

Modelo de segmentación para la extracción de características de una señal EEG^{*}

José Luis-Paredes, Hiram Calvo, Jesús Figueroa Nazuno

Centro de Investigación en Computación, Instituto Politécnico Nacional,
Av. Juan de Dios Bátiz e/M.O. Mendizábal s/n, Nva. Ind. Vallejo, 07738
{paredes_a13, hcalvo, jfn}@cic.ipn.mx

Abstract. In this work, a new experimental model of feature extraction for EEG signals is proposed, having as main characteristic the generation of patterns that can be classified with less computational cost and better performance. The proposed algorithm is based on segmentation stripes of the signal applied to a test consisting on recalling the name of one color out of 4, that are presented to a subject of study in screen. During this period the EEG activity of the subject is measured with an EMOTIV device. The proposed segmentation method was applied to 100 samples to classify them according to the corresponding color, and then 9 different machine learning techniques were used. In 8 of them, the proposed model performed better; the simplicity of our model helps to achieve better performance in space and time at the time of classification.

1 Introducción

Desde sus inicios hace poco más de 30 años las Interfaces Cerebro - Computadora o BCI (por sus siglas en inglés) se han enfrentado a diversos retos de investigación y desarrollo, debido principalmente a cuestiones técnicas, análisis de información y entendimiento sobre el funcionamiento del cerebro humano. Hoy en día existen diversos estudios alrededor de este problema, por ejemplo: Imagen por Resonancia Magnética (fMRI) o Magneto encefalografía (MEG) [1, 2]; sin embargo para estos últimos se requiere de equipos altamente sofisticados con altos costos y laboratorios con condiciones adecuadas. La opción más viable para muchos de los investigadores desde los inicios hasta la fecha sigue siendo la Electroencefalografía (EEG) [3, 4]. La EEG requiere de equipos menos costosos que otras interfaces. Dentro de este contexto, los avances tecnológicos han dado paso a una nueva generación de dispositivos portátiles tales como NeuroSky o EMOTIV [5], los cuales han permitido que la investigación y el desarrollo de sistemas BCI sea más accesible. Es importante mencionar que el rendimiento obtenido en comparación con equipos profesionales es menor, debido principalmente a la frecuencia de muestreo y la capacidad de suprimir el ruido de la señal [6, 7, 8].

^{*} Agradecemos el apoyo del gobierno de México y el IPN (CONACYT-SNI, SIP-IPN, COFAA-IPN y BEIFI-IPN)

Sin importar la finalidad con la que se emplee, un sistema BCI comúnmente tiene los siguientes componentes: adquisición de señal, procesamiento de la señal, extracción de características de la señal e interpretación, como se muestra en la Figura 1.




Figura 1.- Componentes de un BCI.

En la actualidad la mayor parte del trabajo de investigación está orientado a los componentes de [9]:

- **Procesamiento:** Se utilizan técnicas tradicionales de análisis de señales principalmente para realizar el filtrado y remoción de artefactos.
- **Extracción de características:** En la mayoría de los casos se usan métodos basados en estadística como son: Análisis de Coeficientes Principales (PCA) o Patrón Espacial Común (CSP), aunque también son utilizadas técnicas tradicionales de procesamiento de señales como: Coeficientes de Predicción Legal (LPC) o *Spectrum*.
- **Interpretación:** En la mayoría de los casos se usan clasificadores de tipo Bayesiano, Logístico, Lineal y Máquinas de Soporte Vectorial (SVM).

Dentro de este contexto tenemos a la utilización de la Potencial Relación – Evento (ERP) [10] como medida de respuesta a estímulos sensoriales y/o cognoscitivos. Este tipo de estímulo está compuesto por factores exógenos que tienen que ver con el entorno físico (sonido, luz, efecto de ruido y corrientes eléctricas que puedan generar estática al momento de obtener la señal), y componentes endógenos, que están relacionados con el estado mental del individuo (estado físico, anímico y de concentración). Con la información generada por el EEG y la utilización de ERP se ha logrado encontrar patrones morfológicos que corresponden a la frecuencia y amplitud de las señales en respuesta a la presentación de estímulos externos y por el efecto de pensamiento o evocación.

El presente trabajo tiene como propósito proponer un nuevo modelo experimental de extracción de características de señales EEG al cual identificaremos como SEG (por segmentación), teniendo como principales características: la generación de datos que puedan ser clasificados más fácilmente y con un menor costo computacional.

2 Metodología experimental

2.1 Adquisición EEG

Se usó un dispositivo EMOTIV el cual consta con 14 electrodos posicionados de acuerdo al sistema 10 – 20 [11] en las siguientes regiones: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF4 como se muestra en la Figura 2, con una velocidad de muestreo de 128 Hz.




Figura 2.- Ubicación de los electrodos de acuerdo al sistema 10 – 20.

2.2 Procedimiento

El sujeto fue sentado cómodamente frente a un monitor de 14” pulgadas. Antes de comenzar con la adquisición de datos, el sujeto fue sometido a 5 sesiones de práctica con el objetivo de familiarizarlo con la prueba y mantener las condiciones exógenas de manera constante. Posteriormente a las sesiones de prueba el sujeto declaró estar tranquilo y concentrado en la tarea asignada. La prueba consistió en 40 sesiones cortas de 46 segundos con un intervalo de descanso de 60 segundos cada 5 sesiones. Una sesión consta de 12 periodos de inactividad donde se presenta el fondo blanco con una duración de 3 segundos, intercalados con periodos de actividad donde se presenta el fondo con uno de los siguientes colores: “Amarillo, Azul, Rojo, o Verde” con una duración de 1 segundo. Dentro de este periodo, el sujeto hace la evocación del nombre del color en pantalla. Al final de la prueba se tienen 10 segmentos de actividad por cada una de las sesiones. Como resultado se tiene un conjunto de datos compuesto por 100 muestras de cada uno de los colores presentados.

2.3 Análisis EEG

Cada una de las muestras representa al conjunto de datos el cual será analizado de dos formas diferentes: en la primera se tomará el conjunto de datos en bruto para aplicar el modelo propuesto; en el segundo caso, el conjunto de datos será sometido a un filtrado en el dominio de la frecuencia (aplicación de la Transformada Rápida de Fourier (FFT) para generar los coeficientes, mientras que la Transformada Inversa de

Fourier (IFFT) realiza el proceso de filtrado), para posteriormente ser analizados con los siguientes modelos: Análisis de componentes principales (PCA), Coeficientes de predicción lineal (LPC), Densidad espectral de potencia (PSD), Transformada de ondeleta discreta (DWT), Patrón espacial común (CSP). Con cada uno de los análisis realizados se generará un conjunto de datos que representa los patrones que serán sometidos a los siguientes tipos de clasificadores: Bayesianos, Máquinas de Soporte Vectorial (SVM), Regresión Lineal, entre otros. Estos clasificadores fueron elegidos debido a que son los más utilizados de acuerdo al estado del arte [9, 12, 13].

3 Modelo propuesto

El modelo experimental propuesto (SEG) para la extracción de características de una señal EEG (las cuales generalmente se encuentran representada en forma de matrices bidimensionales), consta de 3 etapas las cuales se describen a continuación:

1. Se realiza el proceso de normalización para cada uno de los canales que componen la señal.
2. Se propone un valor para N el cual representara el número de intervalos comprendidos entre 0 y 1. Por ejemplo, si se elige $N = 10$ entonces tendremos los siguientes intervalos: $[0 - .09]$, $[\.10 - .19]$, ..., $[\.9 - 1]$.
3. Para cada una de las dimensiones de análisis se realiza la sumatoria de cada uno de los valores que se encuentran dentro del intervalo correspondiente. Por ejemplo, si se tienen 5 muestras con los valores (.12, .14, .15, .19, .10), los cuales se encuentran dentro del intervalo $[\.10 - .19]$, éstos serán sumados obteniendo .70 el cual será asignado como valor final al intervalo anteriormente mencionado.

Este procedimiento se encuentra explicado de manera gráfica en la Figura 3A. En esta podemos ver representada la señal de un solo canal a manera de ejemplo; si hacemos la sumatoria de cada uno de los valores que se encuentran en el intervalo de 0.6 y 0.7 tenemos un valor total de 7.27 el cual se ve reflejado en la Figura 3.B.




Figura 3A. Señal normalizada para un solo canal.




Figura 3B. Resultado del procedimiento de sumatoria para cada uno de los intervalos.

3.1 Pseudocódigo

Entrada: Matriz EEG bidimensional $N \times M$, donde N es el número de canales y M el número de muestras.

Salida: Vector de longitud $S \times N$ donde S representa el número de segmentos (o atributos que contendrá el patrón por cada canal).

```

1  Para  $i \leftarrow 1$  hasta  $N$  hacer
2    Normalizar elementos de  $i$ 
3  Fin
4  Crear matriz  $PatronTmp_{N \times S} \leftarrow 0$ 
5  Para  $i \leftarrow 1$  hasta  $N$  hacer
6    Para  $j \leftarrow 1$  hasta  $M$  hacer
7      Para  $k \leftarrow 1$  hasta  $S$  hacer
8         $PatronTmp_{i,k} += Valor_{i,j} \in \text{Segmento}$ 
9      Fin Para
10    Fin Para
11  Fin Para
12  Para  $i \leftarrow 1$  hasta  $N$  hacer
13     $Patron = \text{ConcatHorz}(Patron, PatronTmp_i)$ 
14  Fin Para
15  Regresar  $Patron$ 

```

Algoritmo 1.- Extracción de características de una señal EEG para la generación de un patrón con N atributos.

4 Resultados

El conjunto final de análisis está constituido por 5 conjuntos de datos con 400 instancias, correspondientes a 100 muestras por cada uno de los colores: Amarillo, Azul, Rojo, Verde. Cada uno de los conjuntos de datos fue subdividido de igual manera en 80% para la fase de entrenamiento y 20% para la fase de clasificación. Cada uno fue sometido a clasificación con ayuda de los algoritmos implementados en Weka 3.7.11 sin ningún ajuste en particular para algún conjunto, teniendo como resultados los mostrados en la Tabla 1.

Tabla 1.- Tabla comparativa entre los modelos de extracción de características.

	SEG	CSP	PCA	LPC	PSD
LibSVM	88.75%	70.00%	67.50%	61.25%	55.00%
SimpleLogistic	83.75%	75.00%	68.75%	66.25%	63.75%
SMO	82.50%	73.75%	65.00%	60.00%	50.00%
BayesNet	81.25%	68.75%	61.25%	65.00%	58.75%
LibLINEAR	81.25%	50.00%	36.25%	56.25%	20.00%
RandomSubSpace	80.00%	73.75%	73.75%	66.25%	67.50%
Bagging	77.50%	68.75%	63.75%	56.25%	60.00%
RandomForest	75.00%	75.00%	70.00%	57.50%	56.25%
NNGe	65.00%	71.25%	68.75%	66.25%	58.75%
Promedio	79.44%	69.58%	63.89%	61.67%	54.44%

Como podemos observar, el modelo propuesto denominado Segmentación (SEG) tiene un mejor desempeño. Cabe mencionar que para este ejercicio en específico se ha elegido una valor de $N = 50$; sin embargo, al aumentar el número de segmentos se puede obtener un mejor resultado. Bajo el mismo contexto, para la extracción de características dentro del modelo propuesto no se utilizó ningún tipo de filtrado, ya que al momento de hacerlo se tuvo un menor rendimiento. Como ejemplo de ello, para el modelo de clasificación LibSVM sin filtrado se obtuvo un 88.75% mientras que para el mismo ejercicio, pero con los datos filtrados en el dominio de la frecuencia se obtuvo 63.75%. Las ventajas del modelo propuesto no solo se limitan a obtener un mejor resultado al momento de la clasificación, ya que este resultado lo realiza con un costo computacional inferior con respecto a los demás análisis debido principalmente al número de atributos necesarios para obtener dichos resultados.

Dentro del estado del arte, los resultados obtenidos con diversos métodos de análisis y clasificación son variados, pues existen diversas variables como equipo de adquisición de las señales EEG, condiciones de laboratorio y sujetos de prueba, así como la metodología de la prueba. Todo esto hace poco factible una comparación directa en este tipo de experimentos; sin embargo, en la mayoría de éstos se tiene un porcentaje de clasificación correcta que oscila entre el 60% y 89%. Si tenemos esto como referencia, el obtener puntajes de 65% a 88.75% parece prometedor.

5 Conclusiones

Dentro del estado de arte moderno del estudio de las señales EEG nos podemos dar cuenta de que la mayoría de las técnicas de análisis utilizadas y que presentan mejores resultados son aquellas que están basadas en técnicas estadísticas, debido principalmente a que toman en consideración las pequeñas variaciones entre cada una de las muestras. Esto es fundamental, ya que es allí en donde se encuentra la información que nos interesa en este tipo de señal. Teniendo esto en consideración y con base en los resultados podemos apreciar que los modelos SEG, CSP y PCA (los cuales son meramente estadísticos) pueden realizar una mejor extracción de características para una correcta clasificación en comparación con modelos como LPC y PSD, los cuales están basados en análisis tradicionales de señales.

Dentro del análisis de resultados se observó que el modelo propuesto tiene un mejor desempeño en la mayoría de los casos sin necesidad de hacer un filtrado en el dominio de la frecuencia a comparación de los demás, donde se obtuvo una mejor clasificación, en especial LPC y PSD. En comparación con CSP y PCA, además de obtener una mejor clasificación, el modelo propuesto tiene también como característica un menor costo computacional en tiempo de procesamiento y espacio del patrón generado.

Uno de los factores importantes a considerar es que se puede realizar una variación de la cantidad de características que pueden ser generadas; esto le permite ser un modelo dinámico que puede adaptarse a las frecuencias y amplitudes del tipo de señales a analizar. Si bien este modelo está pensado para tratar problemas multidimensionales, sin embargo también puede ser utilizado para la extracción de características en señales unidimensionales.

Referencias

1. Yoichi Miyawaki, Hajime Uchida, Okito Yamashita, Masaaki Sato, Yusuke Morito, Hiroki C. Tanabe (2008). Visual Image Reconstruction from Human Brain Activity using a Combination of Multiscale Local Image Decoders. *Neuron* 60, 915–929.
2. Alexander M. Chan, Eric Halgren, Ksenija Marinkovic, Sydney S. Cash (2011). Decoding word and category-specific spatiotemporal representations from MEG and EEG. *NeuroImage* 54 (2011) 3028–3039.
3. Saeid Sanei y J.A. Chambers (2007). *EEG Signal Processing*. John Wiley & Sons Ltd.
4. Shanbao Tong, Nitish V. Thakor (2009). *Quantitative EEG Analysis Methods and Clinical Applications*. Engineering in Medicine & Biology. Artech House
5. Emotiv EPOC. <http://www.emotiv.com>
6. Nicholas A. Badcock, Petroula Mousikou, Yatin Mahajan, Peter de Lissa, Johnson Thie y Genevieve McArthur (2013). Validation of the Emotiv EPOC

- EEG gaming system for measuring research quality auditory ERPs. PeerJ, DOI 10.7717/peerj.38
7. Matthieu Duvinage, Thierry Castermans, Mathieu Petieau, Thomas Hoellinger, Guy Cheron and Thierry Dutoit (2013). Performance of the Emotiv Epoc headset for P300-based applications. *BioMedical Engineering OnLine* 2013.
 8. Athanasios Vourvopoulos, Fotis Liarokapis (2014). Evaluation of commercial brain – computer interfaces in real and virtual world environment: A pilot study. *Computers and Electrical Engineering* 40, 714–729.
 9. Xing-Yu Wang, Jing Jin, Yu Zhang, Bei Wang (2013). Brain Control: Human-computer Integration Control Based on Brain-computer Interface Approach. *Acta Automatica Sinica*, 2013, Vol. 39, No. 3.
 10. Marta Kutas y Kara D. Federmeier (2011). Thirty Years and Counting: Finding Meaning in the N400 Component of the Event-Related Brain Potential (ERP). *Annu. Rev. Psychol.* 2011.62:621-647.
 11. Jasper, H. H., The ten-twenty electrode system of the International Federation. *Electroen. Clin. Neuro.* 10, 371–375, 1958.
 12. Nikolay V. Manyakov, Nikolay Chumerin, Adrien Combaz, y Marc M. Van Hulle (2011). Comparison of Classification Methods for P300 Brain-Computer Interface on Disabled Subjects. *Computational Intelligence and Neuroscience* Volume 2011, Article ID 519868.
 13. Jason Farquhar y N. Jeremy Hill (2012). Interactions between Pre-Processing and Classification Methods for Event-Related-Potential Classification: Best-Practice Guidelines for Brain-Computer Interfacing. *Neuroinformatics* April 2013, Volume 11, Issue 2, pp 175-192.