Congr. Int. en Ing. Electrónica. Mem. ELECTRO, Vol. 39, pp. 72-76, Oct 2017, Chihuahua, Chih. , México
http://electro.itchihuahua.edu.mx/memorias_electro/MemoriaElectro2017.zip
ISSN 1405-2172

DETECCIÓN Y CLASIFICACIÓN DE POTENCIALES EVOCADOS P300 UTILIZANDO ALGORITMOS DE APRENDIZAJE COMPUTACIONAL

Rascón-Cervantes Kathia Victoria, Ramírez-Alonso Graciela, González-Gurrola Luis Carlos
Universidad Autónoma de Chihuahua
Facultad de Ingeniería
Circuito Universitario Campus II
Tel. 614 442-9500
a281831, galonso, lcgonzalez{@uach.mx}

RESUMEN

En este trabajo se describe el desarrollo de un sistema para la detección y clasificación de señales de un Electroencefalograma. Particularmente se analizan señales de potenciales evocados P300 con el fin de diseñar una interfaz cerebro-computadora que permita la comunicación con pacientes que padezcan algún tipo de parálisis, específicamente, diagnosticadas con el síndrome de enclaustramiento. Estos pacientes no pueden mover su cuerpo a excepción de sus ojos, de tal manera que la creación de interfaces que les permitan comunicarse con otras personas es de gran relevancia. En este trabajo se utiliza la base de datos *BCI Competition III, P300 speller paradigm* y mediante la implementación de algoritmos basados en aprendizaje computacional se clasifican estas señales. El modelo que alcanza un mejor desempeño está basado en el algoritmo de Máquina de Vectores de Soporte logrando resultados de exactitud del 73% y 47% en las etapas de entrenamiento y prueba respectivamente.

Palabras Clave: Electroencefalograma, potenciales evocados P300, máquina de vectores de soporte, aprendizaje máquina.

ABSTRACT

This work describes the development of a system that detects and classify signals of an electroencephalogram. In particular, P300 evoked potentials are analyzed in order to design a brain-computer interface that allows the communication with patients that suffers from severe paralysis diagnosed with the locked-in syndrome. These patients cannot move their body at all except eye-movement. Therefore, by creating interfaces that analyze and interpret EEG signals to achieve communication with other people is of great relevance. In this work, we use the *BCI Competition III database, P300 speller paradigm* and by the implementation of algorithms based on machine learning these signals can be classified. The model that obtained the best performance is based on a Support Vector Machine, achieving accuracy results of 73% and 47% in the training and test stages, respectively.

Keywords: Electroencephalogram, evoked potentials P300, support vector machine, machine learning.

1. INTRODUCCIÓN

Según censos de población del INEGI al año 2010, tan solo en México el 5.1% de la población padecía algún tipo de enfermedad neurológica [1]. Estas personas pueden estar totalmente paralizadas e incapacitadas para realizar cualquier actividad motora pero siguen teniendo algunas de sus actividades cognitivas. Dos de los diagnósticos más relevantes en relación al grado de parálisis en el paciente son: la tetraplejía y el síndrome de enclaustramiento (SLI). En el caso de la tetraplejía el sujeto no puede mover sus extremidades, por otro lado, el SLI está compuesto por tetraplejía y anartria, esta última es la incapacidad neurológica para hablar. SLI tiene dos variantes: 1) que el sujeto no puede mover su cuerpo en absoluto o 2) que únicamente puede mover sus ojos, por lo que sólo tienen la posibilidad de comunicarse con su entorno mediante su actividad cerebral [2] [3].

Los sistemas de interfaz cerebro-computadora (BCI) analizan las señales de actividad cerebral y las traducen en señales de control a un dispositivo. Las características utilizadas en los estudios de dichos sistemas incluyen potenciales de corticales lentos, potenciales evocados P300, ritmos sensorimotores y potenciales relacionados con eventos de acción neuronal registrados en la corteza cerebral [4]. Estudios muestran que la comunicación y el control no muscular son posibles, dando paso a los sistemas BCI como una alternativa para la comunicación de personas que sufren del síndrome de enclaustramiento.

En 1988, con el fin de atacar esta problemática, Farwell y Donchin dieron lugar al primer paradigma del deletreo P300. El experimento consiste en presentarle al paciente una cuadricula de 6×6 con caracteres alfanuméricos. El objetivo es deletrear letra por letra una palabra, por lo que se le pide al sujeto que preste atención especial al carácter que desea deletrear. En la cuadrícula, se intensifican (iluminan) cada fila y columna de manera aleatoria durante 100 ms con un periodo de 75 ms entre intensificaciones (donde la cuadricula no se ilumina). De acuerdo a la literatura, cuando se intensifica la columna y la fila que contienen al carácter deseado, se emiten potenciales P300. Estos potenciales son ondas con deflexiones positivas que aparecen alrededor de los 300 ms después del estímulo (visual en este caso), y son registradas en las lecturas del electroencefalograma (EEG) [5]. Este proceso se muestra en la Figura 1.

Fig. 1: Ejemplo de cuadricula 6x6 usada en un sistema de deletreo *P300*. 300ms después de que se ilumina el carácter de interés, la lectura del EEG captará la deflexión positiva.

Una parte importante del estudio del paradigma del deletreo es implementar un algoritmo para el análisis automático de estas señales. Diversas investigaciones reportan implementaciones de modelos matemáticos basados en análisis de discriminantes lineales (LDA) [6] y máquinas de vectores de soporte (SVM) [2] obteniendo buenos resultados. Sin embargo, para este tipo de problemas también es frecuente el uso de otros clasificadores como lo son: *k*-ésimo vecino más cercano (KNN), Naive Bayes (NB) y *k*- medias (KM), por mencionar algunos. En este trabajo el objetivo es aplicar y evaluar el desempeño de los 4 clasificadores más comunes, reportados en la literatura, para el análisis de señales P300. Específicamente se compara el desempeño de los clasificadores SVM, LDA, KNN y NB, además de determinar cuál de éstos ayudará con mayor fiabilidad a resolver el problema presentado.

2. DESAROLLO

2.1. Base de datos: *P300 speller paradigm*

La autonomía es esencial en la vida de todo ser humano, tomando en cuenta que las personas diagnosticadas con el síndrome de enclaustramiento no presentan mejoría motora, al desarrollar un sistema que logre interpretar la actividad cerebral del paciente se mejoraría significativamente su comunicación con su entorno y en consecuencia, también, su calidad de vida.

Para este proyecto se usó la base de datos *P300 speller paradigm* de la competencia *BCI competition III, Data set II*, disponible en http://www.bbci.de/competition/iii/ . Esta base de datos consta de 4 archivos de Matlab® .mat, los cuales contienen las señales emitidas por dos sujetos, A y B, que fueron sometidos al experimento anteriormente descrito. La descripción del contenido de los archivos .mat se muestra en la Tabla 1. Con el fin de atacar los problemas de la variabilidad y del ruido en las señales, y así obtener muestras más confiables, en esta base de datos se realizaron 15 repeticiones para cada carácter a deletrear. Este experimento es mentalmente agotador, por ello cada sujeto llevó a cabo 5 sesiones de deletreo.

Tabla 1. Descripción de la base de datos BCI competition III. P300 speller paradigm

Nombre	Descripción
Señal	Contiene las muestras que corresponden a las 15 repeticiones de 85 caracteres para entrenamiento o 100 caracteres para prueba monitoreados por 64 canales.
Código del estímulo	Contiene números del 1-12 para especificar si se está intensificando una columna o una fila de la cuadrícula. Contiene un cero si no se está intensificando alguna de ellas.
Tipo de estímulo	Contiene la información sobre si la fila o columna que está siendo intensificada contiene el carácter deseado (solo para los datos de entrenamiento)
Flasheo	Contiene información sobre si alguna fila o columna está siendo intensificada (1's)
Carácter intensificado	Contiene la información del carácter que se desea deletrar para cada conjunto de 12 intensificaciones (solo para los datos de entrenamiento)

Cada sesión está compuesta por corridas, y para cada corrida se le pidió a los sujetos deletrear una palabra, obteniendo así un total de 85 caracteres para entrenamiento y 100 para realizar pruebas en los sistemas. En cada sesión se recolectaron las señales EEG de 64 canales las cuales fueron filtradas con un pasa bandas de 0.1-60 Hz y posteriormente digitalizadas a 240 Hz usando el software BCI2000 [5].

2.2. Vector de características

En el presente trabajo, se analizaron solamente las señales correspondientes a 5 caracteres, considerando 15 repeticiones y 8 canales del sujeto A. Los canales seleccionados fueron: Fz, Cz, Pz, C3, C4, P3, P4 y Oz. Las señales sensadas por estos canales fueron las que reportaron mejores resultados en [2] y su localización se muestra en la Figura 2. Estas señales fueron procesadas por un filtro Chebyshev de orden 8 con frecuencias de corte de 0.1 y 10 Hz.

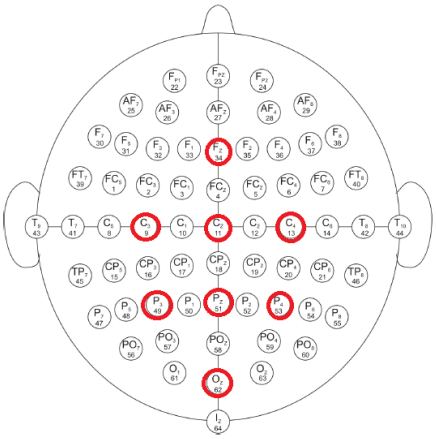

Fig. 2: Localización de los electrodos que se seleccionaron en este trabajo para la detección y clasificación de caracteres.

Posteriormente se normalizaron los datos a una media cero y varianza de uno. Al igual que el trabajo presentado Rakotomamonjy y Guigue [2], la señal se analizó en ventanas de 667 ms que es equivalente a 160 muestras. El tamaño de esta ventana se establece considerando que las señales P300 aparecen en la señal aproximadamente 300 ms después del estímulo, por lo cual este tamaño de 667 ms es suficientemente grande para lograr una clasificación correcta en los caracteres.

Con base en la hipótesis de que al intensificarse una fila o columna que contenga el carácter deseado por el sujeto se emitirán picos característicos, es decir, se tendrán muestras de mayor magnitud, esto implicará que la suma de las muestras contenidas en las ventanas que iniciaron en la intensificación del carácter correcto debe ser mayor que las demás, esto para cada conjunto de 12 intensificaciones. Por consiguiente para cada ventana se sumaron sus 160 muestras y se identificaron las dos sumatorias de mayor valor dentro de las 12 intensificaciones. La Figura 4 muestra una comparación del promediado de las 15 repeticiones de las intensificaciones 1, 2, 3, 7, 8 y 9 que se obtuvieron con el sensor Fz cuando el sujeto trataba de deletrear el carácter A. En líneas continuas de color azul y negro se muestran las intensificaciones 1 y 7 correspondientes a las posiciones del carácter A (como se observa en la Figura 3) mientras que en líneas entrecortadas en rojo y magenta se muestran los resultados de las intensificaciones 2, 3 8 y 9. En la parte superior derecha se indica el valor de la sumatoria de estas intensificaciones dentro de la ventana de 160 muestras. Como se puede observar la sumatoria de las líneas continuas es mayor en comparación con las que se obtienen en las intensificaciones colindantes. Por lo tanto, se tiene la hipótesis que las sumatorias mayores entre las intensificaciones 1 al 6 y 7 al 12 representarán la posición del carácter que se desea deletrear en columnas y filas respectivamente.

Fig. 3: Asignación numérica para filas y columnas dentro de la cuadrícula del sistema P300

De tal manera que el vector de características está formado por los dos valores máximos de las sumatorias y su posición en fila/columna. La Figura 3 muestra la asignación numérica para las filas y columnas de la cuadrícula de 6×6. De igual forma, la Figura 5 muestra el diagrama a bloques del sistema propuesto en este trabajo para la identificación de caracteres que se desean deletrear.

2.3. Implementación de clasificadores

Luego de definir las entradas al clasificador, se implementaron y compararon diferentes algoritmos de aprendizaje computacional, en específico los modelos de Máquina de Vectores de Soporte (SVM), Análisis de Discriminantes Lineales (LDA), *K* vecinos más cercanos (*K*NN) y el clasificador probabilístico *Naïve Bayes* (NB).

Para un clasificador lineal, la toma de decisiones está basada en el valor de una combinación lineal de características dada por $y = w^T x + b$ donde, w se conoce como el vector de pesos, y b se denomina *bías*. Con el fin de reducir el error en la clasificación se lleva a cabo un pre-procesamiento y un proceso de aprendizaje, posteriormente se realiza una validación con la cual se puede determinar qué tan bueno es el clasificador. Los algoritmos se pueden clasificar en supervisados y no supervisados, esto hace referencia a que en el momento de utilizarlos se cuenta o no respectivamente con la información de a qué clase pertenece cada dato. Entre los clasificadores del tipo supervisado se encuentran SVM, LDA, KNN y NB, dentro del tipo no supervisado se pueden encontrar diferentes algoritmos de agrupamiento, como el de *K*-medias [7].

SVM es un clasificador lineal supervisado que separa dos clases. Comúnmente, las etiquetas que se asignan a cada una de estas clases son {-1,+1}, donde los datos etiquetados con +1 pertenecen a una clase y los etiquetados con -1 pertenecen a otra.

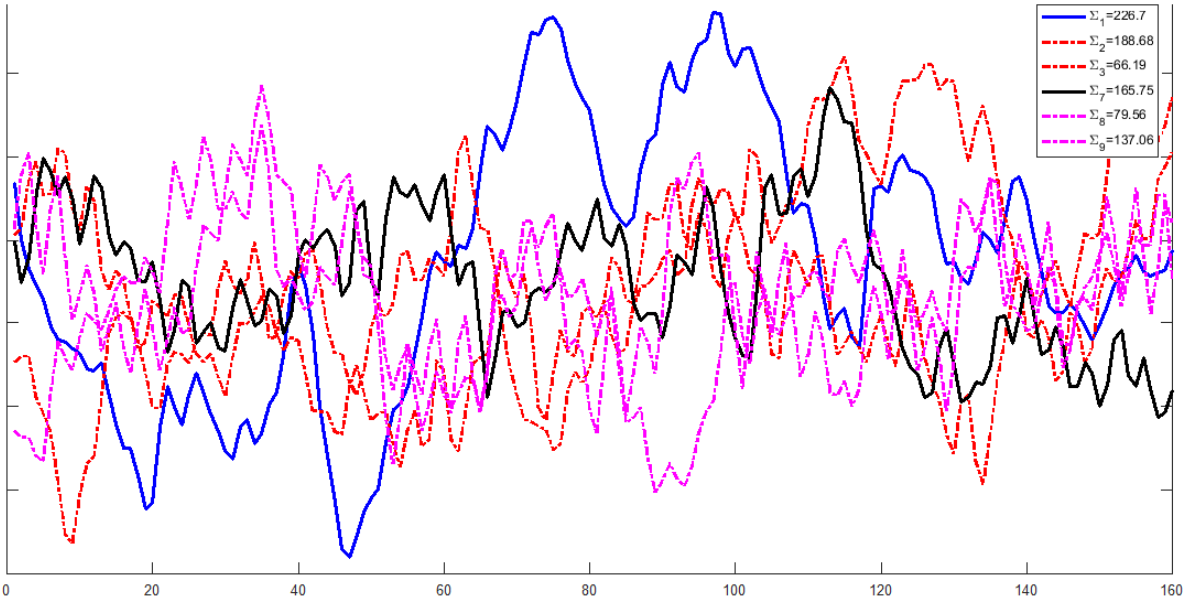

Fig. 4. Comparación entre las intensificaciones 1, 2, 3, 7, 8 y 9 en el electrodo FZ cuando el sujeto trata de deletrear el carácter A. En azul y negro con líneas continuas se muestran las intensificaciones 1 y 7 que representan la posición correcta del carácter. En líneas entrecortadas se muestra el valor de las intensificaciones colindantes con 1 y 7. La parte superior derecha muestra el valor de la sumatoria de estas intensificaciones dentro de la ventana de 160 muestras.

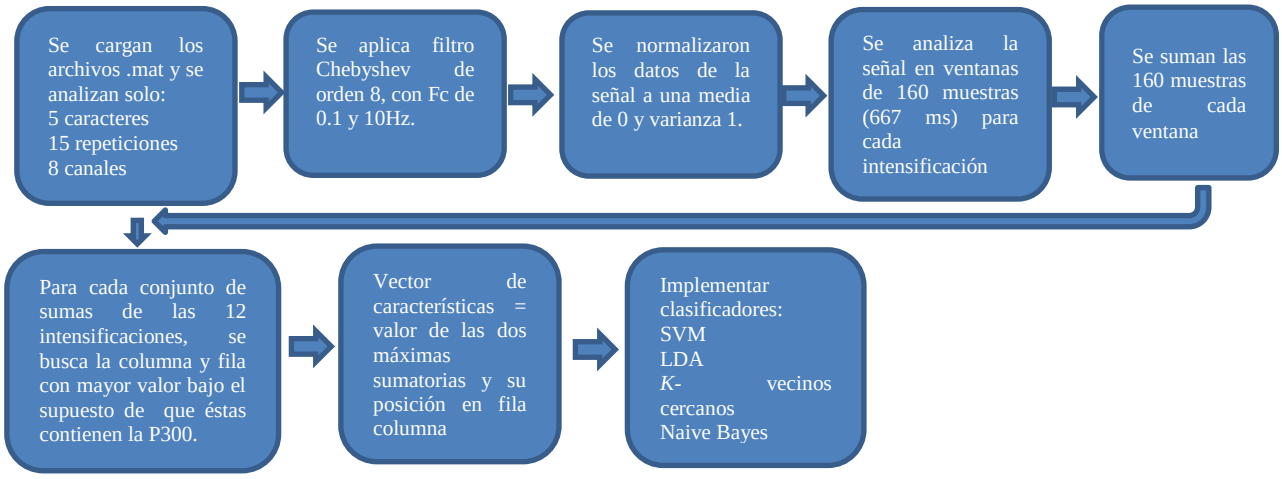

Fig. 5. Diagrama a bloques del sistema propuesto para la detección y clasificación de potenciales evocados P300.

Para realizar la clasificación, SVM encuentra el mejor hiperplano de separación para las clases dado por $w^T x + b = 0$. Es decir, un hiperplano que genere un mayor margen entre dos clases, para lograrlo, se trata como un problema de optimización y se hace uso de los multiplicadores de Lagrange [7]. La separación que hace SVM no necesariamente debe ser lineal, tiene la opción de usar a un kernel gaussiano o polinomial, entre otros.

El algoritmo de LDA, también conocido como discriminante de *Fisher*, sirve de herramienta para disminuir la dimensionalidad en problemas de clasificación y aplicaciones de aprendizaje computacional. Este clasificador puede trabajar con vectores *n*-dimensionales. En LDA se calcula la media de los datos de cada clase y la covarianza entre las clases. Con estos datos se genera la matriz de varianza-covarianza con la cual LDA calcula la dispersión dentro de una clase y entre las clases. Con esta información se define la línea que mejor separe los datos [7].

El algoritmo *K*NN es un sistema de clasificación supervisado basado en criterios de vecindad. *K*NN se basa en la idea de que los datos serán clasificados a la clase a la cual pertenezca la mayor cantidad de vecinos más cercanos a ellos. La distancia euclidiana es la métrica más común que se utiliza para identificar los vecinos más cercanos, sin embargo, no es la única. Cuando se trata con una clasificación binaria es conveniente usar un número impar de *k* vecinos con el fin de evitar empates.

3. RESULTADOS

Como se mencionó anteriormente, en este trabajo se consideró solamente la identificación de 5 caracteres con 15 repeticiones y 8 canales del sujeto de prueba A de la base de datos *BCI competition III, Data set II*. Estos caracteres son A, E, V, Q y T. Considerando las 15 repeticiones de 8 canales de cada carácter, se tienen un total de 120 señales para analizar (15x8).

Si se extraen 4 características por cada señal y tomando 2/3 partes para diseñar el clasificador y el resto para probar su capacidad de generalización (validación), la matriz de entrenamiento es de dimensionalidad 4×80, mientras que la de prueba es de 4×40. La Tabla 2 muestra los resultados de exactitud obtenidos en las etapas de entrenamiento y prueba. El algoritmo que mejor desempeño obtuvo fue el de *K*-vecinos más cercanos con una $K = 3$. Se realizaron varias pruebas para definir el valor de *K* siendo 3 el que mejor resultados obtuvo. El algoritmo de SVM con kernel gaussiano fue el segundo mejor con resultados muy semejantes a *K*NN. SVM es un algoritmo que separa datos pertenecientes a dos clases. Para utilizarlo en problemas donde se deban de identificar más de dos, es necesario implementar *n* cantidad de modelos como clases a identificar. En este caso se implementaron 5 diferentes clasificadores de SVM, uno para cada carácter a identificar.

4. CONCLUSIONES

En la literatura se han reportado resultados cercanos al 90% en la detección y clasificación de potenciales evocados P300 utilizando algoritmos basados en SVM y LDA como clasificadores. En los resultados presentados en la Tabla 2 se mostró un máximo porcentaje de detección del 73% y 47% en las etapas de entrenamiento y prueba respectivamente y uno de los algoritmos que obtuvo ese desempeño es basado en SVM. El otro clasificador que obtuvo mejor desempeño es el basado en vecinos cercanos. Este resultado es muy interesante, dado que esta estrategia es de las menos sofisticadas, por lo que nos hace pensar que existe suficiente diferencia en las señales mismas para lograr una mejor clasificación.

Tabla2. Comparación de resultados para la etapa de entrenamiento y prueba en la detección y clasificación de potenciales evocados P300

Clasificador	Porcentaje fiabilidad en la detección de potenciales evocados P300.	
	Entrenamiento	**Prueba**
SVM (kernel lineal)	0.385	0.39
SVM (kernel gaussiano)	**0.7325**	**0.465**
SVM (kernel polinomial)	0.5925	0.44
Análisis de discriminantes lineales	0.56	0.49
***3*- vecinos más cercanos**	**0.73**	**0.475**
Naive Bayes	0.52	0.49

El siguiente paso es identificar y clasificar los 36 diferentes caracteres de la cuadrícula considerando toda la información que se proporciona en la base de datos del concurso de *BCI competition III*. Ahora que ya se tienen un mayor conocimiento y dominio de la problemática, se deberán también de estudiar e implementar otras estrategias en la etapa de extracción de características ya que el buen desempeño del clasificador depende en gran medida de esta etapa. El analizar señales EEG provenientes de varios electrodos no es una tarea trivial. Estas señales tienen un comportamiento no estacionario y no lineal. Dadas estas características se buscará también la implementación de modelos basados en Redes Neuronales Artificiales ya que estos algoritmos han demostrado ser un buen aproximador de funciones no lineales.

4.1. Referencias.

[1] INEGI, «Discapacidad en Mexico,» 2010. [En línea]. Available: http://cuentame.inegi.org.mx/poblacion/discapacidad.aspx?tema=P. [Último acceso: 2 Junio 2017].

[2] A. Rakotomamonjy y V. Guigue, «BCI Competition III: Dataset II-Ensemble of SVMs for BCI P300 Speller,» *IEEE Transactions on Biomedical Engineering*, vol. 55, nº 3, pp. 1147-1154, 2008.

[3] G. Bauer, F. Gerstenbrand y E. Rumpl, «Varieties of the locked-in syndrome,» *Journal of Neurology*, vol. 221, nº 2, p. 77–91, 1979.

[4] S. Amiri, A. Rabbi, L. Azinfar y R. Fazel-Rezai, «A review of hybrid brain-computer interface systems,» de *Brain-Computer Interface Systems - Recent Progress and*, InTech, 2013, p. 1.

[5] B. Blankertz , K. R. Muller , D. J. Krusienski , G. Schalk , J. R. Wolpaw , A. Schlogl , G. Pfurtscheller , J. R. Millan , M. Schroder y N. Birbaumer, «The BCI competition III: validating alternative approaches to actual BCI problems,» *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, nº 2, pp. 153-159, 2006.

[6] H. Mirghasemi , M. B. Shamsollahi y R. Fazel-Rezai, «Assessment of Preprocessing on Classifiers Used in the P300 Speller Paradigm,» de *International Conference of the IEEE Engineering in Medicine and Biology Society*, New York, NY, USA, 2006.

[7] R. O. Duda, P. E. Hart y D. G. Stork, «Pattern classification, 2nd Edition,» de *Pattern classification*, John Wiley & Sons, 2012, p. 680 .