

Artículo de investigación

Estudio comparativo de métodos de extracción de características y clasificación de potenciales evocados P300

Comparative study of feature extraction methods and classification of event-related potentials P300

Diego Vinicio
Orellana-Villavicencio¹

Julio César
Cuenca-Tinitana^{2*}

1. Carrera de Electrónica y Telecomunicaciones, Facultad de Energía, Industrias y Recursos Naturales no Renovables, Universidad Nacional de Loja, Ecuador.
2. Carrera de Ingeniería Electromecánica, Facultad de Energía, Industrias y Recursos Naturales no Renovables, Universidad Nacional de Loja, Ecuador.

* Autor para correspondencia: julio.cuenca@unl.edu.ec

RECIBIDO: 20/07/2017

APROBADO: 30/10/2017

RESUMEN

El presente trabajo tiene por objetivo comparar la precisión en la detección de potenciales evocados P300 de dos tipos de clasificadores: Máquina de Soporte Vectorial MSV y K-vecinos más cercanos (KNN), estos dos clasificadores son entrenados y evaluados con características morfológicas y también con los coeficientes de aproximación de la Transformada Wavelet Discreta. Previo a la etapa de extracción de características se realizó un pre-procesado de la señal de Electroencefalografía (EEG), que incluye el filtrado, eliminación de artefactos, normalización y segmentación. Todo este procedimiento se realizó para muestras con promediado sincronizado de 15 señales de P300 y también para muestras de solo una señal P300. En la

ABSTRACT

The objective of the present work is to evaluate the potential of two types of classifiers, Vector Support Machines SVM and K-Nearest Neighbors KNN, to detect event-related potentials (P300). These two classifiers are trained and assessed with morphological characteristics and with the approximation coefficients of the Wavelet Discrete transformation. Before feature extraction, electroencephalographic (EEG) signals were processed to remove artifacts, filtered, normalized and segmented. This whole process was performed for samples with the synchronized average of 15 P300 signals and samples of only one P300 signal. In the final part of the document, we present a comparative analysis of the results and propose alternati-

parte final del documento se realiza un análisis comparativo de resultados y se propone alternativas que podrían contribuir a una mejora de los porcentajes de precisión de la clasificación en trabajos futuros.

Palabras clave: Interfaz Cerebro-Computador; BCI; P300; Análisis de Componentes Principales ACP; Transformada Wavelet; LSVM; QSVM; KNN; EEG.

ves that could contribute to an improvement of the classification accuracy in future works.

Keywords: Brain-Computer Interface; BCI; P300; Análisis de Componentes Principales PCA; Wavelet transform; LSVM; QSVM; KNN; EEG.

INTRODUCCIÓN

El principal objetivo de los grupos de investigación en el área de las Interfaces Cerebro-Computador (BCI) es encontrar nuevos canales de comunicación y control sin utilizar las vías normales del cerebro, es decir, los nervios y músculos periféricos. Para personas que sufren discapacidades motoras severas, como por ejemplo esclerosis lateral amiotrófica, síndrome de enclaustramiento u otros tipos de parálisis cerebral, las interfaces cerebro-computador son una opción factible para que puedan interactuar con el entorno.

Los sistemas de Interface Cerebro-Computador no invasivo, dependiendo del tipo de neuromecanismo en el que se basan, se dividen en tres grupos: a) Sincronización y Desincronización de Eventos Relacionados (ERD/ERS) de ritmos sensorimotoraes μ (8-12 Hz) y β (18-25 Hz), señales que normalmente disminuyen ERD durante la imaginación del movimiento e incrementan ERS y disminuyen en el periodo de relajación (Fabiani et al., 2004); b) Potencial P-300 provocado por un paradigma oddball, el cual puede ser de tipo visual, auditivo o somatosensorial (Donchin et al., 2000); y c) Potenciales Visuales Evocados en Estado Estacionario (SSVEP), que son obtenidos por un parpadeo constante a una frecuencia específica (Gao et al., 2003).

El P300 Speller (Deletreador P300) es un sistema que permite a pacientes con discapacidad

para hablar deletrear palabras a través de señales eléctricas de su actividad cerebral. Este sistema se basa en el paradigma denominado oddball (raro), el cual establece que estímulos que no son comunes producen una deflexión positiva (ERPs) en las señales de electroencefalografía aproximadamente 300 ms después de que se produce el estímulo. Este cambio que se produce en la señal EEG se denomina P300 y está presente en casi todos los seres humanos. Farwell & Donchin (1988) fueron los primeros investigadores en aplicar el P300 como una señal de control en un sistema BCI.

Debido a la baja relación señal/ruido (SNR) que presenta el P300, un método sencillo y efectivo que ayuda a la detección de la onda P300 es el promediado sincronizado de la señal EEG; este promediado hace que el ruido aleatorio presente en las diferentes muestras de la señal P300 se cancele, y la deflexión positiva se acentúe. Mientras más muestras se promedian, la onda P300 será más pura y por tanto más fácil de detectar. Sin embargo, promediar un elevado número de muestras provoca un aumento en el tiempo que toma el sistema para deletrear el carácter y, por ende, el tiempo que el usuario debe permanecer frente a la máquina, provocando un agotamiento excesivo. Debido a estas desventajas surge la necesidad de desarrollar técnicas de procesamiento digital de señales y de clasificación de patrones que permitan detectar el P300 con un alto grado de confiabilidad, utilizando la menor cantidad de

muestras en el promediado o en el caso ideal con una sola muestra. En el presente trabajo se utiliza el sistema de reconocimiento de patrones cuyo diagrama de bloques esta descrito en la Figura 1.

El presente trabajo tiene por objetivo comparar la precisión en la detección de potenciales evocados P300, con la finalidad de utilizar el mejor clasificador para la elaboración de una interfaz cerebro computador basada en P300.

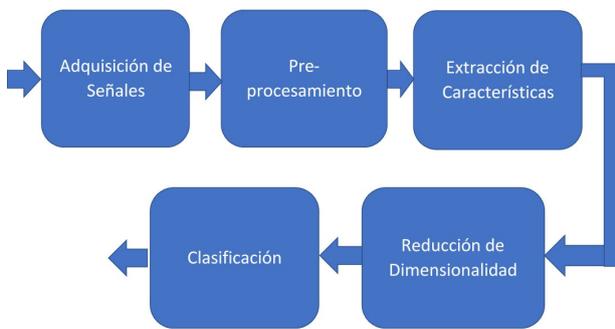


Figura 1. Diagrama de Bloques del Sistema de Detección de señal P300.

MATERIALES Y MÉTODOS

Los métodos y procedimientos descritos a continuación se desarrollaron utilizando el lenguaje de programación Python versión 2.7.

Adquisición de Señales

Se trabajó con la base de datos del proyecto desarrollado por Guger et al. (2009), la cual fue elaborada con las características que se exponen a continuación. Se registró las señales procedentes de los electrodos FZ, CZ, PZ, P3, P4, Po7, Po8 y Oz del sistema internacional estándar de colocación de electrodos 10-20 con una frecuencia de 256 Hz. En la Figura 2 se muestra la distribución de los electrodos sobre la superficie de la cabeza con las posiciones básicas obtenidas a partir del 10% y 20% de la medida total del cráneo.

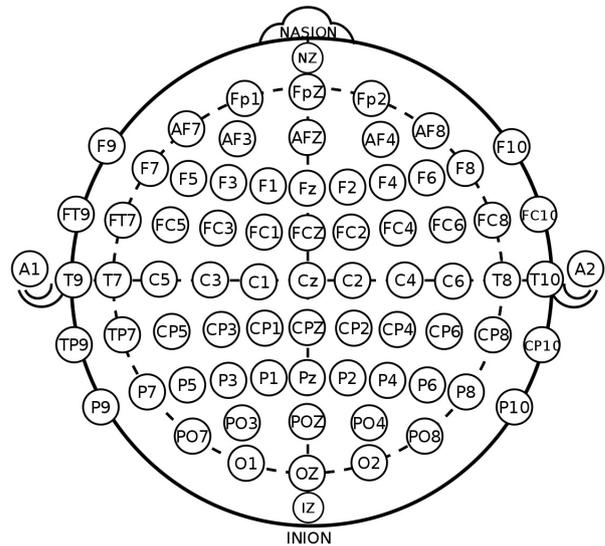


Figura 2. Ubicación de electrodos para adquisición de EEG de acuerdo al sistema internacional 10-20 (Klem et al., 1999).

En el experimento se pide al sujeto que centre su atención en el carácter que quiere deletrear y entonces aparece un potencial evocado P300 en el EEG, en respuesta a la intensificación de una fila o columna que contiene el carácter deseado. Con el fin de que el procedimiento de deletreo sea más fiable, esta secuencia de intensificaciones se repite 15 veces por cada símbolo. En la Figura 3 se muestra una representación de la matriz de caracteres presentado a los sujetos bajo estudio.



Figura 3. Matriz de caracteres para estimulación de P300.

Adicional a los ocho vectores provenientes de los electrodos sobre el cuero cabelludo, se tiene un vector adicional del símbolo que se encendió en la matriz y además el momento exacto de su activación, y por último un vector que indica cuál es la letra objetivo.

Preprocesamiento

La etapa de preprocesamiento se ha dividido en cuatro tareas: Filtrado, Eliminación de artefactos, Normalización y Segmentación. Dado que la mayor cantidad de energía se encuentra entre 0 y 25 Hz y con el objetivo de no alterar la fase de los componentes del P300 se utilizó un filtro forward-backward, de orden 150, y con una frecuencia de corte de 30 Hz.

El experimento tiene una duración aproximada de cinco minutos por cada usuario, dentro de ese tiempo existen cuatro intervalos de descanso de alrededor de 15 segundos; es en estos intervalos de descanso donde se presentan la mayor cantidad de interferencias en la señal, debidas principalmente al movimiento de la cabeza del usuario, al parpadeo, y movimiento de los ojos. Las señales de EEG en los intervalos de descanso no aportan ninguna información, sin embargo, debido a la elevada amplitud que presentan influyen de manera negativa al momento de realizar la normalización; para atenuar este problema se eliminó de forma manual todas las señales de estos intervalos.

La amplitud del potencial P300 varía de una persona a otra y depende de algunos factores entre ellos la edad, la humedad de la piel, etc.; sin embargo, la morfología de la señal se mantiene con elevado grado de similitud. Para estandarizar la amplitud de las señales se aplicó normalización min-máx.

Después de haber filtrado, eliminado artefactos y normalizado en el intervalo de [-1, 1], finalmente se procede a dividir la señal en segmentos

de 600 ms. Cada segmento inicia con el encendido del carácter que se desea deletrear, considerando que el periodo de muestreo es de $T=0.0039s$, se tiene para cada segmento un total de 153 muestras. Según la literatura revisada, el componente P300 aparece aproximadamente 300 ms después del estímulo, ventana lo suficientemente grande como para capturar todas las características de tiempo requeridas para una clasificación eficiente. De este proceso se obtuvo una matriz de 200 muestras. Cada una de estas muestras contiene el promedio sincronizado de 15 señales de P300 y también una matriz de 300 muestras donde cada una de estas muestras representa una sola señal de P300.

Extracción de Características

La etapa de extracción de características sirve para transformar señales cerebrales originales en una representación que facilita la clasificación. En otras palabras, el objetivo de la extracción de características es eliminar el ruido y otra información innecesaria de las señales de entrada, al mismo tiempo que retener información que es importante para discriminar diferentes clases de señales (Amini et al., 2010).

Con el objetivo de comparar qué tipo de características proporcionan mejores insumos para una correcta clasificación, esta etapa se orienta a la extracción de características morfológicas y por otro lado obtener los coeficientes de aproximación de la transformada Wavelet.

Extracción de características morfológicas

El conocimiento neurofisiológico a priori puede ayudar a decidir qué características de la señal cerebral se espera que mantenga la información más discriminante para el paradigma elegido (Selim et al., 2008). Estas características son:

1. Latencia (LAT,t_max), el tiempo donde ocurre el

valor máximo de la señal

$$t_{A_{\max}} = \{t | s(t) = S_{\max}\} \quad (1)$$

2. Amplitud máxima de la muestra

$$S_{\max} = \max\{s(t)\} \quad (2)$$

3. Área positiva. - Sumatoria de todos los valores positivos de la muestra.

$$A_p = \sum_0^{600 \text{ ms}} 0.5(s(t) + |s(t)|) \quad (3)$$

4. Área Negativa. - Sumatoria de todos los valores negativos de la muestra

$$A_n = \sum_0^{600 \text{ ms}} 0.5(s(t) - |s(t)|) \quad (4)$$

5. Valor Pico-Pico.

$$PP = S_{\max} - S_{\min} \quad (5)$$

donde S_{\max} y S_{\min} representan el valor máximo y mínimo respectivamente

6. Intervalo de tiempo entre S_{\max} y S_{\min}

$$t_{pp} = t_{S_{\max}} - t_{S_{\min}} \quad (6)$$

7. Pendiente Pico-Pico

$$S_{pp} = PP/t_{pp} \quad (7)$$

8. Valor pico del N100, valor mínimo de la señal en el intervalo de [50-180 ms]

$$P_{N100} = \min\{s(t), 50 \leq t \leq 180\} \quad (8)$$

9. Latencia de N100.- Tiempo donde ocurre N100

$$t_{N100} = \{t | s(t) = N100\} \quad (9)$$

10. P3N4, diferencia entre el máximo valor en el intervalo [185-500 ms] y el mínimo en el intervalo [320-500 ms], correspondientes a la amplitud del P300 y del N400 respectivamente.

11. P3N1.- Diferencia entre el valor máximo de la señal en el intervalo [185-500 ms] y el valor mínimo de la señal en el intervalo [50-170ms].

En la Figura 4 se muestran las características morfológicas extraídas de la señal P300.

Extracción de coeficientes Wavelet

De los resultados obtenidos en Demiralp et al. (2001), se conoce que las características más relevantes relacionadas al potencial P300 se encuentran en la banda de 0,5-4 Hz, como se puede observar en la Figura 5 tomada del referido artículo.

Considerando estos resultados se realizó inicialmente un sub-muestreo de la señal a 64Hz, sin que esto represente una pérdida de información ya que concuerda con el teorema de muestreo de Nyquist que especifica que la frecuencia de muestreo debe ser superior al doble del ancho de banda de la señal (Alvarado Reyes & Stern Forgach, 2010).

De igual manera, del estudio realizado por Perseh & Sharafat (2012), se eligió la familia de Wavelets Daubechies, específicamente la Daubechies de orden 4 (db4). Luego de aplicar esta transformación y por lo expuesto anteriormente se eligió únicamente los coeficientes de aproximación (21 coeficientes en total). Este procedimiento se realizó para muestras provenientes del promediado coherente de 15 P300 y también con muestras de un solo P300.

Reducción de Dimensionalidad

Con el objetivo de reducir la carga compu-

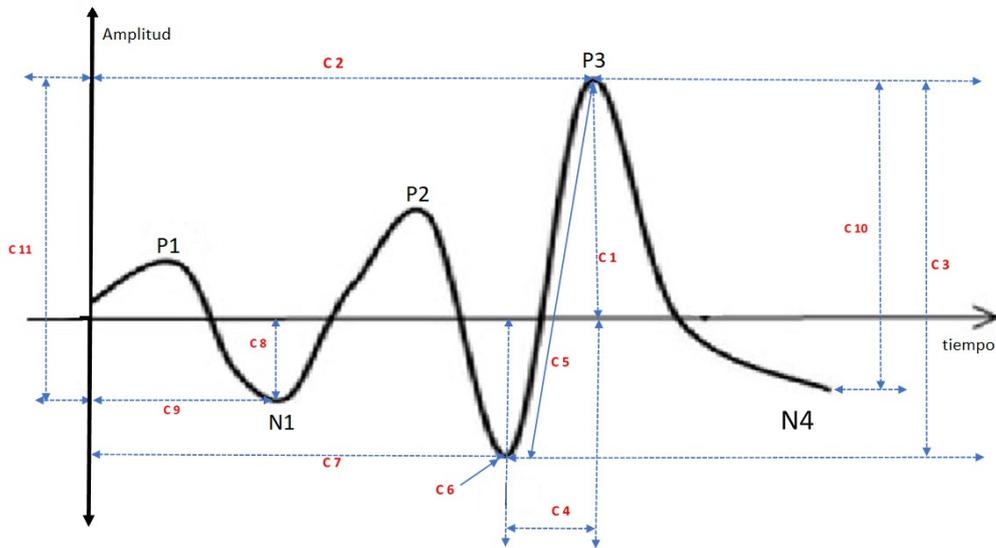


Figura 4. Características morfológicas extraídas del P300.

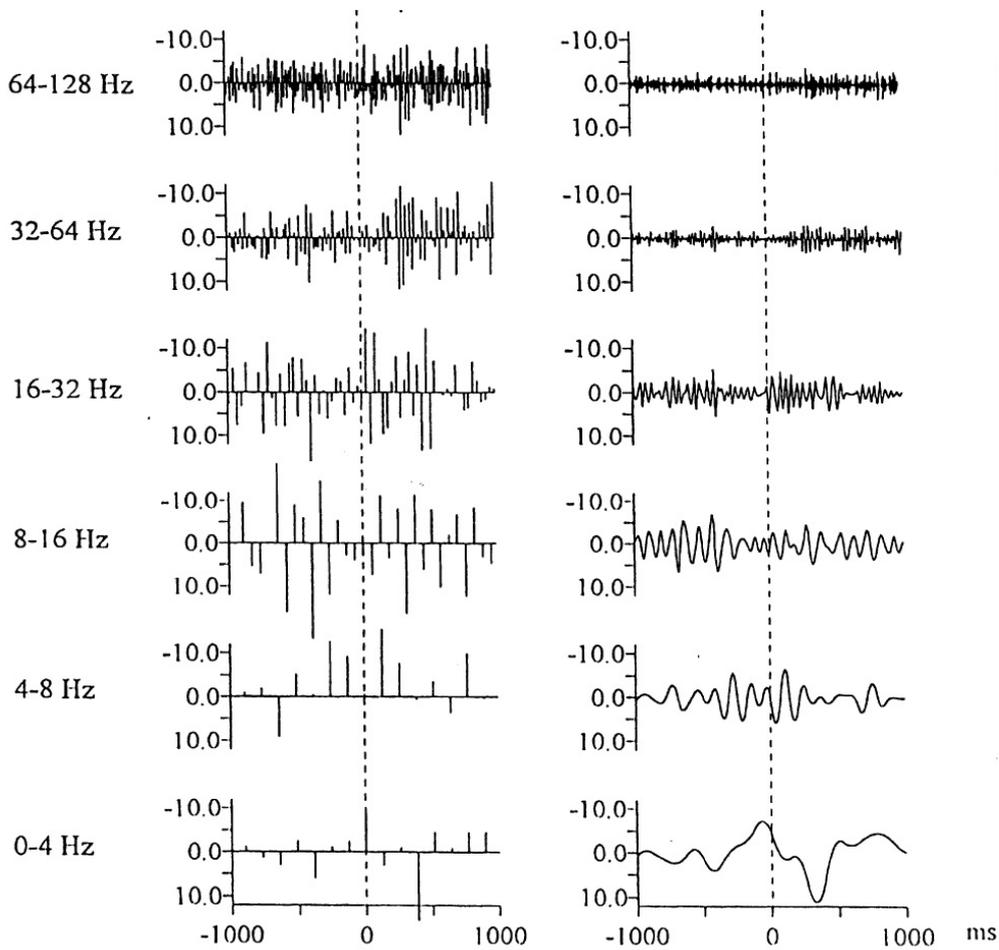


Figura 5. Análisis Wavelet de P30 (Demiralp et al., 2001)

tacional y acelerar el funcionamiento de los clasificadores se aplicó la técnica de análisis de componentes principales, la cual efectúa un re-mapeo lineal de los datos a un espacio de dimensionalidad menor a la original, de tal manera que la varianza de los datos en la representación de pocas dimensiones se maximiza. Para efectuar esta técnica primero se construye la matriz de covarianza y a esta matriz se calcula los valores y vectores propios. Los vectores propios que corresponden a los valores propios más grandes (los componentes principales) se pueden utilizar para reconstruir una gran parte de la varianza de los datos originales.

Clasificadores

Máquinas de Soporte vectorial (SVM)

En las investigaciones de BCI basados en P300, las Máquinas de Soporte Vectorial (SVM) son consideradas uno de los clasificadores más precisos. La idea principal de SVM es encontrar el hiperplano que separe las clases, de manera que la distancia entre el hiperplano y los puntos más próximos a ambas clases sea máxima. En otras palabras, se busca maximizar el margen entre las dos clases (Manyakov et al., 2011). Dado un conjunto de datos de entrada etiquetados

$$\Gamma = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (10)$$

correspondientes al vector $y_i \in \{-1, 1\}$. Entonces el hiperplano separa los datos si y solo si:

$$y_i ((w, x_i) + b) \geq 1 \quad \forall_i \quad (11)$$

Las SVM maximizan la distancia entre dos clases para encontrar el hiperplano óptimo con las mejores capacidades de generalización. En caso linealmente separable, esto equivale a $1/2 ||w||^2$ sujeto a (11). Sin embargo, para el caso de clases no separables linealmente se introducen variables adicionales ε para modificar las restricciones existentes. Además, una penalización C (parámetro

de regularización) se introduce por clasificación errónea:

$$\min [1/2 ||w||^2 + C \sum_{i=1}^n \varepsilon_i], \quad (12)$$

sujeto a $y_i ((w, x_i) + b) \geq 1 - \varepsilon_i, \quad \varepsilon_i > 0 \quad \forall_i$.

Mediante la formación del Lagrangiano y la solución del problema dual, se puede interpretar como sigue:

$$\max [\sum_i \alpha_i - 1/2 \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i x_j], \quad (13)$$

sujeto a $0 \leq \alpha_i \leq C$. Donde α_i es el multiplicador Lagrangiano.

Por cada una de las muestras de entrenamiento hay un multiplicador Lagrangiano. La muestra de entrenamiento cuyo multiplicador Lagrangiano no es cero se llama vector de soporte. Resolviendo este problema (problema QP) (Borges, 1998) se tiene:

$$w = \sum_{i=1}^{N_s} y_i \alpha_i x_i, \quad (14)$$

donde N_s es el número de vectores de soporte (Borges, 1998).

SVM se puede generalizar a otros tipos de superficies no lineales, esto se puede alcanzar utilizando diferentes tipos de funciones simétricas $K(x, y)$ en lugar del producto escalar normal. Cuando se utiliza una función discriminante lineal se denomina comúnmente LSVM y si se utiliza kernel Gaussiano se denomina RSVM. En este trabajo se aplicó discriminante lineal LVSM y discriminante cuadrático QSVM.

K-vecinos más cercanos (KNN)

El método KNN (K Nearest Neighbors) (Lotte et al., 2007) es un método no-paramétrico de clasificación supervisada que estima el valor de la función de densidad de probabilidad o directamente la probabilidad a posteriori de que un elemento x pertenezca a la clase C_j a partir de las muestras de entrenamiento. En el proceso de entrenamiento no se hace ninguna suposición

acerca de la distribución de las variables predictoras. En reconocimiento de patrones la función se aproxima solo localmente y todo el cómputo es diferido a la clasificación.

Las muestras de entrenamiento son vectores en un espacio característico multidimensional en términos de p atributos y q clases

$$x_i = (x_{i1}, x_{i2}, \dots, x_{ip}) \in X \quad (15)$$

El espacio es dividido en regiones (clusters) que se forman a partir del conjunto de muestras de entrenamiento etiquetadas; las nuevas muestras son asignadas a determinada clase si ésta es la clase dominante entre sus K -vecinos más cercanos dentro del conjunto de entrenamiento. Normalmente se utiliza la distancia euclídeana como parámetro de medida.

$$d(x_i, y_j) = \sqrt{\sum_{r=1}^p (x_{ri} - x_{rj})^2} \quad (16)$$

Con un valor suficientemente alto de k y el

adecuado número de muestras de entrenamiento, KNN puede aproximar cualquier función que permita crear superficies de decisión no-lineales. Los algoritmos KNN no son muy populares en la comunidad BCI probablemente debido a que es conocido que son muy sensibles a la “maldición de la dimensionalidad” (Friedman, 1997; Blankertz et al., 2002; Schlögl et al., 2005). Sin embargo, cuando fue usado en BCI’s con vectores de características de baja dimensionalidad, KNN resultó ser eficiente (Borisoff et al., 2004).

RESULTADOS

De acuerdo al resultado de la primera etapa (Figura 6), se observa que la señal está lista para ser segmentada y luego aplicar los algoritmos para extracción de características. Una vez aplicado el procedimiento, se observa una relación de la señal considerablemente mejor (Figura 7).

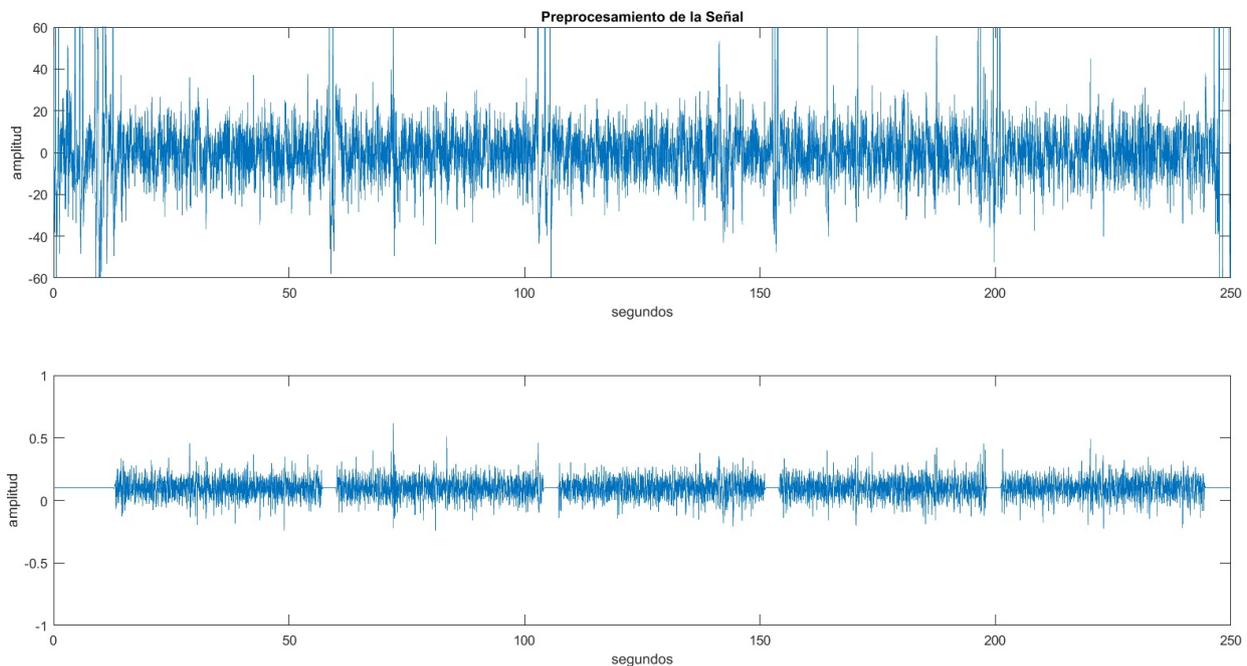


Figura 6. Señal EEG original (arriba), señal EEG sin artefactos, filtrada y normalizada (abajo).

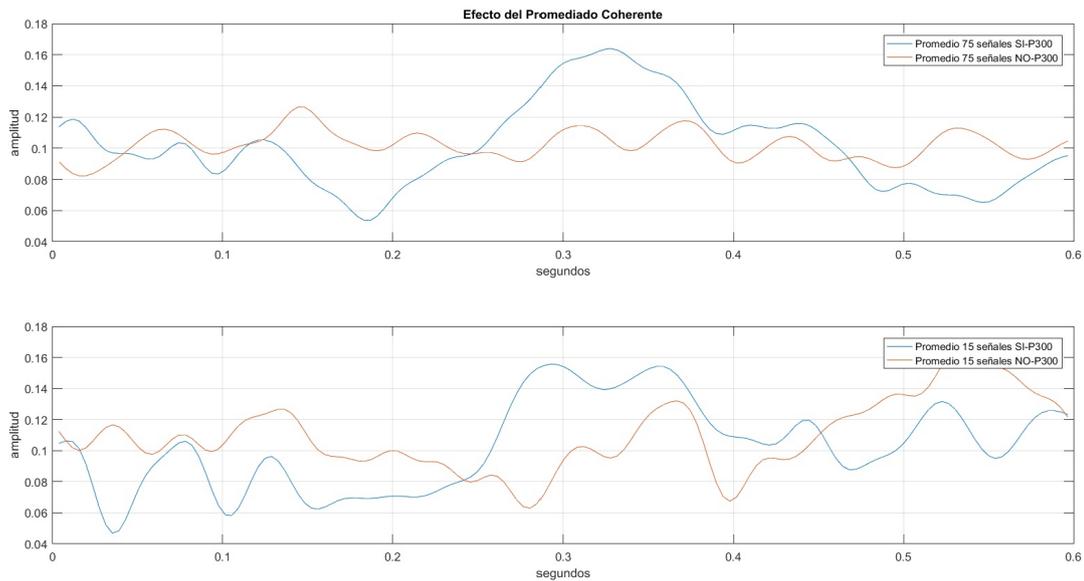


Figura 7. Amplitud de señales, medida en voltios, en un lapso de tiempo de 0,6 segundos, promediadas para 75 muestras (arriba) y para 15 muestras (abajo). En azul se muestran las señales con presencia de P300 y en naranja las muestras sin presencia de P300.

De acuerdo al análisis de componentes principales (Tabla 1), en las características morfológicas se puede verificar que el 96,8% de la información está contenida en siete componentes que representa una reducción de cuatro variables sin pérdida considerable de información. Para el caso de los coeficientes obtenidos con la transformada Wavelet se observa que con 14 componentes se obtiene el 95,2% de información que representa una reducción de siete variables y por ende una disminución considerable en la carga computacional del clasificador.

La etapa de clasificación se desarrolló aplicando los clasificadores SVM y KNN, y como entradas se aplicaron las características morfológicas y los coeficientes Wavelet con y sin realizar el análisis de componentes principales. Como se puede observar en las Tabla 2 y Tabla 3, el mejor resultado de clasificación para el caso de las muestras con promediado de 15 señales P300 fue de 85,5% y para el caso de muestra única se alcanzó un porcentaje de precisión de 58,9%.

Tabla 1. Análisis de Componentes Principales de Características del P300 realizado a las características morfológicas y a los coeficientes obtenidos de la transformada wavelet.

Componente	Características morfológicas %	Características wavelet %
1	30,8313	25,3905
2	26,8212	15,9180
3	11,6802	12,7847
4	9,4056	8,6884
5	7,7820	5,6550
6	5,3249	4,5624
7	4,9398	4,1203
8	2,7718	3,8142
9	0,4433	3,5426
10	0,0000	2,9448
11	0,0000	2,6314
12	-----	1,9866
13	-----	1,6896
14	-----	1,4886

Tabla 2. Resultados de Clasificación con promediado coherente de 15 muestras.

	LSVM %	QSVM%	KNN%
Características morfológicas sin ACP	73,0	73,1	72,1
Características Wavelet sin ACP	82,7	85,5	78,0
Características morfológicas con ACP (7 componentes)	70,1	69,5	70,0
Características Wavelet con ACP (14 componentes)	78,5	85,3	85,0

Tabla 3. Resultados de Clasificación de muestra única.

	LSVM %	QSVM%	KNN%
Características morfológicas sin ACP	56,7	58,9	56,3
Características Wavelet sin ACP	53,2	52,7	53,6
Características morfológicas con ACP (7 componentes)	56,3	58,4	56,3
Características Wavelet con ACP (14 componentes)	52,7	50,3	49,3

DISCUSIÓN

Los esfuerzos por mejorar la precisión y velocidad en la detección de potenciales P300 se mantienen vigentes, debido a su utilidad en una amplia variedad de problemas ya sea en la medicina, psicología y en la ingeniería. Por ejemplo, se ha relacionado la forma, duración e incluso el retardo del P300 con trastornos cognitivos, depresión, drogadicción, trastornos de ansiedad, entre otros (Polich, 1991; Polich & Kok, 1995; Frodl-Bauch et al., 1999; Anderer et al., 2002; Polich & Criado, 2006; Gutz et al., 2015). En ingeniería el P300 se ha usado en Interfaces Cerebro-Computador, específicamente en BCIs de apoyo a la comunicación para personas con parálisis severa. En la última década y gracias a los avances tecnológicos

en el campo de Imágenes Médicas se ha utilizado componentes de los potenciales evocados para la valoración fisiológica de las funciones superiores humanas que podrían ser de gran interés en neurología, psiquiatría y otorrinolaringología.

En el presente trabajo se han expuesto las técnicas y métodos básicos para la detección de potenciales evocados P300. En trabajos futuros es posible mejorar los resultados aplicando, por ejemplo, filtros adaptativos o filtros acoplados para mejorar la relación señal a ruido. Para la separación de fuentes de interferencia es posible aplicar Análisis de Componentes Independientes que ha sido una técnica ampliamente usada en procesamiento de señales. En lo referente a extracción de características, un método de amplia aceptación son los Patrones Espaciales Comunes CSP por sus siglas en inglés (Common Spatial Patterns) con bandas de energía (Lotte et al., 2007). Por último, un algoritmo que ha dado buenos resultados en clasificación de señales EEG es el denominado “Bosques Aleatorios”, en inglés Random Forest (Akram et al., 2015).

Como se puede evidenciar en los resultados, la aplicación de análisis de componentes principales, si bien permite disminuir la dimensionalidad del problema, también presenta una ligera disminución en el porcentaje de precisión de clasificación. Este porcentaje podría ser aceptable en aplicaciones donde se necesite una respuesta muy rápida de clasificación o en sistemas donde la cantidad de memoria y la capacidad de procesamiento son limitados. En este estudio se alcanzó un 85,5%, que es un resultado aceptable; sin embargo, no supera la precisión máxima alcanzada en otros trabajos publicados en los cuales el porcentaje de acierto supera el 90% (Mirghasemi et al., 2006). Sin embargo, en este caso se busca lograr la mayor precisión posible y por lo tanto el clasificador elegido sería QSVM con los coeficientes de la Transformada Wavelet sin aplicar ACP.

La precisión alcanzada por el algoritmo KNN

es ligeramente inferior a la de la máquina de soporte vectorial, sin embargo, se verifica que este algoritmo es eficiente para casos de baja dimensionalidad.

LITERATURA CITADA

Akram F., S.M. Han & T.S. Kim (2015). An efficient word typing P300-BCI system using a modified T9 interface and random forest classifier. *Computers in biology and medicine* 56: 30-36.

Alvarado Reyes J. & C.E. Stern Forgach (2010). Un complemento al teorema de Nyquist. *Revista mexicana de física E* 56(2): 165-171.

Amini Z., V. Abootalebi & M.T. Sadegui (2010). A Comparative Study of Feature Extraction Methods in P300 Detection. *Proceedings of the 17th Iranian Conference of Biomedical Engineering (ICBME2010)*, Teheran.

Anderer P., B. Saletu, H.V. Semlitsch & R.D. Pascual-Marqui (2002). Structural and energetic processes related to P300: LORETA findings in depression and effects of antidepressant drugs. *Methods Find Exp Clin Pharmacol* 24: 85-91.

Blankertz B., G. Curio & K.R. Müller (2002). Classifying single trial eeg: Towards brain computer. *Advances in Neural Information Processing Systems* 14(1): 157-164.

Borisoff J., S. Mason, A. Bashashati & G. Birch (2004). Brain-computer interface design for asynchronous control applications: Improvements to the If-asd asynchronous brain switch. *IEEE Transactions on Biomedical Engineering* 51(6): 985-992.

Burges C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining Knowledge Discovery* 2: 121-167.

Demiralp T., A. Ademoglu, Y. Istefanopulos, C. Başar-Eroglu & E. Başar (2001). Wavelet analysis of oddball P300. *Internacional Journal of Psychophysiology* 39(1): 221-227.

Donchin E., K. Spencer & R. Wijesinghe (2000). The mental prosthesis: Assessing the speed of a p300-based brain-computer interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 8(2): 174-179.

Fabiani G., D. McFarland, R. Wolpaw & P. Pfurtscheller (2004). Conversion of eeg activity into cursor mo-

vement by brain-computer. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 12(3): 331-338.

Farwell L.A. & E. Donchin (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and clinical Neurophysiology* 70(6): 510-523.

Friedman J.H. (1997). On bias, variance, 0/1-loss, and the curse-of-dimensionality. *Data mining and knowledge discovery* 1(1): 55-77.

Frodl-Bauch T., R. Böttlinger & U. Hegerl (1999). Neurochemical substrates and neuroanatomical generators of the event-related P300. *Neuropsychobiology* 40(2): 86-94.

Gao X., D. Xu, M. Cheng & S. Gao (2003). A bci-based environmental controller for the motion-disabled. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11(2): 137-140.

Guger C., S. Daban, E. Sellers, C. Holzner, G. Krausz, R. Carabalona & G. Edlinger (2009). How many people are able to control a P300-based brain-computer interface (BCI)? *Neuroscience Letters* 462(1): 94-98. Disponible en: <http://bncl-horizon-2020.eu/database/data-sets>

Gutz L., B. Renneberg, S. Roepke & M. Niedeggen (2015). Neural processing of social participation in borderline personality disorder and social anxiety disorder. *Journal of abnormal psychology* 124(2): 421-431.

Klem G.H., H.O. Lüders, H.H. Jasper & C. Elger (1999). The ten-twenty electrode system of the International Federation. *Electroencephalogr Clin Neurophysiol* 52(3): 3-6.

Lotte F., M. Congedo, A. Lécuyer, F. Lamarche & B. Arnaldi (2007). A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of Neural Engineering* 4(2): 1-14.

Manyakov N., N. Chumerin, A. Combaz & M. Van Hulle (2011). comparison of classification methods for P300 Brain-Computer Interface on disabled subjects. *Computational Intelligence and Neuroscience* 2011: 519868.

Mirghasemi H., R. Fazel-Rezai & M.B. Shamsollahi (2006). Analysis of P300 Classifiers in Brain Computer Interface Speller. *Proceedings of 28th IEEE EMBS Annual International Conference*, New York City.

Perseh B. & A.R. Sharafat (2012). An efficient P300-based BCI using wavelet features and IBPSO-based channel selection. *Journal of Medical Signals and Sensor* 3(2): 128-143.

Polich J. (1991). P300 in clinical applications: meaning, method, and measurement. *American Journal of EEG Technology* 31(3): 201-231.

Polich J. & J.R. Criado (2006). Neuropsychology and neuropharmacology of P3a and P3b. *International Journal of Psychophysiology* 60(2): 172-185.

Polich J. & A. Kok (1995). Cognitive and biological determinants of P300: an integrative review. *Biological psychology* 41(2): 103-146.

Schlögl A., F. Lee, H. Bischof & G. Pfurtscheller (2005). Characterization of four-class motor imagery eeg data for the bci-competition 2005. *Journal of Neural Engineering* 2(4): 14-22.

Selim A.E., M.A. Wahed & Y.M. Kadah (2008). Machine Learning methodologies in brain-computer interface systems. *Proceedings of the 4th Cairo International Biomedical Engineering Conference, El Cairo.*