

Desarrollo y evaluación de un sistema BCI basado en imaginación motora: comparativa de FBCSP y geometría Riemanniana

Development and evaluation of a motor imagery BCI system: comparison of FBCSP and Riemannian geometry

⁽¹⁾ Cristina Herrero Martínez, ⁽²⁾ Álvaro Fernández Guirao ^[0009-0007-4022-1288], ⁽³⁾ Enrique Navarro Camba ^[0000-0001-8365-0233], ⁽⁴⁾ José Vicente Riera López ^[0000-0002-2754-9592]

⁽¹⁾ IRTIC – Universidad de Valencia, herreromartinezcristina@gmail.com

⁽²⁾ IRTIC – Universidad de Valencia, alvaro.fernandez-guirao@uv.es

⁽³⁾ IRTIC – Universidad de Valencia, enrique.navarro@uv.es

⁽⁴⁾ IRTIC – Universidad de Valencia, j.vicente.riera@uv.es

Resumen. Este trabajo presenta el desarrollo y evaluación de un sistema de interfaz cerebro-computador (BCI) basado en señales EEG para clasificación de imaginación motora bilateral. Se diseñó un protocolo experimental con hardware de bajo coste (OpenBCI Cyton+Daisy, 16 canales, 125 Hz) e implementación en Python. Se compararon Filter Bank Common Spatial Patterns (FBCSP) y geometría Riemanniana con proyección al espacio tangente y alineamiento euclidiano (EA), evaluados mediante validación cruzada leave-one-subject-out (LOSO) con 10 participantes novatos. El FBCSP obtuvo una exactitud balanceada media de $0,569 \pm 0,081$ en el esquema cross-subject; el método Riemannian alcanzó $0,647 \pm 0,086$ ($N=9$). Ambos son significativamente superiores al azar (FBCSP: $t(9)=2,69$, $p=0,025$, $d=0,85$; Riemannian: $t(8)=5,10$, $p<0,001$, $d=1,70$). El EA aportó +5,3 puntos porcentuales al rendimiento Riemannian cross-subject. La latencia de inferencia fue inferior a 7 ms ($p99$), confirmando la viabilidad para retroalimentación en tiempo real.

Palabras clave: interfaz cerebro-computador, imaginación motora, EEG, FBCSP, geometría Riemanniana.

Abstract. This paper presents the development and evaluation of a brain-computer interface (BCI) system based on EEG signals for bilateral motor imagery classification.

A complete experimental protocol was designed with low-cost hardware (OpenBCI Cyton+Daisy, 16 channels, 125 Hz) and implemented in Python. Filter Bank Common Spatial Patterns (FBCSP) and Riemannian geometry with tangent space projection and Euclidean Alignment (EA) were compared using leave-one-subject-out (LOSO) cross-validation with 10 naive participants. FBCSP achieved a mean balanced accuracy of 0.569 ± 0.081 (cross-subject); the Riemannian method reached 0.647 ± 0.086 ($N=9$). Both are significantly above chance (FBCSP: $t(9)=2.69$, $p=0.025$, $d=0.85$; Riemannian: $t(8)=5.10$, $p<0.001$, $d=1.70$). EA contributed +5.3 percentage points to Riemannian cross-subject performance. Inference latency was below 7 ms ($p99$), confirming suitability for real-time neurofeedback.

Keywords: brain-computer interface, motor imagery, EEG, FBCSP, Riemannian geometry.

1. INTRODUCCIÓN

Las interfaces cerebro-computador (BCI) establecen un canal de comunicación directo entre la actividad cerebral y un dispositivo externo sin utilizar el sistema nervioso periférico (Clerc et al., 2016). La electroencefalografía (EEG) es la tecnología de registro más empleada por su carácter no invasivo, portabilidad y bajo coste. La imaginación motora (MI) es el paradigma de elección en BCI basados en EEG: los usuarios imaginan movimientos sin ejecutarlos, generando fenómenos de desincronización y sincronización relacionados con eventos (ERD/ERS) en las bandas mu (8–13 Hz) y beta (13–30 Hz) detectables en el EEG (Wolpaw et al., 2002). Estos patrones permiten discriminar entre tareas de MI y controlar dispositivos externos, con aplicaciones documentadas en rehabilitación neurológica, asistencia a personas con discapacidad motora y sistemas de interacción humano-máquina.

La mayor parte de estudios BCI emplea hardware EEG clínico de alto coste (>5.000 €), lo que limita su accesibilidad y reproducibilidad en entornos no especializados. El hardware consumer-grade, como el OpenBCI Cyton+Daisy (~500 €), ofrece una alternativa viable pero introduce mayor variabilidad en la señal y requiere pipelines de preprocesamiento más robustos. Este trabajo aborda esta brecha, desarrollando y evaluando un sistema BCI completo con hardware de bajo coste en condiciones ecológicas: sujetos novatos, pocas sesiones de calibración y sin infraestructura de laboratorio.

Los objetivos son: (i) implementar un pipeline de adquisición y procesamiento completo con hardware accesible; (ii) comparar FBCSP y geometría Riemanniana bajo esquemas cross-subject y within-subject; (iii) cuantificar la contribución del Euclidean Alignment (EA) mediante un experimento de ablación; (iv) verificar la viabilidad para retroalimentación en tiempo real mediante medición de latencia.

2. TRABAJO RELACIONADO

Los métodos de clasificación para BCI de MI pueden agruparse en tres grandes familias según el tipo de representación de la señal y el paradigma de aprendizaje utilizado (Lotte et al., 2018). La Figura 1 recoge esta taxonomía y la Figura 2 ofrece una síntesis cualitativa orientativa de sus propiedades.

Métodos de filtrado espacial. Common Spatial Patterns (CSP) es la técnica de referencia desde el trabajo seminal de Ramoser et al. (2000): calcula filtros lineales que maximizan la varianza de una clase mientras minimizan la de la otra, permitiendo discriminar ensayos de MI con pocas épocas. Su principal limitación es la sensibilidad al ruido y la dependencia de una única banda de frecuencia. Filter Bank Common Spatial Patterns (FBCSP), propuesto por Ang et al. (2012), extiende CSP aplicándolo sobre múltiples subbandas espectrales y seleccionando automáticamente las más informativas mediante criterios de información mutua. Evaluado sobre los conjuntos BCI Competition IV 2a y 2b, FBCSP obtuvo valores de kappa de 0,569 y 0,600, respectivamente, consolidándose como uno de los métodos de referencia en la comunidad.

Métodos basados en geometría Riemanniana. Barachant et al. (2012) propusieron representar cada época EEG mediante su matriz de covarianza, perteneciente al espacio de matrices simétricas definidas positivas (SPD), que forma una variedad Riemanniana de estructura geométrica no euclídea. Operar sobre ella respetando su geometría mejora la robustez frente a ruido y variabilidad inter-sujeto respecto a los métodos euclídeos clásicos. Los clasificadores basados en Distancia Mínima a la Media Riemanniana (MDM) y la proyección al espacio tangente (TS) demostraron rendimiento comparable o superior a CSP+LDA con menor coste computacional. Congedo et al. (2017) destacaron su eficacia con conjuntos de datos pequeños, condición habitual en estudios con hardware consumer-grade. Un problema crítico en sistemas BCI independientes del sujeto es el *dominio shift* inter-sujeto: la distribución de covarianzas varía considerablemente entre personas. He y Wu (2020) propusieron Euclidean Alignment (EA) para corregirlo: normalizar cada sesión por la raíz cuadrada inversa de su covarianza media antes del entrenamiento, alineando los dominios sin requerir datos del sujeto de test. En su evaluación, el EA aportó mejoras de entre 3 y 8 puntos porcentuales en exactitud cross-subject.

Métodos de aprendizaje profundo. Schirrmeister et al. (2017) demostraron que redes neuronales convolucionales (ConvNets) pueden decodificar EEG crudo con rendimiento competitivo, aunque requieren grandes volúmenes de datos. Lawhern et al. (2018) propusieron EEGNet, una arquitectura compacta diseñada para EEG con buen rendimiento incluso con datos reducidos. Xiong et al. (2024) combinaron transformadas wavelet, generación de datos sintéticos mediante redes generativas adversariales de Wasserstein con penalización de gradiente (WGAN-GP) y clasificación CNN, obteniendo exactitudes de hasta el 89,1 % en datasets de MI. Pese a estos avances, los métodos de aprendizaje profundo presentan baja interpretabilidad y requieren infraestructura GPU, lo que limita su aplicabilidad en sistemas BCI de bajo coste.

Posicionamiento de este trabajo. La revisión de Lotte et al. (2018) concluye que no existe un método dominante. Este trabajo evalúa FBCSP y Riemannian TS+EA bajo condiciones realistas de bajo coste, escenario en el que la literatura aporta menos evidencia comparativa que en entornos de laboratorio controlado.




Figura 1. Taxonomía de los principales enfoques de clasificación EEG para imaginación motora. Los métodos marcados con ★ son los implementados en este trabajo.

Característica	Filtrado espacial (FBCSP)	Geometría Riemanniana (TS + EA)	Aprendizaje profundo (EEGNet, ConvNet)
Datos necesarios	~30-50 épocas	~30-50 épocas	>500 épocas
Generaliz. cross-subject	Media (sin adaptación de dominio)	Alta (con Euclidean Alignment)	Variable (requiere fine-tuning)
Latencia de inferencia	~3,5 ms	~1,7 ms	Alta (reducible con GPU)
Interpretabilidad	Alta (filtros espaciales)	Media (espacio de covarianzas)	Baja (caja negra)
Robustez al ruido	Media (sensible a artefactos)	Alta (geometría SPD estable)	Media-Alta (depende de arquitectura)
Coste computacional	Bajo	Bajo	Alto (GPU recomendada)
Idoneidad hardware consumer-grade	Buena	Muy buena	Limitada

Figura 2. Síntesis cualitativa orientativa de las propiedades de los principales enfoques para clasificación EEG-MI. Los valores de latencia corresponden a los medidos experimentalmente en este trabajo; el resto de propiedades son de carácter comparativo.

3. MÉTODO

3.1. Sistema de adquisición y participantes

Las señales EEG se registraron con OpenBCI Cyton+Daisy (16 canales, 125 Hz, ADC 24 bits, transmisión inalámbrica 2,4 GHz). Los datos se adquirieron mediante BrainFlow, que realiza automáticamente la conversión de cuentas ADC a microvoltios (μV) y los almacena en CSV con marcas temporales de alta precisión. El software de adquisición y presentación de estímulos fue implementado íntegramente en Python. Participaron 10 sujetos (s01–s010). En dos sujetos (s02 y s03) se adquirieron bloques de menor tamaño (20 ensayos por bloque) debido a incidencias durante la recogida de datos. Cada sujeto completó 3 sesiones en el mismo día, con descansos entre bloques según necesidad. Cada sesión constó de ~40 ensayos brutos (9 s/ensayo + 0,5–1,0 s de intervalo inter-ensayo), lo que supone ~6,5 minutos de ensayos activos y ~11–14 minutos incluyendo preparación y colocación del casco EEG. Tras el control de calidad automático, el número de épocas válidas osciló entre 17 y 103 (media: $71,2 \pm 32,1$; total: 712 épocas). Los 16 electrodos se distribuyeron según el sistema internacional 10–20, con énfasis en regiones sensorimotoras: C3/C4

(corteza motora primaria), FC3/FC4 y CP3/CP4 (áreas premotoras y parietales somatosensoriales), completados con cobertura frontal y parieto-occipital.

3.2. Paradigma experimental

Los participantes realizaron imaginación motora bilateral (mano izquierda/derecha) en respuesta a estímulos visuales implementados en *Pygame* (Shinners, 2011). Cada ensayo siguió una secuencia fija de 9 s: línea base (2 s, punto de fijación), *cue* visual (1 s, flecha izquierda o derecha), imaginación motora (4 s) y descanso (2 s). Un intervalo inter-ensayo aleatorio de 0,5–1,0 s separaba cada ensayo del siguiente. Se instruyó a los participantes a imaginar el movimiento de la mano indicada sin realizar movimiento físico alguno. Los *triggers* de eventos se registraron simultáneamente en el stream EEG y en un fichero de log independiente para verificación de sincronización. El desfase EEG–estímulo presentó una media < 5 ms y un $p99 < 24$ ms en todas las sesiones válidas. Los *triggers* generados por el sistema de estímulos se alinearon con el stream EEG de BrainFlow mediante un offset dinámico entre el tiempo de sistema y el timestamp de BrainFlow, permitiendo una sincronización precisa en el dominio temporal del EEG.

3.3. Preprocesamiento y control de calidad

El pipeline de preprocesamiento incluyó cuatro etapas: (i) detección y enmascarado a cero de canales defectuosos: ruidosos ($\text{std} > 5$ MAD [Median Absolute Deviation] de la mediana del conjunto de canales), planos (desviación típica anómalamente baja), o saturados (> 5 % de muestras en valor extremo del rango ADC); (ii) referencia promedio común (CAR) sobre los canales válidos; (iii) filtro notch a 49,8 Hz para eliminación de interferencia de red eléctrica; (iv) resampling a 125 Hz exactos mediante interpolación polyphase.

El control de calidad por sesión empleó umbrales adaptativos basados en los percentiles de la propia sesión, con límites superiores fijos (Tabla 1). El umbral de desfase EEG–estímulo se fijó en $p99 < 20$ ms para el esquema cross-subject y en $p99 < 25$ ms para el esquema within-subject, siendo este último ligeramente más permisivo para compensar la mayor escasez de datos por sujeto. Esta diferencia explica que el sujeto s02, con una única sesión válida bajo el criterio cross-subject, disponga de dos sesiones válidas bajo el criterio within-subject y pueda por tanto incluirse en ese análisis. La tasa media de rechazo de épocas fue del $14,3 \pm 11,8$ % (FBCSP) y del $16,1 \pm 12,4$ % (Riemannian).

3.4. Extracción de características

FBCSP (Ang et al., 2012). Aplica CSP (Ramoser et al., 2000) sobre 4 subbandas espectrales (8–12, 13–18, 18–26, 26–35 Hz), calculando 6 componentes por banda (24 características totales). La covarianza se estimó con el estimador de Ledoit-Wolf para mayor estabilidad con muestras pequeñas. Las 8 características más informativas se seleccionaron por información mutua y se normalizaron por z-score robusto (mediana/IQR) por sesión para reducir el sesgo de offset DC inter-sesión.

Geometría Riemanniana (Barachant et al., 2012). Cada época EEG se representa por su matriz de covarianza en el espacio SPD. En el esquema cross-subject se aplicó Euclidean Alignment (He y Wu, 2020): cada sesión se normaliza como $\tilde{C} = R^{-1/2} C R^{-1/2}$, donde R es la covarianza media de la sesión y

$R^{-1/2}$ denota su raíz cuadrada matricial inversa, corrigiendo el sesgo de dominio inter-sujeto sin necesidad de datos del sujeto de test. Las covarianzas alineadas se proyectan al espacio tangente usando la métrica Bures–Wasserstein, obteniéndose 136 características por época. En el esquema within-subject se desactivó el EA: con un número reducido de sesiones por sujeto, la variabilidad intra-sujeto es insuficiente para que el alineamiento resulte beneficioso, como confirma el experimento de ablación descrito en la sección 4.2.

Tabla 1. Parámetros del pipeline de preprocesamiento y control de calidad por método.

Parámetro	FBCSP	Riemannian TS
Ventana de análisis	0,5–2,65 s post-cue (269 muestras)	0,65–2,65 s post-cue (250 muestras)
Filtrado espectral	4 subbandas: 8–12, 13–18, 18–26, 26–35 Hz	8–28 Hz (banda única, Butterworth ord. 3)
Corrección de línea base	Sí (–0,5 a 0 s)	No
Umbral pico artefacto	150 μ V adaptativo (cap 300 μ V)	300 μ V adaptativo (cap 400 μ V)
Umbral varianza artefacto	2000 μ V ² adaptativo	3000 μ V ² adaptativo
Tasa máx. de rechazo	50 %	40 %
Euclidean Alignment	No aplicable	Cross-subj: activo; Within-subj: inactivo

3.5. Clasificadores y protocolo de evaluación

Para FBCSP, el clasificador se seleccionó por búsqueda en rejilla (LDA, Regresión Logística, SVM lineal y SVM RBF) con validación cruzada interna de 3 particiones sobre los datos de entrenamiento del fold externo, evitando filtración de información al conjunto de test. Para Riemannian, se empleó Regresión Logística con regularización L2 (C optimizado por búsqueda en rejilla). Se definieron dos esquemas LOSO complementarios:

- Cross-subject: en cada fold, un sujeto completo queda reservado para test y el modelo se entrena con los N–1 sujetos restantes (FBCSP: N=10; Riemannian: N=9, excluido s02). Evalúa la generalización a un usuario nuevo sin calibración previa.
- Within-subject: para cada sujeto con ≥ 2 sesiones válidas bajo el criterio within-subject, una sesión queda para test y el modelo se entrena con las sesiones restantes del mismo sujeto. Evalúa la personalización con datos del propio usuario.

La métrica principal es la exactitud balanceada (media aritmética del recall por clase), estándar en evaluación BCI por su insensibilidad al desbalance de clases (Lotte et al., 2018). Se reportan además el recall por clase (izquierda y derecha) para el esquema cross-subject Riemannian. La significación estadística se evaluó con t-test de una muestra contra 0,500 (nivel de azar) y prueba de permutación con 10.000 permutaciones. El tamaño del efecto se calculó con la d de Cohen (1988).

4. RESULTADOS

4.1. Exactitud balanceada por sujeto y método

La Tabla 2 recoge los resultados completos por sujeto. En el esquema cross-subject, el método Riemannian ($0,647 \pm 0,086$, $N=9$) supera al FBCSP ($0,569 \pm 0,081$, $N=10$) en +7,8 puntos porcentuales. De forma agregada, se obtuvieron 474 de 836 clasificaciones correctas para FBCSP (recall izq. 0,569, recall der. 0,565) y 438 de 695 para Riemannian (recall izq. 0,640, recall der. 0,620). Destacan dos perfiles bien diferenciados: s06 es el único sujeto con respuesta robusta ($>0,75$ en todos los métodos y esquemas), mientras que los sujetos s01, s02 y s04 presentan exactitudes sistemáticamente próximas al nivel de azar, compatible con un perfil de baja respuesta BCI descrito en la literatura (Lotte et al., 2013). El caso s03 ($0,685$ en FBCSP cross-subject pero $0,448$ en FBCSP within-subject) ilustra el patrón de mayor variabilidad inter-sesión intra-sujeto que inter-sujeto característico de participantes novatos. La Figura 3 muestra la distribución completa de resultados.

Tabla 2. Exactitud balanceada por sujeto y método. † s02 excluido de Riemannian cross-subject por criterio de control de calidad (QC) estricto (desfase EEG–estímulo $p99 < 20$ ms), pero incluido en within-subject bajo criterio permisivo (desfase $p99 < 25$ ms). ‡ s09 excluido de Riemannian within-subject (solo 1 sesión válida).

Sujeto	N épocas	FBCSP Cross	Riemann Cross	FBCSP Within	Riemann Within	Recall Izq. (Riemann)	Recall Der. (Riemann)
s01	99	0,480	0,557	0,461	0,495	0,519	0,596
s02 †	17	0,458	N/A	0,470	0,492	—	—
s03	49	0,685	0,651	0,448	0,554	0,692	0,609
s04	103	0,480	0,518	0,440	0,541	0,620	0,415
s05	60	0,600	0,733	0,586	0,531	0,742	0,724
s06	70	0,632	0,757	0,880	0,850	0,763	0,750
s07	84	0,664	0,732	0,685	0,682	0,681	0,784
s08	101	0,569	0,644	0,489	0,476	0,680	0,608
s09 ‡	27	0,519	0,668	0,482	N/A	0,643	0,692
s010	102	0,604	0,560	0,524	0,485	0,528	0,592
Media $\pm$ SD	—	$0,569 \pm 0,081$	$0,647 \pm 0,086$	$0,546 \pm 0,139$	$0,567 \pm 0,123$	0,652	0,641




Figura 3. Exactitud balanceada por sujeto y método. La línea discontinua roja marca el nivel de azar (0,500). Las barras ausentes (N/A) corresponden a sujetos excluidos del análisis específico.

4.2. Significación estadística y ablación del EA

Ambos métodos superan el nivel de azar de forma estadísticamente significativa en el esquema cross-subject con tamaño del efecto grande (Tabla 3). La prueba de permutación confirmó los resultados del t-test en ambos casos. El experimento de ablación aísla la contribución del EA: sin alineamiento, el Riemannian cross-subject obtiene $0,595 \pm 0,086$, frente a $0,647 \pm 0,086$ con EA activo (+5,3 pp, la diferencia se calcula sobre las medias no redondeadas). En el esquema within-subject se compararon ambas condiciones numéricamente: EA activo produce $0,572 \pm 0,135$ y EA inactivo $0,567 \pm 0,123$, diferencia no significativa que valida la decisión de desactivarlo en ese esquema. La Figura 4 visualiza los cinco escenarios del experimento de ablación cross-subject y los esquemas within-subject con EA inactivo.

Tabla 3. Tests estadísticos sobre la exactitud balanceada cross-subject y experimento de ablación del EA. * $p < 0,05$; ** $p < 0,01$.

Método / Condición	Bal. acc. media	p (t-test)	p (permutación)	d de Cohen
FBCSP cross-subject (N=10)	$0,569 \pm 0,081$	0,025 *	0,033 *	0,851
Riemannian cross-subject (N=9)	$0,647 \pm 0,086$	<0,001 **	0,005 **	1,701
Riemannian sin EA (ablación, N=9)	$0,595 \pm 0,086$	0,038 *	0,045 *	0,921
FBCSP within-subject (N=10)	$0,546 \pm 0,139$	0,187	—	—
Riemannian within-subject (N=9)	$0,567 \pm 0,123$	0,130	—	—




Figura 4. Exactitud balanceada media ($\pm$ SD) por método. Los asteriscos indican significación estadística respecto al nivel de azar (* $p < 0,05$; ** $p < 0,01$). La flecha muestra la ganancia atribuible al Euclidean Alignment (+5,3 pp). Las dos barras de la derecha corresponden a los esquemas within-subject con EA inactivo.

4.3. Latencia de inferencia

Las latencias del pipeline de inferencia, medidas sobre 200 repeticiones con época sintética de dimensiones reales, fueron: FBCSP, media 3,52 ms, p95 6,01 ms, p99 6,53 ms; Riemannian TS, media 1,74 ms, p95 2,60 ms, p99 4,55 ms. Ambos métodos están muy por debajo del umbral de 500 ms habitualmente establecido para retroalimentación en tiempo real en sistemas BCI (Shenoy et al., 2006). El método Riemannian resulta más rápido al no requerir filtrado multi-banda durante la inferencia. El cuello de botella temporal real en un sistema online es la ventana de análisis (~ 2 s), no el procesamiento computacional.

5. DISCUSIÓN

Rendimiento general y comparativa de métodos. Los resultados obtenidos son consistentes con los valores reportados para BCI con hardware consumer-grade y sujetos novatos, situados típicamente en el rango 0,55–0,65 con alta variabilidad inter-sujeto (Lotte et al., 2018). La superioridad del método Riemannian (+7,8 pp) se explica por dos factores: (i) las representaciones de covarianza en el espacio SPD capturan la estructura espacial del EEG de forma más completa que las características log-varianza del FBCSP con pocos datos de entrenamiento; (ii) el EA aporta +5,3 pp corrigiendo el sesgo de dominio inter-sujeto, explicando aproximadamente el 68 % de la diferencia observada.

Cross-subject vs. within-subject. Un hallazgo metodológicamente relevante es que el esquema *cross-subject* supera al *within-subject* en la mayoría de sujetos para ambos métodos (medias cross: 0,569 y 0,647 vs. within: 0,546 y 0,567). La explicación reside en la alta variabilidad inter-sesión de sujetos novatos con hardware consumer-grade: con solo 2 sesiones (~ 60 – 65 épocas) de calibración, el modelo within-subject ve una muestra insuficiente de la variabilidad individual; el modelo cross-subject, entrenado con 8–9 sujetos distintos, generaliza mejor. El caso s03 (0,685 en FBCSP cross-subject pero 0,448 en within-subject) es el ejemplo más claro de este efecto. Para usuarios novatos

sin historial de calibración, un modelo cross-subject pre-entrenado puede ser más útil que uno personalizado con pocas sesiones. Las técnicas de transfer learning y adaptación online (He y Wu, 2020) son la vía prioritaria para mejorar el rendimiento within-subject en trabajo futuro.

Variabilidad inter-sujeto. La variabilidad inter-sujeto es el factor limitante dominante (rango 0,458–0,685 para FBCSP; 0,518–0,757 para Riemannian). S06 es el único sujeto con respuesta robusta y consistente. Los sujetos con exactitudes próximas al azar presentan un patrón compatible con el perfil de baja respuesta BCI descrito en la literatura (Lotte et al., 2013), si bien con el tamaño muestral disponible no es posible atribuirlo con certeza a características del sujeto frente a factores de calidad de señal. El entrenamiento del usuario y el neurofeedback continuo son estrategias documentadas para mejorar el rendimiento individual.

Limitaciones. El tamaño muestral (N=10) es moderado y la ausencia de datos demográficos formales impide analizar la influencia de variables como la edad o lateralidad. La evaluación es completamente offline; la retroalimentación visual en tiempo real podría modificar el rendimiento por efecto neurofeedback. Los resultados son específicos para el hardware OpenBCI Cyton+Daisy (electrodos secos, 125 Hz) y podrían diferir con otros dispositivos consumer-grade.

6. CONCLUSIONES

Este trabajo ha presentado el desarrollo y evaluación de un sistema BCI completo para imaginación motora bilateral con hardware consumer-grade (OpenBCI Cyton+Daisy, 16 canales, 125 Hz) e implementación íntegra en Python. Las principales conclusiones son:

- Ambos métodos superan el nivel de azar con significación estadística en el esquema cross-subject y tamaño del efecto grande (FBCSP: $d=0,85$; Riemannian: $d=1,70$), validando el hardware OpenBCI Cyton+Daisy para decodificación de MI.
- El método Riemannian supera al FBCSP en +7,8 pp cross-subject, con el Euclidean Alignment como componente más crítico, explicando aproximadamente el 68 % de la diferencia observada (+5,3 pp según el experimento de ablación).
- El esquema cross-subject supera al within-subject en la mayoría de sujetos, resultado atribuible a la alta variabilidad inter-sesión de usuarios novatos con pocas épocas de calibración.
- Las latencias de inferencia ($p99 < 7$ ms) confirman la viabilidad para retroalimentación en tiempo real, siendo el cuello de botella la ventana de análisis y no el procesamiento computacional.

Como trabajo futuro se identifican: (i) implementación de transfer learning y adaptación online para mejorar el rendimiento within-subject; (ii) evaluación con mayor número de sujetos para caracterizar la prevalencia de baja respuesta BCI con hardware consumer-grade; (iii) desarrollo de retroalimentación visual en tiempo real para evaluar el efecto neurofeedback.

7. REFERENCIAS

Ang, K. K., Chin, Z. Y., Zhang, H., y Guan, C. (2012). Filter Bank Common Spatial Pattern algorithm on BCI Competition IV datasets 2a and 2b. *Frontiers in Neuroscience*, 6, 39. <https://doi.org/10.3389/fnins.2012.00039>

- Barachant, A., Bonnet, S., Congedo, M., y Jutten, C. (2012). Multiclass brain-computer interface classification by Riemannian geometry. *IEEE Transactions on Biomedical Engineering*, 59(4), 920–928. <https://doi.org/10.1109/TBME.2011.2172210>
- Clerc, M., Bougrain, L., y Lotte, F. (Eds.). (2016). *Brain-Computer Interfaces: Foundations and Methods*. Wiley.
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2.^a ed.). Lawrence Erlbaum Associates.
- Congedo, M., Barachant, A., y Andreev, A. (2017). A primer on Riemannian geometry for EEG-based brain-computer interfaces. *Brain-Computer Interfaces*, 4(3), 162–174. <https://doi.org/10.1080/2326263X.2017.1297192>
- He, H., y Wu, D. (2020). Transfer learning for brain-computer interfaces: a Euclidean space data alignment approach. *IEEE Transactions on Biomedical Engineering*, 67(2), 399–410. <https://doi.org/10.1109/TBME.2019.2913914>
- Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., y Lance, B. J. (2018). EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 15(5), 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- Lotte, F., Larrue, F., y Mühl, C. (2013). Flaws in current human training protocols for spontaneous brain-computer interfaces: lessons learned from instructional design. *Frontiers in Human Neuroscience*, 7, 568. <https://doi.org/10.3389/fnhum.2013.00568>
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., y Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: a 10+year update. *Journal of Neural Engineering*, 15(3), 031005. <https://doi.org/10.1088/1741-2552/aab2f2>
- Ramoser, H., Müller-Gerking, J., y Pfurtscheller, G. (2000). Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Transactions on Rehabilitation Engineering*, 8(4), 441–446. <https://doi.org/10.1109/86.895946>
- Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W., y Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11), 5391–5420. <https://doi.org/10.1002/hbm.23730>
- Shenoy, P., Krauledat, M., Blankertz, B., Rao, R. P. N., y Müller, K.-R. (2006). Towards adaptive classification for BCI. *Journal of Neural Engineering*, 3(1), R13–R23. <https://doi.org/10.1088/1741-2560/3/1/R02>
- Shinners, P., y Pygame Community. (2011). *Pygame* (versión 2.x) [Software]. Recuperado de <https://www.pygame.org>
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., y Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767–791. [https://doi.org/10.1016/S1388-2457\(02\)00057-3](https://doi.org/10.1016/S1388-2457(02)00057-3)
- Xiong, H., Wang, M., y Xiao, M. (2024). Wasserstein generative adversarial network with gradient penalty and convolutional neural network based motor imagery EEG classification. *Journal of Neural Engineering*, 21, 016032. <https://doi.org/10.1088/1741-2552/ad6cf5>