

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

Escuela de Posgrado



PONTIFICIA
UNIVERSIDAD
CATÓLICA
DEL PERÚ

INFLUENCIA DE LA RETROALIMENTACIÓN VISUAL EN EL
CONTROL DE UNA INTERFAZ CEREBRO COMPUTADOR
MEDIANTE IMAGINACIÓN MOTORA

Tesis para optar al grado de Magister en Ingeniería Mecatrónica

Presentado por:

PAUL DAVID ALVAREZ HERRERA

Asesorado por:

M.Sc. DAVID ACHANCCARAY DÍAZ

Febrero 2017

Lima - Perú



© 2017, Paul David Alvarez Herrera

Se autoriza la reproducción total o parcial,
con fines académicos a través de cualquier
medio o procedimiento, incluyendo la cita
bibliográfica del documento.

RESUMEN

La retroalimentación juega un papel fundamental en varios tipos de sistemas basados en Interfaces Cerebro Computador (BCI), ésta permite que el usuario aprenda a modular cierto tipo de ondas cerebrales que luego serán usadas como base para un sistema de control. En la presente tesis se desarrolla un sistema BCI que usa el principio de Imaginación Motora en el cual se comparan y evalúan tres estrategias de retroalimentación visual: el movimiento de una barra en una pantalla, animación 3D de manos en una pantalla y el movimiento de manos robóticas. En el desarrollo de este sistema se contemplan las siguientes etapas: Adquisición de señales, preprocesamiento de señales, extracción y selección de características, clasificación y retroalimentación al sujeto.

En el presente trabajo se utiliza la técnica de análisis de componentes independientes, la cual provee un filtro espacial que busca recuperar la independencia de las señales. Se utilizan como características las energías de las señales y se clasifica mediante una máquina de soporte vectorial. El procesamiento se realiza en tiempo real en el entorno de Simulink.

Los resultados indican que la retroalimentación visual mediante manos robóticas influye positivamente en mayor medida que la retroalimentación mediante animación, sin embargo, estos resultados deben ser validados con una cantidad mayor de sujetos.



A mis padres

AGRADECIMIENTOS

Al Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica - CONCYTEC y a la Pontificia Universidad Católica del Perú por el otorgamiento de la Beca de Maestría.

A mi asesor, David Achanccaray, por su guía a lo largo de todo este trabajo.



INDICE DE CONTENIDO

	Pág.
RESUMEN.....	1
AGRADECIMIENTOS.....	3
I. INTRODUCCIÓN.....	5
1.1. Objetivos.....	9
1.1.1. Objetivo General.....	9
1.1.2. Objetivos Específicos.....	10
1.1.3. Alcances.....	10
II. ESTADO DEL ARTE.....	12
2.1. Hardware y configuración de electrodos.....	12
2.2. Procesamiento de las señales EEG.....	13
2.3. Retroalimentación visual.....	14
III. DESCRIPCIÓN DEL SISTEMA Y MÉTODOS.....	20
3.1. Descripción General del Sistema.....	20
3.2. Sujetos de Prueba.....	21
3.3. Adquisición de Señales EEG.....	22
3.4. Paradigma Experimental y Sesiones.....	27
3.5. Preprocesamiento.....	30
3.6. Extracción y Selección de Características.....	43
3.7. Clasificación.....	48
3.8. Retroalimentación.....	50
3.9. Integración del Sistema.....	51
3.10. Medidas para la Evaluación del Desempeño.....	57
IV. RESULTADOS.....	59
CONCLUSIONES.....	64
BIBLIOGRAFIA.....	66

CAPÍTULO I

INTRODUCCIÓN

Una Interfaz Cerebro Computador o BCI (del inglés *Brain Computer Interface*), es un sistema que mide las señales cerebrales y luego las procesa mediante un ordenador con la finalidad de obtener información sobre algún tipo de actividad cerebral. Un dispositivo BCI puede registrar señales eléctricas (señales electroencefalograficas 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].

Se ha probado que las técnicas basadas en el análisis de señales EEG pueden detectar correlación entre la actividad cerebral medida y estímulos visuales, ángulo de la mirada, intenciones voluntarias y estados cognitivos, por tal se han dado lugar diversos tipos de sistemas basados en señales EEG dependiendo de las áreas corticales analizadas, las características extraídas y forma en la cual se provee retroalimentación al sujeto [2].

Las investigaciones hechas en BCIs no invasivos basados en EEG indican la posibilidad de su uso en pacientes, se ha probado su éxito en el control de un cursor, sillas de ruedas, 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, parálisis y amputación. En el caso de una persona amputada, las señales EEG pueden servir para controlar una prótesis, como se puede ver en [3][4][5].

Los diversos paradigmas en BCI pueden dividirse en dos principales categorías: exógenos (evocados) y endógenos (autogenerados). En los primeros, el usuario enfoca su atención en un conjunto de estímulos produciendo una respuesta autónoma o inconsciente que puede ser detectada por el sistema. En los paradigmas endógenos el usuario realiza una tarea mental como imaginar movimientos o canto silente. A diferencia de los paradigmas exógenos, los endógenos requieren de entrenamiento por parte del usuario con el fin de que aprenda a modular sus ondas cerebrales. Éste entrenamiento necesita de retroalimentación, la cual consiste en alguna forma de presentación de las ondas cerebrales. Existen dos enfoques al momento de entrenar al usuario: el primero consiste en asignarle tareas cognitivas específicas, por ejemplo, imaginación motora de la mano. En el segundo enfoque (condicionamiento operante) el usuario es provisto de retroalimentación continua mientras trata de controlar la interface, el usuario puede pensar en cualquier cosa para lograr el resultado deseado. Ésta última, sin embargo, es una técnica difícil de dominar [6].

La retroalimentación es indispensable en ciertos sistemas BCI ya que permite que el cerebro del usuario aprenda a controlar el dispositivo. Se ha demostrado ampliamente que la retroalimentación visual juega un papel clave

en el entrenamiento en BCI así como en otros aprendizajes de habilidades y es el tipo más usado de retroalimentación [18]. Por ejemplo, en [4] encontraron que la retroalimentación visual producía un mejor desempeño comparado con retroalimentación háptica, en la percepción del usuario y modulación de fuerza.

Una de las estrategias frecuentemente usada en los sistemas BCI-EEG es la denominada imaginación motora, en inglés *motor imagery (MI)*; 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 al realizarlo, por tal MI puede ser considerado como un método más natural [1][7]. 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)* [7] (Figura 1.1).

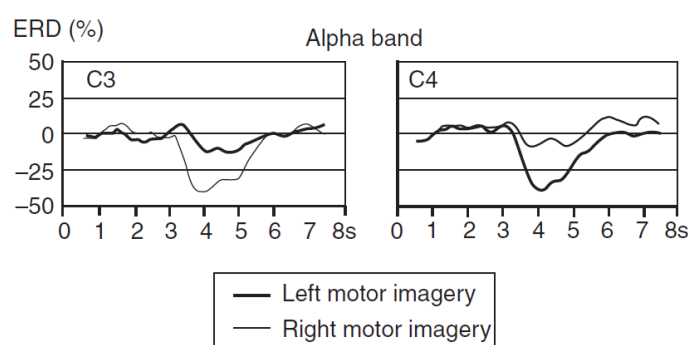


Figura 1.1. ERD en la banda mu (9-13 Hz) durante imaginación motora de las manos, tomadas de los electrodos C3 y C4. Fuente: Rao, R. P. [22].

Aunque la mayor parte de estudios sugieren que la realización de la acción produce mejores resultados que la simple imaginación motora, en [5] 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. Información adicional puede ser obtenida de

señales de baja frecuencia (< 1 Hz), como en [16], donde las usaron para decodificar la velocidad del miembro superior, ya que estas señales llevan información sobre el inicio del movimiento, direcciones 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 [23].

El electroencefalógrafo obtiene las señales del cerebro mediante electrodos. Una forma de seleccionar los electrodos a usar es identificando cuales cambian en potencia cuando se oscila entre ciertas condiciones, como de movimiento y 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 tal, antes de la sesión regular con retroalimentación, se lleva a cabo una sesión de selección (*screening*) sin retroalimentación en donde se determinan que montaje y que banda de frecuencia usar [14].

Los estudios realizados en 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.

Generalmente las etapas a desarrollar en un sistema BCI-EEG son:

-Adquisición de señales: Mediante el dispositivo BCI se obtienen las señales EEG en forma digital en un computador.

-Preprocesamiento de señales: Se elimina el ruido, señales artefacto y se limita el ancho de banda de las señales.

-Extracción de características: A partir de las señales EEG se obtiene un conjunto de valores numéricos, que representan la información de interés sobre estas señales.

-Clasificación: A partir de las características extraídas, el sistema las clasifica en las diversas clases que se pretenden diferenciar.

-Envío de señales a los actuadores: Luego de definidas las acciones a realizar por los actuadores, se envían las órdenes a éstos.

-Retroalimentación al sujeto: El sujeto recibe retroalimentación con la finalidad de que su cerebro pueda aprender a manejar el sistema.

1.1. Objetivos

1.1.1. Objetivo General

Desarrollar un sistema de procesamiento en tiempo real de señales electroencefalográficas y evaluarlo para diferentes tipos de retroalimentación visual.

1.1.2. Objetivos Específicos

- Determinar y comprender el funcionamiento del hardware necesario para la adquisición de las señales electroencefalográficas.
- Desarrollar e implementar técnicas de pre-procesamiento de las señales electroencefalográficas.
- Desarrollar e implementar algoritmos para la extracción de características a partir de las señales electroencefalográficas pre-procesadas.
- Desarrollar e implementar algoritmos para clasificar las características extraídas y producir los comandos para el control del sistema.
- Establecer e implementar tres estrategias de retroalimentación visual: el movimiento de una barra en una pantalla, animación 3D de manos en una pantalla y el movimiento de manos robóticas.
- Establecer la secuencia y forma de los experimentos.
- Establecer y aplicar un método para la evaluación de los resultados experimentales.

1.1.3. Alcances

El desarrollo e implementación del hardware necesario para adquirir señales EEG puede llegar a tomar muchas horas-hombre, además, en el mercado y entorno local existen múltiples opciones para tal fin, es por ello que

el presente trabajo no contempla el desarrollo de tal equipo, sino más bien se limita al entendimiento y aplicación de éste.

Aunque un sistema BCI tiene como objetivo ayudar a sujetos con problemas motores, es posible desarrollar y evaluar sistemas BCI solo con datos recolectados de pacientes sanos aprovechando la mayor disponibilidad de estos. Por ello, en el desarrollo de esta tesis se limitará a usar sujetos sanos para los experimentos.



CAPÍTULO II

ESTADO DEL ARTE

2.1. Hardware y configuración de electrodos

Entre los dispositivos para adquisición de señales EEG se pueden diferenciar los tipo *gadgets*, que básicamente están destinados a un público amplio, principalmente con fines de entretenimiento tales como Emotiv EPOC [8] o Neurosky [9], mientras que otros están destinados exclusivamente para investigación, éstos tienen un mayor desempeño y son más costosos, por ejemplo, el amplificador g.USBamp de g.tec [10] o el Neurowin de NasanMedicals [11]. Claramente los dispositivos tipo gadget pueden y han sido usados en investigación relacionada con MI, por ejemplo en [3] desarrollaron una mano protética para actividades básicas de tacto, sujeción y liberación usando señales de MI mediante el dispositivo Emotiv EPOC y en [1] desarrollaron un sistema de control de un brazo robot basado también en este dispositivo.

La cantidad de electrodos de un dispositivo BCI-EEG varía, algunos pueden tener poco más de una decena, mientras que otros, pasar la centena. En el caso de MI casi siempre se utilizan menos electrodos de los totales, ya que la mayor parte de la información útil extraíble proviene de la corteza motora. Por ejemplo en [1] utilizaron solamente 4 canales: AF3, F7, F3 y FC5,

asociados a la corteza prefrontal y a la corteza motora suplementaria, y en [12] solo usaron los electrodos F3, F4, C3, C4, P3 y P4, también sobre la corteza motora, mientras que en [4] solo se centraron en los electrodos C3 y C4.

2.2. Procesamiento de las señales EEG

Luego de obtener las señales EEG, es necesario filtrarlas para eliminar ruido y señales artefacto. Se denomina señales artefacto a un conjunto variado de señales ajenas al fenómeno cerebral en estudio, que generan una disminución de la calidad de la señal. En MI generalmente se usan filtros pasabanda de por ejemplo 8 a 30 Hz para este propósito. Otra técnica usada, en este caso para mejorar la relación señal/ruido, es la de Patrones Espaciales Comunes o CSP (del inglés, *Common Spatial Patterns*) [7].

Para el análisis de señal muchos autores han utilizado Matlab, ya que cuenta con múltiples herramientas para ello. Por ejemplo en [3] procesaron las señales EEG con el software Toolbox de MATLAB EEGLab mientras que en [6] utilizaron Matlab y Simulink para crear y ejecutar su paradigma. Una interfaz gráfica de usuario puede ser de utilidad en estos sistemas, en [3] se la desarrolló para la adquisición de datos, procesamiento de señales y entrenamiento mediante animación 3D.

Para la extracción de características es común usar técnicas como Wavelet Transform, Transformada Rápida de Fourier, Análisis de componentes principales, Análisis de componentes independientes (ICA) o Densidad Espectral de Potencia [22].

En la clasificación se usan técnicas como Redes Neuronales Artificiales [1], Análisis discriminante lineal [12][15], K-vecinos más cercanos, Naive Bayesian y Máquinas de Soporte Vectorial. Algunas veces es necesaria una clasificación jerárquica, como en [12], 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 [4] 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.

En la decodificación de las señales cerebrales se han reportado clasificaciones que producen conjuntos de salidas tales como: apertura versus cierre de mano [7], de brazo [1], diferenciación del movimiento de la mano derecha versus la izquierda [12][15] o estado de relajación versus movimiento de manos [4]. También se han podido decodificar velocidades de la mano y del codo [16] o movimientos rápidos y lentos de la mano [12], y en [5] pudieron asociar las señales EEG con movimientos de muñeca y dedo. Otra forma de clasificación fue hecha en [7], donde se diferenciaron 2 clases: cerrado y apertura simple (clase 1) y cerrado y apertura doble (clase 2).

2.3. Retroalimentación visual

Los sistemas BCI tradicionales utilizan retroalimentación en la forma de un punto en movimiento o una barra en una pantalla [17] (Figura 2.1), pero también se han usado otras formas de retroalimentación como animación 3D [3], retroalimentación visual de la prótesis [4] o retroalimentación visual basada en realidad virtual [15], existe evidencia de que un entorno de realidad virtual

mejora el proceso de aprendizaje [25]. En algunos estudios combinan varios tipos de retroalimentación, como en [13] donde usan retroalimentación visual y táctil. En [24] usaron una retroalimentación visual que representaba la actividad cerebral de forma realista (Figura 2.2). Al momento de representar información visual casi continua, por ejemplo, las posiciones de una mano desde que está cerrada hasta que se abre completamente, se pueden usar valores producto de la clasificación, como la Distancia LDA [15][19].




Figura 2.1. Clásica forma de retroalimentación visual. La cruz indica al usuario que la sesión va a iniciar. La flecha roja indica que el usuario realice imaginación motora en la mano izquierda. De acuerdo a, por ejemplo la Distancia LDA, la barra gris va creciendo hasta completar cierto objetivo. Finalmente se recibe una recompensa, en este caso, un rectángulo verde. Fuente: Neuper, C., Scherer, R., Wriessnegger, S., & Pfurtscheller, G. [19].




Figura 2.2. Retroalimentación visual representando la actividad cerebral de forma realista. Fuente: Hwang, H. J., Kwon, K., & Im, C. H. [24].

Existen estudios donde se comparan diversas estrategias de retroalimentación visual. En [20], además de una barra abstracta, implementaron retroalimentación basada en realidad virtual donde el sujeto debía controlar un vehículo evitando los obstáculos. Ellos solo usaron 4 electrodos, anteriores y posteriores a C3 y C4 (Figura 3.2), estas posiciones están ubicadas sobre las áreas motoras. Ellos usaron el protocolo de entrenamiento de Graz BCI a lo largo de 7 sesiones en 3 semanas. El sistema debía discriminar entre 2 tareas mentales: relajación mental e imaginación motora de la mano derecha, encontraron que las técnicas de realidad virtual mejoraron el control del sistema.



Figura 2.3. Retroalimentación visual realista. Fuente: Ono, T., Kimura, A., &Ushiba, J. [14].

En [14] exploraron que tipos de retroalimentación visual promovían un robusto ERD en el entrenamiento de imaginación motora. La retroalimentación visual estuvo basada en el ERD proveniente del córtex sensorimotor contralateral y consistió en la visualización realista de la mano sobre una pantalla, consideraron dos posiciones de la pantalla: a 1 metro enfrente del sujeto y superpuesta sobre la mano real, dando así mayor realismo (Figura

2.3). Usaron 7 electrodos sobre las áreas centroparietales, los participantes generalmente lograron ERS por medio de relajación pasiva y ERD por medio de la imaginación de movimiento de agarre de la mano derecha. Encontraron que los mejores resultados fueron para el caso de la animación superpuesta.

Sin embargo, otros estudios no han encontrado diferencias en el desempeño al comparar diversas estrategias de retroalimentación. En [19] investigaron el impacto de la retroalimentación presentada a través de la visualización del movimiento de agarre de la mano sobre la modulación de los ritmos sensorimotoraes, en comparación con una retroalimentación mediante barra abstracta, diferenciando imaginación motora de la mano derecha versus izquierda. Para ello utilizaron 3 canales bipolares seleccionados de 9 electrodos sobre las posiciones C3, Cz y C4. Sus resultados no muestran diferencias entre los 2 grupos de retroalimentación.

En [21] implementaron el control de vehículo en un juego interactivo 3D como retroalimentación y lo compararon con un método tradicional de control de cursor sin obtener diferencias significativas. En [15] desarrollaron 2 estrategias: barra abstracta y representación de las manos mediante un entorno de realidad virtual; no encontraron diferencias en las tasas de error entre ambos tipos de retroalimentación.

Es importante conocer el efecto del entrenamiento del usuario a través de las sesiones. Los estudios demuestran que el entrenamiento con retroalimentación puede ayudar a conseguir altas exactitudes de clasificación [24].

En [14] encontraron un incremento de ERD y de la exactitud de clasificación luego de 5 días de entrenamiento con retroalimentación visual. En la Figura 2.4 se muestran los resultados de este estudio, se puede apreciar que el ERD es mayor (color azul) luego de los 5 días de entrenamiento para todos los tipos de retroalimentación, pero en especial para el caso congruente. Sin embargo, en [20] no observaron una mejora significativa a lo largo de las sesiones.

Es interesante notar que una retroalimentación visual realista puede presentar desventajas respecto de una convencional. La retroalimentación visual realista presentada para la mano equivocada, producto de una errónea clasificación, dirige la atención del usuario hacia esta mano haciendo que sea más difícil concentrarse en la mano correcta. Una solución a esto puede ser empezar el entrenamiento con una retroalimentación abstracta y luego de conseguir un buen desempeño, pasar a una retroalimentación realista [15].

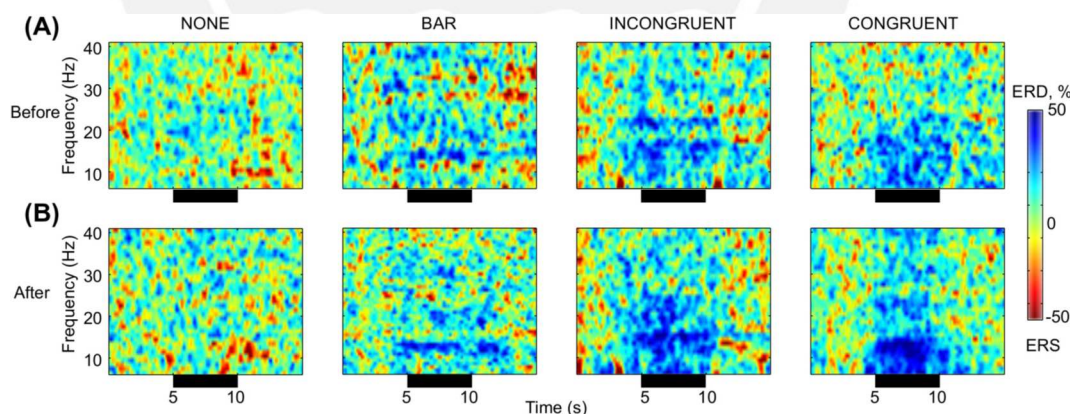


Figura 2.4. ERD antes y después de 5 días de entrenamiento. Fuente: Ono, T., Kimura, A., & Ushiba, J. [14].

En conclusión, 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.



CAPITULO III

DESCRIPCIÓN DEL SISTEMA Y MÉTODOS

3.1. Descripción General del Sistema

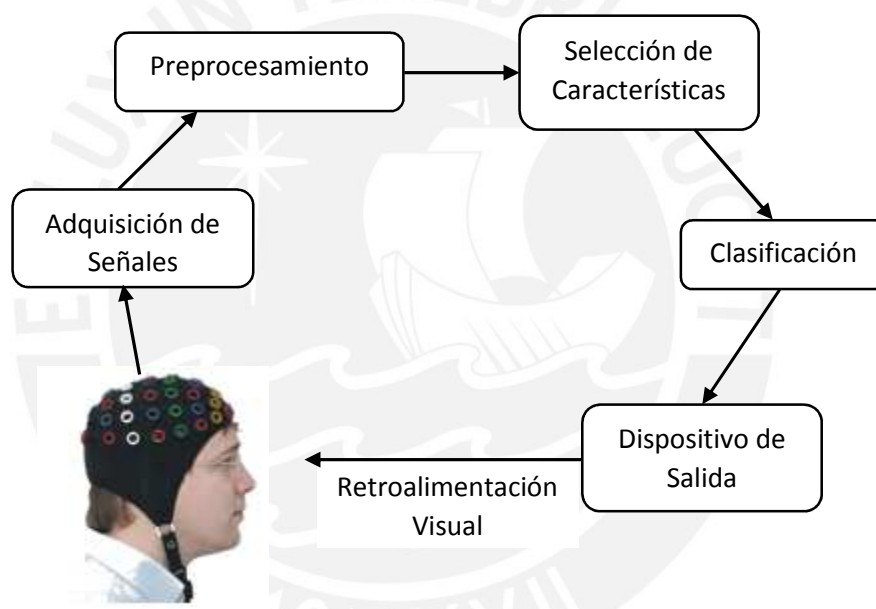


Figura 3.1. Esquema del sistema hombre-máquina. Fuente: Propia.

El sistema se muestra en la Figura 3.1. El primer paso consiste en adquirir/registrar las señales electroencefalograficas, esto se logra mediante los electrodos puestos sobre la cabeza y el amplificador. Estos electrodos deben estar sobre y próximos a las áreas motoras de donde se desea recolectar información, esto se discute en la Sección 3.3. El preprocesamiento consiste en eliminar ruido, señales artefacto y limitar el ancho de banda. En la selección de características se determinan valores numéricos representativos de las

señales cerebrales que a la vez permiten una mayor discriminación entre las diferentes actividades cerebrales a detectar. En la etapa de clasificación se asigna cada muestra de señal a determinada clase o actividad cerebral. En el presente trabajo se diferencian 2 clases: imaginación motora de la mano izquierda y de la mano derecha. El dispositivo de salida tiene la función de representar visualmente los resultados de la clasificación de manera que el sujeto perciba el resultado de sus acciones mentales y pueda aprender a controlar el sistema.

3.2. Sujetos de Prueba

El número de sujetos analizados para un estudio en BCI varía desde uno a varias decenas. Es posible utilizar pocos sujetos cuando se requiere probar nuevas estrategias o pruebas de concepto. Sin embargo, en casos específicamente de comparación es necesaria una cantidad mayor. En los estudios relacionados a este trabajo se puede ver que el número de sujetos usados puede estar en el orden de las decenas aunque también se pueden encontrar números menores. Ya que se implementaron 3 estrategias de retroalimentación y por tal se debieron diferenciar 3 grupos, se decidió tener 5 sujetos por grupo, dando un total de 15 sujetos.

Se admitieron participantes con buena salud y sin historial de enfermedades neurológicas o psicológicas. Ya que la retroalimentación es puramente visual, se consideró deseable que los participantes tengan una visión normal o corregida a normal.

Con la finalidad de tener un grupo más homogéneo y evaluar el aprendizaje en los participantes, se planteó que estos no hayan realizado

experiencias de imaginación motora anteriormente, tanto en BCI como en otras áreas como los deportes. Se les pidió su consentimiento luego de explicarles el procedimiento experimental.

3.3. Adquisición de Señales EEG

De las diversas configuraciones de los electrodos usadas es posible diferenciar dos tipos, en el primero se usan pocos electrodos sobre las áreas motoras y en el segundo, se usan muchos electrodos distribuidos sobre la cabeza. En el segundo caso generalmente es necesario usar filtros espaciales como los Patrones Espaciales Comunes (CSP). Cuando se usan pocos electrodos, al momento de extraer las características, se llevan a cabo procesos de selección de canales y de bandas de frecuencias.

En el presente trabajo se plantea utilizar el Análisis de Componentes Independientes (ICA), el cual genera un filtro espacial que busca recuperar la independencia de las señales. Los principales algoritmos para ICA generan un número de componentes igual al número de canales, así, aplicados a pocos canales, los componentes resultantes seguirán siendo mezclas en vez de reflejar las fuentes individuales [38]. Además, es bien conocido que para múltiples canales, ICA mejora la calidad de la señal. Esto se puede corroborar en muchos estudios, por ejemplo [34] o [39]. Dada la disponibilidad de solo un amplificador de 16 canales, se plantea usar 15 electrodos, lo cual no deja de ser un número apropiado para ICA. La mayoría de estos electrodos están dispuestos sobre las áreas motoras ya que ahí se origina la actividad cerebral de interés.

Diversos estudios muestran que la actividad cerebral producto de la imaginación motora de las manos es detectada con mayor amplitud sobre los

electrodos en las posiciones C3 y C4, así como en electrodos cercanos a éstos [40]. Es usual utilizar electrodos posteriores y anteriores a C3, C4 y Cz a una distancia de entre 2 y 3 cm [14][19]. A partir de lo anterior se decide utilizar los electrodos FC3, FCz, FC4, C3, Cz, C4, CP3, CPz y CP4. Por otro lado en la bibliografía se observa la utilización de ICA generalmente en configuraciones más distribuidas sobre la cabeza y no solo cercanas a C3 y C4, es por ello que se consideró también utilizar los electrodos AF3, AF4, T7, T8, PO3, PO4. La tierra se escogió en Fz y la referencia en A1 (lóbulo de la oreja izquierda), ambas elecciones son usuales en BCI. La configuración planteada se muestra en la Figura 3.2 y el sistema de electrodos colocados en la gorra se muestra en la Figura 3.3.




Figura 3.2. Posición de electrodos en el Sistema Extendido 10-20. En rojo los 15 electrodos activos a usar, en amarillo la tierra y en azul la referencia. Fuente: Adaptado de [32].

Las señales EEG son adquiridas mediante el amplificador g.USBamp [10] y electrodos activos. Se muestrea a una frecuencia de 256Hz, la cual es una frecuencia apropiada considerando que las señales de interés generalmente no pasan los 30 Hz. Se seleccionó el filtro pasabandas entre 5 y 30 Hz integrado en el amplificador con el fin de realizar una primera etapa de procesamiento. También se seleccionó la opción de un filtrado Notch a 60 Hz con la finalidad de disminuir el ruido generado por el suministro eléctrico. A diferencia de los electrodos pasivos, con los electrodos activos no es necesario verificar la impedancia antes de las pruebas, solo basta con aplicar correctamente el gel conductor [33].



Figura 3.3. Sistema de electrodos colocados en la gorra. Ambos productos de g.tec Medical Engineering. Fuente: Propia.

A continuación se describe el protocolo para toma de datos, éste describe la secuencia a seguir para tomar datos (leer señales EEG) del participante. El protocolo es idéntico para las etapas con y sin retroalimentación. La secuencia se detalla a continuación:

1. Colocar los electrodos en gorra: Los electrodos son colocados uno a uno en la gorra de acuerdo a las posiciones definidas (Figura 3.5 (a)).
2. Colocar gorra: Se coloca la gorra con los electrodos sobre la cabeza del paciente
3. Colocar gel: Se aplica gel (Figura 3.5 (b)) entre el cuero cabelludo y los electrodos a través del orificio que presentan estos últimos (Figura 3.5 (c)).
4. Colocar electrodo de referencia: Éste no va unido a la gorra y se coloca en lóbulo de la oreja (Figura 3.5 (d)).
5. Colocar pulsera antiestática. Ésta permite descargar cualquier acumulación de electricidad estática en el cuerpo del participante (Figura 3.4).
6. Encender Amplificador y Controlador de electrodos activos (Figura 3.4).
7. Comprobación básica de electrodos: Se visualizan las ondas alfa, artefactos oculares y todos los canales en general como un medio de comprobación de una buena colocación de electrodos. Para la visualización de las ondas alfa se pide al paciente que se relaje y cierre los ojos, deben mostrarse picos a aproximadamente 10 Hz en los electrodos PO3 y PO4. También se pide a los participantes que pestañeen con la finalidad de observar artefactos oculares en los electrodos AF3 y AF4. Se observan todos los canales restantes con el objetivo de verificar si están funcionando adecuadamente.

8. Dar indicaciones al participante: Se le indica al participante que durante la sesión permanezca relajado, y que evite movimientos de la cabeza y cuello pero principalmente de las manos y brazos. Se propició que los participantes estén lo más cómodo posible, mediante una silla confortable.

9. Colocar tapones para oídos: Estos ayudan a la concentración del participante disminuyendo el ruido del ambiente (Figura 3.4).

10. Tomar datos: Se ejecuta el sistema en Simulink. Éste toma datos, procesa y proporciona la retroalimentación al participante. La toma de datos se realiza mediante sesiones de 5 minutos y cada una consiste en 40 ensayos.

11. Apagar Amplificador y Controlador de electrodos activos.

12. Retirar la gorra de la cabeza.

13. Limpiar gorra y electrodos.

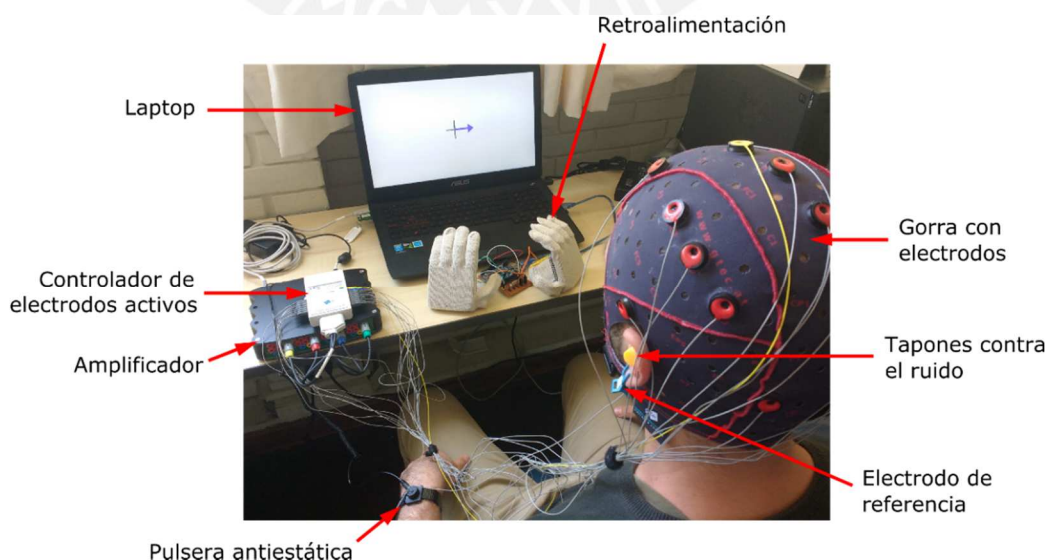


Figura 3.4. Elementos principales para la toma de datos. Fuente: Propia.




Figura 3.5. (a) Colocación de electrodos en gorra. (b) Gel conductivo. (c) Aplicación del gel mediante una jeringa. (d) Electrodo de referencia con gel. Fuente: gGAMMAcap Instructions for use V2.14.00 [33].

Antes de comenzar las sesiones es necesario medir la circunferencia de la cabeza del participante con la finalidad de escoger el tamaño de gorra adecuado.

3.4. Paradigma Experimental y Sesiones

Se desarrollan 2 tipos de sesiones. Las primeras son llamadas “sesiones de selección” ya que se seleccionan las bandas de frecuencias más apropiadas para cada participante, en estas sesiones no se entrega retroalimentación. El segundo tipo de sesiones son las “sesiones con retroalimentación”, aquí se usa la información de las sesiones de selección para proveer una adecuada retroalimentación al participante. La toma de datos para ambos tipos de sesiones se realiza en unidades individuales llamadas “ensayos” (*trials*, en inglés). Cada ensayo dura 7.5 segundos.

Las sesiones de selección están descritas por el esquema temporal de la Figura 3.6. Lo primero que se muestra es una “cruz de fijación” cuyo objetivo es captar la atención del participante con la intención de que se prepare a la señal que vendrá a continuación. Luego, a partir del segundo 1, se muestra una señal con una flecha indicando la tarea de imaginación motora a realizar, si la flecha apunta hacia la izquierda el participante deberá imaginar su mano izquierda abriéndose y cerrándose, y si apunta a la derecha el participante deberá imaginar su mano derecha abriéndose y cerrándose. Esta señal dura 3 segundos y durante este tiempo el participante deberá realizar la tarea mental. Luego de ello se muestra una pantalla en blanco en el que el participante puede descansar.




Figura 3.6. Esquema temporal para cada ensayo en las sesiones de selección. Fuente: Propia.

Las sesiones con retroalimentación están descritas por el esquema temporal de la Figura 3.7. Primero se muestra una “cruz de fijación” y luego se muestra una señal con una flecha indicando la tarea de imaginación motora a realizar, las tareas son iguales a las descritas para la sesión de selección. A partir del segundo 1 se empieza a procesar la señal mediante el algoritmo computacional. Ya que la señal se procesa en bloques de 1 segundo (256 muestras), todavía en el segundo 2 es cuando se muestra la retroalimentación al participante. Con esto se pretende que el participante realice la tarea de

imaginación motora por aproximadamente 4 segundos. Luego de ello se muestra una pantalla en blanco.

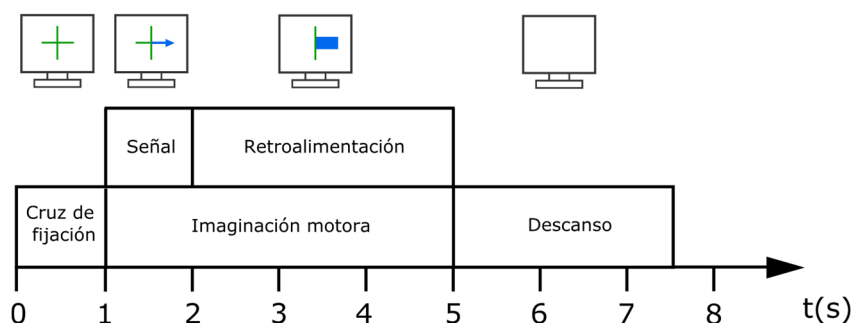


Figura 3.7. Esquema temporal para cada ensayo en las sesiones con retroalimentación. Fuente: Propia.

Se usaron sesiones de 40 ensayos que duran cada una poco más de 5 minutos. Se realizaron un total de 8 sesiones por participante, las primeras 3 de selección y las últimas 5 con retroalimentación, se muestra un diagrama de flujo en la Figura 3.8. En la Figura 3.9 se muestra a un participante en sesión con retroalimentación.

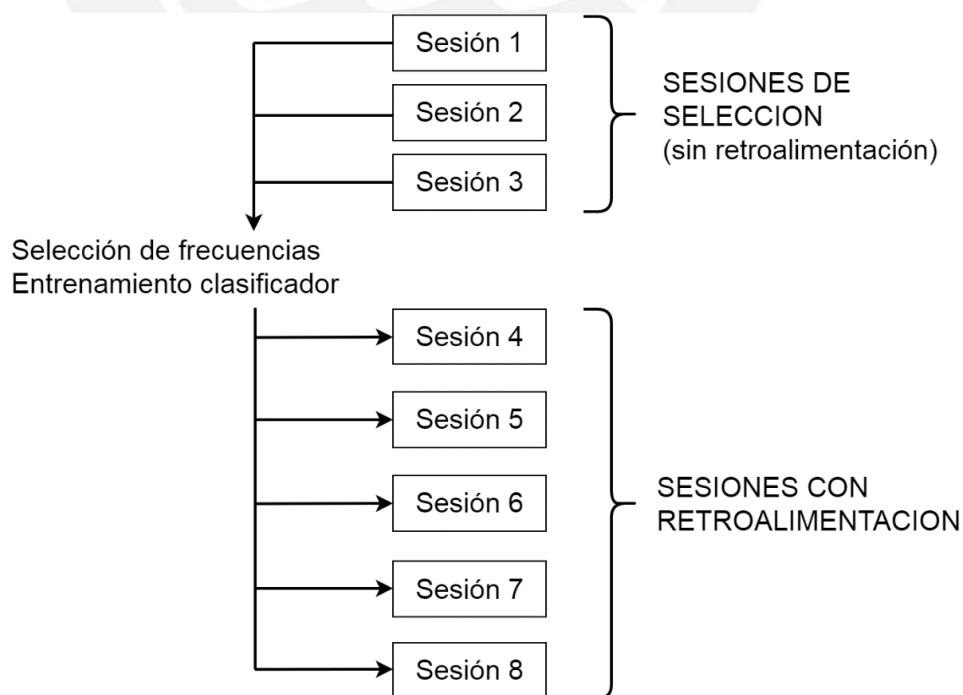


Figura 3.8. Diagrama de flujo de las sesiones. Cada sesión consta de 40 ensayos. Fuente: Propia.




Figura 3.9. Participante en sesión con retroalimentación. Fuente: Propia.

3.5. Preprocesamiento

En imaginación motora las bandas de frecuencias en las que se encuentra información útil son la mu (8-13 Hz) y beta (13-30 Hz), por tal un primer paso es eliminar el resto de frecuencias. Sin embargo, en varios trabajos de investigación se observa el uso de un ancho de banda más amplio cuando se utiliza el Análisis de Componentes Independientes como es este el caso.

Las señales artefacto o simplemente artefactos son señales no deseadas que se originan mayormente fuera del cerebro, pueden tener su origen en alguna otra parte del cuerpo (artefactos fisiológicos) o en el exterior [26]. Ejemplos de artefactos son el ruido de la línea de alimentación (60 Hz), de los dispositivos electrónicos, o por ejemplo señales producidas por músculos o movimientos oculares [26]. Un ejemplo de artefactos que se originan dentro del cerebro pueden ser las ondas visuales alfa cuando afectan sistemas basados en ondas mu [27].

Las señales artefacto pueden cambiar las características de un fenómeno neurológico o incluso ser usadas erróneamente como fuente de control en

sistemas BCI [26]. Cabe señalar que de acuerdo al tipo de paradigma, ciertos tipos de artefactos pueden tener mayor o menor importancia [26]. Algunas de estas señales artefacto pueden ser permisibles o explotadas en aplicaciones de Interacción Humano-Computador (HCI), pero cuando se habla de un sistema BCI puro, estas señales deben ser eliminadas o reducidas [22].

Los artefactos no fisiológicos como el ruido producido por la línea de alimentación (60 Hz) o cambios en la impedancia de los electrodos son evitados mediante un adecuado filtro o blindaje.

Los artefactos fisiológicos, en especial los generados por movimientos de los ojos y del cuerpo son un problema significativo en los sistemas BCI [26]. Los artefactos que se originan dentro del cuerpo del sujeto incluyen los producidos por la respiración y los latidos del corazón (artefactos ECG), distorsión o atenuación debida a los cambios en conductancia de la piel, movimientos oculares y los producidos por parpadeo (artefactos EOG), y artefactos producidos por músculos (artefactos EMG) principalmente generados en zonas cercanas a la cabeza [22]. Estos últimos tienden a ocurrir a 30 Hz o más [26][27] y causan grandes perturbaciones en las señales cerebrales. Incluso, la sudoración de la piel puede alterar la impedancia de los electrodos y causar artefactos [28].

Los artefactos EOG son patrones de alta amplitud causados por el parpadeo o patrones de baja frecuencia causados por movimientos de los ojos [29]. Estos artefactos tienen componentes en bajas frecuencias [26] y son máximos a frecuencias debajo de 4 Hz [27]. En la Figura 3.10 se observan los artefactos oculares producidos al parpadear, fueron captados en el electrodo AF3.




Figura 3.10. Artefactos oculares producidos al parpadear, captados en el electrodo AF3. Se caracterizan por tener alta amplitud y baja frecuencia. Se pueden visualizar como picos en la señal, en la imagen se observan 5 de ellos. Fuente: Propia.

El manejo de los artefactos puede realizarse evitando su ocurrencia mediante instrucciones correctas a los usuarios, por ejemplo pidiéndoles que eviten parpadear o mover su cuerpo durante los experimentos. Tiene la ventaja de tener un mínimo costo computacional pero tiene varias desventajas. Una de ellas es que las señales fisiológicas involuntarias no pueden ser controladas y tampoco es fácil controlar las voluntarias, otra es que estos artefactos pueden ser controlados pero nunca evitados por completo y en sistemas *online* pueden afectar el sistema de forma considerable [26].

Otra forma de manejar los artefactos es mediante su rechazo, es decir, descartando los ensayos contaminados, es realizado usualmente mediante inspección visual o mediante un método automático. El rechazo manual es realizado mediante un experto y tiene la ventaja de no tener una demanda computacional. El rechazo automático puede ser realizado mediante umbralización. Si las señales EMG, EOG o EEG superan cierto umbral,

entonces las muestras son rechazadas. Sin embargo, el método anterior no es muy útil cuando las amplitudes de los artefactos son pequeñas [26]. El umbral puede ser determinado pidiéndole al sujeto que realice diversos movimientos de ojos o corporales con el fin de calibrar el umbral [22]. En los sistemas *online*, la aparición de una muestra contaminada y por tal rechazada genera un periodo de falta de control sobre el sistema.

Una tercera forma de lidiar con los artefactos es mediante su remoción, consiste en identificar el artefacto y removerlo de la señal original, dejando intactas las señales de interés. A continuación se describen los métodos más usados para tal propósito.

Una manera sencilla de lidiar con algunos artefactos es usando un filtro lineal. Éste es útil cuando las bandas de frecuencia de los artefactos no coinciden con las bandas de interés. Un filtro pasabajos puede ser usado para remover artefactos EMG y un pasaaltos para remover artefactos EOG. Los filtros para EOG son exitosos en sistemas que usan características extraídas de componentes de alta frecuencia como los ritmos mu y beta usados en imaginación motora [26]. Los filtros para EMG pueden ser útiles en sistemas donde la señal de interés es de baja frecuencia pero no de gran ayuda cuando se trabaja por ejemplo con los ritmos beta. Por ejemplo, en [1] eliminaron los artefactos mediante un filtro pasabanda Butterworth de orden 5 entre 0.5 y 45 Hz.

También pueden usarse filtros rechaza banda por ejemplo de 59-61 Hz para eliminar el ruido de la línea de energía o de 1-4 Hz para atenuar artefactos EOG. Un filtro de este tipo puede ser realizado transformando la señal al

dominio de la frecuencia, eliminando las bandas no deseadas para luego volver la señal al dominio del tiempo [22].

Una técnica bastante común para eliminar artefactos EOG es mediante el modelamiento lineal [26]:

$$EEG_i^{true}(t) = EEG_i(t) - K \cdot EOG(t) \quad (3.1)$$

Donde $EEG_i(t)$ es la señal contaminada registrada y $EEG_i^{true}(t)$ es la señal libre de artefactos que se desea obtener, ambas para cierto canal i , $EOG(t)$ es la señal EOG registrada y K una constante desconocida [22]. El problema a resolver consiste en estimar K , un método usual es mediante regresión lineal [30]. Aplicar un modelo lineal para los artefactos EMG se hace más difícil ya que estos surgen de múltiples grupos musculares y un modelo con una única señal $EMG(t)$ no sería apropiada [22][26].

Otra manera de remover los artefactos es mediante la Separación Ciega de Fuentes (BSS). Ésta separa la señal en los componentes que la construyen, se identifican los componentes provenientes de artefactos y se reconstruye la señal sin esos componentes [26]. El método BSS más usado es el Análisis de Componentes Independientes (ICA), mayormente para remover artefactos EOG. ICA parte de la hipótesis de que las señales medidas son una combinación lineal de fuentes estadísticamente independientes:

$$\mathbf{x} = M\mathbf{y} \quad (3.2)$$

Donde M es una matriz desconocida y \mathbf{y} es el vector de fuentes independientes. ICA pretende recuperar las fuentes ocultas encontrando una matriz W tal que:

$$\mathbf{a} = W\mathbf{x} \quad (3.3)$$

Donde los componentes de \mathbf{a} tienen la máxima independencia estadística. Cabe señalar que el número de elementos de \mathbf{a} puede ser menor, mayor o igual al número de elementos de \mathbf{x} . Existen varios algoritmos para hallar \mathbf{W} , siendo uno de los más usados el Bell-Sejnowski “infomax” [31].

Otros métodos incluyen el Análisis de Componentes Principales (PCA) el cual es útil en remoción de artefactos EOG, la Transformada Wavelet y filtros adaptativos no lineales. Los artefactos también pueden ser atenuados mediante filtros espaciales, los filtros Common Average Reference (CAR) y Laplaciano largo pueden ser adecuados para sistemas basados en las ondas mu y beta [27]. Existen toolboxes que realizan la remoción de artefactos de manera automática como el Automatic Artifact Removal (AAR) usado a través de EEGLab, éste contiene métodos para la remoción de artefactos EOG y EMG.

En [26] hicieron una revisión sistemática de investigaciones con el fin de conocer los métodos de manejo de artefactos EOG y EMG, encontraron que en las investigaciones basadas en los cambios de los ritmos cerebrales, como en imaginación motora, la gran mayoría usaba el rechazo manual o no mencionaban si abordaban el problema de artefactos. Solo un pequeño porcentaje usó un método automático para el rechazo o remoción de artefactos.

Específicamente, en los estudios enfocados en analizar la influencia de diferentes formas de retroalimentación visual en sistemas BCI, el manejo de artefactos se hizo únicamente en las etapas *offline* mediante inspección visual además de aplicar filtros pasabanda con el fin de aislar las bandas mu y beta [14][15][19][20].

3.5.1. Filtro pasabanda

Un filtro es un elemento que remueve frecuencias no deseadas en una determinada señal. La mayoría de filtros producen cambios en la fase que distorsionan la señal y esta distorsión usualmente aumenta con el orden del filtro. Sin embargo, cuando la información extraída de las señales se basa en la energía en determinadas bandas de frecuencia, tal distorsión no genera mayor inconveniente. La única consideración a tomar es el retraso que genera el filtro, un retraso muy grande puede hacer que el procesamiento de la señal y por tal la retroalimentación no sea tan cercana al tiempo real, y el participante perciba este retraso.

Es usual encontrar filtros tipo Butterworth en muchos trabajos de investigación en sistemas BCI basados en EEG, en el presente trabajo se usó uno de ellos. Éstos están diseñados para tener una respuesta en frecuencia tan plana como sea posible en las frecuencias de pasabanda. Aunque pueden diseñarse filtros Butterworth de Respuesta Finita al Impulso (FIR), los de Respuesta Infinita al Impulso (IIR) generalmente cumplen con las especificaciones con un orden mucho menor y por ello son preferidos.

Se escogió un orden de 14, que es un valor dentro del rango usado en otros trabajos de investigación. Se escogieron las frecuencias a media potencia en 2 y 36 Hz, lo que significa que a esas frecuencias la energía de la señal es atenuada a la mitad. Su respuesta en frecuencia se muestra en la Figura 3.11

En la Figura 3.11 se observa además una atenuación suficiente del ruido del suministro de energía a 60 Hz. Se comprobó con data real que no fue necesario un filtro Notch adicional para filtrar este ruido.

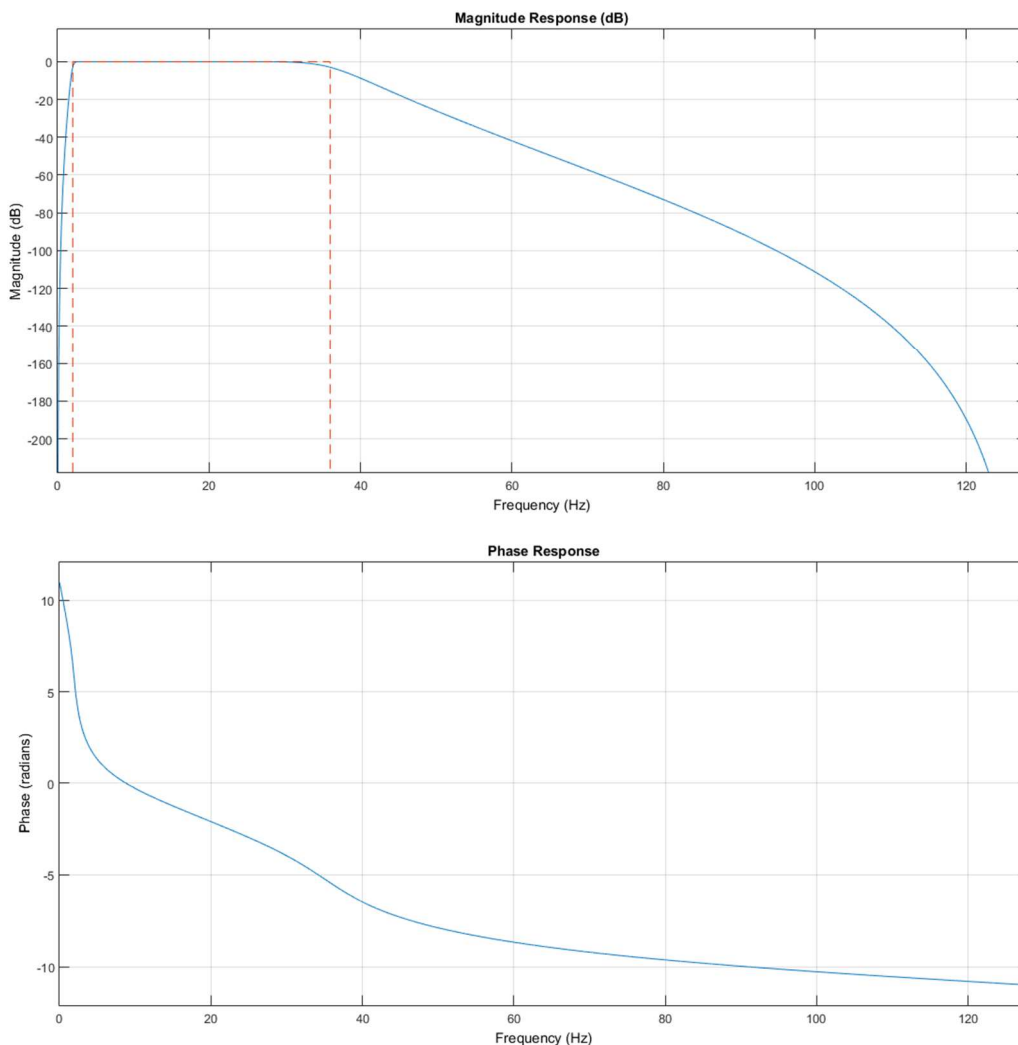


Figura 3.11. Respuesta en frecuencia del filtro IIR pasabandas Butterworth de orden 14 entre las frecuencias de 2 y 36 Hz. Fuente: Propia.

3.5.2. Referencia al Promedio Común (CAR)

Los filtros espaciales, como su nombre lo indica, transforman la señal en el espacio y no en el tiempo como los filtros en frecuencia. La Referencia al Promedio Común es un filtro espacial que ayuda a reducir cierto tipo de artefactos y consiste en restar la media de todos los canales a cada canal. Esto se conoce como re-referenciar, en este caso re-referenciar al promedio común. Por tanto, la señal filtrada debe cumplir, para cada muestra, con:

$$\sum_{i=1}^n s_i(\tau) = 0 \quad (3.4)$$

Donde $s_i(\tau)$ es la muestra en el canal i para el tiempo τ , y n es el número de canales.

3.5.3. Análisis de Componentes Independientes (ICA)

Este método se basa en la hipótesis de que las señales registradas son una mezcla de fuentes cerebrales independientes. Estas señales registradas son sumadas linealmente en los electrodos, además, los retardos en la propagación se consideran despreciables. Una ventaja de este método es que no se requieren canales de referencia para cada fuente.

El problema a resolver consiste en recuperar las fuentes originales. No se sabe nada sobre las fuentes o sobre la manera en que se mezclan:

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (3.5)$$

Donde:

\mathbf{x} : “mezclas” medidas o registradas

\mathbf{A} : Matriz desconocida

\mathbf{s} : Fuentes independientes

El objetivo es encontrar \mathbf{W} (matriz cuadrada) tal que:

$$\mathbf{u} = \mathbf{W}\mathbf{x} \quad (3.6)$$

Donde \mathbf{u} es idéntica (salvo por escalado y permutación) a \mathbf{s} .

El algoritmo planteado por Bell and Sejnowski [31] consiste en una red neuronal y usa la maximización de la información “infomax”:

“La maximización de la entropía conjunta $H(\mathbf{y})$ a la salida de un procesador neural minimiza la información mutua entre los componentes de salida $y_i = g(u_i)$, donde $g(u_i)$ es una no linealidad invertible y acotada, y $\mathbf{u} = \mathbf{W}\mathbf{x}$.”

ICA es efectivo realizando separación de fuentes cuando:

- El medio mezclante es lineal y los retrasos de propagación son despreciables. Se puede asumir que la conducción en medio volumétrico es lineal e instantánea.
- La evolución temporal de las fuentes son independientes. Los artefactos generalmente no están ligados temporalmente a la actividad EEG.
- El número de fuentes es idéntico al número de sensores. Es cuestionable ya que no conocemos el número de fuentes independientes.

Las columnas de la matriz inversa \mathbf{W}^{-1} dan las intensidades proyectadas de las respectivas fuentes sobre los sensores. Así, la topografía de los componentes brinda información sobre la localización de las fuentes [34].

Sea \mathbf{u}' es la matriz de formas de onda \mathbf{u} cuyas filas representando artefactos son hechas cero, entonces, tenemos que las señales “corregidas” EEG son:

$$\mathbf{x}' = \mathbf{W}^{-1}\mathbf{u}' \quad (3.7)$$

Esto ocasiona que el rango de las señales corregidas \mathbf{x}' sea menor al de las señales originales \mathbf{x} .

ICA asegura que los componentes del vector \mathbf{u} tengan una independencia estadística máxima, esto es:

$$f_{\mathbf{u}}(\mathbf{u}) = \prod_{i=1}^N f_{u_i}(u_i) \quad (3.8)$$

Donde $f_{\mathbf{u}}(\mathbf{u})$ es la función de densidad de probabilidad (p.d.f.) de \mathbf{u} . La independencia estadística requiere que todas las correlaciones de mayor orden de u_i sean cero.

La función de densidad de probabilidad conjunta, medida en toda la muestra, se factoriza, y esto es equivalente a decir que la información mutua entre dos fuentes cualesquiera es cero:

$$I(u_1, u_2, \dots, u_N) = E \left[\ln \frac{f_{\mathbf{u}}(\mathbf{u})}{\prod_{i=1}^N f_{u_i}(u_i)} \right] = 0 \quad (3.9)$$

Donde $E[\cdot]$ es el valor esperado. Las “mezclas” observadas x_i 's son estadísticamente dependientes por lo que la información entre cualquier par de muestras $I(x_i, x_j)$ es en general positiva.

El problema a resolver consiste en encontrar una matriz \mathbf{W} , tal que $\mathbf{u} = \mathbf{W}\mathbf{x}$ reestablezca la condición $I(u_i, u_j) = 0$, para todo $i \neq j$. Es necesario proveer estadísticas de alto orden para establecer independencia, por lo que se usa una función no lineal acotada e invertible $g()$ tal que:

$$y_i = g(u_i) \quad (3.10)$$

Consideremos la entropía conjunta de dos componentes de \mathbf{y} :

$$H(y_1, y_2) = H(y_1) + H(y_2) - I(y_1, y_2) \quad (3.11)$$

Maximizar $H(\mathbf{y})$ implica minimizar $I(\mathbf{y})$, en general. Cuando $I(\mathbf{y}) = 0$, las dos variables son estadísticamente independientes. El algoritmo pretende maximizar $H(\mathbf{y})$ de forma iterativa ajustando los elementos de \mathbf{W} . De acuerdo a Bell and Sejnowski [31]:

$$\Delta W \propto \frac{\partial H(\mathbf{y})}{\partial W} W^T W = [I + \varphi u^T] W \quad (3.12)$$

Donde:

$$\varphi_i = \frac{\partial}{\partial u_i} \ln \frac{\partial y_i}{\partial u_i} \quad (3.13)$$

Cuando $g(u)$ es una función sigmoide el algoritmo está limitado a separar fuentes con distribuciones súper-gaussianas. Para fuentes con distribuciones sub-gaussianas o súper-gaussianas se puede utilizar:

$$\Delta W \propto [I - K \tanh(u) u^T - u u^T] W \quad (3.14)$$

Y se escoge $k_i = 1$ para fuentes súper-gaussianas y $k_i = -1$ para fuentes sub-gaussianas. Donde los k_i 's son elementos de la matriz diagonal K de dimensión N . Pueden ser escogidos como [44]:

$$k_i = \text{sign}(E[\text{sech}^2(u_i)] E[u_i^2] - E[\tanh(u_i) u_i]) \quad (3.15)$$

Lo cual asegura estabilidad de la regla de aprendizaje.

ICA tiene varias limitaciones, por ejemplo, solo se puede obtener un número de fuentes igual al número de canales y la actividad cerebral probablemente surge de muchas más fuentes que el número de canales usados. Otro problema es que la selección de componentes generalmente requiere inspección visual, aunque ya se han desarrollado algunos métodos para la identificación automática de ciertos tipos de componentes.

En la aplicación específica de ICA a señales electroencefalograficas, surgen muchos parámetros a considerar y sintonizar, como por ejemplo, la tasa de aprendizaje o un procesamiento previo que muchas veces incluye el operación de *whitening* o Análisis de Componentes Principales. EEGLAB es un toolbox de MATLAB que incluye ICA y está optimizado para su uso en señales electroencefalograficas. En este trabajo se utilizó dicho toolbox, en específico, la función `rúnica`.

La función `rúnica` realiza una descomposición mediante análisis de componentes independientes de la data de entrada. `rúnica` puede correr varios algoritmos, se seleccionó el correspondiente a “Infomax extendido” [44], el cual puede ser usado para fuentes sub-gaussianas y súper-gaussianas. Este algoritmo selecciona los k_i 's según la ecuación 3.15, y usa la regla de aprendizaje dada por la ecuación 3.14.

Como se mencionó anteriormente, las columnas de la matriz \mathbf{W}^{-1} dan las intensidades proyectadas de las respectivas fuentes sobre los electrodos. Es bastante útil graficar estas proyecciones mediante colores en un plano que representa el cráneo con los electrodos. A estas gráficas se le conocen como mapas topográficos, en la Figura 3.12 se muestran los mapas topográficos de 15 fuentes obtenidas de 15 electrodos, dado cierto participante.




Figura 3.12. Mapas topográficos de 15 fuentes encontradas a partir de 15 canales. Ambos extremos, -1 y 1 (azul y rojo oscuro), representan altos valores de las proyecciones de las fuentes. Fuente: Propia.

Cada uno de los 15 mapas de la Figura 3.12 representa el cráneo visto desde arriba donde se aprecian 15 puntos negros, cada uno de ellos representa un electrodo. Cada mapa representa la distribución de las señales de una única fuente a través de los 15 electrodos. Los colores extremos (rojo y azul obscuro) representan altos valores de las proyecciones de las fuentes sobre los electrodos, por ejemplo, si sobre un electrodo se ubica un color rojo oscuro indicando una intensidad de 1, implica que la fuente es detectada con una máxima intensidad en ese electrodo.

Estas gráficas acompañadas de las gráficas de densidad espectral de potencia son muy útiles al momento de identificar componentes.

3.6. Extracción y Selección de Características

La extracción de características consiste tomar valores representativos de un conjunto de datos, en este caso, de una serie temporal. Estos valores son

representativos en el sentido de que nos brindan información útil respecto al fenómeno que estamos analizando. Por otro lado, las características extraídas son un conjunto relativamente pequeño de datos, lo que lo hace adecuado para un clasificador.

Suele suceder que luego de extraerse las características, muchas de ellas pueden no aportar información relevante además de aumentar la dimensionalidad innecesariamente. Es por ello que es necesario reducir el número de características, a esto se le conoce como selección de características y es útil en imaginación motora por el hecho de que las “bandas más reactivas” varían de persona a persona. Las bandas más reactivas son los intervalos de frecuencia donde el fenómeno de ERD/ERS es más fuerte y por tal aportan más información sobre dicho fenómeno.

Varios estudios muestran que las configuraciones bipolares cercanas o sobre los electrodos C3 y C4 son las más indicadas para darnos información sobre imaginación motora. Si consideramos los 6 electrodos: FC3, FC4, C3, C4, CP3, CP4 sobre las áreas motoras, tenemos que podemos formar 6 derivaciones bipolares, éstas son: FC3 - C3, C3 - CP3, FC3 - CP3, FC4 - C4, C4 - CP4 y FC4 - CP4.

Una forma bastante usada para extraer características de éstas señales es mediante un filtrado pasabandas en determinado intervalo de frecuencias y luego hallando la energía de la señal. La energía de la señal es simplemente la varianza de ésta, de la que generalmente luego se toma el logaritmo. Esto se realiza para cada intervalo de frecuencia determinado, y, como no se conoce a priori que intervalos son los que más información aporten, se toma un gran número de intervalos y luego se realiza un proceso de selección. Ya que se

conoce que la actividad de interés se encuentra entre 8 y 30 Hz, se escogen intervalos dentro de ese rango. El ancho del intervalo es variable y se escogen de 3 y 6 Hz, esto implica que tendremos para el ancho de 3 Hz los siguientes intervalos: 8-11, 9-12, ..., 27-30 y para el ancho de 6 Hz: 8-14, 9-15, ..., 24-30. Esto no da un total de 37 intervalos.

3.6.1. Filtrado de la señal

Con la finalidad de obtener la energía en cada intervalo definido en la sección anterior, se realiza un filtrado pasabandas. El filtro tiene las mismas características que el filtro descrito en la sección de preprocesamiento: filtro IIR Butterworth. Sin embargo el orden se consideró menor, de 6, con la finalidad de no causar demasiado retraso en las señales ni aumentar demasiado el costo computacional. Para cada una de las 6 derivaciones se realiza el filtrado con diversos intervalos de frecuencia dando lugar a 222 nuevas señales.

3.6.2. Extracción de características

El fenómeno ERD/ERS es básicamente un cambio en la energía en determinadas bandas de frecuencia, esta energía es estimada usando la varianza, y a estos valores se le aplica el logaritmo con el fin de obtener valores en decibeles. Por tal, dada una señal x de longitud n , la característica extraída está dada por:

$$F_{d,b} = \log_{10} \left(\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \right) \quad (3.16)$$

Donde d es la derivación, b el intervalo de frecuencias y \bar{x} la media. Entonces tendremos un total de 222 características.

3.6.3 Selección de Características

La selección de características consiste en reducir un conjunto relativamente grande de características en uno más pequeño y útil para el clasificador, generalmente un tamaño menor a 10 es usual encontrar en muchos trabajos de investigación relacionados. La selección se basa en una comparación, definida por una “función de criterio”, ésta función nos permite medir la “separabilidad” entre dos clases, es decir, mientras mayor sea el valor de esta función de criterio, mayor será la separación entre clases en el espacio n -dimensional y esto resultará en una mejor clasificación. El problema entonces se reduce a encontrar un subconjunto con la mayor función de criterio.

Encontrar dicho subconjunto analizando todas las combinaciones posibles es muchas veces virtualmente imposible por el alto coste computacional. Lo que se suele hacer es encontrar un subconjunto “sub-óptimo”, es decir, un subconjunto que se aproxime al óptimo sin serlo.

Otra cuestión radica en que muchas funciones criterio son útiles al comparar subconjuntos de un mismo tamaño, pero para subconjuntos de diferente tamaño podrían dejar de reflejar una verdadera comparación entre las separabilidades. Acá se utilizó la llamada Distancia Bhattacharyya, definida por [35]:

$$D_B = \frac{0.5 \log \left(\frac{\det((C_1+C_2)/2)}{\sqrt{\det(C_1) \times \det(C_2)}} \right) + \frac{(M_1-M_2) ((C_1+C_2)/2)^{-1} (M_1-M_2)'}{8}}{n} \quad (3.17)$$

Donde C_1 y C_2 son las matrices de covarianza de las clases 1 y 2, M_1 y M_2 son las medias de las clases 1 y 2, y n es el número de muestras.

Una forma de encontrar el mencionado subconjunto es mediante una búsqueda, un algoritmo popular para ello es el llamado *Sequential Floating Forward Selection* (SFFS). Este algoritmo ejecuta una búsqueda secuencial de características, empieza por un conjunto vacío y va agregando, una a una, características adicionales hasta llegar al número de características deseada. Además tiene la posibilidad de remover alguna característica antes agregada si se verifica que reemplazándola por otra se tiene una separabilidad mayor. El algoritmo fue propuesto por P. Pudil y colegas [36] y está descrito por el seudocódigo de la Figura 3.13.

```

function SFFS( $n, J$ )
begin
 $S := (0, \dots, 0)$ ;
 $k := 0$ ;
 $B := \emptyset$ ;
while  $k < n$ 
 $R := \emptyset$ ;
for each  $\{j \mid S_j = 0\}$ 
 $S' := S$ ;
 $S'_j := 1$ ;
 $R(j) := J(S')$ ;
end;
 $k := k + 1$ ;
 $j := \operatorname{argmin} R(\cdot)$ ;
if  $R(j) \geq J(B(k))$ 
 $S := B(k)$ ;
else
 $S_j := 1$ ;
 $B(k) := S$ ;
 $t := 1$ ;
while  $k > 2 \wedge t = 1$ 
 $R := \emptyset$ ;
for each  $\{j \mid S_j = 1\}$ 
 $S' := S$ ;
 $S'_j := 0$ ;
 $R(j) := J(S')$ ;
end;
 $j := \operatorname{argmin} R(\cdot)$ ;
if  $R(j) < J(B(k - 1))$ 
 $k := k - 1$ ;
 $S_j := 0$ ;
 $B(k) := S$ ;
else
 $t := 0$ ;
end;
end;
end;
return  $B$ ;
end;

```

Figura 3.13. Seudocódigo del algoritmo SFFS. Fuente: Guyon, I., & Elisseeff, A. [37].

Entre las ventajas de este algoritmo es que la función de criterio solo necesita comparar subconjuntos de la misma dimensión, por lo que la distancia Bhattacharyya u otras son adecuadas para el algoritmo. Acá se utilizó un subconjunto de tamaño 6, este número contempla un balance entre complejidad y desempeño, varios estudios muestran que tamaños mayores generalmente no aportan o aportan poco a la separabilidad.

3.7. Clasificación

La clasificación es el proceso de asignar a una muestra un grupo o clase, en nuestro caso, asignar a cada muestra la clase 1 o la clase 2 que representan imaginación en la mano izquierda y derecha respectivamente.

Entre los principales clasificadores usados en trabajos similares destacan el Análisis Discriminante Lineal (LDA), Máquina de Soporte Vectorial (SVM) y Redes Neuronales Artificiales (ANN). El LDA es uno de los clasificadores más sencillos y busca encontrar un hiperplano que divida los datos entre 2 clases. Si w es un vector perpendicular al hiperplano, éste vector maximiza la distancia entre las medias y minimiza las varianzas de cada clase de las proyecciones de los datos sobre él.

El LDA es un clasificador popular en BCI debido a su simplicidad, pero factores como la no-gaussianidad, valores atípicos (*outliers*) o ruido pueden afectar negativamente el desempeño. Las redes neuronales a menudo sufren del problema de sobreajuste de los datos de entrenamiento, resultando en una pobre generalización. Por ello, las máquinas de soporte vectorial son preferidas en vez de las redes neuronales en los sistemas BCI [22]. Además, los métodos lineales son preferidos sobre los no lineales cuando la data es limitada, solo

cuando existen grandes cantidades de data los métodos no lineales son adecuados para encontrar estructuras más complejas en la data [42].

En este trabajo se utilizó una Máquina de Soporte Vectorial para la clasificación, una de las principales diferencias de este método con los demás es que el hiperplano definido solo depende de los puntos ubicados en la frontera de las 2 clases, que son los puntos en los que más clasificaciones erróneas se pueden producir. Por otro lado LDA y ANN toman toda la data como entrada.

En el caso de datos no separables linealmente se utiliza el clasificador SVM de “margen suave” [43], en el que se busca hallar w y b minimizando:

$$\frac{\|w\|^2}{2} + C \sum_{i=1}^m \xi_i, C > 0 \quad (3.18)$$

Sujeto a $y_i(w \cdot x_i - b) \geq 1 - \xi_i$, $\xi_i \geq 0$, para todo $i = 1, 2, \dots, m$.

Donde w es el vector normal al hiperplano de separación, los x_i son los datos de entrada y están asociados a una de dos clases, representadas por los y_i , que puede tomar los valores de -1 y 1.

El primer término en la ecuación 3.18 busca maximizar el margen entre los 2 hiperplanos paralelos que separan la data. Este margen está dado por $\frac{2}{\|w\|}$, por lo que maximizarlo implica minimizar $\|w\|$.

El segundo término de la ecuación 3.18 consiste en la suma de las clasificaciones erróneas. Un $\xi_i = 0$ implica una correcta clasificación, un $\xi_i < 1$ implica una ubicación dentro del margen y un $\xi_i > 1$ implica un error de clasificación.

3.8. Retroalimentación

La retroalimentación es indispensable en el paradigma de imaginación motora, permite que el participante aprenda a modular su actividad cerebral. La retroalimentación es función del valor de salida del clasificador. Para el clasificador SVM usado, se considera la distancia d al hiperplano como variable. Esta distancia es negativa si la muestra es clasificada como de la clase 1 (imaginación motora de la mano izquierda) y positiva si lo es de la clase 2 (imaginación motora de la mano derecha).

Se presenta la retroalimentación visual de 3 maneras. La primera consiste en el crecimiento de una barra, a la izquierda o a la derecha, de acuerdo a la distancia de clasificación (Figura 3.14).




Figura 3.14. Retroalimentación en forma de barra. Fuente: Propia.

La segunda forma de retroalimentación consiste en mostrar en pantalla la animación 3D de 2 manos, izquierda y derecha. Las manos se cerrarán de acuerdo a la distancia de clasificación (Figura 3.15).




Figura 3.15. Retroalimentación en forma de animación de manos en una pantalla. Fuente: Propia.

La tercera forma de retroalimentación consiste en mostrar el movimiento de dos manos robóticas, las manos se cerrarán de acuerdo a la distancia de clasificación (Figura 3.16).




Figura 3.16. Retroalimentación mediante manos robóticas. Fuente: Propia.

3.9. Integración del Sistema

Ahora que se ha definido cada parte del sistema de procesamiento de señales, tal como se planteó en la Figura 3.1, se procede a integrar todo usando

Simulink (MathWorks). Simulink es un entorno de programación grafica que permite modelar, simular y analizar diversos tipos de sistemas. g.tec Medical Engineering, el fabricante del amplificador, distribuye además un toolbox para Simulink llamado Simulink Highspeed On-line Processing [41] y contiene diversos bloques que nos permiten adquirir datos del amplificador y procesarlos en tiempo real. A continuación se describen los dos modelos desarrollados en Simulink, el primero es para las sesiones de selección (sin retroalimentación) y el segundo para las sesiones con retroalimentación.

El modelo para sesiones de selección sin retroalimentación se muestra a continuación, descompuesto en 2 estructuras. La primera estructura se muestra en la Figura 3.17. Esta estructura permite adquirir, mostrar y guardar la data. El bloque principal es el bloque `g.USBamp` el cual lee la data del amplificador a través del puerto USB. Ya que la data es adquirida en el formato `float32`, es necesario convertirla a `double` mediante el bloque `Data Type Conversion`.




Figura 3.17. Primera estructura del modelo para sesiones de selección. Permite adquirir, mostrar y guardar la data. Fuente: Propia.

La segunda estructura se muestra en la Figura 3.18. El bloque `From Workspace` lee la variable `screening_timing`, la cual contiene un esquema temporal que indica mediante números que figura se debe mostrar y en qué momento. El subsistema 1 (`Subsystem1`) se ejecuta mediante un desencadenador (*trigger*) de acuerdo al esquema temporal. Los bloques `Detect Change`, `Delay`, `Constant` y `Add` sirven para activar el desencadenador.

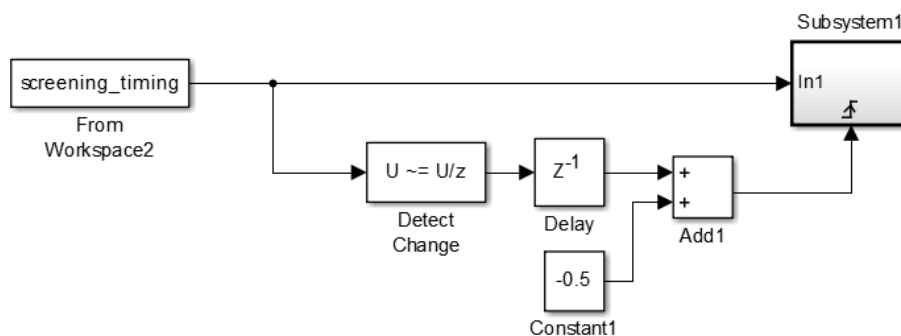


Figura 3.18. Segunda estructura del modelo para sesiones de selección. Permite mostrar las indicaciones visuales al participante. Fuente: Propia.

En el subsistema 1 se leen las imágenes y se las muestran en pantalla (Figura 3.19). Los bloques Image From Workspace leen imágenes desde el espacio de trabajo para luego ser mostradas en pantalla mediante el bloque To Video Display.

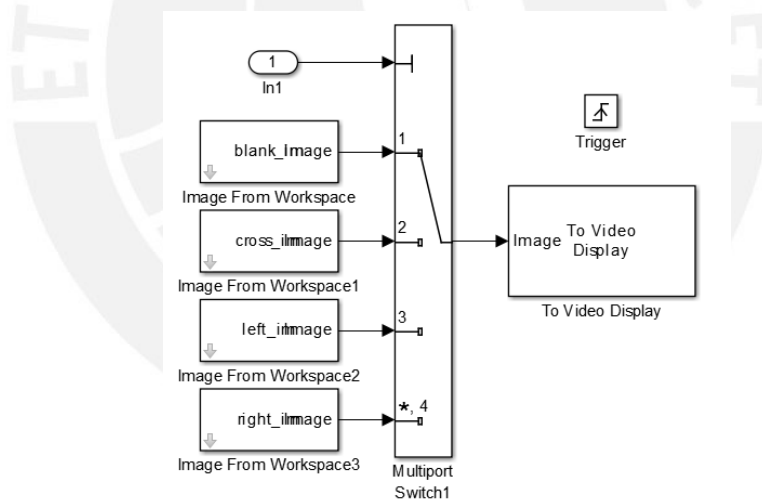


Figura 3.19. Subsistema 1 del modelo para sesiones de selección. Lee y muestra en pantalla las imágenes indicadas. Fuente: Propia.

Ahora se detallará el segundo modelo, usado en sesiones con retroalimentación. Éste se encuentra dividido en 3 estructuras. La primera estructura se muestra en la Figura 3.20 y permite adquirir, mostrar y guardar la data. Además realiza el filtrado pasabanda mediante el bloque Bandpass Filter.

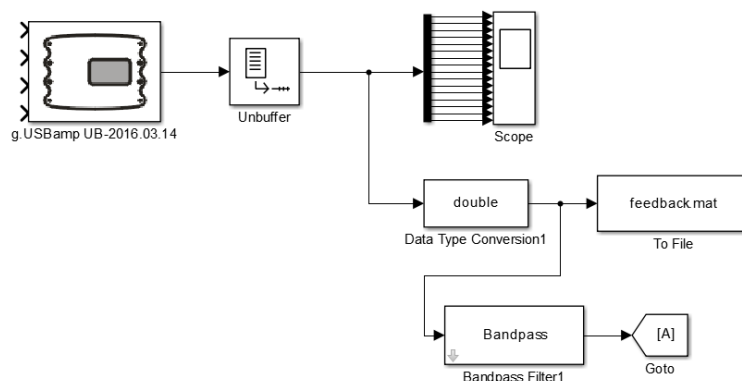


Figura 3.20. Primera estructura del modelo para sesiones con retroalimentación. Permite adquirir, mostrar y guardar la data. Además realiza el filtrado pasabanda. Fuente: Propia.

En la Figura 3.21 se muestra la segunda estructura del modelo para sesiones con retroalimentación. Esta estructura permite realizar el filtrado espacial o derivación, además de filtrar la señal de acuerdo a las bandas de frecuencia reactivas de cada participante, como fueron halladas en la etapa de selección.

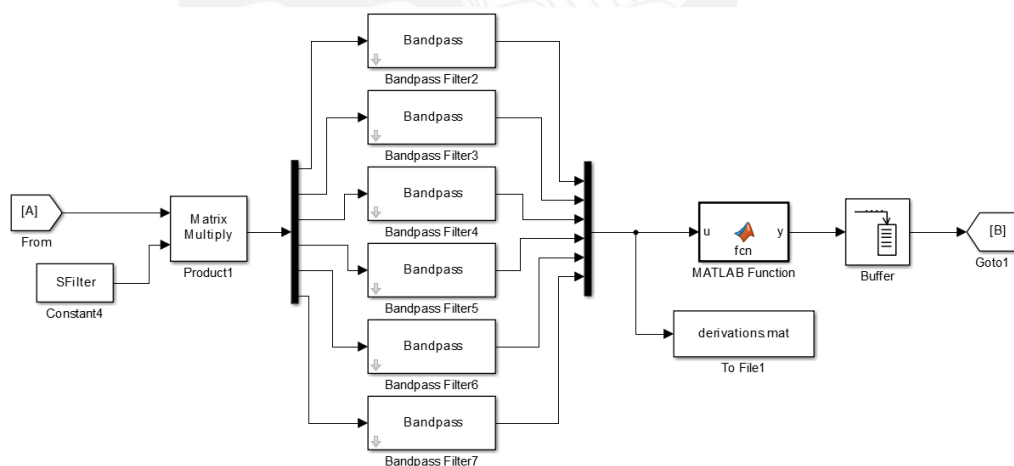


Figura 3.21. Segunda estructura del modelo para sesiones con retroalimentación. Permite realizar la derivación y filtra la señal de acuerdo a las bandas de frecuencia reactivas de cada participante. Fuente: Propia.

El bloque `Product` realiza el filtrado espacial mediante una multiplicación matricial. Luego la señal es filtrada independientemente por 6 filtros pasabanda mediante los bloques `Bandpass Filter`. Los bloques `MATLAB`

Function y Buffer sirven para hallar la transpuesta de la señal que llega en forma matricial y luego almacenarla en paquetes de 256 muestras.

En la Figura 3.22 se muestra la tercera estructura del modelo para sesiones con retroalimentación. Esta estructura sincroniza la ejecución de la función principal. La función principal se encuentra dentro del subsistema 2 y se encarga de obtener el vector de características y de clasificar la señal, tiene como salida la distancia de clasificación la cual se almacena en un bloque de memoria (Data Store Memory).

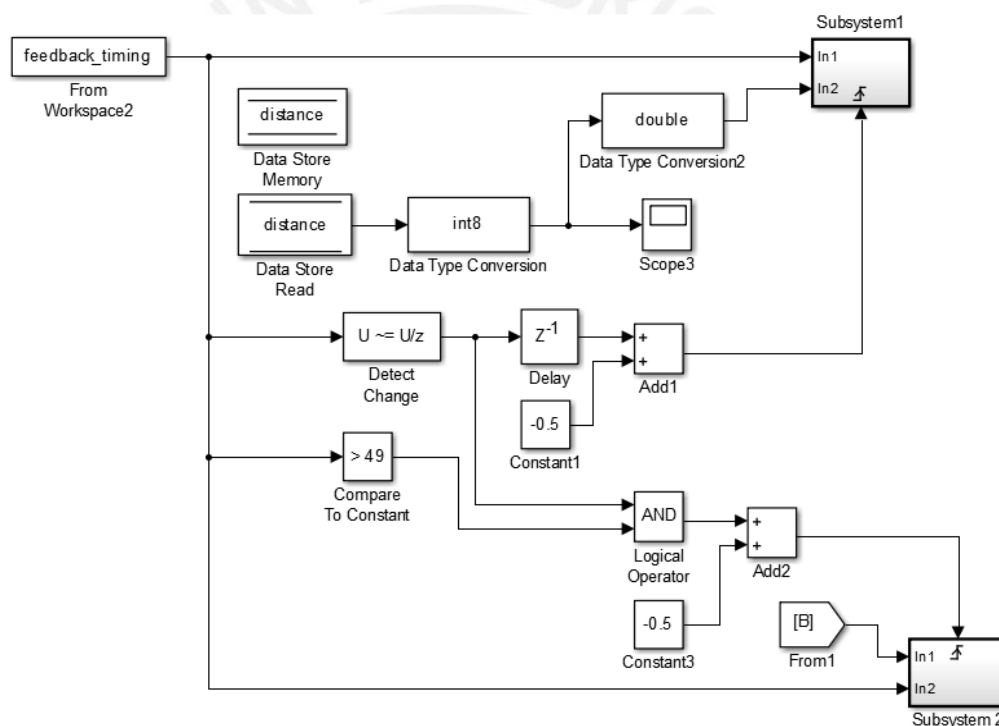


Figura 3.22. Tercera estructura del modelo para sesiones con retroalimentación. Sincroniza la ejecución de la función principal y del subsistema 1. Fuente: Propia.

El subsistema 1 se encarga de mostrar la imagen indicada según el esquema temporal dado, se muestra en la Figura 3.23. El subsistema 1 utiliza también la distancia de clasificación como entrada, ésta es leída mediante el bloque Data Store Read. El bloque MATLAB Function decide qué imagen mostrar en función de la distancia de clasificación y del esquema temporal.

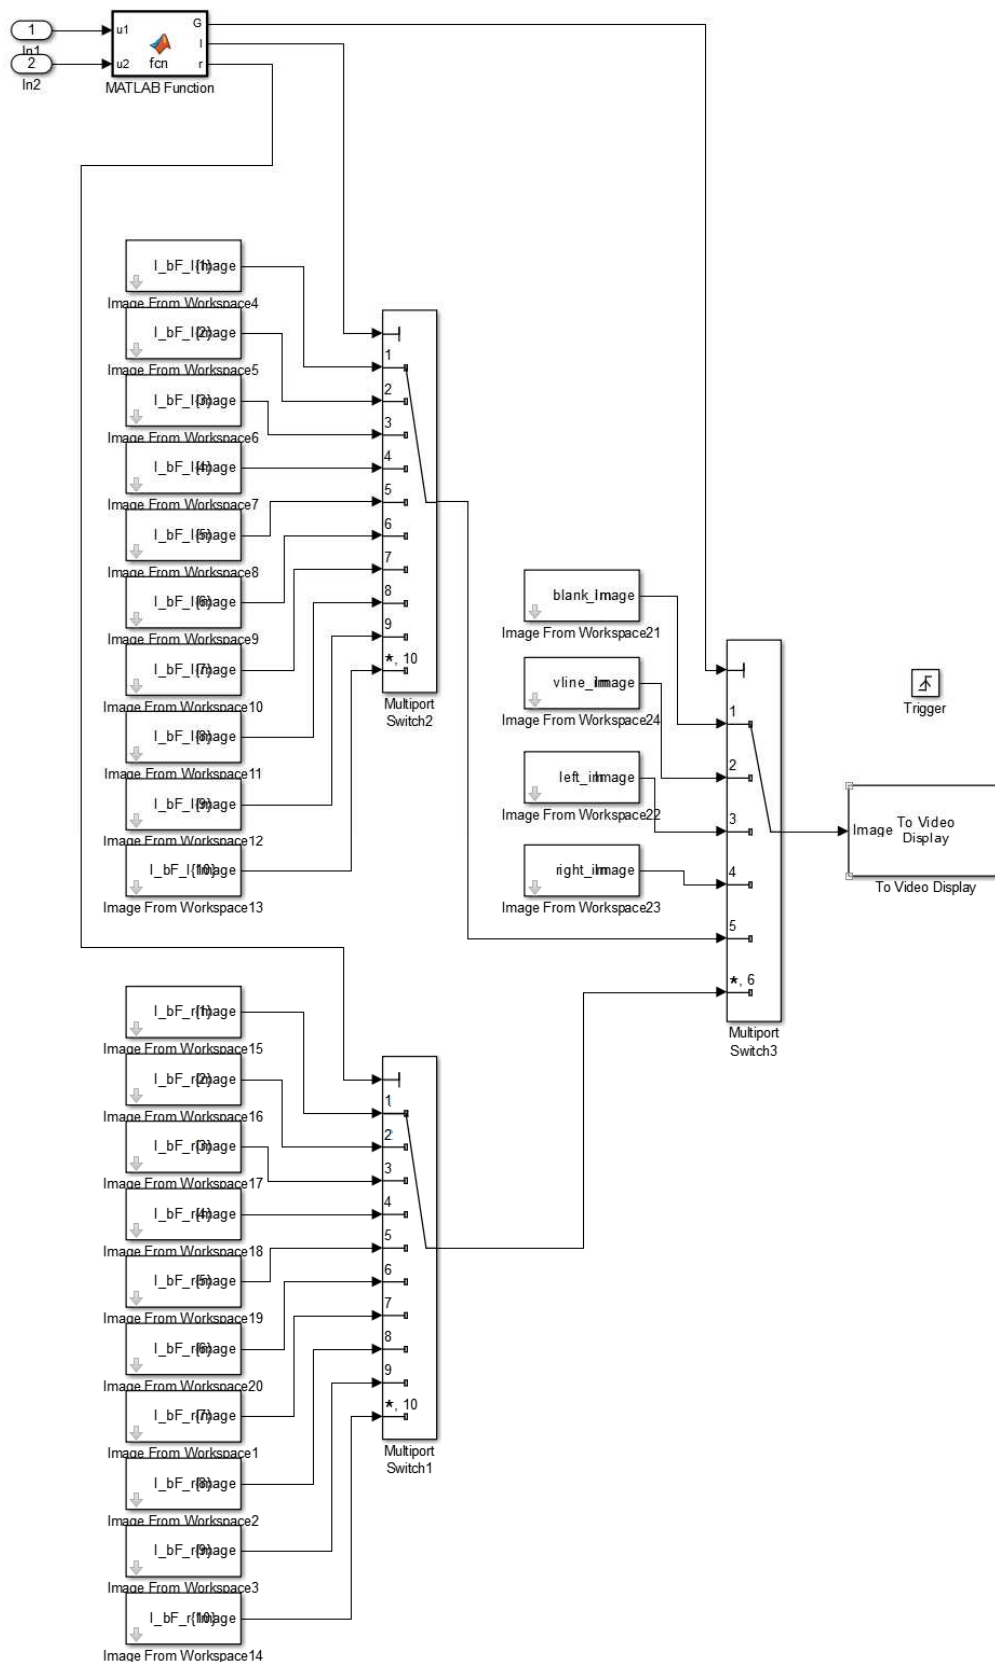


Figura 3.23. Subsistema 1 de la tercera estructura. Se encarga de mostrar la imagen indicada según el esquema temporal dado. Fuente: Propia.

3.10. Medidas para la Evaluación del Desempeño

La medida principal para medir el desempeño en un sistema BCI es la Exactitud de Clasificación. Es la proporción entre las muestras correctamente clasificadas y el total de muestras:

$$ACC = \frac{\# \text{ Correctamente clasificadas}}{\# \text{ Muestras}} \quad (3.19)$$

En nuestro caso evaluamos las exactitudes de clasificación para cada sesión que consta de 40 ensayos. En la aleatoriedad, para dos clases, la exactitud de clasificación tiene un valor esperado de 0.5, y cuando se clasifican correctamente todas las muestras, la exactitud de clasificación resultante es 1.

Como se explicó anteriormente, la clasificación, y por tal la retroalimentación, es realizada usando información del segundo anterior, es decir, la retroalimentación hallada en el instante t es hallada usando los datos tomados entre t y $t - 1$. Lo anterior significa que se usan 256 muestras ya que la frecuencia de muestreo es 256 Hz.

Si queremos encontrar la exactitud de clasificación de cada ensayo de 4s de duración, podemos hacerlo usando las distancias de clasificación de todas las muestras de 1 segundo superpuestas y distribuidas durante los 4 segundos de duración del ensayo. Ya que la superposición es de 0.75 segundos, se tienen un total de 13 muestras de 1 segundo para cada ensayo. Se halla la clase de cada ensayo mediante:

$$C_e = \text{signo} \left(\sum_{i=1}^{13} d_i \right) \quad (3.20)$$

Donde d_i es la distancia de clasificación de cada intervalo de 1 segundo. Si C_e es -1, la clase asignada es la 1 (imaginación motora de mano izquierda) y si es +1, la clase asignada es la 2 (imaginación motora de mano derecha).



CAPITULO IV

RESULTADOS

Los 15 participantes fueron divididos en 3 grupos de 5 participantes cada uno, y en cada grupo se aplicó una retroalimentación visual diferente, tal como se describió en la Sección 3.8. En las tablas y gráficos siguientes se visualizan los resultados de tal manera que se pueda realizar una comparación entre los 3 grupos mencionados.

El sistema es ejecutado en tiempo real para cada uno de los 15 participantes a lo largo de 8 sesiones, donde las primeras 3 sesiones fueron sesiones de selección y las posteriores 5, con retroalimentación, tal como se vio en la Sección 3.4. Las exactitudes de clasificación son medidas para cada una de las 5 sesiones con retroalimentación usando clasificadores entrenados con la información proveniente de las 3 primeras sesiones, las de selección.

En la Tabla 4.1 se observan los resultados usando intervalos de 1 segundo de duración. Como se vio en la Sección 3.10, de cada ensayo de duración de 4 segundos se obtienen 13 intervalos superpuestos de 1 segundo de duración, para cada uno de estos intervalos se aplica el clasificador y se le asigna una de las 2 clases a diferenciar. Por tanto, para cada sesión de 40 ensayos se obtiene un total de 520 intervalos de 1 segundo. Entonces, usando la ecuación 3.19 se hallan las exactitudes de clasificación para cada uno de los 15 participantes a lo largo de las 5 sesiones con retroalimentación.

	Participante	Sesiones					Media:
		1	2	3	4	5	
Barra	1	0.69	0.66	0.59	0.68	0.70	0.66
	2	0.54	0.64	0.69	0.68	0.62	0.63
	3	0.54	0.61	0.55	0.59	0.64	0.59
	4	0.61	0.62	0.74	0.66	0.71	0.67
	5	0.85	0.81	0.75	0.83	0.83	0.81
	Media:	0.65	0.67	0.66	0.69	0.70	0.67
Animación	6	0.56	0.64	0.54	0.64	0.46	0.57
	7	0.63	0.58	0.58	0.61	0.51	0.58
	8	0.54	0.55	0.61	0.53	0.58	0.56
	9	0.83	0.87	0.90	0.89	0.84	0.87
	10	0.55	0.62	0.64	0.73	0.64	0.64
	Media:	0.62	0.65	0.65	0.68	0.61	0.64
Manos Robóticas	11	0.78	0.82	0.78	0.79	0.75	0.78
	12	0.78	0.83	0.75	0.86	0.87	0.82
	13	0.81	0.84	0.80	0.76	0.74	0.79
	14	0.48	0.52	0.57	0.51	0.50	0.52
	15	0.67	0.58	0.60	0.61	0.65	0.62
	Media:	0.70	0.72	0.70	0.71	0.70	0.71

Tabla 4.1. Exactitudes de clasificación para los 15 participantes a lo largo de las 5 sesiones con retroalimentación, usando intervalos de 1 segundo. Se muestran además las medias por participante y por sesión, para cada grupo, en negrita. En rojo se muestra la media general por grupo.

En la Tabla 4.2 se observan los resultados para los ensayos completos de 4 segundos de duración. Para encontrar la clase a la cual pertenece cada ensayo se usó la ecuación 3.20. Luego, usando la ecuación 3.19 se hallan las exactitudes de clasificación para cada uno de los 15 participantes a lo largo de las 5 sesiones con retroalimentación.

	Participante	Sesiones					Media:
		1	2	3	4	5	
Barra	1	0.78	0.80	0.68	0.73	0.80	0.76
	2	0.60	0.78	0.75	0.85	0.63	0.72
	3	0.58	0.75	0.55	0.70	0.65	0.65
	4	0.78	0.65	0.93	0.68	0.88	0.78
	5	1.00	0.90	0.83	0.95	0.95	0.93
	Media:	0.75	0.78	0.75	0.78	0.78	0.77

Animación	6	0.60	0.65	0.53	0.73	0.50	0.60
	7	0.70	0.58	0.65	0.65	0.58	0.63
	8	0.53	0.53	0.63	0.53	0.65	0.57
	9	0.95	0.98	0.93	1.00	1.00	0.97
	10	0.58	0.60	0.70	0.85	0.78	0.70
	Media:	0.67	0.67	0.69	0.75	0.70	0.70
Manos Robóticas	11	0.83	0.98	0.95	0.88	0.78	0.88
	12	0.98	0.88	0.88	0.95	0.98	0.93
	13	0.88	1.00	0.95	0.95	0.95	0.95
	14	0.50	0.50	0.55	0.53	0.50	0.52
	15	0.78	0.58	0.65	0.73	0.73	0.69
	Media:	0.79	0.79	0.80	0.81	0.79	0.79

Tabla 4.2. Exactitudes de clasificación para los 15 participantes a lo largo de las 5 sesiones con retroalimentación, usando los ensayos completos de 4 segundos. Se muestran además las medias por participante y por sesión, para cada grupo, en negrita. En rojo se muestra la media general por grupo.

En la Figura 4.1 se muestra la exactitud de clasificación media por grupo para intervalos de 1s a lo largo de las 5 sesiones. Y en la Figura 4.2, la exactitud de clasificación media por grupo para ensayos de 4 segundos de duración, también a lo largo de las 5 sesiones.

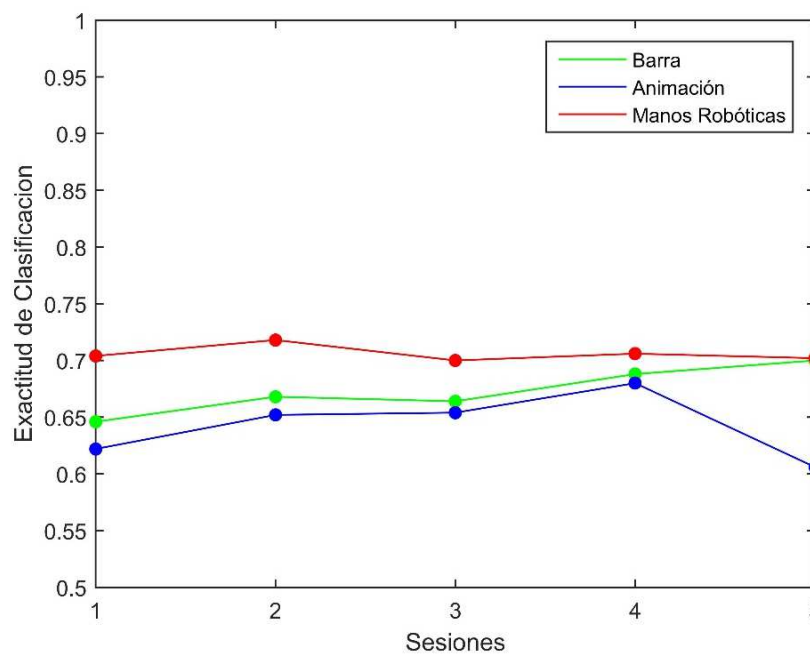


Figura 4.1. Exactitud de clasificación media por grupo para intervalos de 1s a lo largo de las 5 sesiones. Fuente: Propia.




Figura 4.2. Exactitud de clasificación media por grupo para ensayos completos (4 segundos) a lo largo de las 5 sesiones. Fuente: Propia.

Adicionalmente a los resultados anteriores, se realizó una validación cruzada en las sesiones de selección (sin retroalimentación) con la finalidad de evaluar las exactitudes de clasificación y compararlas con las encontradas en las sesiones con retroalimentación.

En las sesiones de selección los ensayos duraron 3s mientras que en las sesiones con retroalimentación 4s. Esto hace que no sea posible hacer una comparación entre ambas al considerar ensayos completos, ya que la diferencia en tiempos genera una diferencia en la cantidad de información. Sin embargo, si se puede hacer una comparación usando intervalos de 1s.

Se tienen 3 sesiones de selección, cada una con 40 ensayos, dando un total de 120 ensayos. Se realiza una validación cruzada de 12 iteraciones, es decir, se dividen los datos en 12 grupos de 10 ensayos cada uno, se coge 11 de ellos para entrenar el clasificador y se lo prueba con el grupo restante. Esto se

repite 12 veces, y se promedian los resultados. Cada ensayo de 3s es dividido en 9 intervalos superpuestos de 1s de duración, de la misma manera que se hizo con las sesiones con retroalimentación en tiempo real. Se muestran los resultados obtenidos en la Tabla 4.3, y como comparación, se muestran las medias obtenidas en las sesiones con retroalimentación, de la Tabla 4.1.

	Participante	Sesiones de Selección	Sesiones con Retroalim.
Barra	1	0.65	0.66
	2	0.59	0.63
	3	0.66	0.59
	4	0.67	0.67
	5	0.80	0.81
	Media:	0.67	0.67
Animación	6	0.60	0.57
	7	0.59	0.58
	8	0.49	0.56
	9	0.81	0.87
	10	0.59	0.64
	Media:	0.62	0.64
Manos Robóticas	11	0.70	0.78
	12	0.75	0.82
	13	0.81	0.79
	14	0.48	0.52
	15	0.61	0.62
	Media:	0.67	0.71

Tabla 4.3. Exactitudes de clasificación para los 15 participantes encontradas mediante validación cruzada en las 3 sesiones de selección (sin retroalimentación), usando intervalos de 1 segundo. Además, se muestran las medias obtenidas en las sesiones con retroalimentación. Se indican las medias por grupo en rojo.

CONCLUSIONES


Se aprecia una diferencia entre las exactitudes de clasificación de los grupos “Manos Robóticas” y “Animación”. Esta diferencia es de $0.79 - 0.70 = 0.09$ cuando se usan ensayos de 4 segundos y de $0.71 - 0.64 = 0.07$ cuando se usan intervalos de 1 segundo, ambas a favor del grupo “Manos Robóticas”. Estos resultados indican que la retroalimentación mediante manos robóticas influye positivamente en mayor medida que la retroalimentación mediante animación, sin embargo, estos resultados deben ser validados con una cantidad mayor de sujetos. Una razón para esta diferencia podría ser que las manos robóticas usadas son más semejantes a las humanas que las manos de animación, que tienen una apariencia metálica y rígida, y por ello facilitarían el proceso de imaginación motora.

A partir de la Tabla 4.3 se encuentra que las diferencias por grupo entre las sesiones de selección y las sesiones con retroalimentación son de 0.04 para el grupo “Manos Robóticas”, 0.02 para el grupo “Animación” y de 0.00 para el grupo “Barra”. Estos resultados se condicen con los encontrados en [14], donde los valores de ERD tienen un mayor aumento en el grupo de retroalimentación “Congruente”, seguido por el grupo “Incongruente”, y en tercer lugar, el grupo “Barra”. Lo anterior sugiere que una retroalimentación visual más natural o realista genera mejores resultados en el control de un sistema BCI mediante imaginación motora.

Las exactitudes de clasificación individuales indican grandes diferencias entre los participantes al momento de controlar la Interfaz Cerebro

Computador. Esto demuestra la gran diversidad entre los individuos al generar Desincronización y Sincronización Relacionada a Eventos (ERD/ERS).

En los resultados se observa claramente que las exactitudes de clasificación son mayores cuando se utilizan los ensayos de 4 segundos a diferencia de cuando se utilizan intervalos de 1 segundo. Esto se debe a que los ensayos completos, por durar más tiempo, contienen mayor información sobre el tipo de imaginación motora que se está realizando (imaginación de mano izquierda o de derecha).



BIBLIOGRAFIA

- [1] 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.
- [2] Lebedev, M. A., & Nicolelis, M. A. (2006). Brain-machine interfaces: past, present and future. *TRENDS in Neurosciences*, 29(9), 536-546.
- [3] Johar, K., Low, C. Y., Hanapiah, F. A., Jaffar, A., Idris, F., & Kasim, M. A. A. (2015). TOWARDS THE DEVELOPMENT OF A ELECTRO-ENCEPHALOGRAPHY BASED NEUROPROSTHETIC TERMINAL DEVICE. *Jurnal Teknologi*, 76(4).
- [4] Murguialday, A. R., Aggarwal, V., Chatterjee, A., Cho, Y., Rasmussen, R., O'Rourke, B., ... & Thakor, N. V. (2007, June). Brain-computer interface for a prosthetic hand using local machine control and haptic feedback. In *Rehabilitation Robotics, 2007. ICORR 2007. IEEE 10th International Conference on* (pp. 609-613). IEEE.
- [5] 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.
- [6] Tan, D. & Nijholt, A. (2010). *Brain-computer interfaces*. London: Springer.
- [7] 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.
- [8] <https://emotiv.com>

- [9] <http://neurosky.com>
- [10] <http://www.gtec.at/Products>
- [11] <http://www.nasanmedical.com/simul-g.html>
- [12] 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.
- [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] Ortner, R., Irimia, D. C., Scharinger, J., & Guger, C. (2012). A motor imagery based brain-computer interface for stroke rehabilitation. *Stud Health Technol Inform*, 181, 319-23.
- [16] 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.
- [17] Blankertz, B., Müller, K. R., Curio, G., Vaughan, T. M., Schalk, G., Wolpaw, J. R., ... & Schröder, M. (2004). The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials. *Biomedical Engineering, IEEE Transactions on*, 51(6), 1044-1051.
- [18] Ramos-Murguialday, A., Schürholz, M., Caggiano, V., Wildgruber, M., Caria, A., Hammer, E. M., ... & Birbaumer, N. (2012). Proprioceptive feedback

and brain computer interface (BCI) based neuroprostheses. *PloS one*, 7(10), e47048.

[19] Neuper, C., Scherer, R., Wriessnegger, S., & Pfurtscheller, G. (2009). Motor imagery and action observation: modulation of sensorimotor brain rhythms during mental control of a brain-computer interface. *Clinical neurophysiology*, 120(2), 239-247.

[20] Ron-Angevin, R., & Díaz-Estrella, A. (2009). Brain-computer interface: Changes in performance using virtual reality techniques. *Neuroscience letters*, 449(2), 123-127.

[21] Wei, P. (2010, August). An virtual vehicle control game for online brain computer interface feedback training. In *Mechatronics and Automation (ICMA), 2010 International Conference on* (pp. 1942-1944). IEEE.

[22] Rao, R. P. (2013). *Brain-computer interfacing: an introduction*. Cambridge University Press.

[23] 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.

[24] Hwang, H. J., Kwon, K., & Im, C. H. (2009). Neurofeedback-based motor imagery training for brain-computer interface (BCI). *Journal of neuroscience methods*, 179(1), 150-156.

[25] Hashimoto, Y., Ushiba, J., Kimura, A., Liu, M., & Tomita, Y. (2010). Change in brain activity through virtual reality-based brain-machine communication in a chronic tetraplegic subject with muscular dystrophy. *BMC neuroscience*, 11(1), 117.

[26] Fatourechi, M., Bashashati, A., Ward, R. K., & Birch, G. E. (2007). EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical neurophysiology*, 118(3), 480-494.

- [27] McFarland, D. J., McCane, L. M., David, S. V., & Wolpaw, J. R. (1997). Spatial filter selection for EEG-based communication. *Electroencephalography and clinical Neurophysiology*, 103(3), 386-394.
- [28] Barlow, J. S. (1986). Artifact processing (rejection and minimization) in EEG data processing. *Handbook of electroencephalography and clinical neurophysiology*, 2, 15-62
- [29] Anderer, P., Roberts, S., Schlögl, A., Gruber, G., Klösch, G., Herrmann, W., ... & Saletu, B. (1999). Artifact processing in computerized analysis of sleep EEG—a review. *Neuropsychobiology*, 40(3), 150-157.
- [30] Croft, R. J., Chandler, J. S., Barry, R. J., Cooper, N. R., & Clarke, A. R. (2005). EOG correction: a comparison of four methods. *Psychophysiology*, 42(1), 16-24.
- [31] Bell, A. J., & Sejnowski, T. J. (1995). An information-maximization approach to blind separation and blind deconvolution. *Neural computation*, 7(6), 1129-1159.
- [32] Bernard Marius 't Hart. Illustration of electrode locations of the 10-20 system. http://www.mariusthart.net/downloads/eeg_electrodes_10-20.svg, Oct 2011. accedido 12 Oct 2016, CC BY-SA 3.0.
- [33] gGAMMAcap Instructions for use V2.14.00 (2014)
- [34] Jung, T. P., Makeig, S., Humphries, C., Lee, T. W., Mckeown, M. J., Iragui, V., & Sejnowski, T. J. (2000). Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, 37(02), 163-178.
- [35] Theodoridis, S., Pikrakis, A., Koutroumbas, K., & Cavouras, D. (2010). *Introduction to pattern recognition: a MATLAB approach*. Academic Press.
- [36] Pudil, P., Novovičová, J., & Kittler, J. (1994). Floating search methods in feature selection. *Pattern recognition letters*, 15(11), 1119-1125.
- [37] Guyon, I., & Elisseeff, A. (2006). An introduction to feature extraction. In *Feature extraction* (pp. 1-25). Springer Berlin Heidelberg.

- [38] Rejer, I., & Gorski, P. (2015). Benefits of ICA in the case of a few channel EEG. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 7434-7437). IEEE.
- [39] Jung, T. P., Humphries, C., Lee, T. W., Makeig, S., McKeown, M. J., Iragui, V., & Sejnowski, T. J. (1998). Extended ICA removes artifacts from electroencephalographic recordings. *Advances in neural information processing systems*, 894-900.
- [40] Neuper, C., Müller-Putz, G. R., Scherer, R., & Pfurtscheller, G. (2006). Motor imagery and EEG-based control of spelling devices and neuroprostheses. *Progress in brain research*, 159, 393-409.
- [41] Simulink Highspeed On-line Processing USER MANUAL V3.14.03 (2014)
- [42] Muller, K. R., Anderson, C. W., & Birch, G. E. (2003). Linear and nonlinear methods for brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 165-169.
- [43] Stoean, C., & Stoean, R. (2014). *Support vector machines and evolutionary algorithms for classification*. Springer-Verlag, Berlin, Heidelberg.
- [44] Lee, T. W., Girolami, M., & Sejnowski, T. J. (1999). Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural computation*, 11(2), 417-441.