Congr. Int. en Ing. Electrónica. Mem. ELECTRO, Vol. 39, pp. 223-228, Oct 2017, Chihuahua, Chih. México
http://electro.itchihuahua.edu.mx/memorias_electro/MemoriaElectro2017.zip
ISSN 1405-2172

METODOLOGÍA PARA GENERACIÓN Y CLASIFICACIÓN DE SSVEP EN AMBIENTE CONTROLADO

Corral S. Alma D., Rangel G. Raúl, Chacón M. Mario I.
Instituto Tecnológico de Chihuahua
División de Estudios de Posgrado e Investigación
Ave. Tecnológico No. 2909, Chihuahua, Chih., México, C.P. 31310
Tel. 52 (614) 2012000 Ext. 112
adcorral@itch.edu.mx, raul.rg07@hotmail.com, mchacon@itch.edu.mx,

RESUMEN.

La tecnología de interfaz cerebro computadora, del inglés Brain Computer Interface (BCI), es una herramienta útil en el desarrollo de sistemas de interacción hombre-computadora y una de sus posibles aplicaciones está dirigida a personas con discapacidad. Algunas investigaciones en BCI utilizan estrategias mentales entre las que destacan los potenciales evocados de estado estable (SSVEP) por su comportamiento estable y por no requerir entrenamiento del usuario final. La investigación descrita en este artículo presenta el desarrollo de una metodología para generar señales SSVEP con un damero que parpadea a cuatro frecuencias diferentes, en ambiente controlado. La actividad cerebral generada se registra mediante una diadema Emotive EPOC+® para luego ser procesada, caracterizada y clasificada con un algoritmo *support vector machine* (SVM) en ventanas de tiempo de distinta duración. Los resultados muestran un desempeño promedio de 87.475% de acierto en la ventana de mayor tamaño, 20 s, lo que puede considerarse aceptable para un clasificador y adecuado para ciertas aplicaciones BCI en donde el usuario tenga posibilidades muy bajas de comunicación.

ABSTRACT.

Brain Computer Interface (BCI) technology is a useful tool on smart computer-person interacting systems and a possible application is aimed to people with disabilities. Some BCI research works use mental strategies, among them, steady-state visual evoked potential (SSVEP) stands out, because of its stable behavior, and the final user does not require training. The work reported in this paper describes the development of a methodology to generate SSVEP signals with a four different frequencies flashing checkerboard on controlled environment. Brain activity generated is recorded through the Emotive EPOC+ headset to be processed, characterized and classified, with a *support vector machine* (SVM) algorithm, using different length time windows. The performance of the method turned to be 87.475% of correct classification using a window of 20 s. This result may be considered suitable for some BCI applications where the user present very low communication skills.

Keywords: BCI, generación de SSVEP.

1. INTRODUCCIÓN

La tecnología de interfaz cerebro computadora, del inglés *Brain Computer Interface* (BCI) ha emergido como una herramienta de utilidad en sistemas inteligentes de interacción hombre-computadora. Una de sus posibles aplicaciones está dirigida a personas con discapacidad motriz a quienes brinda la posibilidad de reemplazar, restaurar, mejorar y extender funciones corporales que incrementan su calidad de vida [1]. El registro de la actividad cerebral se realiza comúnmente mediante una electroencefalografía (EEG) por ser una técnica no invasiva, de costo accesible y portable [2] por medio de dispositivos comerciales como diademas y cascos con electrodos.

En la literatura aparecen investigaciones de sistemas BCI desarrollados para personas con discapacidad, enfocadas en facilitar: las funciones corporales por medio de manos ortopédicas [3][4][5], robots móviles de telepresencia [6][7] y sillas de ruedas [8][9]; la interacción con sistemas de cómputo a través de navegadores de Internet [10][11] y de control de dispositivos en el hogar [2]; la comunicación con otras personas mediante deletreadores o generadores de palabras [12][13][14]. Sin embargo, los grados y tipos de discapacidad motivan el incremento en la variedad de aplicaciones y el mejoramiento de estrategias mentales utilizadas en el desarrollo de éstas, para ofrecer más alternativas o de mayor adaptación a los usuarios.

Dentro de las estrategias mentales utilizadas en la literatura, destaca la SSVEP por mostrar un comportamiento estable y que no requiere de entrenamiento en el usuario final. Por ejemplo en [15], el SSVEP se aplica en la comunicación humano-robot mediante el uso de 8 electrodos y un estímulo a la vez. En [16] se define una nueva metodología para la detección SSVEP con el uso de 6 electrodos. Sin embargo, tanto en estos trabajos como en otra literatura consultada, no se reporta un estudio que indique la metodología a seguir para dar mayor certeza en la generación del SSVEP en entornos controlados y con un uso mínimo de electrodos que propicien la correcta detección del estímulo en personas con discapacidad. Por tal motivo, se alentó el desarrollo de la presente investigación que pretende definir una metodología de este tipo para incorporarla en un trabajo futuro en un deletrador basado en BCI dirigido a personas con discapacidad del habla, que les podrá brindar la posibilidad de expresar sus necesidades físicas elementales

como tomar agua, ingerir alimentos, recibir medidas de higiene y hasta comunicar sentimientos, pensamientos y decisiones.

2. MÉTODO

2.1. Adquisición de señales

Para generar los SSVEP, fueron sometidos 4 sujetos de estudio a sesiones de estímulos mediante dameros que parpadean a determinada frecuencia que generan la ilusión de que los cuadros están cambiando de lugar y un estímulo de movimiento genera más actividad neuronal que uno estático [17]. Los dameros empleados son con patrón de colores blanco y negro en 4x4 cuadros internos y un cuadro rojo en el centro para que el usuario enfoque su mirada. En la figura 1 se muestra un damero con las dimensiones empleadas.

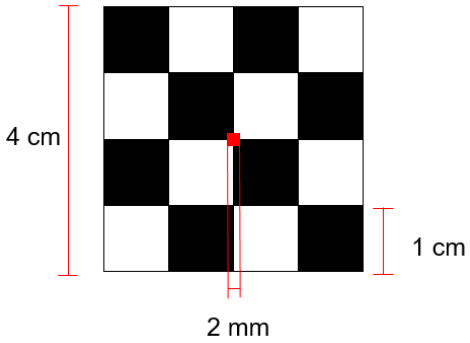

Figura 1. Damero con patrón de colores blanco y negro.

Las dimensiones de los cuadros internos se determinaron al fijar un ángulo de visión de 1 grado que debe tener el sujeto de pruebas al mirar el cuadro interno del estímulo a una distancia común de 55 cm al mirar la pantalla de una computadora. El ángulo de visión de 1 grado es usual en la generación de potenciales evocados visuales en procedimientos clínicos [18]. En la figura 2 se muestran tales dimensiones:

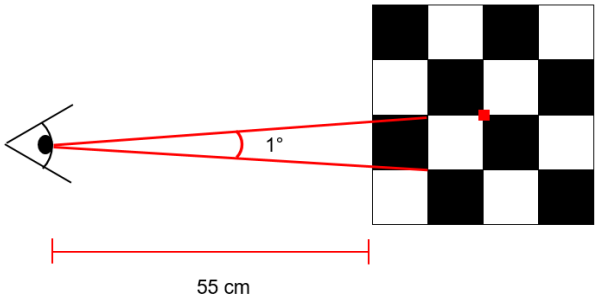

Figura 2. Ángulo de visión de 1 grado.

La dimensión de los cuadros internos del damero se define por:

$$x = 2*\left(D*\arctan\left(\frac{\theta}{2}\right)\right) \tag{2.1}$$

donde D es la longitud en centímetros entre el ojo del usuario y la pantalla donde están los estímulos, y θ es el ángulo de visión que se desea obtener.

Estos dameros fueron presentados a los sujetos de estudio a 4 frecuencias distintas. Para seleccionar los valores de frecuencias de parpadeo se realizaron dos consideraciones: que una frecuencia no debe ser múltiplo de otra para evitar falsos positivos por armónicos y que deben evitarse frecuencias dentro de la banda alfa, especialmente entre los 10 y 11 Hz debido a que en la región occipital del cerebro se presenta gran actividad de este tipo al cerrar y abrir los ojos y la información generada por esta actividad podría presentar una mayor amplitud que la que se genera por un SSVEP.

Las frecuencias de parpadeo entonces fueron definidas mediante la fórmula:

$$Fe = \frac{Fp}{n} \tag{2.2}$$

donde Fp se refiere a la frecuencia de actualización de la pantalla y n es un número entero de manera que las frecuencias obtenidas son: 6 Hz cuando n=10, 6.6 Hz cuando n=9, 7.5 Hz cuando n=8 y 8.57 Hz cuando n=7.

Asimismo, se mantuvieron bajo control ciertas variables externas para facilitar que las características de las muestras fueran consistentes y que los cambios producidos en ellas fueran inducidos puramente por el sujeto de pruebas como respuesta al estímulo visual del damero y no por condiciones externas. Las variables bajo control son:

Iluminación. Se debe contar con una iluminación baja [19]. Se obtuvieron las muestras en habitación con 4 luxes en promedio.

Luces parpadeantes. No deben existir dentro del campo de visión del usuario.

Elementos distractores. No deben existir dentro del campo de visión del usuario [20].

Postura. Se sugiere tener una postura cómoda y similar en todos los casos [20]. Los sujetos de prueba utilizaron una silla con descansa brazos para tener una postura uniforme.

Temperatura. Debe ser agradable para el sujeto de pruebas. Se mantuvo un rango entre los 22 y 26 °C durante la toma de muestras.

Para registrar las señales cerebrales, se utilizó la diadema Emotiv EPOC+® por reunir las siguientes características:

- Es un dispositivo comercial y accesible en costo para cualquier persona, diferencia de otros como los utilizados en [15][16].
- Ofrece frecuencia de muestreo de 128 Hz, que es suficiente para muestrear la frecuencia de parpadeo más alta de los dameros que es de 8.57 Hz.
- Cuenta con 14 electrodos para adquisición de señales de EEG, de los cuales fueron seleccionados el O_1 y O_2 que se posicionan en el lóbulo occipital, área cerebral en donde se

encuentra la corteza visual. De acuerdo a [21], estos electrodos son suficientes para la obtención de las señales SSVEP.
- Proporciona datos crudos de las señales EEG.
- Tiene resolución mayor a 10 µV, que es el rango de amplitud que tienen los potenciales evocados [22].
- Tiene un rango dinámico mayor a ±10 µV para no tener perdida de información.

La lectura de los electrodos O_1 y O_2 se realiza mediante el software TestBench. Para ello, son sometidos a prueba 4 sujetos a los que se les presentan los dameros a las 4 frecuencias obtenidas mediante (2.2). Por cada sujeto se adquieren 30 muestras por estímulo, dando un total de 120 muestras de aproximadamente 20 segundos por sujeto. La frecuencia de muestreo es de 128 Hz y fueron descartadas las señales donde se presentaron artefactos por desconexión de electrodos, es decir, solo se consideraron aquellas en las que ambos electrodos hicieron un registro efectivo.

2.2. Preprocesamiento de señales.

Partiendo de las 120 muestras de 20 s registradas por sujeto, se crearon muestras de 10 y 5 s para analizar posteriormente ventanas de 20, 10 y 5 s. Los datos utilizados para generar las ventanas de 10 y 5 s son los primeros de las muestras de 20 s.

A cada señal se le aplicó la DFT definida por

$$X_c(k) = \sum_{n=1}^{N-1} x_c(n) e^{-j\frac{2\pi kn}{N}}, \; j = 1,...,n \quad , k = 1,...,n \quad c = \{O_1, O_2\} \qquad (2.3)$$

donde n es el índice de tiempo discreto, k es el índice de frecuencia, N el tamaño de la señal, $x_c(n)$ la señal EEG en tiempo discreto, c se refiere al canal de las señales EEG, donde O_1 es la señal proveniente del electrodo O_1 y O_2 es la señal proveniente de del electrodo O_2. Luego se realiza un ajuste para eliminar la mitad redundante y el escalamiento en $N/2$ mediante:

$$Y_c(k) = \left| 2X_c(k)/N \right| \qquad para \qquad 1 \le k \le N/2+1 \qquad (2.4)$$

2.3. Extracción de características

La característica que define a un SSVEP es la componente de frecuencia con mayor amplitud en la señal. Primero se acota $Y_c(k)$ a la banda entre 5.6 Hz y 9 Hz para que contenga solo la banda de las 4 frecuencias de parpadeo definidas con (2.2). Para ello, se calcula la resolución de la frecuencia en Hz mediante:

$$\mathrm{R_{fft}} = \frac{\mathrm{Fs}}{\mathrm{N}} \qquad (2.5)$$

donde Fs es la frecuencia de muestreo. Luego se recorta la señal $Y_c(k)$ de la siguiente forma:

$$\mathrm{Y}_{fc}(\mathrm{k}) = \left\{ \mathrm{Y}_c(\mathrm{k}) \;\; | \;\; \frac{5.6}{\mathrm{R}_{fft}} \le \mathrm{k} \le \frac{8.8}{\mathrm{R}_{fft}} \right\} \qquad (2.6)$$

donde el 5.6 y el 8.8 se refieren a los límites inferior y superior de las frecuencias de estímulo, con cierta tolerancia. Una vez obtenido el vector $Y_{fc}(k)$ acotado dentro de las frecuencias de interés, se procede a encontrar los índices de las amplitudes máximas de la DFT llamados k_{O1} y k_{O2}, los cuales corresponden a los canales O_1 y O_2 respectivamente, luego se obtienen los valores de frecuencia que les corresponden:

$$f_{ij}(k+1) = k\mathrm{R_{fft}} \qquad \text{para } i\text{=20s, 10s, 5s ; } j\text{=O1, O2;} \qquad (2.7)$$

mismos que serán definidos como características de frecuencia. Este procedimiento se realiza a cada muestra de las ventanas de 20, 10 y 5 s y se guardan en un vector en el orden siguiente: los primeros dos elementos corresponden a las características obtenidas cuando se aplicó el estímulo de 6 Hz, los siguientes corresponden al de 6.6 Hz, los siguientes al de 7.5 Hz y los últimos al de 8.57 Hz:

$$f_{caract} = \{ f_{iO1}, f_{iO2} \} \qquad (2.8)$$

2.4. Clasificación de señales

En esta investigación se optó por implementar un clasificador *support vector machine* (SVM) debido que tiene una velocidad de predicción rápida, un uso de memoria medio y una interpretabilidad fácil, además de que permite trabajar al mismo tiempo con la información de los 2 canales: O_1 y O_2. Las características (f_{caract}) para el entrenamiento del clasificador, se tomaron de un solo sujeto de prueba, ya que al ser similares entre todos los sujetos, sería redundante crear un clasificador para cada uno. El sujeto elegido fue el que tuvo una mayor precisión en las características de todas las muestras de la ventana de 20 s. Para realizar la clasificación se definieron 4 clases que corresponden a la frecuencia de parpadeo del damero como se muestra en la tabla 1

Tabla 1. Nombres de clases definidas

Rangos de frecuencia	Nombre de clases
5.600 – 6.150	Derecha
6.175 – 6.800	Izquierda
6.775 – 7.600	Abajo
7.600 – 8.800	Arriba

Luego se genera una función discriminante lineal (FDL) $H(f_{caract})$ que separa un espacio geométrico de características en 2 clases mediante un hiperplano que generalmente es $H(f_{caract})=0$. La función $H(f_{caract})$ se genera mediante un conjunto de vectores que se les conoce como vectores de soporte [22] En este trabajo fue utilizada la función $f\ ()$ de

Matlab® para generar un conjunto de FDL para los casos multiclases. Esta función pide como parámetros de entrada las características f_{caract} y también la clase a la que pertenecen. Por defecto la función regresa un clasificador SVM lineal del tipo uno contra uno; este tipo quiere decir que se crea una FDL por cada par de clases. El número de FDL se define de la siguiente forma:

$$nh = nc(nc-1)/2 \tag{2.9}$$

donde *nc* es el número de clases, así que para manejar 4 clases son necesarios 6 FDL. Con las 6 FDL creadas con la función *fitecoc()* se procede a generar las ecuaciones que los definen. De manera general la ecuación de una FDL es la siguiente:

$$H(f_{caract}) = \beta_{O1} f_{iO1} + \beta_{O2} f_{iO2} + b \tag{2.10}$$

donde β_{O1} y β_{O2} son los pesos para formar la pendiente del hiperplano y b el *offset* del hiperplano. A continuación se muestran las ecuaciones de cada FDL.

$$\begin{aligned}
H_1(f_{caract}) &= -1.6917 f_{io1} - 1.6417 f_{io2} + 20.5 \\
H_2(f_{caract}) &= -0.55 f_{io1} - 1.25 f_{io2} + 11.5612 \\
H_3(f_{caract}) &= -0.1865 f_{io1} - 0.8912 f_{io2} + 7.3492 \\
H_4(f_{caract}) &= -1.1036 f_{io1} - 1.7536 f_{io2} + 19.4286 \\
H_5(f_{caract}) &= 4.5861*10^{-4} f_{io1} - 1.2505 f_{io2} + 9.0628 \\
H_6(f_{caract}) &= 2.924*10^{-4} f_{io1} - 2.2219 f_{io2} + 16.8846
\end{aligned} \tag{2.11}$$

Los hiperplanos son válidos para las señales en cualquier ventana de tiempo: 20, 10 y 5s. Para mostrar los hiperplanos de cada FDL se iguala a cero la ecuación y se toma f_{o1} para el eje horizontal y f_{o2} para el eje vertical. En la figura 3 se puede observar cada uno de los hiperplanos, teniendo a la izquierda el nombre del FDL al que corresponde cada uno.

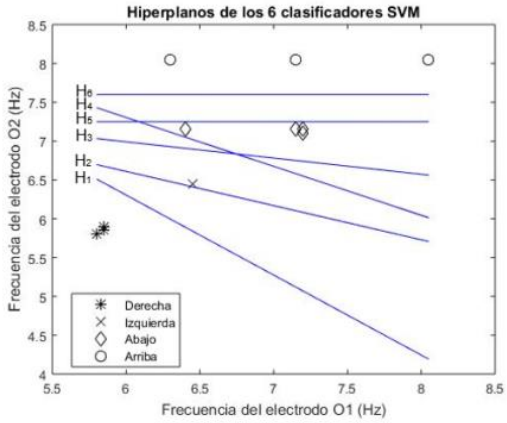

Figura 3. Hiperplanos de los 6 clasificadores SVM.

Clasificar usando el SVM es un poco más complejo, se requiere el vector f_o. Por ser un modelo de tipo uno contra uno y lineal se realiza la clasificación buscando la clase con menor pérdida binaria con la siguiente fórmula:

$$C = \underset{j}{\operatorname{argmin}} \frac{\sum_{l=1}^{L} |m_{jl}| (1 - m_{jl} H_l)/2}{\sum_{l=1}^{L} |m_{jl}|} \tag{2.12}$$

donde m_{jl} es el elemento (j, l) de la matriz de codificación *M*.

La matriz de codificación M se definió con los valores mostrados a continuación:

$$M = \begin{bmatrix} 1 & 1 & 1 & 0 & 0 & 1 \\ -1 & 0 & 0 & 1 & 1 & 0 \\ 0 & -1 & 0 & -1 & 0 & 1 \\ -1 & 0 & -1 & 0 & -1 & -1 \end{bmatrix} \tag{2.13}$$

Donde cada fila representa a una clase y cada columna a una FDL.

3. RESULTADOS

3.1. Tasa de acierto.

Para conocer el desempeño de los clasificadores, se obtienen las tasas de acierto para cada uno de los sujetos de prueba en los 3 tamaños de ventana, excepto en el caso del sujeto de prueba del que se obtendrá el desempeño para las ventanas de 10 y 5 segundos ya que las señales de 20 s fueron utilizadas para el desarrollo de los clasificadores. Cabe aclarar que por estar trabajando fuera de línea, se garantiza que todas las señales evaluadas contienen SSVEP, a sabiendas de que cuando se requiera trabajar en tiempo real se necesitará implementar otro módulo que se encargue de revisar si la señal adquirida contiene SSVEP.

La tasa de acierto se obtuvo dividiendo el número de las características f_{caract} clasificadas correctamente sobre el número de características evaluadas. En la tabla 2 se resumen los datos.

Tabla 2. Porcentajes de acierto del clasificador SVM en diferentes ventanas de tiempo.

Tamaños de ventana	20 s	10 s	5 s
Sujeto de validación	Sin analizar	85.83%	78.33%
Sujeto de pruebas 2	90.83%	77.50%	63.33%
Sujeto de pruebas 3	97.50%	90.83%	76.67%
Sujeto de pruebas 4	75.83%	59.17%	45.83%

De los datos mostrados en la Tabla 2 se observa que el porcentaje de acierto en la clasificación de las señales se incrementa de manera considerable cuando la ventana de tiempo es de 20 s; sin embargo, la tasa de acierto disminuye cuando el tiempo se reduce a 10 s y más aún, a 5 s. La

tendencia observada es que la tasa de acierto es directamente proporcional al tamaño de la ventana de análisis.

3.2. Confusión de clases

Para analizar la forma en que se distribuye el error en la clasificación de las clases, se generaron matrices de confusión que se muestran en la figura 4:

SVM con tamaño de muestra de 5 segundos

Clase real \ Clase obtenida	Derecha	Izquierda	Abajo	Arriba
Derecha	92 76.7%	14 11.7%	3 2.5%	11 9%
Izquierda	9 7.5%	85 70.8%	7 5.8%	19 15.8%
Abajo	5 4.2%	26 21.7%	73 60.8%	16 13.3%
Arriba	10 8.3%	24 20.0%	19 15.8%	67 55.8%

SVM con tamaño de muestra de 10 segundos

Clase real \ Clase obtenida	Derecha	Izquierda	Abajo	Arriba
Derecha	106 88.3%	9 7.5%	1 0.8%	4 3.3%
Izquierda	9 7.5%	89 74.2%	8 6.7%	14 11.7%
Abajo	3 2.5%	20 16.7%	88 73.3%	9 7.5%
Arriba	5 4.2%	11 9.2%	11 9.2%	93 77.5%

SVM con tamaño de muestra de 20 segundos

Clase real \ Clase obtenida	Derecha	Izquierda	Abajo	Arriba
Derecha	86 95.6%	2 2.2%	0 0.0%	2 2.2%
Izquierda	1 1.1%	84 93.3%	0 0.0%	5 5.6%
Abajo	2 2.2%	6 6.7%	73 81.1%	9 10.0%
Arriba	2 2.2%	7 7.8%	7 7.8%	74 82.2%

Figura 4. Matrices de confusión promedio de los 4 sujetos en ventanas de 20, 10 y 5 s.

En la matriz de confusión de ventana de 20 s, solo se están considerando 90 muestras porque se están descartando las 30 muestras del sujeto de prueba que se emplearon para el entrenamiento del clasificador. De las matrices de confusión se identificó el mayor grado de error al intentar clasificar la clase *Arriba* y el mayor acierto en la clase *Derecha;* además, como se esperaba, el tamaño de la ventana afectó proporcionalmente la tasa de acierto, teniendo los porcentajes más altos en las señales de 20 s, un desempeño promedio de 87.475%, y los más bajos a los 5s. Esta disminución del desempeño en las ventanas de 10 s y 5 s se debe a que estas ventanas tienen una menor cantidad de puntos que la ventana de 20 s, lo cual afecta los resultados de la DFT, causando una disminución en la probabilidad de obtener el SSVEP. Debido a que se utiliza un solo modelo de SVM, solo se realizó un entrenamiento con las ventanas de 20 s.

4. CONCLUSIONES

Con base en los resultados experimentales, se concluye que los porcentajes de correcta clasificación son más altos entre más grande sea el tamaño de la ventana de tiempo ya que la probabilidad de que se genere un SSVEP aumenta. El porcentaje de desempeño con la ventana de 20 s, 87.475% se puede considerar aceptable para un clasificador y adecuado para ciertas aplicaciones BCI en donde el usuario tenga posibilidades muy bajas de comunicación; sin embargo un tamaño de ventana de 20 s podría ser poco práctico para ser incorporado en un BCI en otros tipos de aplicaciones en las que el usuario no esté tan limitado en sus posibilidades de comunicación. Por lo anterior, como trabajo futuro, surge la necesidad de buscar incrementar la eficiencia del clasificador en ventanas de 5 s para que su uso en aplicaciones cotidianas pueda contemplar un número mayor de posibles aplicaciones.

La ventaja del clasificador SVM, es que combina la información de los dos electrodos para la clasificación de las señales y aun cuando en la lectura de un electrodo no se haya registrado el SSVEP, existe la posibilidad de hacer una clasificación acertada con la lectura del otro electrodo que sí lo haya registrado, a diferencia de otros clasificadores en los que se elige un solo canal y se descarta el otro. Asimismo, se concluye que la clasificación de muestras erróneas se debió a que no se generó un SSVEP, o si se generó, fue con una amplitud inferior a la del ruido de la señal, que no fue posible distinguir en el dominio de la frecuencia, por lo cual al buscar la amplitud máxima dentro de la función, se escoge otra que no corresponde a una señal de SSVEP.

5. AGRADECIMIENTOS

Se agradece al Tecnológico Nacional de México por el apoyo brindado para la realización de este trabajo bajo el proyecto 5684.16-P.

6. REFERENCIAS

[1] Goran Udovicic, Ante Topic, Mladen Russo. "Wearable Technologies for smart environments: a review with emphasis on BCI", Croatian Science Foundation, Croatia, 2014.
[2] Rebeca Corralejo, Luis. F. Nicolás-Alonso, Daniel Álvarez, Roberto Hornero. “A P300-based brain-computer interface

aimed at operating electronic devices at home for severely disabled people", Medical & Biological Engineering & Computing, vol. 52, pp. 861-872, 2014.

[3] Gernot R. Müller-Putz, Reinhold Scherer, Gert Pfurtscheller, Rüdiger Rupp. "EG-based neuroprosthesis control: a step towards clinical practice", Neuroscience Letters, vol. 382, pp. 167-174, 2005.

[4] Michele Tavella, Robert Leeb, Rüdiger Rupp, José del R. Millán. "Towards natural non-invasive hand neuroprostheses for daily living", 32nd Annual International Conference of the IEEE EMBS, Buenos Aires, Argentina, 2010.

[5] Martin Rohma, Matthias Schneiders, Constantin Müller, Alex Kreilinger, Vera Kaiser, Gernot R. Müller-Putz, Rüdiger Rupp. "Hybrid brain-computer interfaces and hybrid neuroprostheses for restoration of upper limb functions in individuals with high-level spinal cord injury", Artificial Intelligence in Medicine, vol. 59, pp. 133-142, 2013.

[6] José del R. Millán, Frédéric Renkens, Josep Mouriño, Wulfram Gerstner. "Noninvasive brain-actuated control of a mobile robot by human EEG", IEEE Transactions on biomedical engineering, vol. 51, núm. 6, pp. 1026-1033, 2004.

[7] Luca Tonin, Tom Carlson, Robert Leeb, José del R. Millán. "Brain-controlled telepresence robot by motor-disabled people", 33rd Annual International Conference of the IEEE EMBS, pp. 4227-4230, 2011.

[8] Tom Carlson, José del R. Millán. "Brain-controlled wheelchairs: a robotic architecture", IEEE Robotics and Automation Magazine, vol. 20, núm 1, pp. 65-73, 2013.

[9] Fred Achic, Jhon Montero, Christian Penaloza, Francisco Cuellar. "Hybrid BCI system to operate an electric wheelchair and robotic arm for navigation and manipulation tasks", 2016 IEEE International Workshop on Advanced Robotics and its social impacts (ARSO), Shanghai, China, 2016.

[10] Víctor Martínez-Cagigal, Javier Gomez-Pilar, Daniel Alvarez, Roberto Hornero. "An asynchronous P300-Based brain-computer interface web browser for severely disabled people", Transactions on Neural Systems and Rehabilitation Engineering, aceptado para publicación 2017.

[11] Y. H. Tai, Y. J. Tian, T. W. Huang, K. T. Sun. "Brainwave technology gives Internet access to the physically disabled", 2013 Fourth Global Congress on Intelligent Systems, Hong Kong, China, 2013.

[12] Jeong-Hwan Lim, Jun-Hak Lee, Han-Jeong Hwang, Dong Hwan Kim. "Development of a hybrid mental spelling system combining SSVEP-based brain–computer interface and webcam-based eye tracking", Biomedical Signal Processing and Control, vol. 21, pp. 99-104, 2015.

[13] Sumit Soman, B. K. Murthy. "Using brain computer interface for synthesized speech communication for the physically disabled", Procedia Computer Science, vol. 46, pp. 292-298, 2015.

[14] Yi-Chieh Lee, Wen-Chieh Lin, Fu-Yin Cherng, Li-Wei Ko. "A visual attention monitor based on steady-state visual evoked potential", IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 24, núm 3, pp. 399-408, 2016.

[15] Prueckl, Robert, and Christoph Guger. "A brain-computer interface based on steady state visual evoked potentials for controlling a robot", Bio-Inspired Systems: Computational and Ambient Intelligence, pp 690-697, 2009.

[16] Friman, Ola, Ivan Volosyak, and Axel Graser, "Multiple channel detection of steady-state visual evoked potentials for brain-computer interfaces", IEEE transactions on biomedical engineering, vol . 54, num. 4, pp 742-750, 2007.

[17] Nannan Zhang, Yang Yu, Erwei Yin, Zongtan Zhou. "Performance of virtual stimulus motion based on the SSVEP-BCI", 2016 IEEE International Symposium Computer, Consumer and Control, pp. 656-659, 2016.

[18] J. M. Trujillo, C. J. Borrego, "Potenciales Evocados Visuales", Acta Médica Colombiana, vol. 10, núm. 3, pp. 113-124, 1985.

[19] Jian Ding, George Sperling, Ramesh Srinivasan, "Attentional modulation of SSVEP power depends on the network tagged by the flicker frequency", Cerebral Cortex, vol. 16, núm. 7, pp. 1016-1029, 2006.

[20] Chetan Bondre, Deeppak Kapgate. "Steady State Visually Evoked Potentials Framework in Brain Computer Interface", International Journal of Advanced Technology in Engineering and Science, vol. 3, núm. 1, pp. 167-175, 2015.

[21] Yi-Chieh Lee, Wen-Chieh Lin, Fu-Yin Cherng y Li-Wei Ko, "A Visual Attention Monitor Based on Steady-State Visual Evoked Potential", IEEE Transactions on neural systems and rehabilitation engineering, vol. 24, num. 3, 2016.

[22] M. A. Abbasi, A. Gaume, N. Francis, G. Dreyfus, and F. B. Vialatte, "Fast calibration of a thirteen-command BCI by simulating SSVEPs from trains of transient VEPs - Towards time-domain SSVEP BCI paradigms," 7th Annual International IEEE EMBS Conference on Neural Engineering, pp. 186–189, 2015.