

Efecto de la cantidad y dimensión de los patrones en una interfaz cerebro computadora basada en discriminante lineal de Fisher

I. E. Gareis¹, R. C. Acevedo¹, Y. V. Atum¹, V. Medina Bañuelos², H. L. Rufiner^{3,4}, G. G. Gentiletti¹

¹ Facultad de Ingeniería, Universidad Nacional de Entre Ríos, LIRINS, Oro Verde, Argentina

² División Ciencias Básicas e Ingeniería, Universidad Autónoma Metropolitana (Iztapalapa), México

³ Centro de I+D en Señales, Sistemas e Inteligencia Computacional; FICH, Universidad Nacional de Litoral, Argentina

⁴ Laboratorio de Cibernética, Facultad de Ingeniería, Universidad Nacional de Entre Ríos, Argentina

Abstract— The brain-computer interfaces (BCI) translate brain activity into commands for a computer. To improve the performance of BCI, it is necessary to improve the feature extraction techniques that are used to decode the intentions of the users and get a clear understanding of the basic conditions for training the classifier. In this paper we study the behavior of a linear discriminant analysis by varying the number of patterns required for training, and the number of elements used to form patterns. From the results we can conclude that for this application BCI obtain optimal performance when used about eight training patterns for each feature used. In addition, a subsample of 8 Hz value of the temporal signals of the rows of EEG showed the best overall performance as a feature extraction technique.

Palabras claves— Interfaz cerebro-computadora, análisis discriminante lineal, potenciales evocados relacionados a eventos, extracción de características.

I. INTRODUCCIÓN

Las interfaces cerebro-computadora (ICC) son dispositivos que proporcionan un vínculo directo de comunicación entre el cerebro y una computadora [1]. Estas interfaces, pueden ser la única forma posible de comunicación para personas afectadas por alguna de las discapacidades motoras descriptas en [2].

El rendimiento de una ICC es altamente dependiente, de las técnicas de procesamiento utilizadas para extraer las características que codifican las intenciones del usuario, de las señales electroencefalográficas (EEG) generalmente empleadas [3]. Debido a esto, existe la necesidad de contar con métodos objetivos de comparación para analizar las diferentes técnicas de extracción de características [4]. Una alternativa natural consiste en alimentar un clasificador con las características que se desea comparar, y utilizar su desempeño como una medida del poder de discriminación de dichas características. En este caso, hay que ser muy cuidadoso para separar conceptualmente las variaciones en el desempeño del sistema (el bloque de extracción de características más el clasificador) debidas a modificaciones en el comportamiento del clasificador y las variaciones debidas a

las técnicas de extracción de características utilizadas. Para lograr esto, es importante estudiar el comportamiento del clasificador, particularmente bajo condiciones de trabajo similares a las que se presentan al utilizarlo como herramienta de comparación de técnicas de extracción de características.

Uno de los clasificadores más utilizados en aplicaciones en ICC es el análisis discriminante lineal de Fisher (ADL) [5, 6]. A pesar de que el ADL ha sido ampliamente estudiado [7-9], no se ha analizado el efecto de la variación en la cantidad de patrones de entrenamiento utilizando señales de EEG, y el número de patrones necesarios para llegar a una meseta de rendimiento, es decir, el punto en que no hay ganancia significativa del rendimiento al agregar una mayor cantidad de patrones de entrenamiento. Estos son los problemas abordados en este trabajo, en el caso específico de la utilización del ADL, para discriminar entre las señales de EEG que contienen potenciales evocados relacionados con eventos (PRE) y las señales de EEG sin la presencia de los PRE.

II. MATERIALES Y MÉTODOS

A. Deletreador de Donchin basado en P300

Cuando estímulos infrecuentes o particularmente significativos, ya sean auditivos, visuales o somatosensoriales, se mezclan con los estímulos frecuentes o de rutina, PRE son evocados en la corteza parietal de los sujetos que son solicitados atender a los primeros. Este fenómeno se puede utilizar para implementar ICCs, que comúnmente son llamadas basadas en el paradigma P300, debido a que se identifica a la respuesta P300 como el principal PRE presente en estas aplicaciones. Éstas permiten al usuario seleccionar íconos de una matriz en la pantalla de un ordenador [10].

En el paradigma P300 clásico, el usuario se enfrenta a una matriz de 6 x 6 que contiene letras y números. Durante el experimento, se intensifican al azar una sola fila o columna con una frecuencia predefinida, en un bloque completo de 12 intensificaciones, cada fila o columna parpadea

una vez. Para realizar una selección el usuario presta atención al caracter que desea elegir, y al intensificarse éste un PRE es evocado. Como resultado, al utilizar una matriz de estimulación de 6×6 , se obtendrán dos épocas conteniendo respuestas evocadas P300 (correspondientes a los estímulos infrecuentes u objetivos) y diez épocas sin respuestas (estímulos frecuentes o no objetivos) en cada bloque. Generalmente, el bloque de intensificaciones tiene que ser repetido para determinar efectivamente el caracter que el usuario intenta seleccionar.

Para determinar qué intensificación evoca PRE, el sistema debe ser capaz de resolver un problema de clasificación binaria (dos clases posibles: registros con el PRE y los registros sin PRE).

B. Base de datos

El Laboratorio de Investigación en Neuroimagenología (LINI) de la Universidad Autónoma Metropolitana (UAM) ha puesto a disposición una base de datos que contiene los registros de 30 sujetos sanos, utilizando el delectador de P300 provisto por el BCI2000 [11,12]. Los registros fueron muestreados a 256 Hz utilizando un número de canales (N_c) igual a diez. Los canales registrados fueron Fz, C3, Cz, C4, P3, Pz, P4, PO7, PO8, Oz referenciados al lóbulo de la oreja derecha y utilizando como tierra el mastoides derecho.

Cada sujeto participó en cuatro sesiones de quince repeticiones de los 12 estímulos por matriz, con esta configuración se delectaron palabras de largo variable. A partir de estas se obtiene para cada sujeto una base de datos etiquetada, que consta de $N_t = 630$ registros con P300 y $N_{nt} = 3150$ registros sin P300.

Una de las premisas de esta base de datos es preservar los registros tan realistas como sea posible, por tanto, muchos de ellos presentan un número significativo de artefactos. Una selección de diez sujetos se ha hecho entre los registros que presentan menor cantidad de artefactos, con el fin de evitar que estas variables influyan en los resultados y prescindir del uso de un bloque de rechazo de artefactos.

C. Preprocesamiento

En éste trabajo, se generaron tres nuevos conjuntos de datos a partir de los registros originales utilizando tres tasas de submuestreo temporal diferentes (decimación). Las frecuencias F_{si} a las que se decimó fueron 8; 16 y 32 Hz. Previo al submuestreo se filtraron los registros a 3,5; 7 y 14 Hz. respectivamente, con un filtro Chebyshev pasa bajos de octavo orden. Se filtró una vez hacia adelante y una hacia atrás para evitar el desfase. Posteriormente las señales se normalizaron en forma independiente para cada electrodo, para obtener media cero y desviación estándar unitaria.

Épocas individuales de un segundo de duración fueron extraídas de los registros. La primera muestra de éstas épocas corresponde al instante en que se realizó la intensificación de la fila o columna correspondiente (estímulo). Debido a la duración de las épocas y a los valores de F_{si} el número de muestras por época N_{ei} es igual a F_{si} .

Por último, los vectores de características (patrones) fueron construidos concatenando las épocas de los diez canales. Por lo tanto los patrones tienen $N_{ei} \times N_c$ características.

D. Clasificador

El objetivo del ADL es calcular un vector discriminante $w \in \mathfrak{R}^D$ (donde D es la cantidad de características), tal que, dado un conjunto de patrones de entrenamiento $x_j \in \mathfrak{R}^D$, con sus correspondientes etiquetas de clase $j \in \{1 \dots N\}$, separa las clases de la mejor manera posible de acuerdo a una función discriminante dada. Esto se logra, maximizando la función dada por:

$$J(w) = \frac{(\tilde{m}_1 - \tilde{m}_2)^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (1)$$

donde:

$$\tilde{m}_k(w) = \frac{1}{N_k} \sum_{i \in Y_k} w^T x_i, \quad \tilde{s}_k^2 = \sum_{i \in Y_k} (w^T x_i - \tilde{m}_k)^2, \quad (2)$$

Y_k representa el conjunto de índices i correspondientes a la clase k y N_k es el número de patrones de entrenamiento correspondientes a la clase k .

Se puede probar que el w que maximiza (1) puede calcularse de acuerdo a [13]:

$$w \propto S_w^{-1}(m_1 - m_2) \quad (3)$$

donde:

$$m_k = \frac{1}{N_k} \sum_{i \in Y_k} x_i, \quad (4)$$

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

En el ADL, la matriz de dispersión intra-clase S_w puede volverse singular, y por lo tanto no se puede calcular su inversa. Esto ocurre cuando la cantidad de características se hace mayor que el número de patrones de entrenamiento [14, 8]. Para estos casos se han propuesto diversas soluciones, una de ellas es la de realizar el cálculo de la inversa por medio de la pseudo-inversa de Moore-Penrose. Esta es la alternativa utilizada en este trabajo.

E. Evaluación del desempeño

La tasa de error (TE), es la métrica más utilizada como herramienta de evaluación del desempeño [15]. Sin embargo, al calcularse como la media de todas las observaciones que se clasifican, favorece a la clase mayoritaria del conjunto de evaluación, es decir, la clase con mayor cantidad de patrones de prueba.

Para la evaluación de clasificadores de dos clases con datos desbalanceados, es de uso general el área bajo la curva (AUC) ROC (del inglés: receiver operating characteristics) [16]. En las curvas ROC se representa la tasa de verdaderos positivos frente a la tasa de falsos positivos, y por lo tanto una mayor AUC generalmente indica un mejor desempeño del clasificador. A diferencia de la TE, el AUC es invariante al desbalance del conjunto de evaluación [16,17].

Teniendo en cuenta las diferentes características de la TE y el AUC, y el hecho de que los conjuntos de evaluación en este problema están desbalanceados se utilizó el AUC para estimar el desempeño de los clasificadores.

III. EXPERIMENTOS

Como se mencionó previamente, al aplicar tres tasas de submuestreo diferentes, se obtuvieron patrones con diferentes cantidades de características, resultando sus dimensiones en 80; 160 y 320 respectivamente. Por otro lado también se evaluó el efecto de la promediación coherente de entre una y cinco repeticiones. Esta técnica mejora la relación señal a ruido de los patrones, pero disminuye la tasa de transferencia de la interfaz, así como también la cantidad de patrones de entrenamiento disponibles.

En cada serie de experimentos los clasificadores se calcularon variando el número de patrones de entrenamiento de acuerdo a:

$$N_{ik} = \left[0,9^i \times 2 \frac{N_t}{k} \right], \quad (6)$$

donde i corresponde a los enteros de entre uno y veinte, k a los enteros entre uno y cinco y determina la cantidad de épocas promediadas y N_t es el número de patrones objetivo para cada sujeto en la base de datos. Si bien el problema es inherentemente desbalanceado (debido a la diferencia entre N_t y N_m), en este trabajo los patrones de entrenamiento fueron balanceados por defecto, utilizando selección aleatoria.

Todos los patrones que no fueron utilizados para entrenar los clasificadores, se utilizaron para generar los conjuntos de validación. Debido a esto los conjuntos de validación están desbalanceados.

El desempeño fue estimado utilizando validación cruzada [13]. Con cada configuración experimental, los clasificadores fueron entrenados y evaluados treinta veces con diferen-

tes grupos de entrenamiento seleccionados al azar y los resultados fueron promediados.

IV. RESULTADOS

La Figura 1 muestra los valores del AUC, contra N_{ik} obtenidos para los diversos experimentos. También es importante tener en cuenta, que aun cuando el número de patrones utilizados para el entrenamiento fue diferente al emplear distinta cantidad de promediaciones, se está utilizando la misma cantidad de épocas en puntos correspondientes, es decir, los puntos correspondientes a los mismos valores de i .

Los valores mínimos de AUC en las gráficas de la Figura 1, se deben a la transición entre el ADL y el ADL con la pseudo-inversa de la matriz de covarianza. Una explicación de este fenómeno se puede encontrar en [8].

V. DISCUSION

Del análisis de los resultados, puede observarse que al utilizar menor cantidad de características los clasificadores llegan antes a la meseta de rendimiento. Esta se alcanzó únicamente para los patrones con 80 características, alrededor de los 600 patrones de entrenamiento. Para los patrones con 160 características se puede ver la tendencia a la estabilización del AUC hacia los 1200 patrones de entrenamiento. En base a esto y suponiendo un comportamiento lineal podemos estimar que, para este problema con patrones en el dominio temporal, se necesitan del orden de ocho patrones de entrenamiento por cada característica nueva empleada. Es importante tener en cuenta estos factores al utilizar el ADL como herramienta de evaluación de la etapa de extracción de características, ya que estas estrategias suelen modificar la cantidad de características de los patrones, lo cual puede afectar el rendimiento del sistema sin que cambie la capacidad de discriminación intrínseca de dichas características.

En cuanto al uso de promediación coherente como técnica de preprocesamiento, se puede observar que si bien este método disminuye la complejidad del problema se debe tener mucho cuidado al aplicarlo. En estos casos, al disminuir la cantidad de patrones de entrenamiento, podemos obtener un menor desempeño en nuestro sistema, lo cual puede llevarnos a conclusiones erróneas.

A pesar de que no era el objetivo en este trabajo, se obtuvo un buen desempeño con el sistema utilizado, alcanzando valores de AUC superiores a 0,9 en la mayoría de las configuraciones.

VI. CONCLUSIONES

En este trabajo se ha estimado el número de patrones de entrenamiento necesario para llegar a una meseta de rendimiento utilizando ADL para clasificar épocas de EEG con y sin P300. Sin embargo, los resultados obtenidos deben ser analizados con cuidado y en el contexto del presente trabajo.

Las variaciones observadas en el comportamiento del ADL proveen información importante para su correcta utilización. En particular, cuando se utiliza el clasificador para

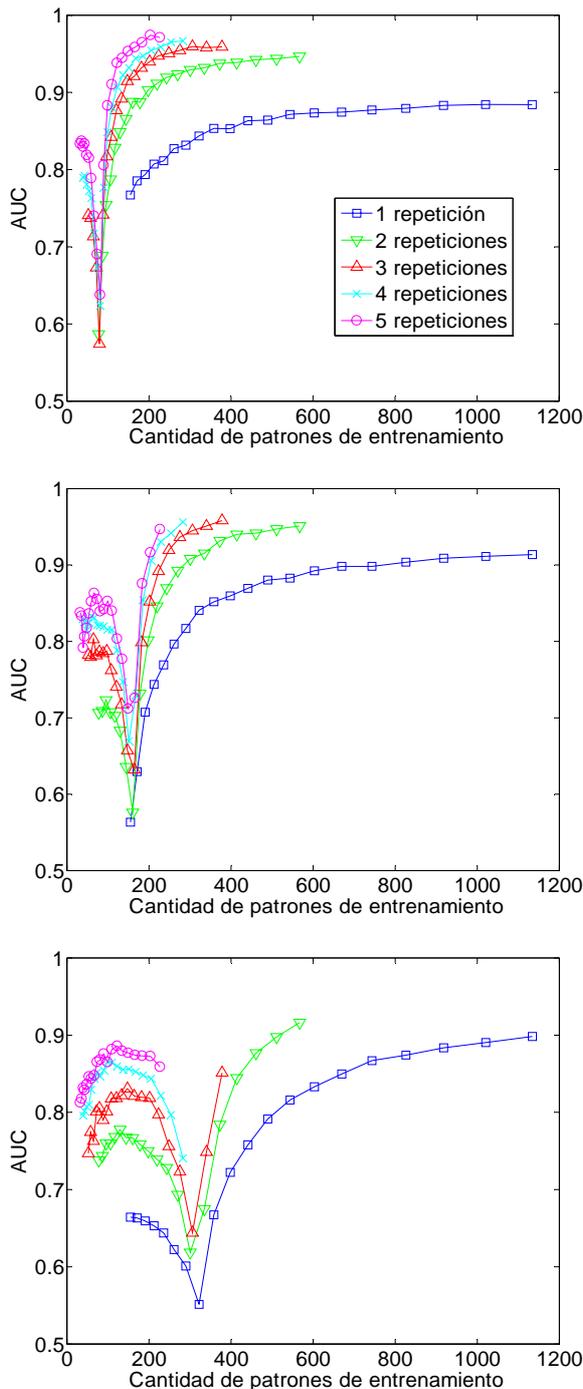


Fig. 1 AUC vs. cantidad de patrones de entrenamiento. De arriba a abajo utilizando 80, 160 y 320 características en los patrones respectivamente. Las curvas en cada gráfica representan patrones formados utilizando diferente cantidad de promediaciones (1 a 5).

evaluar técnicas de extracción de características. Además pueden resultar de utilidad en la mayoría de los casos en que se requiere analizar el rendimiento de un sistema integrado con un clasificador.

REFERENCIAS

1. J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, and T. M. Vaughan, (2002) "Brain Computer Interfaces for communication and control." *Clin. Neurophysiol.*, vol. 113, no. 6, pp. 767-791.
2. A. Kübler, B. Kotchoubey, J. Kaiser, J.R. Wolpaw and N. Birbaumer, (2001) "Brain-computer communication: unlocking the locked in." *Psychol. Bull.* 127 358-75.
3. A. Bashashati, M. Fatourehchi, R.K. Ward and G.E. Birch, (2007) "A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals." *Journal of Neural Eng.*, 4:32-57.
4. Atum, Y.; Gareis, I.; Gentiletti, G.; Acevedo, R.; Rufiner, L. (2010) "Genetic feature selection to optimally detect P300 in brain computer interfaces," *Engineering in Medicine and Biology Society (EMBC), Annual International Conference of the IEEE, Bs. As., Argentina, 2010.* Page(s): 3289 - 3292.
5. F. Lotte, M. Congedo, A. Lecuyer, F. Lamarche and B. Arnaldi, (2007) "A review of classification algorithms for EEG-based brain-computer interfaces," *Journal of Neural Engineering*, 4:R1-R13.
6. DJ Krusienski, EW Sellers, F Cabestaing, S Bayouh, DJ McFarland, TM Vaughan, JR Wolpaw, (2006) "A Comparison of Classification Techniques for the P300 Speller," *Journal of Neural Eng.*, 3:299-305.
7. Fisher R. A. (1936) "The use of multiple measurements in taxonomic problems," *Ann. Eugenics* 7 179-88.
8. S. Raudys, R. P. W. Duin, (1998) "Expected classification error of the Fisher linear classifier with pseudo-inverse covariance matrix," *Pattern Recognition Letters archive Volume 19 Issue 5-6.*
9. Geoffrey J. McLachlan, (1992) "Discriminant Analysis and Statistical Pattern Recognition," John Wiley & Sons, Inc.
10. L.A. Farwell, E. Donchin (1988) "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials." *Electroenceph. clin. Neurophysiol.* 70:510-523.
11. <http://www.bci2000.org/BCI2000/Home.html>.
12. Claudia Ledesma Ramírez, Erik Bojorges Valdez, Oscar Yañez Suárez, Carolina Saavedra, Laurent Bougrain, Gerardo Gentiletti (2010) "An open-access P300 speller database," *Fourth international BCI meeting, Paper L-12, Monterrey, California.*
13. Richard O. Duda and Peter E. Hart and David G. Stork (2000) "Pattern Classification (2nd Edition)," Wiley-Interscience.
14. K. Fukunaga, (1990) "Introduction to Statistical Pattern Recognition," Academic Press.
15. G.M. Weiss, (2004) "Mining with rarity: a unifying framework," *SIGKDD Explor.* 6 (1), 7-19.
16. MH Zweig, G Campbell, (1993) "Receiver-Operating Characteristic (ROC) Plots: A Fundamental Evaluation Tool in Clinical Medicine" *Clinical Chemistry.*
17. A.P. Bradley, (1997) "The use of the area under the ROC curve in the evaluation of machine learning algorithms," *Pattern Recognition* 30 (7) 1145-1159.

Autor: Iván E. Gareis
 Instituto: Facultad de Ingeniería, UNER, LIRIS
 Calle: Ruta Prov. 11 Km.10
 Ciudad: Oro Verde (Dpto. Paraná)
 País: Argentina
 E-mail: ivangareis@hotmail.com