

# Detección de P300 en Interfaz Cerebro Computadora mediante Algoritmos Genéticos y Máquinas de Soporte Vectorial

Yanina Atum<sup>#</sup>, Gerardo G. Gentiletti<sup>#</sup>, Rubén Acevedo<sup>\*\*</sup>, Leonardo Rufiner<sup>\*\*</sup>

<sup>#</sup>LIRINS, Facultad de Ingeniería, UNER, <sup>\*</sup>SINC, Facultad de Ingeniería y Ciencias Hídricas, UNL  
atumyanina@gmail.com

**Resumen**—Una interfaz cerebro computadora es un sistema que genera una forma de comunicación artificial entre el cerebro de una persona y el mundo exterior. En este trabajo se hace uso del paradigma basado en potenciales evocados relacionados a eventos. Como objetivo se planteó resolver en forma eficiente el problema de clasificación que tiene dos clases posibles: registros con respuesta y registros sin respuesta. Registros reales y simulados fueron presentados a máquinas de soporte vectorial lineales. Se utilizó un esquema de extracción de características basado en algoritmos genéticos en combinación con máquinas de soporte vectorial (en configuración envolvente o *wrapper*). Para evaluar el desempeño de las diferentes configuraciones se calcularon el porcentaje de aciertos, la sensibilidad y especificidad, para las distintas cantidades de épocas utilizadas. La configuración envolvente mostró un significativo aumento en estos índices, aún cuando utiliza menos de un 50 % de las características del patrón temporal real y aproximadamente un 20% de las características de los patrones simulados.

**Palabras clave**—P300, Interfaz cerebro computadora, Potenciales evocados relacionados con eventos, Métodos envolventes.

## I. INTRODUCCIÓN

UNA interfaz cerebro computadora (ICC) provee una nueva forma de comunicación directa entre el cerebro de una persona y el mundo exterior, ya sea para incrementar la integración en la sociedad o para proveer de un medio de control sin asistencia permanente en el entorno en el que se desenvuelven personas con discapacidades severas [1].

Los sistemas de comunicación basados en señales de *electroencefalograma* (EEG) representan un grupo de paradigmas de ICC, dentro del cual se encuentra el basado en potenciales evocados relacionados a eventos (ERP, *event related potentials*). Los ERP son potenciales evocados de latencias mayores a 100 ms cuya manifestación depende de procesos psicológicos y conductuales, de los cuales el más estudiado es el P300. Cuando estímulos visuales, auditivos o somatosensoriales infrecuentes (o particularmente significativos) son mezclados con estímulos frecuentes (o de rutina), los primeros evocan un potencial en el EEG sobre la corteza parietal con un pico positivo cercano a los 300 ms. Para estimar y/o detectar la señal de ERP usualmente se mejora la *relación señal a ruido* (RSR) inicial, ya que junto con esta se registra EEG y electromiograma entre otras señales que conforman el ruido

contaminante, que se atenúa utilizando la promediación coherente [2].

En el año 1988, Donchin *et al* diseñaron un deletreador basado en el componente P300 de los ERP, que consistió en una matriz de 6 x 6 caracteres [3]. La ventaja más sobresaliente de esta técnica, es que no requiere de ningún entrenamiento para el usuario.

En una ICC basada en ERP se pueden distinguir claramente los siguientes bloques:

- Instrumentación electrónica (electrodos, amplificación y acondicionamiento de la señal).
- Extracción de características.
- Clasificador.

El objetivo de este trabajo es resolver en forma eficiente el problema de clasificación que tiene dos clases posibles: registros con respuesta (ERP) y registros sin respuesta. Para esto se propone un esquema de extracción de características basado en *algoritmos genéticos* (AGs) en combinación con *máquinas de soporte vectorial* (MSV) en configuración envolvente.

## II. MATERIALES

En el presente trabajo se utilizaron registros de EEG reales y simulados.

### A. Registros Reales

Se utilizaron amplificadores Grass® modelo 8-18-36, los parámetros de adquisición se indican en la Tabla I. Se utilizó el software BCI2000 V2.0 con autorización del Wadsworth Center [4].

TABLA I  
PARÁMETROS DE ADQUISICIÓN.

Parámetro	Descripción
Canales	(Fz, Cz, Pz, Oz, C3 y C4), M1 (referencia) y M2 (tierra)
Bandas de Paso	0,1 – 15 Hz
Frecuencia de Muestreo	1024 mps

Para la estimulación se utilizó el esquema del deletreador de Donchin, pero basados en trabajos previos, se reemplazaron los caracteres del abecedario por íconos que controlan el movimiento de una silla de ruedas [5].

Se adquirieron seis canales de EEG para poder determinar en un próximo trabajo la variación del desempeño del esquema propuesto en función de la posición de los electrodos.

## B. Registros Simulados

Se generaron utilizando una plantilla a la que se le sumó ruido blanco manteniendo la relación señal a ruido de los registros reales [6].

## III. MÉTODOS

### A. Máquinas de Soporte Vectorial

Las MSV son un clasificador derivado de la teoría del aprendizaje estadístico. Estas separan las clases mediante una superficie de decisión que maximiza la distancia entre ambas. Esta superficie conforma el hiperplano óptimo, y los vectores más cercanos a dicho hiperplano se denominan vectores de soporte [7]. Son clasificadores binarios, pero se pueden combinar para generar clasificadores multiclases. Las MSV lineales tienen un parámetro de costo  $C$  que permite un cierto grado de libertad en la clasificación, el cual es particularmente importante para conjuntos de entrenamiento no separables. Este parámetro crea un margen suave que permite cierto error en la clasificación. Si se quiere que el error de clasificación sea el menor se debe aumentar el valor de  $C$ , pero se debe tener presente que ante valores muy elevados de  $C$  el sistema puede no generalizar [7].

### B. Algoritmos Genéticos

Los AGs manipulan una población de posibles soluciones de un problema codificadas en cadenas binarias.

Este conjunto de cadenas representan el material genético de una población de individuos [8]. Operadores artificiales de selección, cruce y mutación son aplicados para buscar los mejores individuos — mejores soluciones — a través de la simulación del proceso evolutivo natural. Cada solución potencial se asocia con un valor de *fitness* (o aptitud), que mide que tan buena es comparada con otras soluciones de la población. De esta forma el *fitness* simula el papel que juega el ambiente en la evolución natural darwiniana. El paradigma de los algoritmos genéticos puede esquematizarse como se muestra en la figura 1.

1. Inicialización de población
  2. Evaluación de población
  3. Mientras Mejor Fitness < Fitness Requerido do
    - Selección de progenitores
    - Cruzas y mutaciones
    - Evaluación de población
- Fin mientras

Fig. 1: Estructura de un AG simple

### C. Selección de características

La selección de características consiste en elegir un subconjunto de características relevantes, ignorando las restantes que conforman el patrón a clasificar. Esta selección no solo mejora la performance de entrenamiento, sino que ayuda al entendimiento e interpretación de los datos [9].

Existen dos esquemas básicos para realizar la selección de características, estos son los *algoritmos de filtrado* y los

algoritmos *envolventes* o *wrappers* [10]. En los primeros el método de selección es independiente del clasificador, por ende, no optimiza en forma directa la performance del mismo. En cambio los algoritmos envolventes utilizan métodos de selección que permiten la optimización de la performance del clasificador en forma directa aunque generalmente con un costo computacional alto [11]. La configuración envolvente utilizada en este trabajo se muestra en la figura 2, la cual se conforma por un AGs como método de selección de características y una MSV como clasificador.




Fig. 2: Configuración envolvente conformada por AG y MSV.

## IV. RESULTADOS

Para este trabajo se emplearon registros temporales reales y simulados correspondientes al canal Fz, a los cuales se les realizó un remuestreo a 256 Hz. En la figura 3 se muestran los promedios de 300 épocas obtenidos en registros simultáneos en las posiciones Fz, Cz, Pz, Oz, C3 y C4. Los trazos en rojo corresponden a registros que contienen respuesta (ERP) y en azul corresponden a registros donde no hay respuesta.




Fig.3 - Morfología de los ERP.

Posteriormente se formaron distintos conjuntos de 800 patrones, la mitad de cada clase, que difieren en la cantidad de épocas promediadas. Se emplearon para la clasificación dos esquemas, MSV y AGs más MSV en configuración envolvente.

### A. Clasificación con MSV solamente

Se utilizaron MSV lineales a las cuales se les presentaron un 80% de patrones temporales de 256 características (todas las muestras correspondientes a 1 segundo). Este proceso de entrenamiento se repitió para los distintos conjuntos de patrones con diferentes cantidades de épocas promediadas, recorriendo el rango que va desde una única época, a promedios de 20 épocas. Para el entrenamiento se utilizó validación cruzada. El parámetro de costo final se estableció en 100. Posteriormente con el 20% restante se testeó el sistema y se calculó el porcentaje de aciertos, la sensibilidad y especificidad. Los resultados obtenidos con los registros reales y simulados se muestran en la Tabla II y Tabla III respectivamente.

### B. Clasificación con AGs y MSV

La población inicial estaba formada por 100 individuos de un cromosoma de 256 bits, cada bit activo indica la presencia de la característica en el patrón (muestra temporal). Estos individuos iniciales poseen distintos porcentajes de elementos activos y la ubicación de los mismos dentro del cromosoma se estableció en forma aleatoria. La función de *fitness* empleada no solo se basa en el porcentaje de clasificación de la MSV, sino que además tiene en cuenta la cantidad de características del individuo, para que el AG devuelva el individuo que posea la mejor performance de clasificación con la menor cantidad de características [7]. La función de *fitness* se expresa mediante la ec. (1):

$$fitness = w_a * \%aciertos + w_c / \sum_{i=1}^{256} c_i \quad (1)$$

donde  $w_a$  es el peso que se le asignó al porcentaje de aciertos y  $w_c$  es el peso que se le asignó a la inversa de la sumatoria de las características  $c_i$  activas. Los valores de  $w_a$  y  $w_c$  fueron de 0.8 y 0.2 respectivamente. Se emplearon selección por competencias, cruza y mutaciones simples, para la obtención de una nueva población. Los parámetros de la MSV se mantuvieron iguales que en el caso anterior.

Para el entrenamiento de este sistema se utilizaron un 80% de los patrones temporales, y el resto para testeo. El AG genera la población de individuos y se entrenan las MSV con estos patrones temporales con las características dadas por las distintas configuraciones de cada individuo. Calculando el *fitness* de la población se obtiene el mejor individuo, que contiene las características más relevantes de la señal. Esto se lleva a cabo en un ciclo que encuentra su fin por el número de iteraciones o porque alcanza el umbral de *fitness* deseado.

TABLA II  
RESULTADOS OBTENIDOS EN REGISTROS REALES.

épocas	MSV solamente			AG + MSV		
	% aciertos	Sens	esp	% aciertos	sens	esp
20	87.5	0.80	0.95	92.0	0.92	0.92
15	86.5	0.85	0.88	88.4	0.88	0.88
10	87.5	0.82	0.92	89.0	0.82	0.96
9	86.3	0.81	0.91	87.5	0.86	0.88
8	88.0	0.80	0.96	89.0	0.82	0.96
7	85.1	0.82	0.87	86.8	0.84	0.89
6	85.6	0.81	0.89	88.0	0.82	0.94
5	85.0	0.83	0.86	89.0	0.92	0.86
4	87.5	0.84	0.91	88.1	0.82	0.94
3	83.0	0.79	0.86	89.1	0.94	0.84
2	83.2	0.83	0.83	88.1	0.86	0.90
1	78.2	0.76	0.80	87.0	0.82	0.92

TABLA III  
RESULTADOS OBTENIDOS CON REGISTROS SIMULADOS.

épocas	MSV solamente			AG + MSV		
	% aciertos	sens	esp	% aciertos	sens	esp
20	100.0	1.00	1.00	100.0	1.00	1.00
15	100.0	1.00	1.00	100.0	1.00	1.00
10	100.0	1.00	1.00	100.0	1.00	1.00
9	100.0	1.00	1.00	100.0	1.00	1.00
8	100.0	1.00	1.00	100.0	1.00	1.00
7	100.0	1.00	1.00	100.0	1.00	1.00
6	100.0	1.00	1.00	100.0	1.00	1.00
5	100.0	1.00	1.00	100.0	1.00	1.00
4	100.0	1.00	1.00	100.0	1.00	1.00
3	99.7	1.00	0.99	100.0	1.00	1.00
2	98.6	0.99	0.98	100.0	1.00	1.00
1	94.2	0.94	0.94	98.0	0.96	1.00

Con los patrones de testeo también generados con las características determinadas por el mejor individuo que se obtuvo durante el entrenamiento, se calcularon el porcentaje de aciertos, sensibilidad y especificidad. Los registros reales se muestran en la Tabla II y los registros simulados en la Tabla III. Este procedimiento se llevó a cabo para los 12 conjuntos, definidos por las diferentes cantidades de épocas promediadas.




Fig. 4: Representación de los mejores individuos de cada conjunto de patrones (muestras seleccionadas) según las épocas promediadas (en blanco están las presentes y en negro las ausentes).

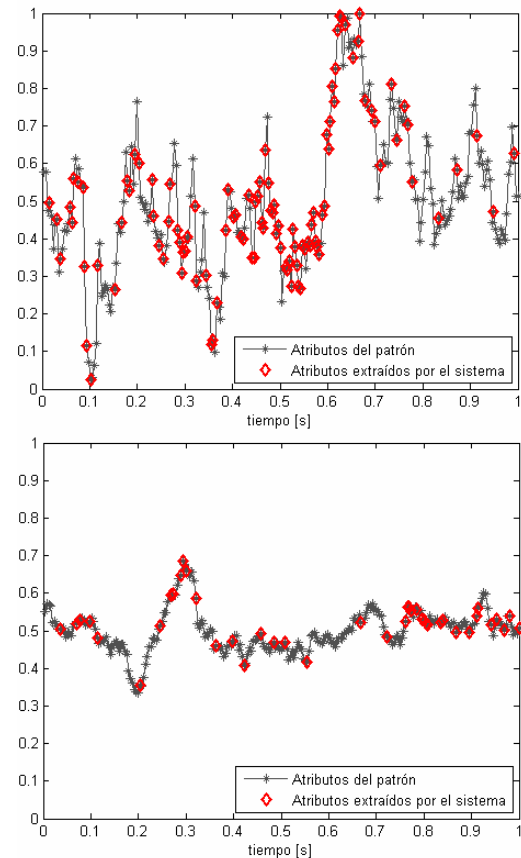


Fig. 5: Características seleccionadas para un patrón de 1 época (gráfica superior) y para uno de 20 promediaciones (gráfica inferior).

En la figura 4 se muestra la distribución de características extraídas en el esquema envolvente para patrones generados por promedios de 1 a 20 épocas. A manera de ejemplo en la figura 5 se muestran los casos extremos de 1 y 20 épocas.

Se puede apreciar como el ruido presente en la gráfica superior, que corresponde a un patrón sin promediar, es reducido en la gráfica inferior a través de las 20 promediaciones que se realizaron. También se puede ver la reducción en la cantidad de características de la gráfica superior con respecto a la inferior. Otro aspecto a destacar es la distribución de las características a lo largo del patrón, que en ambos casos no se concentran en una región temporal específica, denotando que para el sistema existe información relevante a lo largo de todo el patrón.

Si se realiza una comparación entre las dos configuraciones propuestas a partir de los porcentajes de aciertos, la sensibilidad y especificidad, se pueden destacar algunas mejoras obtenidas por la configuración envolvente a pesar de que la misma emplea un menor número de características. Entre ellas se pueden mencionar el aumento de estos tres parámetros para los patrones simulados de 1, 2 y 3 épocas. Además para los registros reales, se obtuvo un aumento en el porcentaje de aciertos para todas las promediaciones estudiadas, alcanzando un 3.2% promedio, destacándose los patrones de "época única" donde la diferencia fue de un 8.8%.

Otro análisis que se abordó, fue la variación de la cantidad de características con respecto a las épocas empleadas, para los registros reales y simulados.

En la figura 6 se muestra la cantidad de características utilizadas, y con las cuales se obtuvo el mayor porcentaje de aciertos, para los distintos conjuntos de patrones según el número de épocas promediadas. Se puede apreciar también que en los patrones simulados, se utilizan aproximadamente un 50% menos de características que en los reales y que los rangos de variación son de 24 y 51 características respectivamente.

También se puede observar que para los dos tipos de registros, la cantidad de características necesarias para alcanzar el máximo porcentaje de aciertos disminuye a medida que aumenta el número de épocas.

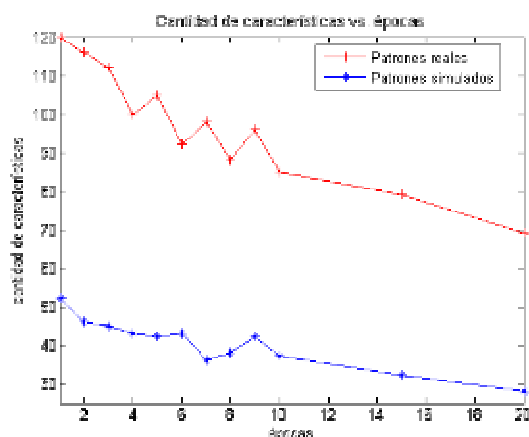


Fig. 6: Cantidad de características finales para patrones reales y simulados para distintas épocas.

## V. CONCLUSIONES

Como se puede observar en la figura 5, los ERP son señales que se encuentran realmente inmersas en ruido. La promediación coherente ayuda a disminuir este ruido, pero se incrementa el tiempo de registro, ya que se necesitan tantas detectar el pico P300 tantas veces como la cantidad de épocas necesarias para formar el patrón, esto no es grave para un estudio estático, pero juega un papel fundamental a

la hora de la implementación de una ICC on-line. Ambas configuraciones mostraron un desempeño aceptable al generar porcentajes de aciertos mayores a 85 % para la mayoría de los casos contemplados, con la utilización de un solo canal de registro. Sin embargo la configuración envolvente utiliza una cantidad menor de características, que es de 120 y 52 para el caso de registros reales y simulados respectivamente en contrapartida a las 256 de los registros originales. Estos valores corresponden a los patrones formados por épocas únicas (sin promediar), ya que como se puede observar en la figura 4, a medida que aumentan las épocas promediadas, disminuyen aún más. Otra conclusión interesante a partir de la distribución de las características seleccionadas por el sistema, es que la información relevante se encuentra a lo largo de todo el patrón. Finalmente, la configuración envolvente demostró ser apropiada para la clasificación de este tipo de señales, aunque restan realizarse estudios con mayor número de sujetos, para probar lo general o no de estos resultados preliminares.

## REFERENCIAS

- [1] R. Fazel-Rezai, J. Peters. "P300 wave feature extraction: preliminary results", en *CCECE/ CCGEI, IEEE*, pp. 390-393, 2005.
- [2] G. Gentiletti, C. Tabernig, R. Acevedo. "Interfaces Cerebro Computadora: Definición, Tipos y Estado Actual", en *CLAIB 2007, IFMBE Proc.*, vol. 18, pp. 1117-1121, 2007.
- [3] L.A. Farwell, and E. Donchin. "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials", *Electroencephalography and Clinical Neurophysiology*, 70(6), pp. 510-523, 1988.
- [4] <http://www.bci2000.org/BCI2000/Home.html>.
- [5] J. del R. Millán, P. W. Ferrez, F. Galán, E. Lew, "Non-invasive brain-machine interaction", *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 20, pp. 1-13, 2007.
- [6] R. Acevedo, G. Gentiletti, V. Medina Bañuelos, L. Rufiner. "Extracción de características en ICC mediante métodos basados en diccionarios óptimos: Resultados preliminares", en *II Jornadas Argentinas sobre Interfaces Cerebro Computadora*, pp. 49-52, 2009.
- [7] L. Zhuo, J. Zheng, F. Wang, X. Li, B. Ai, J. Qian. "A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector machine", en *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XXXVII, part B7, pp. 397-402, 2008.
- [8] Milone D., Rufiner H., Acevedo R., Di Persia L., Torres H., *Introducción a las Señales y a los Sistemas Discretos*. EDUNER. 2006.
- [9] M. Shröder, M. Bogdan, W. Rosenstiel, T. Hinterberger y N. Birbaumer, "Automated EEG Feature Selection for Brain Computer Interfaces", en *Proc. Of the 1st Conference on Neural Engineering*, pp. 626-629, 2003.
- [10] R. Kohavi and G. H. John, "Wrappers for feature subset selection", en *Artif. Intell.*, 97, pp. 273-324, 1997.
- [11] N. Sánchez-Maróño, A. Alonso-Betanzos y E. Castillo. "A New Wrapper Method for Feature Subset Selection", en *Proc. of the European Symposium on Artificial Neural Networks*, pp. 515-520, 2005.