

## **Propuesta de interfaz cerebro computadora realizada en una plataforma de bajo costo para la interpretación de la imaginación de movimiento**

Marcos Alejandro Garibay Campos<sup>1</sup>, Antonio Alarcón Paredes<sup>1</sup>,  
Jessica Cantillo Negrete<sup>2</sup>, Rubén Isaac Cariño Escobar<sup>2</sup>,  
Gustavo Adolfo Alonso Silverio<sup>1</sup>

<sup>1</sup> Maestría en Ingeniería para la Innovación y Desarrollo Tecnológico,  
Chilpancingo, Guerrero,  
México

<sup>2</sup> Instituto Nacional de Rehabilitación Luis Guillermo Ibarra Ibarra,  
México

{10123701,aalarcon,gsilverio}@uagro.mx,  
jessica.cantillo.negrete@gmail.com, rubencarinoe@hotmail.com

**Resumen.** Las Interfaces cerebro computadora (ICC) son sistemas que permiten al usuario crear un canal artificial de comunicación entre el cerebro y un dispositivo periférico haciendo uso de la actividad cerebral, la imaginación motora consiste en incorporar el movimiento voluntario sin depender de la capacidad motora de la persona activando patrones neuronales similares a la ejecución de movimiento, en base a este principio se ha permitido el uso de las ICC como una herramienta auxiliar en el campo de la rehabilitación. Un inconveniente al realizar proyectos de este tipo es que el costo de los elementos necesarios para su desarrollo es muy alto. En el presente trabajo se propone una ICC para la interpretación de la imaginación de movimiento desarrollada en una plataforma de bajo costo que permita evaluar la potencialidad de una ICC de estas características.

**Palabras clave:** ICC, imaginación motora, bajo costo, interfaz cerebro computadora.

### **Brain Computer Interface Proposal Made in a Low-cost Platform for the Interpretation of the Movement Imagination**

**Abstract.** Brain Computer Interfaces (BCI) are systems that allow the user to create an artificial communication channel between the brain and a peripheral device making use of brain activity, motor imagery consists of incorporating voluntary movement without depending on the motor capacity of the person, activating neural patterns similar to the execution of movement, based on this principle has allowed the use of BCI as an auxiliary tool in the field of

rehabilitation. A disadvantage when carrying out projects of this type is that the cost of the necessary elements for its development is very high. In the present work we propose a BCI for the interpretation of the imagination of movement developed on a low-cost platform that allows evaluating the potential of a BCI of these characteristics.

**Keywords:** BCI, motor imagery, low cost, brain computer interface.

## 1. Introducción

Las interfaces cerebro computadora (ICC) son sistemas que permiten al usuario crear un canal artificial de comunicación entre el cerebro y un dispositivo externo mediante la traducción de las señales cerebrales (Lotte et al., 2018), la imaginería motora (MI) o imaginación de movimiento consiste en la evocación de la persona de un movimiento o gesto para aprender o mejorar su ejecución, es decir se incorpora el movimiento voluntario sin depender de la capacidad motora de la persona y está activa patrones neuronales similares a la ejecución de movimiento (Fernández-Gómez & Sánchez-Cabeza, 2018) en el campo de la rehabilitación han sido una propuesta aceptada solo como herramienta auxiliar debido a la falta de evidencia a largo plazo para apoyar su relevancia clínica como se menciona en (Teo & Chew, 2014).

Para las ICC utilizadas en el campo de rehabilitación se busca identificar los fenómenos ocurridos en la actividad cerebral como los que se relacionan con la MI.

En trabajos como en (Khan et al., 2020) se han desarrollado y evaluado algoritmos para optimizar la interpretación de los patrones generados por la MI logrando obtener mejoras en los algoritmos de extracción de características que se reflejan en los rendimientos de clasificación, lo que implica que el peso de los algoritmos utilizados para buscar las características de interés complementan los rendimientos obtenidos por los sistemas de este tipo y acredita la exploración de electroencefalógrafos de bajo costo que utilicen algoritmos robustos para la interpretación de la MI.

La mayoría de los trabajos documentados han sido desarrollados en plataformas de licencia como Matlab como los presentados en (Roy et al., 2022) y a su vez, la mayoría de los *toolkits* especializados para sistemas ICC se han desarrollado para dicho entorno como por ejemplo EEGLAB, EEGVIS o Brainstorm. Los gastos que conllevan mantener una licencia para estas plataformas afectan directamente con la continuidad de los proyectos de ICC y con el desarrollo de nuevos algoritmos, de ahí la necesidad de migrar estos sistemas a plataformas de código abierto que puedan presentar la misma robustez. Esto aunado a que existen pocos dispositivos que sirvan como electroencefalógrafos monetariamente accesibles.

Aura® es una plataforma que permite utilizar su hardware para obtener señales de electroencefalograma (EEG) y es un dispositivo monetariamente accesible comparado con los equipos de grado médico existentes en el mercado, Aura® es compatible con la librería Lab Streaming Layer (LSL). LSL es una herramienta de uso libre que permite capturar las señales obtenidas por los electrodos de Aura®, Python es un lenguaje con

**Tabla 1.** Tabla de precios de dispositivos para ICC.

<b>Dispositivos de grado medico</b>				
<b>Fabricante</b>	<b>Modelo</b>	<b>Costo (USD)</b>	<b>Canales</b>	<b>Velocidad de muestreo</b>
g.tec	USB.Amp	15818	Hasta 16	38.4 Khz
g.tec	USB.Nutilus	7300	Hasta 64	1.024 Mhz
g.tec	USB.Hiamp	64386	Hasta 256	38.4 Khz
<b>Dispositivos comerciales</b>				
<b>Fabricante</b>	<b>Modelo</b>	<b>Costo (USD)</b>	<b>Canales</b>	<b>Velocidad de muestreo</b>
Emotiv	Emotiv Epoc x14	850	14	256 Hz
Mirai Innovation	Aura	3799	8	250 Hz
OpenBCI	CytonBiosensing Board	1543	8	250 Hz

una gran variedad de librerías de desarrollo, fácil de aprender, con una gran comunidad desarrolladores y foros, y es gratuito.

Adicionalmente Python es compatible con librerías robustas para el procesamiento matemático como Scipy y Numpy, para ciencia de datos como Pandas y para machine learning o Deep learning como Teano, Scikit-learn, TensorFlow y Keras por ejemplo, estas librerías pueden ofrecer una gran variedad de posibilidades de mejoramiento a los algoritmos existentes para la interpretación de patrones de MI en las ICC usadas en el campo de rehabilitación.

Por lo anteriormente descrito, en este trabajo se propone una ICC desarrollada en Python para la interpretación de la MI, utilizando la plataforma de Aura® para leer la actividad cerebral de los usuarios, dando como resultado una ICC de precio accesible y desarrollada en un lenguaje de código abierto, logrando evaluar la potencialidad de un electroencefalógrafo de bajo costo para su uso en sistemas de este tipo.

## 2. Trabajos relacionados

En (Martinez-Leon et al., 2016) habla sobre que ha habido poca discusión sobre el rendimiento de los dispositivos para EEG de bajo costo cuando se comparan con dispositivos de EEG profesionales y de investigación. El artículo evalúa un dispositivo de bajo costo, el Emotiv EPOC, en un problema de MI. Se logró concluir que, desde la perspectiva de una aplicación de trabajo final, es demostrado que el rendimiento de este dispositivo es comparable al que se encuentra en dispositivos profesionales cuando se usa el mismo número de sensores y posiciones de sensores.

Como se menciona en (McCrimmon et al., 2017) los sistemas ICC de bajo costo no presentan evidencia suficiente para evaluar si su diseño económico compromete su rendimiento, por lo tanto desarrollaron una ICC portátil de bajo costo y compararon su rendimiento con el de una BCI convencional.

El estudio demuestra que las plataformas ICC integradas basadas en un electroencefalógrafo de bajo costo pueden lograr un rendimiento similar a un sistema ICC convencional que tiene más canales y recursos computacionales. Se menciona que

los sistemas de bajo costo hacen que las ICC sean más accesibles para los usuarios, y aumentan la viabilidad de grandes ensayos clínicos que involucren el uso de las ICC.

Por otro lado, se menciona que los sistemas ICC actuales diseñados con dispositivos de alta calidad no son prácticos para su uso fuera de los laboratorios de investigación debido a su configuración/operación complicada, los costos prohibitivos y falta de portabilidad.

En (Peterson et al., 2020) se menciona que una de las principales limitaciones para el uso generalizado de los dispositivos ICC es el alto costo asociado a un equipo de alta calidad utilizado para capturar las señales biomédicas. Con el objetivo de acercar estos sistemas a los usuarios finales, han surgido diferentes alternativas de bajo costo para el consumidor. Se comenta que aún no se ha explorado cómo estas tecnologías de nivel de consumidor pueden integrarse y usarse para ICC basadas en MI. En (Peterson et al., 2020) Se realiza un análisis de la calidad de las señales adquiridas y la capacidad de detección de MI y también se menciona que encontraron que mediante un método basado en un banco de filtros, se pueden lograr incrementar los rendimientos de clasificación de las ICC construidas bajo dispositivos de bajo de costo logrando brindar evidencia de que se puede construir un ICC basada en MI de bajo costo.

En (García-Moreno et al., 2020) se utilizó una diadema BCI de bajo costo para detectar Imágenes motoras de electroencefalografía (EEG). Además, se discute acerca de la influencia del uso de datos sin procesar. También se discute sobre la influencia de la actividad de ciertas bandas de frecuencia sobre otras en la tarea propuesta. Se menciona que los resultados representan un descubrimiento prometedor para la adopción de tecnologías de bajo costo.

En base a lo anteriormente descrito se propone una ICC desarrollada en Python de bajo costo que pueda interpretar la imaginación de movimiento con una interfaz de usuario específica para dicha aplicación para explorar la potencialidad de una ICC de estas características.

### 3. Materiales y métodos

#### 3.1. Selección del amplificador para el diseño de la ICC

Existen diversos dispositivos con los cuales se pueden capturar las señales de electroencefalografía a continuación se presenta la tabla 1 con algunos de los dispositivos de grado médico que ofrecen las mejores prestaciones para poder ensamblar una ICC y a su vez se presentan las opciones comerciales de este tipo de dispositivos. Cabe destacar que el precio expuesto en los dispositivos de grado medico contemplan una configuración básica de componentes, el precio expuesto contempla el gorro y el amplificador, pero existen diversas opciones de electrodos, diversas herramientas para el desarrollo de la aplicación ICC y algunos accesorios extras que se pueden consultar en la página del fabricante.

Como se puede apreciar existe una diferencia significativa en cuanto al precio de los dispositivos comerciales con los dispositivos de grado médico, si bien los dispositivos comerciales no brindan la misma garantía de confiabilidad que los sistemas de grado médico y tampoco las mismas prestaciones son un buen punto de partida para realizar proyectos experimentales de este tipo para poder evaluar su potencialidad real.

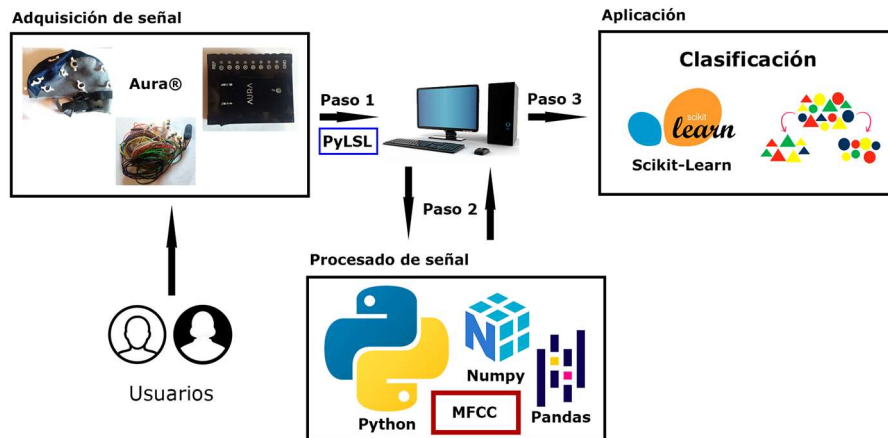


Fig. 1. Esquema propuesto de la ICC.

En general se contempla utilizar un dispositivo que sea capaz de leer la actividad cerebral y mediante software poder traducir las muestras extraídas para poder encontrar los patrones generados por la MI. El dispositivo seleccionado fue Aura, En primera instancia es porque tiene características similares a los demás productos de la misma gama, además de que Aura posee electrodos con un conector estándar como el DIN42802, teniendo así la posibilidad de tener refacciones en caso de que los electrodos dejaran de funcionar o se rompieran.

En segunda instancia porque es un dispositivo que se encuentra disponible en el Consejo de ciencia tecnología e innovación del estado de Guerrero (COCYTIEG) y se logró gestionar que se nos prestara el dispositivo.

### 3.2 ICC propuesta

Con el fin de conseguir el objetivo del presente trabajo se buscaron las herramientas más accesibles que pudieran conseguir buenos resultados de acuerdo con el estado del arte. La propuesta del presente trabajo se presenta con la metodología en la figura 1.

Como se menciona en (Mridha et al., 2021) la arquitectura básica de un sistema ICC consiste en la adquisición de la señal que es el proceso de tomar las muestras de las señales que miden la actividad cerebral, el pre procesamiento que es el proceso mediante él se quita el ruido y las señales indeseadas de las muestras captadas y ayuda a limpiar la señal con diferentes métodos y filtros, la extracción de características que implica analizar la señal y extraer los datos de utilidad empleando algoritmos de procesamiento que permitan la extracción de características del cerebro y la clasificación que ayuda a determinar el tipo de tarea mental que la persona está ejecutando. Otros ejemplos de arquitecturas para ICC bajo este esquema se pueden consultar en (Attallah et al., 2020; Salazar-Ramirez et al., 2019).




Fig. 2. Línea de tiempo de captura de ensayo.

### 3.3. Adquisición de la señal

La lectura de las señales de la actividad cerebral se tomó con Aura®, se utilizó PyLSL para poder comunicar el software del amplificador de Aura con Python, más información sobre aura en la sección 3.6, para más información sobre las instrucciones y forma en que se adquirieron los datos consultar la sección 3.7.

### 3.4. Procesado de la señal

La señal se procesó utilizando numpy y Pandas, esto debido a que pandas presenta muchas facilidades para exportar los conjuntos de datos a un formato estándar como es CSV, numpy es la librería de Python más popular para el procesamiento matemático, realiza las operaciones de una manera rápida y eficaz, y tiene métodos que ayudan a manipular matrices fácilmente, se utilizó Mel-frequency cepstral coefficients (MFCC) de librosa como extractor de características para encontrar la secuencia de MFCC captada por cada canal, más información acerca de MFCC se puede consultar en la sección 3.8. Adicionalmente se utilizaron filtros incluidos en el software del fabricante usando un pasabandas de 5-50 Hz y un elimina banda de 60 Hz esto es debido a que son los que el fabricante recomienda como óptimos.

### 3.5. Aplicación

El fin del presente proyecto tiene una parte de naturaleza exploratoria por lo que la fase de aplicación de esta versión consiste en evaluar el rendimiento de los clasificadores considerados para posteriormente conjuntar el sistema con los elementos que presenten los mejores rendimientos. Para más información sobre los clasificadores seleccionados consultar la sección 3.9.

### 3.6. Aura

Aura® es un producto de Mirai Innovation que puede ser utilizado como electroencefalógrafo, electromiógrafo, electrocardiógrafo y electrooculógrafo. Tiene dos formas de enviar las señales a la computadora que son por medio de un cable USB o por Bluetooth. También incluye un software que puede visualizar la actividad

cerebral en tiempo real con algunos filtros pasa bandas y elimina banda predeterminados en el sistema.

### **3.7. Adquisición**

Estudios como en (Batista et al., 2019) mencionan que existen fenómenos como los eventos relacionados a la sincronización (ERS) y eventos relacionados a la desincronización (ERD) que pueden ayudar a identificar los patrones generados por la MI. En base a esto se utiliza un filtro pasa bandas que tiene por defecto el software de Aura® (5-50 Hz) ya que como se describe en (Batista et al., 2019) el ritmo sensoriomotor (SMR) se encuentra entre el ritmo mu (8 – 12 Hz) y el ritmo beta (18 – 30 Hz) generalmente entre (12 – 17 Hz) aunque puede variar en algunas personas.

Se creó un conjunto de datos donde se puede diferenciar la MI de un estado de concentración que son las clases para evaluar por el clasificador y llamaremos clase 1 a la MI y clase 2 al estado de concentración.

Se pidió a los voluntarios estar lo más concentrados posible, que evitaran hacer parpadeos bruscos o muy constantes, evitar hacer movimientos que involucren a los músculos como los de las piernas o brazos, evitar respirar profundamente y tener una posición cómoda en la cual pudiesen estar lo más relajados posible. La captura del ensayo se ilustra en la línea de tiempo mostrada en la figura 2.

Los ensayos se capturan a una velocidad de 125 muestras por segundo y se usaron tres estímulos diferentes para mostrar en pantalla, cada uno indica lo que debe hacer el usuario. El primer estímulo muestra una animación de una mano que abre y cierra el puño, este estímulo indica al usuario que debe empezar a imaginar el movimiento para generar el patrón de MI, el segundo estímulo muestra una cruz que indica al usuario que debe dejar de imaginar el movimiento y concentrarse en observar la cruz en pantalla, el tercer estímulo muestra una pantalla azul que indica al usuario un descanso si es que necesita hacer un parpadeo prolongado para lubricar sus ojos, reacomodarse, rascarse o atender alguna incomodidad.

Para el primer y segundo estímulo se capturan 500 muestras respectivamente que toma un tiempo aproximado de 4 segundos para cada uno, el tercer estímulo dura un intervalo aleatorio de entre 3 a 6 segundos y sirve como señal para que el usuario pueda atender alguna incomodidad. Un ensayo se compone de las muestras obtenidas de un recorrido de estos 3 estímulos debidamente etiquetados con respecto al estímulo correspondiente capturado, se capturaron 25 ensayos por sujeto y se trabajó con 10 sujetos.

### **3.8. Extractor de características**

Se propone Mel Frequency Cepstral Coefficients (MFCC) como un extractor de características debido a que en (Medina et al., 2018) se menciona que se ha utilizado la transformada rápida de Fourier y la densidad de potencia espectral como extractores de características, y MFCC está basado en la transformada rápida de Fourier y tiene una base similar, además MFCC comúnmente se utiliza para el reconocimiento de patrones



Fig. 3. Interfaz gráfica para visualización de señales.



Fig. 4. Interfaz gráfica para visualización de señales.



Fig.5. ICC propuesta funcionando.

de voz con lo cual trabaja con señales de frecuencia al igual que la frecuencia se utiliza para poder interpretar la actividad cerebral.

Por defecto en diferentes scripts encontrados los coeficientes buscados van desde los 13 hasta los 20, una opción determinista para saber cuántos coeficientes encontrar sería probar por fuerza bruta con cuantos coeficientes da mejores resultados el clasificador,



pero para evitar excesivos consumos computacionales y para homogenizar los conjuntos de datos se propone usar uno de los valores por defecto que es 13.

### **3.9. Clasificador**

Como segunda fase de la etapa de procesamiento se evaluó con 4 diferentes modelos de clasificación además del Análisis discriminante lineal (LDA) que es el modelo más popular en ICC de este tipo. Se utilizaron algunos de los modelos de clasificación incluidos en la librería de Sklearn tal como Análisis discriminante lineal (LDA), Naive Bayes (NB), AdaBoost, vecinos más cercanos (KNN) y el clasificador de bosque aleatorio (RF), esto sustentado en que de manera general son los modelos más utilizados para la tarea de clasificación y existen algunos trabajos documentados donde utilizan estos clasificadores para ICC basados en la interpretación de MI.

En (Behri et al., 2018) se utilizan Naive Bayes, KNN y RF, específicamente, en (Miao et al., 2019) se utiliza Adaboost y en (Aggarwal & Chugh, 2019) utilizan LDA. Todos los clasificadores se utilizaron con sus valores por defecto en la librería de Sklearn.

### **3.10. Preparación del conjunto de datos y clasificación**

Una vez obtenidos los 25 ensayos requeridos se cuenta con los archivos CSV correspondientes a cada ensayo teniendo 9 columnas que corresponden a los 8 canales del amplificador y a la clase etiquetada de las muestras y 1000 filas que son las muestras obtenidas durante el ensayo que son 500 por cada clase.

Para cada archivo se utiliza Pandas para leerlo individualmente y transformarlo en matriz, se utiliza Numpy para transformar cada matriz de forma que se puedan extraer los 13 coeficientes de Mel en cada canal y se aplica el filtro MFCC.

Finalmente se obtienen dos filas, una para cada clase que llamaremos observaciones de 104 columnas que son los 13 coeficientes de Mel extraídos de cada canal. El filtro se aplica para cada uno de los ensayos, se obtienen las observaciones correspondientes a cada uno y se unen en un solo conjunto de datos.

El conjunto de datos final contiene un número de observaciones equivalente al doble del número de ensayos realizados ya que se obtiene una observación de la clase 1 y una de la clase 2 por cada ensayo. El conjunto de datos final es el que se utiliza para usar los 5 clasificadores considerados y obtener las métricas consideradas para evaluar el sistema mencionadas en la sección 3.11.

### **3.11. Validación**

Como parámetros de validación del sistema se consideraron dos enfoques. El primer enfoque consiste en la validación cruzada usando leave one out (LOO) ya que como se comenta en (Magnusson et al., 2019) es un enfoque para evaluar la generalización de un modelo y arroja datos más exactos del desempeño de un conjunto de datos. El segundo enfoque consiste en usar el método tradicional para obtener los conjuntos de prueba y entrenamiento haciendo 500 iteraciones usando el 25% de los datos aleatoriamente como conjunto de prueba, los resultados se guardan para después




Fig. 6. Resultados de accuracy con LOO.




Fig. 7. Resultados de accuracy promedio con 500 iteraciones.

calcular el promedio de todas las iteraciones realizadas, se considera obtener el promedio de las 500 iteraciones de las métricas de accuracy, precision y puntaje f1.

AdaBoost (84.4%) y Naive Bayes (82.4%) fueron los clasificadores que mejor rendimiento promedio tuvieron.

Para el enfoque por promedio de los resultados obtenidos en 500 iteraciones usando el 25% de datos como validación se presentan las figuras 7, 8 y 9 que corresponden al resumen de los resultados obtenidos representados por gráficas para las métricas de accuracy, precision y puntaje F1 respectivamente.




Fig. 8. Resultados de precisión promedio con 500 iteraciones.




Fig. 9. Resultados de puntaje F1 promedio con 500 iteraciones.

Como se puede observar en las gráficas del porcentaje promedio de 500 iteraciones en los resultados de accuracy, precision y puntaje F1 ronda entre el 60% y 91% a excepción del puntaje obtenido por Sujeto 3 (S3) en puntaje F1 con Naive Bayes que fue de 53%. En estas tres métricas consideradas los clasificadores que tuvieron los mejores puntajes promedio generales utilizando la metodología propuesta fueron

RandomForest(82.3%, 82.9%, 81.9%), AdaBoost(79.7%, 80.3%, 78.9%) y Naive Bayes(79.6%, 79.1%, 78.8%).

#### 4. Resultados

A continuación, se presentan las ventanas realizadas para hacer funcionar el sistema.

Como se puede apreciar en la figura 6 se obtuvieron resultados desde el 60% hasta el 96% de clasificación correcta con los diferentes clasificadores utilizados. Los resultados por sujeto están representados por cada línea correspondiente a la letra "S" y el número que le correspondió al realizar sus ensayos, RandomForest (86.6%).

De acuerdo con las características consideradas en este estudio se observó que el clasificador que mejor rendimiento general obtuvo bajo estas condiciones particulares fue RandomForest con un promedio de 86.6% evaluándolo con LOO y a su vez fue el que mejor rendimiento general obtuvo usando el promedio de resultados obtenidos en 500 iteraciones que fue de 82.3%, 82.9% y 81.9% para accuracy, precision y puntaje F1 respectivamente.

En el aspecto individual de los sujetos evaluados el mejor resultado con LOO fue el obtenido por el Sujeto 2 con el clasificador de AdaBoost que fue de 96%, en el enfoque por iteraciones el mejor resultado en la métrica de accuracy fue el obtenido por el sujeto 4 con KNN, en precision el Sujeto 1 en Naive Bayes y Random Forest, así como el Sujeto 5 en KNN obtuvieron un puntaje de 91% y en puntaje F1 el mejor resultado lo obtuvo el Sujeto 4 con KNN y NB con un puntaje de 91% para ambos clasificadores.

En contraste con los resultados obtenidos en (Behri et al., 2018) donde el enfoque es utilizar WPD y MSPCA, se puede observar que en el trabajo de (Behri et al., 2018) los mejores clasificadores fueron KNN(94.57%), SVM(89.48%) y RandomForest(78.09%) utilizando validación cruzada de 10-folds para evaluarlos en la métrica de accuracy, en el presente trabajo los mejores clasificadores fueron RandomForest(86.6%), AdaBoost(84.4%) y Naive Bayes(82.4%) utilizando LOO para evaluarlos en accuracy.

Con respecto a los modelos de clasificación coincidentes entre ambos trabajos se observa que en el presente trabajo se obtuvieron resultados más bajos de clasificación con KNN que los presentados en (Behri et al., 2018), obteniendo 78.6% para esta propuesta y 94.57% para el trabajo de (Behri et al., 2018). Pero se obtuvieron mejores resultados para el clasificador RandomForest con un puntaje de 86.6% en nuestro trabajo y de 78.09% en el trabajo de (Behri et al., 2018).

En (Miao et al., 2019) se evalúa con dos conjuntos de datos públicos el rendimiento de AdaBoost además de otros dos clasificadores utilizando dos enfoques de extracción de características, el clasificador AdaBoost tuvo mejor rendimiento promedio que los otros dos clasificadores, alcanzando un puntaje de accuracy de 78.4 y 80.6% para los conjuntos 1 y 2 respectivamente utilizando validación cruzada de 10-Folds para evaluar su rendimiento. En este trabajo se obtuvo un rendimiento de AdaBoost del 84.4% que es mayor que el resultado expuesto en el trabajo de (Miao et al., 2019) y se obtuvo utilizando validación cruzada con LOO. Lo cual es evidencia que el proceso de extracción de características con MFCC funciona eficientemente para ciertos clasificadores y puede considerarse una ventaja con respecto a otros trabajos.

Es importante considerar que el rendimiento de la ICC propuesta depende mucho de que la forma en que se adquieren las muestras sea lo más controlada posible, el factor más importante es garantizar el contacto adecuado entre el cuero cabelludo y el electrodo, otro factor importante es el estado del usuario al usar el sistema ya que factores como el sueño, el desinterés y la desconcentración afectan negativamente el rendimiento que obtienen los datos al ser clasificados, otros factores que afectan negativamente el rendimiento son los movimientos involuntarios como los tics por nervios o ansiedad.

Los ambientes utilizados para la experimentación con los usuarios se controlaron de la mejor manera posible, pero factores fuera del alcance de controlarlos como los ruidos de los automóviles, puertas, voces de fondo, el sonido de los pasos, etc. No se lograron suprimir del todo. Además de que la experimentación se dio con voluntarios que quisieran utilizar el sistema, pero algunos mostraron notables signos de desinterés o falta de atención.

## **5. Conclusiones y trabajo a futuro**

Se puede observar que la ICC obtuvo un rendimiento competitivo en los conjuntos de datos creados para la clasificación logrando el mejor puntaje promedio evaluado con leave one out de un 86.6%, a su vez en los promedios generales obtenidos por ejecutar 500 iteraciones usando el 25% aleatorio de los datos generados para validación del clasificador RandomForest presenta los puntajes más altos para la métricas evaluadas que son accuracy, precision y puntaje F1 con un puntaje de 82.3%, 82.9%, 81.9% respectivamente, es importante observar que AdaBoost y Naive Bayes mostraron rendimientos aceptables también, logrando un puntaje de 84.4% y 82.4% respectivamente en accuracy evaluándolos con leave one out y al ejecutar 500 iteraciones usando el 25% aleatorio de los datos generados para validación del clasificador AdaBoost obtuvo los puntajes de 79.7%, 80.3% y 78.9% para las métricas de accuracy, precisión y puntaje F1 respectivamente, y Naive Bayes 79.6%, 79.1% y 78.8% para dichas métricas.

Finalmente tenemos una propuesta de ICC de bajo costo desarrollada en una plataforma de código abierto que proporciona un rendimiento aceptable al interpretar y clasificar los patrones generados por la MI del usuario, siendo también flexible y escalable con la posibilidad de probar y desarrollar diferentes scripts para mejorar el rendimiento del sistema. El trabajo realizado es una primera versión de una ICC con estas características, se deben realizar más pruebas para explotar al máximo la potencialidad del sistema.

**Agradecimientos.** Agradecemos a Conacyt por financiar proyectos de ciencia como este, al Consejo de Ciencia y Tecnología del Estado de Guerrero (COCYTIEG) por habernos prestado el sistema Aura® utilizado para realizar este proyecto, al Ing. Leo Enver Garibay Campos jefe del departamento de fortalecimiento del COCYTIEG por intervenir como responsable del sistema Aura® a su cargo y también a todos los voluntarios que participaron en este experimento.

## Referencias

1. Aggarwal, S., Chugh, N.: Signal processing techniques for motor imagery brain computer interface: A review. *Array*, vol. 1-2 (2019) doi: 10.1016/j.array.2019.100003
2. Attallah, O., Abougharbia, J., Tamazin, M., Nasser, A. A.: A BCI system based on motor imagery for assisting people with motor deficiencies in the limbs. *Brain Sciences*, vol. 10, no. 11, pp. 864 (2020) doi: 10.3390/brainsci10110864
3. Batista, E., Serracín, S., Gómez, L., Moreno, R., Moreno, I.: Análisis y caracterización de señales eléctricas del cerebro utilizando interfaz cerebro computador. *Revista de Iniciación Científica*, vol. 5, pp. 110–113 (2019) doi: 10.33412/rev-ric.v5.0.2395
4. Behri, M., Subasi, A., Qaisar, S. M.: Comparison of machine learning methods for two class motor imagery tasks using EEG in brain-computer interface. In: *Advances in Science and Engineering Technology International Conferences (ASET)*, pp. 1–5 (2018) doi: 10.1109/ICASET.2018.8376886
5. Fernández-Gómez, E., Sánchez-Cabeza, Á.: Imaginería motora: revisión sistemática de su efectividad en la rehabilitación de la extremidad superior tras un ictus. *Rev. Neurol. (Ed. Impr.)*, vol. 66, no. 5, pp. 137–146 (2018)
6. Garcia-Moreno, F. M., Bermudez-Edo, M., Rodríguez-Fórtiz, M. J., Garrido, J. L.: A CNN-LSTM deep Learning classifier for motor imagery EEG detection using a low-invasive and low-Cost BCI headband. In: *16th International Conference on Intelligent Environments (IE)*, pp. 84–91 (2020) doi: 10.1109/IE49459.2020.9155016
7. Khan, M. A., Das, R., Iversen, H. K., Puthusserypady, S.: Review on motor imagery based BCI systems for upper limb post-stroke neurorehabilitation: From designing to application. *Computers in Biology and Medicine*, vol. 123, (2020) doi: 10.1016/j.compbimed.2020.103843
8. Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., Yger, F.: A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of Neural Engineering*, vol. 15, no. 3, 31005 (2018)
9. Magnusson, M., Andersen, M., Jonasson, J., Vehtari, A.: Bayesian leave-one-out cross-validation for large data. In: *International Conference on Machine Learning*, vol 97, pp. 4244–4253 (2019)
10. Martínez-Leon, J. A., Cano-Izquierdo, J. M., Ibarrola, J.: Are low cost Brain computer interface headsets ready for motor imagery applications? *Expert Systems with Applications*, 49, pp. 136–144 (2016) doi: 10.1016/j.eswa.2015.11.015
11. McCrimmon, C. M., Fu, J. L., Wang, M., Lopes, L. S., Wang, P. T., Karimi-Bidhendi, A., Liu, C. Y., Heydari, P., Nenadic, Z., Do, A. H.: Performance assessment of a custom, portable, and low-cost brain-computer interface platform. *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 10, pp. 2313–2320 (2017) doi: 10.1109/TBME.2017.2667579
12. Medina, B., Sierra, J. E., Ulloa, A. B.: Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI. *Revista ESPACIOS*, vol. 39, no. 22 (2018)
13. Miao, Y., Yin, F., Zuo, C., Wang, X., Jin, J.: Improved RCSP and AdaBoost-based classification for motor-imagery BCI. In: *IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, pp. 1–5 (2019) doi: 10.1109/CIVEMSA45640.2019.9071599
14. Mridha, M. F., Das, S. C., Kabir, M. M., Lima, A. A., Islam, M., Watanobe, Y.: Brain-computer interface: Advancement and challenges. *Sensors*, vol. 21, no. 17, pp. 5746 (2021) doi: 10.3390/s21175746

15. Peterson, V., Galván, C., Hernández, H., Spies, R.: A feasibility study of a complete low-cost consumer-grade brain-computer interface system. *Heliyon*, vol. 6, no. 3, pp. e03425 (2020) doi: 10.1016/j.heliyon.2020.e03425
16. Roy, G., Bhoi, A. K., Das, S., Bhaumik, S.: Cross-correlated spectral entropy-based classification of EEG motor imagery signal for triggering lower limb exoskeleton. *Signal, Image and Video Processing*, vol. 16, pp. 1–9 (2022) doi: 10.1007/s11760-022-02142-1
17. Salazar-Ramirez, A., Martin, J. I., Martinez, R., Arruti, A., Mugerza, J., Sierra, B.: A hierarchical architecture for recognising intentionality in mental tasks on a brain-computer interface. *Plos One*, vol. 14, no. 6, pp. e0218181 (2019) doi: 10.1371/journal.pone.0218181
18. Teo, W. P., Chew, E.: Is motor-imagery brain-computer interface feasible in stroke rehabilitation? *PM&R*, vol. 6, no. 8, pp. 723–728 (2014) doi: 10.1016/j.pmrj.2014.01.006