

# Procesamiento de señales de electroencefalogramas (EEG)

para ayudar a pacientes con discapacidades motoras

➤ Ing. Evelyn Janeth González Wong y Dra. Graciela Ramírez Alonso

Universidad Autónoma de Chihuahua / Facultad de Ingeniería  
FINGUACH Año 5, Núm. 18, diciembre - febrero 2019

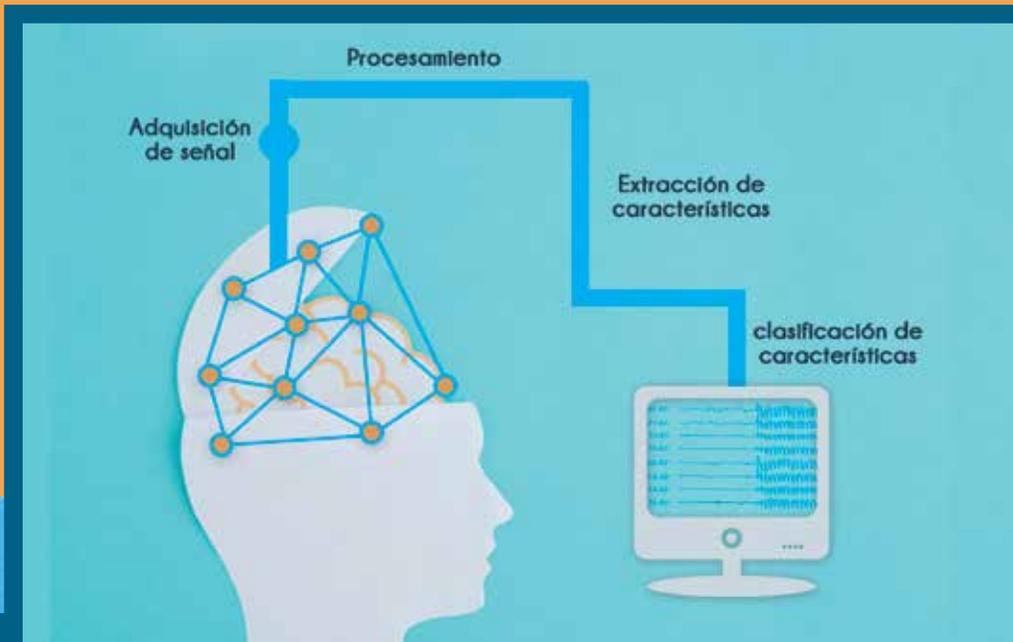


Según el informe mundial sobre la discapacidad de la Organización Mundial de la Salud (OMS) hasta el 2011 se estimaba que alrededor de 1 000 millones de personas (15 % de la población mundial) cuenta con alguna discapacidad ya sea motriz, auditiva, de lenguaje, visual o mental (OMS, 2011). Las causas principales de estas discapacidades están clasificadas en: nacimiento y cognitivas, por alguna enfermedad, accidente o vejez.

En América Latina y el Caribe entre el 80 % y 90 % de la población adulta con alguna discapacidad no cuenta con empleo debido a que no se tiene un transporte o instalaciones adecuados para ellos. Por el mismo motivo entre el 20 % y 30 % de los niños con discapacidad no asisten a la escuela (OMS, 2011).

Según cifras del INEGI hasta el año 2014, de aproximadamente 120 millones de personas en México, 7.2 millones (6 % de la población) presenta alguna discapacidad, 2.97 millones (el 41.3 %) cuenta con una discapacidad motriz a causa de alguna enfermedad, 0.63 millones (el 8.8 %) por accidente y 2.38 millones (el 33.1 %) por edad avanzada (INEGI, 2015). Con el fin de ayudar a esta población vulnerable algunos investigadores se han enfocado al desarrollo de diferentes herramientas que apoyen el avance de su autonomía (N Mak & Wolpaw, 2009). Tal es el caso del control de prótesis, sillas de ruedas o algún dispositivo externo de acuerdo con alguna acción de control. Gracias a los avances en la tecnología y a la reducción de costos en la misma, las interfaces cerebro computadora que usualmente se describen por su nombre en inglés *Brain Computer Interface* (BCI) han tenido un gran auge en el desarrollo de sistemas de control (Minguez, 2008). Una de las técnicas que se utiliza en sistemas BCI, es la visualización motora, la cual es la representación mental de un movimiento, pero sin realizar ningún gesto físico. De esta manera, una persona con discapacidad física puede imaginar el movimiento y el sistema BCI lo identificará y podrá realizar una acción de control en apoyo a la persona con discapacidad.

El electroencefalograma (EEG) es una prueba que permite el registro de la actividad cerebral. Este sistema se considera como el método más empleado para la adquisición de las señales eléctricas del cerebro ya que tiene una alta resolución temporal, es fácil de usar y seguro (Avila Perona, 2006). El EEG registra la actividad eléctrica en un corto periodo de tiempo a través de múltiples electrodos situados en el cuero cabelludo.



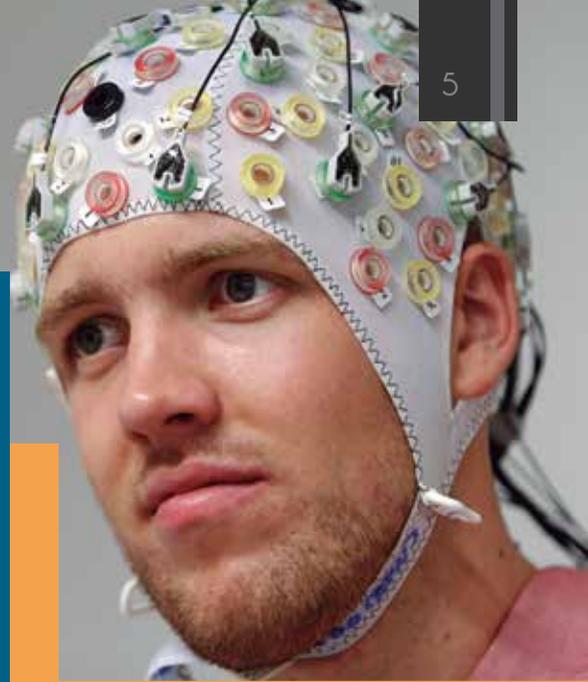
**Figura 1.** Diagrama de bloques de componentes del sistema BCI.

Un sistema BCI básico que analiza señales de un EEG consta de cuatro componentes: adquisición de señales, preprocesamiento de señales, extracción de características y clasificación (Véase Figura 1). El componente de adquisición de señal es responsable de registrar las ondas cerebrales y enviarlas al componente de preprocesamiento para mejorar la señal y reducir el ruido. El componente de extracción de características identifica atributos discriminativos de la señal mejorada, en algunos casos disminuye el tamaño de los datos aplicados al componente de clasificación y los clasificadores se encargan de traducir las señales en comandos de dispositivo.

En la literatura se han desarrollado e implementado diferentes modelos matemáticos para el procesamiento, extracción de características y clasificadores. Dentro de ellos destacan aquellos basados en *Common Spatial Pattern* (CSP) para proporcionar señales más fáciles de clasificar y que nos conduzcan a variaciones óptimas para la discriminación de dos señales de EEG relacionadas con visualizaciones motoras (Wang, Gao, & Gao, 2006) (Yang, Shakhavi, Ang, & Guan, 2015) (Duan, Hongxin, Muhammad Saad, & Fang, 2018). De igual manera, dos de los filtros más utilizados por los investigadores para separar bandas de frecuencia en las señales EEG son los filtros *Butterworth* y *Chevyshev* (Sun, Zuren, Badong, & Na, 2018) (Steven W. Smith, 2002) (Yang, Luo & Ke, 2016). Una vez que se tiene la señal filtrada sigue la tarea de extraer las características. En este punto, modelos estadísticos basados en el cálculo de la media, mediana, sesgo, moda, entre otros, suelen implementarse para identificar patrones en las señales. En la parte de clasificación de las señales, modelos como Máquinas de Vectores de Soporte (Duan, Hongxin, Muhammad Saad, & Fang, 2018) (Olivas Padilla, Chacón Murguía, & Ramirez Quintana, 2017) Clasificadores Lineales (Myrden & Chau, 2016) (Tan, Sa, & Yu, 2016) Redes Neuronales (Rejendra Acharya, Shu Lih, Yuki, Hong Tan, & Hojjat, 2017)

(Zhang, Yan, & Gong, 2017) (Yousef Rezaei & Halici, 2017) entre otros, han demostrado dar resultados superiores al 80 % en la clasificación de señales EEG.

En la Facultad de Ingeniería de la Universidad Autónoma de Chihuahua se han realizado diferentes investigaciones en donde alumnos de la carrera de Ingeniería Matemática y de la Maestría en Ingeniería en Computación se han dado a la tarea de implementar varias estrategias para el análisis de señales EEG. Estas señales fueron adquiridas de diferentes bases de datos que se comparten en la literatura, tal es el caso de *BCI Competition* <http://www.bbc.de/competition/>, *Physionet* <https://www.physionet.org/>, *Temple University Hospital EEG* <https://www.isip.piconepress.com/>, *UC Irvine Machine Learning Repository* <https://archive.ics.uci.edu/>, *Multimedia Authoring & Management using your Eyes & Mind* <http://www.mamem.eu/>. Actualmente, los alumnos trabajan para identificar los modelos más robustos que logren dar buenos resultados en las diferentes problemáticas en que se enfoca el análisis de señales EEG. De igual manera, se trabaja con la adquisición de señales crudas censadas por el equipo de *OpenBCI* <http://openbci.com/>, la etapa de procesamiento en tarjetas *Raspberry Pi 3* y las acciones de control en diferentes dispositivos electrónicos como brazos robóticos, control de motores, entre otros. Con el desarrollo de este tipo de investigación los alumnos tienen la oportunidad de poner en práctica lo aprendido en su carrera para la solución de problemas reales y además aportan en el desarrollo tecnológico de la comunidad. Todo el equipo que se tiene para el desarrollo de esta investigación fue adquirido gracias al apoyo del proyecto PRODEP Laboratorio de Sistemas Electrónicos y Procesamiento de Bio-Senales Aplicado al Desarrollo de Neuro-Interfaces de Control, BCI.



## Referencias

- Avila Perona, M. E. (2006). *Bioinstrumentación II*. Universidad Nacional de San Juan.
- Duan, L., Hongxin, Z., Muhammad Saad, K., & Fang, M. (2018, Marzo). A self adaptive frequency selection common spatial pattern and least squares twin support vector machine for motor imagery electroencephalography recognition. *Biomedical Signal Processing and Control*, 41, 222 – 232. doi:10.1016/j.bspc.2017.11.014
- INEGI. (2015). Estadísticas a propósito del día Internacional de las personas con discapacidad. In INEGI. Retrieved from <http://www.inegi.org.mx/saladeprensa/aproposito/2015/discapacidad0.pdf>
- Minguez, J. (2008). Tecnología de interfaz cerebro-computador.
- Myrden, A., & Chau, T. (2016, Abril). A Passive EEG-BCI for Single-Trial Detection of Changes in Mental State. 25(4), pp. 345-356. doi:10.1109/TNSRE.2016.2641956
- N Mak, J., & Wolpaw, J. R. (2009). Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE reviews in biomedical engineering*, 187 – 199.
- Olivas Padilla, B. E., Chacón Murguía, M. I., & Ramírez Quintana, J. A. (2017). Multiclass motor imagery classification based on the correlation of pattern images generated by spatial filters. 14th *International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*, (pp. 1-6). Mexico City, Mexico. doi:10.1109/ICEEE.2017.8108835
- OMS. (2011). *Informe Mundial sobre la Discapacidad*. Retrieved from [http://www.who.int/disabilities/world\\_report/2011/es/](http://www.who.int/disabilities/world_report/2011/es/)
- Rejendra Acharya, U., Shu Lih, O., Yuki, H., Hong Tan, J., & Hojjat, A. (2017, Septiembre). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*. doi:10.1016/j.compbiomed.2017.09.017
- Steven W. Smith, P. (2002). *The Scientist and Engineer's Guide to Digital Signal Processing*. San Diego, California: California Technical Publishing.
- Sun, L., Zuren, F., Badong, C., & Na, L. (2018, Marzo). A contralateral Channel guided model for EEG based motor imagery classification. *Biomedical Signal Processing and Control*, 1-9. doi:10.1016/j.bspc.2017.10.012
- Tan, P., Sa, W., & Yu, L. (2016). Applying Extreme Learning Machine to classification of EEG BCI. *IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems*, (pp. 228-232). Chengdu, China. doi:10.1109/CYBER.2016.7574827
- Tang, Z., Li, C., & Sun, S. (2017). Single-trial EEG classification of motor imagery using deep convolutional neural networks. *Optik - International Journal for Light and Electron Optics*, 130, 11-18. doi:10.1016/j.ijleo.2016.10.117
- Vasilakos, R. A. (2017). Brain computer interface: control signals review. In *Neurocomputing* (Vol. 223, pp. 26-44).
- Wang, Y., Gao, S., & Gao, X. (2006). Common Spatial Pattern Method for Channel Selection in Motor Imagery Based Brain-computer Interface. *IEEE Engineering in Medicine and Biology 27th Annual Conference*, (pp. 5392-5395). Shanghai, China. doi:10.1109/IEMBS.2005.1615701
- Yang, H., Shakhavi, S., Ang, K., & Guan, C. (2015). On the Use of Convolutional Neural Networks and Augmented CSP Features for Multi-class Motor Imagery of EEG Signals Classification. 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, (pp. 2620-2623). Milan, Italy. doi:10.1109/EMBC.2015.7318929
- Yang, L., Luo, M. L., & Ke, L. (2016, Junio). A multiwavelet-based time-varying model identification approach for time-frequency analysis of EEG signals. *Neurocomputing*, 193, 106-114. doi:doi.org/10.1016/j.neucom.2016.01.062
- Yousef Rezaei, T., & Halici, U. (2017). A novel deep learning approach for classification of EEG motor imagery signals. *Journal of Neural Engineering*, 14(1), 016003. doi:10.1088/1741-2560/14/1/016003
- Zhang, J., Yan, C., & Gong, X. (2017). Deep Convolutional Neural Network for Decoding Motor Imagery based Brain Computer Interface. *IEEE International Conference on Signal Processing, Communications and Computing*, (pp. 1-5). Xiamen, China.