



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

PROCESAMIENTO ESTADÍSTICO APLICADO AL DESARROLLO DE INTERFACES CEREBRO-COMPUTADORA

Dania Gutiérrez Ruiz

Centro de Investigación y Estudios Avanzados del IPN
Unidad Monterrey, Apodaca, N.L.,
dgtz@ieee.org

RESUMEN:

Las interfaces cerebro-computadora (ICC) son sistemas que, en teoría, permitirán la comunicación directa entre los pensamientos de un usuario y una computadora. Sin embargo, las aplicaciones prácticas de los sistemas ICC a la fecha son limitadas. La gran mayoría de los sistemas ICC actuales requieren de condiciones de operación *ad-hoc* que poco se asemejan a la realidad. Además, los usuarios que alcanzan el nivel de control deseado en un sistema ICC sólo lo logran después de muchas sesiones de entrenamiento que, usualmente, llegan a tomar meses. Todo esto mantiene a los sistemas ICC aún en la categoría de ciencia ficción. Es por ello que, desde hace ya casi 10 años, el grupo de procesamiento de señales médicas del Cinvestav Monterrey hemos estado trabajando en desarrollar métodos basados en el procesamiento estadístico con el fin de proporcionar el nivel de robustez y facilidad de operación que lleven a los sistemas ICC a operar en escenarios realistas. Desde nuestra perspectiva, son tres los elementos fundamentales que requieren atención para lograr dicho objetivo: (i) operación en condiciones de alto ruido e interferencias, (ii) operación con un número limitado de sensores sin afectar el desempeño, y (iii) proporcionar retroalimentación a los usuarios en distintos niveles sensoriales para facilitar la operación del sistema. Así pues, en este artículo se presenta un resumen de los trabajos que hemos venido realizando en estas tres áreas.

1. INTRODUCCIÓN

Una interfaz 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]. En general, una ICC funciona de la siguiente manera: (i) mediante electroencefalografía (EEG) o magnetoencefalografía (MEG) se obtienen señales que reflejan la actividad neuronal en la corteza cerebral, (ii) las señales son interpretadas por una computadora que previamente fue “entrenada” y ésta realiza la función que le fue asignada. 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. Seguido a esto, se extraen características específicas de las señales que permiten identificarlas y relacionarlas de manera única. En los últimos años se han propuesto diversos clasificadores para aplicaciones de ICC en la literatura, muchos de los cuales reportan un excelente desempeño en la clasificación de diferentes eventos motrices y cognitivos



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

[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 *ad-hoc* lejanas a la realidad. Por ello, la evaluación de la ICC debe incluir pruebas bajo circunstancias 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.

3. MEJORANDO LA RELACIÓN SEÑAL A RUIDO

En la práctica, la cantidad de datos de entrenamiento y el número de sensores pueden ser manejados con relativa facilidad, no así el ruido producido por “interferencias” o señales no relacionadas con la actividad de interés, tales como las debidas a distracción y/o estrés del paciente durante la medición de datos. Dichas condiciones impactan en la relación señal a ruido (*Signal-to-Noise Ratio* o SNR), la cual usualmente es baja en sistemas reales de ICC. Es por ello que en [3] nos enfocamos en proponer una solución basada en una etapa de preprocesamiento por medio de un filtro que cambia la distribución espacial de los datos, lo que permitió aumentar el SNR de las señales antes de ser clasificadas y así mejorar el desempeño global del sistema ICC. Al mismo tiempo, el método propuesto proporcionó una mayor robustez al sistema manteniendo un desempeño óptimo aún en condiciones de operación reales, tales como cuando se cuenta con unos cuantos canales de medición y/o pocas mediciones de experimentos independientes para entrenar el algoritmo de clasificación.

Para comprobar la eficiencia del método propuesto en [3], se realizaron una serie de experimentos con datos realistas de EEG con los que se comparó el desempeño del clasificador que utiliza el filtro espacial contra el clasificador de Mahalanobis en distintas condiciones de operación. Los resultados numéricos mostraron que el clasificador basado en el filtro espacial tiene un mejor desempeño para un SNR bajo y un menor número de canales de medición, mientras que el clasificador de Mahalanobis bajo las mismas condiciones tiene una operación subóptima. El método propuesto tiene el potencial de mejorar la eficiencia de los sistemas de ICC en condiciones reales con un costo computacional relativamente bajo. Los resultados se ejemplifican en la Figura 1, donde se comparan sistemas ICC en condiciones de alto ruido (SNR = -8dB), y para distintos números de datos utilizados para entrenar a los sistemas, así como dos distintos números de sensores utilizados para medir la actividad cerebral. Los resultados muestran como la estrategia basada en la redistribución espacial de los datos permite alcanzar eficiencias por arriba del 80% (área bajo la curva ROC de 0.8) aún cuando se utilicen pocos sensores y se entrene poco al sistema ICC.

Otro método basado en filtrado espacial es el de patrones espaciales comunes (*Common Spatial Patterns* o CSP), el cual es ampliamente utilizado en aplicaciones de ICC para discriminar entre diferentes tareas de imaginación de actividad motora [4], pero su desempeño depende del conocimiento de las frecuencias de operación de los eventos a discriminar. En [5] propusimos un método basado en la eigendescomposición de las señales a partir de su modelo autorregresivo



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

variante en el tiempo (*time-varying autoregressive* o TVAR) a fin de estimar la frecuencia específica para cada individuo, de modo que los CSP fueron calculados de las principales eigencomponentes.

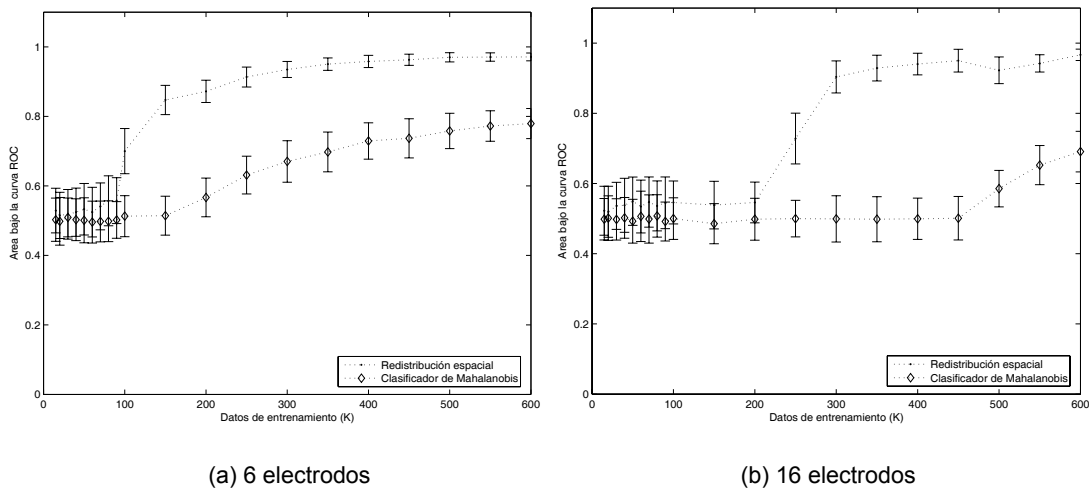


Figura 1: Desempeño, medido por la media y desviación estándar del área bajo la curva ROC, para el clasificador con redistribución espacial y el de Mahalanobis cuando SNR = -8 dB. Tomado de [3].

A pesar de que el método propuesto reportó alta efectividad en la clasificación de datos de EEG, la selección sistemática de los sensores continúa como una pregunta abierta.

3. REDUCIENDO EL NÚMERO DE ELECTRODOS UTILIZADOS

Utilizar un gran número de electrodos puede mejorar el proceso de clasificación de las señales, sin embargo colocar muchos electrodos en la cabeza del usuario puede ser incómodo además de que se invierte mucho tiempo, lo que hace que el proceso de adquisición sea poco práctico para aplicaciones reales de ICC. Por otro lado, manejar información adquirida a través de un denso arreglo de electrodos es muy costoso en términos computacionales, lo que dificulta el procesamiento en tiempo real.

Así pues, nosotros aquí proponemos una técnica basada en el hecho de que diferentes regiones cerebrales son simultáneamente activadas y se comunican entre sí cuando se realizan diversas tareas [6]. Entonces, un arreglo óptimo de sensores puede ser determinado con base en la información de dicha conectividad. Una medida que provee información acerca de la conectividad es la coherencia. En [7] se estudian los patrones de coherencia producidos al realizar tareas de manera simultánea y sucesiva. Por otro lado, en [8] se hace uso de la coherencia para clasificar señales de EEG correspondientes al estado de reposo, imaginando un movimiento y ejecutando un movimiento. Sin embargo la coherencia no ha sido utilizada para estudiar la conectividad entre diferentes regiones cerebrales y cómo emplear esta información para la selección de sensores. Así



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

pues, la búsqueda de sensores basada en la coherencia puede realizarse calculando la coherencia entre todas las posibles combinaciones de sensores y elegir la que tenga una coherencia significativa para una clase y no para la otra.

Así pues, si suponemos el caso de un arreglo de EEG con nueve sensores, nuestra propuesta consiste en evaluar la coherencia entre pares de sensores para el caso de sólo tres sensores. Entonces, en la Tabla 1 se muestran las 84 posibles combinaciones de sensores, para cada una de las cuales se evalúa la coherencia entre pares de sensores y para todas las clases a discriminar (en nuestro caso dos).

F3 Fz F4	F3 Fz C3	F3 Fz Cz	F3 Fz C4	F3 Fz P3	F3 Fz Oz	F3 Fz P4
F3 F4 C3	F3 F4 Cz	F3 F4 C4	F3 F4 P3	F3 F4 Oz	F3 F4 P4	F3 C3 Cz
F3 C3 C4	F3 C3 P3	F3 C3 Oz	F3 C3 P4	F3 Cz C4	F3 Cz P3	F3 Cz Oz
F3 Cz P4	F3 C4 P3	F3 C4 Oz	F3 C4 P4	F3 P3 Oz	F3 P3 P4	F3 Oz P4
Fz F4 C3	Fz F4 Cz	Fz F4 C4	Fz F4 P3	Fz F4 Oz	Fz F4 P4	Fz C3 Cz
Fz C3 C4	Fz C3 P3	Fz C3 Oz	Fz C3 P4	Fz Cz C4	Fz Cz P3	Fz Cz Oz
Fz Cz P4	Fz C4 P3	Fz C4 Oz	Fz C4 P4	Fz P3 Oz	Fz P3 P4	Fz Oz P4
F4 C3 Cz	F4 C3 C4	F4 C3 P3	F4 C3 Oz	F4 C3 P4	F4 Cz C4	F4 Cz P3
F4 Cz Oz	F4 Cz P4	F4 C4 P3	F4 C4 Oz	F4 C4 P4	F4 P3 Oz	F4 P3 P4
F4 Oz P4	C3 Cz C4	C3 Cz P3	C3 Cz Oz	C3 Cz P4	C3 C4 P3	C3 C4 Oz
C3 C4 P4	C3 P3 Oz	C3 P3 P4	C3 Oz P4	Cz C4 P3	Cz C4 Oz	Cz C4 P4
Cz P3 Oz	Cz P3 P4	Cz Oz P4	C4 P3 Oz	C4 P3 P4	C4 Oz P4	P3 Oz P4

Tabla 1: Posibles combinaciones de sensores de EEG (denotados de acuerdo a la norma internacional 10-20) para el caso de un sistema de nueve sensores.

Para cada caso es necesario identificar no sólo si los tres pares de sensores tienen señales coherentes, sino también que lo sean en mayor medida para una clase y no para la otra. Esto se logra mediante pruebas de hipótesis, en donde:

H_0 : Las coherencias de la clase 1 y la clase 2 son iguales;

H_a : Las coherencias de la clase 1 y la clase 2 son distintas.

Para ello se realizaron pruebas estadísticas t del estudiante a un nivel de significancia $\alpha=0.01$, cuyos resultados se muestran en la Figura 2 para el caso de un sujeto al que se le solicitó imaginarse el movimiento de la mano derecha (clase 1) o el movimiento de los pies (clase 2). En



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

este caso, la mejor combinación de electrodos resultó la F3-C3-P3 debido a que el valor p obtenido en la prueba estadística es el más pequeño con el que se rechaza H_0 para los tres sensores.




Figura 2: Valores p de la prueba t del estudiante en función de la frecuencia correspondientes a la evaluación de la prueba de hipótesis comparando las coherencias entre la clase 1 y clase 2. Los sensores evaluados tienen el mismo orden que en la Tabla 1. Los símbolos usados sirven para diferenciar a los tres pares de coherencias en cada uno de los casos.

De esta manera, habiendo seleccionado la mejor combinación de electrodos para un sujeto, la clasificación de sus señales se realiza de manera óptima, tal y como lo muestra la Figura 3.

4. NUEVAS ESTRATEGIAS DE ENTRENAMIENTO

Habiendo propuesto métodos para el funcionamiento óptimo de los sistemas ICC aún bajo condiciones de ruido y utilizando un número reducido de electrodos, aún queda por desarrollar



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO




Figura 3: Coherencias de 100 eventos independientes para la mejor combinación de sensores.

estrategias que permitan reducir el tiempo que requiere a los voluntarios entrenarse en el uso de la ICC.

La mayor problemática reside en la ambigüedad existente en la instrucción proporcionada al sujeto, que en nuestro caso corresponde a la imaginación de movimientos. Hemos encontrado que los sujetos muchas veces realizan esa tarea de diversas maneras: creando una imagen mental de él/ella o alguien más realizando el movimiento, asociando el movimiento a sensaciones muy personales, etcétera. Cada una de estas maneras genera patrones cerebrales muy diversos que difícilmente pueden ser replicados entre usuarios, lo que nos deja con un entrenamiento personalizado.

En un esfuerzo por coadyuvar a homogeneizar el proceso de entrenamiento, hemos estado experimentando con la presentación de estímulos eléctricos superficiales al tendón de la mano derecha, de manera que el sujeto asocie una sensación específica con el movimiento de la mano. Esta estimulación se incluye en un esquema tradicional de entrenamiento de la ICC, e igualmente se evalúa en términos de la eficiencia desarrollada en la operación de una ICC (para más detalles del experimento, ver [9]). Resultados preliminares de este esquema muestran que los voluntarios asimilan de mejor manera el entrenamiento cuando éste incluye la estimulación eléctrica que cuando no se proporciona. Esto se puede evidenciar en la Figura 4 para el caso de dos voluntarios. Sin embargo, mayor experimentación es aún necesaria para logra estandarizar este procedimiento en el entrenamiento de sistemas ICC.



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

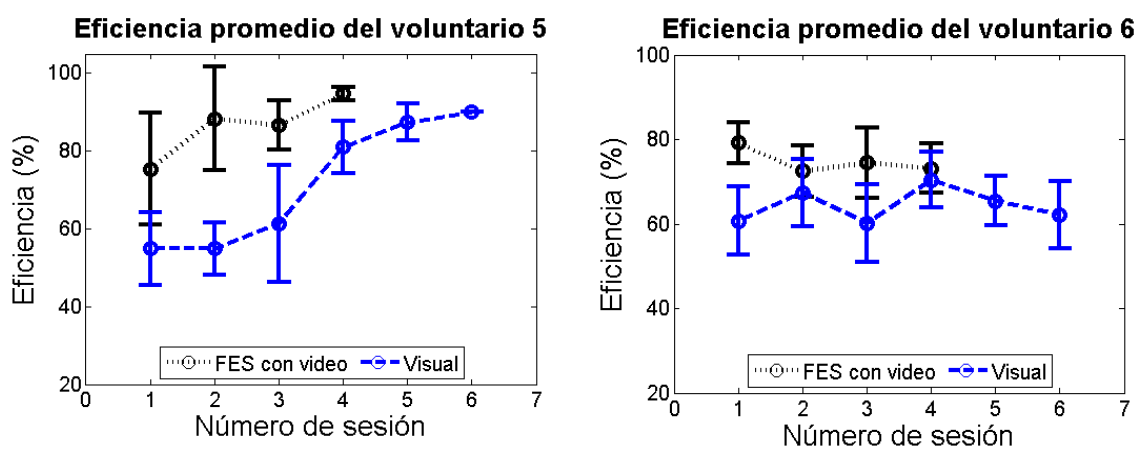


Figura 4: Eficiencia en la operación de una ICC tras diversas sesiones de entrenamiento cuando se proporciona estimulación eléctrica funcional (FES) comparado con el caso de entrenamiento pasivo tradicional basado exclusivamente en la retroalimentación visual. En ambos casos los sujetos mejoran significativamente su desempeño cuando se proporciona FES.

4. CONCLUSIONES

En este artículo se han resumido algunos de los resultados obtenidos en el Laboratorio de Procesamiento de Señales Médicas del Cinvestav Monterrey, en lo que respecta a métodos orientados a desarrollar sistemas ICC que operen en condiciones realistas.

BIBLIOGRAFÍA

- [1] D. J. McFarland G. Pfurtscheller J. R. Wolpaw, N. Birbaumer, T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, pp. 767–791, Marzo 2002.
- [2] M. Fatourehchi A. Bashashati, R. K. Ward, "A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals," *Journal of Neural Engineering*, vol. 4, pp. R32–R57, Marzo 2007.
- [3] D. Gutiérrez, D. I. Escalona-Vargas, "EEG Data Classification through Signal Spatial Redistribution and Optimized Linear Discriminants," *Computer Methods and Programs in Biomedicine*, vol. 97, no. 1, pp. 39–47, 2010.
- [4] J. Miller-Gerking H. Ramoser, G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *IEEE Transactions on Biomedical Engineering*, vol. 8, pp. 441–446, Diciembre 2000.



V CONGRESO NACIONAL DE TECNOLOGÍA APLICADA A CIENCIAS DE LA SALUD

5, 6 y 7 de junio de 2014
TONANTZINTLA, PUEBLA, MÉXICO

- [5] D. Gutiérrez, R. Salazar-Varas, "Using eigenstructure decompositions of time-varying autoregressions in common spatial patterns-based EEG signal classification," *Biomedical signal processing and control*, vol. 7, pp. 622–631, Abril 2012.
- [6] Ch. Neuper G. Pfurtscheller, A. Stancák Jr., "Event-related synchronization (ERS) in the alpha band an electrophysiological correlate of cortical idling: A review," *International journal of psychophysiology*, vol. 24, pp. 39–46, Noviembre 1996.
- [7] S. Okazaki S.T. Okuhata, H. Maekawa, "EEG coherence pattern during simultaneous and successive processing tasks," *International Journal of Psychophysiology*, vol. 72, pp. 89–96, 2009.
- [8] L. B. Felix C. A. Maia A. P. Souza, S. A. S. Filho, C. J. Tierra-Criollo, "Classification of imaginary movements using the magnitude-squared coherence feature extractor," in *Biosignals and biorobotics conference. IEEE*, 2012, vol. III, pp. 1–6.
- [9] I. N. Angulo-Sherman, D. Gutiérrez, "Effect of different feedback modalities in the performance of brain-computer interfaces," en *Proceedings of the 24th International Conference on Electronics, Communications, and Computers*, Cholula, Puebla, México, Feb. 2014, pp. 14-21.