



2019 10 al 13 de septiembre - Cartagena de Indias, Colombia

RETOS EN LA FORMACIÓN
DE INGENIEROS EN LA
ERA DIGITAL



ANÁLISIS DE BIOSEÑALES PARA LA DECODIFICACIÓN DE INTENCIÓN DE MOVIMIENTO ORIENTADO A LA REHABILITACIÓN DE PACIENTES CON LESIÓN DE MÉDULA ESPINAL

Carlos Ferrin-Bolaños, Humberto Loaiza-Correa

**Universidad del Valle
Cali, Colombia**

Resumen

Las estadísticas de incidencia y prevalencia de las lesiones de médula espinal (LME) a nivel mundial son preocupantes según la Organización Mundial de la Salud. En Colombia no se tienen cifras concretas, pero se estima que este tipo de lesiones se debe principalmente a la violencia y los accidentes de tránsito. Las LME producen diferentes niveles de discapacidad y un alto número de ellas ocasionan parálisis parcial o total de miembros inferiores y superiores. Entre los protocolos para el tratamiento de las LME que afectan los miembros superiores se encuentra las terapias de rehabilitación funcional motora que involucran dispositivos de asistencia tecnológica. Recientemente se han reportado casos de mejoras en la movilidad de miembros de pacientes después de largas sesiones terapéuticas con dispositivos de asistencia tecnológica comandados con interfaces basadas en bioseñales. Sin embargo, el uso de estos dispositivos de asistencia tecnológica en las actividades de rehabilitación ha sido limitado debido a que carecen de interfaces que permitan la interacción dispositivo-paciente a través de comandos confiables y naturales; por ejemplo, una órtesis robótica para apoyar los ejercicios de alcance y agarre de objetos con las manos del paciente. Aunque en los últimos años se han realizado importantes avances en el comando de dispositivos de asistencia mediante interfaces cerebro computador (BCI), la variabilidad del desempeño diario obtenido con estas interfaces han alejado a los pacientes de una experiencia de comando natural y exitosa, haciendo que se pierda el interés por usarlas, inclusive durante las sesiones terapéuticas. Aun cuando son varios los frentes que se deben abordar para contribuir en el avance de las interfaces cerebro computador, la decodificación de la intención de movimiento a partir de bioseñales y la generación de comandos naturales en dispositivos de asistencia de miembros superiores para pacientes con LME a nivel cervical en procesos de rehabilitación, siguen siendo los frentes más investigados a nivel internacional. Por lo anterior, en

este trabajo se describen y comparan estrategias modernas para decodificación de intención de movimiento a partir de señales electroencefalográficas superficiales adquiridas mediante dispositivos de bajo costo bajo un paradigma de imaginación motora.

Palabras clave: bioseñales; dispositivos de asistencia tecnológica; interfaces cerebro computador; imaginación motora; lesión medular; rehabilitación

Abstract

Incidence and prevalence statistics of spinal cord injuries (SCI) worldwide are worrisome according to the World Health Organization. In Colombia there are no concrete statistics, nonetheless, some studies establishes that this type of injuries is mainly due to violence and traffic accidents. SCIs produce different levels of disability and a high number of them cause partial or total paralysis of lower and upper limbs. Among the protocols for the treatment of SCI that affect the upper limbs is the functional motor rehabilitation therapy that involve assistive technology devices. Recently, there have been reports of improvements in the mobility of patients after long therapeutic sessions with technological assistive devices commanded by biosignals-based interfaces. However, the use of these assistive technology devices in rehabilitation activities has been limited because they lack of reliable and natural commands through, for instance, a robotic orthosis to support reaching and grasping objects with the patient's hands. Although in recent years important advances have been made in the command of assistive devices through brain computer interfaces (BCI), the variability of the daily performance obtained with these interfaces has distanced patients from a natural and successful command experience, in consequence loss of interest, even during the therapeutic sessions. Although there are several fronts that must be addressed to contribute to the advancement of the brain computer interfaces, the decoding of the movement intention from biosignals and the generation of natural commands in upper limb assist devices for patients with SCI a cervical level in rehabilitation processes, are still the most researched fronts at international level. Therefore, this paper describes and compares modern strategies for decoding movement intention from superficial electroencephalographic signals acquired through low-cost devices under a paradigm of motor imagination.

Keywords: biosignals; assistive device technology; brain-computer interface; motor imagery; spinal cord injury; rehabilitation

1. Introducción

En los últimos años, un tipo particular de tecnologías de asistencia (Rupp et al., 2014) basadas en señales del cerebro llamadas interfaces cerebro-computador, BCI (por sus siglas en inglés: *Brain-Computer Interface*) (Dornhege, Millán, Hinterberger, McFarland, & Müller, 2007; Shih, Krusienski, & Wolpaw, 2012), que permiten comandar dispositivos externos como exomanos, computadores o sillas de ruedas, ha llamado la atención de expertos en rehabilitación de pacientes con limitaciones motrices, ya que su uso por parte del paciente puede complementar las sesiones terapéuticas e incluso, en algunos casos, motivar la realización de las mismas en los pacientes que

han perdido el interés. Más aun, recientemente, el uso de esta tecnología por pacientes con paraplejia ha demostrado sus beneficios clínicos en procesos de rehabilitación permitiendo pasar de una lesión completa (pérdida total de las funciones sensitivas y motoras por debajo de la lesión) a incompleta (pérdida parcial de las funciones sensitivas y motoras por debajo de la lesión) (Rupp et al., 2014). Esto ha motivado la investigación y desarrollo en este tipo de tecnologías para rehabilitación de miembros superiores en pacientes con lesiones cervicales.

La interfaz cerebro-computador no invasiva electroencefalográfica, EEG, basada en imaginación motora, miBCI (del inglés: **m**otor **i**magery **B**rain **C**omputer-**I**nterface), es considerada una de las más apropiadas para rehabilitación motriz de miembros superiores (Alonso-Valerdi, Salido-Ruiz, & Ramirez-Mendoza, 2015), no solo en pacientes con lesiones medulares sino también en pacientes con déficit motores debido a otras causas, como por ejemplo en pacientes con accidente cerebro vascular (Peckham et al., 2001). Esto se debe a que de acuerdo con (Mateo et al., 2015), con ayuda de la imaginación motora, es posible no solo incrementar las capacidades de agarre y la fortaleza muscular, sino también disminuir el tiempo de realización del movimiento, mejorar la variabilidad en la ejecución de la trayectoria del mismo, y corregir anomalías en los patrones de actividad cerebral, incrementados en algunos casos después de la lesión medular (Grangeon, Revol, Guillot, Rode, & Collet, 2012).

Las miBCI generalmente constan de dos fases (Barachant, Bonnet, Congedo, & Jutten, 2013; Castillo, 2015; Vidaurre, Klauer, Schauer, Ramos-Murguialday, & Muller, 2016). Primero, una fase de calibración o entrenamiento, en la que se recogen segmentos (épocas) de las señales EEG (preferiblemente a nivel superficial) asociadas a dos o más intenciones motoras imaginadas, las cuales permiten entrenar un modelo de clasificación de señales EEG. Después, una fase de retroalimentación, en la que se utiliza el modelo entrenado para clasificar intenciones motoras con base en el protocolo de entrenamiento propuesto en la fase de calibración, ver Figura 1 – (izquierda). Para la construcción de estos modelos de clasificación se hace uso principalmente de técnicas de procesamiento digital de señales (Proakis & Manolakis, 1996) y de reconocimiento de patrones (C. Bishop, 2007; C. M. Bishop, 1995) que permiten el tratamiento adecuado de la no estacionariedad y la baja relación señal ruido de las señales EEG superficiales y la efectiva discriminación de diferentes tareas mentales, respectivamente. En los últimos años, dos técnicas que explotan la información de covarianza de las señales EEG han demostrado una destacable capacidad discriminante en un sinnúmero de retos internacionales sobre bancos de datos disponibles por parte de la comunidad científica para fines de comparación (Barachant, Bonnet, Congedo, & Jutten, 2012; Blankertz, Tomioka, Lemm, Kawanabe, & Muller, 2008; Lotte & Cuntai Guan, 2011; Mingxu, 2014; Tangermann et al., 2012). Las primeras utilizan la información de covarianza para la construcción de filtros supervisados espaciales, denominadas Patrones Comunes Espaciales, CSP (Common Spatial Pattern), (Blankertz et al., 2008; Ge, Wang, & Yu, 2014; Lotte & Cuntai Guan, 2011), junto con técnicas de clasificación clásicas como el análisis discriminante cuadrático/líneal (LDA/QDA) (Hastie, Tibshirani, & Friedman, 2017) o máquinas de vectores de soporte (SVM) (C. M. Bishop, 1995; Haykin, 2009). En la otra técnica, la información de covarianza es tratada como patrón característico de la señal EEG y su tratamiento se realiza en una variedad de Riemann (Alexandre, 2006; Barachant, Bonnet, Congedo, & Jutten, 2010; Barachant et al., 2012, 2013; Congedo, Barachant, & Andreev, 2013; Yger, Berar, & Lotte, 2016). A pesar de los resultados sobresalientes de estos dos tipos de técnicas en los retos

internacionales, en su mayoría con sujetos de control sin ningún de tipo de lesión medular o daño cerebral, este tipo de técnicas ha sido poco evaluado utilizando dispositivos de bajo costo para EEG superficial como el Emotiv EPOC (Holewa & Nawrocka, 2014) en pacientes con lesiones medulares a nivel cervical. En (Martinez-Leon, Cano-Izquierdo, & Ibarrola, 2016) se ha mostrado que el Emotiv EPOC es un dispositivo habilitado para el desarrollo no solo de miBCI sino también de BCI relacionada a otro tipo de eventos como los auditivos (Badcock et al., 2015), con capacidades similares a las de equipos costosos para la adquisición de EEG superficial para investigación avanzada. En este estudio se plantea que el desempeño obtenido con las BCI utilizando información de covarianza de las señales EEG utilizando el Emotiv EPOC y la información de covarianza de las señales EEG estará por encima del nivel de azar en la decodificación de intención de movimiento de miembros superiores en pacientes con lesiones cervicales en un paradigma de imaginación motora.

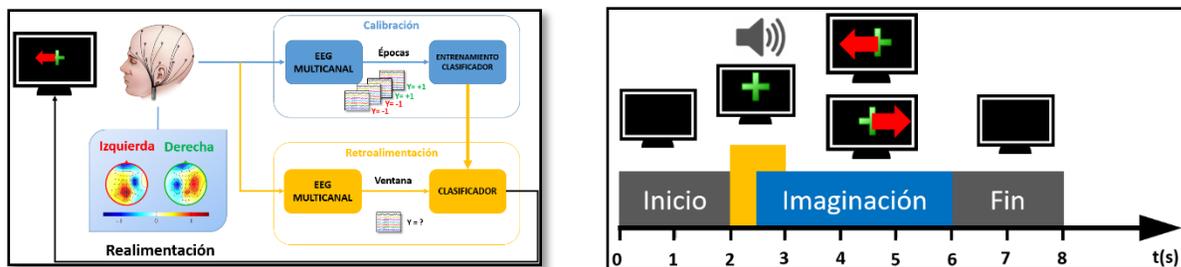


Figura 1. Visión general de un sistema miBCI utilizando técnicas procesamiento de señales y reconocimiento de patrones (Blankertz et al., 2008), (Izquierda). Esquema de tiempo para imaginación motora. El segmento en azul corresponde al periodo de tiempo en el que se extrae una época de señal EEG asociado con el tipo de movimiento que debe realizarse con base en la dirección de las flechas (derecha).

2. Métodos

En este estudio se adquirieron segmentos (épocas) de señales EEG asociadas a imaginación de mano cerrada e imaginación de mano abierta de 5 sujetos con edades entre 22 y 56 años: dos con lesión cervical (S1 y S2) y tres sin ningún tipo de lesión (S3, S4, y S5). De acuerdo con los especialistas médicos, ninguno de los sujetos de prueba presentó limitaciones cognitivas ni daño cerebral que impidiera la participación de los sujetos de experimentación. Asimismo, los sujetos dieron consentimiento informado respecto a las pruebas realizadas y los datos adquiridos. Cada sujeto se ubicó frente a una pantalla de 55 pulgadas a 1.5 m de distancia. En la pantalla se desplegaron en forma aleatoria flechas orientadas hacia la derecha (indicando imaginación de mano cerrada) y hacia la izquierda (indicando imaginación de mano abierta). En el caso de los sujetos con lesiones cervicales, se utilizó la silla de rueda propia de cada sujeto. Para la captura de las señales EEG se usó el Emotiv EPOC el cual consta de 14 canales (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) con frecuencia de muestreo de 128 Hz. Por cada sujeto se realizaron 20 sesiones y durante cada sesión se ejecutaron 10 ensayos. Cada ensayo tuvo una duración de 8 segundos y solo se desplegó una de las flechas a la vez. El esquema de eventos durante cada ensayo se puede observar en la Figura 1 – (derecha). Las épocas de las señales EEG para la imaginación de mano cerrada o abierta se extrajeron desde los 2 s hasta los 6 s. En cada sesión se siguió un protocolo de asepsia que consistió en limpiar el cuero cabelludo de los sujetos de experimentación con agua destilada y se aseguró que los canales del Emotiv EPOC presentaran

alta calidad de contacto con ayuda del Software Emotiv Test Bench v.15.0.3. Las épocas de las señales EEG extraídas se procesaron mediante un filtro Butterworth de 5° orden pasa banda con frecuencias de corte de 8 – 30 Hz con el fin de filtrar de forma plana las componentes sensorimotoras asociadas a la imaginación de mano cerrada y abierta (Lu, McFarland, & Wolpaw, 2013).

Se conciben dos tipos de interfaces cerebro computador que aprovechan la información de covarianza entre los canales de las épocas EEG. El primero de ellos utiliza esta información para la construcción de filtros espaciales óptimos que mejoran la relación señal ruido, ver Figura 2 – (izquierda), y el otro tipo de técnicas utiliza esta misma información como una nueva representación de las épocas de señales EEG la cual puede ser manipulada sobre una variedad Riemanniana para la construcción de filtros y clasificadores, ver Figura 2 – (derecha). Los nombres de las arquitecturas basadas en filtros espaciales empiezan con CSP y las basadas en geometría de Riemann con RM. GF, significa filtrado geodésico (Barachant et al., 2012), y TS proyección en el espacio tangente (Yger et al., 2016). LDA y QDA son análisis discriminante lineal y cuadrático respectivamente. SVM Lineal y Rbf son máquinas de vectores de soporte con kernel lineal y kernel gaussiano respectivamente.

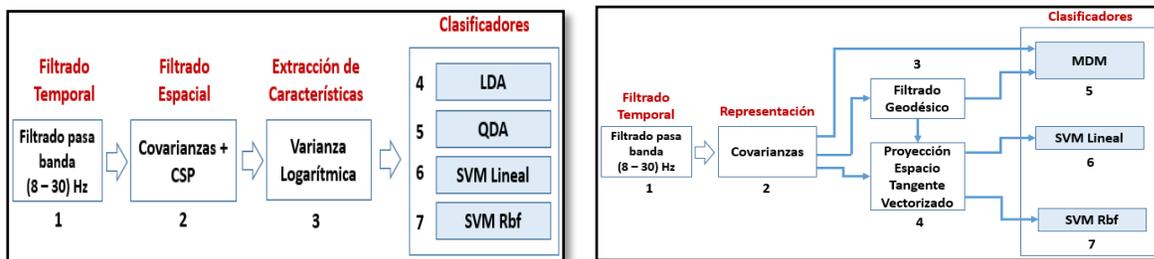


Figura 2. Cuatro arquitecturas de BCI basadas en CSP: CSP+LDA (1-2-3-4), CSP+QDA (1-2-3-5), CSP+SVM Lineal (1-2-3-6) y CSP+SVM Rbf (1-2-3-7) (izquierda). Seis arquitecturas de miBCI basadas en Geometría de Riemann: RM+MDM (1-2-5), RM+GF+MDM (1-2-3-5), RM+TS+SVM Lineal (1-2-4-6), RM+TS+SVM Rbf (1-2-4-7), RM+GF+TS+SVM Lineal (1-2-3-4-6), RM+GF+TS+SVM Rbf (1-2-3-4-7) (derecha).

3. Pruebas y Resultados

Para evaluar las miBCI basadas en CSP y las basadas en Geometría de Riemann, se valida que los promedios de precisión (clasificación correcta) general (incluyendo todos los sujetos) estén por encima del nivel de azar. Después se evalúa el área bajo la curva ROC de cada uno de los clasificadores para cada uno de los sujetos. Este permitirá, de los clasificadores sobre el banco de datos obtenidos para cada uno de los sujetos experimentales en un esquema de validación cruzada estratificada con 10 divisiones (Fushiki, 2011). El banco de datos consta de 200 épocas de EEG de las cuales 100 están asociadas a imaginación de mano cerrada (flecha derecha) y las otras 100 a mano abierta (flecha izquierda), lo que significa que para los 5 sujetos el total de ensayos es de 1000.

Las precisiones de las diferentes arquitecturas sobre todos los ensayos se promediaron a lo largo de las diferentes divisiones del dataset (10 divisiones). Para probar si este desempeño estuvo significativamente por encima del desempeño de un clasificador que asociara cualquier clase a las

épocas (Combrisson & Jerbi, 2015), se estima el nivel de azar (*chance-level*, en inglés) como el intervalo de confianza del 0.95 de la inversa de la distribución binomial en función del número de muestras disponibles (1000) y la probabilidad de las clases (0.5), lo que lleva a un valor de 0.53. En la Figura 3 – (izquierda) se observa que todos estos valores están por encima del nivel de azar estimado para este caso. Nótese que la arquitectura RM+TS+SVM Lineal presenta la mejor precisión promedio entre todas las arquitecturas.

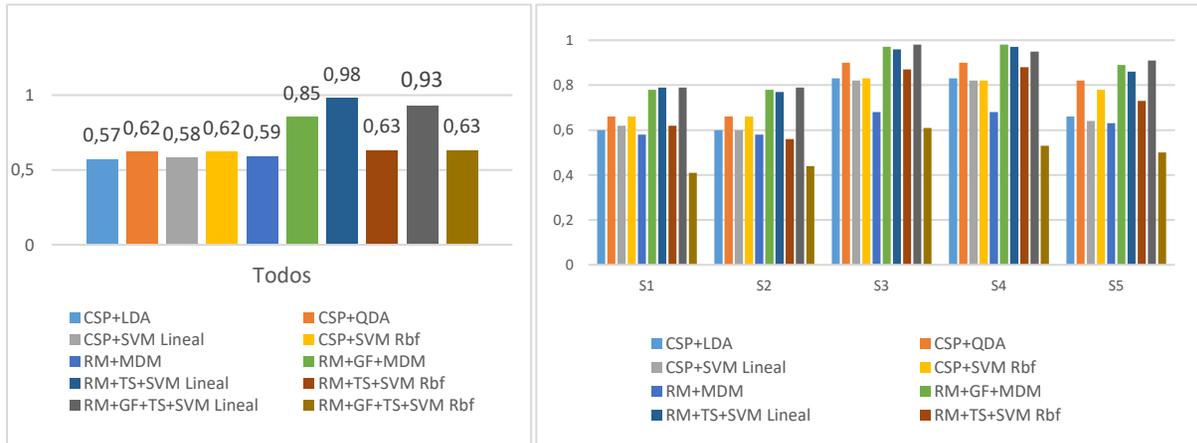


Figura 3. Precisión general de las arquitecturas miBCI sobre todas las épocas de los sujetos (izquierda) y AUC para cada una de las diez miBCI por sujeto (derecha).

Para determinar cuál o cuáles fueron las mejores miBCI por sujeto, se comparó el desempeño de cada una de estas utilizando el área bajo la curva ROC, AUC (Fawcett, 2006). Ver Figura 3 – (derecha). En primer lugar, se observa de estos resultados que las miBCI basadas en geometría de Riemann presentan mejor desempeño que las basadas en CSP. Esto es independiente del sujeto; específicamente, las siguientes miBCI: RM+GF+MDM, RM+TS+SVM Lineal y la RM+GF+TS+SVM Lineal fueron las de mejor desempeño en todos los casos. Nótese además que las únicas arquitecturas basadas en geometría de Riemann que presentan desempeño inferiores incluso por debajo que las basadas en CSP son las que utilizan SVM de kernel gaussiano como clasificador.

Se observa que mientras las miBCI en los sujetos con lesiones cervicales (S1 y S2) presentan un desempeño regular, en los sujetos de control se logran miBCI con desempeños buenos (S5: 0.91 – miBCI: RM+GF+TS+SVM Lineal) y muy buenos (S3, S4: 0.98 - miBCI: RM+GF+TS+SVM Lineal, RM+GF+MDM). El bajo desempeño de las arquitecturas propuesta con respecto a los sujetos de control puede deberse a la reorganización de la actividad cortical sensoriomotora (Moxon, Oliviero, Aguilar, & Foffani, 2014) que tiene lugar en los pacientes que han sufrido lesiones en el sistema nervioso central como es el caso de los pacientes con lesiones cervicales, lo que indicaría que es necesario una reubicación de los electrodos sobre el cuero cabelludo de los sujetos con lesiones medulares para obtener bioseñales más discriminantes. Es posible que una sintonización de los hiperparámetros (los cuales se dejaron fijo para este estudio) mejore el desempeño particular las miBCI de Riemann que utilizan SVM de kernel gaussiano.

4. Conclusiones

Se diseñaron e implementaron diez miBCI utilizando información de covarianza de las señales EEG adquiridas con un Emotiv EPOC y asociadas a imaginación de mano cerrada y abierta en tres sujetos de control y dos sujetos con lesiones medulares cervicales. Todas las miBCI tuvieron porcentajes de precisión por encima del nivel de azar. Sin embargo, para ambos tipos de sujetos, las miBCI basadas en geometría de Riemann (a excepción de las que utilizan SVM de kernel gaussiano) mostraron mejor desempeño que las miBCI basadas en CSP. En las arquitecturas basadas en geometría de Riemann de mejor desempeño, los sujetos de control presentan mejores resultados que los sujetos con lesiones medulares. Se espera, a futuro, que la sintonización de los hiperparámetros de las arquitecturas propuestas en los sujetos con lesiones medulares mejore el desempeño de las miBCI basadas en geometría de Riemann. También debe evaluarse la capacidad de generalización de estas miBCI, con número de ensayos menores, en aplicaciones reales de generación de comandos, por ejemplo, hacia entornos virtuales o exomanos como apoyo a procesos de rehabilitación de miembros superiores.

5. Agradecimientos

A Colciencias, en el marco de la convocatoria 727 del Programa de Doctorados Nacionales, 2015, por el apoyo económico brindado. Y a la Facultad de Ingeniería de la Universidad del Valle por la gestión administrativa del proyecto.

6. Referencias

- Alexandre, B. (2006). *Commande robuste d'un effecteur par une interface cerveau-machine EEG asynchrone*. Université de Grenoble.
- Alonso-Valerdi, L. M., Salido-Ruiz, R. A., & Ramirez-Mendoza, R. A. (2015). Motor imagery based brain-computer interfaces: An emerging technology to rehabilitate motor deficits. *Neuropsychologia*, 79, 354–363. <https://doi.org/10.1016/j.neuropsychologia.2015.09.012>
- Badcock, N. A., Preece, K. A., de Wit, B., Glenn, K., Fieder, N., Thie, J., & McArthur, G. (2015). Validation of the Emotiv EPOC EEG system for research quality auditory event-related potentials in children. *PeerJ*, 3, 17. <https://doi.org/10.7717/peerj.907>
- Barachant, A., Bonnet, S., Congedo, M., & Jutten, C. (2010). Riemannian Geometry Applied to BCI Classification. In *9th International Conference Latent Variable Analysis and Signal Separation* (pp. 629–636). Springer. https://doi.org/10.1007/978-3-642-15995-4_78
- Barachant, A., Bonnet, S., Congedo, M., & 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>
- Barachant, A., Bonnet, S., Congedo, M., & Jutten, C. (2013). Classification of covariance matrices using a Riemannian-based kernel for BCI applications. *Neurocomputing*, 112, 172–178. <https://doi.org/10.1016/j.neucom.2012.12.039>

- Bishop, C. (2007). *Pattern Recognition and Machine Learning*. (M. Jordan, J. Kleinberg, & B. Schölkopf, Eds.), Microsoft Research Ltd. Springer.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. (C. Press, Ed.), *Journal of the American Statistical Association*. Birmingham: Aston University.
- Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., & Muller, K. (2008). Optimizing Spatial filters for Robust EEG Single-Trial Analysis. *IEEE Signal Processing Magazine*, 25(1), 41–56. <https://doi.org/10.1109/MSP.2008.4408441>
- Castillo, J. (2015). *Interfaz Cerebro-Computador Adaptativa Basada en Agentes Software para la Discriminación de Cuatro Tareas Mentales*. Universidad del Valle.
- Combrisson, E., & Jerbi, K. (2015). Exceeding chance level by chance: The caveat of theoretical chance levels in brain signal classification and statistical assessment of decoding accuracy. *Journal of Neuroscience Methods*, 250, 126–136. <https://doi.org/10.1016/j.jneumeth.2015.01.010>
- Congedo, M., Barachant, A., & Andreev, A. (2013). A New Generation of Brain-Computer Interface Based on Riemannian Geometry. *ArXiv Preprint ArXiv:1310.8115*, 33(0). Retrieved from <http://arxiv.org/abs/1310.8115>
- Dornhege, G., Millán, J. del R., Hinterberger, T., McFarland, D. J., & Müller, K.-R. (2007). *Toward Brain-Computer Interfacing*. *Neural information processing series*. <https://doi.org/10.1111/j.1468-1331.2008.02463.x>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Fushiki, T. (2011). Estimation of prediction error by using K-fold cross-validation. *Statistics and Computing*, 21(2), 137–146. <https://doi.org/10.1007/s11222-009-9153-8>
- Ge, S., Wang, R., & Yu, D. (2014). Classification of Four-Class Motor Imagery Employing Single-Channel Electroencephalography. *PLoS ONE*, 9(6), e98019. <https://doi.org/10.1371/journal.pone.0098019>
- Grangeon, M., Revol, P., Guillot, A., Rode, G., & Collet, C. (2012). Could motor imagery be effective in upper limb rehabilitation of individuals with spinal cord injury? A case study. *Spinal Cord*, 50(10), 766–771. <https://doi.org/10.1038/sc.2012.41>
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The Elements of Statistical Learning*. (T. Hastie, R. Tibshirani, & J. Friedman, Eds.), *Springer Series in Statistics* (2nd ed.). Springer. <https://doi.org/10.1007/b94608>
- Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson, Prentice Hall.
- Holewa, K., & Nawrocka, A. (2014). Emotiv EPOC neuroheadset in brain - computer interface. In *Proceedings of the 2014 15th International Carpathian Control Conference (ICCC)* (pp. 149–152). IEEE. <https://doi.org/10.1109/CarpathianCC.2014.6843587>
- Lotte, F., & Cuntai Guan. (2011). Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms. *IEEE Transactions on Biomedical Engineering*, 58(2), 355–362. <https://doi.org/10.1109/TBME.2010.2082539>
- Lu, J., McFarland, D. J., & Wolpaw, J. R. (2013). Adaptive Laplacian filtering for sensorimotor rhythm-based brain-computer interfaces. *Journal of Neural Engineering*, 10(1), 31. <https://doi.org/10.1088/1741-2560/10/1/016002>
- Martínez-Leon, J. A., Cano-Izquierdo, J. M., & Ibarrola, J. (2016). Are low cost Brain Computer Interface headsets ready for motor imagery applications? *Expert Systems with*

- Applications*, 49, 136–144. <https://doi.org/10.1016/j.eswa.2015.11.015>
- Mateo, S., Rienzo, F. Di, Bergeron, V., Guillot, A., Collet, C., & Rode, G. (2015). Motor imagery reinforces brain compensation of reach-to-grasp movement after cervical spinal cord injury. *Frontiers in Behavioral Neuroscience*, 9(September), 1–12. <https://doi.org/10.3389/fnbeh.2015.00234>
 - Mingxu, S. (2014). *A FES Control System for Upper Limb Rehabilitation*. University of Salford. Retrieved from <http://stacks.iop.org/0964-1726/26/i=10/a=105037?key=crossref.7455f3bb928620d7b120b4c9d6c542f4>
 - Moxon, K. A., Oliviero, A., Aguilar, J., & Foffani, G. (2014). Cortical reorganization after spinal cord injury: always for good? *Neuroscience*, 283, 78–94. <https://doi.org/10.1016/j.neuroscience.2014.06.056>.Cortical
 - Peckham, P. H., Keith, M. W., Kilgore, K. L., Grill, J. H., Wuolle, K. S., Thrope, G. B., ... Wiegner, A. (2001). Efficacy of an implanted neuroprosthesis for restoring hand grasp in tetraplegia: A multicenter study. *Archives of Physical Medicine and Rehabilitation*, 82(10), 1380–1388. <https://doi.org/10.1053/apmr.2001.25910>
 - Proakis, J. G., & Manolakis, D. (1996). *Digital Signal Processing: Principles, Algorithms, and Applications*. (P. Hall, Ed.) (3rd ed.). London: Prentice Hall International Inc.
 - Rupp, R., Kleih, S., Leeb, R., Millan, J. del R., Kübler, A., & Müller-Putz, G. (2014). Brain-Computer Interfaces and Assistive Technology. In G. Grübler & E. Hildt (Eds.), *Brain-Computer-Interfaces in their ethical, social and cultural contexts* (Vol. 12, pp. 7–38). Springer. <https://doi.org/10.1007/978-94-017-8996-7>
 - Shih, J. J., Krusienski, D. J., & Wolpaw, J. R. (2012). Brain-Computer Interfaces in Medicine. *Mayo Clinic Proceedings*, 87(3), 268–279. <https://doi.org/10.1016/j.mayocp.2011.12.008>
 - Tangermann, M., Müller, K., Aertsen, A., Birbaumer, N., Braun, C., Brunner, C., ... Müller-putz, G. R. (2012). Review of the BCI competition IV. *Frontiers in Neuroscience*, 6(July), 1–31. <https://doi.org/10.3389/fnins.2012.00055>
 - Vidaurre, C., Klauer, C., Schauer, T., Ramos-Murguialday, A., & Müller, K. R. (2016). EEG-based BCI for the linear control of an upper-limb neuroprosthesis. *Medical Engineering and Physics*, 38(11), 1195–1204. <https://doi.org/10.1016/j.medengphy.2016.06.010>
 - Yger, F., Berar, M., & Lotte, F. (2016). Riemannian approaches in Brain-Computer Interfaces: a review. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 4320(c), 1–1. <https://doi.org/10.1109/TNSRE.2016.2627016>

Sobre los autores

- **Carlos Ferrin:** Ingeniero Físico (2010) y Joven Investigador Colciencias (2011) de la Universidad del Cauca. Magister en Ingeniería Electrónica (2015) y Estudiante de Doctorado en Ingeniería con énfasis en Eléctrica y Electrónica dentro del Grupo de Percepción y Sistemas Inteligentes de la Universidad del Valle. Sus áreas de interés son el procesamiento de señales, la visión artificial, el reconocimiento de patrones y la neuroingeniería. carlos.ferrin@correounivalle.edu.co
- **Humberto Loaiza:** Ingeniero Electricista (1990) y Magister en Automática (1995) de la Universidad del Valle; Doctor en Robótica y Visión Artificial (1999) de L'Université d'Evry,

Francia. Director del Grupo de Investigación en Percepción y Sistemas Inteligentes [PSI]. Áreas de interés son la robótica móvil, la visión artificial y el procesamiento digital de señales. humberto.loaiza@correounivalle.edu.co

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2019 Asociación Colombiana de Facultades de Ingeniería (ACOFI)