

Evaluation of Classification Methods for EEG Signals in Older Adults for Right-Hand Motor Imagery Movements

Evaluación de Métodos de Clasificación de Señales EEG de Adultos Mayores para Movimientos Imaginados de la Mano Derecha

Ivan Carrillo^{1,*}, Victoria Meza-Kubo², Luis Pellegrin²

¹UABC Carretera Estatal No. 3, Col. Gutiérrez S/N, Guadalupe Victoria, Mexicali, Baja California, México

²UABC, Carretera Transpeninsular Ensenada-Tijuana Número 3917, Colonia Playitas. Ensenada, B.C., C.P. 22860

* Corresponding author(s); contact in the panel below.

Abstract

Cognitive decline, characterized by the progressive loss of functions such as memory, attention, and speech, significantly affects the well-being of older adults, a population that is growing rapidly worldwide. In response to this issue, brain-computer interfaces (BCIs) represent a promising technological alternative to facilitate interaction with digital devices, particularly for individuals experiencing reduced motor abilities. This study proposes a methodology for classifying five imagined right-hand movements in older adults using EEG signals. Exhaustive experimentation was conducted, evaluating eight distinct representational features extracted from the EEG data and applying various machine learning algorithms, including ensemble methods, to develop a computational model that achieved an accuracy of 93.7%. Additionally, subsets of features capable of maintaining classification accuracy above 90% were identified. These findings support the feasibility of integrating BCI solutions tailored to the needs of older adults in assistive and rehabilitation applications.

Resumen. El deterioro cognitivo, caracterizado por la pérdida progresiva de funciones como la memoria, la atención y el habla, afecta significativamente la calidad de vida de los adultos mayores, población que crece de forma acelerada a nivel mundial. En respuesta a esta problemática, las interfaces cerebro-computadora (BCI) son una alternativa tecnológica prometedora para facilitar la interacción con dispositivos digitales, especialmente en personas con capacidades motrices en declive. En este trabajo se propone una metodología para llevar a cabo la tarea de clasificación de cinco movimientos imaginados con la mano derecha, generados por adultos mayores a partir de sus señales EEG. El trabajo presenta una experimentación exhaustiva considerando ocho diferentes características de representación extraídas de las señales cerebrales y diferentes algoritmos de aprendizaje automático incluyendo ensambles, para generar un modelo computacional que alcanza una exactitud de 93.7%. Además, se identificaron subconjuntos de características de representación que permiten mantener una exactitud superior al 90%. Estos resultados refuerzan la viabilidad de integrar soluciones BCI adaptadas a adultos mayores en aplicaciones de asistencia y rehabilitación.

Keywords: Older adults, BCI classification, EEG, motor imagery. (*Palabras clave: adultos mayores, BCI clasificación, EEG, imaginación motora.*)

Revista Mexicana de Ingeniería Biomédica

ISSN 2395-9126 • SOMIB

Vol./No./Year	47/2/2026
Article no.	e2026-1564
DOI	10.17488/RMIB.47.2.1564
Received	01 May 2025
Accepted	18 April 2026
Published	29 June 2026
Corresponding	ivan.carrillo@uabc.edu.mx

This is an open access article under the CC BY-NC 4.0 license.

1. Introducción

El envejecimiento de la población es una tendencia demográfica global ampliamente documentada. Según datos de las Naciones Unidas, se estima que para el año 2080 el número de personas de 65 años o más alcanzará los 2,200 millones, lo que representará más del 20% de la población mundial, superando el número de niños y jóvenes (menores de 18 años)

[1], [2]. Este cambio en la estructura poblacional plantea retos significativos para los sistemas de salud, protección social e inclusión tecnológica, haciendo indispensable el desarrollo de soluciones orientadas a mejorar la calidad de vida de este sector en crecimiento. La población de adultos mayores presenta características particulares que la distinguen, entre las que destacan la presencia de enfermedades o padecimientos crónicos como hipertensión, niveles elevados de colesterol, diabetes y artritis. Además, con el paso del tiempo suelen manifestarse condiciones asociadas al envejecimiento como pérdida progresiva de la visión y audición, la disminución de la movilidad motora y, en muchos casos, el deterioro cognitivo. Este último representa una de las condiciones más delicadas, ya que puede evolucionar hacia formas más severas como la demencia [2], [3] o el Alzheimer [4], [5], afectando significativamente la calidad de vida de quienes lo padecen.

El deterioro cognitivo es un proceso que varía entre los individuos, ya que su progresión depende de múltiples fac-

tores personales y contextuales. Algunas funciones cognitivas pueden presentar un decaimiento acelerado mientras que otras pueden no verse afectadas [3], [6]. Aunque actualmente no existe una cura definitiva para este tipo de afecciones, se han desarrollado tratamientos farmacológicos que buscan ralentizar su avance, así como intervenciones no farmacológicas, tales como actividades de estimulación cognitiva, las cuales han demostrado ser efectivas para retrasar la aparición de síntomas o para evitar un avance acelerado [7], [8].

Las actividades de estimulación cognitiva pueden desarrollarse mediante métodos tradicionales –como ejercicios en papel, de memoria, atención y lenguaje– o bien mediante el uso de tecnologías digitales que permiten ofrecer experiencias interactivas y personalizadas [8], [9], [10], [11]. Diversas investigaciones han demostrado que el uso de herramientas tecnológicas puede potenciar los efectos de la estimulación cognitiva, promoviendo una mayor motivación y adherencia a las actividades [13], [14]. Sin embargo, uno de los principales desafíos radica en la adopción de estas tecnologías por parte del adulto mayor, debido a que usualmente han sido diseñadas pensando en usuarios más jóvenes [15], [16], [17].

El acercarse al adulto mayor con el uso de las nuevas tecnologías no solo permite reducir la brecha digital, sino que también les ofrece herramientas útiles para la comunicación, el entretenimiento, la autonomía y la estimulación cognitiva [3], [17], ejemplo de ello pueden ser los sistemas BCI (*Brain-Computer Interfaces*).

Los sistemas BCI permiten la interacción directa entre el cerebro y un dispositivo externo a través de señales neuronales, sin necesidad de movimientos físicos. Esta forma de interacción es una solución factible para los adultos mayores, ya que no depende de habilidades motrices finas, facilitando el acceso a las aplicaciones. Los sistemas BCI se han empleado en diferentes áreas como el entretenimiento, particularmente videojuegos controlados por señales cerebrales [18]; en el área de la salud, como en rehabilitación física [5], [19], [20]; en la comunicación, por ejemplo, en estudios de *neuromarketing* [21]; y en el desarrollo de tecnologías asistidas diseñadas para brindar asistencia a adultos mayores [18], [22].

Con los avances tecnológicos que se tienen actualmente, los dispositivos portátiles para el registro de electroencefalogramas (EEG) se han vuelto más asequibles [19], [23], [24]. Una de las aplicaciones más relevantes de los dispositivos EEG es su integración en los sistemas BCI. Colocando este tipo de dispositivos en el cuero cabelludo, permiten a los usuarios interactuar con hardware o software a través de la interpretación de su actividad cerebral, sin necesidad de utilizar dispositivos convencionales de entrada [5], [20], [25], [26]. Por esta razón, las condiciones físicas del usuario no resultan un impedimento para la interacción, siendo su funcionalidad cerebral el único requisito fundamental, siempre y cuando no existan lesiones neurológicas severas que afecten la generación de las señales.

Para permitir esta interacción, entre el usuario y el sistema BCI, existen diferentes paradigmas generando patrones reconocibles en la actividad cerebral [20], [25], [26]; que varían según el tipo de tarea cognitiva o sensorial que se le pide al usuario

realizar, como responder a estímulos visuales, auditivos o realizar acciones mentales específicas. Entre los paradigmas más estudiados y utilizados destaca el de imaginación motora (*motor imagery*), el cual se basa en la capacidad del individuo para imaginar movimientos voluntarios de sus extremidades sin ejecutar físicamente dicha acción [29], [30], [31].

La Tabla 1 presenta un resumen comparativo de estudios recientes en sistemas BCI basados en imaginación motora, en los cuales se analizan distintos movimientos imaginados de extremidades, tales como la mano derecha, mano izquierda, pie derecho y pie izquierdo. De acuerdo a este análisis, los estudios reportados han empleado diversos algoritmos para la tarea de clasificación, entre los que destacan: árboles de decisión (DT), redes neuronales artificiales (ANN), máquinas de soporte vectorial (SVM), k-vecino más cercanos (KNN), ingenuo bayesiano (NB), regresión logística (LR), bosque aleatorio (RF) y recientemente aprendizaje profundo [27], [28]. Además, entre los métodos de extracción de características reportados se encuentran aquellas extraídas por medio del Análisis de Componentes Principales (PCA) o Análisis por Discriminante Lineal (LDA), kurtosis, media, entre otras, sin que hasta el momento se haya establecido un mínimo o un máximo de características que deben ser empleadas para la tarea de imaginación motora. Finalmente, los registros EEG reportados corresponden principalmente a participantes jóvenes o adultos jóvenes, con exactitudes entre 71.17% a 98.53%.

2. Materiales y Métodos

El objetivo principal de la investigación es obtener una metodología de clasificación de señales cerebrales de movimientos imaginados de adultos mayores, que les permita interactuar con aplicaciones BCI y brindarles herramientas para abordar el deterioro cognitivo o su aplicación en otras áreas. A diferencia de los trabajos descritos en la sección anterior, en este trabajo se busca generar un modelo computacional para llevar a cabo la clasificación de registros EEG de cinco movimientos imaginados, pero con una sola extremidad, la mano derecha. Los movimientos imaginados son: derecha, izquierda, arriba, abajo y hacia al frente (simulando presionar un botón).

El proceso que se siguió está basado en la literatura [34], [35], donde se definen las siguientes etapas: 1) Registro de las señales EEG, 2) Preprocesamiento de las señales, 3) Extracción de características de representación de señales, 4) Generación del modelo de clasificación, 5) Uso de aplicación BCI mediante el modelo. En este estudio se mostrarán los resultados de las primeras cuatro etapas.

2.1 Registro de las señales de imaginación motora (IM)

En esta fase se realiza la obtención del conjunto de datos. Para la obtención de las señales EEG se invitó a participar a adultos mayores diestros. Previo al registro de las señales, los participantes acudieron al Laboratorio de Interfaces Multimodales de la Universidad, donde se les proporcionó la información sobre el objetivo del estudio y su participación. Posteriormente, al confirmar su participación, se les solicitó la firma de la carta de

Tabla 1. Trabajos reportados en la literatura para la tarea de imaginación motora según tareas, características y algoritmos.

Trabajo	Movimientos imaginados	Algoritmos	Características de representación usadas	Resultados
[29]	Mano izquierda Pie izquierdo	ANN, SVM	PCA, LDA	La base de datos empleada cuenta con registros de siete participantes jóvenes/adultos. Se emplean ANN (88.54% de exactitud) y SVM (83.93% de exactitud). El algoritmo ANN brinda un mejor resultado empleando LDA.
[30]	Mano derecha Mano izquierda	SVM KNN NB LR	Media, mediana, desviación estándar, desviación absoluta de la media, cuartil 25, cuartil 75, rango intercuartil de señal, oblicuidad, kurtosis, entropía, valores pico, raíz cuadrada de la media, factor de cresta, factor de forma, factor de impulso, factor de margen, energía de la señal	El conjunto de datos empleados se basa en registros de 20 participantes jóvenes/adultos. Se evalúan los algoritmos siendo SVM (71.17% de exactitud) empleando todas las características.
[31]	Mano derecha Pie izquierdo Pie derecho	KNN	Media, promedio de la potencia, desviación estándar, relación de los valores medios absolutos, oblicuidad, kurtosis.	La base de datos se compone de cinco participantes jóvenes. La descomposición de paquetes wavelet (WPD) vs otros empleados fue el método que brinda en promedio un 92.8% de exactitud en la clasificación de los movimientos imaginados considerando todas las características.
[32]	Mano izquierda Mano derecha Pie izquierdo Pie derecho	NB, SVM, LR	Ondas cerebrales: gamma, beta, alpha, theta, y delta.	En este trabajo la base de datos contiene el registro de siete participantes jóvenes. El área bajo la curva (AUC) se emplea como la medida para establecer el mejor algoritmo en la clasificación, NB, SVM y LR obtienen 89.09% en la clasificación.
[33]	Mano derecha Mano abierta Mano cerrada Mano izquierda Mano abierta Mano cerrada	RF, DT, SVM, KNN, ANN	Potencia de bandas, aproximación de la entropía, espacio de patrones comunes (CSP), cuartil 1, cuartil 3, desviación absoluta de la mediana, media, desviación estándar, oblicuidad, kurtosis.	Los registros empleados contienen los registros de 109 participantes jóvenes/adultos. De los algoritmos empleados SVM con la característica de aproximación de la entropía presenta el mejor resultado obteniendo un 98.53% de exactitud al clasificar los movimientos imaginados.

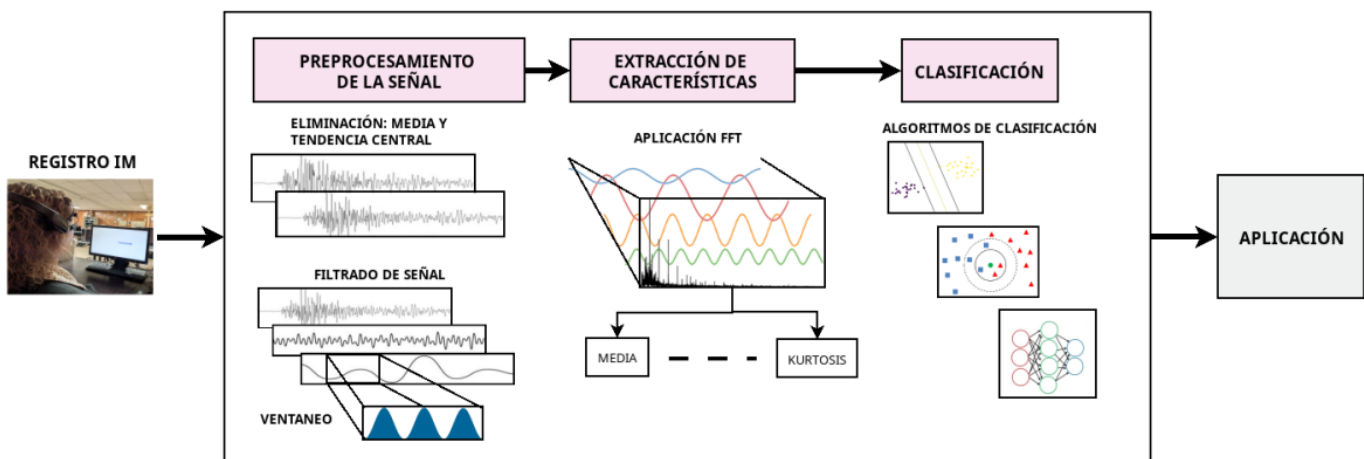


Figura 1. Etapas de un sistema BCI.

consentimiento informado. Finalmente, con el fin de verificar que ninguno de los participantes presentaba indicios de deterioro cognitivo, se les aplicó el cuestionario *Mini-Mental State Examination (MMSE)* versión validada al español [42]. Esta prueba permitió evaluar de forma rápida y estandarizada el es-

tado cognitivo de los participantes para confirmar su inclusión en el estudio.

Los participantes fueron seis mujeres, con edad entre 58 y 78 años (promedio de 66.5 y una desviación estándar de 7.25), las participantes obtienen puntajes en el MMSE que van de 26

a 29 puntos, con un nivel de estudios superior a secundaria.

2.2 Materiales

- (1) Aplicación visual. Para apoyar la adquisición de los registros de la actividad cerebral se desarrolló una aplicación, en lenguaje de programación Java, para presentar los diferentes estímulos de forma visual a las participantes.
- (2) Dispositivo EEG. Para la captura de la actividad cerebral se utilizó el dispositivo Emotiv EPOC que cuenta con 14 electrodos y dos referencias distribuidos de acuerdo al sistema estandarizado 10-20, esto es, los electrodos son colocados a distancias relativas (10% o 20%) entre los puntos de referencia craneales sobre la cabeza [43].

2.3 Actividades

La actividad consta de una serie de tareas de imaginación motora las cuales presentan el siguiente orden: *derecha, izquierda, arriba, abajo, enfrente*. Cada tarea tiene una duración de un minuto, en la Figura 2a se presenta el esquema de la actividad, donde se identifica la secuencia de los estímulos a utilizar. Durante este minuto, al adulto mayor se le presentan dos estímulos de forma alternada. Se inicia con el estímulo neutro, con una duración de cinco segundos el cual se presenta 6 veces, posteriormente el estímulo de la tarea, con una duración de 6 segundos la cual se lleva a cabo 5 veces.

En la actividad se utilizan marcadores que se introducen al inicio y al final del estímulo correspondiente a la tarea. Esto permite identificar en el registro EEG la sección correspondiente al movimiento imaginado realizado por el adulto mayor. Cuando el estímulo visual de la actividad (flecha) se presenta, el adulto mayor debe de imaginar que mueve su mano derecha de acuerdo a la orientación que presente la imagen del estímulo. En la Figura 2b se muestran los estímulos: neutro, movimiento a la derecha y el adulto mayor visualizando el estímulo en una actividad.

Durante la visualización del estímulo el adulto mayor debe de imaginar el movimiento de su mano derecha de manera reiterada. En el caso del movimiento hacia enfrente, el estímulo que se presenta es un botón (Figura 2b), para este caso el adulto mayor debe imaginar que mueve su mano derecha hacia enfrente. Para el caso del estímulo neutro, cuando este se presenta el adulto mayor no realiza ningún movimiento imaginado.

Tras finalizar cada tarea de imaginación motora, el participante dispone de un descanso de dos minutos; en total, la sesión contempla cuatro de estos intervalos. Durante este tiempo, se explican las instrucciones de la siguiente actividad sin retirar el dispositivo EEG. Con el fin de prevenir la fatiga del participante, las tareas se limitaron a un minuto de duración. Esto debido a las características del dispositivo. Es recomendable limitar el uso de éste a un máximo de 15 minutos continuos. Por un lado, la característica de los electrodos secos exige rehidratación constante para mantener la integridad de la señal. Por otro lado, la presión ejercida por el equipo para asegurar el contacto y evitar el movimiento puede resultar incómoda para el usuario si se extiende demasiado el tiempo de sesión.

2.4 Preprocesamiento de las señales

Una vez capturadas las señales EEG, se procede a prepararlas aplicando técnicas de preprocesamiento de señales como la eliminación de ruido y el ventaneo.

2.5 Eliminación de ruido

Por la naturaleza de la información registrada, en este caso la actividad eléctrica cerebral, el ruido que suele introducirse en la señal corresponde a movimientos musculares, respiración, movimientos oculares y la señal eléctrica de los dispositivos que se estén empleando. Para eliminar el ruido de las señales pueden emplearse diferentes métodos [36]. En este trabajo se elimina la media que se presenta en los registros (Ecuación 1) y la tendencia lineal (Ecuación 2) que se pueda presentar en los datos. Adicionalmente, es necesario aplicar un filtro de señal; la literatura reporta diferentes tipos de filtros [35][37]; en este trabajo se aplicó el filtro pasa bandas *Butterworth* de 4to orden (Ecuación 3). Con este filtro solo se mantienen las frecuencias de señales que se encuentran en el intervalo de 0.1Hz - 50Hz.

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \tag{1}$$

N = total de datos, A_i = vector de datos, i = valores de 1 hasta N

$$y(t) = m * t + b \tag{2}$$

m = pendiente, t = muestra, b = ordenada al origen

$$H(z) = \frac{b_1 + b_2z^{-1} + \dots + b_rz^{-(r-1)}}{a_1 + a_2z^{-1} + \dots + a_rz^{-(r-1)}} \tag{3}$$

H(z) = Función de transferencia, a,b = coeficientes de la función de transferencia

2.6 Ventaneo

La función de ventaneo consiste en segmentar un registro continuo de señal en secciones que pueden ser de diferentes tamaños, además de que los extremos de las secciones generadas de cada señal son alisados, lo que permite que exista continuidad entre cada una de estas secciones. Para este trabajo se empleó la ventana *Hanning* (Ecuación 4) con un tamaño de 128. Este valor equivale a 128 datos registrados en un segundo por el dispositivo utilizado.

$$w(n) = 0.5 * \left(1 - \cos \left(2\pi \frac{n}{N} \right) \right), 0 \leq n \leq N \tag{4}$$

N = índice de muestra, N = longitud de la ventana n + 1 puntos

2.7 Extracción de características

La etapa de extraer características consiste en procesar la señal con la finalidad de obtener una característica definida por una representación vectorial. Una vez realizada la extracción de características, los registros resultantes se utilizan como ejemplos de entrada para la generación de modelos en la etapa de clasificación.

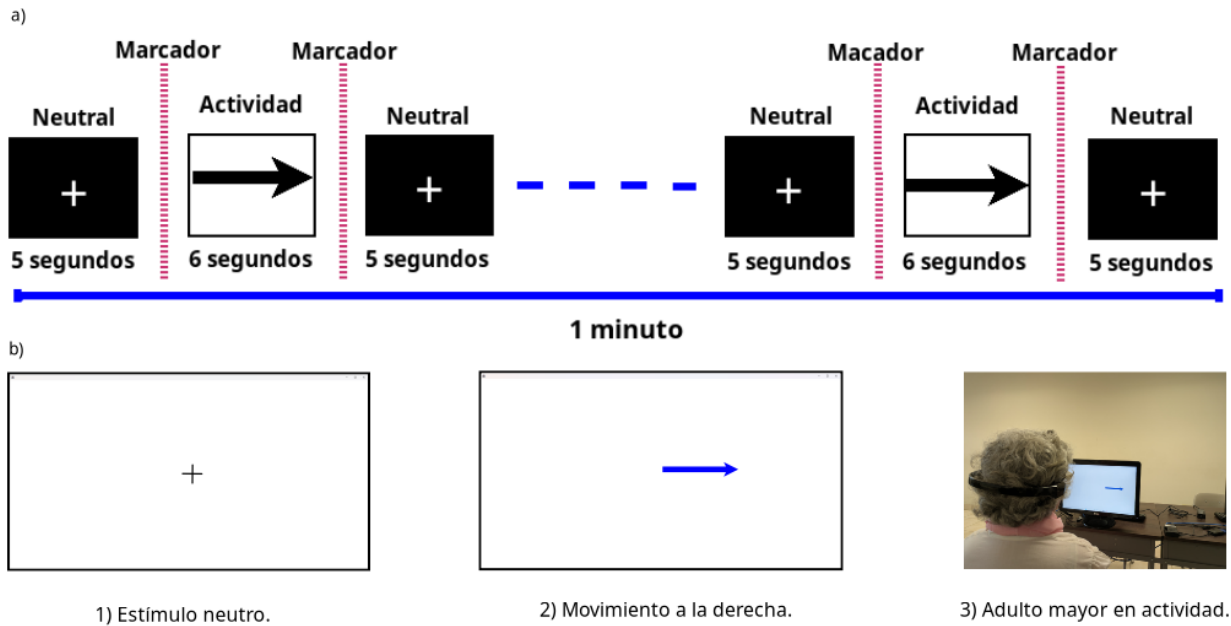


Figura 2. a) Esquema de la actividad realizada en cada tarea de imaginación motora b) Estímulos durante la actividad y Adulto en actividad de imaginación motora.

2.8 Transformada de Fourier

Primero, se procesan las señales cerebrales a través de la Transformada Rápida de Fourier (FFT) [38] usando la Ecuación 5:

$$Y(k) = \sum_{j=1}^n X(j)W_n^{(j-1)(k-1)}, W_n = e^{\frac{-2\pi i}{n}} \quad (5)$$

K = k – énesimo elemento del vector transformado, n = total de datos, X(j) = vector de números complejos, j = valores entre 1 y n – 1, W_n = raíz n- énesima de la unidad

2.9 Características

Una vez que la información es procesada mediante la FFT, a partir de la matriz resultante se calcula la Densidad Espectral de Potencia (PSD) (Ecuación 6). Posteriormente, se realiza la extracción de características espectrales para representar las señales EEG, las cuales se calculan de manera independiente para cada ventana y cada canal, dentro del rango de frecuencias definido en la etapa de eliminación de ruido. Las características obtenidas representan cada segmento de la señal y se utilizan para asociar las señales EEG a las actividades de imaginación motora consideradas (*derecha, izquierda, arriba, abajo, botón y otros*).

$$PSD = \left(\frac{1}{f_s * N} \right) * abs(rFFT)^2 \quad (6)$$

F_s = frecuencia de muestreo, N = total de datos, abs = valor absoluto, rFFT = resultado de FFT

En este estudio, se ha experimentado con diversas características reportadas en la literatura [28], [30]; tales como: media, varianza, desviación estándar, kurtosis, valor máximo, valor

mínimo, raíz cuadrada de la media y oblicuidad. Estas pueden ser empleadas de manera individual o combinando varias de ellas en la tarea de clasificación. En el presente estudio se utilizaron 8 características de manera individual, las cuales se presentan las usadas para la extracción de características.

Durante esta etapa se generaron diferentes conjuntos de datos, es decir, por cada movimiento se generaron ocho subconjuntos de datos los cuales corresponden a cada una de las características calculadas. En total se experimentó con 240 conjuntos de datos con una dimensión de 4514, siendo 45 el número de registros obtenidos después del procesamiento, y 14 corresponde al número de electrodos que toman registro de lectura con el dispositivo *Emotiv Epoc*.

Los distintos conjuntos de datos fueron reorganizados y unificados por característica y movimiento quedando finalmente un total de 40 conjuntos con una dimensión de 27014. Adicionalmente, se generó un conjunto extra el cual contiene registros de actividad cerebral correspondiente a un estado base definido para “*otros*”, es decir, el estado base se compone de registros EEG donde no se realiza ninguna actividad. Todos los conjuntos de datos fueron normalizados empleando z-score (Ecuación 7).

$$z = \frac{x - \mu}{\sigma} \quad (7)$$

x = valor, = media, = desviación estándar

2.10 Clasificación

En la etapa de clasificación se aplican los diferentes algoritmos para la identificación de patrones que permitan clasificar cada uno de los cinco movimientos imaginarios que fueron capturados, preprocesados y segmentados de acuerdo al movimiento

imaginado y las características extraídas.

2.11 Algoritmos de aprendizaje automático:

Para la tarea de clasificación se seleccionaron algoritmos supervisados, los cuales han sido utilizados para tareas de clasificación de imaginación motora: redes neuronales artificiales (ANN), *k*-vecino más cercanos (KNN), discriminante lineal, árboles de decisión, máquinas de vectores de soporte (SVM), ingenuo bayesiano (NB) y ensambles. Para todos los algoritmos se llevó a cabo una optimización de los diferentes parámetros que presentan por medio del *framework* de MatLab durante la fase de entrenamiento. El *framework* permite optimizar un conjunto de algoritmos generando un ensamble, usando métodos ya establecidos como *AdaBoost*, *RusBoost*, *Bagging*, empleando algoritmos de árboles de decisión, discriminantes y KNN.

- Media

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \tag{1}$$

N = total de datos, $A_i = i$ -ésima observación

- Kurtosis

$$k = \frac{E(x - \mu)^4}{\sigma^4} \tag{8}$$

$x =$ observación, $\mu =$ media, $\sigma =$ desviación estándar

- Raíz cuadrada de la media (RMS)

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2} \tag{9}$$

N = total de observaciones, $x_i = i$ -ésima observación, $i =$ valores desde 1 hasta N

- Varianza

$$V = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2 \tag{10}$$

N = número total de observaciones, $x_i = i$ -ésima observación, $\mu =$ media, $i =$ valores desde 1 hasta N

- Valor Máximo

$$M = \max(X) \tag{11}$$

X = vector de datos

- Oblicuidad

$$s = \frac{E(x - \mu)^3}{\sigma^3} \tag{12}$$

X = observaciones, $\mu =$ media, $\sigma =$ desviación estándar, E = esperanza matemática

- Desviación Estándar

$$S_w = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2} \tag{13}$$

N = número de observaciones, $A_i = i$ -ésima observación, $\mu =$ media, $i =$ valores desde 1 hasta N

- Valor mínimo

$$M = \min(X) \tag{14}$$

X = vector de datos

2.12 Evaluación de modelos

Para la evaluación de los modelos, la selección de los datos se realiza de manera aleatoria. Para el entrenamiento y validación de los modelos generados se aplicó validación cruzada de cinco pliegues, del conjunto de datos se toma el 10% de los registros para la parte de pruebas, es decir, 90% entrenamiento y validación y 10% para pruebas, este proceso es realizado de manera aleatoria, el conjunto de datos utilizado contiene los registros de todos los participantes y los cinco movimientos imaginados siguiendo el orden (*derecha - izquierda - arriba - abajo - botón*). Para medir el desempeño de cada uno de los algoritmos en la tarea de clasificación de imaginación motora, se calculó la Exactitud (Ecuación 15), obtenida de la matriz de confusión.

$$Exactitud = \frac{\text{Clasificaciones correctas}}{\text{Total de clasificaciones}} = \frac{TP + TN}{TP + TN + FP + FN} \tag{15}$$

TP = verdaderos positivos, TN = verdaderos negativos, FN = falsos negativos, FP = falsos positivos

2.13 Estrategias de clasificación

Finalmente, para la clasificación de los cinco movimientos imaginados se decidió implementar dos estrategias de clasificación:

- (1) **Estrategia A.** Esta estrategia consistió en clasificar los conjuntos de datos como un problema binario, es decir, clasificar de manera independiente cada movimiento imaginado vs el estado base (otros). Esto generó los siguientes escenarios: *derecha vs otros*, *izquierda vs otros*, *arriba vs otros*, *abajo vs otros*, *botón vs otros*. Para cada problema, todos los conjuntos de datos comprenden un tamaño de 54014 registros.
- (2) **Estrategia B.** Esta estrategia plantea un escenario multiclase, incluyendo a todos los movimientos imaginados y al estado base. Para ello se generaron ocho conjuntos de datos (uno por cada característica) con un tamaño de 1,62014 registros.

3. Resultados y Discusión

De acuerdo a trabajos similares encontrados en la literatura [39], [40], [41], los problemas de imaginación motora existentes se enfocan principalmente en movimientos realizados por varias extremidades, a diferencia de este trabajo donde se busca identificar hasta cinco movimientos imaginados realizados únicamente con la mano derecha. Por otro lado, los trabajos encontrados utilizan registros EEG de jóvenes o adultos jóvenes.

Al utilizar dos estrategias para llevar a cabo la tarea de clasificación de movimientos imaginados, binaria y multiclase

(estrategias A y B, respectivamente), se consiguió resolver la clasificación multiclase, con una experimentación de los algoritmos y características para su entrenamiento de manera gradual, es decir, primero resolviendo la tarea binaria.

Estrategia A: Clasificación binaria. En esta estrategia se clasifica un movimiento imaginado *versus* los demás movimientos. Mediante una evaluación exhaustiva, se usa cada característica extraída por separado, se tienen ocho características, cinco movimientos imaginados y se emplean 33 algoritmos de clasificación con lo cual se generan combinaciones resultando en 1,320 experimentos. En la Tabla 3 se reportan sólo los mejores resultados basados en la métrica exactitud que se obtiene para los diferentes experimentos, mientras que en la Tabla 4 se presentan los peores resultados obtenidos.

A partir de la Tabla 3 es posible identificar que el rango de la exactitud que se obtiene en la tarea de clasificación binaria va desde un 97.1% hasta 98.6%. Es posible establecer que el algoritmo que presenta una prevalencia es un ensamble. Con respecto a las ocho características evaluadas, se identifica que aquellas relacionadas a la descripción de la tendencia central de los datos (media, RMS, varianza, desv. estándar), son las que obtienen una mayor exactitud. No obstante, se presenta una excepción en la característica correspondiente a valores máximos, siendo la única característica no relacionada a la tendencia central que muestra un buen rendimiento. En cambio, en la Tabla 4 se observa que las características que no corresponden a la descripción de la tendencia central de los datos (oblicuidad, mínimo, kurtosis) presentan los resultados más deficientes.

Posteriormente, para identificar la mejor configuración algoritmo-característica, se llevó a cabo un análisis detallado usando matrices de confusión, considerando únicamente los mejores resultados. Dada la Figura 3, se comparan los resultados obtenidos usando las características de *desviación estándar* y *máximo*, para el movimiento imaginado *botón*, con lo cual se concluye que para esta clasificación resulta mejor emplear la característica *máximo* que obtiene un 0.99 de TPR (Ecuación 16), y un 0.02 de FNR (Ecuación 17). Para alcanzar estos resultados se emplearon un ensamble y una ANN, respectivamente.

$$TPR = \frac{TP}{TP + FN} \quad (16)$$

TP = verdaderos positivos, FN = falsos negativos

$$FNR = \frac{FN}{TP + FN} \quad (17)$$

FN = falsos negativos, TP = verdaderos positivos

En otra comparación de rendimiento de clasificación, se muestran los resultados del movimiento imaginado *arriba* empleando las características *varianza* y *máximo* (Figura 4). Para este caso, la característica *varianza* (Figura 4a) presenta los mejores resultados, en la clase *otros*, se contabilizan 239 registros clasificados de manera correcta y solo 4 clasificados de manera incorrecta. Por otro lado, en la característica *máximo* (Figura 4b) para la clase *arriba* 235 registros fueron clasifica-

dos correctamente y 8 incorrectamente. En ambos casos, se emplearon ensambles.

Estrategia B: Para esta estrategia se evalúa la clasificación multiclase, es decir, empleando los cinco movimientos imaginados a la vez [*derecha - izquierda - arriba - abajo - botón*] más un estado base (nombrado como *otros*). Los conjuntos de datos empleados para la tarea de clasificación se componen de 162014 registros. Se experimentó exhaustivamente con las diferentes características evaluando el rendimiento nuevamente de 33 algoritmos comparando 264 resultados. A partir de los resultados se identifican los mejores y peores rendimientos.

La Tabla 5 resume los mejores resultados obtenidos, con lo cual se identifica que las características relacionadas a la tendencia central resultan ser favorables. Al emplear la característica *RMS* se alcanza un 93.7% de exactitud. Para una mejor comprensión de los resultados se emplea nuevamente matrices de confusión (Figura 5), esta vez comparando las características *RMS* y *media*.

En la Figura 5, las clases que aparecen en la matriz de confusión se identifican como: *izquierda*, *derecha*, *arriba*, *abajo*, *botón* y *otros*. El total de registros es de 1,458 por los 14 canales. Donde a cada clase le corresponden 243 registros. A partir de la matriz de confusión se puede observar que el uso de la característica *RMS* es en la clase *derecha*, obtiene una ventaja con 240 registros clasificados correctamente usando un ensamble como algoritmo de aprendizaje.

Para complementar los resultados obtenidos en términos de exactitud de acuerdo a la matriz de confusión correspondiente a la característica *RMS*, se calcularon métricas adicionales de evaluación. Estas métricas permiten una evaluación más robusta del desempeño del modelo en el escenario multiclase. De acuerdo a los valores de F1-Score obtenidos para cada clase, se identifica que la clase *izquierda* presenta el mejor desempeño, lo que sugiere que los registros asociados a esta clase exhiben características más diferenciables respecto a las demás. En contraste, la clase *otros* presenta un F1-Score de 85.2%, lo cual indica una mayor complejidad en su clasificación y una tendencia del modelo a confundir los registros con otras clases.

Adicionalmente, se calculó el coeficiente Kappa de Cohen, obteniéndose un valor de 92.4%, así como un Macro F1-Score de 93.7%. La similitud entre la exactitud global y el Macro F1-Score es consistente con los patrones observados en la matriz de confusión, donde se identifican errores simétricos entre ciertas clases (por ejemplo, *abajo-otros* y *otros-abajo*). A pesar de estas confusiones específicas, el valor del coeficiente Kappa indica un alto nivel de concordancia y fiabilidad del modelo (ver Tabla 6).

En la Figura 6 se muestra el promedio de los registros correspondientes a cada uno de los movimientos imaginados que se emplean en la característica *RMS*, la cual presentó el mejor resultado de las ocho empleadas. Se identifica que los registros se encuentran en un rango de [0 - 0.045], de los 5 movimientos son *botón* y *arriba* los que presentan puntos superiores (0.045) mientras que los movimientos *izquierda*, *abajo* y *derecha* presentan puntos bajos menores a (0.005). A pesar de tratarse de un promedio de lecturas, se identifica la eficacia de la caracte-

Tabla 3. Mejores resultados obtenidos de la estrategia A.

Movimiento imaginado	Exactitud	Algoritmo	Característica
Derecha	97.9	Ensamble	Media
Izquierda	98.5	Ensamble	Varianza
Arriba	97.5	Ensamble	RMS, Desv. estándar, Varianza
Abajo	97.1	Ensamble	RMS
Botón	98.6	ANN	Máximo

Tabla 4. Peores resultados obtenidos de la estrategia A.

Movimiento imaginado	Exactitud	Algoritmo	Característica
Derecha	61.5 - 74.4	Ensamble	Oblicuidad, Mínimo, Kurtosis
Izquierda	58 - 87	SVM, Ensamble	Oblicuidad, Kurtosis, Mínimo
Arriba	56.7 - 60.9	SVM, Ensamble	Oblicuidad, Mínimo, Kurtosis
Abajo	60.4 - 62.9	ANN, SVM	Oblicuidad, Mínimo, Kurtosis
Botón	59.8 - 67.4	ANN, Ensamble	Oblicuidad, Mínimo, Kurtosis




Figura 3. Matrices de confusión de la clasificación del movimiento imaginado (botón) de acuerdo a la característica utilizada: a) Desviación estándar b) Máximo.

Tabla 5. Resultados obtenidos de la estrategia B.

Movimiento imaginado	Algoritmo	Exactitud	Características
derecha, izquierda, arriba, abajo, botón, otros	Ensamble	93.7	Raíz cuadrada de la media (RMS)
derecha, izquierda, arriba, abajo, botón, otros	Ensamble	93.5	Media
derecha, izquierda, arriba, abajo, botón, otros	Ensamble	92.9	Varianza

terística *RMS* para distinguir a cada movimiento, razón por la cual el modelo generado alcanza un alto rendimiento.

4. Conclusiones

El trabajo realizado permitió alcanzar la meta establecida de poder generar al menos un modelo de clasificación para cinco movimientos imaginados con un porcentaje de exactitud mayor o igual al 90%. Adicionalmente, se construyó un conjunto de datos referentes a los cinco movimientos empleados, con una sola extremidad (la mano derecha), lo cual difiere de varios trabajos reportados en la literatura, donde identifican uno o varios movimientos imaginados pero generados con diferentes extremidades.

A partir de las ocho características evaluadas, se concluye que aquellas relacionadas con medidas de tendencia central proporcionan un mejor desempeño en las tareas de clasificación,

tanto en escenarios binarios como multiclase. Mediante una evaluación exhaustiva de distintos algoritmos de aprendizaje automático para la generación de modelos, se determinó que el algoritmo de ensamble mostró el mejor rendimiento para la tarea de clasificación de imaginación motora.

Sin embargo, es importante considerar ciertas limitaciones del estudio. En particular, el conjunto de datos utilizados es reducido y está conformado únicamente por registros correspondientes a mujeres, lo que limita la generalización de los resultados. Asimismo, los registros empleados no emplearon estrategias de validación a nivel de sujeto, lo que impide analizar de manera individual la influencia de cada participante sobre el comportamiento del modelo tanto de manera positiva como negativa.

Para solventar estas limitaciones, se plantea como trabajo futuro la incorporación de registros EEG de adultos mayores varones y la implementación de estrategias de validación cruzada, tales como leave-one-subject-out. Esto permitirá fortalecer la solidez de los resultados y garantizar una validación externa más robusta. Además, se integrará el modelo de ensamble en una aplicación BCI para su evaluación en tiempo real. Finalmente, se explorarán otras técnicas alternativas de

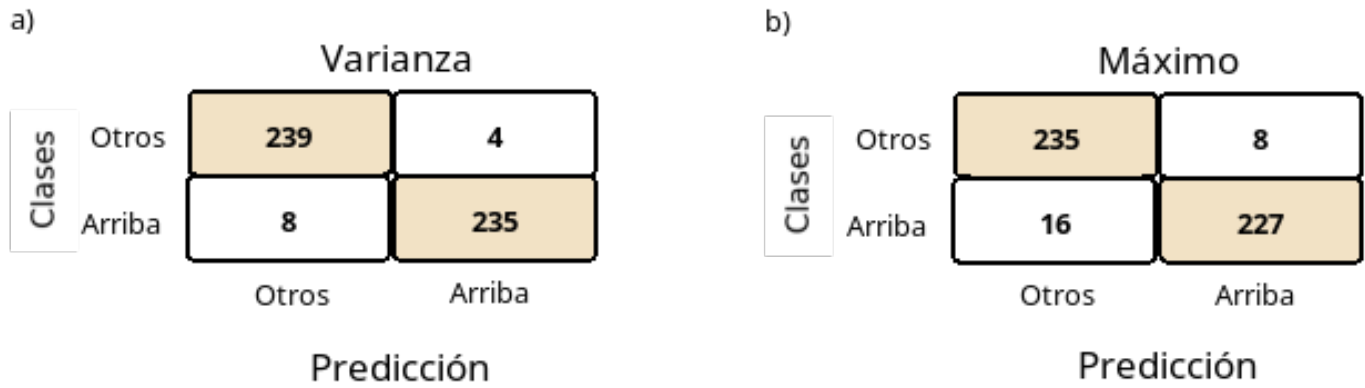


Figura 4. Matrices de confusión de la clasificación del movimiento imaginado (arriba) de acuerdo a la característica utilizada: a) Varianza b) Máximo.

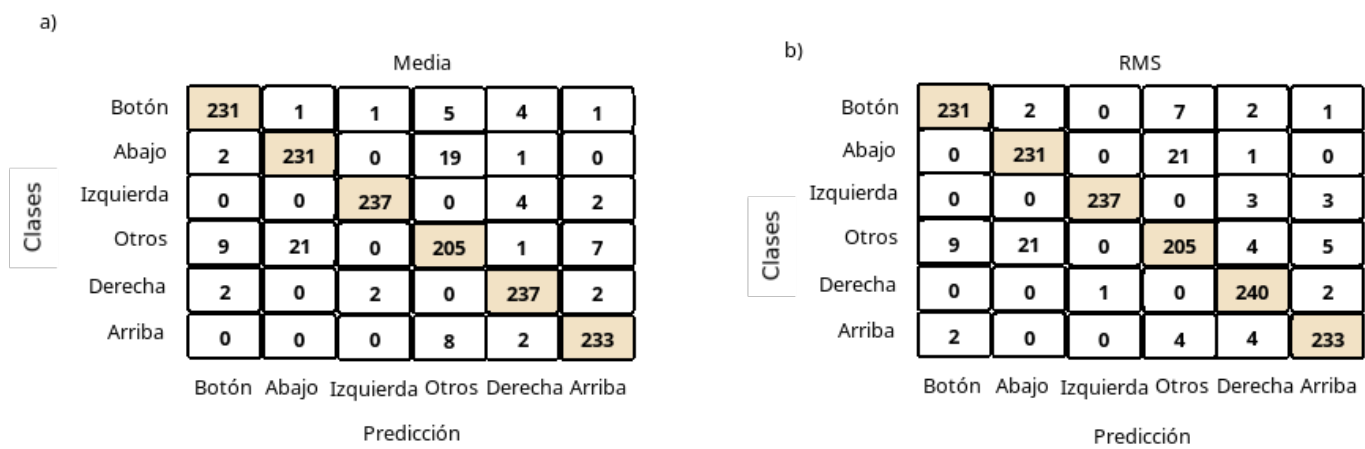


Figura 5. Matrices de confusión generadas con la clasificación correspondiente a las características: a) Media b) RMS.

Tabla 6. Métricas de evaluación de la característica RMS.

Parámetro	Movimiento imaginado	Movimiento imaginado	Movimiento imaginado	Movimiento imaginado	Movimiento imaginado	Movimiento imaginado
Parámetro	Derecha	Izquierda	Arriba	Abajo	Botón	Otros
F1-Score (%)	96.5	98.5	95.6	91.1	95.2	85.2

procesamiento de señales, tales como wavelets, transformada de Fourier de Tiempo Reducido (STFT) y Espacio Común de Patrones (CSP).




Figura 6. Promedio de registros por movimiento imaginado.

5. Financiamiento

Universidad Autónoma de Baja California, proyecto interno con clave 105/6/C/66/24.

6. Agradecimientos

Se agradece a todos los adultos mayores que participaron en esta actividad y el interés mostrado.

7. Contribuciones de los Autores (CRedit)

Carrillo, Ivan.: Conceptualization; Methodology; Formal analysis; Investigation; Writing – original draft. **Meza-Kubo, Victoria.:** Supervision; Writing – review & editing; Formal analysis. **Pellegrin, Luis.:** Supervision; Methodology; Formal análisis; Writing – review & editing ; Validation.

8. Conflicto de Interés

Los autores declaran no tener conflictos de interés.

9. Declaración de Disponibilidad de Datos

Los datos están disponibles a través del autor de correspondencia previa solicitud razonable.

10. Bioética

El estudio fue aprobado por un comité de ética de la universidad. Todas las participantes firmaron un documento de consentimiento informado.

11. Declaración de Uso de Inteligencia Artificial

Los autores declaran que no se utilizaron herramientas de IA generativa en la preparación de este manuscrito.

12. Referencias

- [1] DESA, «World Population Prospects 2024 Summary of Results», 2024, p. 1. [En línea]. Disponible en: https://population.un.org/wpp/assets/Files/WPP_2024_Key-Messages.pdf (Consultado Marzo, 15, 2025)
- [2] United Nations Department for Economic and Social Affairs, *World Population Prospects 2024: Summary of Results*. S.I.: United Nations, 2025. [En línea]. Disponible en: https://population.un.org/wpp/assets/Files/WPP_2024_Summary-of-Results.pdf (Consultado Marzo, 15, 2025)
- [3] K. Kim, S. S. Gollamudi, y S. Steinhubl, «Digital technology to enable aging in place», *Exp. Gerontol.*, vol. 88, pp. 25-31, feb. 2017, doi: 10.1016/j.exger.2016.11.013.
- [4] M. F. H. López, «La situación demográfica en México. Panorama desde las proyecciones de población», 2013, [En línea].Disponible en: http://www.conapo.gob.mx/work/models/CONAPO/Resource/1720/1/images/1-La_Situacion_Demografica_En_Mexico.pdf (Consultado Marzo, 12, 2025)
- [5] T.-S. Lee *et al.*, «A Brain-Computer Interface Based Cognitive Training System for Healthy Elderly: A Randomized Control Pilot Study for Usability and Preliminary Efficacy», *PLoS ONE*, vol. 8, n.º 11, p. e79419, nov. 2013, doi: 10.1371/journal.pone.0079419.
- [6] L. Mendes, J. Oliveira, F. Barbosa, y M. Castelo-Branco, «A Conceptual View of Cognitive Intervention in Older Adults With and Without Cognitive Decline—A Systemic Review», *Front. Aging*, vol. 3, p. 844725, mar. 2022, doi: 10.3389/fragi.2022.844725.
- [7] S. J. Oh, S. Seo, J. H. Lee, M. J. Song, y M.-S. Shin, «Effects of smartphone-based memory training for older adults with subjective memory complaints: a randomized controlled trial», *Aging Ment. Health*, vol. 22, n.º 4, pp. 526-534, abr.

- 2018, doi: 10.1080/13607863.2016.1274373.
- [8] B. Klimova y M. Valis, «Smartphone Applications Can Serve as Effective Cognitive Training Tools in Healthy Aging», *Front. Aging Neurosci.*, vol. 9, p. 436, ene. 2018, doi: 10.3389/fnagi.2017.00436.
- [9] A. C. M. Bauer y G. Andringa, «The Potential of Immersive Virtual Reality for Cognitive Training in Elderly», *Gerontology*, vol. 66, n.º 6, pp. 614-623, 2020, doi: 10.1159/000509830.
- [10] P. Gamito *et al.*, «Cognitive Stimulation of Elderly Individuals with Instrumental Virtual Reality-Based Activities of Daily Life: Pre-Post Treatment Study», *Cyberpsychology Behav. Soc. Netw.*, vol. 22, n.º 1, pp. 69-75, ene. 2019, doi: 10.1089/cyber.2017.0679.
- [11] L. Lopez-Samaniego, B. Garcia-Zapirain, y A. Mendez-Zorrilla, «Memory and accurate processing brain rehabilitation for the elderly: LEGO robot and iPad case study», *Biomed. Mater. Eng.*, vol. 24, n.º 6, pp. 3549-3556, nov. 2014, doi: 10.3233/BME-141181.
- [12] A. Palumbo, V. Gramigna, B. Calabrese, y N. Ielpo, «Motor-Imagery EEG-Based BCIs in Wheelchair Movement and Control: A Systematic Literature Review», *Sensors*, vol. 21, n.º 18, p. 6285, sep. 2021, doi: 10.3390/s21186285.
- [13] J. M. Toribio-Guzmán, E. Parra Vidales, M. ^a J. Viñas Rodríguez, Y. Bueno Aguado, M. ^a T. Cid Bartolomé, y M. A. Franco-Martín, «Rehabilitación cognitiva por ordenador en personas mayores: programa gradior», *Aula*, vol. 24, n.º 0, p. 61, jul. 2018, doi: 10.14201/aula2018246175.
- [14] V. Palumbo y F. Paterno, «Micogito: a Serious Gamebook Based on Daily Life Scenarios to Cognitively Stimulate Older Adults», en *Proceedings of the Conference on Information Technology for Social Good*, Roma Italy: ACM, sep. 2021, pp. 163-168. doi: 10.1145/3462203.3475889.
- [15] S. Kim, W. Yao, y X. Du, «Exploring Older Adults' Adoption and Use of a Tablet Computer During COVID-19: Longitudinal Qualitative Study», *JMIR Aging*, vol. 5, n.º 1, p. e32957, mar. 2022, doi: 10.2196/32957.
- [16] E. Hargittai, A. M. Piper, y M. R. Morris, «From internet access to internet skills: digital inequality among older adults», *Univers. Access Inf. Soc.*, vol. 18, n.º 4, pp. 881-890, nov. 2019, doi: 10.1007/s10209-018-0617-5.
- [17] S. J. Czaja y S. Z. Weingast, «The changing face of aging: Characteristics of older adult user groups», *Gerontechnology*, vol. 19, n.º 2, pp. 115-124, jul. 2020, doi: 10.4017/gt.2020.19.2.004.00.
- [18] K. Pai, R. Kallimani, S. Iyer, B. Uma Maheswari, R. Khanai, y D. Torse, «A Survey on Brain-Computer Interface and Related Applications», en *Machine Intelligence for Internet of Medical Things: Applications and Future Trends*, M. Ouaisa, M. Ouaisa, Z. Boulouad, I. Ullah Khan, y S. Iyer, Eds., Bentham Science Publishers, 2023, pp. 210-228. doi: 10.2174/9789815080445123020016.
- [19] K. Värbu, N. Muhammad, y Y. Muhammad, «Past, Present, and Future of EEG-Based BCI Applications», *Sensors*, vol. 22, n.º 9, p. 3331, abr. 2022, doi: 10.3390/s22093331.
- [20] R. Abiri, S. Borhani, E. W. Sellers, Y. Jiang, y X. Zhao, «A comprehensive review of EEG-based brain-computer interface paradigms», *J. Neural Eng.*, vol. 16, n.º 1, p. 011001, feb. 2019, doi: 10.1088/1741-2552/aaf12e.
- [21] G. Li, C. H. Lee, J. J. Jung, Y. C. Youn, y D. Camacho, «Deep learning for EEG data analytics: A survey», *Concurr. Comput. Pract. Exp.*, vol. 32, n.º 18, p. e5199, sep. 2020, doi: 10.1002/cpe.5199.
- [22] M. Bamdad, H. Zarshenas, y M. A. Auais, «Application of BCI systems in neurorehabilitation: a scoping review», *Disabil. Rehabil. Assist. Technol.*, vol. 10, n.º 5, pp. 355-364, sep. 2015, doi: 10.3109/17483107.2014.961569.
- [23] J. Sabio, N. S. Williams, G. M. McArthur, y N. A. Badcock, «A scoping review on the use of consumer-grade EEG devices for research», *PLOS ONE*, vol. 19, n.º 3, p. e0291186, mar. 2024, doi: 10.1371/journal.pone.0291186.
- [24] L. Rizzo, P. Zicari, F. Cicirelli, A. Guerrieri, M. Micieli, y A. Vinci, «A Study on Consumer-Grade EEG Headsets in BCI Applications», en *2024 IEEE Conference on Pervasive and Intelligent Computing (PICom)*, Boracay Island, Philippines: IEEE, nov. 2024, pp. 67-74. doi: 10.1109/PICom64201.2024.00016.
- [25] W. Zhang, C. Tan, F. Sun, H. Wu, y B. Zhang, «A Review of EEG-Based Brain-Computer Interface Systems Design», *Brain Sci. Adv.*, vol. 4, n.º 2, pp. 156-167, dic. 2018, doi: 10.26599/BSA.2018.9050010.
- [26] K. Haltas, A. Erguzen, y E. Erdal, «Classification methods in EEG based motor imagery BCI systems», en *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Turkey: IEEE, oct. 2019, pp. 1-5. doi: 10.1109/ISMSIT.2019.8932947.
- [27] H. Altaheri *et al.*, «Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: a review», *Neural Comput. Appl.*, vol. 35, n.º 20, pp. 14681-14722, jul. 2023, doi: 10.1007/s00521-021-06352-5.
- [28] M. F. Saputra, N. A. Setiawan, y I. Ardiyanto, «Deep Learning Methods for EEG Signals Classification of Motor Imagery in BCI», *IJITEE Int. J. Inf. Technol. Electr. Eng.*, vol. 3, n.º 3, p. 80, dic. 2019, doi: 10.22146/ijitee.48110.
- [29] A. Tyagi y V. Nehra, «Classification of motor imagery EEG signals using SVM, k-NN and ANN», *CSI Trans. ICT*, vol. 4, n.º 2-4, pp. 135-139, dic. 2016, doi: 10.1007/s40012-016-0091-2.
- [30] M. Y. Hossain y A. Sayeed, «A Comparative Study of Motor Imagery (MI) Detection in Electroencephalogram (EEG) Signals Using Different Classification Algorithms», en *2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI)*, Rajshahi, Bangladesh: IEEE, jul. 2021, pp. 1-6. doi: 10.1109/ACMI53878.2021.9528276.
- [31] J. Kevric y A. Subasi, «Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system», *Biomed. Signal Process. Control*, vol. 31, pp. 398-406, ene. 2017, doi: 10.1016/j.bspc.2016.09.007.
- [32] N. E. Md Isa, A. Amir, M. Z. Ilyas, y M. S. Razalli, «Motor imagery classification in Brain computer interface (BCI) based on EEG signal by using machine learning technique», *Bull. Electr. Eng. Inform.*, vol. 8, n.º 1, pp. 269-275, mar. 2019, doi: 10.11591/eei.v8i1.1402.

- [33] H. Nisar, K. Wee Boon, Y. Kim Ho, y T. Shen Khang, «Brain-Computer Interface: Feature Extraction and Classification of Motor Imagery-Based Cognitive Tasks», en *2022 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)*, Shah Alam, Malaysia: IEEE, jun. 2022, pp. 42-47. doi: 10.1109/I2CACIS54679.2022.9815460.
- [34] N. Sharma *et al.*, «Recent Trends in EEG-Based Motor Imagery Signal Analysis and Recognition: A Comprehensive Review», *IEEE Access*, vol. 11, pp. 80518-80542, 2023, doi: 10.1109/ACCESS.2023.3299497.
- [35] J. R. Wolpaw, J. D. R. Millán, y N. F. Ramsey, «Brain-computer interfaces: Definitions and principles», en *Handbook of Clinical Neurology*, vol. 168, Elsevier, 2020, pp. 15-23. doi: 10.1016/B978-0-444-63934-9.00002-0.
- [36] C. Rashmi y C. Sahntala, «EEG artifacts detection and removal techniques for brain computer interface applications: a systematic review», *Int. J. Adv. Technol. Eng. Explor.*, vol. 9, n.º 88, 2021, doi: 10.19101/IJATEE.2021.874883.
- [37] D. D. Mondal y M. Alagirisamy, «A Detailed Study on IIR-FIR Filters and Design of a Graphical User Interface for Simulation of EEG Signals», *Res. J. Comput. Syst. Eng.*, vol. 4, n.º 2, pp. 216-225, dic. 2023, doi: 10.52710/rjcsce.89.
- [38] D. Bansal y R. Mahajan, «EEG-Based Brain-Computer Interfacing (BCI)», en *EEG-Based Brain-Computer Interfaces*, Elsevier, 2019, pp. 21-71. doi: 10.1016/B978-0-12-814687-3.00002-8.
- [39] P. D. E. Baniqued *et al.*, «Brain-computer interface robotics for hand rehabilitation after stroke: a systematic review», *J. NeuroEngineering Rehabil.*, vol. 18, n.º 1, p. 15, ene. 2021, doi: 10.1186/s12984-021-00820-8.
- [40] D. Marcos-Martínez, V. Martínez-Cagigal, E. Santamaría-Vázquez, S. Pérez-Velasco, y R. Hornero, «Neurofeedback Training Based on Motor Imagery Strategies Increases EEG Complexity in Elderly Population», *Entropy*, vol. 23, n.º 12, p. 1574, nov. 2021, doi: 10.3390/e23121574
- [41] Y. Miao *et al.*, «BCI-Based Rehabilitation on the Stroke in Sequela Stage», *Neural Plast.*, vol. 2020, pp. 1-10, dic. 2020, doi: 10.1155/2020/8882764.
- [42] Lobo A, Saz P, Marcos G, Día JL, de la Cámara C, Ventura T, Morales Asín F, Fernando Pascual L, Montañés JA, Aznar S. Revalidación y normalización del Mini-Examen Cognoscitivo (primera versión en castellano del Mini-Mental Status Examination) en la población general geriátrica [Revalidation and standardization of the cognition mini-exam (first Spanish version of the Mini-Mental Status Examination) in the general geriatric population]. *Med Clin (Barc)*. 1999 Jun 5;112(20):767-74. Spanish. Erratum in: *Med Clin (Barc)* 1999 Jul 10; 113(5):197. PMID: 10422057. [En línea] <https://pubmed.ncbi.nlm.nih.gov/10422057/>
Disponible en: https://www.researchgate.net/profile/Tirso-Faci/publication/232425808_Revalidacion_y_normalizacion_del_Mini-Examen_Cognoscitivo_primera_version_en_castellano_del_Mini-Mental_Status_Examination_en_la_poblacion_general_geriatica/links/53ea354a0cf2dc24b3cb1491/Revalidacion-y-normalizacion-del-Mini-Examen-Cognoscitivo-primera-version-encastellano-del-Mini-Mental-Status-Examination-en-la-poblacion-general-geriatrica.pdf