

# Caracterización de señales de **EEG relacionadas a potenciales evocados visuales en estado estacionario**

Cristian Felipe Blanco-Díaz<sup>1</sup>  
Universidad Antonio Nariño  
[cblanco88@uan.edu.co](mailto:cblanco88@uan.edu.co)

Andrés Felipe Ruiz-Olaya<sup>2</sup>  
Universidad Antonio Nariño  
[andresru@uan.edu.co](mailto:andresru@uan.edu.co)

DOI: <https://doi.org/10.21158/23823399.v7.n0.2019.2459>

**Fecha de recepción:** 09 de septiembre de 2019

**Fecha de aprobación:** 07 de diciembre de 2019

**Cómo citar este artículo:** Blanco-Díaz, C. F.; Ruiz-Olaya, A. F. (2019). Caracterización de señales de EEG relacionadas a potenciales evocados visuales en estado estacionario. *Revista Ontare*, 7, 11-26.

DOI: <https://doi.org/10.21158/23823399.v7.n0.2019.2459>

<sup>1</sup> Estudiante de último semestre del programa de Ingeniería Biomédica de la Universidad Antonio Nariño. Integrante del grupo de investigación de Bioingeniería, dedicado a las líneas de investigación y análisis de información biomédica, bioinformática, biónica y robótica médica, Ingeniería clínica, Ingeniería de rehabilitación y discapacidad y E-Salud. **ORCID:** <https://orcid.org/0000-0002-8083-7454>

<sup>2</sup> Ingeniero Electrónico de la Universidad del Valle (Colombia), con Especialización en Robótica de la Universidad Politécnica de Madrid (España), y Doctorado en Ingeniería Eléctrica, Electrónica y Automática de la Universidad Carlos III de Madrid (España). **ORCID:** <https://orcid.org/0000-0002-5883-5786>







# RESUMEN

Uno de los paradigmas más utilizados en la literatura para la implementación de un sistema EEG BCI son los potenciales evocados visuales en estado estacionario, estos normalmente surgen en la corteza occipital del cerebro. Para poder visualizar, extraer y clasificar estos, se requieren una serie de etapas. La metodología del estudio se dividió en las fases iniciales en el diseño de un sistema BCI: adquisición, preprocesamiento, extracción y clasificación. En este estudio, se realizó una caracterización de estos potenciales desde la adquisición utilizando el equipo g. Nautilus con el estándar 10-20 de la Universidad Antonio Nariño hasta la clasificación de los datos utilizando los métodos matemáticos CCA y SED en diferentes ventanas de tiempo. Así pues, puesto que en la implementación de un sistema BCI en tiempo real se espera que el tiempo de clasificación sea lo más corto posible para la ejecución rápida de un comando, este tipo de estudios permiten identificar cuáles métodos son los más válidos en la clasificación de estos datos, así como algunas variables a tener en cuenta. Los resultados permiten identificar, entonces, una mejor efectividad en la clasificación de datos con CCA que con SED, además del comportamiento del sistema según las ventanas de tiempo.

**Palabras clave:** Análisis electroencefalográfico; señales de electroencefalografía —EEG; Brain Computer Interface – BCI-; caracterización de potenciales; clasificación de datos; ejecución de comandos.





## Characterization of EEG signals related to **visual evoked potentials in steady state**

# ABSTRACT

One of the paradigms that has been mostly used in the literature for the implementation of an EEG BCI system is the visual evoked potentials in steady state, which normally arise in the occipital cortex of the brain. There is a series of stages that are required in order to visualize, extract, and classify them. The initial phases of the methodology in this study were divided into acquisition, pre-processing, extraction, and classification, just as in the design of an IBD system. This study makes a characterization of these potentials, from the acquisition using the g. Nauti-lus equipment with the 10-20 standard of Universidad Antonio Nariño until the classification of the data using the CCA and SED mathematical methods in different time windows. Thus, the implementation of a real-time BCI system is supposed to have a classification time that is as short as possible for the rapid execution of a command; this type of study allows the identification of the best methods to be used in the classification of these data, as well as some variables that can be taken into account. The results allow to identify, then, greater effectiveness in the classification of data with CCA than with SED, as well as the fact that the system behaves according to the time window.

**Keywords:** electroencephalographic analysis; electroencephalographic signals (EEG); Brain Computer Interface (BCI); characterization of potentials; data classification; command execution.



## Caracterização de sinais de EEG relacionados a **potenciais evocados visuais em estado estacionário**

# RESUMO

Um dos paradigmas mais utilizados na literatura para a implementação de um sistema EEG BCI são os potenciais evocados visuais em estado estacionário, que normalmente surgem no córtex occipital do cérebro. Para visualizar, extrair e classificá-los, são necessárias várias etapas. A metodologia do estudo foi dividida nas fases iniciais do projeto de um sistema BCI: aquisição, pré-processamento, extração e classificação. Neste estudo, foi realizada uma caracterização desses potenciais desde a aquisição utilizando o equipamento g. Nautilus com o padrão 10-20 da Universidade Antonio Nariño até a classificação dos dados usando os métodos matemáticos CCA e SED em diferentes janelas de tempo. Assim, como na implementação de um sistema BCI em tempo real, espera-se que o tempo de classificação seja o mais curto possível para a execução rápida de um comando, esse tipo de estudo permite identificar quais métodos são os mais válidos na classificação desses dados, bem como algumas variáveis a serem consideradas. Os resultados permitem identificar, então, uma melhor efetividade na classificação dos dados com o CCA do que com o SED, além do comportamento do sistema de acordo com as janelas de tempo.

**Palavras-chave:** Análise eletroencefalográfica; sinais de eletroencefalografia - EEG; Brain Computer Interface - BCI-; caracterização de potenciais; classificação de dados; execução de comandos.





## Caractérisation des signaux EEG liés aux potentiels visuels à l'état d'équilibre

# RÉSUMÉ

L'un des paradigmes les plus largement utilisés dans la littérature pour la mise en œuvre d'un système EEG BCI est le potentiel visuel à l'état d'équilibre qui se produit normalement dans le cortex occipital du cerveau. Pour visualiser ces signaux, les extraire et les classer, une série d'étapes est nécessaire. La méthodologie de l'étude se divise en phases initiales de conception d'un système BCI: acquisition, prétraitement, extraction et classification. Nous caractériserons ces potentiels d'acquisition à l'aide de l'équipement g. Nautilus sous la norme 10-20 de l'Université Antonio Nariño de classification des données et en utilisant les méthodes mathématiques CCA et SED sous différentes fenêtres temporelles. Ainsi, comme dans l'implémentation d'un système BCI en temps réel, on s'attend à ce que le temps de classification soit le plus court possible pour l'exécution rapide d'un ordre. Ce type d'étude permet d'identifier quelles méthodes sont les plus valables pour la classification des données et la prise en compte des variables. Les résultats permettent d'identifier l'efficacité de la classification des données via CCA et SED ainsi que du comportement du système en fonction des fenêtres temporelles.

**Mots clés:** analyse électroencéphalographique; signaux d'électroencéphalographie - EEG; Interface cerveau-ordinateur - BCI-; caractérisation potentielle; classification des données; exécution de la commande.



## 1. Introducción

Según la Organización Mundial de la Salud o OMS, en su última encuesta realizada en el 2010, cerca del 15,6 % de la población mundial sufre de alguna discapacidad, y el 2,2 % tiene dificultades muy significativas de funcionamiento neuromotor (OMS, 2011). Por tal motivo, durante los últimos años desde la ingeniería de rehabilitación se han propuesto diferentes métodos que permiten mejorar la calidad de vida de esta población, entre los cuales se encuentran las interfaces cerebro-computador o BCI. Aun así, esta tecnología no permite reconocer por completo la intención del usuario respecto a una acción (Becedas, 2012; Boelts, Cerquera y Ruiz, 2015), por lo cual se implementan diferentes técnicas para la extracción de información cerebral por medio de la medición de señales de electroencefalografía — EEG— con electrodos no invasivos, normalmente usando el estándar 10-20.

Entre estas señales se encuentran los potenciales evocados que aparecen cuando se presentan estímulos continuos y están relacionados con la fase de la señal y los potenciales inducidos que aparecen cuando se presenta algún estímulo discreto, lo cual, a su vez, está relacionado con el cambio de amplitud o potencia de la señal. En los potenciales evocados, los más usados corresponden a los potenciales evocados visuales en estado estacionario o SSVEP (Inkaew, Charoenkitkamjorn, Yangpaiboon, Phothisonothai y Nuthong, 2015). Estos se registran en la parte occipital de la corteza cerebral cuando al usuario se le presentan estímulos de cierta característica frecuencial. Las fases para el diseño de un BCI basado en SSVEP se pueden clasificar en cinco: adquisición, preprocesamiento de la señal, extracción de características, clasificación y aplicación. En las dos primeras fases se adquieren los datos por medio de EEG y se implementan, a su vez, diferentes métodos de rechazo a fin de reducir la presencia de artefactos externos, como, por ejemplo, el ruido. Con el propósito de facilitar el acceso y el almacenamiento de estas señales normalmente se guardan en una base de datos para un posterior análisis (Lee *et al.*, 2019).





En la tercera etapa se utilizan diferentes métodos matemáticos. Entre los más usados se encuentran el análisis de correlación canónico o CAA y el análisis de densidad de energía espectral o SED (Wei, Xiao y Lu, 2011). En la cuarta fase se clasifican los resultados de las fases anteriores con el fin de identificar la intención del usuario, de manera que permite así en la última fase ejecutar una acción de control para dispositivos externos (Liu *et al.*, 2018). En el presente trabajo, liderado por el grupo de bioingeniería de la Universidad Antonio Nariño o UAN, mediante el equipo *g.Nautilus* de electroencefalografía se realiza la adquisición de potenciales evocados visuales de cinco sujetos de prueba durante dos o tres sesiones. Para la adquisición de los datos se hace uso de cinco canales EEG del estándar 10-20: PO7, PO3, OZ, PO4 y PO8. El experimento consiste en presentarle a los sujetos de prueba, en una pantalla con fondo negro, cuatro estímulos: arriba, abajo, derecha e izquierda, con diferentes frecuencias: 6,67, 7,51, 8,545 y 10 Hz. Los potenciales evocados visuales en estado estacionario se analizan en el dominio de la frecuencia usando los métodos de CAA y SED, debido a que uno de los objetivos principales de un sistema BCI en línea es la ejecución de comandos en el menor tiempo posible. Este análisis se realiza en diferentes ventanas de tiempo.

## 2. Materiales y métodos

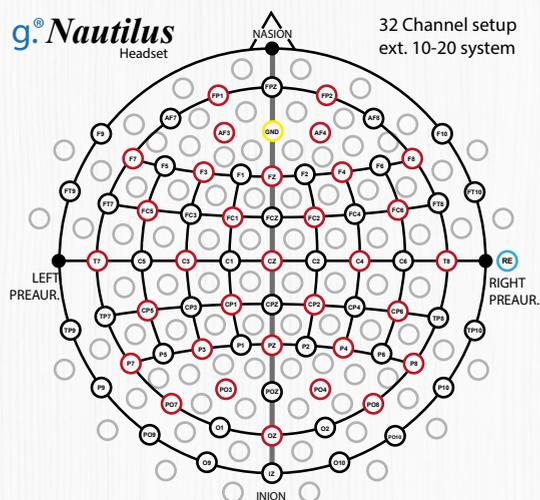
La metodología del estudio se dividió en las fases iniciales en el diseño de un sistema BCI: adquisición, preprocesamiento, extracción y clasificación.

### 2.1 Adquisición de las señales de EEG

En esta primera fase se hace uso del sistema *g.Nautilus* de la Universidad Antonio Nariño, el cual permite el registro de señales de EEG de hasta 32 canales del estándar 10-20.



**Figura 1.** Canales de electrodos disponibles en el equipo g.Nautilus PRO 32 de la UAN



**Fuente.** g.tec medical engineering GmbH, 2017.

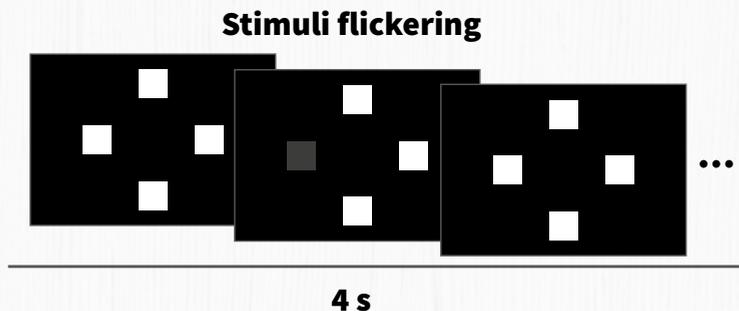
Al seguir los lineamientos que surgen en la literatura (Inkaew et al., 2015; Lee et al., 2019; Wei et al., 2011), se concluye que la región de la corteza cerebral en la que aparecen los potenciales evocados visuales corresponde a la parte occipital, por lo que se definen cinco canales de esta región: PO7, PO3, OZ, PO4 y PO8, los cuales registrarán los datos de electroencefalografía a una frecuencia de muestreo de 250 Hz.

Para que los potenciales evocados visuales sean evidentes, es necesaria la presentación de estímulos con ciertas características frecuenciales. Por tanto, se toman como base ciertos estudios realizados para la adquisición de este tipo de bioseñales (Lee et al., 2019) en la selección de estímulos. Así mismo, se escogen cuatro estímulos que parpadean en diferentes frecuencias: 6,65, 7,51, 8,545 y 10 Hz.





**Figura 2.** Presentación de los cuatro estímulos a diferentes frecuencias en el momento de la adquisición



**Fuente.** Lee, *et al*, 2019.

El experimento consiste en que un sujeto de prueba observe fijamente alguno de los cuatro estímulos durante 20 segundos. Posterior a esto, siguiendo el sentido horario, realiza el mismo procedimiento con los estímulos visuales restantes. Los primeros tres sujetos de prueba realizaron tres sesiones, mientras que los restantes realizaron el experimento dos veces, para un total de 13 intentos.

## 2.2 Preprocesamiento de la señal

En el momento de la adquisición se implementa un filtro pasa bandas de entre 0,5 y 60 Hz, lo que reduce la contaminación de ruido en la señal. Además de un filtro notch que permita rechazar el ruido producido por la línea de corriente alterna —60 Hz—. El sistema de adquisición se realiza en la plataforma Simulink de Matlab y los datos de EEG quedan guardados como un archivo tipo .mat. El análisis de los datos se realiza en la plataforma Matlab, donde inicialmente se vuelve a implementar un filtro, esta vez digital, de tipo pasa banda, de entre 4 Hz y 40 Hz a fin de atenuar aún más el ruido.

Luego se realiza un análisis superficial con los datos segmentados en cuatro situaciones —uno por cada frecuencia presentada—, y se eliminan los dos primeros y los dos últimos segundos de cada intervalo, a fin de trabajar con mayor exactitud, dado que el usuario tiende a distraerse o parpadear



en el momento entre estímulos. Por tanto, al final quedan cuatro segmentos con intervalos de 16 segundos. Este análisis se realiza en el dominio de la frecuencia al aplicar la transformada rápida de Fourier en las señales de EEG, en la se pueden apreciar componentes frecuenciales de gran amplitud en los valores de las frecuencias presentadas en los estímulos visuales junto con sus armónicos.

## 2.3 Extracción y clasificación de los datos

En esta fase se utilizan dos métodos para la extracción de características de los SSVEP: el análisis de correlación canónico o CCA y el análisis de densidad espectral o SED.

El CCA consiste en la comparación de dos señales cuya coincidencia se ve reflejada en el valor del índice de correlación —entre el 0 y el 1—. Los valores del espectro de las señales EEG para aplicar este método matemático deben tener una señal de referencia, en este caso se implementan señales sinusoidales cuyos componentes frecuenciales coincidan con la frecuencia de los estímulos presentados.

$$y(t) = \sin(2\pi ft) \begin{cases} f = 6.65 \text{ Hz} \\ f = 7.51 \text{ Hz} \\ f = 8.545 \text{ Hz} \\ f = 10 \text{ Hz} \end{cases} \quad (1)$$

El SED se realiza mediante la segmentación del espectro de las señales EEG, para lo cual se usan filtros pasa banda cuya frecuencia central corresponde a las frecuencias presentadas en los estímulos, y, posteriormente, al calcular la energía presente en este espectro resultante.

$$E = \frac{1}{2\pi} \int_{-\infty}^{\infty} |X(w)|^2 dw \quad (2)$$





La clasificación de los datos se realiza mediante la implementación de cada segmento en las ecuaciones (1) y (2). Con el CCA aquella frecuencia que genera el índice más alto de correlación se clasifica como la frecuencia del estímulo, la cual el sujeto de prueba observaba en ese instante de tiempo. Por otra parte, en el SED aquel componente de frecuencia que tenga el índice de energía espectral más alto se clasifica como la frecuencia del estímulo que el sujeto de prueba observaba en ese instante. Posterior a esto el sistema se evalúa en diferentes ventanas de tiempo al implementar el CCA y el SED en ventanas de 1, 1.5, 2, 2.5, 3, 3.5, 4 y 4.5 segundos, lo cual permite encontrar una relación entre esta variable y la precisión del sistema.

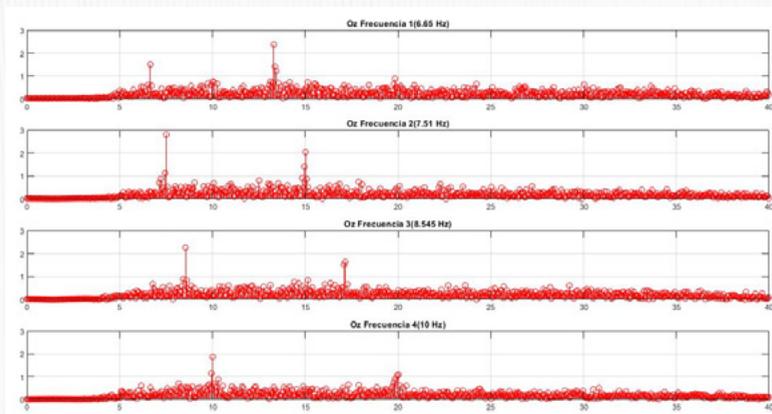
$$P (\%) = \frac{\# \text{ de aciertos en la identificación de estímulos}}{\# \text{ total estímulos}} * 100 \quad (3)$$

### 3. Resultados y discusión

Inicialmente, a fin de facilitar el procesamiento de los algoritmos implementados en las ecuaciones (1) y (2), lo más conveniente es realizar un reordenamiento de los datos. Esto, debido a que no todos los sujetos de prueba empezaron por el mismo estímulo, por lo que —por medio de la FFT— es posible obtener información sobre la frecuencia del estímulo que observaba en ese intervalo de tiempo. Los datos se organizan por orden de frecuencia ascendente, esto es, 6,65 Hz, 7,51 Hz, 8,545 Hz y 10 Hz.



**Figura 3.** Espectro en frecuencia de las señales de EEG adquiridas por el canal Oz, en cada intervalo de tiempo de 16 segundos



**Fuente.** Elaboración propia.

Como se puede observar en la figura 3, en el dominio de la frecuencia se presentan componentes de gran amplitud sobre las frecuencias de los estímulos y sus armónicos, por lo que esto podría funcionar como base para un sistema BCI en tiempo real ligado a la ingeniería de rehabilitación. En el sistema los métodos de clasificación cuentan con algoritmos matemáticos. En este estudio el CCA se usa en conformidad con los espectros de las señales dados por la ecuación (1), en la que el sistema se evalúa según el índice de correlación más alto y si este corresponde a la frecuencia del estímulo que el sujeto observaba. El SED se realiza de forma similar. Sin embargo, según la energía que se obtiene en la ecuación (2), se tiene en cuenta el segmento de frecuencias que cuente con mayor energía y si esta corresponde a la frecuencia del estímulo que el sujeto miraba. Según esto, con la ecuación (3) se analiza si el estímulo detectado por el algoritmo equivale al estímulo observado por el sujeto, de manera que define la precisión del algoritmo. Este procedimiento se analiza en las diferentes ventanas de tiempo y se obtienen los resultados que se presentan en la tabla 1.





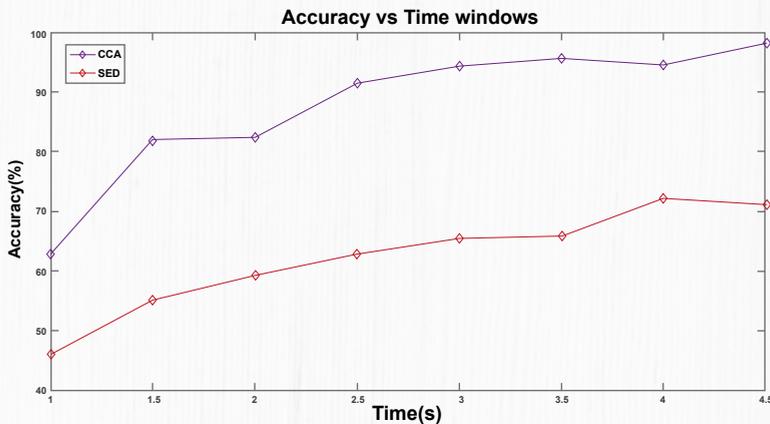
**Tabla 1.** Precisión del sistema en varias ventanas de tiempo

| Ventana de tiempo(s) | CCA                 |                | SED                 |                |
|----------------------|---------------------|----------------|---------------------|----------------|
|                      | Precisión media (%) | Desviación (%) | Precisión media (%) | Desviación (%) |
| 1                    | 62,78               | ± 8,63         | 46,03               | ±12,75         |
| 1.5                  | 82,03               | ± 7,14         | 55,46               | ± 15,69        |
| 2                    | 82,41               | ± 6,47         | 59,34               | ± 16,34        |
| 2.5                  | 91,35               | ± 2,62         | 62,88               | ± 18,68        |
| 3                    | 94,23               | ± 3,79         | 65,39               | ± 18,73        |
| 3.5                  | 95,6                | ± 4,41         | 65,93               | ± 17,23        |
| 4                    | 94,55               | ± 6,88         | 72,11               | ± 16,78        |
| 4.5                  | 98,08               | ± 3,25         | 71,15               | ± 18,61        |

**Fuente.** Elaboración propia.

En una gráfica de precisión vs. ventanas de tiempo se puede observar la relación que existe entre estas dos métricas.

**Figura 4.** Precisión vs ventanas de tiempo según método de clasificación CCA y SED



**Fuente.** Elaboración propia.



Como se puede observar en la figura 4, existe una proporcionalidad directa entre la precisión y las ventanas de tiempo, debido a que cuanto mayor es el intervalo de tiempo para el análisis se cuenta con una mayor cantidad de datos. No obstante, en la implementación de un sistema BCI en tiempo real se espera que el tiempo de clasificación sea lo más corto posible para la ejecución rápida de un comando, por lo que este tipo de estudios permiten identificar cuáles métodos son los más válidos en la clasificación de estos datos, así como algunas variables a tener en cuenta.

## 4. Conclusiones

Este estudio permite identificar características de las señales de EEG conocidas como «potenciales evocados visuales en estado estacionario», lo cual permite reconocer ciertas variables a tener en cuenta. Entre ellas fue posible identificar una mejor efectividad en la clasificación de datos con CCA que con SED, además del comportamiento del sistema según las ventanas de tiempo. Como estudios futuros se usará esta información resultante del análisis SSVEP *off line* para la implantación de un sistema BCI en tiempo real.





## Referencias

- Becedas, J. (2012). Brain machine interfaces: basic and advances. *IEEE Transactions on Systems, Man and Cybernetics*, 42(6), 825-836.  
DOI: <https://doi.org/10.1109/TSMCC.2012.2203301>
- Boelts, J.; Cerquera, A.; Ruiz, A. (2015). Decoding of imaginary motor movements of fists applying spacial filtering in a BCI simulated. En J. Ferrández Vicente; F. Álvarez-Sánchez de la Paz López; H. Toledo-Moreo (eds.), *Artificial Computation in Biology and Medicine*. Cham: Springer.  
DOI: [https://doi.org/10.1007/978-3-319-18914-7\\_16](https://doi.org/10.1007/978-3-319-18914-7_16)
- g.tec medical engineering GmbH (2017). *Instruction for use V1.16.06 g.Nautilus PRO*. Recuperado de [http://nbt ltd.com/wp-content/uploads/2018/05/gnautilus\\_pro\\_instructionforuse\\_fda.pdf](http://nbt ltd.com/wp-content/uploads/2018/05/gnautilus_pro_instructionforuse_fda.pdf)
- Inkaew, N.; Charoenkitkamjorn, N.; Yangpaiboon, C.; Phothisonothai, M.; Nuthong, C. (2015). Frequency component analysis of eeg recording on various visual tasks: steady-state visual evoked potential experiment. En *7th International Conference on Knowledge and Smart Technology (KST)* (pp. 180-183). Faculty of Informatics, Burapha University, Chon buri, Tailandia. DOI: <https://doi.org/10.1109/KST.2015.7051483>
- Lee, M.-H.; Kwon, O-Y.; Kim, Y.-K.; Kim, H. K.; Lee, Y.-E.; Williamson, J.; Fazli, S.; Lee, S.-W. (2019). EEG dataset and openBMI toolbox for three BCI paradigms. *GigaScience*, 8(5), 1-16. DOI: <https://doi.org/10.1093/gigascience/giz002>
- Liu, C.; Xie, S.; Xie, X.; Duan, X.; Wang, W.; Obermayer, K. (2018). Design of a video feedback SSVEP-BCI system for a car control based on improved MUSIC method. En *6th International conference on Brain Computer Interface (BCI)* (pp. 1-4). DOI: <https://doi.org/10.1109/IWW-BCI.2018.8311499>
- OMS (Organización Mundial de la Salud). (2011). *Resumen Informe mundial sobre la discapacidad*. Ediciones de la OMS. Recuperado de [https://www.who.int/disabilities/world\\_report/2011/summary\\_es.pdf](https://www.who.int/disabilities/world_report/2011/summary_es.pdf)
- Wei, Q.; Xiao, M.; Lu, Z. (2011). Comparative study of canonical correlation analysis and power spectral density analysis for SSVEP detection. En *Third International Conference on Intelligent Human-Machine Systems and Cybernetics* (pp. 7-10). DOI: <https://doi.org/10.1109/IHMSC.2011.72>