

# Reconocimiento de comandos a través de señales EEG basado en Potenciales Evocados Visuales de Estado Estacionario (PEVEE)

Ing. H. Candelario-Emigdio<sup>1</sup>, Dr. JA. Montero-Valverde<sup>2</sup>, Dr. E. de la Cruz-Gómez<sup>3</sup>, MC. JF. Gazga-Portillo<sup>4</sup>

**Resumen-**La interpretación de comandos aplicando dispositivos conectados al cerebro se han utilizado en una amplia variedad de aplicaciones tales como: apoyo a discapacitados, ambientes virtuales de entrenamiento y entretenimiento entre otras. En este artículo se muestra la metodología basada en potenciales evocados visuales de estado estacionario (PEVEE) para el análisis de señales EEG. La metodología contempla el desarrollo de un prototipo de tres clases de sistema de interfaz cerebro-computadora para el reconocimiento de comandos utilizando la diadema Emotiv EPOC. El sistema utilizará la transformada de átomos de onda (WAT) para la extracción de características y las técnicas de análisis discriminante lineal (LDA) y máquinas de soporte vectorial (SVM) como clasificadores. Por el momento se muestran resultados parciales relacionados con la etapa de adquisición y tratamiento de la señal EEG.

**Palabras clave-** Interfaz Cerebro Computadora; Señal EEG; Potenciales Evocados Visuales de Estado Estacionario; Reconocimiento de patrones.

## Introducción

Una interfaz cerebro computadora (BCI) es un sistema que genera una forma de comunicación artificial entre el cerebro de una persona y el mundo exterior. El funcionamiento básico de una BCI es medir la actividad cerebral, procesarla para obtener características de interés, y una vez obtenidas interactuar con el entorno en la forma deseada por el usuario.

Desde los primeros experimentos de electroencefalografía (EEG) en seres humanos en 1929, el EEG del cerebro humano se ha utilizado principalmente para evaluar trastornos neurológicos en el entorno clínico e investigar las funciones cerebrales en el laboratorio. Una idea de que la actividad cerebral podría ser utilizado como un canal de comunicación ha ido surgiendo poco a poco. La posibilidad de reconocer un único mensaje o comando considerando la complejidad, distorsión y variabilidad de las señales cerebrales parecía ser extremadamente remota.

El desarrollo continuo de hardware y software de computadora ahora soporta un análisis altamente sofisticado en línea de muchos canales de señal a alta velocidad. Además, el reconocimiento social de las necesidades y las contribuciones potenciales de las personas con trastornos neuromusculares graves, como lesiones de la médula espinal, ha generado interés clínico, científico y comercial ha resultado una mejor tecnología de comunicación y control. Se ha creado un campo interdisciplinario de investigación para ofrecer una interacción directa humano-computadora a través de señales generadas por el propio cerebro.

La tecnología BCI es un canal de comunicación que permite a los usuarios controlar dispositivos y aplicaciones sin el uso directo de los músculos [1]. El desarrollo del campo de la neurociencia cognitiva ha sido investigado por los recientes avances en las tecnologías de imagen cerebral como la electroencefalografía, magnetoencefalografía y resonancia magnética funcional. El creciente campo de investigación BCI es relativamente nuevo. El primer prototipo BCI fue creado por el Dr. Vidal en 1973 [2]. Este sistema estaba destinado a ser utilizado como un canal de comunicación prometedor para las personas con discapacidades graves, tales como parálisis, esclerosis lateral amiotrófica, accidente cerebrovascular o parálisis cerebral [3]. La aceleración continua de los avances recientes en la investigación y el desarrollo de las BCI han comenzado a abordar aplicaciones del mundo real que abarcan actividades de la vida diaria tales como, control ambiental, ejercicio, locomoción y comunicación verbal [4].

<sup>1</sup> Alumno de la Maestría en Sistemas Computacionales del I.T. de Acapulco  
[honorio\\_30@hotmail.com](mailto:honorio_30@hotmail.com)

<sup>2</sup> Profesor Adscrito al Depto. De Sistemas y Computación del I.T. de Acapulco

<sup>3</sup> Profesor Adscrito al Depto. De Sistemas y Computación del I.T. de Acapulco

<sup>4</sup> Profesor Adscrito al Depto. De Sistemas y Computación del I.T. de Acapulco

La tecnología BCI, combinada con sistemas de vida asistida viable, puede potencialmente hacer que el ambiente doméstico sea más inteligente y asistido, proporcionando medios de comunicación alternativos para apoyar la vida independiente de las personas mayores con algún impedimento. La calidad de vida de las personas que sufren discapacidades motrices puede beneficiarse con el uso de la tecnología de asistencia basada en BCI [5]. A pesar de los recientes acontecimientos, todavía existen numerosos obstáculos para construir un sistema BCI utilizable y eficaz. Los mayores desafíos están relacionados con la precisión, velocidad, precio y facilidad de uso. Los sistemas BCI actuales son inexactos y tienen una baja tasa de transferencia de información. Esto significa que el usuario necesita un largo período de tiempo para enviar comandos al dispositivo que se está controlando. Otro problema es el alto costo de los equipos de EEG [6]. Los sistemas con un alto número de sensores tardan mucho en prepararse para el uso y son incómodos. Debido a estas limitaciones, ningún sistema BCI ha tenido éxito comercial hasta la fecha. El conocimiento del proceso de adquisición de datos, las características de la forma de onda EEG, las metodologías de procesamiento de señales para la extracción de características y la clasificación es un requisito previo antes de intentar diseñar e implementar un sistema BCI funcional. Estos puntos de investigación han sido destacados por la comunidad de desarrollo de BCI como importantes y necesarios [7 - 8].

Por lo tanto, la tecnología BCI todavía tiene muchos problemas a resolver para el tránsito a una vida asistida viable con un esfuerzo mínimo de capacitación y el apoyo necesario para un uso independiente en el hogar [9].

La problemática a resolver es sin duda una de las etapas críticas de todo sistema BCI la interpretación de las señales electroencefalográficas y su clasificación, esto con el propósito de reconocer descriptores de la señal y analizar su comportamiento a ciertos casos clínicos e interpretación de acciones del cuerpo humano; ejemplos de ello son el estudio de patologías o como auxiliar en la implementación de prótesis. Dependiendo de la tasa de acierto que se tenga al momento de identificar y clasificar la señal EEG, es como el sistema tendrá una mayor eficiencia al momento de ejecutar un comando en el mecanismo efector.

El objetivo de este trabajo es explorar la tecnología BCI como una opción para el reconocimiento de comandos, que puede requerir menos calidad de EEG y presentar interacciones de bajo riesgo. Mediante el uso de dispositivos de bajo costo y portabilidad, como la diadema Emotiv EPOC, se busca un compromiso entre el rendimiento y la comodidad del usuario.

### **Metodología**

Actualmente existen dos enfoques para desarrollar sistemas BCI. 1) Un BCI es llamado invasivo si el sistema de adquisición de señal (por ejemplo, electrodos) tiene que ser implantado directamente en el cerebro. 2) En otro caso, el sistema puede ser desarrollado sin necesidad de cirugía mediante la colocación del sistema de adquisición en la superficie del cráneo. En este último caso el BCI es llamado no invasivo. Los más prácticos y usables son aquellos basados en electroencefalografía (EEG) no invasiva, de forma que las señales son adquiridas de la superficie craneal. Estos datos proporcionan información de las ondas cerebrales mediante la grabación de la actividad eléctrica del cerebro.

Los BCIs no invasivos basados en EEG generalmente utilizan respuestas cerebrales aplicando modelos como los potenciales relacionados con eventos (o ERP – Event- Related Potentials) tales como P300, potenciales evocados visuales (VEP – Visual Evoked Potentials) o potenciales evocados visuales de estado estacionario (SSVEP – Steady-State visual evoked potentials). Los ERPs son potenciales generados en el cerebro durante la presentación de estímulos. Los estímulos pueden ser generados por un sensor o un evento psicológico. Esto genera una onda con un retraso temporal que puede ser detectada después de procesar las señales EEG. Por otra parte, VEP consiste en un conjunto de ondas, concretamente aquellas que se derivan de la actividad de la corteza cerebral. Las diferentes formas de onda generadas por los estímulos visuales pueden ser distinguidas según su latencia. Los potenciales VEP son llamados “fugaces” porque la baja tasa de estimulación permite a las vías sensoriales recuperarse antes que el siguiente estímulo aparezca. Cuando los estímulos visuales son presentados a una tasa constante y suficientemente alta se evita que la actividad neuronal evocada regrese a su estado base, entonces la respuesta elegida se vuelve continua. A esto se le llama SSVEP. Ante altas tasas de estimulación, la respuesta cerebral al estímulo toma forma sinusoidal.

El enfoque que se va a aplicar en este trabajo es PEVEE debido a su efectividad y menor entrenamiento para el sujeto. La señal producida por un estímulo PEVEE es medible en la mayoría de la población y la tarea de extraer la información se reduce tan solo a hallar el componente frecuencial de la misma con mayor potencia dentro de las

componentes para las que se esperan mayores picos de potencias que se corresponden con la frecuencia de parpadeo de cada uno de los objetivos en el BCI. No obstante, es importante tener en cuenta que este tipo de estímulos visuales a ciertas frecuencias pueden provocar ataques epilépticos y ciertos tipos de iluminación pueden afectar la visión del sujeto. Además de ello, algunas frecuencias pueden inducir fatiga.

Las etapas de la metodología propuesta en este trabajo son: Adquisición de la señal EEG, Preprocesamiento, Extracción de características, Clasificación y Comando reconocido (ver Figura 1).

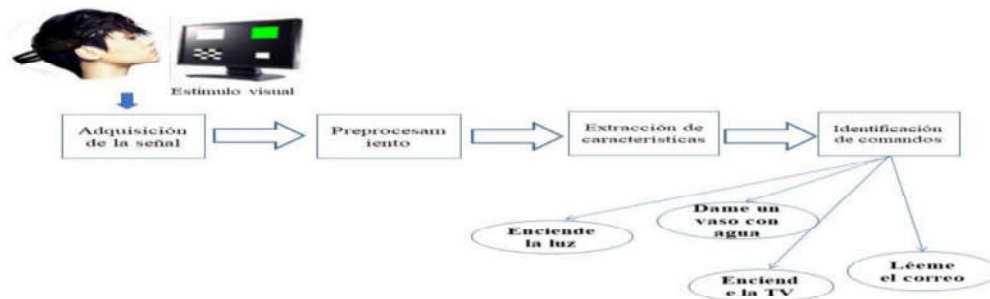


Figura 1. Metodología.

### Adquisición de la señal EEG

La adquisición de la señal EEG se realiza seleccionando los canales que se utilizarán para la grabación de datos. Las señales de interés, en el caso del paradigma PEVEE, son O1, O2, P7 y P8 (ver Figura 2). La posición de estos electrodos se elige cerca de las regiones parietal y occipital ya que la potencia producida en este caso es mayor en las zonas cercanas al córtex parietal y occipital.




Figura 2: Disposición del sensor.

### Preprocesamiento

Las señales de los sensores se promedian y se les aplica un filtrado pasa-banda de 6-40 Hz. La señal se divide en bloques de 2 segundos, con un intervalo de 0.5 segundos. Se obtiene un valor de señal promedio promediando 4 bloques y se realiza una FFT para visualizar las diferentes bandas de frecuencia. A continuación, se realizan pasos de preprocesamiento con el fin de reducir el ruido de la señal y extraer las características de información relevantes para el clasificador: 1) Primero, los datos se dividen en tres grupos, según su etiqueta de clase correspondiente, IZQUIERDA, DERECHA y CENTRO. Esto se hace para que un clasificador binario pueda distinguir si un entrenamiento pertenece a una clase determinada o no, usando el criterio "uno contra todos". 2) A continuación, se aplica un filtrado temporal y espacial a cada uno de los tres grupos. Específicamente, cada grupo de señales se le aplica un filtrado pasa-banda

sobre la frecuencia objetivo de interés: para la clase IZQUIERDA es de 29.5-30.5 Hz; para la clase CENTRO es de 19.5-20.5 Hz; y para la clase DERECHA es de 11.5-12.5 Hz. Esto se hace utilizando un filtro Butterworth de cuarto orden.

### Extracción de características

Para la extracción de características se utiliza la transformada de átomo de onda (WAT), una transformada relativamente nueva propuesta por Demanet y Ying [10]. WAT realiza un análisis multiresolución de una señal, es decir, descomponiendo una señal en diferentes sub-bandas de frecuencia. El WAT se ha utilizado previamente en el dominio del procesamiento de imágenes para la marca de agua de imágenes, para la extracción de características, la reducción de la dimensionalidad, el análisis numérico [11] y el análisis de los datos del electrocardiograma (ECG) [12].

Para extraer características, primero se segmenta la señal, extrayendo el período de estimulación de 5 segundos por entrenamiento, ya que sólo esta parte de la señal lleva información relevante. A continuación, cada segmento se divide en bloques de 1 segundo cada 0.2 segundos, lo que proporciona un 80% de superposición entre bloques vecinos. Posteriormente, se obtienen coeficientes de WAT para cada bloque, y se crea un vector de características. Finalmente, se extraen 25 vectores de características para cada entrenamiento. Estos vectores se utilizarán para el entrenamiento del clasificador.

### Clasificación

La fase de clasificación se divide en dos pasos. Primero, el clasificador se debe entrenar con varias muestras de vectores de características. Posteriormente, la fase de prueba o fase “online”, se utiliza el clasificador previamente entrenado para que determine la etiqueta del comando de acuerdo a un vector de características entrante.

Para la fase de entrenamiento se capturan muestras de las señales EEG para obtener sus vectores de características; este procedimiento se aplica para cada una de las tres clases (IZQUIERDA, DERECHA y CENTRO). Primero, se muestra en la pantalla una flecha amarilla por un segundo indicando el objetivo en el que el usuario debe centrar su atención. Del segundo 1 al segundo 6, el entrenamiento entra en fase de estimulación. En esta fase los tres objetivos (figuras geométricas en la pantalla) comienzan a parpadear en sus frecuencias correspondientes. Los usuarios están específicamente cómodos para no mover la cabeza, relajar los músculos de la cara, y no parpadear durante esta fase. A continuación, la estimulación es seguida por un período de reposo de 4 segundos, en el que se permite al usuario descansar su mirada, parpadear o mover la cabeza (ver Figura 3). Los datos EEG de este período no se utilizan para la clasificación. Los datos de las señales EEG son grabados, junto con los eventos marcados, como las etiquetas de clase de cada prueba. Para el análisis sólo se utilizan los canales relevantes, en este caso, O1, O2, P7 y P8.




Figura 3. Ilustración del entrenamiento.

Para clasificar las señales EEG en las categorías (IZQUIERDA, DERECHA y CENTRO) se aplica el algoritmo SVM (*Support Vector Machine – Máquinas de Soporte Vectorial*). La SVM son estructuras de aprendizaje basadas en la teoría estadística del aprendizaje. Se basan en transformar el espacio de entrada en otro de dimensión superior en el que el problema puede ser resuelto mediante un hiperplano óptimo. Estos métodos están propiamente relacionados con problemas de clasificación y regresión. Dado un conjunto de ejemplos de entrenamiento (muestras) podemos etiquetar las clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra.

### Identificación de Comando.

Para la fase de prueba o fase “online”, se emplea el mismo flujo del sistema para extraer el vector de características a partir de las señales EEG, aplicando las fases de pre-procesamiento de la señal. En esta fase se utiliza el modelo clasificador previamente entrenado. La señal EEG es interpretada por el clasificador y se obtiene la etiqueta con mayor probabilidad de entre las tres posibles (IZQUIERDA, DERECHA y CENTRO), obteniendo así el comando mental.

Para esto, se presenta en la pantalla tres figuras geométricas, una para cada comando mental (ver Figura 4). El usuario es capaz de centrar su atención en una de las figuras geométricas, para que la señal EEG sea interpretada como un comando mental.

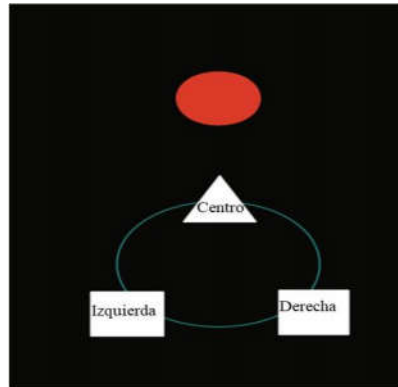




Figura 4. Figuras geométricas, una para cada comando mental.

### Resultados parciales

Utilizando el EEG de Emotiv, se realizó el entrenamiento en sujetos que permitieron generar las señales de control necesarias para el reconocimiento de comandos, comunicando el paquete de desarrollo del Epoc con OpenViBE, mediante una comunicación cliente-servidor. Para el entrenamiento centraron su atención en tres cuadrados parpadeantes, imaginando los movimientos. Al fijar la mirada en uno de los cuadrados (Derecha, Izquierda y Centro), este empezaba a parpadear simulando el movimiento respectivo. En cuanto al resultado en la adquisición de las señales fue suficiente y no necesito de mucho entrenamiento de parte de los usuarios (ver Figura 5). En el caso de la generación de señales mediante acciones cognitivas, se obtuvieron las señales elementales de los sensores O1, O2, P7 y P8.



a) Señal adquirida sin procesar



b) Estimulación visual

Figura 5. Ilustración de la Estimulación visual para clasificar categoría de control mental (IZQUIERDA, DERECHA y CENTRO).

### Conclusión

Las señales cerebrales reflejan las actividades manejadas y controlan el comportamiento del cerebro o la influencia de la información recibida de otras partes del cuerpo, ya sea la detección o los órganos internos. BCI proporciona una facilidad de canalización entre el cerebro y el equipo externo.

Hemos estudiado las técnicas de procesamiento y clasificación de señales de electroencefalograma (EEG) para diseñar sistemas de interfaz cerebro-computadora (BCI) que se utilizarán en ambientes fuera del laboratorio como ambientes de vida asistida viable o hogares inteligentes, con estos objetivos principales : (1) mejorar la eficiencia en términos de precisión del BCI; (2) mejorar la usabilidad y aplicabilidad, por lo tanto avanzar hacia el usuario final; (3) diseñar un sistema BCI amigable para el usuario en el reconocimiento de comandos.

Hemos estudiado el rendimiento del sistema al utilizar el paradigma de potencial evocado visualmente en estado estacionario (SSVEP). Se analizó un sistema BCI de tres clases, basado en el paradigma SSVEP y la diadema Emotiv EPOC para el desarrollo de mi proyecto.

## Referencias

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [2] J. J. Vidal, "Toward direct brain-computer communication," *Annual Review of Biophysics and Bioengineering*, vol. 2, no. 1, pp. 157–180, 1973.
- [3] A. Kübler, B. Kotchoubey, J. Kaiser, J. R. Wolpaw, and N. Birbaumer, "Brain-computer communication: unlocking the locked in," *Psychological Bulletin*, vol. 127, no. 3, pp. 358–375, 2001.
- [4] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks et al., "Brain-computer interface technology: a review of the first international meeting," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 164–173, 2000.
- [5] F. Cincotti, D. Mattia, F. Aloise et al., "Non-invasive brain-computer interface system: towards its application as assistive technology," *Brain Research Bulletin*, vol. 75, no. 6, pp. 796–803, 2008.
- [6] A. M. Holz, L. Botrel, and A. Kubler, "Bridging gaps: long-term independent BCI home-use by a locked-in end-user," in *Proceedings of the 4th TOBI Workshop*, Sion, Switzerland, January 2013.
- [7] R. Kazman, L. Bass, and B. E. John, "Bridging the gaps II: bridging the gaps between software engineering and human-computer interaction," in *Proceedings of the 26th International Conference on Software Engineering (ICSE '04)*, pp. 773–774, May 2004.
- [8] D. J. Krusienski, M. Grosse-Wentrup, F. Galan et al., "Critical issues in state-of-the-art brain-computer interface signal processing," *Journal of Neural Engineering*, vol. 8, no. 2, Article ID 025002, 2011.
- [9] F. Miralles, E. Vargiu, S. Dauwalder et al., "Brain computer interface on track to home," *The Scientific World Journal*, vol. 2015, Article ID 623896, 17 pages, 2015.
- [10] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain Computer Interfaces, a Review", *Sensors*, vol. 12, no. 2, año 2012, pages 1211-1279.
- [11] L. Demanet and L. Ying, "Wave atoms and sparsity of oscillatory patterns," *Applied and Computational Harmonic Analysis*, vol. 23, no. 3, pp. 368–387, 2007.
- [12] A. A. Mohammed, Q. M. Jonathan Wu, and M. A. Sid-Ahmed, "Application of wave atoms decomposition and extreme learning machine for fingerprint classification," in *Image Analysis and Recognition*, A. Campilho and M. Kamel, Eds., vol. 6112 of *Lecture Notes in Computer Science*, pp. 246–255, Springer, 2010.
- [13] H. Xu and G. Zhai, "ECG data compression based on wave atom transform," in *Proceedings of the 3rd IEEE International Workshop on Multimedia Signal Processing (MMSP '11)*, Hangzhou, China, November 2011.