



UNIVERSIDAD NACIONAL AUTÓNOMA DE
MÉXICO

FACULTAD DE MEDICINA
INSTITUTO DE FISIOLÓGÍA CELULAR

IMPLEMENTACIÓN DE ESTRATEGIAS DE
ENTRENAMIENTO DE UNA INTERFAZ
CEREBRO-COMPUTADORA PARA
INCREMENTAR EL CONTROL DEL SISTEMA
POR PARTE DE PACIENTES CON
ENFERMEDAD VASCULAR CEREBRAL
DURANTE TERAPIAS DE REHABILITACIÓN

T E S I S

QUE PARA OBTENER EL TÍTULO DE:

LICENCIADO EN NEUROCIENCIAS

P R E S E N T A :

LUIS ARTURO FRANCESCHI JIMENEZ

TUTOR:

Dr. en C. RUBEN ISAAC CARIÑO ESCOBAR



NEUROCIENCIAS
UNAM

Ciudad Universitaria, CD. MX., 2024



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Dedicatorias

A mi abuela María de Lourdes Guédez, que me demostró en vida todo su amor y afecto a través del lenguaje de la cocina.

A mi abuelo Pedro José Márquina, que siempre fue un gran apoyo de amor y alegría para toda la familia.

Agradecimientos

Agradezco a mis tutores, el Dr. Ruben Isaac Cariño Escobar y la Dra. Jessica Cantillo Negrete por su apoyo, enseñanzas y guía durante todo este proceso cómo también por la oportunidad de trabajar con ellos. Igualmente, a mis compañeros de laboratorio Emiliano y Juan Carlos.

Agradezco a mis padres Sandra Dolores Jiménez Guédez y German Luis Franceschi Hung, quienes siempre han procurado darme la mejor educación y me han apoyado con su amor en cada decisión durante este camino. A mis tíos María Alejandra y Mateo, quienes me brindaron su afecto y perspectivas de la vida para seguir avanzando hacia un gran futuro. A mis amigos Johana, Paulina y Rodrigo, por ser los mejores compañeros que la universidad me pudo dar, trascendiendo más allá de lo escolar. A Mariana Rodríguez por haber sido un pilar importante de amor y apoyo durante todos estos años. Y a mi mascota Kenzo Clemente, por su gran compañía y ser un soporte incondicional.

Agradezco a la UNAM, especialmente a la Coordinación de Neurociencias por su apoyo constante a mi como estudiante; y a la Facultad de Medicina y al Instituto de Fisiología Celular por abrirme sus puertas y permitirme obtener una gran formación académica de los mejores investigadores en las neurociencias del país y del mundo.

Agradezco al Instituto Nacional de Rehabilitación “Luis Guillermo Ibarra Ibarra” y al Consejo Nacional de Humanidades Ciencias y Tecnologías (CONAHCYT) por la beca y el apoyo brindado por medio del proyecto “Validación de una interfaz cerebro-computadora para rehabilitación neurológica por medio de un ensayo clínico controlado y aleatorizado” con clave “SALUD-2018-02-B-S-45803”.

Agradezco a los integrantes del jurado de mi examen profesional, conformado por la Mtra. Ana María Escalante Gonzalbo, el Dr. Miguel Ángel Padilla Castañeda, el Dr. Augusto César Poot Hernández, el Dr. Erik Molino Minero Re y nuevamente, mi tutor, el Dr. Ruben Isaac Cariño Escobar. Agradezco el tiempo dedicado a revisar mi tesis y aportar desde sus áreas de expertise valiosos comentarios.

Por último, agradezco a México, por las oportunidades, por ser mi nuevo hogar y por permitirme demostrar que un mexicano nace donde le da la gana.

ÍNDICE

ABREVIATURAS Y SIGLAS.....	6
Resumen.....	7
Introducción	9
Marco teórico	11
Enfermedad vascular cerebral.....	11
Mecanismos celulares en la EVC y neuroplasticidad	12
Interfaces cerebro-computadora.....	13
Implementación de sistemas BCI en rehabilitación de EVC	17
Entrenamiento y desempeño con un sistema BCI en terapias de rehabilitación en el contexto de la EVC.....	17
Antecedentes.....	19
Planteamiento del problema	21
Justificación	22
Objetivos e hipótesis.....	22
Objetivo general	22
Objetivos específicos	22
Hipótesis	23
Metodología	23
Descripción de la base de datos	23
Proceso de entrenamiento de la etapa de procesamiento	25
Estrategias de entrenamiento propuestas	28
Análisis estadístico de los resultados	30
Resultados	31
Discusión	46
Conclusiones.....	54
Trabajo a futuro	55
Bibliografía	56

ABREVIATURAS Y SIGLAS

- AC (Acumulativa)
- ANOVA (Análisis de la Varianza)
- BCI (Interfaz Cerebro-Computadora)
- CSP (Patrones Espaciales Comunes)
- ECoG (Electrocorticografía)
- EEG (Electroencefalografía)
- ERD/ERS (Desincronización/Sincronización Relacionada al Evento)
- EVC (Enfermedad Vasular Cerebral)
- FBCSP (Banco de Filtros de CSP)
- fMRI (Imagen por Resonancia Magnética Funcional)
- FN (Falsos Negativos)
- fNIRS (Espectroscopia por Infrarrojo Cercano Funcional)
- FP (Falsos Positivos)
- ICA (Análisis de Componentes Independientes)
- IM (Intención de Movimiento)
- IN (Instantánea)
- kNN (K-Vecinos Más Cercanos)
- LDA (Análisis de Discriminante Lineal)
- MEG (Magnetoencefalografía)
- ML (Aprendizaje de Máquina)
- PCA (Análisis de Componentes Principales)
- PET (Tomografía de Emisión de Positrones)
- PSO (Optimización por Enjambre de Partículas)
- SA (Sesión Anterior)
- SNC (Sistema Nervioso Central)
- SVM (Máquina de Soporte Vectorial)
- VN (Verdaderos Negativos)
- VP (Verdaderos Positivos)

Resumen

Introducción: Las interfaces cerebro-computadora (BCI) son sistemas que, por medio de información extraída del sistema nervioso central, como la señal de electroencefalografía (EEG), permiten controlar dispositivos externos. Para ello, es necesario que se realice un entrenamiento de la etapa de procesamiento de la BCI para reconocer correctamente cada una de las tareas que debe efectuar el usuario. Actualmente, estos sistemas se han propuesto como posibles terapias de rehabilitación para pacientes con enfermedad vascular cerebral (EVC). No obstante, en estudios clínicos se ha presentado una variabilidad en la capacidad de control del sistema por parte de los pacientes, debido a diversos factores como la no estacionariedad de la señal de EEG. Por lo que se hace necesario la búsqueda de estrategias de entrenamiento del sistema BCI que permitan a los pacientes incrementar su control durante intervenciones terapéuticas con estos sistemas.

Metodología: Utilizando una base de datos de señales de EEG de 12 pacientes con EVC que efectuaron de 11 a 30 sesiones de rehabilitación, se exploró y evaluó el desempeño de un sistema BCI al utilizar tres estrategias de entrenamiento: a) entrenando con los datos de una sesión anterior (SA), b) entrenando con todos los datos de las sesiones anteriores (AC), y c) entrenando con los datos de la sesión anterior y de la sesión cursante (IN). Los entrenamientos se realizaron de forma retrospectiva, simulando un protocolo de rehabilitación sesión a sesión, obteniendo de forma subsecuente el desempeño con el sistema.

Resultados y conclusiones: Se observaron diferencias significativas entre las tres estrategias en términos de porcentaje de exactitud, sensibilidad y especificidad. La estrategia IN fue aquella con la que se observaron los mejores resultados de porcentaje de exactitud, con una mediana de 76.38% (Q1 = 68.68%, Q3 = 81.53%), seguida por la estrategia AC con 71.67% (Q1 = 65.07%, Q3 = 78.54%) y por la estrategia SA con 69.17% (Q1 = 58.96%, Q3 = 77.43%). Además, con la estrategia IN se presentó una tendencia a mejorar el desempeño y disminuir la variabilidad del sistema BCI mientras transcurrían las sesiones. Estos resultados sugieren que entrenar el sistema BCI utilizando los datos más recientes, adquiridos durante la misma sesión de terapia, podría

mejorar el desempeño del sistema y aminorar las variaciones ocasionadas por la no estacionariedad de la señal de EEG, entre otros factores.

Introducción

La enfermedad vascular cerebral (EVC) es considerada la segunda causa de muerte a nivel mundial [1] y la quinta en México, con un número de defunciones de 44,352 habitantes en 2019 [2]. También es considerada como una de las primeras causas de discapacidad en personas adultas en México, estimando que afecta a 1 millón 315 mil habitantes de los cuales el 42.9% son hombres y el 57.1% son mujeres [2,3]. Además, se estima que ocurren 170 mil nuevos casos al año, de los cuales un 20% pueden fallecer en los primeros 30 días y siete de cada 10 tendrán secuelas que provocarán discapacidad [4].

Una de las secuelas que ocasiona mayor discapacidad derivada de la EVC es la parálisis total o parcial de medio lado del cuerpo, denominada hemiparesia. La hemiparesia puede ocasionar la pérdida de la función motora en una de las extremidades superiores limitando la independencia del individuo para realizar actividades de la vida diaria. Estas secuelas hacen que la EVC sea considerada dentro de las diez principales causas de discapacidad a nivel mundial [5].

De los sobrevivientes de una EVC, un 10% logrará una recuperación espontánea, un 80% requerirá rehabilitación y alcanzará una mejoría clínica y el 10% restante requerirá rehabilitación y es probable que no presente una mejoría clínica [6]. Si estos pacientes, que presentan afectación en una mano inician terapia de rehabilitación en los primeros 6 meses después de la aparición de los síntomas iniciales, tienen un 70% de probabilidad de recuperar la función motora de la extremidad afectada [7]. Esto nos indica que la rehabilitación es parte fundamental en la recuperación de las habilidades motoras de los sobrevivientes de una EVC.

Para la rehabilitación motora en pacientes con EVC la principal técnica utilizada es la rehabilitación motora tradicional, realizada a través de terapia física y/u ocupacional [8]. No obstante, se han propuesto terapias experimentales como las basadas en interfaces cerebro-computadora (BCI) [9]. Estas terapias se basan en utilizar señales cerebrales (como las obtenidas con electroencefalografía) para procesar y clasificar una señal en particular asociada a algún proceso mental específico (por ejemplo, la intención

de movimiento de una extremidad superior) para proporcionar retroalimentación al paciente (a través de estímulos visuales, ortesis, entre otros). Estas terapias dependen de un entrenamiento previo del sistema BCI, para que pueda clasificar los patrones de las intenciones de los usuarios del sistema. Sin embargo, su variabilidad puede ser alta entre individuos y también entre sesiones de un mismo individuo, provocando diferentes grados de control del sistema BCI en las terapias realizadas, por lo que se deben de buscar estrategias de entrenamiento del sistema BCI que se adapten al sujeto y a los cambios de sus señales.

En este trabajo, se explora y evalúa, por medio de una base de datos de señales de electroencefalografía de pacientes con EVC durante un protocolo de rehabilitación con BCI, el desempeño del sistema al utilizar diferentes estrategias de entrenamiento. Esto con el objetivo de validar y proponer estrategias de entrenamiento que posteriormente puedan ser aplicadas en protocolos de rehabilitación con BCI.

Marco teórico

Enfermedad vascular cerebral

La EVC es definida como una afección médica en la que el suministro de sangre al cerebro se ve interrumpido o reducido. Esto produce un cuadro clínico de síntomas neurológicos que persisten por más de 24 horas de duración desde el evento inicial y que deben ser corroborados mediante estudios de imagen como tomografía computarizada de cráneo o resonancia magnética [10].

La EVC se clasifica dependiendo de su etiología, en isquémica y hemorrágica. La EVC isquémica es aquella causada por un bloqueo en uno de los vasos sanguíneos que suministran sangre al cerebro. La causa más común es un coágulo de sangre que se forma en una arteria estrecha debido a la acumulación de placa aterosclerótica, formada por acumulación de colesterol en las paredes de las arterias (trombótico), limitando u obstruyendo el flujo sanguíneo y que puede ocurrir en cualquier parte del cerebro. Esto se produce en aproximadamente el 80% de los casos de EVC [11].

Por otro lado, la EVC hemorrágica es causada por la ruptura de vasos sanguíneos en el cerebro. Esto puede deberse a la presencia de un aneurisma (una protuberancia en la pared de un vaso sanguíneo) o a una hipertensión arterial no controlada, entre otras causas. La EVC hemorrágica es menos común que la EVC isquémica [3]. La EVC sigue un curso temporal de evolución y se ha descrito por etapas: hiperaguda (las primeras veinticuatro horas desde la aparición de los síntomas), aguda (los primeros siete días), subaguda temprana (desde el séptimo día hasta tres meses posteriores al inicio de la enfermedad), subaguda tardía (desde el tercer mes hasta seis meses posteriores a la lesión) y crónica (después de seis meses de originada la lesión) [12]. Cada etapa es caracterizada por procesos celulares, inflamatorios y de reorganización particulares [13].

Existen diversas secuelas que pueden presentarse a consecuencia de una EVC que dependen del tipo, los vasos sanguíneos afectados, la región cerebral perjudicada, su extensión y la eficacia de la atención médica temprana. Estas secuelas pueden ser cognitivas, somatosensoriales, motoras, emocionales o conductuales. Las afectaciones

motoras son las más frecuentes, tanto en la EVC isquémica como hemorrágica, ocasionando déficits de diferentes grados (medio, agudo, severo), y afectando mayoritariamente a un hemicuerpo a distintos niveles: superior (cara, cuello), medio (tronco, miembros superiores) e inferior (extremidades inferiores) [14].

La hemiparesia es una de las secuelas motoras más recurrente, definida como la debilidad muscular o parálisis parcial o completa restringida a un lado del cuerpo. Esta deficiencia está presente en el 88% de los pacientes con EVC, afectando tanto a miembros inferiores como superiores. La presencia de debilidad y falta de control motor en medio lado del cuerpo conduce a una ausencia de uso de las extremidades. Esta inmovilidad aunada con el dolor crónico y las deficiencias sensoriales que pueden presentarse, contribuyen a un aprendizaje del no uso, lo que puede agravar la pérdida funcional de la extremidad. Por otro lado, los pacientes con EVC pueden presentar espasticidad, que se define como un estado de aumento del tono muscular y tensión inusual prolongado. Esta espasticidad puede promover la utilización de movimientos compensatorios, que, si son persistentes en el tiempo, pueden concluir en un aprendizaje inadecuado de movimientos de la extremidad [14].

Mecanismos celulares en la EVC y neuroplasticidad

Posteriormente al inicio de la lesión, se desencadenan diversos procesos celulares que determinan la gravedad de la enfermedad. El primero, es que al haber una disminución de oxigenación se produce muerte neuronal, pudiéndose distinguir dos regiones en el área lesionada: el núcleo isquémico, en el que se produce la mayor cantidad de muerte celular y la zona de penumbra, en la que se presenta reducción de flujo sanguíneo, pero no es total, por lo que las células de esta zona subsisten durante un tiempo y tienen el potencial de sobrevivir por medio de reperfusión u otras estrategias terapéuticas [15]. También se presenta el fenómeno de diasquisis, definido como los cambios neurofisiológicos a distancia causados directamente por una lesión focal [16].

Después del evento isquémico o hemorrágico, las limitaciones producto de los procesos inflamatorios y de cicatrización que se presentan en las regiones lesionadas, dificultan la reconexión y extensión axonal [17,18]. No obstante, se han descrito procesos

de modificación en la organización de los componentes neurales a nivel celular, estructural, funcional y de conectividad [19–22]. Estos cambios adaptativos se denominan neuroplasticidad [23].

Aunque los mecanismos que subyacen a la reorganización de la red y la recuperación funcional aún no se conocen por completo, se cree que implica tres fases principales: la reversión de la diasquisis, con la activación de la génesis celular y de procesos de reparación celular; los cambios en las propiedades de las vías neuronales existentes; y los procesos de plasticidad neuroanatómica que conducen a la formación de nuevas conexiones neuronales [24,25]. Este último proceso, asociado con el aprendizaje motor, en el caso de la hemiparesia, es el principal mecanismo de recuperación en la EVC.

Interfaces cerebro-computadora

Las interfaces cerebro-computadora (BCI) son sistemas que permiten controlar, por medio de información extraída del sistema nervioso central (SNC), dispositivos externos, como puede ser un monitor, una silla de ruedas o sistemas robóticos asistenciales. Estos sistemas se han desarrollado con la finalidad de reemplazar, restaurar, complementar o mejorar la salida natural del SNC como herramienta de apoyo en diversas situaciones, sean patológicas o no [26,27]. Una de sus aplicaciones ha sido enfocada primordialmente para ser usada en ámbitos clínicos con diversos tipos de pacientes, destacando entre ellos, los pacientes con EVC [7,28–30].

Para poder controlar los dispositivos externos, las BCIs necesitan información del SNC para poder analizar, discriminar y generar una salida del sistema. Esta información puede ser obtenida mediante diferentes técnicas de monitoreo de actividad del SNC, entre ellas tenemos métodos electrofisiológicos no invasivos, como lo son la electroencefalografía (EEG), la espectroscopia por infrarrojo cercano funcional (fNIRS), la magnetoencefalografía (MEG) y la imagen por resonancia magnética funcional (fMRI) [31]; y métodos invasivos, como lo pueden ser la electrocorticografía (ECoG) y la tomografía por emisión de positrones (PET). Sin embargo, estas últimas son técnicas con altos costos económicos y de baja accesibilidad poblacional. Además, PET, fMRI y

fNIRS dependen del flujo sanguíneo, por lo que su resolución temporal es baja, siendo menos aplicables en sistemas que requieren una comunicación rápida. En la actualidad, el EEG al ser un método no invasivo que requiere equipos relativamente económicos, comparado con otras modalidades de adquisición, y que tiene una buena resolución temporal, aunque presenta una resolución espacial poco óptima, es la técnica de registro más utilizada para BCIs [32].

Para que un sistema BCI reconozca la señal de EEG, es necesario que se implementen paradigmas establecidos que guían y facilitan al sujeto a generar las señales de EEG específicas necesarias. Estos paradigmas se pueden clasificar según el componente específico de la señal que se utiliza (por ejemplo, la potencia en banda frecuencia o puntos en el tiempo) y el área que se registra (por ejemplo, electrodos centrales, occipitales, entre otros). Entre ellos tenemos los basados en potenciales relacionados a eventos (por ejemplo, P300), potenciales evocados visuales (por ejemplo, potenciales visuales de estado estacionario), potenciales corticales lentos y ritmos sensoriomotores (por ejemplo, ritmos mu durante imaginación de movimiento o intención de movimiento) [31]. Asimismo, estas señales deben pasar por diversos procesos para generar información clasificable entre dos o más estados (por ejemplo, intención de movimiento y reposo). Por ello, los sistemas BCI están estructurados por etapas. A continuación, cada una de estas etapas será detallada de manera general como se describe en [31] y se encuentra ilustrada en la Figura 1:

Primeramente, se realiza la adquisición de la señal utilizando electrodos colocados en el cuero cabelludo; luego se hace un preprocesamiento de la señal realizando procesos de amplificación, filtrado y digitalización de la señal. Durante este paso también la señal registrada puede ser almacenada para su posterior uso. Subsiguientemente, se ejecuta un procesamiento de la señal, donde ésta será transformada en comandos entendibles por el dispositivo de salida. Para esta transformación se utilizan algoritmos computacionales que secuencialmente eliminan artefactos producidos por otros tipos de actividades eléctricas (por ejemplo, movimiento ocular o muscular), extraen características de la señal que se relacionan al paradigma, seleccionan las mejores características y por último traducen estas características para

generar una señal de control del dispositivo (a través de una clasificación). Esta señal finalmente es integrada a una interfaz de control del dispositivo de salida para generar la acción deseada. De esta manera, se pueden proporcionar diversos estímulos al sujeto que funcionan como retroalimentación (por ejemplo, estímulos visuales o movimiento pasivo proporcionado por un dispositivo robótico).

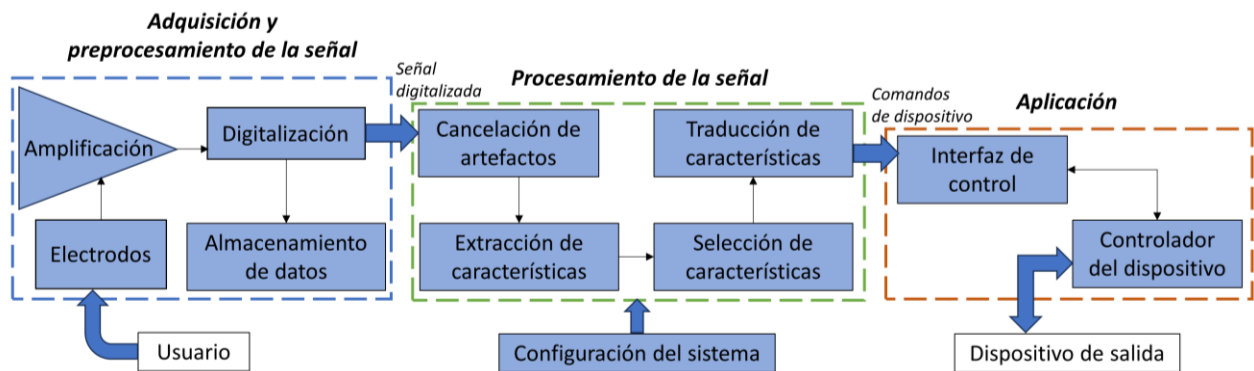


Figura 1. Etapas de una interfaz cerebro-computadora, adaptada de [31] con permiso.

La etapa de procesamiento de una BCI es de suma importancia para el correcto funcionamiento del sistema y existen diferentes opciones de diseño para esta etapa. Un diseño de etapas de procesamiento de la señal en sistemas BCI implementa algoritmos computacionales programados imperativamente, es decir, que las reglas se definen en su totalidad por lo que se crea un único modelo matemático para el uso de todos los usuarios de la BCI. Este diseño fue el primero en implementarse [33,34]. De esta manera, los sujetos tienen que aprender a controlar características específicas de la señal EEG, como, por ejemplo, los ritmos μ (8-12 Hz) y beta (18-26 Hz) para el control bidimensional de un cursor. A estas características fijas se les otorga un propósito específico, como el ritmo μ para controlar el movimiento del cursor horizontal y el ritmo beta para controlar el movimiento del cursor vertical [35]. Sin embargo, esta aproximación requiere del entrenamiento intensivo por parte del sujeto y se denomina aprendizaje por condicionamiento operante [36].

Para adaptar de mejor forma la etapa de procesamiento de las BCI, se ha implementado el aprendizaje de máquina (ML). El ML se puede definir como la técnica que permite a las computadoras hacer predicciones utilizando experiencias pasadas

(ejemplos y observaciones) mediante el aprendizaje automático de relaciones y patrones significativos [37,38]. En contraposición al paradigma imperativo, en el aprendizaje de máquina se proporciona a la computadora un conjunto de datos de entrenamiento y se le permite aprender patrones y realizar predicciones o tomar decisiones basadas en esos datos. De esta manera, utilizando datos previos de un sujeto, se puede entrenar un modelo computacional que se amolda específicamente a las señales de EEG del mismo. Esto se reflejaría en un mejor desempeño del sistema BCI al momento de clasificar entre dos o más tareas codificadas en la señal.

Durante los últimos años se han propuesto e implementado diversos algoritmos de aprendizaje de máquina para cada subetapa del procesamiento de la señal (extracción, selección y traducción de características). Entre ellos tenemos para la extracción de características algoritmos como el análisis de componentes principales (PCA), el análisis de componentes independientes (ICA) y el algoritmo de patrones espaciales comunes (CSP), que es el algoritmo de extracción de características más utilizado en la actualidad en sistemas BCI basados en ritmos sensoriomotores [39–41]. Estos algoritmos funcionan como filtros espaciales que optimizan la identificación entre dos o más estados. De manera similar, se han propuesto extensiones de estos enfoques para optimizar tanto filtros espaciales como espectrales simultáneamente, por ejemplo, el método de banco de filtros de CSP (FBCSP) [39,42].

Para reducir dimensiones, evitar un posible sobreentrenamiento y una mayor eficiencia computacional, se realiza una selección de características. Entre los algoritmos que se han utilizado durante esta subetapa se tienen técnicas como la información mutua, algoritmos evolutivos metaheurísticos como la optimización por enjambre de partículas (PSO) y algoritmos genéticos [39,43]. Por último, para realizar la traducción de las características que resultaría en una clasificación entre estados y otorgar una salida para controlar el dispositivo externo, se han utilizado clasificadores lineales como las máquinas de soporte vectorial (SVM), el análisis de discriminante lineal (LDA) y clasificadores de vecino más cercano como el algoritmo de k-vecinos más cercanos (kNN) [39].

Implementación de sistemas BCI en rehabilitación de EVC

Los sistemas BCI pueden ser utilizados en diversos aspectos de la rehabilitación de pacientes con EVC [9], sin embargo, un área donde se ha profundizado en su estudio y validación es en protocolos clínicos experimentales aplicados en la rehabilitación motora. Estas terapias mayoritariamente utilizan como paradigma de control la imaginación de movimiento, definida como la simulación o ensayo mental de movimientos sin movimientos reales; o la intención de movimiento (IM), que se presenta cuando sujetos con una discapacidad motora (como pacientes con EVC) intentan realizar un movimiento, y este no puede hacerse manifiesto parcial o totalmente debido a la lesión neurológica [44]. Estas actividades se ven reflejadas en los registros de EEG como un cambio en la potencia espectral llamado desincronización/sincronización relacionada al evento (ERD/ERS), principalmente en las bandas de frecuencia de alfa (8-13 Hz) y beta (13-30 Hz), cómo también en los ritmos mu (8-13 Hz) en regiones de la corteza sensoriomotora [45].

La IM aplicada en sistemas BCI permite identificar si el paciente con EVC desea realizar un movimiento, de esta manera, el sistema podrá ejecutar alguna acción de retroalimentación con un dispositivo de salida, como lo puede ser una ortesis robótica [7,28]. La activación cortical y la retroalimentación otorgada a través del dispositivo de salida fomentaría la neuroplasticidad y puede favorecer la recuperación motora del paciente [7,9,28,29,31].

Entrenamiento y desempeño con un sistema BCI en terapias de rehabilitación en el contexto de la EVC

La mayoría de los algoritmos de aprendizaje de máquina que pueden formar parte de la cadena de procesamiento de un sistema BCI aplicado en terapias de rehabilitación para pacientes con EVC, requieren de un entrenamiento previo. Este entrenamiento consiste en enseñar al algoritmo a distinguir entre dos o más estados utilizando datos representativos de cada uno, por ejemplo, discriminar cuando la señal EEG refleja la intención de movimiento del sujeto o refleja un estado de reposo no relacionado a la intención. Eso hace necesario poseer un conjunto de datos de entrenamiento, un

conjunto de datos de validación para buscar la mejor arquitectura del modelo, un conjunto de datos de prueba desconocidos para el modelo y métricas de evaluación para cuantificar los resultados del modelo [46]. Entre las métricas de evaluación tenemos la matriz de confusión, la exactitud, la sensibilidad, la especificidad y la precisión [47]. De estas métricas, la exactitud es la más utilizada en evaluación de sistemas BCI y otorga información sintetizada del desempeño y el control de la BCI que puede tener un usuario del sistema.

En diversos estudios de pacientes con EVC [7,8,28,40,48–55], el desempeño del control del sistema BCI ha tendido a presentar variabilidad entre e intra sujetos, y a fluctuar mucho con el tiempo debido a la no estacionariedad de la señal EEG, que se refiere a que las propiedades estadísticas de la señal EEG varían con el tiempo, lo que hace necesario comprender estos problemas para crear sistemas más estables. El desempeño puede depender de diversos aspectos, entre ellos están los intrínsecos al sujeto, como lo son su capacidad de producir la señal EEG objetivo, su estado psicológico, sus capacidades cognitivas y el estado neurológico [48,56].

Asimismo, están aquellos aspectos de los que depende el desempeño del sistema BCI y sobre los que se puede incidir computacionalmente, como lo son las etapas de procesamiento del sistema BCI [39]. Algunos estudios se han enfocado en la validación e implementación de algoritmos para mejorar el desempeño [39,57], sin embargo, estos algoritmos dependen de la estrategia usada para entrenar la etapa de procesamiento de la BCI para que su desempeño sea óptimo. Es importante definir el tipo de estrategia de entrenamiento que se usará, ya que los modelos obtenidos posteriormente al entrenamiento serán cruciales para obtener una clasificación de salida. Teniendo en cuenta la variabilidad y no estacionariedad de la señal EEG, es necesario ahondar en las diversas estrategias de entrenamiento que se puedan proponer para obtener el mejor desempeño del sistema BCI. Esto se traducirá en mejor control del sistema por parte del paciente durante sus terapias de rehabilitación.

Antecedentes

Se efectuó una revisión bibliográfica por medio de bases de datos científicas como *ScienceDirect*, *Springerlink*, *PubMed* e *IEEE Xplore*, utilizando las palabras clave “BCI”, “Stroke Patients”, “Motor Rehabilitation”, “Upper Limb”, “Motor Imagery”, “Movement Intention”, “Clinical Study”, “Calibration”, “Strategies”. Se seleccionaron artículos científicos que implementaron terapias de rehabilitación motora de extremidad superior utilizando sistemas BCI en pacientes con EVC, que involucraron más de dos sesiones de terapias y utilizaron algoritmos de aprendizaje de máquina.

En los estudios encontrados, se han utilizado, en términos generales, tres estrategias de entrenamiento: a) entrenamiento utilizando una sesión de calibración realizada al inicio del protocolo experimental, b) entrenamiento con datos de una sesión de calibración que fue realizada cada día antes del inicio de la terapia, y c) entrenamiento utilizando los datos de la sesión anterior de terapia [28,48,49,53,58,59]. Cada una de estas estrategias presenta limitaciones que pueden observarse tanto en el desempeño del sistema como en aspectos de viabilidad de la terapia, entre ellas, la falta de ajuste de las estrategias para adaptarse a la no estacionariedad de la señal EEG y el incremento de la duración de las sesiones.

Posteriormente, se buscaron artículos que, utilizando bases de datos de terapias BCI en pacientes con EVC, realizaron estudios retrospectivos sobre la implementación de estrategias de entrenamiento (o calibración) de la etapa de procesamiento del sistema BCI durante terapias BCI, para de esta manera, conocer cuántos estudios lo han hecho, qué estrategias han implementado y sus resultados de desempeño. En la Tabla 1 se puede observar un resumen de estos estudios.

Tabla 1: Revisión bibliográfica de trabajos que realizan estudios retrospectivos sobre implementación de estrategias de entrenamiento de un sistema de interfaz cerebro-computadora en bases de datos de pacientes con enfermedad vascular cerebral.

Título del trabajo (año de publicación)	Características de la base de datos	Algoritmos utilizados	Estrategias de entrenamiento implementadas	Resultados
<i>EEG-Based Strategies to Detect Motor Imagery for Control and Rehabilitation (2017) [60]</i>	6 pacientes EVC en etapa crónica 4 tipo Hemorrágico 2 tipo Isquémico 1 sesión de calibración 18 sesiones de terapia	FBCSP, Información Mutua, LDA Shrinkage	Machine Learning (ML): utilizando los datos de la sesión de calibración Adaptative All (AA): utilizando todos los datos de las sesiones anteriores Adaptative 160 (A160): utilizando 160 datos inmediatamente anteriores	Gran promedio de porcentajes de exactitud ML: 69.5% AA: 77.5% A160: 75.9%
<i>Comparing recalibration strategies for electroencephalography-based decoders of movement intention in neurological patients with motor disability (2017) [56]</i>	4 pacientes EVC tipo isquémico en etapa crónica 8 sesiones de terapia	Filtro Laplaciano, Modelo autorregresivo de orden 16, Análisis discriminante disperso (SDA)	Previous Session (PS): utilizando datos de la sesión anterior Accumulated previous sessions (APS): utilizando todos los datos de las sesiones anteriores Current Session (CS): utilizando un porcentaje de los datos de la sesión cursante con procedimiento de validación cruzada dejando uno fuera Accumulated sessions (AS): utilizando todos los datos de las sesiones anteriores y un porcentaje de la sesión cursante	Gran Promedio de Porcentajes de Verdaderos Positivos y Falsos Positivos PS: 76.3% y 34.6% APS: 80.1% y 19.5% CS: 85.5% y 31.4% AS: 85.3% y 17.3%
<i>A Transfer Learning Algorithm to Reduce Brain-Computer Interface Calibration Time for Long-Term Users (2022) [57]</i>	11 pacientes EVC 8 tipo isquémico 3 tipo hemorrágico 1 sesión de screening 18 sesiones de terapia	r-KLwDSA	Utilizando todos los datos de las sesiones anteriores + 10 ensayos de la sesión cursante	Gran Promedio de porcentajes de exactitud 73.09%

La tabla 1 nos permite identificar que son pocos los estudios que se han enfocado en las estrategias de entrenamiento de la etapa de procesamiento como método para mejorar el desempeño del sistema BCI. Se observa que los estudios implementan estrategias similares, como lo son la estrategia *Adaptative All* (AA) utilizada por Ang y colaboradores en [60] y la estrategia *Accumulated Previous Sessions* (APS) implementada por López-Larraz y colaboradores en [56]. Mientras que Giles y colaboradores en [57] utilizan una estrategia similar a la estrategia *Accumulated Sessions* (AS) empleada en [56]. Por otro lado, los algoritmos implementados en la etapa de procesamiento varían en cada estudio, como también el número de pacientes, con un máximo de 11 pacientes, y el número de sesiones, con un máximo de 18 sesiones.

En la Tabla 1 se puede observar que los desempeños del sistema son reportados en diferentes tipos de métricas como el porcentaje de exactitud, el porcentaje de verdaderos positivos (sensibilidad) y el porcentaje de falsos positivos, por lo que no pueden compararse directamente. En términos de porcentaje de exactitud, con la estrategia AA en [60] se presenta el mejor resultado con un 77.5% de exactitud, que puede compararse indirectamente con el resultado de la sensibilidad que se presenta con la estrategia homóloga APS (80.1%) en [56]. Sin embargo, los mejores resultados de sensibilidad se presentaron con las estrategias *Current Session* (CS) y AS (85.5% y 85.3%, respectivamente). Estos resultados sugieren que entrenar utilizando todos los datos de las sesiones anteriores o utilizando los datos de la sesión cursante o combinarlos, podría ser beneficioso para el desempeño del sistema.

Planteamiento del problema

Las terapias de rehabilitación de extremidades superiores utilizando BCIs en pacientes con EVC son una opción prometedora para la recuperación funcional motora del paciente. Sin embargo, el control del sistema por parte de los pacientes es variable y no se ha ahondado en el diseño e implementación de nuevas estrategias de entrenamiento para la etapa de procesamiento de la BCI, para aumentar o mantener el control del sistema por parte del paciente sesión a sesión.

Justificación

La variabilidad en el desempeño del sistema BCI hace destacar la necesidad de llevar a cabo estudios retrospectivos que tengan el objetivo de validar y aplicar estrategias previamente utilizadas y explorar nuevas aproximaciones de entrenamiento. De esta manera, se buscaría mejorar tanto el control del sistema BCI por parte de los participantes, como la viabilidad general de la terapia de rehabilitación.

Objetivos e hipótesis

Objetivo general

Evaluar el desempeño de la etapa de procesamiento de una interfaz cerebro-computadora para reconocer correctamente entre tareas de intención de movimiento de la mano paralizada de pacientes con enfermedad vascular cerebral, usando diferentes estrategias para el entrenamiento de la etapa de procesamiento.

Objetivos específicos

Obtener el desempeño de clasificación de tareas de intención de movimiento con una interfaz cerebro-computadora en una base de datos de pacientes con EVC, usando una estrategia de entrenamiento con información de la sesión anterior (estrategia sesión anterior).

Obtener el desempeño de control de los pacientes con una estrategia de entrenamiento con información de todas las sesiones anteriores (estrategia acumulativa).

Obtener el desempeño de control de los pacientes con una estrategia de entrenamiento con información de la sesión anterior y la sesión cursante (estrategia instantánea).

Realizar un análisis con estadística inferencial para determinar si existen diferencias significativas en el desempeño dependiendo de la estrategia propuesta.

Hipótesis

Existirán diferencias entre los desempeños de la etapa de procesamiento de una interfaz cerebro-computadora obtenidos de forma retrospectiva utilizando las tres estrategias de entrenamiento propuestas, siendo la estrategia acumulativa la que obtendrá el mayor desempeño en términos de porcentajes de exactitud entre las estrategias evaluadas.

Metodología

Descripción de la base de datos

Para realizar la comparación entre las estrategias de entrenamiento se utilizó una base de datos de registros EEG de pacientes con EVC que fue adquirida en el Instituto Nacional de Rehabilitación “Luis Guillermo Ibarra Ibarra”, Ciudad de México, durante sesiones de una terapia experimental de rehabilitación motora con una BCI acoplada a una ortesis de mano robótica cuyos resultados clínicos ya han sido publicados [28].

La base de datos está conformada por 12 pacientes (7 hombres, 5 mujeres) con EVC tipo isquémica con una edad promedio de 55.8 ± 15.4 años. 7 pacientes se encontraban en la etapa subaguda y 5 en la etapa crónica al comienzo del registro de los datos. 1 paciente realizó 11 sesiones y 9 pacientes realizaron 12 sesiones de terapia, cada sesión estuvo compuesta por 3 corridas a excepción de un paciente que en una sesión realizó 2 corridas, debido a reportar cansancio. Los otros 2 pacientes realizaron 30 sesiones de terapia compuestas por 4 corridas, con excepción en una sesión en la que un paciente realizó 3 corridas, debido a reportar cansancio y un paciente en una sesión realizó 5 corridas, debido a un error en el registro de una corrida. Cada corrida tiene 20 ensayos, por lo tanto, un total de 60 a 80 ensayos fueron recabados por sesión, dependiendo de si el paciente realizó 12 o 30 sesiones de terapia. Esta información se encuentra detallada en la Tabla 2.

Los registros de EEG fueron obtenidos utilizando un gorro con 11 electrodos activos (g.LadyBird, g.tec) posicionados en F3, C3, T3, P3, Fz, Cz, Pz, F4, C4, T4 y P4 de acuerdo al sistema internacional 10-20. El electrodo de referencia y el de tierra fueron

colocados en el lóbulo de la oreja derecha y en la posición AFz, respectivamente. Cada canal fue amplificado y digitalizado con el amplificador g.USBamp (g.tec) conectado a una computadora con una frecuencia de muestreo de 256 Hz con 24-bit A/D de resolución.

Tabla 2: Descripción de la base de datos

ID	Género	Hemiparesia	Tiempo desde el inicio del EVC (días)	Etapas	Edad	FMA-US inicial	Sesiones	Ensayos registrados por sesión
1P	Femenino	Derecha	280	Crónica	54	12	11	60
2P	Femenino	Izquierda	81	Subaguda	85	13	12	60
3P	Femenino	Derecha	218	Crónica	58	9	12	60
4P	Femenino	Izquierda	146	Subaguda	54	9	12	60
5P	Masculino	Izquierda	37	Subaguda	43	8	12	60
6P	Masculino	Derecha	100	Subaguda	48	15	12	60
7P	Masculino	Derecha	97	Subaguda	53	14	12	60
8P	Masculino	Derecha	260	Crónica	63	59	12	60
9P	Masculino	Izquierda	87	Subaguda	65	12	12	60
10P	Femenino	Izquierda	98	Subaguda	76	24	12	60
11P	Masculino	Derecha	186	Crónica	28	18	30	80
12P	Masculino	Izquierda	341	Crónica	42	23	30	80

FMA-US, Escala de Fugl-Meyer para Extremidad Superior.

El protocolo experimental de las terapias de rehabilitación con BCI de las cuales se obtuvo la base de datos consistió en sesiones de rehabilitación en las que al paciente con EVC se le colocó el sistema BCI. Durante la terapia se presentaron señales visuales y auditivas para indicar las diferentes actividades que el paciente debe de realizar. Estas actividades consistieron en ejecutar IM de la extremidad superior afectada o estar en estado de reposo.

La estructura temporal de cada ensayo fue la siguiente: los primeros 3 segundos indicaron el periodo de reposo, posteriormente con la señalización de una flecha durante 1.5 segundos se indicó el comienzo de la acción de IM de la mano paralizada. El tiempo de duración de IM fue del segundo 3 al segundo 8 (5 segundos). Posteriormente, del segundo 8 al 12, si la etapa de procesamiento del sistema BCI detectó la intención de movimiento por parte del paciente, se proporcionó retroalimentación a través de la ortesis

robótica con la flexión pasiva de los dedos de la mano afectada del sujeto, seguida de la extensión. Después, se presentó un periodo de descanso donde el paciente pudo moverse o relajarse con una duración aleatoria de 3 a 5 segundos para prevenir la habituación. De esta manera se realizaron los 20 ensayos de una corrida y al finalizarla, se otorgó un descanso de mínimo 1 minuto antes de comenzar la siguiente corrida.

Es importante recalcar que la primera sesión es la única que difiere con respecto a las demás ya que durante ella se proporcionó retroalimentación con la ortesis en cada uno de los ensayos. Esta sesión sirve para que el paciente se familiarice con el paradigma y, asimismo, se pueda dar la recolección de los datos para poder entrenar a la etapa de procesamiento del sistema BCI para la siguiente terapia con base en el paradigma utilizado durante ese protocolo experimental.

Proceso de entrenamiento de la etapa de procesamiento

Por medio de una interfaz gráfica de usuario programada en el software “MATLAB”, desarrollada como parte de otro proyecto de investigación, de manera fuera de línea se procesaron los datos de EEG, se realizaron los entrenamientos de la interfaz cerebro-computadora y su evaluación (Figura 2). Se utilizó una workstation marca Dell, modelo Precision 5820 para realizar cada una de estas etapas. El proceso se puede segmentar en los siguientes pasos:

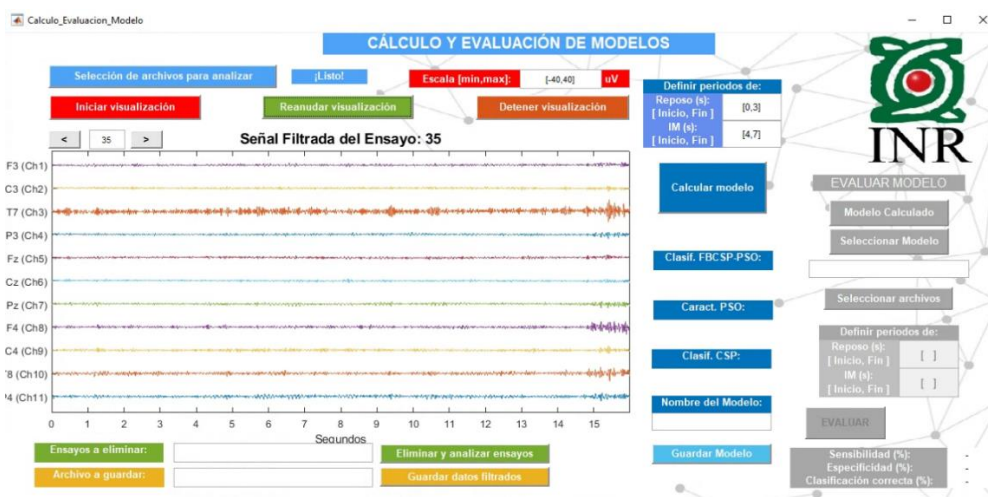


Figura 2: Interfaz gráfica de usuario programada en el software “MATLAB” para la visualización de los registros EEG, entrenamiento del modelo y su posterior evaluación.

- 1. Cargado y visualización de los datos:** los datos a analizar que se usaron para entrenar el modelo dependiendo de cada estrategia (detalladas en la sección “Estrategias de entrenamiento propuestas”), se cargaron de archivos tipo “.MAT”, de MATLAB y se observó secuencialmente cada ensayo para eliminar de forma visual, aquellos que presentaron artefactos pronunciados y/o ruido (por ejemplo, actividad ocular o muscular).
- 2. Entrenamiento:** Utilizando el algoritmo FBCSP [42] para extracción de características, a cada ensayo se le aplicaron 6 filtros temporales pasabanda FIR de orden 30 por cada canal en las sub-bandas de 8-12 Hz, 12-16 Hz, 16-20 Hz, 20-24 Hz, 24-28 Hz y 28-32 Hz. Posteriormente, se segmentó la señal de cada ensayo en dos periodos que representan a los estados mentales que debe de distinguir la BCI: el periodo de reposo (0 a 3 segundos del ensayo) y el periodo de IM (4 a 7 segundos del ensayo). De cada periodo se tomaron 3 ventanas de una duración de un segundo para analizarse por separado. Después se aplicó el algoritmo CSP [41] con el que se obtienen coeficientes con los que se filtra espacialmente la señal, aumentando la varianza de la señal de EEG para una clase (reposo o IM) y reduciéndola para la otra. Posteriormente se realizó la selección de características utilizando el algoritmo PSO para seleccionar un subconjunto de características y así disminuir el error de clasificación y el número de características a utilizar. Por último, se entrenó el algoritmo supervisado LDA para realizar la clasificación.
- 3. Selección de modelo:** el algoritmo PSO, al ser metaheurístico, produce resultados que pueden variar por cada iteración, es decir, existe la posibilidad de que con el algoritmo se seleccione un número diferente de características cada vez que es ejecutado, y produzca resultados diferentes con los mismos datos de entrada. Por lo tanto, es posible obtener desempeños de clasificación que tendrán variabilidad. Por esto, es necesario entrenar más de un modelo y realizar una selección del modelo que se utilizará. Se tomó un criterio empírico al seleccionar el modelo con base en el número de características óptimo por modelo y sus porcentajes de exactitud en la validación.

4. Evaluación: Teniendo la etapa de procesamiento de la BCI entrenada con el modelo seleccionado, se realizó la prueba de este modelo utilizando datos que corresponderían de manera análoga a lo que serían las señales EEG de la sesión “cursante” de las terapias de rehabilitación. Estos datos se usaron para evaluar el desempeño de la BCI a través del cálculo del porcentaje de exactitud (o de clasificación correcta), el porcentaje de sensibilidad y el porcentaje de especificidad.

La exactitud es definida como el porcentaje de predicciones correctas en un conjunto de datos de prueba [61]; y se calcula de la siguiente manera:

$$\% \textit{Exactitud} = \frac{VP + VN}{VP + VN + FP + FN} \times 100 \quad (1)$$

Donde *VP* son los verdaderos positivos y en el caso de este estudio, hace alusión a aquellas observaciones que se predicen en la clase de IM y realmente lo son; *VN* que son los verdaderos negativos, definido como aquellas observaciones que se clasifican en la clase de Reposo y realmente pertenecen a ella. Mientras que *FN* son los falsos negativos, aquellas observaciones que se predicen como Reposo y en realidad pertenecen a la clase de IM; y *FP*, que son los falsos positivos, definido como aquellas observaciones que se predicen pertenecer a la clase IM cuando en realidad pertenecen a la clase de Reposo.

También tenemos a la sensibilidad, que nos indica cuantas veces se clasificó correctamente que pertenecía a la clase de IM, y se define como:

$$\% \textit{Sensibilidad} = \frac{VP}{VP + FN} \times 100 \quad (2)$$

Por último, la especificidad nos indica cuantas veces se clasificó correctamente que pertenecía a la clase de Reposo, y es definida como:

$$\% \textit{Especificidad} = \frac{VN}{VN + FP} \times 100 \quad (3)$$

Estrategias de entrenamiento propuestas

Para el entrenamiento de la etapa de procesamiento de la BCI se diseñaron e implementaron tres estrategias diferentes, que se ilustran en conjunto en la Figura 3: Estrategia Sesión Anterior (SA), Estrategia Acumulativa (AC) y Estrategia Instantánea (IN).

La estrategia Sesión Anterior consistió en entrenar utilizando los datos de la sesión inmediatamente anterior del paciente. Por ejemplo, para la sesión 2 se entrenó el modelo utilizando los ensayos de la sesión 1, para la sesión 3 se utilizaron los ensayos de la sesión 2, y así consecutivamente. Esta estrategia ha sido utilizada en un estudio clínico de terapias de rehabilitación BCI [28]. Por lo tanto, implementarla proporciona una referencia de los resultados que podrían obtenerse en un proyecto clínico.

La estrategia Acumulativa consistió en entrenar utilizando todos los datos de las sesiones anteriores a la actual, acumulando los datos de las sesiones. Por ejemplo, para la sesión 3 se entrenó con los ensayos obtenidos durante la sesión 1 y 2 (ilustrado dentro de un óvalo en la Figura 3). Para la sesión 4, se entrenó con los ensayos obtenidos durante la sesión 1, 2 y 3. De esta manera se acumularon en el entrenamiento de forma progresiva, todos los datos de EEG registrados en los ensayos de las sesiones anteriores, obteniendo un máximo de 720 ensayos para los pacientes que realizaron 12 sesiones compuestas por 3 corridas y 2420 ensayos para los pacientes que realizaron 30 sesiones compuestas por 4 corridas. Esta estrategia ha sido implementada por López-Larraz et al. y Ang et al. [56,60].

Por último, la estrategia Instantánea consistió en realizar el entrenamiento utilizando información de la sesión anterior y la sesión “cursante” tomando un número de los ensayos más recientes realizando una actualización por cada corrida pasada y descartando la corrida temporalmente más antigua. En una sesión se actualiza el modelo

$n-1$ veces dependiendo del total de corridas de la sesión cursante (n), por ejemplo: durante la sesión de un paciente se registraron 3 corridas, por lo que se actualizó el modelo 2 veces. En la primera corrida se entrenó el modelo con los ensayos de la sesión anterior. Para la segunda corrida, se entrenó nuevamente el modelo con las dos últimas corridas de la sesión anterior y los ensayos registrados durante la primera corrida de la sesión cursante (en la Figura 3 se ilustra con una flecha como los datos son introducidos al óvalo), descartando la primera corrida de la sesión anterior (observado en la Figura 3 con una flecha que indica que los datos son removidos del óvalo). Para la tercera corrida, se entrenó el modelo con la última corrida de la sesión anterior y las dos corridas registradas durante la sesión actual. Debido a que al evaluar esta última estrategia se obtuvo por cada corrida un valor por métrica, se realizó un promedio de éstas para obtener el desempeño por sesión de la estrategia en general.

Los entrenamientos se realizaron a partir de la sesión 2 debido a que la sesión 1 nos otorga los primeros datos para poder entrenar el sistema para la próxima sesión.

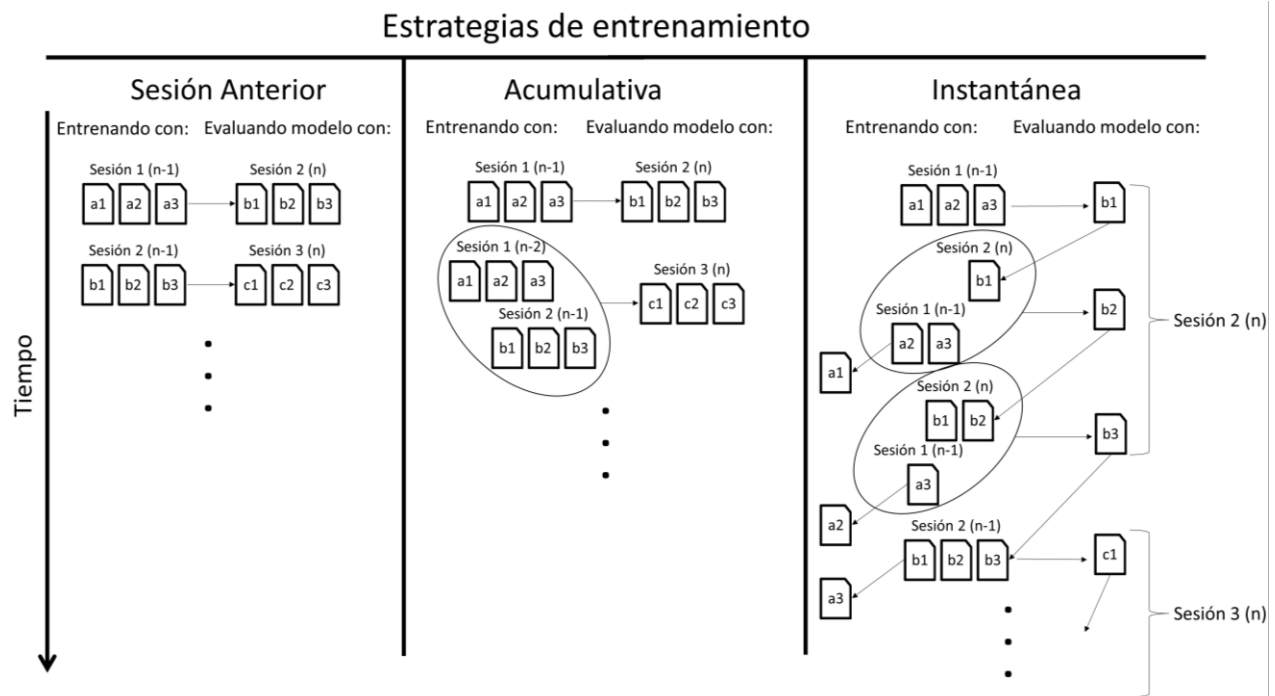


Figura 3. Estrategias de entrenamientos de la etapa de procesamiento del sistema BCI propuestas. “ax” representa los datos de la corrida “x” de la sesión 1, “bx” representa los datos de la corrida “x” de la sesión 2 y “cx” representa los datos de la corrida “x” de la sesión 3. Los

óvalos engloban al conjunto de datos inter-sesión con los que se entrena el modelo en las estrategias Acumulativa e Instantánea.

Análisis estadístico de los resultados

Utilizando el lenguaje de programación de *MATLAB (R2020B)*, se realizaron análisis de estadística descriptiva e inferencial para comparar las tres estrategias. Se verificó que los datos no mostraron una distribución Gaussiana con la prueba de normalidad de Lilliefors, por lo que se empleó la prueba no paramétrica de Friedman para evaluar las diferencias entre las estrategias, considerando una prueba para cada métrica (porcentajes de exactitud, sensibilidad y especificidad) de los pacientes en todas las sesiones, sin hacer distinción por sesión. Posteriormente, se hizo una prueba *post-hoc* de comparación múltiple con corrección de Bonferroni para determinar si existieron diferencias significativas entre pares de estrategias para cada una de las métricas. Todas las pruebas de estadística inferencial fueron realizadas con un nivel de confianza del 95%.

Además, utilizando la mediana de la distribución del porcentaje de exactitud de cada estrategia con los datos de todos los pacientes distinguiendo sesión a sesión, se calculó una regresión lineal simple por medio del método de mínimos cuadrados para obtener la tendencia temporal del desempeño del sistema BCI (la pendiente de la recta), el coeficiente de determinación (R^2) y el valor de probabilidad del estadístico F. También se realizó este procedimiento para los resultados individuales de porcentaje de exactitud de los primeros diez pacientes.

Es importante mencionar que, para todos los análisis comentados anteriormente, se utilizaron los datos de las primeras 12 sesiones de los 12 pacientes, con el propósito de evitar posibles sesgos en la distribución que pueden provocar los datos de las demás sesiones registradas de los pacientes *11P* y *12P*, que efectuaron 30 sesiones. Para considerar las 30 sesiones llevadas a cabo por los últimos dos pacientes y examinar las tendencias del desempeño con respecto a un mayor número de terapias, se efectuó una regresión lineal simple para cada paciente utilizando el porcentaje de exactitud obtenido en cada sesión.

Resultados

En la Figura 4 se presentan las distribuciones de los porcentajes de exactitud, especificidad y sensibilidad obtenidas al entrenar la etapa de procesamiento del sistema BCI con cada una de las 3 estrategias y en cada uno de los 12 pacientes a lo largo de las 12 sesiones de intervención. De acuerdo con la prueba estadística de Friedman, existieron diferencias significativas ($p < 0.001$) entre las medianas de los porcentajes de exactitud con las 3 estrategias. También se obtuvieron diferencias significativas ($p < 0.001$) entre las medianas de la sensibilidad y la especificidad con las 3 estrategias.

En términos de porcentaje de exactitud, con la estrategia IN se presentó el mayor valor de mediana (76.39%, $Q1 = 68.68\%$, $Q3 = 81.53\%$), seguido por la estrategia AC (71.67%, $Q1 = 65.07\%$, $Q3 = 78.54\%$) y por la estrategia SA (69.17%, $Q1 = 58.96\%$, $Q3 = 77.43\%$). Las comparaciones múltiples con corrección de Bonferroni indicaron que existió una diferencia estadísticamente significativa entre los porcentajes de exactitud entre la estrategia SA y la estrategia AC ($p = 0.0012$), entre la estrategia SA y la estrategia IN ($p < 0.001$) y entre la estrategia AC y la estrategia IN ($p < 0.001$).

Asimismo, en términos de porcentajes de especificidad, con la estrategia SA y la estrategia IN se obtuvo el mismo valor de mediana (77.22%) con cuartiles de $Q1 = 58.96\%$ y $Q3 = 89.3\%$ para la estrategia SA y de $Q1 = 66.67\%$ y $Q3 = 86.56\%$ para la estrategia IN. Con la estrategia AC se presentó una mediana de 75% ($Q1 = 63.47\%$, $Q3 = 83.89\%$). Únicamente se presentaron diferencias estadísticamente significativas entre la estrategia AC e IN ($p < 0.001$). No se presentaron diferencias estadísticamente significativas entre la estrategia SA y la estrategia AC ($p = 0.16$), ni entre la estrategia SA e IN ($p = 0.19$).

Con respecto al porcentaje de sensibilidad, con la estrategia IN se obtuvo la mayor mediana (78.75%, $Q1 = 63.54\%$, $Q3 = 85.56\%$) seguida por la estrategia AC (75.42%, $Q1 = 60.14\%$, $Q3 = 87.08\%$) y la estrategia SA (69.44%, $Q1 = 52.29\%$, $Q3 = 84.44\%$). Se encontraron diferencias estadísticamente significativas entre la estrategia SA y la estrategia AC ($p < 0.001$) y entre la estrategia SA y la estrategia IN ($p < 0.001$), mientras que no existieron diferencias significativas entre la estrategia AC y la estrategia IN ($p = 0.5$).

En las métricas de especificidad y sensibilidad se observó una mayor cantidad de valores atípicos en comparación con el porcentaje de exactitud. Adicionalmente, con la estrategia IN se presentó la menor cantidad de valores atípicos en las tres métricas.




Figura 4. Diagrama de cajas y bigotes de los porcentajes de exactitud, especificidad y sensibilidad obtenidos por cada estrategia aplicada, considerando los porcentajes de todas las sesiones de todos los sujetos. Los corchetes indican las comparaciones que obtuvieron diferencias estadísticamente significativas en la prueba de comparación múltiple con corrección de Bonferroni ($p < 0.05$). Estrategia Sesión Anterior (SA), Estrategia Acumulativa (AC), Estrategia Instantánea (IN).

En la Figura 5 se observan las distribuciones de porcentaje de exactitud obtenidas sesión a sesión teniendo en cuenta los 12 sujetos. Con la estrategia IN se presentaron los valores más altos de mínimos (a excepción de la sesión 7) y de primer cuartil, como también las mayores medianas en todas las sesiones. Las regresiones lineales de las medianas del porcentaje de exactitud no mostraron un ajuste estadísticamente significativo ($p > 0.5$) con ninguna de las tres estrategias. Asimismo, los coeficientes de determinación sugieren poco ajuste lineal de los porcentajes de clasificación para las tres estrategias ($R^2 = 0.0014$ para la estrategia SA, $R^2 = 0.0004$ para la estrategia AC y de R^2

= 0.1015, para la estrategia IN). Todas las pendientes fueron positivas, destacando la estrategia IN por tener el valor de pendiente más alto, con un valor de 0.29.

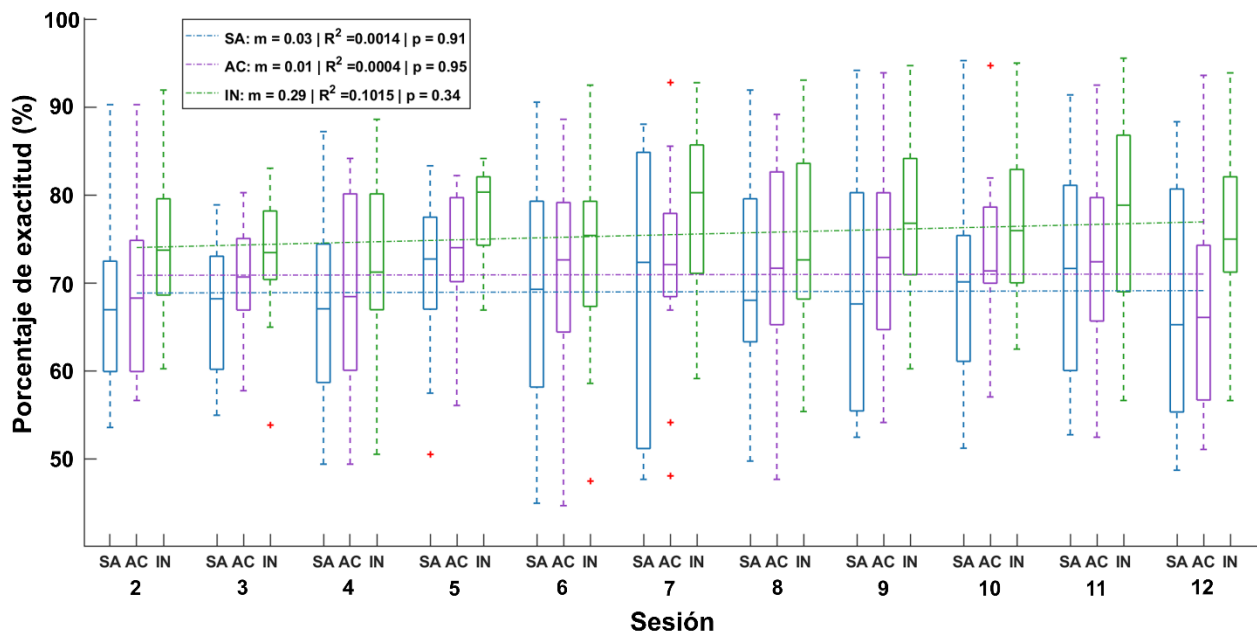


Figura 5. Diagrama de cajas y bigotes de los porcentajes de exactitud obtenidos por cada estrategia aplicada considerando a los 12 sujetos, sesión a sesión. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p). Estrategia Sesión Anterior (SA), Estrategia Acumulativa (AC), Estrategia Instantánea (IN).

En la Figura 6 se observan los porcentajes de exactitud del paciente 1P durante sus 11 sesiones de terapia. El ajuste lineal no fue estadísticamente significativo ($p > 0.05$) en cada una de las 3 estrategias ($p = 0.595$ para la estrategia SA, $p = 0.165$ para la estrategia AC y $p = 0.876$ para la estrategia IN) y los valores del coeficiente de determinación presentaron bajo ajuste a la recta ($R^2 = 0.037$ para la estrategia SA, $R^2 = 0.226$ para la estrategia AC y $R^2 = 0.003$ para la estrategia IN). Los ajustes lineales de la estrategia AC e IN presentaron pendientes positivas ($m = 0.635$ para la estrategia AC y $m = 0.073$ para la estrategia IN) mientras que el ajuste lineal de la estrategia SA presentó una pendiente negativa ($m = -0.337$).




Figura 6. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 1P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

La Figura 7 presenta los porcentajes de exactitud del paciente 2P durante sus 12 sesiones de terapia. Se observó una disminución drástica del porcentaje de exactitud en la sesión 6 debido a que los datos registrados durante esa sesión presentaron ruido excesivo. Debido a esto, es necesario aclarar que los datos de la sesión 6 del paciente 2P fueron utilizados para evaluar el modelo generado después de la sesión 5, pero al momento de evaluar con los datos de la sesión 7, se utilizó nuevamente datos de la sesión 5 para no comprometer el entrenamiento. El ajuste lineal no fue estadísticamente significativo ($p > 0.05$) para las tres estrategias ($p = 0.428$ para la estrategia SA, $p = 0.379$ para la estrategia AC y $p = 0.922$ para la estrategia IN) y los valores del coeficiente de determinación sugieren poco ajuste a la recta ($R^2 = 0.071$ para la estrategia SA, $R^2 = 0.087$ para la estrategia AC y $R^2 = 0.001$ para la estrategia IN). Los ajustes lineales de las tres estrategias presentaron pendientes negativas ($m = -1.19$ para la estrategia SA, $m = -1.367$ para la estrategia AC y $m = -0.126$ para la estrategia IN).




Figura 7. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 2P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

En la Figura 8 se observan los porcentajes de exactitud del paciente 3P durante sus 12 sesiones de terapia. El ajuste lineal no fue estadísticamente significativo ($p > 0.05$) para cada una de las tres estrategias ($p = 0.236$ para la estrategia SA, $p = 0.916$ para la estrategia AC y $p = 0.543$ para la estrategia IN) y los valores del coeficiente de determinación presentaron poco ajuste a la recta ($R^2 = 0.152$ para la estrategia SA, $R^2 = 0.001$ para la estrategia AC y $R^2 = 0.043$ para la estrategia IN). Los ajustes lineales de las tres estrategias presentaron pendientes negativas ($m = -0.672$ para la estrategia SA, $m = -0.053$ para la estrategia AC, $m = -0.321$ para la estrategia IN).

3P




Figura 8. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 3P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

La Figura 9 presenta los porcentajes de exactitud del paciente 4P durante sus 12 sesiones de terapia. El ajuste lineal fue estadísticamente significativo ($p < 0.05$) para cada una de las tres estrategias ($p = 0.001$ para la estrategia SA y $p < 0.001$ para la estrategia AC y la estrategia IN). Asimismo, los coeficientes de determinación sugieren una asociación lineal de moderada a fuerte entre el número de sesiones con el porcentaje de exactitud para las tres estrategias ($R^2 = 0.7$ para la estrategia SA, $R^2 = 0.82$ para la estrategia AC y $R^2 = 0.79$ para la estrategia IN). Asimismo, los ajustes lineales de las tres estrategias presentaron pendientes positivas ($m = 2.329$ para la estrategia SA, $m = 2.449$ para la estrategia AC y $m = 2.318$ para la estrategia IN).




Figura 9. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 4P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

También, los ajustes lineales de los porcentajes de exactitud del paciente 5P (Figura 10) fueron estadísticamente significativos ($p < 0.05$) para la estrategia SA ($p = 0.023$) y la estrategia IN ($p = 0.042$), mientras que no lo fueron para la estrategia AC ($p = 0.1$). A su vez, los valores del coeficiente de determinación obtenidos sugieren una asociación débil a moderada entre el número de sesiones y el porcentaje de exactitud en las estrategias SA ($R^2 = 0.453$) e IN ($R^2 = 0.384$), mientras que en la estrategia AC sugiere una asociación débil ($R^2 = 0.27$). Los ajustes lineales de las tres estrategias presentaron pendientes positivas ($m = 2.437$ para la estrategia SA, $m = 1.434$ para la estrategia AC y $m = 1.308$ para la estrategia IN).

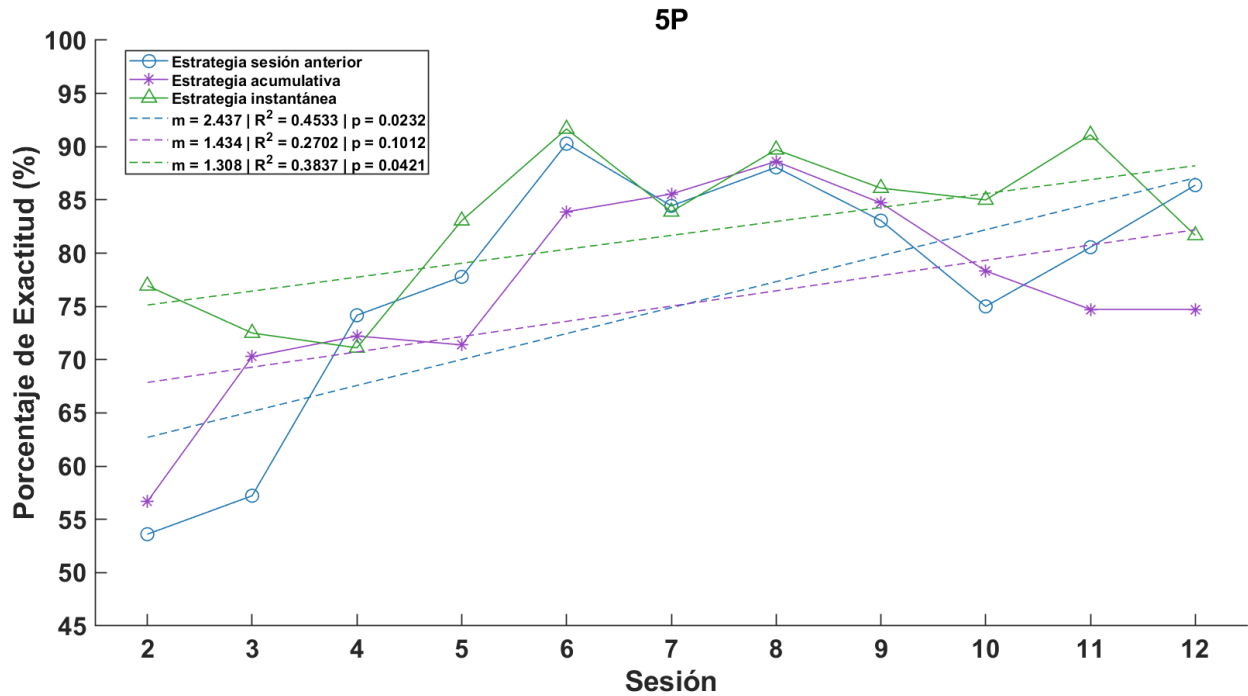


Figura 10. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 5P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

En la Figura 11 se observan los porcentajes de exactitud del paciente 6P durante sus 12 sesiones de terapia. El ajuste lineal no fue estadísticamente significativo ($p > 0.05$) para las tres estrategias ($p = 0.49$ para la estrategia SA, $p = 0.322$ para la estrategia AC y $p = 0.910$ para la estrategia IN) y los valores del coeficiente de determinación presentaron poco ajuste a la recta ($R^2 = 0.055$ para la estrategia SA, $R^2 = 0.109$ para la estrategia AC, $R^2 = 0.001$ para la estrategia IN). Los ajustes lineales de la estrategia SA e IN presentaron pendientes positivas ($m = 0.435$ para la estrategia SA y $m = 0.0404$ para la estrategia IN) mientras que para la estrategia AC se presentó una pendiente negativa ($m = -0.525$).




Figura 11. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 6P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

En la Figura 12 se muestran los porcentajes de exactitud del paciente 7P durante sus 12 sesiones de terapia. El ajuste lineal no fue estadísticamente significativo ($p > 0.05$) para las tres estrategias ($p = 0.867$ para la estrategia SA, $p = 0.326$ para la estrategia AC y $p = 0.385$ para la estrategia IN) y los valores del coeficiente de determinación indicaron poco ajuste a la recta ($R^2 = 0.003$ para la estrategia SA, $R^2 = 0.107$ para la estrategia AC y $R^2 = 0.085$ para la estrategia IN). Los ajustes lineales de las tres estrategias presentaron pendientes positivas ($m = 0.127$ para la estrategia SA, $m = 0.369$ para la estrategia AC y $m = 0.311$ para la estrategia IN).

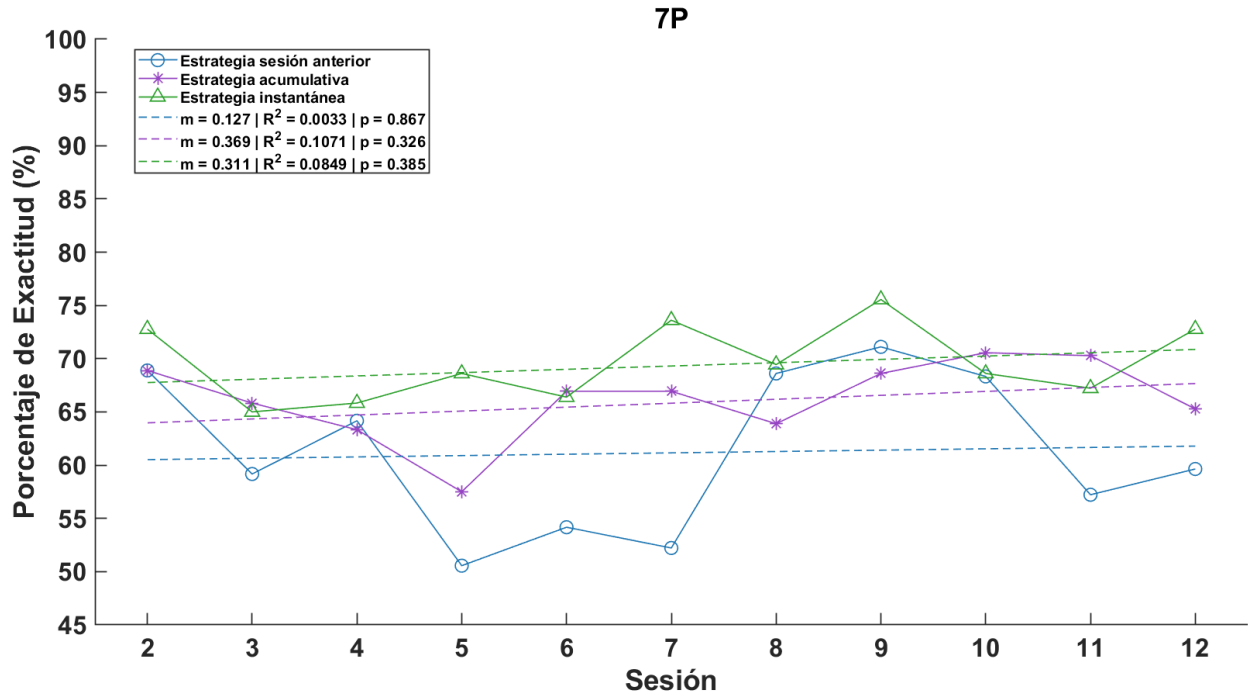


Figura 12. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 7P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

Por otro lado, el paciente 8P (Figura 13) presentó un ajuste lineal estadísticamente significativo ($p < 0.05$) para las tres estrategias ($p = 0.024$ para la estrategia SA, $p = 0.008$ para la estrategia AC y $p = 0.005$ para la estrategia IN). Los coeficientes de determinación sugieren una asociación moderada entre el número de sesiones y el porcentaje de exactitud para las tres estrategias ($R^2 = 0.45$ para la estrategia SA, $R^2 = 0.57$ para la estrategia AC y $R^2 = 0.6$ para la estrategia IN). No obstante, el ajuste lineal para cada estrategia presentó una pendiente negativa ($m = -0.909$ para la estrategia SA, $m = -1.018$ para la estrategia AC y $m = -0.924$ para la estrategia IN).




Figura 13. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 8P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

La Figura 14 muestra los porcentajes de exactitud del paciente 9P durante sus 12 sesiones de terapia, cuyos ajustes lineales no fueron estadísticamente significativos ($p > 0.05$) para las tres estrategias ($p = 0.588$ para la estrategia SA, $p = 0.391$ para la estrategia AC y $p = 0.192$ para la estrategia IN) y los valores del coeficiente de determinación presentaron un ajuste bajo a la recta ($R^2 = 0.034$ para la estrategia SA, $R^2 = 0.083$ para la estrategia AC y $R^2 = 0.181$ para la estrategia IN). Por otra parte, el ajuste lineal de cada estrategia presentó una pendiente positiva ($m = 0.624$ para la estrategia SA, $m = 0.679$ para la estrategia AC y $m = 0.71$ para la estrategia IN).

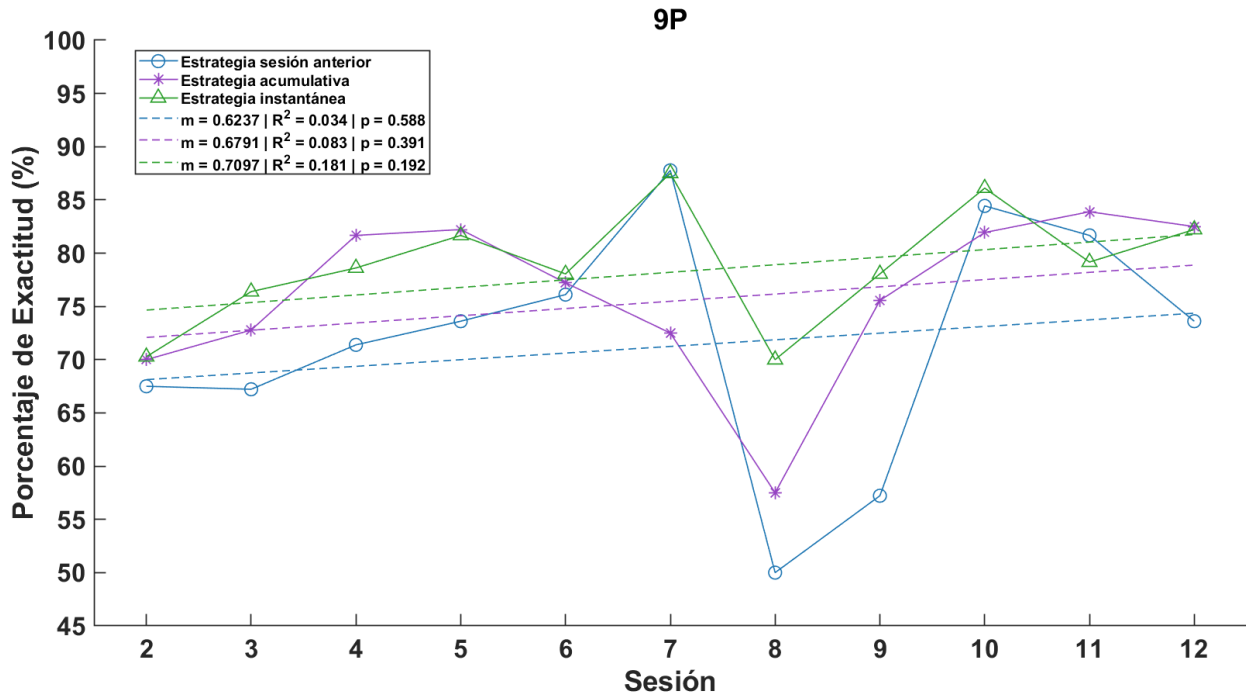


Figura 14. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 9P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

En la Figura 15 se observan los porcentajes de exactitud del paciente 10P durante sus 12 sesiones de terapia. Los ajustes lineales no resultaron estadísticamente significativos ($p > 0.05$) para las tres estrategias ($p = 0.972$ para la estrategia SA, $p = 0.871$ para la estrategia AC y $p = 0.383$ para la estrategia IN) y los valores del coeficiente de determinación indicaron poco ajuste a la recta ($R^2 = 0.0001$ para la estrategia SA, $R^2 = 0.003$ para la estrategia AC y $R^2 = 0.085$ para la estrategia IN). Los ajustes lineales de la estrategia AC e IN presentaron pendientes positivas ($m = 0.157$ para la estrategia AC y $m = 0.773$ para la estrategia IN) en contraste con el ajuste lineal de la estrategia AS que presentó una pendiente negativa ($m = -0.033$).




Figura 15. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 10P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

También se realizó la regresión lineal de los porcentajes de exactitud sesión a sesión de manera individual de los pacientes 11P y 12P (Figura 16 y 17) teniendo en cuenta sus 30 sesiones. Las regresiones lineales de los datos del sujeto 11P presentaron un ajuste lineal estadísticamente significativo ($p < 0.001$) y coeficientes de determinación que sugieren una asociación moderada entre el número de sesiones y los porcentajes de exactitud para las tres estrategias ($R^2 = 0.425$ para la estrategia SA, $R^2 = 0.401$ para la estrategia AC y $R^2 = 0.458$ para la estrategia IN). Asimismo, las pendientes de los ajustes lineales para cada estrategia fueron positivas ($m = 1.001$ para la estrategia SA, $m = 0.815$ para la estrategia AC y $m = 0.841$ para la estrategia IN).




Figura 16. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del paciente 11P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

Por último, el ajuste lineal de los porcentajes de exactitud del paciente 12P (Figura 17) presentaron valores estadísticamente significativos ($p < 0.05$) para cada una de las tres estrategias ($p < 0.001$ para la estrategia SA, $p = 0.012$ para la estrategia AC y $p < 0.001$ para la estrategia IN). Sin embargo, los valores del coeficiente de determinación sugieren una asociación débil a moderada entre el número de sesiones y el porcentaje de exactitud ($R^2 = 0.35$ para la estrategia SA, $R^2 = 0.21$ para la estrategia AC y $R^2 = 0.36$ para la estrategia IN). Por otra parte, el ajuste lineal de cada estrategia presentó una pendiente positiva ($m = 0.719$ para la estrategia SA, $m = 0.324$ para la estrategia AC y $m = 0.31$ para la estrategia IN).

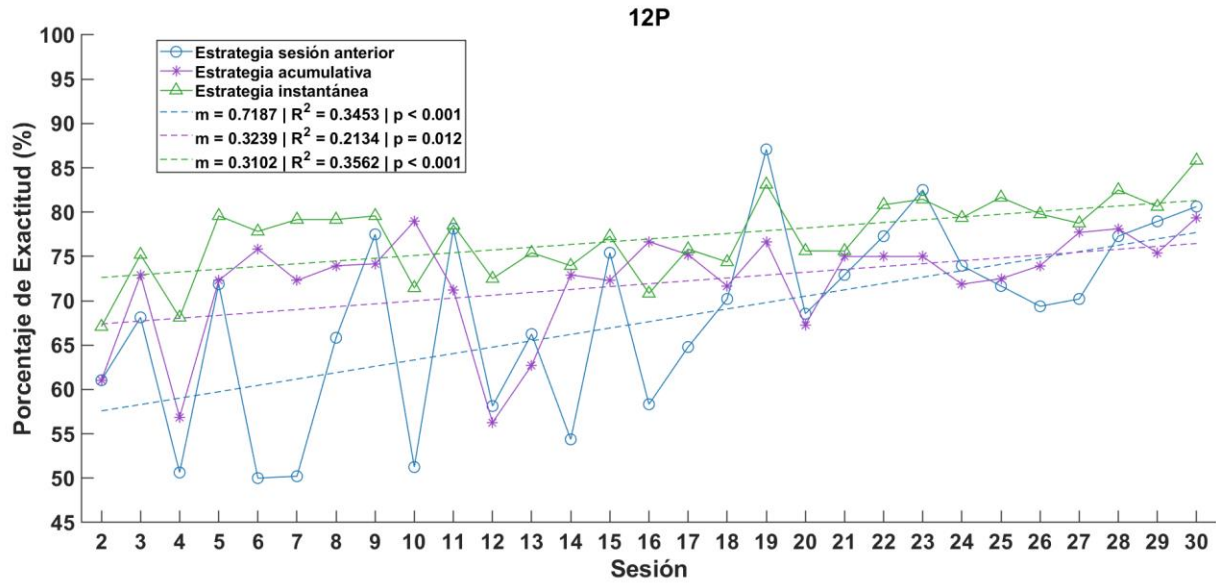


Figura 17. Gráfica de líneas de los porcentajes de exactitud obtenidos con los datos del sujeto 12P al aplicar cada una de las estrategias de entrenamiento. En línea punteada se indica la regresión lineal computada para cada estrategia con su respectiva pendiente (m), coeficiente de determinación (R^2) y significancia del ajuste lineal de la regresión (p).

Discusión

En este estudio se evaluó y comparó el desempeño de tres estrategias de entrenamiento de la etapa de procesamiento de un sistema BCI. Para esta evaluación se realizaron simulaciones fuera de línea usando una base de datos obtenida previamente en un protocolo de rehabilitación en pacientes con EVC. Éste es uno de los pocos estudios realizados de manera retrospectiva en el que se compararon estrategias para buscar mejorar el grado de control de un sistema BCI por parte de pacientes con EVC.

La hipótesis propuesta en este estudio fue que existirían diferencias en el desempeño dependiendo de la estrategia utilizada, proponiéndose la estrategia AC como aquella con la que se obtendría el mejor desempeño. No obstante, la estrategia con la que se observó el mejor desempeño fue la estrategia IN que obtuvo un mayor desempeño en términos de porcentaje de exactitud con respecto a la estrategia AC y SA. Estas diferencias entre la estrategia IN con respecto a la SA y AC fueron significativas. Por lo tanto, existieron diferencias en el desempeño con la BCI entre las tres estrategias (Figura 4) y con la estrategia IN se observaron los mejores desempeños y se debe de rechazar la hipótesis experimental planteada en este estudio.

En la hipótesis se propuso la estrategia AC como aquella con la que se obtendría mejor desempeño bajo la premisa de que, a mayor cantidad de datos de entrenamiento se obtiene una distribución que puede representar mejor los datos, lo que desemboca en un posible mejor desempeño del sistema por parte de pacientes con EVC. También se tomaron en cuenta los resultados reportados con esta estrategia en estudios anteriores [56,60]. En uno de estos estudios, Ang y colaboradores observaron que con la estrategia “*Adaptative All*” (símil a la estrategia AC de este trabajo) se presentó un aumento significativo en el desempeño BCI con respecto a utilizar los datos de una sesión de calibración efectuada al comienzo del protocolo [60]. Asimismo, López-Larraz y colaboradores obtuvieron en términos de sensibilidad una mejoría al utilizar la estrategia “*Accumulated previous sessions*” (símil a la estrategia AC) con respecto a la estrategia “*Previous Session*” (símil a la estrategia SA), aunque la mejoría reportada no fue significativa, posiblemente debido al pequeño tamaño de muestra, que constó de 4

pacientes y 8 sesiones [56]. Estos dos estudios sugieren que se podría aumentar el desempeño de una BCI controlada por pacientes con EVC al utilizar una técnica con todos los datos adquiridos previamente, en contraste con utilizar solo los datos de la sesión anterior.

Como se ha comentado previamente, en este estudio con la estrategia IN se obtuvieron los mejores resultados de desempeño y se presentaron los mayores valores de mediana, al igual que las distribuciones con menor variabilidad en cada una de las métricas. Estos desempeños pueden deberse a que al utilizar datos de la sesión anterior y actualizar en cada corrida con datos de la misma sesión, se pueden contrarrestar de manera efectiva algunas fuentes de variabilidad como lo son la no estacionariedad de la señal de EEG y la posición de los electrodos al momento de la colocación del gorro de EEG. Asimismo, al entrenar el algoritmo con cada corrida e ir añadiendo mayor cantidad de datos de la misma sesión y menos de la sesión anterior, podría incrementarse la adaptabilidad del sistema al seleccionar nuevas características de EEG que ayuden a una mayor clasificación. Estos resultados sugieren que utilizar los datos más recientes, aunque con una menor cantidad de datos de entrenamiento con respecto a la estrategia AC, pueden obtenerse mejores resultados y podría indicar que es más importante proporcionar datos más actuales que una mayor cantidad de ellos.

En el estudio realizado por López-Larraz y colaboradores se propone también la estrategia "*Current Session*", parecida a la estrategia IN de este estudio al utilizar datos de la sesión cursante, y obtuvieron mejores desempeños en términos de diferencias significativas de sensibilidad con respecto a la estrategia "*Accumulated previous sessions*" y "*Previous Session*". Sin embargo, López-Larraz et al. aplicaron un procedimiento de validación dejando-uno-afuera, para seleccionar los datos con los que se obtuvo un mejor desempeño, por lo que se asume que se tienen todos los datos de la sesión actual previamente, lo cual no sucede en situaciones reales de control BCI. Aunque esos resultados no pueden compararse directamente con los obtenidos en este estudio, debido a que no están presentados en términos de porcentaje de clasificación y se utiliza un procedimiento diferente de entrenamiento, en conjunto pueden sentar una base de evidencia para el uso de datos de la misma sesión para entrenar el sistema BCI.

La segunda estrategia con la que se obtuvieron los mejores resultados fue la estrategia AC, que obtuvo una mejoría significativa en el porcentaje de exactitud con respecto a la estrategia SA. Esta mejora en el desempeño puede deberse a la mayor cantidad de datos con los que se entrena el sistema BCI, generando un entrenamiento amplio de la información del paciente y produciéndose una adaptabilidad inter-sesión. No obstante, presenta un leve déficit en cuestión de la clasificación del estado de reposo (especificidad) que puede ser ocasionado por la variabilidad de la actividad mental que realizaron los pacientes durante estos ensayos de reposo.

La última estrategia en cuestión del desempeño obtenido fue la estrategia SA que, al igual que en el estudio de López-Larraz y colaboradores, fue la estrategia con la que se observaron los menores desempeños [56]. Con la estrategia SA se presentó, en términos de especificidad, el mismo valor de mediana que en la estrategia IN, mientras que se presentó un déficit al clasificar la IM (observable en la sensibilidad), lo que ocasiona una disminución de su desempeño en términos de porcentaje de exactitud con respecto a las otras dos estrategias. Los resultados podrían indicar que, al depender directamente de los datos de la sesión anterior, con esta estrategia no se podría lidiar completamente con la no estacionariedad de la señal EEG, debido a la distancia temporal que puede presentarse entre las sesiones y a la variabilidad con la que se colocan los electrodos. Estas fuentes de variabilidad pueden traducirse en valores menores de porcentaje de exactitud y mayor inestabilidad en el desempeño entre cada sesión. A conocimiento del autor, no se había reportado con anterioridad la especificidad junto con la sensibilidad del control BCI en estudios y protocolos clínicos en pacientes con EVC, información que es relevante para identificar donde están las fortalezas y debilidades de las estrategias implementadas.

También se obtuvo la distribución del porcentaje de exactitud del sistema BCI para todos los pacientes sesión a sesión por cada estrategia implementada (Figura 5) y se observó que la variabilidad de los porcentajes de exactitud no se puede representar con un ajuste lineal para ninguna de las estrategias cuando se utilizan todos los datos de todos los pacientes debido a la alta variabilidad que se presenta por cada individuo. Esta variabilidad inter-sujeto también fue reportada por Irimia y colaboradores, donde con una

muestra de 5 pacientes con EVC, se presentaron los porcentajes de exactitud obtenidos por cada terapia y las tendencias lineales de los desempeños del sistema BCI a lo largo de la intervención [62]. En este estudio cabe resaltar que se observó una tendencia con la estrategia IN, en la que se aumentaron los porcentajes de exactitud mientras transcurrieron las terapias, observándose una menor variabilidad en los resultados inter-sujetos. Por lo que, la estrategia IN parece producir un efecto de actualización sobre la información referente a la actividad cerebral realizada por el paciente durante la IM, lo que ayudaría a aumentar los porcentajes de exactitud. Asimismo, la estrategia AC parece lidiar con la variabilidad sesión a sesión a través de un efecto de “amortiguación”, donde los porcentajes de exactitud se mantienen en un rango de valores al transcurrir la intervención y aminora las caídas bruscas del porcentaje de exactitud. Por último, la estrategia SA presenta una alta variabilidad en las distribuciones de porcentaje de exactitud sesión a sesión, por lo tanto, parece ser la más lábil a los cambios que se pueden producir en los datos registrados en la sesión anterior y su similitud con los datos que se van registrando en la sesión cursante.

Del mismo modo, se evaluó el porcentaje de exactitud sesión a sesión a nivel individual y se apreció en la mayoría de los pacientes una jerarquía de desempeño en la cual con la estrategia IN se observaron mayores desempeños, seguidos por la estrategia AC y la estrategia SA, donde con la estrategia IN y AC se presentaron menos fluctuaciones bruscas en el desempeño entre sesiones. De 12 pacientes, 5 presentaron un ajuste lineal estadísticamente significativo, observando en 4 de ellos una pendiente positiva en todas las estrategias. Las pendientes positivas pueden sugerir que el paciente durante el paso de las sesiones BCI va mejorando y homogeneizando la estrategia con la que evoca la IM, lo que disminuiría de alguna manera la variabilidad en la señal EEG entre las sesiones y produciría un aumento en la clasificación. Esto se puede evidenciar en los resultados al usar la estrategia SA en estos pacientes, ya que aumentó considerablemente su porcentaje de exactitud de la segunda terapia a la última terapia disminuyendo la variabilidad del desempeño inter-sesión. Es interesante mencionar que, en el estudio realizado por Irimia y colaboradores, alrededor de la mitad de los pacientes, una proporción parecida a la del presente estudio, presentaron una pendiente positiva

en el ajuste lineal de los desempeños del sistema BCI sesión a sesión, observándose también una mejoría en el desempeño a lo largo de las sesiones con la terapia BCI [62].

De los 4 pacientes de este estudio cuyo desempeño pudo ser descrito con un modelo lineal, 2 pacientes fueron aquellos que realizaron 30 terapias (Figura 16 y 17). Esto nos podría sugerir que, a mayor cantidad de terapias, el desempeño del sistema tiende a ser lineal con respecto al número de sesiones de terapia BCI transcurridas. Sin embargo, los resultados de desempeño obtenidos no solo se pueden atribuir al entrenamiento de la etapa de procesamiento sino también al aprendizaje y al proceso de neuroplasticidad por el que pasan los pacientes a lo largo de las sesiones de la terapia. Asimismo, por los cambios en la actividad cerebral de los pacientes, el utilizar datos de sesiones temporalmente alejadas parece perjudicar el desempeño de la BCI mientras más largo sea el proceso de rehabilitación. Esto puede observarse en los resultados del paciente *11P* (Figura 16), ya que a partir de la terapia 19, con la estrategia SA se mantuvo un mejor desempeño con respecto a la estrategia AC. Aunque estos resultados deben de ser replicados en más de un solo paciente y, se necesita de mayor investigación y análisis estadístico para validar esta asunción.

El desempeño del sistema BCI en terapias en pacientes con EVC ha demostrado relevancia, debido a que se ha reportado que proporcionar la retroalimentación en el momento adecuado en que se realiza la intención de movimiento y no de manera aleatoria, produce mejores resultados en la mejoría clínica del paciente [63–65]. Por lo que aumentar la certidumbre de la retroalimentación resultaría beneficioso para el paciente. Además, un mayor control de la BCI podría aumentar la rehabilitación en el paciente de manera indirecta, ya que el recibir la retroalimentación con mayor exactitud a la participación activa del paciente, obtiene una recompensa al sentir que sus intenciones son aquellas que ejecutan el sistema, mejorando su estado de ánimo y aumentando su motivación de continuar con el proceso de rehabilitación. Estos dos últimos aspectos se han relacionado con un incremento en la recuperación funcional del paciente al finalizar terapias BCI [66,67].

A su vez, dada la importancia de validar que los resultados clínicos se atribuyan principalmente a la retroalimentación obtenida por acción de la actividad cerebral del

paciente y no al azar, se necesita de un desempeño mínimo del sistema BCI con respecto a la aleatoriedad, tema que ha sido motivo de discusión en el ámbito de las BCIs para uso en las áreas de la salud [68]. En tareas de clasificación de dos clases, este nivel de aleatoriedad se considera del 50%, y en estudios anteriores en pacientes con EVC los valores obtenidos se encuentran en un rango del 40% y el 96% de exactitud [48,50,53,58,69,70]. En este estudio los porcentajes de exactitud oscilaron en un rango entre 44.72% y 95.56% y al menos el 75% de los valores de sus distribuciones presentaron valores por encima del 50%, por lo que se podría considerar que con las 3 estrategias probadas se obtienen resultados por encima de la aleatoriedad y con ellas se podrían obtener resultados similares o mejores de desempeño, a los obtenidos en estudios en los que los pacientes con EVC controlaron el sistema [48,50,53,58,69,70]. Sin embargo, con los resultados obtenidos en este estudio no se puede concluir que las estrategias planteadas sean mejor en línea, es decir, cuando se implementa la BCI en tiempo real y se clasifica la señal de EEG al momento. Se necesitaría de estudios experimentales en los que los pacientes con EVC intenten controlar una BCI con las diferentes estrategias estudiadas para poder confirmar los resultados obtenidos de manera fuera de línea en este estudio.

Es importante no solo tener en cuenta los resultados del desempeño del sistema sino también variables y limitaciones prácticas del uso de la estrategia para tener una implementación exitosa en la clínica. Por ejemplo, para la estrategia AC, al irse incrementando linealmente la cantidad de datos sesión a sesión, la duración del entrenamiento incrementa proporcionalmente, por lo que se debe de tomar en cuenta que el entrenamiento en las últimas terapias requerirá más recursos computacionales y tiempo de procesamiento en comparación con las primeras sesiones de terapia. La estrategia SA es la estrategia entre las evaluadas, que requiere la menor inversión de tiempo y costo computacional para entrenar el sistema BCI. Esta estrategia por ende permite optimizar el tiempo efectivo de rehabilitación en una sesión de terapia. Pero parece ser también la más susceptible a los cambios de colocación del gorro con electrodos y otras fuentes de variabilidad que pueden reducir el desempeño BCI de los pacientes. Por el otro lado, la estrategia IN necesita de entrenamientos durante la sesión, por lo que podría incrementar la duración de las sesiones, aunque se pueden proponer

soluciones, por ejemplo, efectuar los entrenamientos de la etapa de procesamiento de la BCI durante los tiempos de descanso del paciente, entre cada corrida. Además, al requerir de entrenar el sistema múltiples veces durante la sesión de terapia, puede incrementarse la probabilidad de que haya un error humano a la hora de realizar el entrenamiento de la etapa de procesamiento de la BCI. Aun así, la estrategia IN parece ser una opción viable para ser usada en los protocolos clínicos debido al aumento en el desempeño del sistema y la disminución de la variabilidad inter-sesión presentados en los resultados. Por lo que entrenar reiteradas veces durante una misma sesión podría ser un precio aceptable a pagar para proporcionar mejores terapias de rehabilitación a los pacientes.

Es importante mencionar que, aún con estos resultados, es necesaria la implementación de estas estrategias en distintos estudios con diferentes bases de datos con un mayor número de pacientes y sesiones para otorgar una mayor validez y puedan ser aplicadas en futuros protocolos en línea en pacientes con EVC. De igual manera, se incentiva a seguir implementando y evaluando nuevas estrategias que puedan tomar características de la estrategia AC y la estrategia IN como las propuestas por López-Larraz y colaboradores en [56] y Giles J y colaboradores en [57], y que podría ser beneficioso para el desempeño del sistema BCI. Ang y colaboradores en [60] demuestran que limitar a una cantidad los datos utilizados para entrenar la BCI, produce resultados similares a usar todos los datos disponibles hasta el momento para el entrenamiento. Por lo que se podría proponer para futuras pruebas utilizar tanto los datos de la sesión actual junto con datos de las sesiones anteriores limitando a un número establecido de datos para disminuir los tiempos de entrenamiento y aun así obtener un beneficio en el porcentaje de exactitud, que se podría reflejar en la rehabilitación del paciente. También, se podría considerar el uso de estrategias de entrenamiento con procesamientos más complejos que involucren metodologías de “*transfer learning*” a la par de la selección de los datos de entrenamiento como la propuesta por Giles J y colaboradores [57].

Por último, a pesar de las limitaciones de este trabajo, se puede inferir que el aplicar cualquiera de las 3 estrategias evaluadas en una terapia BCI de rehabilitación de extremidad superior en pacientes con EVC, es válido desde el punto de vista del

desempeño BCI que se obtiene. Sin embargo, si se requiere obtener el mayor desempeño posible y se cuentan con los recursos computacionales que permitan realizar el entrenamiento de la etapa de procesamiento de la BCI en el periodo de descanso, es decir, entre las corridas del protocolo experimental, entonces es recomendable aplicar la estrategia instantánea.

Conclusiones

Los resultados presentados en este estudio nos brindan un amplio panorama de las diferencias en el desempeño del sistema BCI dependiendo de la cantidad y que tan recientes son los datos utilizados para entrenar la etapa de procesamiento. Se concluyó que la estrategia IN fue con la que se obtuvieron los mejores desempeños en cada una de las métricas evaluadas, seguida por la estrategia AC y por último la estrategia SA. De igual manera, con la estrategia IN se presentó menor variabilidad entre los resultados y una tendencia a que el desempeño mejore sesión a sesión.

La estrategia IN, al actualizar constantemente el modelo, muestra que puede lidiar de mejor manera con los cambios que se producen en la evocación de la IM, el aprendizaje mismo, la colocación de los electrodos y la característica de no estacionariedad de la señal EEG. Mientras que la estrategia AC, al contener una gran cantidad de datos para generalizar la clasificación, a través de un efecto de amortiguación, hace posible que los cambios en el desempeño no sean tan bruscos como los presentados por la estrategia SA.

Estos resultados nos sugieren que, utilizar la estrategia IN en protocolos clínicos podría mejorar el desempeño del sistema BCI con respecto a otras estrategias ya utilizadas como lo es la estrategia SA. No obstante, es necesario más evaluación de estas estrategias tanto en estudios retrospectivos con otras bases de datos como también en protocolos clínicos en línea en pacientes con EVC.

Como última observación, es importante comentar que pocos estudios se han enfocado en evaluar las estrategias de entrenamiento de la etapa de procesamiento de un sistema BCI, por lo que este estudio realiza un aporte importante en la búsqueda de estrategias de entrenamiento que permitan proporcionar mejores terapias de rehabilitación con sistemas BCI a los pacientes con EVC, con la finalidad de mejorar su recuperación y validar este tipo de terapias que pueden apoyar a muchos pacientes con EVC alrededor del mundo.

Trabajo a futuro

El presente trabajo ha abordado la importancia del entrenamiento de la etapa de procesamiento de un sistema BCI y los cambios que puede ocasionar en el desempeño de este mismo. Sin embargo, existen diversas oportunidades para ampliar y profundizar en el tema que pueden contribuir a mejorar y acercar las terapias BCI a la práctica clínica en pacientes con EVC. Como trabajo a futuro, se plantea explorar asociaciones, entre valores clínicos iniciales de pruebas motoras y cognitivas con los valores de desempeños BCI obtenidos en este estudio. Esto con el objetivo de identificar factores clínicos que puedan influir en el control del sistema BCI, para adaptar de mejor forma estrategias de entrenamiento para grupos de pacientes con ciertas características clínicas. Asimismo, se plantea explorar en el futuro el desempeño de las estrategias evaluadas en el presente trabajo y de nuevas estrategias en una muestra más amplia de pacientes.

Además, en un entorno clínico, se plantea aplicar la estrategia IN en terapias BCI, pero esta vez en línea con pacientes con EVC, para comprobar que los beneficios observados en este estudio sean consistentes en un entorno no simulado. De igual manera, se propone automatizar parcialmente el proceso de múltiples entrenamientos dentro de una misma sesión que se realiza durante la estrategia IN.

Bibliografía

- [1] World Health Organization. The top 10 causes of death. World Health Organization 2020. <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death> (accessed June 25, 2023).
- [2] Cruz-Góngora VD la, Chiquete E, Gómez–Dantés H, Cahuana-Hurtado L, Cantú-Brito C. Trends in the burden of stroke in Mexico: A national and subnational analysis of the global burden of disease 1990–2019. *The Lancet Regional Health - Americas* 2022;10:100204. <https://doi.org/10.1016/j.lana.2022.100204>.
- [3] INNN. Enfermedad Vascular Cerebral. Instituto Nacional de Neurología Y Neurocirugía 2022. <https://www.gob.mx/salud/prensa/525-enfermedad-vascular-cerebral-entre-las-10-primeras-causas-de-muerte-y-segunda-de-discapacidad> (accessed June 26, 2023).
- [4] Instituto Nacional de Neurología y Neurocirugía. 525. Enfermedad vascular cerebral, Entre las 10 primeras causas de muerte y segunda de discapacidad. Gobierno de México 2022. <https://www.gob.mx/salud/prensa/525-enfermedad-vascular-cerebral-entre-las-10-primeras-causas-de-muerte-y-segunda-de-discapacidad> (accessed June 25, 2023).
- [5] Virani SS, Alonso A, Aparicio HJ, Benjamin EJ, Bittencourt MS, Callaway CW, et al. Heart Disease and Stroke Statistics—2021 Update. *Circulation* 2021;143. <https://doi.org/10.1161/CIR.0000000000000950>.
- [6] Cruz Cruz Copytzy. Factores pronósticos de la supervivencia, recurrencia y secuelas en pacientes con Enfermedad Vascular Cerebral del Instituto Nacional de Neurología y Neurocirugía. Tesis de doctorado. Escuela de Salud Pública de México, 2017.
- [7] Cantillo-Negrete J, Carino-Escobar RI, Carrillo-Mora P, Elias-Vinas D, Gutierrez-Martinez J. Motor Imagery-Based Brain-Computer Interface Coupled to a Robotic Hand Orthosis Aimed for Neurorehabilitation of Stroke Patients. *J Healthc Eng* 2018;2018:1–10. <https://doi.org/10.1155/2018/1624637>.
- [8] Vourvopoulos A, Pardo OM, Lefebvre S, Neureither M, Saldana D, Jahng E, et al. Effects of a Brain-Computer Interface With Virtual Reality (VR) Neurofeedback: A Pilot Study in Chronic Stroke Patients. *Front Hum Neurosci* 2019;13. <https://doi.org/10.3389/fnhum.2019.00210>.
- [9] Mane R, Chouhan T, Guan C. BCI for stroke rehabilitation: Motor and beyond. *J Neural Eng* 2020;17. <https://doi.org/10.1088/1741-2552/aba162>.
- [10] Rivera-Nava Silvia Cristina, Miranda-Medrano LI, Pérez-Rojas JEA, Flores J de J, Rivera-García BE, Torres-Arreola L del P. Guía de práctica clínica

Enfermedad vascular cerebral isquémica. *Rev Med Inst Mex Seguro Soc* 2012;50:335–46.

- [11] González Piña R, Landínez Martínez Daniel. Epidemiología, etiología y clasificación de la enfermedad vascular cerebral. *Archivos de Medicina (Col)* 2016;16:495–507.
- [12] Bernhardt J, Hayward KS, Kwakkel G, Ward NS, Wolf SL, Borschmann K, et al. Agreed definitions and a shared vision for new standards in stroke recovery research: The Stroke Recovery and Rehabilitation Roundtable taskforce. *International Journal of Stroke* 2017;12:444–50. <https://doi.org/10.1177/1747493017711816>.
- [13] Jung H-Y. Rehabilitation in Subacute and Chronic Stage After Stroke. *Stroke Revisited: Diagnosis and Treatment of Ischemic Stroke*, Singapore: Springer Singapore; 2017, p. 351–60. https://doi.org/10.1007/978-981-10-1424-6_33.
- [14] Aqueveque P, Ortega P, Pino E, Saavedra F, Germany E, Gómez B. After Stroke Movement Impairments: A Review of Current Technologies for Rehabilitation. *Physical Disabilities - Therapeutic Implications*, InTech; 2017. <https://doi.org/10.5772/67577>.
- [15] Donnan GA, Baron J-C, Ma H, Davis SM. Penumbral selection of patients for trials of acute stroke therapy. *Lancet Neurol* 2009;8:261–9. [https://doi.org/10.1016/S1474-4422\(09\)70041-9](https://doi.org/10.1016/S1474-4422(09)70041-9).
- [16] Carrera E, Tononi G. Diaschisis: past, present, future. *Brain* 2014;137:2408–22. <https://doi.org/10.1093/brain/awu101>.
- [17] Silver J, Miller JH. Regeneration beyond the glial scar. *Nat Rev Neurosci* 2004;5:146–56. <https://doi.org/10.1038/nrn1326>.
- [18] Shi X, Luo L, Wang J, Shen H, Li Y, Mamtilahun M, et al. Stroke subtype-dependent synapse elimination by reactive gliosis in mice. *Nat Commun* 2021;12:6943. <https://doi.org/10.1038/s41467-021-27248-x>.
- [19] Alia C, Spalletti C, Lai S, Panarese A, Lamola G, Bertolucci F, et al. Neuroplastic Changes Following Brain Ischemia and their Contribution to Stroke Recovery: Novel Approaches in Neurorehabilitation. *Front Cell Neurosci* 2017;11. <https://doi.org/10.3389/fncel.2017.00076>.
- [20] Nishibe M, Urban ETR, Barbay S, Nudo RJ. Rehabilitative Training Promotes Rapid Motor Recovery but Delayed Motor Map Reorganization in a Rat Cortical Ischemic Infarct Model. *Neurorehabil Neural Repair* 2015;29:472–82. <https://doi.org/10.1177/1545968314543499>.
- [21] Murphy TH, Corbett D. Plasticity during stroke recovery: from synapse to behaviour. *Nat Rev Neurosci* 2009;10:861–72. <https://doi.org/10.1038/nrn2735>.
- [22] Dancause N, Nudo RJ. Shaping plasticity to enhance recovery after injury, 2011, p. 273–95. <https://doi.org/10.1016/B978-0-444-53355-5.00015-4>.

- [23] Carey L, Walsh A, Adikari A, Goodin P, Alahakoon D, De Silva D, et al. Finding the Intersection of Neuroplasticity, Stroke Recovery, and Learning: Scope and Contributions to Stroke Rehabilitation. *Neural Plast* 2019;2019:1–15. <https://doi.org/10.1155/2019/5232374>.
- [24] Wieloch T, Nikolich K. Mechanisms of neural plasticity following brain injury. *Curr Opin Neurobiol* 2006;16:258–64. <https://doi.org/10.1016/j.conb.2006.05.011>.
- [25] Pekna M, Pekny M, Nilsson M. Modulation of Neural Plasticity as a Basis for Stroke Rehabilitation. *Stroke* 2012;43:2819–28. <https://doi.org/10.1161/STROKEAHA.112.654228>.
- [26] Wolpaw J, Wolpaw EW. *Brain–Computer Interfaces Principles and Practice*. Oxford University Press; 2012. <https://doi.org/10.1093/acprof:oso/9780195388855.001.0001>.
- [27] Kosmyna N, Tarpin-Bernard F, Rivet B. Towards Brain Computer Interfaces for Recreational Activities: Piloting a Drone, 2015, p. 506–22. https://doi.org/10.1007/978-3-319-22701-6_37.
- [28] Cantillo-Negrete J, Carino-Escobar RI, Carrillo-Mora P, Rodriguez-Barragan MA, Hernandez-Arenas C, Quinzaños-Fresnedo J, et al. Brain-Computer Interface Coupled to a Robotic Hand Orthosis for Stroke Patients' Neurorehabilitation: A Crossover Feasibility Study. *Front Hum Neurosci* 2021;15. <https://doi.org/10.3389/fnhum.2021.656975>.
- [29] Caria A, Weber C, Brötz D, Ramos A, Ticini LF, Gharabaghi A, et al. Chronic stroke recovery after combined BCI training and physiotherapy: A case report. *Psychophysiology* 2011;48:578–82. <https://doi.org/10.1111/j.1469-8986.2010.01117.x>.
- [30] Kai Keng Ang, Cuntai Guan, Sui Geok Chua K, Beng Ti Ang, Kuah C, Chuanchu Wang, et al. A clinical study of motor imagery-based brain-computer interface for upper limb robotic rehabilitation. 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE; 2009, p. 5981–4. <https://doi.org/10.1109/IEMBS.2009.5335381>.
- [31] Josefina Gutiérrez-Martínez, Jessica Cantillo-Negrete, Rubén Isaac Cariño-Escobar, David Elías-Viñas. Los sistemas de interfaz cerebro-computadora: una herramienta para apoyar la rehabilitación de pacientes con discapacidad motora. *Investigación En Discapacidad* 2013;2:62–9.
- [32] Wolpaw JR, Birbaumer N, McFarland DJ, Pfurtscheller G, Vaughan TM. Brain–computer interfaces for communication and control. *Clinical Neurophysiology* 2002;113:767–91. [https://doi.org/10.1016/S1388-2457\(02\)00057-3](https://doi.org/10.1016/S1388-2457(02)00057-3).

- [33] Kübler A. The history of BCI: From a vision for the future to real support for personhood in people with locked-in syndrome. *Neuroethics* 2020;13:163–80. <https://doi.org/10.1007/s12152-019-09409-4>.
- [34] Wolpaw JR, McFarland DJ, Neat GW, Forneris CA. An EEG-based brain-computer interface for cursor control. *Electroencephalogr Clin Neurophysiol* 1991;78:252–9. [https://doi.org/10.1016/0013-4694\(91\)90040-B](https://doi.org/10.1016/0013-4694(91)90040-B).
- [35] Wolpaw JR, McFarland DJ. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences* 2004;101:17849–54. <https://doi.org/10.1073/pnas.0403504101>.
- [36] Kübler A, Neumann N, Wilhelm B, Hinterberger T, Birbaumer N. Predictability of Brain-Computer Communication. *J Psychophysiol* 2004;18:121–9. <https://doi.org/10.1027/0269-8803.18.23.121>.
- [37] Md Isa NE, Amir A, Ilyas MZ, Razalli MS. Motor imagery classification in Brain computer interface (BCI) based on EEG signal by using machine learning technique. *Bulletin of Electrical Engineering and Informatics* 2019;8:269–75. <https://doi.org/10.11591/eei.v8i1.1402>.
- [38] Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning. *Electronic Markets* 2021;31:685–95. <https://doi.org/10.1007/s12525-021-00475-2>.
- [39] Lotte F, Bougrain L, Cichocki A, Clerc M, Congedo M, Rakotomamonjy A, et al. A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update. *J Neural Eng* 2018;15:031005. <https://doi.org/10.1088/1741-2552/aab2f2>.
- [40] Santos EM dos, Fernandes CA, Castellano G. Performance of stroke patients using a brain-computer interface during motor imagery: a systematic review. *Research on Biomedical Engineering* 2023;39:451–65. <https://doi.org/10.1007/s42600-023-00284-w>.
- [41] Blankertz B, Tomioka R, Lemm S, Kawanabe M, Muller K. Optimizing Spatial filters for Robust EEG Single-Trial Analysis. *IEEE Signal Process Mag* 2008;25:41–56. <https://doi.org/10.1109/MSP.2008.4408441>.
- [42] Kai Keng Ang, Zhang Yang Chin, Haihong Zhang, Cuntai Guan. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), IEEE; 2008, p. 2390–7. <https://doi.org/10.1109/IJCNN.2008.4634130>.
- [43] Ang KK, Chin ZY, Wang C, Guan C, Zhang H. Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. *Front Neurosci* 2012;6. <https://doi.org/10.3389/fnins.2012.00039>.

- [44] Chen S, Shu X, Wang H, Ding L, Fu J, Jia J. The Differences Between Motor Attempt and Motor Imagery in Brain-Computer Interface Accuracy and Event-Related Desynchronization of Patients With Hemiplegia. *Front Neurobot* 2021;15. <https://doi.org/10.3389/fnbot.2021.706630>.
- [45] Pfurtscheller G, Lopes da Silva FH. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology* 1999;110:1842–57. [https://doi.org/10.1016/S1388-2457\(99\)00141-8](https://doi.org/10.1016/S1388-2457(99)00141-8).
- [46] Jordan J. Preparing data for a machine learning model 2017. <https://www.jeremyjordan.me/preparing-data-for-a-machine-learning-model/> (accessed June 29, 2023).
- [47] Nighania K. Various ways to evaluate a machine learning model's performance 2018. <https://towardsdatascience.com/various-ways-to-evaluate-a-machine-learning-models-performance-230449055f15> (accessed June 29, 2023).
- [48] Vourvopoulos A, Jorge C, Abreu R, Figueiredo P, Fernandes J-C, Bermúdez i Badia S. Efficacy and Brain Imaging Correlates of an Immersive Motor Imagery BCI-Driven VR System for Upper Limb Motor Rehabilitation: A Clinical Case Report. *Front Hum Neurosci* 2019;13. <https://doi.org/10.3389/fnhum.2019.00244>.
- [49] Kai Keng Ang, Cuntai Guan, Sui Geok Chua K, Beng Ti Ang, Kuah C, Chuanchu Wang, et al. A clinical study of motor imagery-based brain-computer interface for upper limb robotic rehabilitation. 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE; 2009, p. 5981–4. <https://doi.org/10.1109/IEMBS.2009.5335381>.
- [50] Ang KK, Guan C, Chua KSG, Ang BT, Kuah CWK, Wang C, et al. A Large Clinical Study on the Ability of Stroke Patients to Use an EEG-Based Motor Imagery Brain-Computer Interface. *Clin EEG Neurosci* 2011;42:253–8. <https://doi.org/10.1177/155005941104200411>.
- [51] Frolov AA, Mokienko O, Lyukmanov R, Biryukova E, Kotov S, Turbina L, et al. Post-stroke Rehabilitation Training with a Motor-Imagery-Based Brain-Computer Interface (BCI)-Controlled Hand Exoskeleton: A Randomized Controlled Multicenter Trial. *Front Neurosci* 2017;11. <https://doi.org/10.3389/fnins.2017.00400>.
- [52] Ramos-Murguialday A, Broetz D, Rea M, Lärer L, Yilmaz Ö, Brasil FL, et al. Brain-machine interface in chronic stroke rehabilitation: A controlled study. *Ann Neurol* 2013;74:100–8. <https://doi.org/10.1002/ana.23879>.
- [53] Wang C, Phua KS, Ang KK, Guan C, Zhang H, Rongsheng Lin, et al. A feasibility study of non-invasive motor-imagery BCI-based robotic rehabilitation for Stroke patients. 2009 4th International IEEE/EMBS Conference on Neural Engineering, IEEE; 2009, p. 271–4. <https://doi.org/10.1109/NER.2009.5109285>.

- [54] Ono T, Shindo K, Kawashima K, Ota N, Ito M, Ota T, et al. Brain-computer interface with somatosensory feedback improves functional recovery from severe hemiplegia due to chronic stroke. *Front Neuroeng* 2014;7. <https://doi.org/10.3389/fneng.2014.00019>.
- [55] Ang KK, Guan C, Chua KSG, Ang BT, Kuah CWK, Wang C, et al. A clinical evaluation of non-invasive motor imagery-based brain-computer interface in stroke. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE; 2008, p. 4178–81. <https://doi.org/10.1109/IEMBS.2008.4650130>.
- [56] López-Larraz E, Ibáñez J, Trincado-Alonso F, Monge-Pereira E, Pons JL, Montesano L. Comparing Recalibration Strategies for Electroencephalography-Based Decoders of Movement Intention in Neurological Patients with Motor Disability. *Int J Neural Syst* 2018;28:1750060. <https://doi.org/10.1142/S0129065717500605>.
- [57] Giles J, Ang KK, Phua KS, Arvaneh M. A Transfer Learning Algorithm to Reduce Brain-Computer Interface Calibration Time for Long-Term Users. *Frontiers in Neuroergonomics* 2022;3. <https://doi.org/10.3389/fnrgo.2022.837307>.
- [58] Irimia DC, Cho W, Ortner R, Allison BZ, Ignat BE, Edlinger G, et al. Brain-Computer Interfaces With Multi-Sensory Feedback for Stroke Rehabilitation: A Case Study. *Artif Organs* 2017;41:E178–84. <https://doi.org/10.1111/aor.13054>.
- [59] Ang KK, Chua KSG, Phua KS, Wang C, Chin ZY, Kuah CWK, et al. A Randomized Controlled Trial of EEG-Based Motor Imagery Brain-Computer Interface Robotic Rehabilitation for Stroke. *Clin EEG Neurosci* 2015;46:310–20. <https://doi.org/10.1177/1550059414522229>.
- [60] Ang KK, Guan C. EEG-Based Strategies to Detect Motor Imagery for Control and Rehabilitation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2017;25:392–401. <https://doi.org/10.1109/TNSRE.2016.2646763>.
- [61] Jordan J. Evaluating a machine learning model 2017. <https://www.jeremyjordan.me/evaluating-a-machine-learning-model/> (accessed June 29, 2023).
- [62] Irimia DC, Ortner R, Poboroniuc MS, Ignat BE, Guger C. High Classification Accuracy of a Motor Imagery Based Brain-Computer Interface for Stroke Rehabilitation Training. *Front Robot AI* 2018;5. <https://doi.org/10.3389/frobt.2018.00130>.
- [63] Ramos-Murguialday A, Broetz D, Rea M, Läer L, Yilmaz Ö, Brasil FL, et al. Brain-machine interface in chronic stroke rehabilitation: A controlled study. *Ann Neurol* 2013;74:100–8. <https://doi.org/10.1002/ana.23879>.

- [64] Frolov AA, Mokienko O, Lyukmanov R, Biryukova E, Kotov S, Turbina L, et al. Post-stroke Rehabilitation Training with a Motor-Imagery-Based Brain-Computer Interface (BCI)-Controlled Hand Exoskeleton: A Randomized Controlled Multicenter Trial. *Front Neurosci* 2017;11. <https://doi.org/10.3389/fnins.2017.00400>.
- [65] Biasiucci A, Leeb R, Iturrate I, Perdakis S, Al-Khodairy A, Corbet T, et al. Brain-actuated functional electrical stimulation elicits lasting arm motor recovery after stroke. *Nat Commun* 2018;9:2421. <https://doi.org/10.1038/s41467-018-04673-z>.
- [66] Morone G, Pisotta I, Pichiorri F, Kleih S, Paolucci S, Molinari M, et al. Proof of Principle of a Brain-Computer Interface Approach to Support Poststroke Arm Rehabilitation in Hospitalized Patients: Design, Acceptability, and Usability. *Arch Phys Med Rehabil* 2015;96:S71–8. <https://doi.org/10.1016/j.apmr.2014.05.026>.
- [67] Fotakopoulos G, Kotlia P. The Value of Exercise Rehabilitation Program Accompanied by Experiential Music for Recovery of Cognitive and Motor Skills in Stroke Patients. *Journal of Stroke and Cerebrovascular Diseases* 2018;27:2932–9. <https://doi.org/10.1016/j.jstrokecerebrovasdis.2018.06.025>.
- [68] Billinger M, Daly I, Kaiser V, Jin J, Allison BZ, Müller-Putz GR, et al. Is It Significant? Guidelines for Reporting BCI Performance, 2012, p. 333–54. https://doi.org/10.1007/978-3-642-29746-5_17.
- [69] Arvaneh M, Guan C, Ang KK, Ward TE, Chua KSG, Kuah CWK, et al. Facilitating motor imagery-based brain–computer interface for stroke patients using passive movement. *Neural Comput Appl* 2017;28:3259–72. <https://doi.org/10.1007/s00521-016-2234-7>.
- [70] Barsotti M, Leonardis D, Loconsole C, Solazzi M, Sotgiu E, Procopio C, et al. A full upper limb robotic exoskeleton for reaching and grasping rehabilitation triggered by MI-BCI. 2015 IEEE International Conference on Rehabilitation Robotics (ICORR), IEEE; 2015, p. 49–54. <https://doi.org/10.1109/ICORR.2015.7281174>.