# Aplicación de las Máquinas de Vector Soporte en Sistemas Brain Computer Interface basados en potenciales P300

L. Martín González<sup>1</sup>, R. Corralejo Palacios<sup>1</sup>, R. Hornero Sánchez<sup>1</sup>

<sup>1</sup> Grupo de Ingeniería Biomédica, E. T. S. Ingenieros de Telecomunicación, Universidad de Valladolid, Valladolid, España lauramartingc@gmail.com, rebeca.corralejo@uva.es, robhor@tel.uva.es

## Resumen

En el presente trabajo se ha analizado el conjunto de datos II de la III Competición BCI (2005) proporcionados por el Wadsworth Center (NYS Department of Health) y se ha profundizado en los métodos de selección de canales y clasificación de características considerados por el método ganador de esta competición. Este método emplea un conjunto de máquinas de vector soporte (Support Vector Machine, SVM) junto con un procedimiento de selección de canales. Se propone modificar el procedimiento de selección de canales y ampliar el rango de valores del hyperparámetro C del SVM. Dicha metodología consigue una precisión media del 98,5 % para 15 repeticiones, mejorando los resultados obtenidos por el método ganador.

## 1. Introducción

Un sistema *Brain Computer Interface* (BCI) es aquel que monitoriza la actividad cerebral y traduce determinadas características, correspondientes a la intención del usuario, en comandos de control de un dispositivo. Para registrar dicha actividad cerebral el método más empleado es el electroencefalograma (EEG) ya que es una técnica portátil, de bajo coste y no invasiva [1].

El EEG aporta gran variedad de señales útiles para el control de sistemas BCI: potenciales evocados visuales, potenciales P300, ritmos sensoriomotores y potenciales corticales lentos [1]. Este trabajo se centra en los sistemas BCI que emplean como señal de control los potenciales evocados P300.

Cuando a un sujeto se le presentan dos categorías de estímulos, una de ellas con menor probabilidad que la otra, se provoca un potencial evocado denominado P300 [2]. La latencia en aparecer el potencial es de 300 ms, de ahí su nombre. La probabilidad de aparición del potencial es mayor cuanto menos frecuente es el estímulo asociado. La aplicación típica de un sistema BCI basado en potenciales P300 la desarrollaron Farwell v Donchin en 1988 [2], también llamado paradigma P300. Se trata de una matriz de 6 filas y 6 columnas que contiene letras y números. Las filas y las columnas de la matriz se iluminan aleatoriamente. Los sujetos deben prestar atención a uno de los caracteres de la matriz y contar cuántas veces se ilumina. Como respuesta a la intensificación de la fila o columna que contiene el caracter deseado, aparece un potencial en la actividad cerebral del usuario. Tras doce iluminaciones, cada fila y columna se ha iluminado una vez y, por tanto, el elemento deseado por el usuario se ha iluminado dos veces. Se promedia, entonces, la respuesta para cada elemento de la matriz. El elemento que presente un potencial de mayor amplitud se idenfica como el deseado por el usuario.

Para interpretar la señal del sujeto a partir de la señal EEG se necesitan dos etapas de procesado de señal: extracción de características y clasificación de las mismas. Los métodos de extracción de características realizan distintas combinaciones y transformaciones sobre la señal EEG. Las características obtenidas deben proporcionar la mayor capacidad discriminatoria posible. Por su parte, los métodos de clasificación aplican diferentes modelos estadísticos al conjunto de características extraídas. De esta forma, se determina para qué fila y qué columna aparece un potencial evocado.

Los diferentes grupos de investigación que implementan métodos de extracción y de clasificación de características, tienen la posibilidad de participar en las competiciones BCI. Estas competiciones comenzaron a desarrollarse a partir del año 2001 [3]. En éstas se ofrecen señales registradas de distintos sujetos. Los grupos de investigación prueban sus métodos sobre las mismas señales y divulgan los resultados. La señales proporcionadas se dividen en dos grupos: señales etiquetadas y señales sin etiquetar. Las señales etiquetadas (conjunto de entrenamiento) se emplean para optimizar los métodos implementados. Posteriormente, esos métodos se aplican a las señales sin etiquetar (conjunto de test). El grupo ganador es el que consigue la mayor precisión al clasificar las señales del conjunto de test.

En el presente trabajo se emplea el conjunto de datos II de la III Competición BCI (2005). Esta competición es la mas reciente que aporta señales de potenciales P300. El grupo ganador emplea un método de clasificación basado en un conjunto de máquinas de vector soporte (Support Vector Machine, SVM) junto con un procedimiento de selección de canales [4]. Se propone una modificación del procedimiento de selección de canales así como del rango de valores del hiperparámetro C del SVM. El objetivo de este trabajo es diseñar una clasificación mas precisa para el conjunto de datos de la competición.

## 2. Señales EEG

Las señales que se emplean pertenecen al conjunto de datos II de la III Competición BCI (2005) proporcionados

por el Wadsworth Center (NYS Department of Health) [5]. Este conjunto contiene registros completos de potenciales evocados P300. Las señales se filtran entre 0.1 y 60 Hz y se muestrean a 240 Hz. El conjunto de datos pertenecen a registros de dos sujetos distintos. Cada uno de ellos realiza 5 sesiones. Las columnas o filas se intensifican durante 100 ms. Después de la intensificación de una fila o columna, la matriz permanece inalterada durante 75ms. Estas filas y columnas se iluminan en bloques de 12, de forma aleatoria. El conjunto de las 12 intensificaciones de cada columna y fila de la matriz se repite 15 veces. De esta forma, se producen 180 iluminaciones de filas y columnas para la selección de un carácter. Entre la selección de un carácter y el siguiente pasan 2.5 s en el que la matriz permanece intacta. Durante este periodo, se muestra en la parte superior de la pantalla entre paréntesis, el carácter que se acaba de seleccionar y se muestra el siguiente carácter en el que ha de fijarse el sujeto.

El conjunto de entrenamiento está formado por las pruebas realizadas con 85 caracteres y el conjunto de test por pruebas realizadas con 100 caracteres para cada sujeto. La señales fueron registradas según el sistema 10-20 [6].

El objetivo de la III Competición BCI (2005) para este conjunto de datos, consiste en implementar un método que emplee el conjunto de datos de entrenamiento y prediga la secuencia de caracteres del conjunto de datos de test. Los resultados deben mostrar la precisión obtenida para ambos sujetos sobre el conjunto de test tanto si se han producido 15 repeticiones (15 intensificaciones fila/columna, 180 intensificaciones en total), como si se han producido 5 repeticiones (60 intensificaciones en total). El grupo con mayor porcentaje de aciertos cuando se consideran 15 repeticiones gana la competición. En caso de empate, gana el que mayor porcentaje de aciertos consiga con 5 repeticiones.

El método que obtuvo mejores resultados fue el que propusieron Rakotomamonjy y Guigue de la escuela pública de ingenieros INSA de Rouen, en Francia [4].

## 3. Metodología

## 3.1. Método ganador

P300 Los potenciales evocados aparecen aproximadamente 300 ms después del estímulo. Por esta razón, el método ganador extrae de las señales de la competición, los 667 ms posteriores a la intensificación de una columna o fila. A continuación, se realiza un filtrado pasa-banda de Chevyschev de orden 8 y de Tipo I con frecuencias de corte de 0.1 y 10 Hz. Después se procede a hacer un diezmado obteniendo 14 muestras por cada post- estímulo para cada uno de los 64 canales. Para cada post-estímulo se genera un vector de 896 columnas. La matriz obtenida estará formada por 896 columnas v 15300 filas (12 estímulos x 15 repeticiones x 85 caracteres de entrenamiento) para cada sujeto. Cada una de las filas de la matriz se asocia a una etiqueta de valor 1 ó -1 dependiendo de si el estímulo iluminado es el deseado o no.

Una vez realizado el preprocesado y la extracción de características se procede a la división del conjunto de datos de entrenamiento en 17 subgrupos cada uno de éstos formado por 5 caracteres. Por tanto, cada partición de estas 17 será una matriz de tamaño 896 columnas y 900 (5 caracteres x180 post-estímulos) filas. El objetivo es crear un clasificador múltiple para cada sujeto, empleando para ello SVM. Cada uno de los clasificadores que forman parte del clasificador múltiple, es una SVM lineal entrenada en un subgrupo del conjunto de entrenamiento. La función de decisión para una SVM entrenada, viene dada por la expresión:

$$f_k(x) = \sum_{i \in P_k} y_i \alpha_i^{(k)} \langle x, x_i \rangle + b^{(k)}$$
 (1)

donde  $\left\{\alpha_i^{(k)}\right\}$  y  $b^{(k)}$  son parámetros que se obtienen después del entrenamiento de la SVM, x es el conjunto de post-estímulos de la patición k,  $x_i$  es cada uno de los post-estímulos del conjunto x e  $y_i$  es la etiqueta asociada a cada post- estímulo.

El resultado de esta clasificación se fusiona para obtener el carácter predicho. Se obtienen 17 clasificadores entrenados en un subconjunto del conjunto de entrenamiento. Cada clasificador asigna una puntuación  $f_k(x_{f|c})$  para k=1,...,K siendo K=17, a cada postestímulo del vector  $x_{f|c}$  asociado a una fila o columna. Después de un número de repeticiones J, se considera que la fila o columna más probable maximiza la puntuación:

$$S_{f|c} = \frac{1}{J} \frac{1}{K} \sum_{i=1}^{J} \sum_{k=1}^{K} f_k(x_{f|c}^{(j)}),$$
 (2)

donde  $x_{f|c}^{(j)}$  es el post-estímulo asociado a cada columna o fila para la partición j-ésima y  $S_{f|c}$  es la puntuación de cada fila o columna.

El método ganador incluye un procedimiento de selección de canales basado en un algoritmo recursivo de reducción de los mismos. La selección de los canales se hace en base a una puntuación obtenida a partir de la matriz de confusión. Esta puntuación viene definida por:

$$Ccs = \frac{tp}{tp + fp + fn},$$
(3)

siendo tp el número de verdaderos positivos, fp en número de falsos positivos y fn en número de falsos negativos. Cuanto mayor sea el valor de Ccs mayor será el número de potenciales P300 correctamente detectados. El valor de Ccs se calcula después de cada post-estímulo, en la clasificación binaria. Para ello, se entrena el SVM lineal con las 896 características proporcionadas por los 64 canales. Cada canal se elimina temporalmente, por lo que las 14 muestras correspondientes a ese canal se eliminan. A continuación, se calcula el valor de Ccs. Si la eliminación de ese canal nos da un valor de Ccs elevado, es debido a que el canal eliminado no proporciona información relevante al modelo. Por tanto, los canales que se eliminan son aquellos cuya eliminación proporciona mayor puntuación Ccs. Este procedimiento

se realiza para los 64 canales. La eliminación de estos canales se hace de 4 en 4 para que el algoritmo sea mas rápido (los 4 canales cuya eliminación dé como resultado las 4 puntuaciones más altas de *Ccs*). De esta forma, se eliminan primero las canales que proporcionan menos información. La configuración del modelo se hace en base al número de canales seleccionados y al hiperparámetro *C* del SVM.

El conjunto de entrenamiento está formado por 17 particiones, para cada sujeto. Cada una de estas particiones se corresponde con 5 caracteres y su tamaño inicial (sin haber eliminado ningún canal) es de 900 filas x 896 columnas. Cuando un SVM se entrena en una partición k siendo  $k \in [1,...,8]$ , entonces el conjunto de datos de validación será [1,...,8] excepto la considerada en ese momento, es decir, k. El conjunto de validación estará formado por 6300 post-estímulos. Exactamente lo mismo ocurrirá cuando se trate de las particiones  $k \in [9,...,17]$ , solo que en este caso el conjunto de validación estará formado por 7200 post-estímulos. El rango de valores del hiperparámetro C que se evalúa es  $C \in [0.01 \ 0.05 \ 0.1 \ 0.5 \ 1]$ . Para cada configuración del clasificador se elige un valor del hiperparámtero C del rango de valores considerado y el número de canales seleccionados que maximiza la puntuación Ccs.

# 3.2. Metodología propuesta

En este trabajo se proponen variaciones al método ganador propuesto por Rakotomamonjy y Guigue [4]. En particular, se ha modificado el procedimiento de selección del conjunto óptimo de canales, así como el rango de valores que puede tomar el hiperparámetro *C* del SVM.

Para la selección de canales, se emplea el modelo de eliminación recursivo propuesto por el método ganador [4]. Cada canal es temporalmente eliminado y se entrena el SVM con el resto de canales. Se calcula la puntuación Ccs obtenida para cada eliminación. Posteriormente, el vector formado por las puntuaciones Ccs obtenidas de cada eliminación del canal, se ordena de mayor a menor. Se eliminan los 4 canales cuya eliminación previa dio como resultado los 4 valores de Ccs más elevados. A continuación, se almacena el valor máximo de puntuación de cada bloque de 4 canales eliminados. Al final de este algoritmo se obtiene un vector de dimensiones 1x15 que contiene los valores máximos de puntuación Ccs conseguidos por cada bloque de 4 canales. Por último, se obtiene el valor máximo de este vector de dimensiones 1x15. Los canales que se seleccionan para el modelo se corresponden con los 4 que obtienen la puntuación máxima en dicho vector, así como los canales que fueron eliminados posteriormente a éstos. Los 4 canales que nunca se eliminan serán los que aportan mayor información.

Por otro lado, se ha modificado el rango de valores que puede tomar el hiperparámtero C del SVM. En el estudio de Rakotomamonjy y Guigue [4] el hiperparámetro C toma el rango de valores  $C \in \begin{bmatrix} 0.01 & 0.05 & 0.1 & 0.5 & 1 \end{bmatrix}$ . La elección del rango de valores de este parámetro se

elige, habitualmente, de forma experimental [7]. En este trabajo, se varió entre diferentes rangos del hiperparámetro C del SVM. Finalmente, el rango de valores seleccionado para este trabajo, además del propuesto por el método ganador, es  $C \in [1.01 \ 1.05 \ 1.1 \ 1.5 \ 2]$ . El procedimiento de selección de canales óptimos se lleva a cabo para cada valor del hiperparámtero C incluído en el rango. Finalmente se selecciona el par C-subconjunto de canales óptimos que maximiza la puntuación Ccs.

## 4. Resultados

En la Tabla 1, se muestran los resultados de precisión sobre el conjunto de test obtenidos por el método ganador y por el propuesto en este estudio. El conjunto de datos de test ha sido preprocesado de la misma forma que los datos del conjunto de entrenamiento.

Para un número de repeticiones igual a 15 se alcanza una mayor precisión con el método propuesto que con el ganador. Sin embargo, cuando el número de repeticiones es igual a 5 la precisión mejora únicamente para el sujeto B. Los valores del hiperpárametro C del SVM que han proporcionado estos valores de precisión óptimos han sido, para el sujeto A  $C \in \begin{bmatrix} 0.01 & 0.05 & 0.1 & 0.5 & 1 \end{bmatrix}$  y para el sujeto B  $C \in \begin{bmatrix} 1.01 & 1.05 & 1.1 & 1.5 & 2 \end{bmatrix}$ .

En la Tabla 2 se presentan el número de canales óptimo para la configuración de cada clasificador para el método ganador y el propuesto, en ambos sujetos. El número de canales seleccionados por ambos métodos para el sujeto A se compensa en número. Es decir, en aquellas configuraciones en las que un método elige un mayor número de canales, el otro método elige un número menor y viceversa. En el caso del sujeto B se selecciona siempre un mayor número de canales en el método propuesto para todas las configuraciones del clasificador.

Por último, en la Figura 1 se muestra la localización espacial de los canales que mayor información aportan y que se repiten en mayor número de clasificadores. Para el sujeto A estos canales se encuentran en la zona central, parietal e, incluso, temporal. Sin embargo, para el sujeto B esta localización de canales se concentra en la zona parietal y central.

# 5. Discusión y conclusiones

A la vista de los resultados, puede decirse que hay un compromiso entre la precisión alcanzada por cada sujeto, y el número de canales óptimos seleccionados. Es posible mejorar la precisión pero como consecuencia, el número

	Número de repeticiones	1	2	5	10	13	15
Método ganador	Sujeto A	16.0	32.0	72.0	83.0	94.0	97.0
	Sujeto B	35.0	53.0	75.0	91.0	96.0	96.0
	Media	25.5	42.5	73.5	87.0	95.0	96.5
Método	Sujeto A	21.0	34.0	63.0	89.0	93.0	99.0
propuesto	Sujeto B	36.0	58.0	78.0	93.0	94.0	98.0
	Media	28.5	46.0	70.5	91.0	93.5	98.5

Tabla 1. Precisión (%) sobre el conjunto de test.

Clasificador	Sujeto	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Rakotomamonjy [4]	A	32	32	36	20	40	24	36	40	40	24	28	12	56	16	40	16	16
Modelo propuesto		16	48	32	36	24	38	48	52	24	32	32	40	8	36	48	28	32
Rakotomamonjy [4]	В	12	8	16	16	12	12	4	12	16	16	8	8	8	4	8	12	4
Modelo propuesto		48	52	52	56	42	52	36	48	52	52	48	48	48	52	48	36	36

Tabla 2. Número de canales seleccionados para cada configuración del clasificador en el método ganador y en el propuesto.

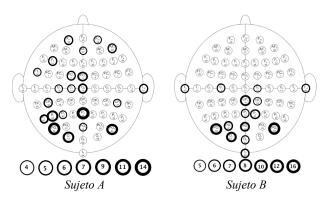


Figura 1. Localización de los canales óptimos seleccionados por el método propuesto. El grosor de la línea es mayor cuantas más veces haya sido seleccionado el canal.

de canales óptimos seleccionados es mayor. O al contrario, disminuye la precisión a costa de disminuir el número óptimo de canales seleccionados.

El sujeto A ha conseguido mayor precisión para un número de 15 repeticiones debido al número de canales óptimos seleccionados. Los canales de los que prescinde o los canales añadidos al modelo, con respecto a los canales considerados por el método ganador, proporcionan información adicional. Como consecuencia se produce un incremento de la precisión patente cuando el número de repeticiones es mayor de 13. Por otro lado, esta diferencia en el número de canales óptimos seleccionados hace que disminuya la precisión si el número de repeticiones es de 5

Para el sujeto B la precisión, tanto para 5 como 15 repeticiones, se ha incrementado con respecto al método ganador. Este aumento de precisión se debe a dos factores fundamentales. Por un lado, el número de canales que selecciona el método propuesto es considerablemente mayor que en el método ganador. Esto da mas margen a la hora de calcular la precisión puesto que se dispone de mas información. Sin embargo, el número de electrodos empleados sería muy elevado. Otro de los factores está relacionado con la selección del rango de valores del hiperparémtro C del SVM. Para este sujeto el rango de valores seleccionado ha sido  $C \in [1.01 \ 1.05 \ 1.1 \ 1.5 \ 2]$ . La elección de este rango de valores ha localizado espacialmente mejor la respuesta al potencial evocado P300 en la zona central y parietal, donde típicamente aparece. Por lo tanto, sería aconsejable aprovechar esta localización de los canales y analizar cómo afecta a la precisión una reducción progresiva en el número de éstos.

Una de las limitaciones del presente estudio se debe al reducido número de usuarios así como al reducido tamaño de los datos del conjunto de entrenamiento y de test disponibles. En futuros estudios sería recomendable disponer de señales de más usuarios y un conjunto de datos más amplio.

Como línea futura de investigación, se propone el estudio de métodos de extracción de características en el dominio de la frecuencia, tal y como se presenta en el trabajo de Krusienski y Jerry [8]. En este caso, en vez de emplear registros de electrocorticografía (ECoG), trabajaríamos con registros EEG.

## Agradecimientos

Este estudio ha sido financiado parcialmente por el Proyecto Cero 2011 en Envejecimiento de la Fundación General del CSIC, Obra Social La Caixa y CSIC, por el proyecto TEC2011-22987 financiado por el Ministerio de Economía y Competitividad y por el proyecto VA111A11-2 de la Consejería de Educación de la Junta de Castilla y León. R. Corralejo es beneficiaria de una ayuda PIRTU financiada por la Consejería de Educación de la Junta de Castilla y León y el Fondo Social Europeo.

## Referencias

- [1] Wolpaw JR, Birbaumer N, McFarland DJ, Pfurtscheller G, Vaughan TM. Brain-computer interfaces for communication and control. *Clin Neurophysiol*, vol 113, 2002, pp 767-791.
- [2] Farwell LA, Donchin E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography & Clinical Neurophysiology*, vol 70, 1988, pp 510-23.
- Blankertz B. Página web de las competiciones BCI. <a href="http://www.bbci.de/competition/">http://www.bbci.de/competition/</a> (Consultada: Junio 2012).
- [4] Rakotomamonjy A, Guigue V. BCI Competition III: Dataset II - Ensemble of SVM's for BCI P300 Speller. IEEE Transactions on biomedical Engineering, vol 55, sup 3, 2008.
- [5] Blankertz B. Página web de la competición III de BCI. http://www.bbci.de/competition/iii/ (Consultada: Junio 2012).
- [6] Klem GH, Lüders HO, Jasper HH, Elger C. The ten twenty electrode system of the international federation. *Electroencephalography and Clinical Neurophysiology*, vol 10, 1958, pp 214-15.
- [7] Haykin S. Neuronal networks. A comprehensive foundation. Prentice Hall International, 1999.
- [8] Krusienski DJ, Jerry J. Spectral components of the P300 speller response in electrocorticography. *Proceedings of the 5th International IEEE EMBS Conference on Neural Engineering*, 2011.