

# Evaluación del diseño de una interfaz cerebro-computadora para detección de emociones

*Evaluation of the design of a brain-computer interface for emotion detection*

Ramón-Sidonio Aparicio-García<sup>1</sup>, Gustavo Juárez-Gracia<sup>1</sup>, Jesús Álvarez-Cedillo<sup>1</sup>, Jacobo Sandoval-Gutiérrez<sup>2</sup> y Blanca Tovar-Corona<sup>1</sup>

<sup>1</sup> Instituto Politécnico Nacional (Méjico)

<sup>2</sup> Universidad Autónoma Metropolitana (Méjico)

DOI: <http://dx.doi.org/10.6036/8862>

Con una interfaz Cerebro-Computadora (BCI) se puede lograr la detección de emociones a partir de la señal electroencefalográfica (EEG), tal como se ha reportado por Murugappan, et. al [1] y por otros trabajos similares. Sin embargo, una de las oportunidades detectadas para mejorar estos métodos fue desarrollada por Aparicio-García, et. al [2] mediante la descomposición wavelet discreta, ejecutada como proceso de extracción de características, seguida de la selección de características de mayor separabilidad, y la clasificación, buscando que el clasificador sea capaz de entrenarse de manera no intensiva, e igualando condiciones como las características, el número de canales, y las emociones asociadas.

De las dos clases de tecnología, las no invasivas miden la actividad cortical con sensores superficiales ofreciendo ventajas de bajo costo, fácil instalación y portabilidad, que contrastan con la dificultad de generar un método adecuado para el reconocimiento afectivo en cualquier dispositivo. En este sentido, el diseño de una evaluación para cualquier BCI en la detección de emociones definimos cuatro etapas que deberán ser analizadas y comparadas de forma independiente:

- a) Adquisición de las señales
- b) Extracción de características
- c) Selección de características
- d) Clasificación

En la adquisición de las señales la forma de evaluar la capacidad del método se mide con la reducción de canales, es decir, incorporar una mayor cantidad de información descriptiva, en el caso de [2] hubo una comparación que pudo reducir esto. En la extracción de características, la expresión matemática debe ser reducida para minimizar el costo del cálculo numérico. Para la selección de caracterís-

ticas dos métodos se consideraron principalmente: ranking y selección de subconjuntos; por último en la clasificación se reportaron algunos como *Naive Bayes*, *Perceptron Multicapa*, K vecinos más cercanos, K-Star y Árbol de decisiones, los cuales son parámetros de referencia comparables y probadas.

La aportación presentada en la extracción de características por la descomposición wavelet es la propiedad de multi-resolución, útil al análisis del comportamiento frecuencial y los cambios temporales de la señal. Haciendo un comparativo para los métodos de búsqueda-selección, con la selección individual de características se obtuvieron los mejores desempeños para el caso de las clases de *arousal*, siendo un clasificador *Naive-Bayes* el de mayor porcentaje de asertividad. Para el caso de valencia, se tienen diferencias mínimas entre el resultado del método de selección de subconjuntos e individual, en donde no hubo mayor ventaja para cualquiera de los clasificadores. De los resultados revisados en [2] se puede observar, para la clasificación de acuerdo al eje de *arousal*, que en la mayoría de casos los valores de la *Entropía Relativa de Wavelet* (RWE o coeficientes  $\rho$ ) de las ondas beta, resultaron ser las variables más descriptivas; mientras que la información relacionada con las ondas alfa y teta, así como del cuantificador de la Entropía de Wavelet Total Normalizada (NTWS), tuvieron un menor impacto. La mayor contribución de información útil durante la clasificación de señales respecto al eje de valencia, la proporcionaron las variables atributo relacionadas con el comportamiento de las ondas beta y alfa, siendo sólo reducidos casos en los que las ondas teta y el descriptor NTWS tuvieron relevancia. El cuantificador RWS no proporcionó información útil durante la clasificación para ninguno de los dos casos. Después de haber aplicado el método de reducción de características, se cumplió con verificar que para reducir el número de variables, se descartaron algunas poco descriptivas como las concernientes al cuantificador SWR y las relacionadas al cálculo de la entropía de Shannon de la señal para los tres tipos de onda. Un análisis realizado sobre las señales provenien-

tes del sensor Fp1 demostró que puede ser aplicable para la detección siempre que se realice un entrenamiento previo de la interfaz conectada al usuario final.

En conclusión, debido a la dificultad que representa la estimulación afectiva al tomar en cuenta el proceso de recabar información para la construcción de un conjunto de entrenamiento en el usuario final, mismo que no puede ser exhaustivo, es conveniente optar por algoritmos de clasificación cuyo entrenamiento no requiera de grandes cantidades de muestras, validando entonces, que los diversos métodos de ingeniería de características para la BCI son tema de investigación enfocada a optimizar las condiciones de aplicación en conjunto con las bases de la detección de las emociones.

## REFERENCIAS

- [1] MURUGAPPAN Murugappan, RAMACHANDRAN Nagarajan, and SAZALI Yaacob, COMBINING SPATIAL FILTERING AND WAVELET TRANSFORM FOR CLASSIFYING HUMAN EMOTIONS USING EEG SIGNALS, *Journal of Medical and Biological Engineering*, vol. 31, no. 1, pp. 45-5. DOI: <http://dx.doi.org/10.5405/jmbe.710>
- [2] APARICIO-GARCIA, Ramon Sidonio, JUAREZ-GRACIA, Gustavo, ALVAREZ-CEDILLO, Jesus Antonio et al. FEATURE EXTRACTION AND SELECTION APPROACH FOR A BRAIN-COMPUTER INTERFACE IMPLEMENTATION IN EMOTION DETECTION. *DYNA New Technologies*, Enero-Diciembre 2017, vol. 4, no. 1, [13 p.]. DOI: <http://dx.doi.org/10.6036/NT7829>
- [3] KLAUS R Scherer, WHAT ARE EMOTIONS? AND HOW CAN THEY BE MEASURED?, *Social science information*, vol. 44, no. 4, pp. 695-729, DOI: <https://doi.org/10.1177/0539018405058216>