoesqueleto en modo activo mediante el uso de señales EEG basados en imaginación motora se logrará una mejor neuro-rehabilitación en pacientes con daños neurológicos .

Para dar cumplimiento a este objetivo general y a partir del análisis de la literatura, se plantean las siguientes **tareas:**



- Fundamentar del problema de la investigación a partir del diagnóstico del estado actual de las terapias para la neuro-rehabilitación motora de pacientes post ictus y el desarrollo de exoesqueletos en los procesos de rehabilitación.
- Realizar un estudio desde el punto de vista gnoseológico, histórico y actual de los métodos de extracción de características y de clasificación de señales EEG en sistemas BCI
- Proponer un método de clasificación para tareas de imaginación motora en sistemas BCI a partir de señales EEG
- Evaluar el método propuesto en bases de datos de imaginación motora reconocidas en la comunidad científica.
- Corroborar los resultados alcanzados y emitir conclusiones.

### **Aporte Práctico**

- El diseño de un sistema BCI que contribuye a una futura implementación del desarrollo de una terapia robótica activa que brinda a los pacientes con daños neurológicos la posibilidad de su integración a la sociedad en que viven, y que además logren trabajar con equidad y dignidad.

### **Métodos de investigación utilizados.**

- Método de análisis y síntesis: Se aplica para establecer el estado del arte del tema de investigación, como marco teórico referencial, permitiendo conocer qué se ha investigado sobre el tema de la evolución histórica del desarrollo de los exoesqueletos para la rehabilitación en el entorno clínico.

- Método de inducción-deducción: Se aplica para proponer una propuesta integradora partiendo de diferentes análisis que logran establecer aspectos generales y métodos empíricos, que constituyen puntos de partida para inferir o confirmar formulaciones teóricas, las cuales permitirán deducir nuevas conclusiones lógicas que son sometidas a prueba de acuerdo con las generalizaciones empíricas.
- Método de la observación científica: consiste en la percepción directa del objeto de investigación y constituye el instrumento universal del investigador. Se utiliza para observar la dinámica del proceso de reconocimiento de las señales EEG y analizar en cada caso cómo se comportan las variables identificación de posturas que se corresponden con tales señales, rango de movimiento articular (ROM) del miembro superior.
- Métodos de medición: se desarrollan con el objetivo de obtener información numérica acerca de una propiedad o cualidad del objeto o fenómeno, comparando magnitudes medibles y conocidas, según una unidad de medida. Se aplicó específicamente para medir las señales EEG.
- Métodos estadísticos y matemáticos: se utilizan para la extracción y procesamiento de las señales EEG, así como para analizar estadísticamente los resultados experimentales obtenidos y establecer generalizaciones apropiadas a partir de ellas.

La estructura de este trabajo comprende más allá de la presente sección de introducción, tres capítulos, conclusiones y recomendaciones, referencias bibliográficas y finalmente el apartado de anexos.

En el Capítulo 1, “Estado del arte en sistemas BCI e imaginación motora”, se realiza una descripción de las características, tipos y aplicaciones de los sistemas BCIs así como su uso en el campo de la imaginación motora. Se revisan los métodos de extracción, y clasificación de señales EEG en los sistemas BCIs. También se describe el exoesqueleto implementado en la sala de rehabilitación del hospital Juan Bruno Zayas.

En el Capítulo 2, “Descripción del sistema BCI y Métodos”, se exponen las características de las bases de datos utilizadas, los métodos de extracción de las señales, clasificadores empleados y las herramientas empleadas para el diseño del sistema de control, se presentan y analizan los resultados de la evaluación de los diferentes clasificadores utilizados y se comparan los resultados entre ellos, y finalmente se plantean las conclusiones y se esbozan las principales líneas abiertas para un trabajo futuro, surgidas de la tesis.

## **CAPÍTULO 1. ESTADO DEL ARTE DE LOS SISTEMAS BCIs E IMAGINACIÓN**

### **MOTORA**

---

---

#### **INTRODUCCIÓN**

En este capítulo se abordan las características, aplicaciones y tipos de sistemas BCIs, así como el paradigma de la imaginación motora. También se realiza una revisión de las técnicas empleadas en las diferentes etapas del sistema BCI y un análisis de su estado del arte.

#### **1.1 MODELOS Y ARQUITECTURA DE LA INTERFAZ CEREBRO COMPUTADOR**

La BCI permite la comunicación en tiempo real entre el cerebro y algún dispositivo de salida, como un computador [17]. En un BCI la actividad cerebral debe ser registrada, digitalizada y clasificada de manera tal que esta información pueda generar una señal de salida, la cual será controlada por la actividad cerebral. Inicialmente el objetivo de una BCI fue permitir a un individuo, con discapacidad motora severa, tener control efectivo sobre algún dispositivo, como un computador, sintetizador de voz, prótesis u otro [20], aunque también fue usada con el fin de restaurar funciones cognitivas [17].

En particular, el propósito de la BCI es aumentar o mejorar algunas capacidades humanas permitiendo la interacción con un computador a través de una modulación consciente o espontánea de las oscilaciones cerebrales después de un período de entrenamiento [18]. De este modo, la BCI se convierte en un sistema cerebro-actuado que permite canales alternativos de comunicación y control [18].

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

Un sistema de BCI es capaz de detectar ciertas características de la actividad cerebral (habitualmente asociada al movimiento) que tienen relación con la intención de controlar un movimiento [19]. Para reconocer esta actividad cerebral se emplean múltiples algoritmos del ámbito del procesamiento de señales, algunos serán discutidos en los epígrafes siguientes.

La investigación acerca de sistemas BCI se inició en 1970 en la Universidad de California, Los Ángeles. Inicialmente se concentró en el desarrollo de aplicaciones clínicas, particularmente en pacientes con alteraciones del sistema nervioso. Sin embargo, el desarrollo de nuevas tecnologías ha incrementado su espectro de aplicaciones y las áreas de investigación, de esta manera sus campos de acción han crecido considerablemente. De este modo, también se ha usado como alternativa de comunicación en individuos sanos [20].

Las modalidades de adquisición usadas para BCI, ya sea en humanos o primates no humanos incluyen EEG adquiridas desde electrodos localizados en el cuero cabelludo y registros específicos de neuronas a través de micro electrodos implantados. La técnica con EEG se considera un método seguro, además de bajo costo comparado con los métodos invasivos, pero tiene baja resolución espacial y pobre relación señal-ruido [21], provocado por la atenuación que generan los huesos del cráneo y por la contaminación de la señal debido a los músculos vecinos. Por el contrario el registro específico de unidades neuronales presenta una mejor resolución espacial, permitiendo además el uso de más canales independientes. Estos permiten el registro de múltiples neuronas en un mismo tiempo otorgando la posibilidad de activar una prótesis mediante movimiento multiplanares [22]. Kennedy et al. describieron un método de implante de electrodos cónicos que son fijados con un

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

sustrato que contiene factor de crecimiento nervioso. Este sistema requiere indemnidad del tejido neural de manera de permitir el crecimiento dentro del cono, proceso que ocurre en un período de varias semanas. Esta modalidad permite obtener registros por períodos prolongados [23,24,25,26,27]. Sin embargo, este tipo de registro requiere una gran proximidad con el tejido neuronal (alrededor de 100 micrones), por lo que no es recomendable para estudio en humanos por el alto riesgo clínico que esto implica, además de la falta de efecto en el tiempo debido a la respuesta cicatrizal en la zona de registro y del alto costo de implementación [28,29]. Wolpaw y McFarland demostraron que métodos de registro no invasivos en humanos, a través de electrodos en el cuero cabelludo, permiten lograr control multidimensional del cursor de un computador, similar a los obtenidos con registros invasivos en monos [30]. Esto sugiere que personas con desordenes motores podrían controlar movimientos complejos sin necesidad del uso de registros con electrodos implantados.

Además, los trabajos de Wolpaw [29,30] y los de Pfurtscheller [31] muestran que personas sanas y con parálisis pueden realizar control voluntario de los ritmos sensorio-motores en la corteza motora a través de la imaginación de movimientos. Por otro lado, también existe evidencia que personas con deterioro motor pueden aprender a manipular potenciales eléctricos cerebrales, como los ritmos mu o beta [32, 33, 34]. Pfurtscheller localizó los ritmos sensorios motores en regiones cerebrales siguiendo la organización homuncular del cerebro. La imaginación del movimiento de la mano anuló los ritmos sensorios motores sobre la región de la mano, y el movimiento imaginario o real de las extremidades inferiores bloqueó los ritmos sensorios motores en el sulcus interhemisférico [31].

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

La mayoría de los estudios de BCI con EEG como sistema de registro han utilizado las bandas de frecuencias conocidas como ritmos mu y beta asociados a la corteza motora. Se piensa que los ritmos mu y beta son el producto de circuitos tálamo corticales que muestran atenuación de la amplitud durante la activación cortical. Esta supresión se conoce como Event Related Descynchronization (ERD) y puede ser inducida por movimiento real o imaginario. Los ritmos mu y beta están separados respecto a la secuencia de activación y a la distribución topográfica [35], pero tienden a mostrar supresión bilateral difusa (contra-lateral dominante) con la actividad motora. Adicionalmente, bandas de frecuencias más altas, conocidas como ritmos gamma, también han sido investigadas. Las bandas gamma (>30 Hz) están a menudo relacionadas con un incremento en la amplitud (Event Related Synchronization, ERS), la cual se asocia a una activación cortical. También se ha postulado que estarían vinculadas con programación motora, atención e integración sensorio motora [36]. Sin embargo, estas altas frecuencias de oscilaciones no han sido utilizadas en sistemas BCI.

En términos generales un sistema de BCI está formado por cuatro módulos, el de adquisición de señales, el de preprocesamiento, el de procesamiento y el de actuación. El módulo de adquisición de señales está formado por el sistema de registro, habitualmente electrodos de superficie, considera además la amplificación y digitalización de la señal de EEG. El módulo de preprocesamiento incluye técnicas que buscan mejorar la calidad de la señal previa al procesamiento, entre éstas se cuentan el re-muestreo, normalización, referenciación y uso de filtros. Para el análisis de señal muchos autores han utilizado Matlab, ya que cuenta con múltiples herramientas para ello. Por ejemplo, en [37] procesaron las señales EEG con el software Toolbox de

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

MATLAB EEGLab mientras que en [6] utilizaron Matlab y Simulink para crear y ejecutar su paradigma.

El módulo de procesamiento tradicionalmente incluye dos etapas, extracción de características y clasificación. La etapa de extracción de características implica el uso de diversos métodos para filtrar y extraer información relevante (o características) a partir de los datos registrados. Esta información se puede obtener por ejemplo de los ritmos sensorio-motores, potenciales evocados como el P300 u otro. Para la extracción de características es común usar técnicas como transformadas de Wavelet, Transformada Rápida de Fourier, Análisis de componentes principales, Análisis de componentes independientes (ICA) o Densidad Espectral de Potencia [38].

La etapa de clasificación permite identificar las tareas de imaginación realizadas por el usuario del BCI mediante la detección de un patrón de actividad conocido previamente, para ello utiliza las características extraídas de la señal de EEG. En la clasificación se usan técnicas como Redes Neuronales Artificiales [36], Análisis discriminante lineal [37,38], K-vecinos más cercanos, Naive Bayesian y Máquinas de Soporte Vectorial. Algunas veces es necesaria una clasificación jerárquica, como en [39], de dos niveles, donde el primer nivel clasifica entre el movimiento de la mano derecha o izquierda, y el segundo, entre movimientos rápidos y lentos. Otro ejemplo de clasificación jerárquica es presentado en [40] donde se usó un primer clasificador para diferenciar entre relajación e imaginación motora, y un segundo clasificador para diferenciar entre las tareas de imaginación motora de la mano derecha e izquierda.

El módulo de actuación desarrolla la acción correspondiente, de esta manera se logra el control del dispositivo deseado, por ejemplo: silla de ruedas, cursor del computador,



*Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

neuroprótesis, etc. La figura 1.1 muestra un diagrama de bloques con estos módulos básicos.



*Figura 1.1: Arquitectura tradicional de un sistema BCI. Notar que el módulo de procesamiento tradicionalmente considera las etapas de extracción de características y clasificación.*

Como se mencionó anteriormente, la mayoría de las tecnologías de BCI se basa en el uso de EEG como sistema de registro. Sin embargo, éste presenta desventajas como la elevada impedancia de entrada, la mala relación señal-ruido o variabilidad en el posicionamiento de los electrodos [42] y la baja resolución espacial [43]. A pesar de ello, el EEG se utiliza en más del 80% de los trabajos publicados en BCI [13]. A grandes rasgos, existen dos tipos de extracción de señales desde el cerebro, BCI invasivo y BCI no invasivo. En el BCI invasivo se utilizan arreglos de electrodos implantados directamente en el cerebro, aquí se registra la actividad de cientos de neuronas, obteniéndose una alta calidad de señal. Esta tecnología ha sido explorada principalmente en primates no humanos. Los experimentos realizados en monos

Rhesuspor [44] permitieron registrar la actividad de amplias poblaciones de neuronas cerebrales para generar movimiento en un brazo robótico. Los monos fueron entrenados para alcanzar y tomar objetos en una pantalla de computador mediante la manipulación de un joystick, mientras el correspondiente movimiento de un brazo robótico ocurría de manera oculta.

### **1.1.1 APLICACIONES DE LOS SISTEMAS BCI**

El envejecimiento y dependencia son dos términos cada vez más interrelacionados. El incremento de la esperanza de vida de la población en los países occidentales lleva asociado un aumento progresivo del número de personas en situación de dependencia. La evolución hacia sociedades más envejecidas demanda nuevas soluciones para asistir a las personas de avanzada edad que ven limitadas sus capacidades para realizar actividades de la vida diaria y que requieren ayuda para su ejecución. En este sentido, los sistemas BCI pueden resultar de gran utilidad, ya que facilitan una nueva forma de interactuar con los diferentes dispositivos presentes en su entorno habitual. Así, es posible satisfacer algunas necesidades fundamentales de comunicación, confort, ocio y desplazamiento. Por tanto, estos sistemas contribuyen a un incremento de la autonomía de las personas en situación de dependencia, mejorando tanto su calidad de vida como su integración en la sociedad.

Las aplicaciones más habituales están dirigidas a facilitar la comunicación, el control de sillas de ruedas y prótesis o el control del entorno. También se han desarrollado aplicaciones orientadas al control del ordenador y la navegación a través de Internet.

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

Las aplicaciones orientadas a facilitar la comunicación se han desarrollado a partir de sistemas BCI, que presentan al usuario las letras del abecedario en forma de matriz o de teclado de ordenador. El usuario forma palabras y frases mediante la selección de las letras que las conforman. La técnica de selección de letras y caracteres se ha implementado con sistemas BCI de varios tipos: basados en P300, en potenciales corticales lentos o en imágenes motoras. Actualmente, se está dedicando un gran interés y esfuerzo en el desarrollo de sistemas que combinen la selección de letras con la navegación por Internet, de forma que existen aplicaciones BCI para la publicación de mensajes en Twitter y navegadores BCI para la exploración de páginas web.

**TAMBIÉN SE HAN EMPLEADO DIFERENTES TIPOS DE SISTEMAS BCI, BASADOS EN P300 O EN IMÁGENES MOTORAS, PARA EL CONTROL DEL MOVIMIENTO DE SILLAS DE RUEDAS. DICHS SISTEMAS PERMITEN ACTIVAR O PARAR EL MOVIMIENTO DE LA SILLA, GIRARLA A LA DERECHA O A LA IZQUIERDA E INCLUSO DESPLAZARSE HASTA UN PUNTO CERCANO QUE EL USUARIO HA SELECCIONADO.** Además, las sillas están dotadas de sensores y otros dispositivos que permiten detectar posibles obstáculos y ayudan a esquivarlos para garantizar siempre la seguridad del usuario. Una aplicación similar, de control de trayectorias, movimientos y giros, que ha sido implementada con sistemas BCI, es la de teleoperación de robots, es decir, control de robots que pueden estar ubicados a miles de kilómetros de distancia.

Por último, ya se está investigando en la aplicación de sistemas BCI orientados a la realización de tareas mentales que mejoren las capacidades cognitivas de los usuarios. Las primeras aplicaciones desarrolladas resultan prometedoras, aunque

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

desde el punto de vista del entrenamiento cognitivo y del retraso de los efectos del envejecimiento, queda aún un largo camino por recorrer.

### **Uso de sistema BCI en pacientes hemipléjicos en Santiago de Cuba.**

En Cuba, la Universidad de Oriente ha desarrollado varios prototipos de exoesqueletos para la rehabilitación del miembro superior en pacientes hemipléjicos, uno de los cuales operando en modo pasivo ha servido para mostrar índices muy favorables en pacientes hemipléjicos aquejados del síndrome del hombro doloroso.

Esta plataforma incluye entre sus bondades: un diseño que con 4 grados de libertad permite 5 movimientos terapéuticos puros y compuestos secuenciales, una interfaz de usuario sencilla que permite controlar el número de repeticiones de la rutina, el tiempo de duración, la amplitud del movimiento articular, la velocidad de realización de los ejercicios, incorporar nuevas rutinas de movimiento y además posee un sistema de seguridad que incluye elementos de control por software, limitadores de recorrido y sistema de “pushbottom”[15] (Figura 1.2).



## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

*Figura 1.2 Exoesqueleto en uso en la sala de rehabilitación del Hospital Doctor Juan Bruno Zayas de Santiago de Cuba. Fuente: Robotic therapy for the hemiplegic shoulder pain: a pilot study. Journal of Neuro Engineering and Rehabilitation*

Con la movilidad natural de la extremidad en el dispositivo, la rehabilitación robótica ofrece la capacidad de integrar gradualmente a los pacientes a un tipo diferente de rehabilitación comparado con la terapia convencional. Es decir, proveer los movimientos en cada articulación, mediante el robot, con las mismas repeticiones de ejercicios que usualmente el terapeuta provee.

La rehabilitación robótica, además de valerse del uso de dispositivos robóticos, se basa en un concepto de diseño, análisis, construcción y desarrollo de dispositivos automatizados para asistir y ayudar a que las personas discapacitadas se integren a las actividades de la vida cotidiana a pesar de las consecuencias y efectos de la discapacidad. Así, este concepto requiere de la comprensión de las ciencias médicas, de la rehabilitación y de la ingeniería. Las ciencias médicas y la rehabilitación se encargan del análisis del movimiento neuromuscular, motor y los procesos de neuro-recuperación(terapia) y la ingeniería del diseño y control de las BCI, que sean ergonómicas y útiles para estimular con seguridad al paciente durante una sesión de terapia (Krebs y cols., 2003).

Un paso de avance en los estudios de métodos de clasificación en sistemas BCI para la detección de eventos sensorimotrices basados en imaginación motora contribuirá a la evolución del exoesqueleto de rehabilitación a modo activo, con ello la terapia es más emocionante e incrementa la motivación del paciente, logrando el éxito de la rehabilitación debido a que la estimulación sensorial es parte fundamental en la recuperación.

## **1.2 RENDIMIENTO DE LAS BCI BASADAS EN IMAGINACIÓN MOTORA**

El rendimiento de las BCI basadas en MI, se mide regularmente con el porcentaje de acierto en la clasificación, lo cual depende en gran medida de una correcta extracción de características. Existen diferentes procedimientos para llevar a cabo este proceso como el filtrado espacial o el análisis espectral. En [11], pueden consultarse diferentes algoritmos usados en las etapas de extracción de características y clasificación. El uso de características basadas en tiempo y frecuencia han demostrado ser eficaces en el proceso de clasificación de tareas mentales. No obstante, proporcionan poca información sobre la actividad y las funciones cerebrales subyacentes. En la práctica una buena clasificación sin una explicación del fenómeno involucrado es poco útil.

La mayoría de los BCI utilizan el análisis de potencia espectral de señales adquiridas en canales únicos de EEG durante tareas de MI. Estas tareas involucran usualmente partes del cuerpo como las manos o los pies. De esta manera, los Ritmos sensorio-motores SMR, en inglés Sensorimotor Rhythms modulan sus oscilaciones en función de la parte del cuerpo que se está imaginando.

Particularmente, cuando el sujeto imagina el movimiento de alguna extremidad, los ritmos mu y beta se desincronizan sobre el área motora contralateral [12]. Es así, como el rendimiento de una BCI con este tipo de análisis es dependiente de la extracción de características basadas comúnmente en ERD/ERS, quedando espacialmente limitado a los lugares de registro de EEG en la corteza somatosensorial y motora.

En referencia a la observación anterior, se ha demostrado que durante el MI se activan y se comunican entre sí muchas partes del cerebro, específicamente el área motora suplementaria (SMA), área prefrontal, corteza premotora, cerebelo y los ganglios basales [13]. Por consiguiente, es necesario obtener características que proporcionen


información sobre la relación entre las señales de adquiridas en diversos sensores de EEG. Para así, poder observar la interacción de áreas del cerebro separadas espacialmente. Lo anterior, se puede llevar a cabo a través del análisis de la conectividad funcional, la cual en los últimos años ha resultado ser una herramienta eficiente de la neurociencia

### ***1.3 USO DE MÉTODOS DE CLASIFICACIÓN DE CARACTERÍSTICAS EN SISTEMAS BCI EN LA ACTUALIDAD.***

Hay dos aproximaciones principales para el diseño de esta etapa: métodos regresivos o métodos de clasificación. En este trabajo se estudian varios métodos para el diseño de la etapa de clasificación de un BCI., los algoritmos de clasificación usan las propiedades de las señales como variables independientes para definir los límites entre los distintos objetivos correspondientes a las intenciones del usuario descifrables por el BCI. Los más habituales son los métodos de clasificación [37]. McFarland et al. [38] ilustra las principales diferencias entre estas dos alternativas.

Para un caso en el que se requiere descifrar dos intenciones diferentes del usuario, tanto el método de regresión y el método de clasificación requieren determinar una sola función. Sin embargo, en el caso de tener que detectar cuatro opciones, el método de regresión todavía requiere una sola función mientras que si se emplea clasificación es necesario determinar tres funciones o fronteras de decisión para lograr distinguir los cuatro objetivos. Por lo tanto, los métodos de regresión pueden ser preferibles para un mayor número de objetivos, o para aplicaciones que impliquen el control continuo

de movimiento del cursor. La Figura 1.3 muestra estas diferencias entre los métodos de clasificación y regresión.



*Figura 1.3. Representación de los métodos de clasificación y regresión para dos objetivos .*

Los algoritmos de regresión emplean las características extraídas de las señales de la señal EEG como variables independientes para predecir las intenciones del usuario. Sin embargo, los métodos de clasificación utilizan las características extraídas como variables independientes para definir los límites entre los diferentes objetivos en el espacio de características.

El diseño de nuevos métodos de clasificación para BCI puede ser llevado cabo mediante sesiones offline, online o ambos tipos de sesiones. Las sesiones offline consisten en probar un método en concreto empleando conjuntos de datos grabados previamente como, por ejemplo, los que se proporcionan en las competiciones BCI [39, 40]. Durante las sesiones offline no es necesario analizar las señales de manera causal ni en tiempo real. Además, es posible estimar ciertas propiedades de las señales observando todas las señales en su extensión en el tiempo y realizar cálculos que impliquen largos tiempos de computación. Los resultados del algoritmo diseñado pueden ser revisados con el objetivo de mejorar el rendimiento del algoritmo. El análisis offline es valioso, pero no trata los problemas relacionados con el análisis de señales en tiempo real. Por el contrario, el análisis online es el medio para evaluar un



## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

BCI en un entorno real. Los datos solo pueden ser procesados de manera causal además de que este tipo de análisis tiene en cuenta la realimentación proporcionada por el BCI que se está diseñando.

Aunque algunos investigadores proponen algoritmos que solo han sido probados con datos offline, son necesarios ambos tipos de análisis para el diseño de algoritmos efectivos en un entorno real en el que el usuario recibe realimentación del BCI [41,42].

El entrenamiento o calibración de los algoritmos de clasificación habitualmente se hace de manera supervisada empleando un conjunto de señales etiquetado. Se asume que el clasificador es capaz de detectar los patrones similares que se encontrarán durante las sesiones con realimentación. Sin embargo, esto conlleva que el rendimiento del BCI disminuya, ya que las señales cerebrales son inherentemente no estacionarias.

Los patrones observados en la sesión de entrenamiento pueden ser diferentes de los observados durante las sesiones online. Además, el progresivo entrenamiento de los usuarios o los cambios de concentración, atención, o motivación pueden afectar a las señales cerebrales [43]. Por tanto, es esencial diseñar algoritmos adaptativos para mejorar la precisión de los BCI. Esto resulta ser particularmente necesario para el diseño de BCI asíncronos y no invasivos [44, 45].

El entrenamiento supervisado, además de no ser óptimo para la clasificación de señales no estacionarias, requiere normalmente procesar una gran cantidad de datos para realizar la calibración inicial del clasificador y, por tanto, requiere que el usuario dedique gran cantidad de tiempo para la calibración del BCI. Por este motivo, se ha propuesto el entrenamiento semi-supervisado, que reduce el tiempo necesario de calibración inicial haciendo una actualización de los algoritmos durante las sesiones online [46]. Con el entrenamiento supervisado, el clasificador es entrenado empleando

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

un pequeño conjunto de datos etiquetado, y después se actualiza con los datos procesados online.

En un escenario más realista, no es posible conocer al mismo tiempo las señales y las intenciones de los usuarios. En este caso, se tienen que aplicar métodos que empleen entrenamiento no supervisado o aprendizaje reforzado. Los métodos no supervisados tratan de encontrar estructuras dentro de los datos no etiquetados para clasificarlos. Estos métodos se basan en técnicas enfocadas a la adaptación entre el usuario y el BCI [47-48]. El entrenamiento reforzado se basa en el hecho de que es posible detectar algunos patrones característicos en las señales de EEG que son generados cuando los usuarios son conscientes de que el BCI ha malinterpretado su intención. Este tipo de patrones se puede usar como señales de aprendizaje que eviten que el error cometido por el BCI en un momento determinado se repita en el futuro [49]. Los métodos adaptativos normalmente implican una mejora en el rendimiento del BCI. No obstante, existen algunos riesgos en los BCI adaptativos. Un BCI adaptativo podría aprender demasiado aprisa y poder confundir al usuario, ya que está aprendiendo a manejar el BCI en un entorno que para él está cambiando continuamente. Además, la adaptación del BCI podría enmascarar algunas propiedades relevantes de las señales. Existe, por tanto, un compromiso entre tener una alta capacidad de adaptación y la extracción de características [50].

El problema de la clasificación de patrones presenta tres importantes dificultades: la maldición de la dimensionalidad, el compromiso sesgo-varianza, y el sobreentrenamiento. La maldición de dimensionalidad significa que el número de muestras necesarias para entrenar un clasificador de manera supervisada crece exponencialmente con la dimensión del vector de propiedades [51].

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

Desafortunadamente, los conjuntos de muestras que se pueden emplear para el entrenamiento son pequeños porque la generación de estas señales es un proceso largo que produce cansancio en los usuarios de los BCI. El compromiso entre el sesgo y la varianza está relacionado con la tendencia natural de los clasificadores a tener un alto sesgo con baja varianza y viceversa [37]. El error medio de clasificación puede ser descompuesto en tres términos:

$$MSE = \text{Ruido}^2 + \text{Sesgo}(f(x))^2 + \text{Var}(f(x)) \quad (1.1)$$

El ruido representa el carácter aleatorio de las muestras de entrenamiento y de test. El sesgo representa la divergencia entre el modelo estimado y el mejor modelo. La varianza refleja la sensibilidad del clasificador al conjunto de muestras de entrenamiento empleado.

Los clasificadores más estables se caracterizan por tener un elevado sesgo y baja varianza y los más inestables tienen alta varianza y bajo sesgo. El objetivo para conseguir el menor error en la clasificación es tratar de reducir al mismo tiempo el sesgo y la varianza. Se pueden emplear algunas técnicas como la regularización o la combinación de clasificadores para reducir la varianza [37]. El sobreentrenamiento se produce cuando un clasificador solo es capaz de clasificar los patrones que han sido empleados para el entrenamiento u otros muy similares. Esto puede ser evitado empleando regularización. La regularización es un método para controlar la complejidad del clasificador con el fin de prevenir el sobreentrenamiento, limitar el efecto de los outliers, e irregularidades en las fronteras de decisión [52,53].

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

Muchos de estos métodos de clasificación están basados en investigaciones anteriores dentro del campo del procesamiento de señales y del reconocimiento de patrones. Como consecuencia, a pesar de que el campo de investigación en BCI es relativamente joven, se han logrado muchos avances en poco más de dos décadas. La precisión de los sistemas BCI se ha mejorado significativamente y con ello se ha reducido el tiempo de entrenamiento necesario para controlarlos.

A pesar de los importantes logros que se han hecho en el campo de los BCI, hay algunas cuestiones que todavía quedan sin resolver. La mayoría de los sistemas BCI todavía se encuentran en fase de investigación y no están listos para ser introducidos en los hogares para su uso continuo en su vida diaria. Aún se requiere un esfuerzo excesivo para configurar, calibrar y operar los sistemas BCI además de que es necesaria la supervisión de técnicos expertos. La mayoría de los BCI actuales están basados en la monitorización de la señal eléctrica mediante EEG. A pesar de que esta técnica de adquisición es la que está más extendida por su fácil uso, todavía resulta poco amigable porque requiere humedecer los electrodos y vigilar que la calidad de los contactos entre el cuero cabelludo y los electrodos sea buena. También el software con el que el BCI es controlado puede precisar de inicialización que tenga que ser realizada por un experto.

Por otro lado, el uso de la tecnología BCI actual exige bastante concentración del usuario lo que puede causarle fatiga rápidamente. A pesar de las dificultades encontradas, se ha comprobado que, en los últimos años, la comunidad científica ha impulsado su investigación y desarrollo enormemente por las beneficiosas aplicaciones que los sistemas BCI ofrecen a la sociedad. Esta disciplina ha llegado a involucrar en la actualidad a científicos de múltiples disciplinas, como por ejemplo,

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

neurocientíficos, ingenieros, matemáticos, especialistas en rehabilitación clínica, entre otros. El principal objetivo de este creciente interés es superar las dificultades que presenta el diseño de un BCI amigable y preciso con el fin de hacer la vida más cómoda a personas afectadas por enfermedades neurológicas. No obstante, los alentadores resultados que se van obteniendo han permitido pensar que se puede extender los sistemas BCI a aplicaciones no solamente dirigidas a personas con graves discapacidades, sino también en todo tipo de personas. De esta manera, los sistemas BCI podrían significar en un futuro próximo una nueva forma de interacción hombre-máquina con una importancia similar a otras interfaces actuales.

### **CONCLUSIONES**

En resumen la etapa de clasificación forma parte del módulo de procesamiento y es fundamental en la arquitectura de un sistema de BCI. Aquí se busca clasificar las señales de EEG tomando en cuenta los vectores de características, de ahí lo determinante de las etapas anteriores. Particularmente en este documento la etapa de clasificación busca reconocer la intención del usuario (imaginería motora). Tradicionalmente los algoritmos de clasificación han sido entrenados mediante aprendizaje supervisado, etiquetando la base de datos de entrenamiento y de prueba, con el objetivo de detectar patrones de actividad cerebral. Sin embargo, considerando la naturaleza no estacionaria de las señales cerebrales, este enfoque podría no ser del todo apropiado.

Por un lado, los patrones observados durante el período de muestreo para la calibración pueden ser diferente a los registrados durante las sesiones de prueba. Por

## *Capítulo 1. Estado del arte de los sistemas robóticos utilizados para rehabilitación.*

---

otra parte, el entrenamiento mental progresivo de los usuarios o incluso cambios en la concentración, la atención o la motivación pueden afectar las señales cerebrales.

En paradigmas como MI, la retroalimentación es fundamental ya que permite que el cerebro del individuo aprenda a controlar el sistema. La retroalimentación de tipo visual ha mostrado buenos resultados comparada con otras, la forma como este tipo de retroalimentación influye en el aprendizaje a través de varias sesiones también es un factor a considerar. Los estudios indican que aún es una cuestión abierta cómo los diversos tipos de retroalimentación visual influyen en el ERD/ERS, y por tal, el control de un sistema BCI.

La adaptación a señales no estacionarias es particularmente necesaria en los BCIs no invasivos, de ahí la propuesta presentada en la hipótesis de este trabajo está basada en el estudio de los métodos de clasificación más utilizados para lograr una mejora en el rendimiento de intencionalidad de movimiento del sujeto.

## **CAPÍTULO 2. DESCRIPCIÓN DEL SISTEMA BCI Y MÉTODOS**

---

---

### **INTRODUCCIÓN**

En este capítulo se describe el sistema BCI implementado y los algoritmos utilizados para lograr clasificar las tareas de imaginación motora. Los métodos de clasificación que incluye el estudio son el análisis discriminante lineal, máquina de soporte vectorial, el perceptrón multicapa y la red probabilística de Parzen. Se ha utilizado la base de datos 2b de la Competición BCI de 2008 por tanto se tomara como referencia el método ganador de dicha competición.

### **2.1 EXPERIMENTO. BASE DE DATOS**

El conjunto de datos 2b de la competición BCI 2008 se compone de datos de EEG de 9 sujetos de un estudio publicado en [54]. Todos los sujetos cuyos datos aparecen en esta base realizaron tareas motoras y de imaginación. Los sujetos eran diestros y tenían una visión normal. Para el registro de los datos todos los voluntarios se sentaron en un sillón, mirando a una pantalla colocada aproximadamente a 1 metro de distancia. El conjunto de datos proporciona 5 sesiones para cada sujeto, de las cuales las dos primeras sesiones contienen datos de entrenamiento sin realimentación, y las tres últimas sesiones fueron grabadas con la realimentación. Cada sesión contó de varios tipos de grabaciones. Al comienzo de cada sesión, se llevó a cabo una grabación de 5 minutos aproximadamente para estimar la influencia EOG. Esta grabación está dividida en 3 bloques: (1) el sujeto permaneció dos minutos con los ojos abiertos (mirando una cruz en la pantalla), (2) un minuto con los ojos cerrados, y (3) un minuto

realizando movimientos oculares. Después se incluye un bloque de artefactos dividido en cuatro secciones (15 segundos de artefactos con 5 segundos de descanso entre ellos). Durante la grabación de este bloque, se pidió a los sujetos a través de un texto en la pantalla que llevaran a cabo una de las siguientes tareas: parpadeo de los ojos, hacer círculos con la mirada, movimientos arriba-abajo o de izquierda-derecha.

El paradigma de detección consistió en la clasificación de la señal EEG en dos clases: la imaginación del movimiento de la mano izquierda (clase 1) y la del movimiento de la mano derecha (clase 2). Durante las sesiones sin realimentación (Figura 2.1 (a)), el sujeto recibía una indicación del movimiento que tenía que imaginar pero no se recibía ningún tipo de indicación de cuán bien lo estaba haciendo. Cada sujeto participaba en dos sesiones sin realimentación, las cuales contenían 120 pruebas. El número de movimientos de cada clase es el mismo, por tanto en cada sesión hay 60 movimientos de cada tipo.

El protocolo seguido durante estas sesiones sin realimentación es el siguiente. Cada prueba se iniciaba mostrando una cruz en la pantalla y un sonido de aviso de frecuencia 1 kHz y de duración 70 ms. Tres segundos más tarde se presentaba una señal visual (una flecha que apunta hacia la izquierda o hacia la derecha, de acuerdo con la clase solicitada) durante 1,25 segundos. Después, los sujetos tenían que imaginar el movimiento de la mano correspondiente durante un período de 4 segundos. Finalmente, cada prueba se finalizaba con un breve descanso de al menos 1,5 segundos. Se incluía un tiempo aleatorio para evitar que el usuario se adaptara a este tiempo de descanso. Durante las tres sesiones con realimentación en tiempo real (Figura 2.1 (b)) se mostraba en la pantalla una cara sonriente cuando el movimiento era imaginado en la dirección correcta o triste en otro caso. Al comienzo de cada



prueba (segundo 0) se mostraba una cara con una sonrisa neutral. En el segundo 2 se hacía sonar un pitillo de aviso de frecuencia 1 kHz y duración 70 ms. La señal indicando qué tipo de movimiento se debía imaginar se presentaba desde el segundo 3 hasta el 7,5. Los sujetos, en función de la indicación, debían mover la cara con la sonrisa hacia la izquierda o la derecha por medio de la imaginación del movimiento de la mano izquierda o derecha.

Durante el período de realimentación, la cara con la sonrisa cambiaba a color verde si era movida en la dirección correcta o a rojo en caso contrario. La distancia de la cara sonriente desde el origen se calculaba integrado la salida clasificación en los últimos dos segundos [54]. La salida de la clasificación también se empleaba para modificar la curvatura de la boca. Si el movimiento era correcto la curvatura se modificaba para mostrar una cara más sonriente y en caso contrario se mostraba una cara más triste. En el segundo 7,5 la pantalla se quedaba en blanco y se introducía un intervalo aleatorio entre 1,0 y 2,0 segundos para finalizar la prueba y comenzar la siguiente.

El criterio anunciado al comienzo de la competición para determinar el ganador de la misma fue el que proporcionara el mayor valor de kappa. Los participantes debían proporcionar una salida de clasificación continua para cada muestra en forma de dos etiquetas para cada clase (1, 2). Todos los algoritmos deben ser causales, es decir, la salida proporcionada por el método en un instante de tiempo debe depender únicamente de muestras de las señales adquiridas en instantes de tiempo anteriores.

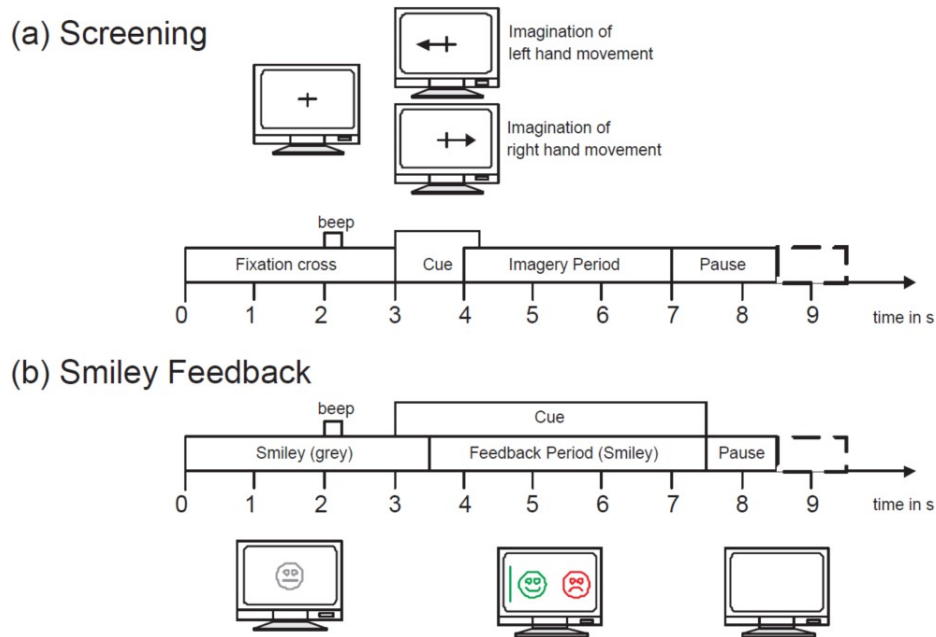


Figura 2.1. Esquema temporal de las pruebas. Pruebas con realimentación (a) y sin realimentación (b).

## 2.1 DESCRIPCIÓN DEL SISTEMA BCI PROPUESTO.

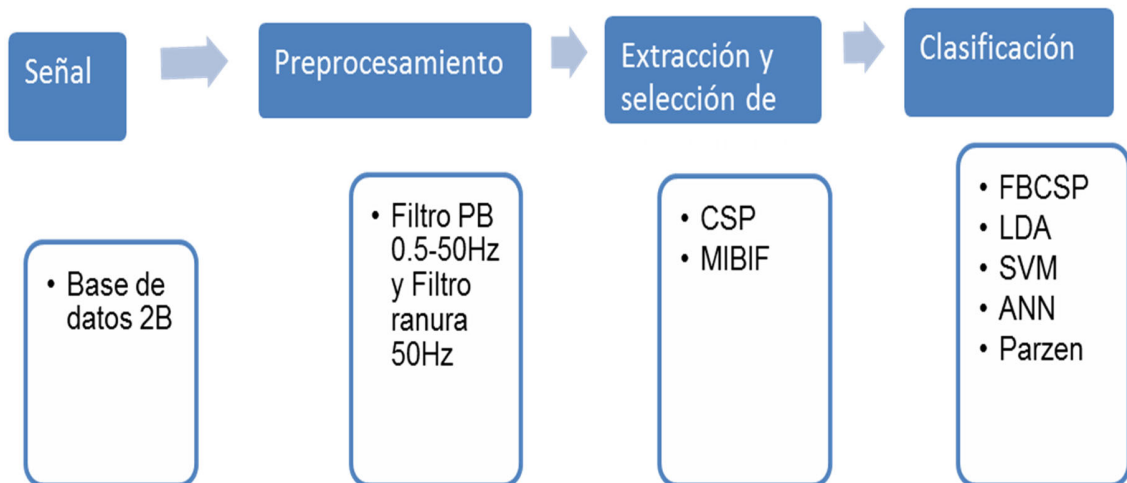


Figura 2.2 Sistema BCI propuesto.

Las señales que se emplean en este estudio pertenecen al conjunto de datos 2b de la Competición BCI 2008 [53] que fue proporcionado por el Instituto de Ingeniería Biomédica de la Universidad Tecnológica de Graz (Austria).

En este conjunto de señales se proporcionan señales de EEG correspondientes a tres canales bipolares localizados en C3, Cz y C4. Las señales registradas fueron muestreadas a 250 Hz y filtradas con un filtro paso banda entre 0,5 Hz y 50 Hz. Además, para evitar el efecto de la señal de alimentación a 50 Hz se aplicó un filtro de ranura a 50 Hz. Como señal EEG de referencia se empleó un electrodo localizado en Fz. Las señales de EOG se registraron con tres electrodos monopolares situados en las sienes y en el nasión.

Para la extracción de características se emplea en primer lugar un banco de filtros Chebychev Tipo II, que descompone la señal EEG en 9 bandas de frecuencia. Las bandas de frecuencia usadas fueron 4 – 8 Hz, 8 – 12 Hz, ..., 36 – 40 Hz. Los ganadores de la competición aseguran que pueden emplearse otras configuraciones con la misma eficacia, pero que esta configuración asegura una respuesta estable de los filtros al mismo tiempo que cubre el rango de frecuencias 4 – 40 Hz, que es el que parece más interesante para el procesamiento de señales EEG. Después de procesar la señal EEG con el banco de filtros, en una segunda fase, se emplea el algoritmo CSP para filtrar espacialmente. CSP es un método de extracción de características que proyecta señales EEG, que pueden proceder de varios canales, en un subespacio donde se destacan las diferencias entre las clases y se minimizan las similitudes.

Para la selección de características se propone MIBIF (Mutual Information-based Best Individual Feature) algoritmo de selección de las mejores características individuales basadas en información mutua. El algoritmo de selección de características de MIBIF

depende de un metaparámetro, el número de características seleccionadas, que se estableció en función de los resultados obtenidos en los datos de imágenes de motor de 2 clases del anterior BCI Competition III Dataset 4a en Ang et al. (2008). Por lo tanto, podría ser posible una mejora adicional utilizando el algoritmo de selección de características MIBIF optimizando el número de características seleccionadas a través de un enfoque de validación cruzada anidado.

Para la clasificación de características se emplean varias propuestas y se toma el método Filter Bank Common Spatial Pattern (FBCSP) como referencia por ser el algoritmo que alcanzó mejores resultados en la Competición BCI 2008.

## **2.2 MÉTODOS DE CLASIFICACIÓN EMPLEADOS**

A continuación, se presenta un estudio de los métodos de clasificación empleados para mejorar el rendimiento del algoritmo tomado como referencia. Estos son el análisis discriminante lineal, la máquina de soporte vectorial, el perceptrón multicapa y la red probabilística de Parzen.

### **✓ Análisis discriminante lineal (LDA)**

LDA se suele aplicar para clasificar los patrones encontrados en las señales cerebrales en dos clases. No obstante, es posible extender el método a múltiples clases [57].

Sin embargo, puede suceder que este clasificador lleve a conclusiones totalmente equivocadas cuando, entre los vectores de propiedades de entrenamiento que se emplean para construir el clasificador, existan valores atípicos o que hayan sido afectados severamente por el ruido [58].

Para un problema de dos clases, LDA supone que las dos clases son linealmente separables. Según esta hipótesis, se define una función lineal que representa un plano

en el espacio de características para distinguir la clase a la que pertenece el vector de características a clasificar. La clase a la que el vector de propiedades pertenece se decide en función del lado del plano en el que se encuentra el vector (Figura 2.3).




Figura.2.3 Clasificador lineal. La frontera de decisión es la línea continua. El margen del clasificador lineal es la mínima distancia desde cualquier punto a la frontera de decisión.

En este caso, el margen es la distancia entre las líneas punteadas y la línea continua.

El plano de decisión se puede representar matemáticamente como:

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

donde  $w$  es conocido como el vector de pesos,  $x$  es el vector de características de entrada y  $w_0$  es un umbral. El vector de propiedades de entrada  $x$  se asigna a una clase u otra en función del signo de  $g(x)$ .

Existen varios métodos para calcular  $w$ , por ejemplo, se puede calcular  $w$  como:

$$w = \Sigma_c^{-1}(\mu_2 - \mu_1) \quad (2.2)$$

Donde  $\mu_i$  es la media de la clase  $i$  y  $\Sigma_c = \frac{1}{2}(\Sigma_1 + \Sigma_2)$  es la matriz de covarianza común, que se calcula como la media de las matrices de covarianza de las dos clases. La estimación de la media y la covarianza se hace según:

$$\Sigma = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (2.3)$$

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.4)$$

siendo  $x$  una matriz que contiene los  $n$  vectores de propiedades  $x_1, x_2, x_3, \dots, x_n \in \mathbb{R}^d$  utilizados para construir el clasificador lineal.

Brevemente, si se considera el problema de proyectar datos desde  $d$  dimensiones, una simple solución para reducir su dimensionalidad sería proyectarlos en una línea. Evidentemente, aun cuando las muestras formen grupos compactos y bien separados en el espacio de dimensiones, la proyección en una línea arbitraria producirá una mezcla de las muestras y por lo tanto dificultará la clasificación de ellas. Sin embargo, al mover la línea se podría encontrar una orientación para la cual las muestras proyectadas estén bien separadas. Éste es exactamente el objetivo del análisis discriminante clásico.

✓ **Máquina de soporte vectorial (SVM)**

SVM es considerado como un clasificador lineal, ya que para llevar a cabo la clasificación utiliza uno o varios hiperplanos con el fin de separar los vectores de características en varias clases. Sin embargo, a diferencia de LDA, SVM selecciona los hiperplanos que maximizan los márgenes, es decir, la distancia de los vectores de propiedades a los hiperplanos [59].

Los vectores que se encuentran más cerca de estos hiperplanos se denominan vectores soporte. No obstante, es posible crear SVM que empleen límites de decisión no lineales por medio de un núcleo función  $K(x, y)$ .

SVM no lineales proporcionan un límite de decisión más flexible lo que puede aumentar la precisión de la clasificación. El kernel que se utiliza generalmente en el campo de los BCI es la función de Gauss o de base de radial (RBF):

$$K(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (2.5)$$

El SVM con núcleo gaussiano se ha aplicado en el BCI para clasificar a los potenciales evocados P300 [60].

✓ **Red neuronal artificial: Perceptrón Multicapa**

Una red neuronal artificial (ANN) es un conjunto de nodos y conexiones que son modificados durante el proceso de entrenamiento. Durante el entrenamiento, la ANN es alimentada con un conjunto de ejemplos de entrenamiento observándose el resultado producido por la red.

Desde el punto de vista matemático, ANN define una aplicación de un espacio de entrada a un espacio de salida que puede ser descrito como una función vectorial  $Y = F(X)$ , donde X e Y pueden tener cualquier dimensión.

Las ANN se componen de un conjunto de nodos o neuronas artificiales que procesan la información por medio de una función no lineal. Esta propiedad es especialmente importante sobre todo en aquellos casos en los que el mecanismo físico que genera la señal de entrada es no lineal [61].

Una de las estructuras más conocidas de ANN es el perceptrón multicapa (MLP, del inglés multilayer perceptron) presentado por Rumelhart y McClelland en 1986. El MLP se divide en varias capas que contienen varias neuronas artificiales,. El número de neuronas en cada capa depende de la complejidad de la red.

El MLP es un ejemplo de ANN donde las señales van siempre en dirección de la capa de entrada a la capa de salida. Esta restricción garantiza la estabilidad en el sistema. Gracias al teorema de Kolmogorov se sabe que una ANN de tres capas es suficiente para solucionar cualquier problema de clasificación, siempre y cuando el número de nodos de cada capa sea suficientemente alto.

Matemáticamente, la salida generada por un MLP se puede describir como una suma ponderada de varias entradas:

$$y = f \left( \sum_{i=1}^N w_i x_i - w_0 \right) \quad (2.6)$$

donde  $y$  es el término de salida,  $x_i$  es la  $i$ -ésima entrada de las  $N$  entradas y  $w_i$  su peso asociado. La función  $f$  es siempre una función monótona y, por lo general, es la función de Heaviside,  $H(z)$ , o la función sigmoidea logística  $\varphi(z)$ .

$$H(z) = \begin{cases} 0 & z < 0 \\ 1 & z \geq 0 \end{cases}, \varphi(z) = \frac{1}{1 + e^{-\beta z}} \quad (2.7)$$

Ambas funciones comparten la propiedad de que sus resultados tienden a cero para entradas negativas y a uno para entradas positivas. Esto significa que las funciones conmutarán de cero a uno cuando la suma ponderada de las entradas sea mayor que el término umbral  $w_0$ .

El valor de cada peso  $w_i$  es modificado durante el proceso de aprendizaje. Durante este proceso de aprendizaje se introducen diferentes entradas a la ANN y se analiza la salida. Si la salida es incorrecta entonces se ajustan internamente los pesos para reducir el riesgo de cometer el mismo error otra vez.

Con esta modificación se espera que la próxima vez la red neuronal responda correctamente a las mismas entradas o similares.



✓ **Red probabilística de Parzen**

Las redes neuronales probabilísticas (PNN, del inglés Probabilistic Neural Network) son redes que implementan la regla de Bayes. Este tipo de redes consiste en varias sub-redes, una por cada clase, que calculan para cada patrón de entrada  $x$  la función densidad de probabilidad del dato para una clase dada  $w_i$ . Para ello, se aplica el procedimiento de ventana Parzen [62].

Normalmente, en el proceso de cálculo de la función de densidad se emplea un núcleo gaussiano tal como muestra la siguiente ecuación:

$$p(x|w_i) = \frac{1}{N_i} \sum_{n=1}^{N_i} \frac{1}{(2\pi\sigma_p^2)^{\frac{d}{2}}} \exp\left(-\frac{\|x - x^n\|^2}{2\sigma_p^2}\right) \quad (2.8)$$

Las funciones kernel gaussianas están centradas en cada uno de los patrones de entrenamiento  $x^n$  correspondientes a cada clase y  $N_i$  es el número de patrones de entrenamiento empleados, correspondientes a cada clase  $w_i$  de entrenamiento empleados.

Para clasificar la red neuronal estima la probabilidad a posteriori  $P(x|w_i)$  mediante el Teorema de Bayes [63]

$$P(x|w_i) = \frac{P(w_i)P(x|w_i)}{\sum_{i=0}^N P(x|w_i)P(w_i)} \quad (2.9)$$

Las probabilidades a priori  $P(w_i)$  pueden ser obtenidas mediante la proporción:

$$P(w_i) = \frac{N_i}{N} \quad (2.10)$$

donde  $N_i$  es el número de muestras de entrenamiento de clase  $w_i$  y  $N$  es el número total de muestras.

Las redes neuronales probabilísticas han sido empleadas de manera exitosa en la clasificación de ritmos sensiomotores para el control de una mano en un entorno virtual [64].

### **2.3 CORROBORACIÓN DE LOS RESULTADOS ALCANZADOS**

La comparación de diferentes BCI requiere establecer una métrica común. La métrica más común para medir el rendimiento de un BCI es el error de clasificación o la precisión [65]. No obstante, hay otras métricas que también han sido propuestas para la evaluación de BCI como el coeficiente Kappa de Cohen [66], la información mutua o la transferencia de información [67], el error cuadrático medio [68], el área bajo la curva ROC [69] o la matriz de confusión [70]. En este trabajo el método de evaluación que se emplea es el mismo que el propuesto para el data set 2b de la Competición IV, es decir, el coeficiente Kappa de Cohen [6].

La precisión de clasificación es una medida de rendimiento que es muy fácil de calcular y de interpretar. Se trata de sumar el número de pruebas que son clasificadas correctamente y dividir por el número total de pruebas. Esto presenta el inconveniente de que no se tiene en cuenta que las clases pueden tener distinta probabilidad ni tampoco la ocurrencia de falsos positivos o negativos. El coeficiente Kappa de Cohen evita estos inconvenientes combinando dos medidas.

El coeficiente Kappa se calcula a partir de los elementos de la matriz de confusión. La matriz de confusión contiene el número de pruebas que han sido clasificadas correctamente en cada clase así como los falsos positivos y negativos. En la Tabla 2.1 se muestra un ejemplo de una matriz de confusión para un problema de dos clases.

En la diagonal de la matriz de confusión se encuentran contabilizados los casos en los que la clasificación ha sido correcta.

Es decir, aquellos casos en los que se detectó correctamente que la prueba era de la clase 1 y en los que se detectó correctamente que no era de la clase 1 y, por tanto, era de la clase 2. Fuera de la diagonal, se encuentran contabilizados los falsos positivos y los falsos negativos. Los primeros se corresponden con el total de casos en los que una señal fue clasificada como de la clase 1 cuando en realidad era de la clase 2 y en los segundos se contabilizan los casos en los que sucede lo contrario.

Tabla 2.1 Matriz de confusión para dos clases.

Clase	1	2
1	Aciertos	Falsos negativos
2	Falsos positivos	Rechazos correctos

Teniendo en cuenta los elementos de la matriz de confusión, el coeficiente Kappa se define como:

$$p_0 = \frac{\sum_{i=1}^M n_{ii}}{N}, \quad p_e = \frac{\sum_{j=1, i=1, j \neq i}^M n_{ij} n_{ji}}{N^2}, \quad k = \frac{p_0 - p_e}{1 - p_e} \quad (2.11)$$

donde  $n_{ij}$  es cada uno de los elementos de la matriz de confusión, N es el número total de pruebas y M el número de clases, que es igual al número de filas o columnas de la matriz de confusión.

El coeficiente Kappa evita los problemas de la medida de precisión ya que tiene en cuenta la distribución de las pruebas que han sido mal clasificadas, es decir, los elementos que no pertenecen a la diagonal de la matriz de confusión.

A continuación se presentan los resultados obtenidos por cada método de clasificación y se presenta una comparación con el método de clasificación aplicado por el ganador de la competición. Como ya se ha indicado anteriormente los métodos de clasificación fueron: análisis discriminante lineal, máquina de soporte vectorial, red neuronal artificial y red probabilística de Parzen. Además se ha reproducido el mismo método propuesto por el ganador de la competición.

En primer lugar se presentarán los resultados obtenidos de las pruebas de validación 5x5. En los que las pruebas de las sesiones de entrenamiento se dividen aleatoriamente en cinco parte quedando 4 para entrenamiento y 1 para validación. Este proceso se repite 5 veces con la misma partición. Finalmente, se calcula el valor medio y la desviación típica de los resultados obtenidos en las 5 repeticiones. En segundo lugar, se listan los resultados obtenidos con los datos de test de la competición.

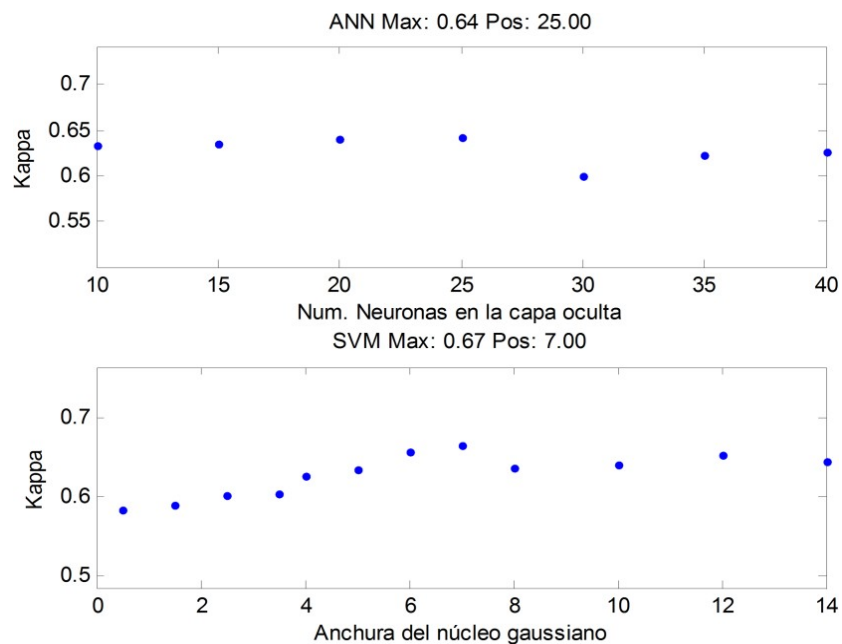
### **Resultados de la validación cruzada**

Algunos de los métodos de clasificación empleados en este estudio necesitan el ajuste de algunos parámetros. El ajuste de estos parámetros se ha realizado mediante validación cruzada 5x5 empleado las sesiones etiquetadas de la competición. Se evaluó el rendimiento medio de todos los sujetos con el valor de kappa promediado para todos los sujetos.

Para mejorar los resultados, no se emplearon todas las sesiones con las pruebas etiquetadas de la competición sino que se hizo una selección de las mismas del mismo modo que hicieron los ganadores de la competición. Para el clasificador basado en el perceptrón multicapa, se varió el número de neuronas de la capa oculta y en las máquinas de soporte vectorial se varió la anchura del núcleo gaussiano empleado para

la transformación de los datos a un dominio lineal. En la Figura 10 se pueden ver los valores de kappa obtenidos al variar cada uno de los parámetros.

Los resultados de la validación cruzada mostrados en la Figura 2.4 indican que un aumento de la complejidad de la red neuronal no conlleva un mejor resultado de clasificación. Esto puede ser debido a un sobre entrenamiento en la red neuronal que reduce el rendimiento del clasificador en la fase de validación. También cabe destacar que una red neuronal con pocas neuronas en la capa oculta (10 neuronas) consigue un valor de kappa muy cercano al máximo, que se consigue con 25 neuronas en la capa oculta. Con esto cabe pensar que la frontera de decisión presenta poca complejidad y puede ser representada con un número inferior de neuronas en la capa oculta.



## Capítulo 2. Descripción del sistema BCI y métodos

Figura 2.4. Valores de Kappa obtenidos variando el número de neuronas de la capa oculta del MLP (arriba) y la anchura del kernel gaussiano de la máquina de soporte vectorial (abajo).

En la Tabla 2.2 se listan los valores de kappa obtenidos para cada sujeto en función del tipo de clasificador aplicado. Los resultados se corresponden con el valor medio y la varianza de los resultados obtenidos en las pruebas de validación cruzada 5x5. Los rendimientos ofrecidos por cada uno de los clasificadores estudiados son muy similares entre sí. Cabe destacar que todos los clasificadores superan al método propuesto por el ganador de la competición si se tienen en cuenta solamente los resultados después de replicar el método del ganador. No obstante, las mejoras no son muy grandes ya que, SVM, que es el que proporciona mejor rendimiento, sólo supera al NaiveBayes en 0.05.

Tabla 2.2. Valor medio de Kappa y desviación típica obtenidas en la validación cruzada para cada sujeto en función del método de clasificación aplicado con las sesiones de entrenamiento.

	<b>LDA</b>	<b>SVM</b>	<b>ANN</b>	<b>Parzen</b>	<b>NaiveBayes</b>
1	0.55±0.01	0.55±0.04	<b>0.63±0.03</b>	0.57±0.02	0.56±0.01
2	0.18±0.02	<b>0.23±0.04</b>	0.13±0.05	0.16±0.03	0.10±0.02
3	<b>0.34±0.07</b>	0.28±0.01	0.23±0.01	0.22±0.01	0.12±0.03
4	0.97±0.01	<b>0.99±0.01</b>	0.97±0.01	0.97±0.01	0.99±0.01
5	0.89±0.01	0.89±0.01	0.85±0.01	0.87±0.01	<b>0.90±0.01</b>



*Capítulo 2. Descripción del sistema BCI y métodos*

	(máx.)		(máx.)		(máx.)		(máx.)		(máx.)	
1	0.27	5.44	<b>0.29</b>	5.04	0.28	5.32	0.25	3.56	0.28	2.52
2	<b>0.22</b>	4.60	0.19	6.24	0.12	5.16	0.22	4.64	0.16	4.76
3	0.09	0.60	0.10	0.80	0.10	1.00	<b>0.12</b>	5.64	0.11	0.72
4	0.92	4.12	0.92	4.08	0.93	4.92	<b>0.93</b>	4.36	0.92	4.12
5	0.84	5.48	0.80	5.12	0.77	4.96	<b>0.85</b>	6.36	0.79	5.56
6	0.62	5.96	0.62	6.08	0.58	6.16	<b>0.70</b>	6.16	0.64	5.36
7	<b>0.58</b>	4.32	0.55	4.80	0.57	5.44	0.54	4.44	0.51	6.28
8	0.79	5.40	0.86	6.28	<b>0.88</b>	4.84	0.80	6.12	0.85	5.20
9	0.71	5.36	<b>0.73</b>	5.00	0.72	4.40	0.70	5.72	0.71	6.32
MEDIA	0.54	5.40	0.54	6.32	0.52	6.28	<b>0.55</b>	6.44	0.53	5.40

En la Tabla 2.4 se muestran el rendimiento ofrecido por cada clasificador en el instante de tiempo seleccionado en las pruebas de validación cruzada. Se observa que los métodos aplicados no suponen una gran mejora con respecto a la implementación que replica el método ganador de la competición.

*Tabla 2.4. Coeficiente Kappa para cada sujeto en función del método de clasificación.*

Sujetos	LDA	SVM	ANN	Parzen	NaiveBayes
1	0.27	0.27	0.25	0.22	<b>0.28</b>
2	<b>0.19</b>	0.19	0.07	0.12	0.10
3	<b>0.05</b>	0.03	0.00	0.08	0.01



## Capítulo 2. Descripción del sistema BCI y métodos

---

4	0.87	0.86	0.90	<b>0.90</b>	<b>0.90</b>
5	0.79	0.75	0.75	<b>0.85</b>	0.77
6	0.62	0.62	0.57	<b>0.70</b>	0.63
7	0.53	0.54	<b>0.55</b>	0.53	0.46
8	0.78	<b>0.86</b>	0.86	0.79	0.83
9	0.67	<b>0.70</b>	0.67	0.69	0.67
MEDIA	0.53	0.54	0.51	<b>0.54</b>	0.52

Los resultados obtenidos a partir de la clasificación de los datos de test muestran que el rendimiento de los métodos propuestos es prácticamente el mismo que el que proporciona el método del ganador de la competición. Los métodos que emplean una máquina de soporte vectorial o una red probabilística de Parzen ofrecen un rendimiento ligeramente superior.

La mejora en el rendimiento del método de clasificación depende de cada sujeto. En el sujeto 1 no se consiguió mejorar el método del ganador y en el sujeto 4 se consiguió igualar. En el resto, los métodos de clasificación propuestos superan al método del ganador. No obstante, el método de clasificación que lo hace depende del sujeto. En los sujetos 2 y 3 el método de clasificación mejor es el LDA, en los sujetos 4, 5 y 6 la red probabilística de Parzen, en el sujeto 7 el perceptrón multicapa y en los sujetos 8 y 9 la máquina de soporte vectorial.

Hay claramente tres sujetos, los sujetos 1, 2 y 3, que evidencian mucha más dificultad que el resto para generar señales que se puedan clasificar con mayor facilidad. Esto

es claramente patente en los sujetos 2 y 3 en los que el rendimiento es prácticamente igual al rendimiento que ofrecería una clasificación aleatoria.

Si se comparan los resultados de test con los obtenidos mediante validación cruzada se constata que hay una pérdida significativa de rendimiento de alrededor del 1.3. Esto puede ser debido a un sobreentrenamiento de los métodos de clasificación, a las pruebas de entrenamiento o que las características extraídas de las pruebas de entrenamiento no reflejan de manera significativa el problema. Es conocido que el problema de clasificación de señales cerebrales presenta la dificultad de que tienen una gran variabilidad. Por este motivo, resulta especialmente difícil encontrar unas características de entrenamiento que representen el problema y no se obtenga una pérdida de rendimiento en la clasificación de las pruebas de test.

En la Tabla 2.5 se muestran los resultados indicados por el ganador de la competición [71]. El rendimiento obtenido de la reproducción del método propuesto, aunque se aproxima, es diferente.

*Tabla 2.5. Resultados obtenidos por el ganador con las sesiones de test [71].*

Sujetos	NaiveBayes (Resultados dados por el ganador)
<b>1</b>	<b>0.36</b>
<b>2</b>	<b>0.17</b>
<b>3</b>	<b>0.17</b>
<b>4</b>	<b>0.96</b>
<b>5</b>	<b>0.85</b>

---

<b>6</b>	<b>0.59</b>
<b>7</b>	<b>0.56</b>
<b>8</b>	<b>0.86</b>
<b>9</b>	<b>0.75</b>
<b>MEDIA</b>	<b>0.59</b>

### **2.3.1 ANÁLISIS VALORATIVO DE LOS ASPECTOS ECONÓMICOS Y MEDIOAMBIENTALES.**

Los últimos avances en la investigación en BCI sugieren que en futuro próximo se van a producir avances significativos. Los logros conseguidos en las dos últimas décadas y el potencial de nuevas aplicaciones BCI han dado un impulso importante a la investigación BCI con participación de grupos científicos multidisciplinarios como aquellos donde participan neurocientíficos, ingenieros, matemáticos y especialistas en clínicas de rehabilitación, entre muchos otros. Se espera que el interés en el campo de los BCI aumente aún más en los próximos años y que el diseño de BCI cada vez mejores consiga incrementar de manera efectiva la calidad de vida de las personas con discapacidad. Por otra parte, existe un creciente interés por algunas empresas en extender el uso de los BCI y las ventajas que ofrece este nuevo modo de interacción a personas que no padecen discapacidad. Ya se pueden encontrar algunas aplicaciones de los BCI dirigidas a la población general. Esto sugiere que, en un futuro próximo, los BCI podrían convertirse en un nuevo modo de interacción hombre-máquina con una importancia similar a otras interfaces actuales.

**CONCLUSIONES DEL CAPITULO**

El algoritmo tomado como referencia para lograr una conexión cerebro-computador FBCSP ha sido mejorado en este trabajo, pero siguen existiendo problemas como: la mala resolución de los electroencefalogramas, las características específicas que se debieran extraer y qué tipo de clasificador utilizar para mejorar el desempeño de la BCI. Actualmente no se ha logrado determinar un clasificador mejor que otro, ya que su eficacia depende exclusivamente del tipo de muestra que uno quiera clasificar y de las características relevantes que fueron extraídas de esa muestra inicial, lo que hace más compleja la configuración de la BCI.

Con la correcta clasificación de las muestras se logra determinar el nivel real de conciencia de un paciente en estado vegetativo persistente, mínima respuesta o con trastornos severos de la movilidad, establecer comunicación con personas en situación de discapacidad severa, entregar una retroalimentación sobre sensaciones, sentimientos, síntomas y necesidades, a sus cercanos y tratantes, lo que mejoraría su calidad de vida directamente al poder expresar qué cosas están bien o mal y entregar información consistente a sus tratantes sobre su condición y síntomas asociados a su enfermedad, independencia para algunas actividades que tengan que ver con el control de su entorno; como prender la luz o la televisión, el manejo de un computador, pedir ayuda e informar concretamente lo que necesita. En cuanto a la terapia cognitiva, al permitir la comunicación efectiva se podrían realizar terapias de tipo psicológicas, logrando evaluaciones consistentes y terapias con respuestas claras, que indicarían realmente lo que puede hacer y sentir el paciente sobre su proceso de rehabilitación.

---

## **CONCLUSIONES GENERALES**

---

En este trabajo se ha realizado en primer lugar un estudio de las investigaciones más importantes en el campo de los BCI. Este estudio ha permitido conocer el funcionamiento de los BCI así como las técnicas empleadas para su diseño. En las últimas dos décadas se han logrado avances muy importantes que han permitido desarrollar BCI que detectan las intenciones del usuario con una precisión bastante aceptable. Se ha revisado una amplia variedad de características de la señal y algoritmos de clasificación en el diseño BCI. Después de realizar el estudio de las investigaciones más recientes en el campo de los BCI, se ha llevado a cabo un estudio pormenorizado de varios métodos que se pueden aplicar a la etapa de clasificación de características. Para este estudio se han empleado las señales que se proporcionan en el conjunto de datos 2b de la competición BCI de 2008. Estas señales han sido adquiridas mediante EEG y recogen ritmos sensoriomotores generados por 9 sujetos diferentes. El estudio de diferentes métodos de clasificación de propiedades de señales EEG en BCI basados en ritmos sensoriomotores comienza con el estudio del método de clasificación NBPW aplicado por el ganador de la competición. Luego se proponen un conjunto de métodos alternativos como el análisis discriminante lineal, la máquina de soporte vectorial, el perceptrón multicapa, y la red probabilística de Parzen.

Teniendo en cuenta los resultados obtenidos mediante la replicación del método ganador de la competición y no los publicados por los organizadores de la competición, los resultados indican que los clasificadores propuestos como alternativas al NBPW

superan a éste pero no proporcionan una mejora significativa del rendimiento. El perceptrón multicapa no consigue superar el rendimiento de NBPW, la red probabilística de Parzen y SVM consiguen mejorar el rendimiento en 3.8%, el LDA en 1.9% en cuanto a valores predictivos positivos y negativos en la clasificación de tareas mentales y valores óptimos de especificidad de ésta.

Teniendo en cuenta estos resultados podemos concluir que los métodos seleccionados podrían ser utilizados para evolucionar el exoesqueleto a modo activo ya que, al poder reconocer las diferentes tareas mentales, es posible dar órdenes a un computador para cumplir tareas de dos comandos, como prender o apagar un interruptor, tocar un timbre, responder si o no; por lo que estos clasificadores, podrían servir para comunicarnos con algún paciente con alteraciones severas de movilidad y que no pudiera comunicarse mediante otro medio y/o nos podría ayudar en la calidad de vida de un usuario con discapacidad motora.

## **LÍNEAS FUTURAS DE TRABAJO**

---

Del estudio de los métodos que se pueden aplicar a la etapa de clasificación de características se pueden extraer varias líneas de investigación futuras.

- Una ampliación del número de métodos de clasificación incluyendo otros algoritmos como el clasificador de los vecinos más próximos, modelos ocultos de Markov, árboles de decisión o clasificadores basados en cuantificación del vector de aprendizaje.
- Hacer que los métodos de clasificación tengan en cuenta información de las señales a lo largo del tiempo. En este estudio el clasificador era entrenado para clasificar en un instante de tiempo determinado de la prueba sin tener en cuenta el pasado. Posiblemente si para clasificar una prueba en un instante de tiempo se tuvieran en cuenta muestras anteriores en el tiempo podría mejorarse el rendimiento.
- Los métodos de clasificación que se han aplicado en el estudio no son adaptativos. Varios estudios ya apuntan a que el empleo de métodos adaptativos podría mejorar sustancialmente la precisión.
- Se puede intentar mejorar el rendimiento creando comités de clasificadores. Si se tiene en cuenta la decisión de varios clasificadores creando un sistema de votación entre varios clasificadores se podrían evitar algunos errores de clasificación.

---

**BIBLIOGRAFÍA**

---

- [1] Cuba. Centro Nacional de Información de Ciencias Médicas. Biblioteca Médica Nacional. Accidente Cerebrovascular. Estadísticas Mundiales. Factográfico salud. 2017 Oct [citado: 06/09/2018];3(12):[aprox. 13 p.]. Disponible en: <http://files.sld.cu/bmn/files/2017/12/factografico-de-salud-diciembre-2017.pdf>
- [2] HeartDisease and StrokeStatistics - 2018 Update: A Reportfromthe American HeartAssociation. Circulation. 2018 [citado: 20/11/2018];137:e67-e492. Disponible en: <https://doi.org/10.1161/CIR.0000000000000558>
- [3] Anuario estadístico de salud año 2014. Dirección de estadísticas y registros médicos. Ministerio de Salud Pública de la República de Cuba. La Habana, 2015
- [4] C. Senanayake y A. Senanayake, «Emerging robotics devices for therapeutic rehabilitation of the lower extremity,» IEEE Xplore, pp. 1142-1147, 2009.
- [5] A. Khairul y A.-J. Adel Ali, «Active Exoskelton Control Systems: State of the Art,» ScienceDirect, vol. 41, pp. 955-994, 2012.
- [6] M. A. Chávez Cardona, F. Rodríguez Spitia y A. Baradica López, «Exoesqueletos para potenciar las capacidades humanas y apoyar la rehabilitación,» Revista Ingeniería Biomédica, vol. 4, nº 7, pp. 63-73, 2010.
- [7] Torres M et al. (2014) Robotic Training SystemforUpperLimbRehabilitation. Ingeniería y Universidad, 18(2) p 235-252.
- [8] Müller-Putz, G. R., Ofner, P., Kaiser, V., Clauzel, G., &Neuper, C. (2011, August). Brisk movement imagination for the non-invasive control of neuroprostheses: a first attempt. In *Engineering in Medicine and Biology*



*Society, EMBC, 2011 Annual International Conference of the IEEE* (pp. 4219-4222). IEEE.

[9] Bhattacharyya, S., Hossain, M. A., Konar, A., Tibarewala, D. N., & Ramadoss, J. (2014). Detection of Fast and Slow Hand Movements from Motor Imagery EEG Signals. In *Advanced Computing, Networking and Informatics-Volume 1* (pp. 645-652). Springer International Publishing.

[10] Mohamed, A. K., Marwala, T., & John, L. R. (2011, August). Single-trial EEG discrimination between wrist and finger movement imagery and execution in a sensorimotor BCI. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE* (pp. 6289-6293). IEEE.

[11] Kim, J. H., Chavarriaga, R., Millan, D. R., & Lee, S. W. (2013, February). Three-dimensional upper limb movement decoding from EEG signals. In *Brain Computer Interface (BCI), 2013 International Winter Workshop on* (pp. 109-111). IEEE.

[12] Hashimoto, Y., Ushiba, J., Kimura, A., Liu, M., & Tomita, Y. (2010). Correlation between EEG-EMG coherence during isometric contraction and its imaginary execution. *Acta NeurobiolExp (Wars)*, 70(1), 76-85

[13] Fok, S., Schwartz, R., Wronkiewicz, M., Holmes, C., Zhang, J., Somers, T., ... & Leuthardt, E. (2011, August). An EEG-based brain computer interface for rehabilitation and restoration of hand control following stroke using ipsilateral cortical physiology. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE* (pp. 6277-6280). IEEE.

- [14] Ono, T., Kimura, A., & Ushiba, J. (2013). Daily training with realistic visual feedback improves reproducibility of event-related desynchronisation following hand motor imagery. *Clinical Neurophysiology*, 124(9), 1779-1786.
- [15] Serrezuela, R. R., Quezada, M. T., Zayas, M. H., Pedrón, A. M., Hermosilla, D. M., & Zamora, R. S. (2020) Robotic therapy for the hemiplegic shoulder pain: a pilot study. *Journal of Neuro Engineering and Rehabilitation*, 17(1) p 1-12.
- [16] Shedeed, H. A., Issa, M. F., & El-Sayed, S. M. (2013, November). Brain EEG signal processing for controlling a robotic arm. In *Computer Engineering & Systems (ICCES), 2013 8th International Conference on* (pp. 152-157). IEEE.
- [17] Organización Mundial de la Salud, «Discapacidades,» [En línea]. Available: <http://www.who.int/topics/disabilities/es/>. [Último acceso: 03 Febrero 2019].
- [18] A. F. A. Bernabé, Sistema mecatrónico para rehabilitación de pacientes con parálisis total o parcial en miembros superiores, Lima, Perú: Pontificia Universidad Católica del Perú, 2015.
- [19] J. J. C. Armas, Diseño de un exoesqueleto de mano basado en músculos activos artificiales (EAP) de dos dedos para ayuda en la vida diaria, Lima, Perú: Pontificia Universidad Católica del Perú, 2016.
- [20] D. Purves, G. J. Augustine, D. Fitzpatrick, W. C. Hall, A. S. Lamantia, J. O. Mcnamara y M. S. Williams, *Neurociencia*, Buenos Aires, Bogotá, Caracas, Madrid, Mexico, Sao Paulo: Editorial Médica Panamericana, 2008.

- [21] E. Cardo, S. Casanovas, G. De la Banda y M. Servera, «Signos neurológicos blandos: ¿tienen alguna utilidad en la evaluación y diagnóstico del trastorno por déficit de atención/hiperactividad?,» *RevueNeurologique*, vol. 46, 2008.
- [22] A. Khairul y A.-J. Adel Ali, «Active Exoskelton Control Systems: State of the Art,» *ScienceDirect*, vol. 41, pp. 955-994, 2012.
- [23] M. A. Chávez Cardona, F. Rodríguez Spitia y A. Baradica López, «Exoesqueletos para potenciar las capacidades humanas y apoyar la rehabilitación,» *Revista Ingeniería Biomédica*, vol. 4, nº 7, pp. 63-73, 2010.
- [24] J. L. Pons, *Wearable robots: Biomechatronic exoskeleton*, England: John Wiley Editorial, 2008
- [25] CYBERDYNE, «ABOUT US,» [Enlínea]. Available: <https://www.cyberdyne.jp/english/company/Recruit.html>. [Último acceso: 6 Febrero 2019].
- [26] G. Dragos, «smashingrobotics,» *How Hybrid Assistive Limb (HAL) Exoskeleton Suit Works*, 12 Junio 2014. [En línea]. Available: <https://www.smashingrobotics.com/how-hybrid-assistivelimb-hal-exoskeleton-suit-works/>. [Últimoacceso: 6 Febrero 2019].
- [27] P. Fanning, «Eureka!,» *Bionic exoskeleton could transform lives of paraplegics*, 11 Octubre 2012. [En línea]. Available: <http://www.eurekamagazine.co.uk/design-engineeringfeatures/technology/bionic-exoskeleton-could-transform-lives-of-paraplegics/45464/>. [Últimoacceso: 6 Febrero 2019].
- [28] ReWalk: More Than Walking, «About ReWalk Robotics,» [Enlínea]. Available: <http://rewalk.com/about-us/>. [Últimoacceso: 6 Febrero 2017].

- [29] M. Talaty, A. Esquenazi y J. E. Briceno, «Differentiating ability in users of the ReWalk powered exoskeleton: an analysis of walking kinematics,» IEEE Xplore, 2013.
- [30] Hocoma, «ABOUT US,» [En línea]. Available: <https://www.hocoma.com/usa/us/aboutus/company/>. [Último acceso: 6 Febrero 2019].
- [31] Blankertz, B.; Muller, K.R.; Curio, G.; Vaughan, T.M.; Schalk, G.; Wolpaw, J.R.; Schlogl, A.; Neuper, C.; Pfurtscheller, G.; Hinterberger, T.; Schroder, M.; Birbaumer, N. The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials. IEEE Trans. Biomed. Eng. 2004, 51, 1044-1051.
- [32] N. Neckel, W. Wisman y J. Hidler, «Limb Alignment and Kinematics Inside a Lokomat Robotic Orthosis,» IEEE Xplore, pp. 2698-2701, 2006.
- [33] ETHzurich, «Sensory-Motor Systems Lab,» [Enlínea]. Available: <http://www.sms.hest.ethz.ch/research/current-research-projects/lower-limb-exoskeletonsand-exosuits/lokomat-gait-rehabilitation-robot.html>. [Último acceso: 6 Febrero 2019].
- [34] REX BIONICS, «PRODUCT INFO,» [En línea]. Available: <http://www.rexbionics.com/productinformation/>. [Último acceso: 6 Febrero 2019].
- [35] S. Franco Dominquez, «Rehabilitación Blog,» 20 Julio 2010. [En línea]. Available: <http://www.rehabilitacionblog.com/2010/07/rex-bionics-exoesqueleto-robotico-para.html>. [Último acceso: 6 Febrero 2019].
- [36] G. Barbareschi, R. Richards, M. Thornton, T. Carlson y C. Holloway, «Statically vs dynamically balanced gait: Analysis of a robotic exoskeleton compared with a human,» IEEE Xplore, pp. 6728-6731, 2015

- [37] Lotte, F.; Congedo, M.; Lecuyer, A.; Lamarche, F.; Arnaldi, B. A review of classification algorithms for EEG-based brain–computer interfaces. *J. Neural Eng.* 2007, 4, R1.
- [38] McFarland, D.J.; Wolpaw, J.R. Sensorimotor rhythm-based brain-computer interface (BCI): feature selection by regression improves performance. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2005, 13, 372-379.
- [39] Leeb, R.; Brunner, C.; Müller-Putz, G.; Schlögl, A.; Pfurtscheller, G. BCI Competition 2008–Graz data set B. 2009.
- [40] Brunner, C.; Leeb, R.; Müller-Putz, G.; Schlögl, A.; Pfurtscheller, G. BCI Competition 2008–Graz data set A. 2008.
- [41] Millan, J.R.; Mourino, J. Asynchronous BCI and local neural classifiers: an overview of the adaptive brain interface project. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2003, 11, 159-161.
- [42] Galán, F.; Nuttin, M.; Lew, E.; Ferrez, P.W.; Vanacker, G.; Philips, J.; Millán, J.d.R. A Brain-Actuated Wheelchair: Asynchronous and Non-Invasive Brain-Computer Interfaces for Continuous Control of Robots. *Clin. Neurophysiol.* 2008, 119, 2159-2169.
- [43] Pradeep, S.; et al. Towards adaptive classification for BCI. *J. Neural Eng.* 2006, 3, R13.
- [44] Li, Y.; Guan, C.; Li, H.; Chin, Z. A self-training semi-supervised SVM algorithm and its application in an EEG-based brain computer interface speller system. *Pattern Recogn. Lett.* 2008, 29, 1285-1294.
- [45] Vidaurre, C.; Sannelli, C.; Müller, K.-R.; Blankertz, B. Machine-Learning-Based Coadaptive Calibration for Brain-Computer Interfaces. *Neural Comput.* 2010, 23, 7918-16.

- [46] Buttfeld, A.; Ferrez, P.W.; Millán, J.d.R., Online Classifier Adaptation in High Frequency EEG. In Proceedings of the 3rd International Brain-Computer Interface Workshop & Training Course 2006, 2006.
- [47] Shijian, L.; Cuntai, G.; Haihong, Z. Unsupervised Brain Computer Interface Based on Intersubject Information and Online Adaptation. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2009, 17, 135-145.
- [48] Ferrez, P.W.; del R. Millan, J. Error-Related EEG Potentials Generated During Simulated Brain Computer Interaction. *IEEE Trans. Biomed. Eng.* 2008, 55, 923-929.
- [49]. Millan, J.R. On the need for on-line learning in brain-computer interfaces. In Proceedings of the IEEE International Joint Conference on Neural Networks, (IJCNN'04), Budapest, Hungary, July 2004; pp. 2877-2882.
- [50]. Jain, A.K.; Duijn, R.P.W.; Jianchang, M. Statistical pattern recognition: a review. *IEEE Trans. Pattern Anal.* 2000, 22, 4-37.
- [51] Muller, K.R.; Anderson, C.W.; Birch, G.E. Linear and nonlinear methods for braincomputer interfaces. 2003, 11, 165-169
- [53] Leeb, R.; Brunner, C.; Müller-Putz, G.; Schlögl, A.; Pfurtscheller, G. BCI Competition 2008–Graz data set B. 2008.
- [54] Leeb, R.; Lee, F.; Keinrath, C.; Scherer, R.; Bischof, H.; Pfurtscheller, G. Brain–computercommunication: motivation, aim, and impact of exploring a virtual apartment. 2007, 15, 473-482.
- [55] Kai Keng, A.; Zheng Yang, C.; Haihong, Z.; Cuntai, G. Filter Bank Common Spatial Pattern (FBCSP) algorithm using online adaptive and semi-supervised learning. In

Proceedings of the The 2011 International Joint Conference on Neural Networks (IJCNN'11), , San Jose, CA, USA, July 31-Aug. 5 2011; pp. 392-396.

[56] Kai Keng, A.; Chai, Q. Rough set-based neuro-fuzzy system. In Proceedings of the International Joint Conference on Neural Networks, 2006 (IJCNN '06), Vancouver, BC, Canada, 16-21 July 2006; pp. 742-749.

[57] Ang, K.K.; Chin, Z.Y.; Wang, C.; Guan, C.; Zhang, H. Filter Bank Common Spatial Pattern algorithm on BCI Competition IV Datasets 2a and 2b. *Front. Neurosci.* 2012, 6.

[58] Garrett, D.; Peterson, D.A.; Anderson, C.W.; Thaut, M.H. Comparison of linear, nonlinear, and featureselectionmethodsfor EEG signalclassification. 2003, 11, 141-144.

[59] Muller, K.R.; Anderson, C.W.; Birch, G.E. Linear and nonlinearmethodsforbrain-computer interfaces. 2003, 11, 165-169.

[60] Burges, C.J.C. A Tutorial onSupport Vector Machines forPatternRecognition. *Data Min. Knowl. Discov.* 1998, 2, 121-167

[61] Haihong, Z.; Cuntai, G.; Chuanchu, W. Asynchronous P300-Based Brain-Computer Interfaces: A ComputationalApproachWithStatisticalModels. *IEEE Trans. Biomed. Eng.* 2008, 55, 1754-1763. 18

[62] Palaniappan, R. BrainComputer Interface DesignUsing Band PowersExtractedDuring Mental Tasks. In Proceedings of the Neural Engineering, 2005. ConferenceProceedings. 2nd International IEEE EMBS Conferenceon, 16-19 March 2005 2005; pp. 321-324

[63] Specht, D.F. Probabilistic neural networks. *Neural. Netw.* 1990, 3, 109-118.

- [64] Hazrati, M.K.; Erfanian, A. An online EEG-based brain-computer interface for controlling hand grasping using an adaptive probabilistic neural network. 2010, 32, 730-739.
- [65] Bishop, C.M. Neural networks for pattern recognition, Oxford University Press: 1995.
- [66] Schlögl, A.; Lee, F.; Bischof, H.; Pfurtscheller, G. Characterization of four-class motor imagery EEG data for the BCI-competition 2005. J. Neural Eng. 2005, 2, L14.
- [67] Schlogl, A.; Keinrath, C.; Scherer, R.; Furtcheller, P. Information transfer of an EEG based brain computer interface. In Proceedings of the First International IEEE EMBS Conference on Neural Engineering (NER'03). 20-22 March 2003; pp. 641-644
- [68] Wu, W.; Gao, Y.; Bienenstock, E.; Donoghue, J.P.; Black, M.J. Bayesian Population Decoding of Motor Cortical Activity Using a Kalman Filter. Neural Comput. 2006, 18, 80-118.
- [69] Lal, T.N.; Schörder, M.; Hill, N.J.; Preissl, H.; Hinterberger, T.; Mellinger, J.; Bogdan, M.; Rosenstiel, W.; Hofmann, T.; Birbaumer, N.; Schalkopf, B., A brain computer interface with online feedback based on magnetoencephalography. In Proceedings of the 22nd international conference on Machine learning, ACM: Bonn, Germany, 2005; pp 465-472.
- [70] Obermaier, B.; Neuper, C.; Guger, C.; Pfurtscheller, G. Information transfer rate in a five classes brain-computer interface. IEEE Trans. Neural Syst. Rehabil. Eng. 2001, 9, 283-288.
- [71] Ang, K.K.; Chin, Z.Y.; Wang, C.; Guan, C.; Zhang, H. Filter Bank Common Spatial Pattern algorithm on BCI Competition IV Datasets 2a and 2b. Front. Neurosci. 2012, 6.



---

**ANEXOS**


---

**ANEXO 1**
**ANUARIO ESTADÍSTICO DE SALUD, EN SU EDICIÓN 2020**
**Tabla 1.** Distribución de pacientes con enfermedad cerebrovascular según grupos de edades y sexo

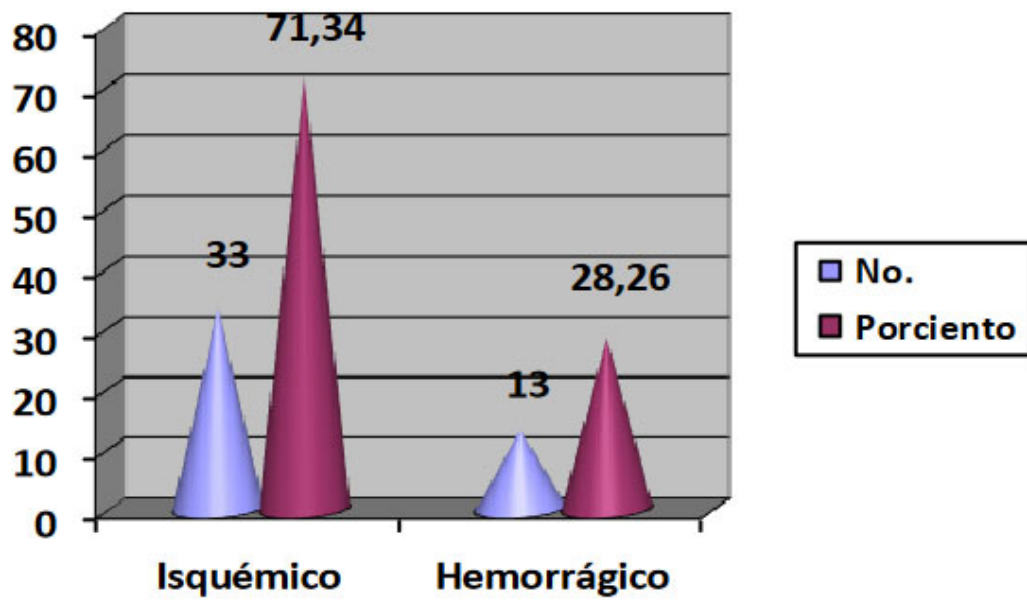
Grupo de Edades (Años)	Femenino		Masculino		Total	
	No.	%	No.	%	No.	%
Menor de 50	0	0	3	6.52	3	6.52
50 a 59	2	4.34	3	6.52	5	10.86
60 a 69	3	6.52	5	10.86	8	17.39
70 a 79	7	15.21	9	19.56	16	34.79
80 y más	6	13.04	8	17.39	14	30.43
Total	18	39.13	28	60.87	46	100

Los factores de riesgo para la enfermedad cerebrovascular que más se registraron fueron la hipertensión arterial (80.43%), el tabaquismo (76.08%), el sedentarismo (69.56%) y la mal nutrición por exceso (sobrepesos y obesos) (65.21%). La relación de los factores de riesgo con el sexo, obtuvo que excepto en la obesidad, todos los factores de riesgo fueron más frecuente en el sexo masculino, tabla 2

**Tabla 2.** Factores de riesgo presentes en los pacientes según sexo

Factores de riesgo	Femenino		Masculino		Total	
	No.	%	No.	%	No.	%
Hipertensión arterial	16	34.78	21	45.65	37	80.43
Tabaquismo	12	26.08	23	50	35	76.08
Sedentarismo	14	30.43	18	39.13	32	69.56
Obesidad	17	36.95	13	28.26	30	65.21
Enfermedad Cardíaca	10	21.73	13	28.26	23	50
Dislipidemia	9	19.56	12	26.08	21	45.65
Diabetes Mellitus	9	19.56	11	23.91	20	43.47
Alcoholismo	1	2.17	11	23.91	12	26.08
Antecedente personal de Ictus	3	6.52	5	10.86	8	17.39
Antecedente familiar de Ictus	1	2.17	4	8.69	5	10.86

Existió un predominio dentro de Las formas clínicas de la enfermedad cerebrovascular, isquémicos con 71.34 %, gráfico 1



**Gráfico 1.** Formas clínicas de la enfermedad cerebrovascular