

Clasificación de señales EEG usando LDA y QDA aplicado a una Interface Cerebro – Computador basada en P300

Classification of EEG signals using LDA and QDA applied to a Brain – Computer Interface based on P300

Franklin Cabezas¹ *, Fermín Cabezas¹

¹ Facultad de Ingeniería Eléctrica y Electrónica, Universidad Nacional de Ingeniería, Av. Túpac Amaru 210, Lima, Perú.

Recibido (Received): 22/12/2018

Aceptado (Accepted): 17/02/2018

RESUMEN

Se han empleado diferentes técnicas de *Machine Learning* con la finalidad de identificar las voluntades de pacientes con enfermedades neurodegenerativas. Para tal fin se empleó una base de datos de señales electroencefalográficas (EEG) las cuales fueron filtradas y procesadas. La determinación de las voluntades de los pacientes se consiguió a través de la identificación de las ondas cerebrales P300, estas señales se presentan en el cerebro como respuesta a un estímulo inesperado y entre sus muchas aplicaciones se encuentra la implementación de la llamada Interface Cerebro – Computador.

La etapa de pre procesamiento de las señales se consiguió mediante el filtrado de las mismas, empleando un Filtro Digital Butterworth de Sexto Orden, así como mediante técnicas de Submuestreo, Windsorizing y Escalamiento. Adicionalmente, para efectos de reducción de dimensionalidad de las señales, se empleó la técnica de Análisis de Componentes Principales (PCA). Finalmente, para efectuar la clasificación de señales y determinar si estas contienen o no ondas P300, se emplearon las técnicas de Análisis Discriminante Lineal (LDA), Análisis Discriminante Cuadrático (QDA) y Coeficiente de Correlación de Pearson. Los resultados obtenidos muestran que las técnicas propuestas consiguen determinar eficientemente las voluntades de los pacientes, alcanzando una tasa de clasificación de 86% al usar LDA. Estos resultados fueron validados con los datos proporcionados en la base de datos.

Palabras Clave: P300, Machine Learning, Interface Cerebro – Computador, Enfermedades Neurodegenerativas

ABSTRACT

Different Machine Learning techniques have been used in order to identify the wishes of patients with neurodegenerative diseases. For this purpose, a database of electroencephalographic (EEG) signals was used, which were filtered and processed. The determination of the wills of patients was achieved through the identification of P300 brain waves, these signals are presented in the brain in response to an unexpected stimulus and among its many applications is the implementation of the so-called Brain Computer Interface.

The stage of pre-processing of the signals was achieved by filtering them, using a Sixth Order Butterworth Digital Filter, as well as by Subsampling, Windsorizing and Scaling techniques. Additionally, for reducing the dimensionality of the signals, the technique of Principal Component Analysis (PCA) was used. Finally, to perform the classification of signals and determine if they contain P300 waves or not, the techniques of Linear Discriminant Analysis (LDA), Quadratic Discriminant Analysis (QDA) and Pearson's Correlation Coefficient were used. The results obtained show that the proposed techniques efficiently determine the wills of patients, reaching a classification rate of 86% when using LDA. These results were validated with the data provided in the database.

Keywords: P300, Machine Learning, Brain – Computer Interface, Neurodegenerative Diseases

1. INTRODUCCIÓN

Cada año millones de personas en el mundo se ven afectadas por diversos males neurodegenerativos que conllevan a severas discapacidades motrices.

Enfermedades tales como la esclerosis lateral amiotrófica, la esclerosis múltiple o la enfermedad de Huntington, conllevan a limitaciones permanentes de las vías nerviosas, las cuales están designadas al control de los músculos implicados en la ejecución voluntaria de los movimientos. Como consecuencia de estos males, muchas de estas personas quedan prácticamente aisladas de su entorno.

*Corresponding author:
E-mail: fcabezash@uni.pe

En el Perú, aproximadamente 700.000 personas sufren alguna enfermedad neurodegenerativa, cifra que representa más del 2% de la población nacional [1].

En los últimos 30 años se ha venido desarrollando una tecnología llamada Interface Cerebro – Computador (BCI), la cual utiliza señales cerebrales para establecer una ruta de comunicación entre una persona y un dispositivo externo. Esta tecnología permite a los pacientes comunicarse, desplazarse o activar y/o controlar dispositivos de su entorno.

Entre las muchas señales cerebrales, existen un grupo que pueden ser empleadas como señales de control en sistemas BCI, tales como: Potenciales evocados visuales, potenciales corticales lentos, ritmos sensoriomotores y los potenciales evocados cognitivos. La onda P300 es un potencial evocado que se manifiesta aproximadamente 300 ms después de la presentación de un estímulo inesperado, sea este visual, audible o somatosensorial, en la Figura 1 se observa una típica onda P300.




Figura 1. Onda P300 [1].

Farwell y Donchin (1988) fueron los primeros en emplear el P300 como señal de control en una Interfaz Cerebro – Computador. Describieron el sistema de deletreo P300, una matriz de 6 x 6 que contenía las letras del alfabeto y otros símbolos que se mostraban en una pantalla de computadora, lo que permitía a los pacientes formar palabras y comunicarse.

En este trabajo se empleó la base de datos generada por Hoffmann et al. [2] quienes emplearon un paradigma P300 de seis opciones, que se probó utilizando una población de cinco personas discapacitadas y cuatro personas sanas. En su experimentación emplearon seis imágenes que destellaban en una pantalla de forma aleatoria con un intervalo de estímulo de 400 ms. Se probaron configuraciones de electrodos que consistían en cuatro, ocho, dieciséis y treinta y dos. Para clasificar las señales cerebrales se emplearon el Análisis Discriminante Lineal Bayesiano (BLDA) y el Análisis Discriminante Lineal de Fisher (FLDA).

En la Figura 2 se observa una recreación de la experimentación realizada por Hoffman et al. para la adquisición de las señales electroencefalográficas.




Figura 2. Paciente contando mentalmente el número de destellos de la imagen solicitada mientras sus señales cerebrales son registradas.

2. METODOLOGÍA

Dado que las señales cerebrales presentan un alto nivel de ruido, es necesario aplicar distintas técnicas de pre procesamiento:

Extracción de componente referencial: Entre el grupo de electrodos empleados para captar las señales cerebrales de los participantes, dos de ellos fueron ubicados en la región de las apófisis mastoides, esta región permite captar con mayor sensibilidad ciertos ruidos biológicos. Por tanto a cada señal cerebral se le sustrajo el promedio de las señales medidas por estos dos electrodos.

Filtrado: Dado que los electrodos, además de captar las señales de interés, captan también abundantes señales ruidosas, es necesario restringir la banda de frecuencias a un intervalo en el cual sea más probable encontrar las ondas P300. Por ello, se eligió como banda de interés el rango comprendido entre 0.1 y 12Hz. Para restringir las señales a esta banda se diseñó y empleó un Filtro Digital Butterworth Pasa Banda de Sexto Orden.

Extracción de segmentos temporales: En esta etapa se extrajeron los segmentos de tiempo en que destelló la imagen en la que se concentró cada paciente y los segmentos de tiempo en los que destellaron el resto de imágenes, conformando matrices para cada caso.

Windsorización: Los valores de amplitud de cada una de las muestras por encima del 90° percentil y por debajo del 10° percentil fueron ajustados a los percentiles 90 y 10 respectivamente, esto se efectuó como una medida para atenuar las señales biológicas que se presentan fuera de estos rangos.

Escalamiento: Las muestras de cada electrodo fueron escaladas al rango entre -1 y 1.

3. RESULTADOS

Se trabajó con una configuración de 4 electrodos. En la parte superior de la Figura 3 se observa la ubicación de estos electrodos, en la parte inferior se observan las señales medidas por estos electrodos.




Figura 3. Ubicación y medición de los electrodos.

Se observa en la Figura 3 que al final de cada señal hay una caída abrupta de voltaje, para obviar esta caída que podría alterar los resultados, se obviaron las muestras finales. En la Figura 4 se observan las señales cerebrales sin caídas de voltaje.




Figura 4. Señales de los electrodos sin caídas de voltaje.

A estas señales se les sustrajo el promedio de las señales de referencia. En la Figura 5 se observan las señales resultantes.




Figura 5. Señales de los electrodos menos la referencia.

Previamente a la aplicación del Filtro Digital Butterworth, se estudió el desempeño de otros filtros digitales para la identificación de las ondas P300, en la Tabla 1 se compara el rendimiento de cada uno de los filtros estudiados.

TABLA 1. Valores por cada electrodo y filtro analizado.

Filtro	Voltaje máximo (uV) por lóbulo			
	Frontal (Fp1, e1)	Temporal (T8, e8)	Parietal (Pz, 13)	Occipital (Oz, 16)
V. Hamming	2621.3	219.5	5243.6	-1386.2
V. Von Hann	2624.8	219.8	5250.7	-1388.1
V. Rectangular	2580.9	216.5	5162	-1364.3
V. Blackman	2422.8	202.9	4846.5	-1281.2
V. Triangular	2374.8	198.9	4750.3	-1255.8
Butterworth	3115.1	261	6231.8	-1647

Posteriormente fue aplicado el filtro pasa banda, en la Figura 6 se observan las señales resultantes.




Figura 6. Señales de los electrodos filtradas en banda entre 1 y 12Hz.

Luego las señales fueron sub muestreadas a 32 Hz, las señales se observan en la Figura 7.




Figura 7. Señales de los electrodos sub muestreadas a 32Hz.

Las señales cerebrales posteriormente son segmentadas en intervalos en los que destelló la imagen elegida por el paciente e intervalos en los que destellaron el resto de imágenes, construyendo así dos matrices. Al promediar los intervalos de tiempo en los que destelló la imagen en la que se concentró el paciente, se consiguió aumentar el nivel de señal a ruido y quedó en evidencia la presencia de la onda P300, tal como se observa en la Figura 8.




Figura 8. Onda P300 detectada.

Dado que el ruido biológico presente en las señales EEG registradas produce valores atípicos de amplitud, se aplicó la técnica estadística de windsorización, el resultado se observa en la Figura 9.




Figura 9. Resultado de aplicar Windsorizing.

Para la obtención de un buen desempeño del clasificador a emplearse, se escaló la señal de entrada, con valores en el rango de $[-1,1]$. Esto permitió evitar que los datos fueran altamente variables haciendo así más rápida la clasificación y evitando caer en óptimos locales, el resultado se observa en la Figura 10.



Figura 10. Resultado de aplicar Escalamiento.

Seguidamente se aplicó el Diagrama de Cajas (Boxplot) a las señales obtenidas, los resultados se observan en la Figura 11.




Figura 11. Boxplot de las señales cerebrales.

En la Figura 11 se observa que hay baja variabilidad en las señales de los electrodos 31 (Fz) y 32 (Cz), mientras que en los electrodos 13 (Pz) y 16 (Oz), la variabilidad es mayor. Las muestras que conforman las dos primeras componentes principales pueden ser graficadas de forma escalada, en la Figura 12 se observa el gráfico respectivo.




Figura 12. Muestras escaladas en las primeras componentes principales.

En la Figura 12 se observa que se han indicado las muestras 332, 838 y 1454, estos son algunas de las muestras que se encuentran más distancias del cúmulo de muestras de la gráfica.

A continuación, en la Figura 13 se observa la variabilidad porcentual para cada componente principal. Así, la primera componente principal contiene el 77.85% de toda la información medida por los 4 electrodos, mientras que la segunda componente principal alberga el 19%, la tercera y cuarta componente principal contienen el 2.6% y 0.6% respectivamente.




Figura 13. Diagrama de Componentes Principales

En la Figura 14 se observa a cada uno de los cuatro electrodos representados por un vector, la dirección y la longitud del vector indican cómo cada electrodo contribuye a los dos componentes principales de la Figura 13.




Figura 14. Representación vectorial de electrodos.

El primer componente principal en el eje horizontal tiene coeficientes positivos y negativos para los cuatro electrodos, así los 4 vectores se dirigen al lado derecho e izquierdo del plano.

Los mayores coeficientes en el primer componente principal son los correspondientes a los electrodos Pz y Fz, de los cuales el electrodo Pz es el de mayor longitud, lo cual permite verificar lo aseverado por [3 - 6], en el que se indica que la amplitud de la onda P300 es máxima.

Como primera técnica de clasificación, se empleó el Coeficiente de Correlación de Pearson, el cual permitió medir el grado de asociación entre las variables X, Y. Siendo X el vector conformado por las muestras que constituyen el promedio de segmentos de tiempo en los que destellaron cada una de las imágenes y siendo Y el vector conformado por las muestras de los destellos de cada imagen.




Figura 15. Diagrama de dispersión entre las variables y recta de regresión.

Los resultados de clasificación se observan en la Figura 16, en la cual se deduce que para un ensayo específico la figura en la que se concentró el paciente fue el televisor.




Figura 16. Coeficientes de correlación promedio de cada una de las seis imágenes.

Debido al impacto repetitivo de alguno de los estímulos en la señal cerebral aparecen eventos target. De esta forma la señal cerebral está compuesta de eventos target y eventos non - target [7 - 10].




Figura 17. Eventos target y non - target.

Cada uno de estos eventos se representa por un vector espacial de 32 muestras o propiedades $x = [x_1, x_2, \dots, x_{32}]$.

doi: <https://doi.org/10.21754/tecnia.v28i2.573>

La representación de estos vectores será un conjunto de círculos en un espacio matemático de 32 dimensiones. El gráfico de estos vectores (círculos) en un plano (asumiendo que solo tienen dos componentes) se presenta en la Figura 18 donde los círculos blancos representan los eventos *target* y los círculos negros, son los eventos *non - target* [11 -13].




Figura 18. Hiperplano de separación de clases LDA.

Si se aplica la probabilidad de ocurrencia de las dos clases (asumiendo que ambas tienen distribución gaussiana), se obtiene la Figura 19.




Figura 19. Separación de clases target y non target [4].

Si las Figuras 18 y 19 se representan en un plano para visualización, se obtiene la Figura 20.




Figura 20. Separación en clases 1 y 2 [5].

El objetivo de LDA es hallar los coeficientes W de la ecuación de un plano que permita separar en la mejor forma (clasificación óptima) las dos clases de eventos: target y non - target en el espacio de eventos.

La ecuación del plano es:

$$g(x_1, x_2, \dots, x_{32}) = \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_{32} x_{32}$$

$$g(x) = \omega^T x \quad (1)$$

Dónde: x_i son las propiedades de los eventos.

ω_i pesos que definen la ubicación del plano.

Como se ve en la Figura 20, al separar los eventos, por lo general se producirá un error debido a que las funciones probabilísticas de las dos clases se traslapan. Evidentemente el error será mínimo cuando la distancia entre las medias de las dos clases sea la máxima posible y sus varianzas sean las mínimas posibles. Esto resulta en un problema de maximización con función objetivo [14 - 16].

$$J(\omega) = \frac{\omega^T S_B \omega}{\omega^T S_W \omega} \quad (2)$$

Donde:

$$m_1 = \frac{1}{N_1} \sum_{i \in C_1} x_i; \quad m_2 = \frac{1}{N_2} \sum_{i \in C_2} x_i \quad (3)$$

m_1 y m_2 son medias vectoriales de las clases 1 y 2.

c_1 y c_2 son índices de las clases 1 y 2.

N_1 y N_2 son los números de muestras en las clases 1 y 2.

$$S_B = (m_1 - m_2)(m_1 - m_2)^T \quad (4)$$

S_B es la distancia matricial entre las medias de las clases.

$$S_W = \sum_{k=1}^2 \sum_{i \in C_k} (x_i - m_k)(x_i - m_k)^T \quad (5)$$

S_W es la suma de las varianzas matriciales de las dos clases.

El máximo valor de $J(\omega)$ se encuentra calculando su derivada y haciéndola igual a cero, con esto se consigue el vector ω .

$$\omega = S_W^{-1}(m_1 - m_2) \quad (6)$$




Figura 21. Clasificación LDA y QDA en una dimensión.

En la Tabla 2 se muestran los resultados de clasificación de los cuatro pacientes.

TABLA 2. Resultados de clasificación (%).

	LDA	Pearson	QDA
Paciente 1 (Parálisis Cerebral)	86	81	67
Paciente 2 (Esclerosis Múltiple)	88	80	61
Paciente 3 (Esclerosis Lateral Amiotrófica)	81	78	68
Paciente 4 (Lesión cerebral y daño a la columna)	83	77	67

4. CONCLUSIONES

Se concluye que las técnicas de clasificación empleadas permitieron identificar exitosamente las voluntades de los pacientes, esta tasa de clasificación se vio repotenciada con la aplicación de las técnicas de pre - procesamiento y PCA.

REFERENCIAS

- [1] Cabezas F. 2018. Identificación de Potenciales Eléctricos relacionados a eventos seleccionados por pacientes con enfermedades neurológicas empleando Transformada Wavelet. Tesis de Maestría (datos no publicados). Universidad Nacional de Ingeniería. Perú.
- [2] Hoffmann U. et al. 2007. An Efficient P300 – based brain – computer interface for disabled subjects. *Journal of Neuroscience Methods* 167, 115 – 125.
- [3] Franz E. 2014. Development of a Fast and Efficient Algorithm for P300 Event Related Potential Detection. Master’s Thesis. Temple University. United States.
- [4] Polich J. 1986. Normal variation of P300 from auditory stimuli.
- [5] R. Sepúlveda et al. Clasificación de señales EEG mediante redes neuronales artificiales. *Computación y sistemas*, Vol. 19, N° 1, 2015, pp. 69 – 88.
- [6] Artusi X. 2013. Interface Cerveau Machine avec adaptation automatique à l'utilisateur. PhD Dissertation. École Centrale de Nantes. France.
- [7] Fazel R et al. 2012. P300 brain computer interface: current challenges and emerging trends. *Frontiers in Neuroengineering*, 1(1), 5:14.
- [8] Girase P, Deshmukh M. 2016. A Review of Brain Computer Interface. *International Conference on Global Trends in Engineering, Technology and Management (ICGTETM)*.
- [9] Henríquez C. 2014. Estudio de técnicas de análisis y clasificación de señales EEG en el contexto de Sistemas BCI. Tesis de Maestría. Universidad Autónoma de Madrid. España.
- [10] Nicolás – Alonso L y Gómez – Gil J. 2012. Brain Computer Interfaces, a Review. *Sensors*, 12(2), 1211 – 1279.
- [11] Nicolás Alonso, L. 2012. Clasificación de características de electroencefalogramas en sistemas Brain Computer Interface basados en ritmos sensoriomotores. Tesis de Maestría. Universidad de Valladolid. España.
- [12] Won D, Zhang H, Guan C & Lee S. 2014. A BCI Speller based on SSVEP using high frequency stimuli design. *IEEE International Conference on Systems, Man and Cybernetics*.
- [13] Combaz A & Van Hulle. 2015. Simultaneous Detection of P300 and Steady – State Visually Evoked Potentials for Hybrid Brain – Computer Interface.
- [14] Achic F et al. 2016. Hybrid BCI System to Operate and Electric Wheelchair and a Robotic Arm for Navigation and Manipulation Tasks. *ARSO*.
- [15] Amiri S, Rabbi, A, Azinfar, L & Fazel – Rezai R. 2013. A Review of P300, SSVEP and Hybrid P300/SSVEP Brain - Computer Interface Systems.
- [16] Liu, Y, Wang, S & Hu, M. 2016. A Self - Paced P300 Healthcare Brain - Computer Interface System with SSVEP - Based Switching Control and Kernel FDA + SVM - Based Detector.



Los artículos publicados por TECNIA pueden ser compartidos a través de la licencia Creative Commons: CC BY 4.0 Perú. Permisos lejos de este alcance pueden ser consultados a través del correo revistas@uni.edu.pe