

# Evaluación de Métodos de Clasificación para el Reconocimiento de Imaginación de Movimiento en un Paciente con Enfermedad Vasculare Cerebral

R.I. Carino-Escobar<sup>1</sup>, J. Cantillo-Negrete<sup>1</sup>, J. Gutiérrez-Martínez<sup>1</sup>

<sup>1</sup>Subdirección de Investigación Tecnológica. Instituto Nacional de Rehabilitación.

**Resumen**—Una interfaz cerebro-computadora que transforma las intenciones de movimiento de un usuario, codificadas en la señal de electroencefalografía, a señales de control para un dispositivo externo, puede beneficiar a pacientes paralizados debido a una enfermedad vascular cerebral. Para que esto sea posible se debe de identificar cual es el mejor método de clasificación para las intenciones de movimiento generadas por el paciente. En este trabajo se plantea un análisis del desempeño y costo computacional de 8 clasificadores diferentes para reconocer la imaginación de movimiento de las manos en un paciente con enfermedad vascular cerebral. Para diseñar y evaluar los clasificadores, se calcularon características de potencia espectral de la señal de electroencefalografía. Se encontró que no existe una diferencia significativa entre los mejores clasificadores lineales y los no lineales. El análisis de discriminante lineal de Fisher, y la red neuronal artificial multicapa obtuvieron el mejor desempeño, tanto en la tasa de clasificación correcta, como en el costo computacional. Es necesario realizar este análisis para encontrar el clasificador con mejor desempeño para diferentes pacientes, y con ello mejorar el desempeño de un BCI, lo cual sería un paso más para llevar esta tecnología a la práctica clínica.

**Palabras clave**— BCI, potencia espectral, EEG, entrenamiento supervisado, neurorehabilitación

## I. INTRODUCCIÓN

Una interfaz cerebro-computadora (BCI) transforma las intenciones de movimiento de un usuario, codificadas en señales cerebrales, a comandos de control para un dispositivo externo como una silla de ruedas, o una prótesis robótica. Uno de los paradigmas usados para codificar intenciones de un usuario en señales eléctricas medibles por medio de electroencefalografía (EEG), es la imaginación de movimiento (IM). La IM consiste en realizar los mismos procesos cognitivos de planeación de un movimiento pero sin ejecutarlos, lo cual, se ha comprobado que produce activaciones corticales similares a las producidas cuando se realiza un movimiento real [1] [2] [3]. Estos sistemas han sido poco probados para la neurorehabilitación de enfermedades que provocan parálisis parcial o completa del miembro inferior y superior, como es el caso de la enfermedad vascular cerebral (EVC). Se estima que cerca del 30% de los potenciales usuarios de un BCI, basado en IM, no podrán controlar este tipo de sistemas con las metodologías de adquisición, extracción de características y clasificación actuales [4]. Una de las etapas más importantes de un BCI, es la de clasificación, por lo que si se mejora su desempeño para el reconocimiento de la IM, se podría

incrementar el número de potenciales usuarios de un BCI enfocado a neurorehabilitación. En este trabajo se realiza un análisis de ocho diferentes métodos de clasificación para reconocer patrones de IM en la señal de EEG de un paciente diagnosticado con un EVC, para conocer si alguno proporciona una ventaja en cuanto a su desempeño y costo computacional.

## II. METODOLOGÍA

### 1) Adquisición de datos:

Se adquirió la señal de EEG de un paciente masculino, de 50 años de edad, y con una evolución de 7 meses al momento del estudio, fue diagnosticado con EVC subcortical en el hemisferio izquierdo, localizado en la región posterior de la capsula interna izquierda. Se colocaron 11 electrodos de EEG localizados en las posiciones F3, C3, T3, P3, Cz, Fz, Pz, F4, C4, T4 y P4, de acuerdo al sistema internacional 10-20. El registro se realizó con un amplificador certificado para investigación en humanos, modelo g.USBamp, marca, g.Tec de 24 bits de resolución, previo consentimiento informado del paciente y autorización del comité de ética del INR. La frecuencia de muestreo utilizada fue de 256 Hz. En un total de 4 sesiones, el paciente realizó 120 ensayos correspondientes a la IM de mano derecha (IMD), y 120 ensayos de IM de mano izquierda (IMI); las indicaciones se dieron por medio de guías auditivas y visuales presentadas de forma aleatoria al usuario (para evitar habituación) usando una interfaz basada en el paradigma de Graz [5]. Cada ensayo consistió en una ventana temporal de registro de 8 segundos, los primeros 3 segundos corresponden a un periodo de descanso con los ojos abiertos antes de la señalización del inicio de IM, la cual tiene una duración de 5 segundos. Para ello se diseñó una interfaz sincronizada con la adquisición de la señal de EEG que se detalla en [6].

### 2) Pre-procesamiento de señal:

Para acondicionar las señales de EEG, se aplicó un filtro pasa-banda tipo Butterworth de orden 9 de 1 a 30 Hz, para no alterar la potencia de las bandas de frecuencia de  $\alpha$  (8-13 Hz) y  $\beta$  (14-30 Hz) donde se presenta la IM, y un filtro rechaza-banda de 59 a 61 Hz, para asegurar la eliminación del ruido debido a la línea eléctrica.

En el registro de la señal de EEG, un electrodo mide una mezcla de señales de diversos grupos de neuronas, por lo que para mejorar la clasificación de las señales de EEG es necesario realizar un filtrado espacial para obtener

solamente la señal de electrodo de interés y eliminar artefactos comunes. Aquí se realizó un filtrado espacial tipo Laplaciano a los canales centrales C3, Cz y C4, este filtrado consiste en usar la información de los cuatro electrodos circundantes para filtrar los canales de interés, ubicados en la zona de la corteza cerebral encargada de las tareas motoras [7].

### 3) Extracción de Características:

Se obtuvieron características de potencia espectral de los 3 canales de EEG filtrados temporal y espacialmente. Para cada ensayo de IMD e IMI, se realizó un análisis tiempo-frecuencia basado en la transformada Wavelet usando una familia de wavelets Morlet compleja, para una descripción detallada del procedimiento ver el trabajo de Tallon-Baudry y colaboradores [8]. Después, se calculó la potencia promedio de una ventana de 1 s para cada ensayo, en los rangos de alfa (8-13.5 Hz) y beta (14-30 Hz). El intervalo temporal de estas ventanas se definió de 3.5 a 4.5 s, ya que se ha observado en trabajos anteriores que en ese intervalo de tiempo hay diferencia significativa entre la potencia de ambas tareas [9] [10]. Con lo que se obtuvo un vector de 6 características por ensayo, al obtener el promedio de potencia para el rango de alfa y beta para cada uno de los 3 canales.

### 4) Clasificación:

Se implementaron 8 diferentes esquemas de clasificación, los cuales fueron entrenados con un subconjunto del total de características de potencia espectral y probados con el subconjunto restante. A continuación se describe la metodología empleada para cada uno de los esquemas de clasificación:

*Distancia Euclidiana (DE):* Para su implementación se calculan dos centroides correspondientes a cada clase a reconocer, IMD e IMI, para ello se promedian las columnas del vector de características de todos los ensayos usados para el entrenamiento. Una vez calculados estos valores promedio, se calcula la distancia Euclidiana usando las ecuaciones (1) y (2).

$$deuc_1 = \sqrt{(c_1 - m_{(1,1)})^2 + (c_2 - m_{(1,2)})^2 \dots + (c_6 - m_{(1,6)})^2} \quad (1)$$

$$deuc_2 = \sqrt{(c_1 - m_{(2,1)})^2 + (c_2 - m_{(2,2)})^2 \dots + (c_6 - m_{(2,6)})^2} \quad (2)$$

Donde  $deuc_1$  y  $deuc_2$  son las distancias euclidianas con respecto al centroide para IMD e IMI respectivamente.  $m_{(i,j)}$  es el centroide calculado para la  $i$ -ésima clase, y la  $j$ -ésima característica. Finalmente  $c_j$  corresponde a la magnitud de la  $j$ -ésima característica.

*Distancia de Mahalanobis (DM):* Se implementa la distancia de Mahalanobis como criterio de clasificación, a partir de las ecuaciones (3) y (4).

$$dmah_1 = \sqrt{(c - m_1) S^{-1} (c - m_1)^T} \quad (3)$$

$$dmah_2 = \sqrt{(c - m_2) S^{-1} (c - m_2)^T} \quad (4)$$

Donde  $dmah_1$  y  $dmah_2$  son las distancias de Mahalanobis al centroide de IMD e IMI respectivamente. Siendo que  $S^{-1}$  corresponde a la matriz de covarianzas inversa. La  $c$  representa al vector de características definido para cada ensayo.  $T$  corresponde a la transpuesta de la matriz.

*Análisis de discriminante lineal (LDA):* Este clasificador se basa en encontrar una proyección espacial de los datos que permita la máxima separabilidad entre las clases de acuerdo a una función lineal [11].

*Análisis de discriminante cuadrático (QDA):* Es una modificación del LDA clásico que involucra utilizar una función cuadrática en lugar de una lineal para establecer la separación entre clases, ambos clasificadores de discriminante fueron implementados usando las herramientas de MATLAB (*Statistics and Machine Learning*).

*Mapa auto-organizado (SOM):* Es un tipo de red neuronal artificial que permite llevar un problema de clasificación de un número alto de dimensiones, a dos o tres dimensiones [12]. Aunque los SOMs son generalmente usados para la clasificación de datos por medio de un esquema no-supervisado, una modificación permite entrenarlos de forma supervisada [13]. En el caso del presente trabajo se utilizó un mapa de 8x13 nodos, con topología hexagonal. El mapa fue inicializado de una forma lineal usando los eigenvectores y eigenvalores de la matriz de datos de entrenamiento y entrenado de acuerdo al algoritmo de tipo Batch [12]. Los SOMs fueron implementados por medio del toolbox SOM presentado en [14].

*Red neuronal artificial perceptrón multicapa (ANN):* La red consta de 3 capas, de acuerdo a la figura 1. Las neuronas que componen a la ANN tienen una función de activación sigmoideal inversa, permitiendo salidas definidas de 0 a 1. Las entradas fueron normalizadas linealmente entre 0 a 1 de acuerdo al valor máximo de las dimensiones. Las entradas fueron presentadas de forma aleatoria a la red.

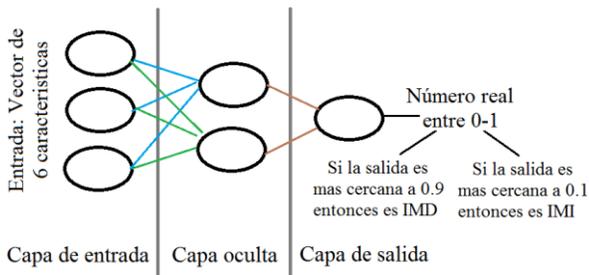


Fig. 1: Diagrama de arquitectura empleada para la ANN. Tres neuronas en capa de entrada, dos en capa oculta y una en capa de salida. La salida está definida entre 0 a 1.

**Máquina de soporte vectorial (SVM):** Método que permite encontrar el hiperplano que mejor separa datos de 2 clases diferentes. El mejor hiperplano es aquel que tiene el margen de separación más grande entre las clases. Un modelo SVM fue implementado con un kernel lineal, el cual se ha visto que es mejor para reconocer entre patrones bi-clase. Como regla de clasificación se usó la ecuación (7). Donde el valor de  $c$  define si el vector de características pertenece a una clase o a la otra,  $\alpha_i$  son los pesos,  $s_i$  son los vectores soporte (vectores con los cuales se define el margen de separación entre clases),  $b$  es el bias y  $k$  es la función del kernel [15].

$$c = \sum_i \alpha_i k(s_i, x) + b \quad (7)$$

**Clasificador de votación mayoritaria (VM):** Finalmente se usó un conjunto de clasificadores: SVM, ANN y LDA, para diseñar un clasificador de votación mayoritaria (VM), esto es, si dos o más de los clasificadores indicaban la misma clase, al ensayo se le asignaba esa clase.

Para los clasificadores, se usó una validación cruzada del tipo aleatoria, en la cual se entrenaron los clasificadores con 120 ensayos, 60 ensayos de IMD y 60 de IMI, y se probaron con los restantes 60 ensayos de cada clase. El proceso de selección de conjuntos, entrenamiento y prueba de los clasificadores se repitió 30 veces, seleccionando aleatoriamente los conjuntos de entrenamiento y prueba. Se obtuvo el porcentaje de clasificación correcta (%CC) para cada clasificador al obtener el promedio de los %CC obtenidos en cada validación. Se calculó la matriz de confusión para conocer la sensibilidad (capacidad de reconocimiento de IMD) y especificidad (capacidad de reconocimiento de IMI) de cada clasificador.

### 5) Análisis Estadístico

Se realizó una prueba t de Student para muestras pareadas, para evaluar si existían diferencias significativas entre el desempeño del clasificador con el %CC más alto

con respecto al obtenido para cada uno de los otros clasificadores. Se usó un nivel de significancia del 95% ( $\alpha=0.05$ ).

### 6) Costo Computacional

El costo computacional de cada clasificador se calculó en términos de su complejidad computacional, tanto en operaciones aritméticas, como con la notación “big-O”. El cálculo se realizó para la etapa de prueba y no se tomó en cuenta el costo del entrenamiento del algoritmo, como son el cálculo de pesos y de centroides. Los costos se basan en clasificar un solo vector de 6 características de IM (un ensayo).

## III. RESULTADOS

En la figura 2 se muestran los %CC para cada uno de los clasificadores evaluados. Se observa que el clasificador VM obtuvo la mejor tasa de desempeño con un 78%. Seguido por la SVM con un 76%. El LDA obtuvo un desempeño prácticamente igual con un 75%. La ANN obtuvo un desempeño del 74 %, mientras que los SOMs del 73%. Los tres clasificadores que obtuvieron el peor desempeño fueron QDA, DE y DM, teniendo todos 69%. Para todos los clasificadores la especificidad fue mayor o igual a la sensibilidad, indicando que el reconocimiento de IMI fue mejor que el de IMD. El análisis estadístico indica que no existe una diferencia significativa entre el desempeño de SVM y VM, y que existe una diferencia significativa entre el desempeño del resto de los clasificadores probados con respecto a SVM y VM.

En la Tabla 2 se puede observar el costo computacional para cada clasificador. El LDA y QDA son los clasificadores que tiene un menor costo computacional, seguido por ANN. Mientras que SVM y VM son los que tienen un costo computacional mayor.

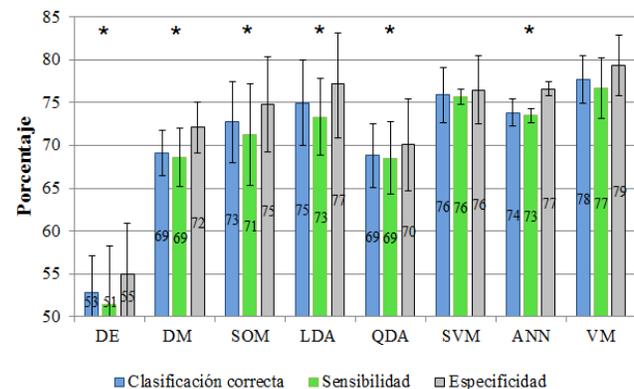


Fig 2. Resultados del desempeño obtenido por los clasificadores para reconocer IMD e IMI en el paciente con EVC. La sensibilidad y especificidad se representan por las barras verdes y grises respectivamente. El clasificador de VM fue significativamente mejor ( $p \leq 0.05$ ) que el clasificador marcado con un asterisco (\*).

Tabla 2. Costo computacional de los clasificadores.

Clasificador	Costo computacional		
	Sumas	Multiplicaciones	big-O
DE	13	7	O(216)
DM	99	252	O(216)
QDA	20	18	O(6)
SOM	845	455	O(624)
ANN	35	30	O(18)
LDA	7	6	O(6)
SVM	721	721	O(330)
VM	763	757	O(372)

#### IV. DISCUSIÓN

Para definir cuál es el clasificador con mayores ventajas, debe considerarse tanto su desempeño para reconocer las tareas de IM, como el costo computacional de su implementación. En este trabajo, consideramos que la etapa de entrenamiento de los clasificadores se realiza fuera de línea, como en la mayor parte de los BCIs, por lo que el costo computacional a considerar es el de la etapa de clasificación de vectores de características de IM que no fueron usadas en el entrenamiento del clasificador. El VM tiene el mejor desempeño entre todos los clasificadores, sin embargo también tiene un alto costo computacional, ya que este costo equivale al de la ANN, la SVM y el LDA juntos. Una ventaja de este tipo de clasificadores es que presentan una mayor estabilidad en su desempeño, en comparación a cuando se usa un clasificador individual [16]. Sin embargo, algunos temas como, si se debe de asignar pesos a la salida de los clasificadores, como hacerlo y la metodología para la selección de los clasificadores para formar el nuevo clasificador, son aún objeto de investigación. El LDA presenta el menor costo computacional entre los clasificadores evaluados y tiene un desempeño únicamente superado por un 3% por VM, aunque el costo computacional del LDA es aproximadamente 50 veces menor al de este.

No parece haber una diferencia importante en el %CC entre usar un clasificador basado en una función de decisión lineal (LDA) y otro basado en una función de decisión no lineal (ANN). El hecho de que en general los clasificadores tengan una mayor tasa para reconocer IMI que IMD puede deberse a que la lesión del paciente se encuentra en el hemisferio izquierdo del cerebro, lo cual puede generar mayor variabilidad en los patrones correspondientes a IMD.

#### V. CONCLUSIÓN

Para el caso del paciente con EVC de este trabajo, la mejor opción de clasificador es el LDA, ya que permite obtener un desempeño muy cercano inclusive al de un clasificador computacionalmente más costoso como el SVM y VM. La ANN también mostró un buen desempeño con un costo cercano al del LDA. Esta elección de clasificadores podría no ser aplicable a una muestra más grande de pacientes, sin embargo como la señal de EEG tiene características que

presentan mucha variabilidad entre sujetos, puede ser que sea necesario un análisis de clasificadores para reconocer la IM en cada paciente. Este análisis personalizado de clasificadores podría permitir que un mayor número de pacientes sean capaces de controlar un BCI y por lo tanto permitiría acercar esta tecnología a aplicaciones clínicas de neurorehabilitación.

#### RECONOCIMIENTOS

Se agradece al paciente que participo en este trabajo por su tiempo y gran esfuerzo. Se agradece al CONACYT por los recursos brindados al INR por medio del proyecto SALUD-2012-01-180159.

#### BIBLIOGRAFÍA

- [1] M. Rodriguez, C. Llanos, Malechka, M. Sabate, "The kinematics of motor imagery: Comparing the dynamics of real and virtual movements," *Neuropsychologia*, vol. 47, no. 2, pp. 489-496, 2009.
- [2] M.T. Carrilo-de-la-peña, S. Galdo-Alvarez, C. Lastra-Barreira, "Equivalent is not equal: Primary motor cortex (MI) activation during motor imagery and execution of sequential movements," *Brain Research*, vol. 1226, pp. 134-143, 2008.
- [3] S. Kraeutner, A. Gionfriddo, T. Bardouille, S. Boe, "Motor imagery-based brain activity parallels that of motor execution: Evidence from magnetic source imaging of cortical oscillations", *Brain Research*, vol. 1588, pp. 81-91, 2014.
- [4] M. Ahn, S. Jhun. "Performance variation in motor imagery brain-computer interface: a review". *Journal of Neuroscience Methods*. vol. 243, pp. 103-110. 2015.
- [5] G. Pfurtscheller, "Motor imagery and direct brain-computer communication", *Proc IEEE*, vol. 89, No 7, 1123-1134, 2001.
- [6] J. Cantillo-Negrete, J. Gutierrez-Martinez, R.I. Cariño-Escobar, D. Elias-Viñas. "Module to present and identify motor imagery tasks in electroencephalography", PAHCE. 2013.
- [7] B. Hjort, "An on-line transformation of EEG scalp potentials in Orthogonal Source Derivations", *Electroencephalography and Clinical Neurophysiology*, vol. 39, pp. 526-530. 1975.
- [8] C. Tallon-Baudry, O. Bertrand, C. Delpuech, J. Pernier. "Oscillatory gamma-band (30-70 Hz) activity induced by a visual search task in humans". *Journal of Neuroscience*, Vol. 17, no. 2, p.p. 722-734, 1997.
- [9] J. Cantillo-Negrete, J. Gutierrez-Martinez, T.B. Flores Rodriguez, R.I. Cariño-Escobar, D. Elías-Viñas. "Characterization of electrical brain activity related to hand motor imagery on healthy subjects". *Rev Invest Clin*. No. 66(S1), pp. 111-121. 2014.
- [10] J. Cantillo-Negrete, J. Gutierrez-Martinez, R.I. Carino-Escobar, T.B. Carrillo-Mora, D. Elias-Vinas. "An approach to improve the performance of subject-independent BCIs-based on motor imagery allocating subjects by gender". *BioMedical Engineering OnLine*. Vol. 13 No. 158. 2014.
- [11] R.A. Fisher. "The Use of Multiple Measurements in Taxonomic Problems". *Annals of Eugenics*, vol. 7, pp. 179-188, 1936.
- [12] T. Kohonen. *Self Organizing Maps*. Springer, 3era edición. 2001.
- [13] T. Kohonen. "Essentials of the self-organizing map", *Neural Networks*, vol. 37, pp. 52-65.
- [14] Vatanen, et al. (2015,05,19). "Self Organization and missing values in SOM and GTM". [en línea] Disponible en: <http://research.ics.aalto.fi/software/somtoolbox>.
- [15] Cortes C., Vapnik V. "Support-Vector Networks". *Machine Learning*. vol. 20, pp. 273-297. 1995.
- [16] L.I. Kuncheva. *Combining Pattern Classifiers: Methods and Algorithms*. John Wiley & Sons. 2004. pp. 112-123.