

IMPLEMENTACIÓN ÓPTIMA DE UN FILTRO ESPACIAL PARA MEJORAR EL DESEMPEÑO DE CLASIFICADORES DE SEÑALES CEREBRALES EN INTERFACES CEREBRO-COMPUTADORA

Escalona Diana, Gutiérrez David.

Centro de Investigación y de Estudios Avanzados del IPN-Unidad Monterrey
Parque de Investigación e Innovación Tecnológica (PIIT)
Autopista al Aeropuerto Km. 9.5, Lote 1, Manzana 29 Apodaca, N.L. Tel.: 52-81-1156-1740,
E-mail: {diana, dgtz}@hecate.mty.cinvestav.mx

RESUMEN.

En este trabajo presentamos una técnica de preprocesamiento para mejorar la clasificación de señales de Electroencefalografía (EEG) para aplicaciones de Interface-Cerebro Computadora (ICC) tomando en cuenta condiciones de operación reales, tales como baja relación señal a ruido (SNR, Signal to Noise Ratio), un número reducido de sensores de medición y número reducido de datos de entrenamiento en la etapa de clasificación. El método propuesto está basado en el diseño de un filtro espacial lineal de mínimo error cuadrático medio (LMMSE) que mejora la SNR de las señales de EEG antes de ser clasificadas. Los parámetros de dicho filtro son obtenidos a través de la versión optimizada del discriminante lineal de Fisher (DLF) tal que el área bajo la curva ROC (Receiver Operating Characteristics) sea máxima. Para comprobar la eficiencia del método se realizaron una serie de experimentos con datos simulados de EEG y se comparó el desempeño del clasificador que utiliza el filtro espacial contra el desempeño del clasificador de Mahalanobis bajo las distintas condiciones de operación planteadas. Los resultados numéricos muestran que el clasificador que utiliza el filtro espacial aumenta su desempeño para condiciones de SNR baja y el menor número posible de sensores de medición, mientras que el clasificador de Mahalanobis bajo las mismas condiciones de operación disminuye su desempeño. El método propuesto tiene el potencial de mejorar la eficiencia de los sistemas de ICC en condiciones reales con un costo computacional relativamente bajo.

Palabras clave: Electroencefalografía, interface cerebro-computadora, filtrado espacial,

discriminante lineal de Fisher, curvas ROC, clasificación de señales.

I. INTRODUCCIÓN

Una interface cerebro-computadora (ICC) puede definirse como un dispositivo de comunicación directa entre el cerebro y una computadora. Dicho dispositivo permite al usuario interactuar a través de sus pensamientos con un ambiente computarizado [1]. Una ICC tiene el potencial de ayudar a personas que sufrieron lesiones cervicales altas, parálisis cerebral, esclerosis múltiple o distrofia musculares, realizar alguna tarea a través de la comunicación de su cerebro y un dispositivo externo, por ejemplo, una silla de ruedas, prótesis o mover un cursor en una pantalla de computadora, etcétera.

En general, una ICC funciona de la siguiente manera: (i) Mediante técnicas como la electroencefalografía (EEG) o magnetoencefalografía (MEG), se captan señales eléctricas o magnéticas, respectivamente, asociadas a la actividad neuronal en la corteza cerebral; (ii) tales señales son interpretadas por una computadora previamente "entrenada" para mandar una orden al dispositivo externo.

En la etapa de procesamiento de las señales se contemplan métodos de filtrado, amplificación y compresión, con el fin de acondicionar las señales adquiridas a los niveles de amplitud y/o frecuencia deseados. Después, se extraen características específicas de las señales para identificarlas y relacionarlas de manera única. Algunas de las características más usadas en aplicaciones de ICC son parámetros espectrales, coeficientes de

modelos paramétricos, eigenvalores y eigenvectores, parámetros estadísticos. Todas estas características se relacionan con eventos fisiológicos específicos, tales como actividad sensorial o motriz, potenciales corticales, respuesta a actividades mentales o actividad de neuronas específicas. Sin embargo, la manera en que la computadora relaciona cualquier característica de la señal con algún evento fisiológico es por medio de un algoritmo de clasificación.

En los últimos años se han propuesto diversos clasificadores para su aplicación en ICC, muchos de los cuales reportan excelente desempeño en la clasificación de diferentes eventos motrices y cognitivos [2]. En la gran mayoría de estos estudios, el desempeño de la ICC se evalúa en términos de la velocidad y/o precisión en la clasificación de las señales cerebrales. Sin embargo, dicha evaluación del desempeño usualmente se lleva a cabo bajo condiciones de operación óptima y lejana a la realidad. Por ello, la evaluación de la ICC debe incluir pruebas bajo condiciones reales, tales como cuando se opera con un número limitado de mediciones, cuando se utiliza una base de datos reducida para el entrenamiento del clasificador o cuando se trabaja en presencia de ruido e interferencias.

En la práctica la cantidad de datos de entrenamiento y el número de sensores para las mediciones pueden ser ajustados con relativa facilidad, no así el ruido e interferencias debidas a distracción y/o estrés del paciente durante la medición de datos. Por ello, que se propone como alternativa un filtro espacial que ayude a disminuir el ruido e interferencias y por consiguiente que el desempeño del clasificador mejore.

II. MÉTODO

Se considera el caso en el que se tienen mediciones de actividad neuronal relacionada con algún evento motriz o cognitivo, tales mediciones provienen de un arreglo de m transductores de EEG, MEG o ambos. También se considera el caso en que las fuentes de actividad neuronal cambian su magnitud en el tiempo, pero mantienen su misma posición durante el periodo de las

mediciones. Esta suposición es válida en la práctica para experimentos de potenciales evocados, en donde una cierta actividad neuronal es provocada por estímulos visuales, audibles o sensitivos [3]. La estimulación se repite K veces con el fin de obtener K mediciones independientes de la actividad neuronal deseada.

Entonces, los datos de EEG/MEG son organizados en una matriz de m renglones para las muestras en el tiempo $t=1,2,\dots,N$. Así pues, la matriz con información espacio-temporal es de tamaño $m \times N$. Cuando las mediciones se repiten K veces, cada una de las mediciones independientes están definidas por el siguiente modelo:

$$Y_k = X + E_k, \text{ para } k = 1, 2, \dots, K, \quad (1)$$

donde Y_k es la matriz de mediciones para el experimento k , X es la matriz que contiene la señal deseada (evento neuronal) y E_k es la matriz de ruido con distribución probabilística Gaussiana con media cero y varianza σ_E^2 , no correlacionada en el tiempo ni en el espacio entre muestras.

Si además se considera el caso en el que se estudia un número I de eventos neuronales distintos, entonces las mediciones pueden ser organizadas en clases, tal que $Y_{k,i}$ corresponda a las mediciones obtenidas en el experimento k para el evento neuronal i , donde $i=1,2,\dots,I$ clases.

II.B. Clasificación.

El problema de clasificar datos de EEG/MEG consiste en que dada una medición Y , se debe identificar el evento neuronal i al que corresponde. Un ejemplo de clasificador es el de Mahalanobis, el cual está definido en términos de la distancia de Mahalanobis (d_M) para un grupo de datos Y de K mediciones independientes como:

$$d_M = |(Y - \bar{Y})^T R_{YY}^{-1} (Y - \bar{Y})|_F, \quad (2)$$

donde $\|\cdot\|_F$ es la norma de Frobenius, \bar{Y} es la media de los datos dado por:

$$\bar{Y} = \frac{1}{K} \sum_{k=1}^K Y_k, \quad (3)$$

y R_{YY} es estimada como:

$$\hat{R}_{YY} = \left(\frac{1}{K} \sum_{k=1}^K Y_k Y_k^T \right) - \bar{Y} \bar{Y}^T. \quad (4)$$

La clasificación de la matriz Y usando el clasificador de Mahalanobis sigue este procedimiento:

1. Para cada una de las i clases, le corresponden matrices $\{\bar{Y}, R_{YY}\}_i$ calculadas a partir de datos de entrenamiento;
2. Se calcula d_M usando (2) para cada clase $\{\bar{Y}, R_{YY}\}_i$ de la matriz Y ;
3. Y es asignado a la clase i para la cual d_M es mínima.

El clasificador de Mahalanobis ha sido utilizado en aplicaciones de ICC con técnicas de medición de EEG para diferentes procesos neuronales cognitivos o motores con una exactitud aceptable aún reduciendo el número de canales utilizados [4]. Sin embargo, esto es sólo viable para valores suficientemente grandes de K (es decir, cuando se estima una matriz de covarianza consistente) y alto SNR. Otro tipo de clasificadores no sólo requieren un valor grande de K , sino también un número grande de sensores m , resultando una gran carga computacional y un proceso de clasificación impráctico. Es evidente que un clasificador con un desempeño teórico del 100% no necesariamente trabajará de manera óptima a menos que durante su entrenamiento se hayan considerado factores reales que afecten su funcionamiento, tales como número reducido de transductores (m) para las mediciones, número reducido de datos de entrenamiento (K) y

baja SNR. Sin embargo, las variables m y K pueden ser ajustadas con relativa facilidad en aplicaciones reales, no así el SNR. Por ello, se propone un método basado en filtrado espacial para mejorar la SNR de la señal y, por ende, mejorar el desempeño del clasificador.

II.C. Filtrado espacial.

La matriz de covarianza de mediciones de EEG/MEG usualmente exhibe una estructura espacial considerable. Es entonces que, intentos recientes para mejorar el SNR de este tipo de mediciones se ha centrado en técnicas de filtrado espacial [5]. Un filtro espacial es aquel que permite amplificar señales que vienen de una dirección deseada, mientras suprime señales de otras direcciones. Este tipo de filtros han sido utilizados en diversas aplicaciones de arreglos de sensores, tales como radar y sismología [6]. El diseño del filtro propuesto está inspirado en el DLF para el caso especial de $I=2$ clases [7]. Esto es, considerando el modelo de datos dado por (1) y definiendo el error cuadrático medio (MSE, *mean square error*) entre la señal X y el filtro espacial F aplicado a los datos Y como:

$$e^2(F) = \text{tr}\{(X - FY)(X - FY)^T\}, \quad (5)$$

donde $\text{tr}\{\cdot\}$ denota la traza. El filtro de mínimo error cuadrático medio (*Linear Minimum Mean Square Error*, LMMSE) es [8]:

$$F_{LMMSE} = R_{XX} R_{YY}^{-1}, \quad (6)$$

donde R_{XX} y R_{YY} son la matriz de covarianza de la señal deseada y de los datos medidos, respectivamente. En la práctica R_{XX} no está disponible, por lo que se estimada a partir de los datos como:

$$\hat{R}_{XX} = \bar{Y} \bar{Y}^T. \quad (7)$$

donde \bar{Y} es la media dada por (3) y la matriz R_{YY} se estimada con (4).

Una implementación óptima del filtro espacial dado por (6) es sólo posible si se conoce la procedencia de la señal *a priori*, lo cual no es factible pues el filtro se aplica a las señales antes de identificar de donde provienen. Entonces, la mejor manera de conocer la procedencia de la señal es basarnos en probabilidades, es decir, posicionar nuestro filtro espacial hacia la dirección más probable donde encontraremos la señal deseada. Esta información podemos obtenerla del Discriminante Lineal de Fisher (DLF) que se basa en el cálculo del hiperplano óptimo cuya condición de optimización esta dada por el análisis de curvas ROC (*Receiver Operating Characteristics*).

Las curvas ROC son elementos que permiten observar, organizar y seleccionar discriminantes basados en su desempeño. Estas curvas han sido utilizadas en teoría de detección de señales para representar la proporción entre los aciertos y falsas alarmas de clasificadores. Su uso se ha extendido a la observación, análisis de comportamiento de sistemas de diagnóstico o la evaluación y comparación de algoritmos en máquinas de aprendizaje [9]. En este trabajo se utilizan para el análisis de discriminantes. La información que podemos asociar con el desempeño de discriminantes y las curvas ROC es el área bajo la curva, donde un área igual a 1 describe un discriminante perfecto y un área menor o igual a 0.5 es un discriminante inservible [10].

El hiperplano del DLF se calcula usando el vector normal definido, para el caso especial de $I = 2$ clases como:

$$V = (\gamma\{\hat{R}_{YY}\}_1 + (1-\gamma)\{\hat{R}_{YY}\}_2)^{-1} \cdot (\{\bar{Y}\}_2 - \{\bar{Y}\}_1), \quad (8)$$

donde $\{\hat{R}_{YY}\}_i$ y $\{\bar{Y}\}_i$ son, respectivamente, la matriz de covarianza y la media de la clase $i=1,2$, mientras γ es la constante de ajuste en el intervalo de $0 > \gamma > 1$. Cuando $\gamma = 0.5$ tenemos el DLF clásico.

Por otro lado, si variamos el valor de γ en la ecuación (8) en el intervalo $0 < \gamma < 1$ obtenemos distintos hiperplano, para lo que es necesario recurrir a algún criterio que nos proporcione la dirección más adecuada del filtro espacial. Se sabe que la mejor curva puede ser generada variando γ para cuando el área bajo la curva ROC sea máxima, y por tanto, el hiperplano sea óptimo [11]. Así, cada punto de la curva ROC estará asociado al óptimo valor de γ y a la dirección más probable que se puede obtener.

Es entonces que se propone aplicar una metodología similar para el caso de datos de EEG/MEG correspondientes a actividad contralateral (i.e., señales que provienen del hemisferio derecho o izquierdo del cerebro). Los parámetros obtenidos de la versión optimizada del DLF para calcular el filtro espacial es de la siguiente manera:

$$\hat{F} = \hat{C}_{XX} \hat{C}_{YY}^{-1}, \quad (9)$$

donde:

$$\hat{C}_{YY} = \gamma_{opt}\{\hat{R}_{YY}\}_1 + (1-\gamma_{opt})\{\hat{R}_{YY}\}_2, \quad (10)$$

y

$$\hat{C}_{XX} = (\{\bar{Y}\}_2 - \{\bar{Y}\}_1)(\{\bar{Y}\}_2 - \{\bar{Y}\}_1)^T. \quad (11)$$

El hiperplano óptimo para el caso $I = 2$ clases esta dado por:

$$V_{opt} = (\gamma_{opt}\{\hat{R}_{YY}\}_1 + (1-\gamma_{opt})\{\hat{R}_{YY}\}_2)^{-1} \cdot (\{\bar{Y}\}_2 - \{\bar{Y}\}_1), \quad (12)$$

Entonces el proceso de optimización tendrá los siguientes pasos:

1. Realizar la vectorización del modelo de mediciones dado por (1) para obtener un arreglo de $m \times N \times K$, con columnas correspondientes a mediciones independientes de cada evento conteniendo la información espacio-temporal de la actividad neuronal.

2. Calcular la matriz de covarianza y la medias a partir de los datos de entrenamiento vectorizados para cada clase $\{\bar{Y}, \hat{R}_{YY}\}_i$ utilizando las ecuaciones (4) y (7).
3. Calcular los parámetros óptimos del filtro :
 - 3.1. Calcular el hiperplano V dado por (8) utilizando las matrices de covarianza $\{\bar{Y}, \hat{R}_{YY}\}_i$ tomando un valor de γ en el intervalo $0 < \gamma < 1$;
 - 3.2. Usando V y γ , calcular:

$$v_0 = -\frac{\gamma\sigma_1^2 V^T \{\bar{Y}\}_2 + (1-\gamma)\sigma_2^2 V^T \{\bar{Y}\}_1}{\gamma\sigma_1^2 + (1-\gamma)\sigma_2^2}, \quad (13)$$
 usando

$$\sigma_i^2 = V^T \{\hat{R}_{YY}\}_i V, \quad (14)$$
 - 3.3. Calcular la función discriminante utilizando datos de prueba Y como:

$$D(Y) = V^T Y + v_0, \quad (15)$$
 - 3.4. Calcular la regla de discriminación (RD) de la siguiente forma:

$$RD = \begin{cases} Y \in P & \text{si } D(Y) > 0; \\ Y \in N & \text{si } D(Y) \leq 0. \end{cases} \quad (16)$$
 - 3.5. Calcular la curva ROC utilizando (16) y (15) para obtener los verdaderos positivos $VP = P(Y|p)$, los falsos positivos $FP = P(Y|n)$ y el área bajo la curva.
 - 3.6. Cambiar γ en todo el intervalo $0 < \gamma < 1$ repitiendo los pasos 3.1 a 3.5 hasta obtener los valores de γ_{opt} tal que el área bajo la curva ROC sea máxima para cada dato de prueba;
 - 3.7. Utilizar γ_{opt} para calcular \hat{C}_{YY} y \hat{C}_{XX} usando (10) y (11) respectivamente y sustituir en (9) para calcular el filtro óptimo.
4. Aplicar el filtro \hat{F} al elemento a clasificar, es decir, $\hat{Y} = \hat{F}Y$;

5. Alimentar \hat{Y} al clasificador y evaluar su desempeño con las curvas ROC.

II.D. Ejemplos Numéricos.

Para generar mediciones simuladas de EEG se utiliza el método de solución directa de un modelo esférico de cuatro capas descrito en [12] donde la actividad cortical es modelada como un dipolo de corriente con una magnitud que cambia en el tiempo, aproximándose a una típica señal de respuesta evocada. Este modelo es similar al usado previamente en [13]. La posición del dipolo se asume fijo sobre el área de la corteza motora en el hemisferio derecho o izquierdo del cerebro durante las mediciones. Entonces, las matrices de mediciones de EEG se realizan para $m=6$ y $m=16$ sensores distribuidos sobre el área de activación para una esfera de radio 10.5 cm como se muestra en la Figura 1. A los datos generados se les añade ruido aleatorio con distribución $N(0, \sigma^2)$ no correlacionado en tiempo y espacio, con diferentes valores de σ hasta obtener valores de SNR de -3, -6,-8 dB (i.e., condiciones de ruido bajo, medio y alto). Algunos ejemplos de la distribución del evento de la señal cerebral se muestran en la Figura 2.




Figura 1: Distribución de sensores de medición.

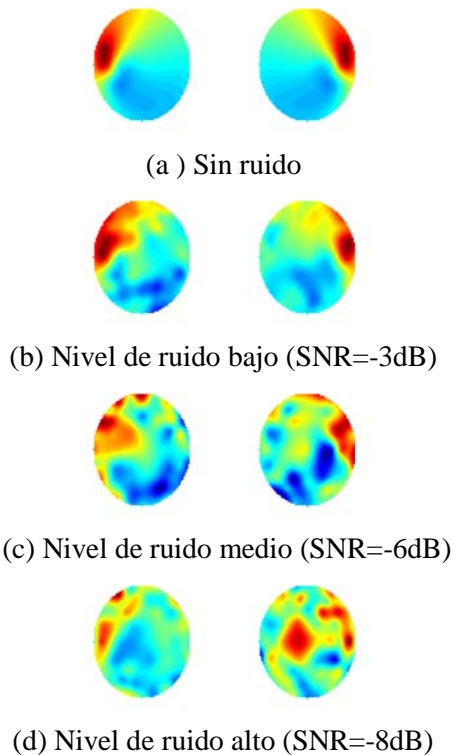


Figura 2: Datos simulados de EEG de actividad contra-lateral con diferentes niveles de ruido.

Los datos de EEG fueron alimentados al filtro espacial donde \tilde{Y} corresponde a la redistribución espacial de los datos originales medidos Y . Sin embargo, ésta redistribución espacial no resulta un efecto indeseado, sino resulta ventajosa cuando se tiene niveles de ruido alto y en consecuencia la discriminación de \tilde{Y} pueda ser fácilmente realizada. Un ejemplo de la redistribución de los datos se observa en la Figura 3, donde un sólo dato de prueba es aplicado al filtro espacial.

Así mismo se realizaron pruebas para evaluar el desempeño del clasificador alimentado por el filtro espacial, en comparación con el desempeño del clasificador de Mahalanobis para diferentes valores de m , K y SNR. De las 1300 mediciones simuladas de EEG se utilizaron 100 eventos destinados para la etapa de clasificación (datos de prueba) y K eventos usados como datos de entrenamiento, con $K = 15-600$.

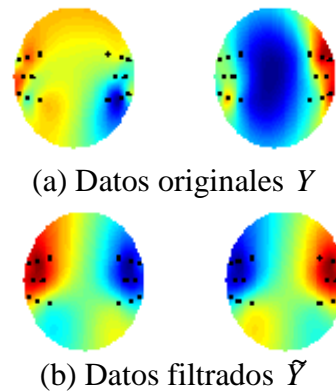


Figura 3: Redistribución espacial para datos simulados de EEG.

Los datos crudos fueron alimentados al clasificador de Mahalanobis y se calcularon las curvas ROC para evaluar su desempeño. Los datos filtrados fueron alimentados a un clasificador basado en la detección del pico positivo sobre la superficie de redistribución del potencial e igualmente se calcularon las curvas ROC para evaluar el desempeño y compararlo con el clasificador de Mahalanobis. Los datos de prueba, en ambos casos, fueron aleatoriamente ordenados. Así, todas las posibles combinaciones de m , K , SNR, previamente definidas, fueron analizadas con el clasificador de Mahalanobis y el clasificador alimentado con el filtro espacial. En la Figura 4 se muestran las curvas ROC para el caso especial donde $m = 16$, $K = 250$ y tres diferentes valores de SNR. Tales valores de m y K son un ejemplo correspondiente a valores típicos observados en condiciones de operación reales y nos ayuda a observar en el procedimiento de clasificación el efecto producido por los niveles de ruido. Claramente, la clasificación tras utilizar el filtro espacial aumenta el desempeño en comparación con el clasificador de Mahalanobis. En efecto, el clasificador de Mahalanobis tiene un desempeño bajo para el número de datos de entrenamiento usados en este ejemplo. Es bien sabido que el clasificador de Mahalanobis funciona de manera óptima cuando K es lo suficientemente grande. Sin embargo, esto no es factible en condiciones de operación real, ya que se requiere que el paciente esté sujeto a sesiones largas de adquisición de los

datos lo cual tiende a aumentar los niveles de ruido durante las mediciones debidas a estrés o distracción.

Por otro lado, el proceso de clasificación es un proceso aleatorio con una distribución de probabilidad de valor extremo [14] que puede ser caracterizada a partir de su media y desviación estándar, para lo cual es necesario repetir el experimento múltiples veces. Así, se calcularon las áreas bajo la curva ROC para 100 veces el proceso de clasificación cambiando aleatoriamente los datos, para valores de m , K y SNR definidos previamente. Los valores de media y desviación estándar son mostrados en las Figuras 5, 6 y 7 (las barras de error muestran la desviación estándar a partir de la media), donde para un nivel de ruido bajo (Figura 5) el clasificador basado en filtrado espacial está por arriba de la media del desempeño del clasificador de Mahalanobis, el cual para el valor de $K = 250$ funciona en un 100% al igual que el clasificador basado en filtrado espacial, con la diferencia de que este último tiene un desempeño entre el 70% (Figura 5b) y 80% (Figura 5a) para $K = 150$. Si aumentamos el ruido a un nivel medio (Figura 6), se observa que el desempeño del clasificador utilizando el filtro está de nuevo por arriba de la media del clasificador de Mahalanobis el cual para $K = 200$ baja su desempeño no así el clasificador basado en filtrado espacial que tiene un desempeño del 80% (Figura 6a) para $K = 150$. Si aumentamos aún más el nivel de ruido observamos la misma tendencia (Figura 7), el clasificador de Mahalanobis tiene un desempeño bajo y el clasificador basado en filtrado por arriba del 80% (Figura 7a) para $K = 200$. Sin embargo, es posible observar que el clasificador basado en filtro espacial también decae su desempeño para ciertos valores de K (Figuras 5b, 6b, 7b), esto es debido a que la matriz \hat{Y} tiene más variables y menos información de la etapa de entrenamiento y es de esperarse que el desempeño del clasificador decaiga cuando tenemos valores de $m = 16$, aún así bajo estas mismas condiciones observamos que el clasificador de Mahalanobis está por debajo de la media del clasificador basado en el filtro espacial.




Figura 4: Curvas ROC para evaluar el desempeño del clasificador basado en filtro espacial en comparación con el de Mahalanobis.

Entonces, nuestros resultados muestran que para el caso de los datos filtrados, el desempeño de la media del clasificador está arriba del 80% de correctas clasificaciones cuando se acerca a $K = 250$ sólo usando 6 sensores durante la medición y con un nivel de ruido alto. Por otro lado, la variabilidad del proceso de clasificación es baja. Bajo estas mismas condiciones el clasificador de Mahalanobis tiene resultados desfavorables.

Los experimentos muestran un buen desempeño en el proceso de clasificación usando el menor número posible de sensores y datos de entrenamiento tras utilizar el filtro espacial. Esto comprueba la aplicabilidad de dicho método bajo condiciones de operación real. Por otro lado, con anterioridad se ha demostrado que métodos neuronales no han mostrado grandes ventajas en comparación a métodos lineales y cuadráticos, alcanzando sólo mejoras de alrededor del 6% en el número de clasificaciones correctas, pero incrementando considerablemente la complejidad computacional de la implementación [15], por lo que el método aquí propuesto promete poca complejidad computacional y un buen desempeño del clasificador bajo condiciones de operación real que podría llevar a la práctica a los sistemas ICC.




Figura 5: Análisis de medias y desviación estándar del clasificador basado en filtrado espacial y de Mahalanobis para ruido bajo.

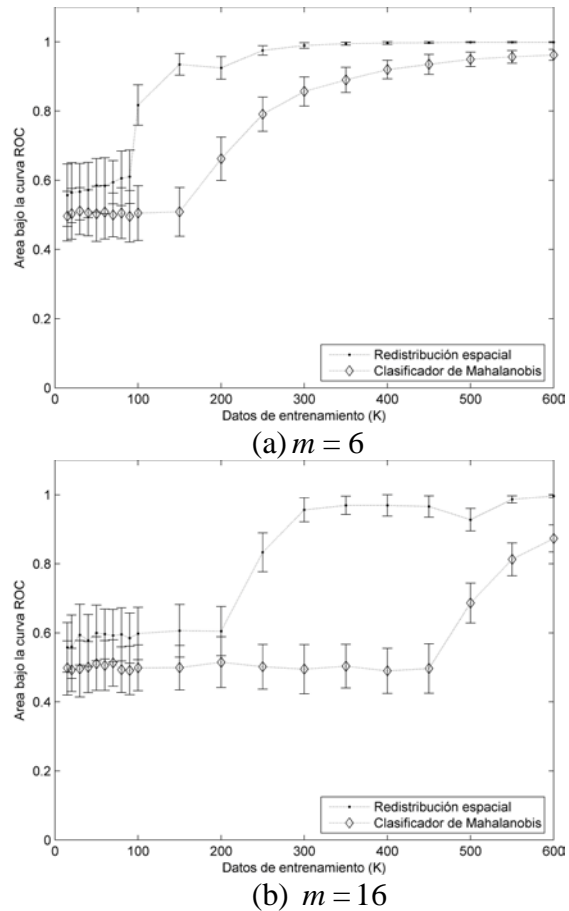


Figura 6: Análisis de medias y desviación estándar del clasificador basado en filtrado espacial y de Mahalanobis para nivel de ruido medio.

III. CONCLUSIONES

El método propuesto basado en filtrado espacial para datos de EEG de actividad contralateral con parámetros obtenidos por la optimización del DLF por análisis de curvas ROC incrementa la SNR. El filtro espacial aplicado a datos simulados de EEG favorece la etapa de clasificación. Por otro lado, el método propuesto tiene una potencial aplicación para mejorar el desempeño de clasificadores en condiciones de operación real de los sistemas ICC, es decir, consideraciones como bajo SNR, número reducido de datos de entrenamiento y el menor número posible de sensores de medición. Los trabajos a futuro estarán encaminados en términos de la implementación computacional para seleccionar el óptimo valor de γ y en generalizar el método para la clasificación de eventos multiclase o señales

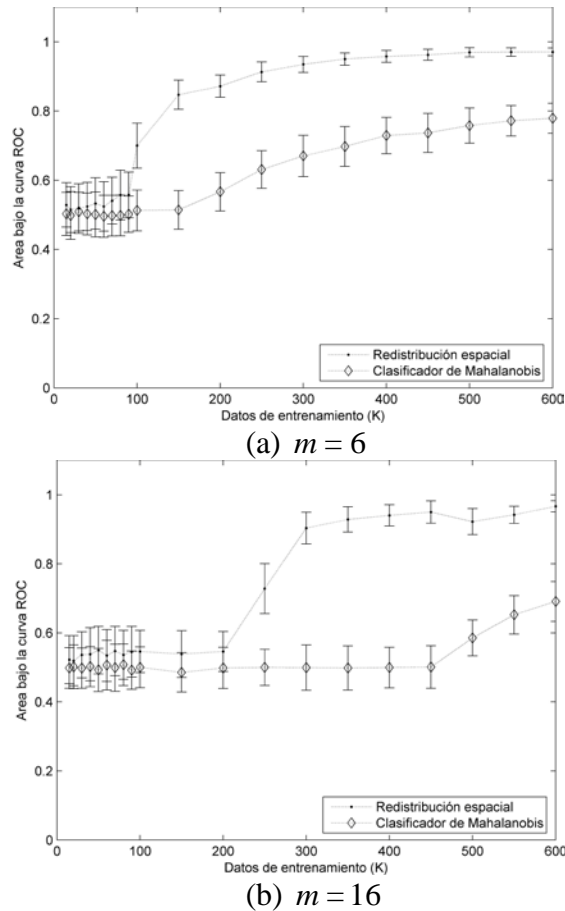


Figura 7: Análisis de medias y desviación estándar del clasificador basado en filtrado espacial y de Mahalanobis para nivel de ruido alto .

más complejas, así como aplicar el mismo método utilizando datos de magnetoencefalografía (MEG) para extraer mejores características de la señal y utilizarlas en la etapa de entrenamiento de los sistemas ICC.

IV. REFERENCIAS

[1] J.R Wolpaw, N. Birbaumer, D, J. Mcfarland, G. Pfurtscheller y T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767-791, 2002.

[2] A. Bashashati, M. Fatourehchi, R. K. Ward y G.E. Birch, "A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals," *Journal of*

Neural Engineering, vol.4, pp.R32-R57, 2007.

[3] J. W Rohrbaugh, R. Parasuraman y R Johnson, *Event-related brain potentials: basic issues and applications*, Oxford University Press, Nueva York, 1990.

[4] F. Babiloni, L. Bianchi, F. Semeraro, J. R. Millán, J. Mouriño, A. Cattini, S. Salinari, M. G. Marciani y F. Cincotti, "Mahalanobis distance-based classifiers are able to recognize EEG patterns by using few EEG electrodes," en *Proceedings of the 23th Annual Conference of the IEEE Engineering in Medicine and Biology Society*, Estambul, Turquía, 2001, pp.651-654.

[5] K. B. Yu y C.D. Mc Gillem, "Optimum filters for estimating evoked potential waveforms," *IEEE Transactions on Biomedical Engineering*, vol. 30, No. 11, pp.730-737, 1983.

[6] B. D van Veen y K. M. Buckley, "Beamforming: A versatile approach to spatial filtering," *IEEE Signal Processing Magazine*, vol.5, pp. 4-24, 1988.

[7] R. A. Fisher, "The use of multiple measurements in taxonomic problems," *Annals of Eugenics*, vol.7, Parte II, pp. 179-188, 1936.

[8] S. J. Orfanidis, *Optimum signal processing*, an introduction. New York: MacMillan Publishers, 1985.

[9] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters Elsevier*, vol. 27, pp. 861-874, 2006.

[10] A. P. Bradley, "The use of the area under the ROC curve in the evaluation of machine learning algorithms," *Pattern Recognition Society*, vol.30, No. 7, pp. 1145-1159, 1997.

[11] T. Cooke y M. Peake, "The optimal classification using a linear discriminant for two point classes having known mean and covariance," *Journal of Multivariate Analysis*, vol. 82, pp. 379-394, 2002.

[12] J. C. Mosher, R. Leahy, y P. S. Lewis, "EEG and MEG: forward solutions for inverse methods," *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 3, pp. 245-259, 1999.

- [13] D. Gutiérrez, A. Nehorai, y C. Muravchik, "Estimating brain conductivities and dipoles source signals with EEG arrays," *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 12, pp. 2113-2122, 2004.
- [14] D. Gutiérrez, "Designing a spatial filter to improve SNR in two-class discrimination problems for BCI applications," en *Proceedings of the 42nd Asilomar Conference on Signals, Systems and Computers*, Pacific Grove, CA, USA, 2008, pp. 372-377.
- [15] D. Garrett, D. A. Peterson, C. W. Anderson y M. H. Thaut, "Comparison of linear, nonlinear, and feature selection methods for EEG signal classification," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 141-144, Junio 2003.

becario del Programa Fulbright-García Robles durante sus estudios en UIC y desde 2005 es miembro del Sistema Nacional de Investigadores de CONACYT.

V. AUTORES

Diana Irazú Escalona Vargas obtuvo los títulos de Ingeniero en Biónica por la Unidad Profesional Interdisciplinaria en Ingeniería y Tecnologías Avanzadas (UPIITA) del Instituto Politécnico Nacional y de Maestría en Ingeniería y Física Biomédicas por el Centro de Investigaciones y Estudios Avanzados del IPN (Cinvestav) Unidad Monterrey en 2006 y 2009, respectivamente. Sus intereses están encamidos en el procesamiento de señales biomédicas en el área de las neurociencias y en el procesamiento digital de imágenes.

David Gutiérrez recibió el título en Ingeniería Mecánica Eléctrica (con mención honorífica) por la Universidad Nacional Autónoma de México (UNAM) en 1997, y los títulos de Maestría en Ingeniería Electrónica y Ciencias de la Computación y de Doctorado en Bioingeniería en 2000 y 2005, respectivamente, ambos por la Universidad de Illinois en Chicago (UIC). Entre 2005 y 2006 realizó una estancia posdoctoral en el Instituto de Investigaciones en Matemáticas Aplicadas y en Sistemas (IIMAS), UNAM. Desde Junio de 2006 es Investigador Adjunto en el Centro de Investigación y de Estudios Avanzados (Cinvestav), Unidad Monterrey. Sus líneas de investigación son en el área de procesamiento estadístico de señales médicas. También está interesado en imagenología médica, neurociencias y algoritmos de procesamiento en tiempo real. El Dr. Gutiérrez fue