

**Decodificación de imaginación motora en la señal de electroencefalografía
mediante mapas auto-organizados**
*Motor imagery decoded from electroencephalography signal by means of
self-organizing maps*

Rubén I. CARINO-ESCOBAR

Subdirección de Investigación Tecnológica, Instituto Nacional de
Rehabilitación, Ciudad de México, Universidad La Salle, Ciudad de México
(México)

Jessica CANTILLO-NEGRETE

Subdirección de Investigación Tecnológica, Instituto Nacional de
Rehabilitación, Ciudad de México (México)

Josefina GUTIÉRREZ-MARTÍNEZ

Subdirección de Investigación Tecnológica, Instituto Nacional de
Rehabilitación, Ciudad de México (México)

Roberto A. VÁZQUEZ

Universidad La Salle, Ciudad de México (México)

Fecha de recepción: mayo de 2015

Fecha de aceptación: febrero de 2016

Resumen

La imaginación motora es un proceso cognitivo que consiste en la planeación de un movimiento sin ejecutarlo. En la señal de electroencefalografía, esta planeación puede decodificarse para usarse como método terapéutico para pacientes con enfermedad vascular cerebral. Los mapas auto-organizados son redes neuronales que podrían usarse como clasificadores de imaginación de movimiento. En este trabajo se evalúa el desempeño de los mapas auto-organizados para clasificar imaginación de movimiento en la señal de EEG. Se registraron las señales de electroencefalografía a 4 participantes, dos de ellos sanos y



dos con enfermedad vascular cerebral mientras realizaban imaginación de movimiento de las manos. Se aplicó un filtrado espacial tipo Laplaciano en los canales centrales C3, Cz y C4, después se obtuvieron características espectrales en las bandas alfa y beta mediante un análisis tiempo-frecuencia. Se entrenaron mapas auto-organizados para cada participante con sus características espectrales en 3 condiciones distintas de imaginación de movimiento de mano y reposo. Se obtuvieron porcentajes de clasificación correcta superiores al nivel de aleatoriedad y de hasta 80%. Los clasificadores propuestos son prometedores para decodificar imaginación motora en el EEG y para diseñar sistemas de retroalimentación del desempeño del usuario.

Palabras clave: Enfermedad vascular cerebral, redes neuronales artificiales, clasificadores, entrenamiento supervisado, terapia.

Abstract

Motor imagery is a cognitive process which involves a planning of a movement without performing its execution. This planning can be decoded from the electroencephalography signal and be used for therapeutic purposes. Self-organized maps are artificial neural networks that have a potential to be used as motor imagery classifiers. In this work 11 channels were recorded from 2 healthy subjects and from 2 stroke patients. The data from the channels was pre-processed with a Laplacian type spatial filter applied to channels C3, Cz and C4, then power features were computed with a wavelet transform in the alpha and beta bands. Self-organized maps were trained and tested for each participant with the power features obtained from 3 different conditions. Correct classification accuracies above the chance level were achieved and even reached 80%. The proposed classifiers are promising for motor imagery decoding in the EEG signal, the performance of the proposed classifiers can be increased if a feedback system could be used to train the system's users.

Keywords: Stroke, artificial neural networks, classifiers, supervised training, therapy.

Introducción

Las personas con discapacidad motora debido a lesiones neurológicas, generalmente ven limitada su independencia debido a una recuperación incompleta de las funciones motoras. Este es el caso de una enfermedad vascular cerebral (EVC). Una de las secuelas de esta enfermedad, presentadas con mayor incidencia, es la pérdida de la funcionalidad motora de las manos, lo cual provoca una disminución de la calidad de vida de este tipo de pacientes (Dijkerman et al., 1996).

La imaginación de movimiento o imaginación motora (IM), es la representación mental de movimientos que involucran la planeación motora y una simulación interna de una actividad motora, sin realizar movimientos reales (Jeannerod et al., 1999). Se ha reportado que la IM tiene los mismos componentes, e involucra las mismas áreas cerebrales, que cuando se realiza un movimiento real (Rodríguez et al., 2009) (Carrilo-de-la-peña et al., 2008) (Kraeutner et al., 2014). Los patrones de activación cerebral consisten en cambios en el electroencefalograma (EEG) en frecuencias específicas. Al descenso en la potencia espectral de la señal de EEG, con respecto a una línea base, se le conoce como desincronización relacionada al evento (ERD) y, al aumento de la potencia, se define como sincronización relacionada al evento (ERS). Los cambios en la potencia se registran en la región sensorial-motora de la corteza cerebral, en el rango de frecuencias del ritmo mu (8-13 Hz) y beta (13-30 Hz) (Pfurtscheller et al., 1999).

Existen varios estudios que muestran que imaginar el movimiento de la mano afectada puede ayudar a recuperar la función de la mano. La evidencia más directa son los trabajos de Page y colaboradores, quienes primero realizaron un estudio piloto en el que combinaron fisioterapia clásica con IM en pacientes con EVC, los resultados mostraron una mejor recuperación del movimiento del brazo (Page, 2000). Después, en un estudio con una muestra más grande, se obtuvieron resultados similares (Page et al., 2001).

A la fecha, la terapia con IM no se ha difundido debido a que no se ha establecido una técnica confiable para determinar que los pacientes realicen las tareas de imaginación, por lo que es necesario explorar métodos que permitan la decodificación de la IM en la señal de EEG. Por ejemplo, Nguyen y colaboradores aplicaron la transformada Wavelet y seleccionaron las mejores bandas de frecuencias, para clasificar IM en el EEG por medio de un sistema difuso usando un aprendizaje de búsqueda por tabú. Con este método lograron obtener resultados de 92% de clasificación correcta para un sujeto sano y un paciente con esclerosis lateral amiotrófica (Nguyen et al., 2015). Hu y colaboradores extrajeron características del dominio de la frecuencia del EEG con un modelo autoregresivo

modificado y, características en el dominio de la frecuencia con la transformada rápida de Fourier; para clasificar la IM de mano de dos sujetos sanos, usaron un clasificador de discriminante lineal, obteniendo 80% de clasificación correcta (Hu et al., 2013). Yi y colaboradores aplicaron patrones espaciales comunes (CSP) (Lemm et al., 2005) y máquinas de soporte vectorial para clasificar IM de ambas manos y el pie derecho de 10 sujetos sanos, obteniendo un 70% de clasificación correcta en promedio (Yi et al., 2013). En otro trabajo se aplicó análisis de componentes principales, análisis de discriminante lineal y, una máquina de aprendizaje extremo por votación mayoritaria, para clasificar correctamente el 93.5% de ensayos de IM de un sujeto sano (Duan et al., 2014). También se ha aplicado CSP y máquinas de soporte vectorial optimizadas por medio de un algoritmo de computo evolutivo, para discriminar entre tareas de IM en 4 sujetos sanos, obteniendo en promedio 70% de clasificación correcta (Mo et al., 2015).

Un método que podría ser usado para decodificar IM, y que no se ha investigado extensivamente, son las redes neuronales artificiales del tipo mapas auto-organizados (SOMs) (Kohonen, 2013) (Kohonen, 2001). Los SOMs son un tipo de redes neuronales artificiales que permiten trasladar un problema de dimensión alta a un espacio de dimensión baja, generalmente de dos dimensiones. A diferencia de los esquemas de redes neuronales artificiales, como el Perceptron o Adaline, que utilizan pesos para poder generar una función que discrimine mejor entre los patrones en el espacio definido por el problema, los pesos en los SOMs funcionan con el concepto de asociar entradas con atributos similares, lo cual hace posible vislumbrar la relación de los datos y sus diferencias mediante representaciones topográficas.

Los SOMs se encuentran organizados por nodos, los cuales son equivalentes a las neuronas en otras redes neuronales artificiales. El nodo consiste en un vector de pesos con igual dimensión que la de los patrones de entrada que se quieren conocer, y una posición la cual permite la interpretación topográfica de la red. Al conjunto de nodos se les conoce como un mapa, ya que simula la corteza cerebral formada por neuronas.

El primer paso para entrenar un SOM, consiste en inicializar los pesos de los nodos, ya sea de forma aleatoria o, por medio de los eigenvalores asociados a los dos componentes principales de los datos (inicialización lineal), siendo el segundo método el que presenta una mayor velocidad de convergencia (Kohonen, 2013). Posteriormente, se presentan los vectores representativos de las entradas de patrones a clasificar, esto puede hacerse secuencialmente (algoritmo secuencial, recomendado para fines de aprendizaje del algoritmo) o en una sola iteración (algoritmo tipo batch, recomendado para aplicaciones reales). Para cada entrada se calcula en el mapa el nodo, cuyos pesos presentan la menor

distancia Euclidiana con respecto a los valores de las dimensiones de entrada (este nodo es conocido como Best Matching Unit o BMU por sus siglas en ingles). Los pesos son actualizados para ser más similares al vector de entrada, y los nodos circundantes también lo son de acuerdo a la topología del SOM (generalmente hexagonal) y a una función de vecindad.

Los SOMs son principalmente usados en los campos de la bioinformática y en el procesamiento de bases de datos masivas (Kohonen, 2013). Aunque los SOMs implementados como clasificadores pueden ser de aprendizaje no-supervisado, también existe una variante de aprendizaje supervisado (Kohonen, 2001).

El objetivo de este trabajo es evaluar el desempeño de SOMs, esto con un esquema de entrenamiento supervisado para decodificar imaginación de movimiento de mano en el EEG de sujetos sanos y pacientes con secuelas motoras debido a un EVC. Este tipo de clasificadores, combinados con una extracción de características en el dominio de tiempo-frecuencia, no han sido usados previamente para clasificar patrones de IM de la señal de EEG de sujetos sanos o pacientes con EVC. Las características de clasificación de los SOMs, como su propiedad de transferir las dimensiones originales de proyección del problema a un espacio bidimensional, podrían ayudar a incrementar el porcentaje de clasificación correcta de IM. Lo cual, permitiría el desarrollo de sistemas de retroalimentación para terapias basadas en IM con buen desempeño para un mayor número de usuarios.

Metodología

A) Sujetos y tarea experimental

La muestra consta de: 2 sujetos sanos, y 2 pacientes con hemiparesia de la mano derecha debido a una enfermedad vascular cerebral. Los participantes sanos negaron antecedentes de daños neurológicos o psiquiátricos. Los pacientes no tenían alteraciones cognitivas ni de lenguaje. Todos los participantes tenían visión normal o corregida a normal. Un especialista en electrofisiología clínica descartó alteraciones en el análisis cualitativo de los registros de EEG. Todos los participantes firmaron un consentimiento informado autorizado por el comité de investigación y ética del Instituto Nacional de Rehabilitación (INR).

Los participantes se sentaron en un sillón cómodo frente al monitor de una computadora, en él (monitor) se les dieron indicaciones de manera visual. Los sujetos fueron instruidos para realizar 120 ensayos en los que se mantenía en reposo con ojos abiertos (REP), 120 ensayos

de imaginación del movimiento de pinza gruesa de la mano derecha (IMD) y, 120 ensayos de imaginación del movimiento de pinza gruesa mano izquierda (IMI). Los ensayos se realizaron de manera aleatoria para evitar la habituación de los sujetos, cada ensayo tiene una duración de 8 s. El protocolo se basa en el paradigma propuesto por Pfurtscheller y colaboradores (2001).

B) Adquisición de la señal

La señal de EEG se registró con un amplificador marca gTec, modelo gUSBamp de 16 canales y 24 bits de resolución, a una frecuencia de muestreo de 256 Hz. Se colocaron 11 electrodos de EEG, en el cuero cabelludo de los participantes, de acuerdo al sistema internacional 10-20 (T3, P3, C3, Cz, C4, P4, T4, F3, Fz, F4 y Pz). Las posiciones de los electrodos se definieron considerando que los cambios generados en la señal de EEG debido a la IM de las manos se registran en la corteza sensorial-motora, ubicada en la zona central de la corteza cerebral. El electrodo de referencia se colocó en el lóbulo de la oreja derecha, y el de tierra, en la posición AFz del sistema internacional 10-10. Se colocaron dos canales de electromiografía en ambos brazos para comprobar que el participante no realizaba el movimiento real. En la Figura 1 se observa la adquisición de las señales de EEG en uno de los participantes.

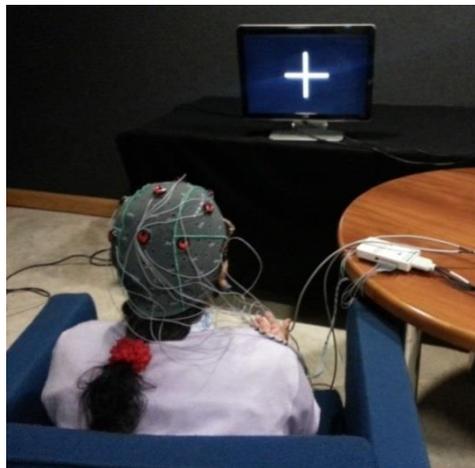


Figura 1: Adquisición de señales de EEG para uno de los participantes del estudio. Se puede observar la guía visual en el monitor, y la gorra de adquisición en la que se colocan electrodos.

C) Pre-procesamiento de la señal

Puesto que los ritmos sensorial-motores generados durante la IM se presentan en la banda de frecuencias de 8-30 Hz, se aplicó un filtro pasa-banda tipo Butterworth de orden 9 en ese rango de frecuencias. Posteriormente, para eliminar artefactos por movimiento y parpadeos en la señal de EEG, se aplicó un filtrado espacial tipo Laplaciano a los canales centrales C3, Cz y C4. El filtrado Laplaciano es una operación que consiste en restar a la señal de cada electrodo EEG, la media de las señales de sus cuatro vecinos más próximos (Hjort, 1975).

D) Extracción de Características

Para obtener las características de la señal de EEG, se calcularon representaciones tiempo-frecuencia utilizando la transformada Wavelet tipo Morlet compleja para cada uno de los 120 ensayos por tarea. El análisis se realizó usando una resolución de 0.5 Hz en la banda de frecuencia de 8 a 30 Hz. La familia de wavelets seleccionada fue con α y β , la cual es caracterizada por la relación de compensación constante $\alpha\beta = 6$, esto es, valores más grandes de α incrementan la resolución en frecuencia mientras que, valores más pequeños incrementan la resolución temporal, y en el caso de este trabajo se fijó en 6 (Tallon-Baudry et al., 1997). Los valores de potencia fueron calculados desde 1 hasta 7 s, de cada ensayo, en pasos de 50 ms.

Con este precedente, se calculó la potencia promedio de una ventana de 1 s para cada ensayo, en los rangos de alfa y beta separada en 4 sub-bandas: alfa1 de 8-10.5 Hz, alfa2 de 11-13.5 Hz, beta1 de 14-16.5 Hz y beta2 de 17-19 Hz. El intervalo temporal de estas ventanas consiste de 1.5 s a 2.5 s para REP, y de 3.5 s a 4.5 s para IMD e IMI, esto con base en resultados previos obtenidos por Cantillo-Negrete y colaboradores (2014). Considerando lo anterior, se obtuvieron cuatro características de potencia por canal, haciendo un total de 12 por cada ensayo. Una ilustración de las características extraídas de la señal de EEG puede observarse en la Figura 2., en el que se realizó el mismo procedimiento para las tres tareas realizadas por los voluntarios.

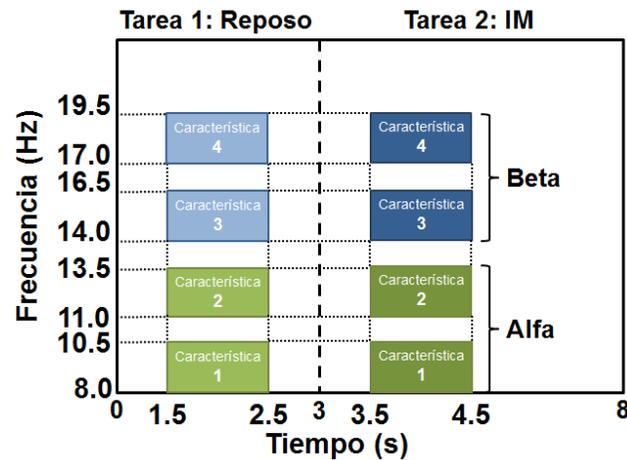


Figura 2: Características extraídas para los intervalos de imaginación de movimiento y reposo de los canales C3, C4 y Cz del EEG.

E) Implementación del SOM

Usando las herramientas de licencia libre denominadas SOM Toolbox para Matlab (Vatanen et al., 2015), se implementaron dos configuraciones para cada sujeto y paciente: un SOM supervisado de dos clases para clasificar entre dos de cada una de las tareas de IM y el periodo de reposo, y un SOM de tres clases para clasificar entre las tres condiciones. Los SOMs fueron entrenados usando una topología hexagonal, con una matriz de nodos de 15 filas y 5 columnas para el caso de dos clases, y de 8 filas por 10 columnas para el caso de tres clases. Este tamaño de los mapas fue fijado con base en el tamaño de los dos componentes principales de la información: los que contienen los eigenvalores más altos de la matriz de correlación de los datos de entrada, tal como se recomienda por Kohonen (Kohonen, 2013). Las magnitudes de las 12 dimensiones de entrada fueron normalizadas de acuerdo a su valor máximo. El mapa fue inicializado de una forma lineal usando los eigenvectores y eigenvalores de la matriz de datos de entrenamiento (Kohonen, 2013). El algoritmo usado para entrenar el mapa es del tipo batch, y modificado, de acuerdo a lo propuesto por Kohonen (2001), de modo que pueda ser aplicado a un esquema de entrenamiento supervisado. Con el fin de ello, se añadió una dimensión más a los vectores de características usados en la clasificación, que consistió en una etiqueta numérica para cada clase, siendo que, el valor de uno indicaba que la clase a la cual correspondían los datos era IMD, dos para IMI y tres para reposo.

F) Validación y prueba del clasificador

Para validar el desempeño del SOM, se realizaron 100 experimentos de cada configuración cumpliendo con el teorema del límite central. En cada repetición se seleccionaron de manera aleatoria el 70% de los datos para el entrenamiento, y el 30% restante para la prueba. Se obtuvieron los porcentajes de clasificación correcta (%CC) de los SOMs para todas las configuraciones.

Además, se calculó el nivel práctico de aleatoriedad, con el cual se estima la confiabilidad de los resultados obtenidos con esta metodología, es decir, indica que el desempeño del algoritmo implementado no presenta un comportamiento aleatorio (Muller-Putz et al., 2008). El nivel práctico de aleatoriedad depende del número de ensayos usados, (240 para el SOM de dos clases y 360 para el SOM de tres clases) y se calcula usando un intervalo de confianza de 95%. Los niveles de aleatoriedad calculados se compararon con los %CC obtenidos.

Con el fin de obtener una comparativa del desempeño de clasificación del SOM de tres clases, se utiliza la misma información de entrenamiento y prueba para obtener el %CC de un clasificador de análisis de discriminante lineal (LDA). En aplicaciones de clasificación de patrones, el LDA maximiza la variabilidad inter-clase y maximiza la variabilidad intra-clase, de tal forma que puedan ser separados con una función lineal. El LDA es un método de clasificación ampliamente usado en trabajos de clasificación de IM (Choi et al., 2011) (Rodríguez-Bermúdez et al., 2012) (Cantillo-Negrete et al., 2014) (Li et al., 2011). El SOM de tres clases no se comparó contra LDA, debido a que éste tiene la restricción de poder clasificar únicamente entre dos clases. Aunque con modificaciones puede adaptarse a la clasificación de más clases, este ejercicio se deja para un análisis posterior.

Resultados

En la Figura 3 se observa un SOM entrenado para clasificar entre las tres tareas de IMD, IMI y REP. Si la característica presentada al mapa tenía la distancia euclidiana más pequeña con un nodo marcado con la clase a la cual pertenecía, se consideraba como una clasificación correcta. Si no era así, entonces se consideraba con una clasificación incorrecta.

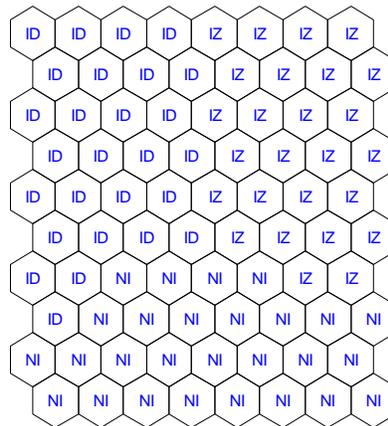


Figura 3: Diseño de un SOM usado para la clasificación entre tres tareas. ID son los nodos correspondientes a imaginación de movimiento mano derecha, IZ son los nodos correspondientes a imaginación de movimiento de mano izquierda, y, NI son los correspondientes al periodo de reposo.

En la Figura 4 se observa uno de los SOMs diseñados para clasificar entre dos tareas. El número de nodos es menor al SOM de la Figura 1, debido a que, tiene un menor número de datos de entrada (los SOMs de tres clases fueron entrenados con 360 muestras mientras los SOMs de dos clases fueron entrenados con 240 muestras).

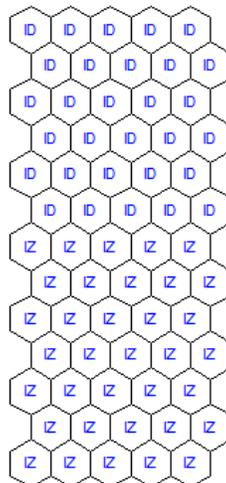


Figura 4: Diseño de un SOM usado para la clasificación entre dos condiciones. ID son los nodos correspondientes a imaginación de movimiento de mano derecha, e IZ son los correspondientes a la imaginación de mano izquierda.

Los %CC obtenidos para cada participante, en la clasificación entre dos tareas, se pueden observar en la Figura 5. En la gráfica también se observa el nivel práctico de aleatoriedad calculado para este experimento, el cual es de 57.6%. El paciente masculino obtuvo un mejor desempeño en todas las pruebas, llegando a alcanzar el 80% de clasificación correcta para IMD vs. IMI y para IMD vs. REP con el SOM. Se puede observar que los %CC obtenidos con el SOM, y con el LDA, son similares para este paciente.

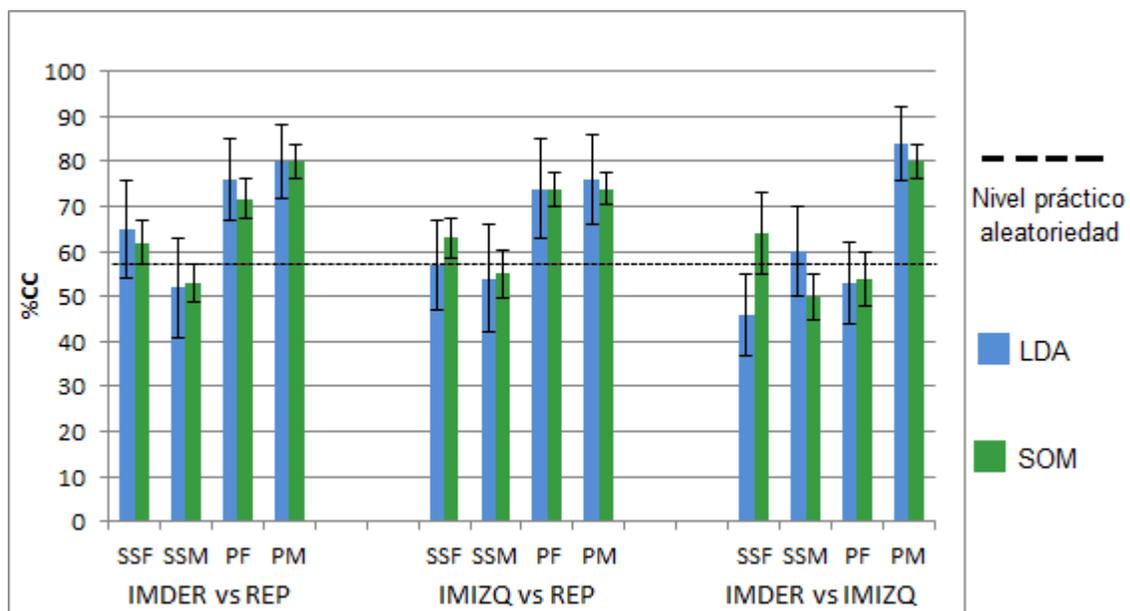


Figura 5: Porcentajes de clasificación correcta (%CC) de los SOMs diseñados correspondientes a los participantes con el fin de discernir entre dos tareas. Se diseñaron 3 tipos de SOMs por participante. SSF es sujeto sano femenino, SSM es sujeto sano masculino, PF es paciente femenino y PM es paciente masculino. Los %CC obtenidos con los SOMs, se muestran en color verde. Los %CC obtenidos con el método de clasificación LDA, se muestran en color azul. Las desviaciones estándar se marcan arriba de cada columna. La línea punteada representa el nivel de aleatoriedad calculado.

El participante que tuvo el segundo mejor desempeño, fue el paciente femenino con 74%, en relación a IMI vs. REP, y 72% de clasificación correcta con IMD vs. REP, usando SOMs. En el caso de la paciente, el SOM mostró un desempeño similar al obtenido con el LDA.

Los clasificadores de los sujetos sanos tuvieron un menor desempeño que los diseñados tomando en cuenta a los pacientes, teniendo el sujeto femenino un 63% para IMI vs. REP, y un 62% para IMD vs. REF con los SOMs. Sin embargo, cabe resaltar que, en los casos de IMIZQ vs. REP e IMDER vs. IMIZQ, el SOM obtuvo %CC mejores que los obtenidos con el LDA, a tal grado que superan el nivel práctico de aleatoriedad, mientras que con el LDA este nivel no se alcanza.

Ninguno de los clasificadores del sujeto masculino tuvieron un %CC arriba del 50%, siendo estos los que mostraron el desempeño más bajo entre los SOMs diseñados para todos los participantes. Vía el LDA, podemos decir que, únicamente, con IMDER vs. IMIZQ, se logró obtener un %CC arriba del nivel de aleatoriedad, mientras con el SOM no se logró superar este nivel.

En la Figura 6 se observan los %CC de los SOMs diseñados para todos los participantes Clasificando así, las tres tareas de IMD, IMI, y REP. Además, se muestra el nivel práctico de aleatoriedad para el experimento de tres clases (39.6%). El clasificador diseñado para el paciente masculino obtuvo el mejor desempeño con un 80%. Adicionalmente, el desempeño de la paciente y el del sujeto sano masculino, también, fue superior al nivel práctico de aleatoriedad.

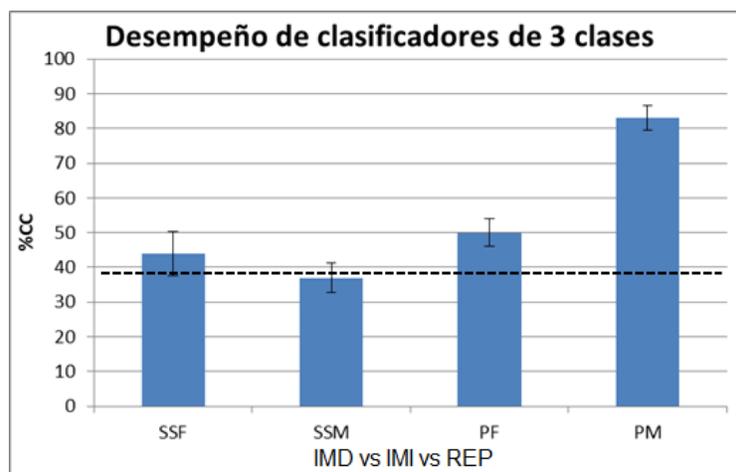


Figura 6: %CC de los SOMs diseñados para todos los participantes con el objetivo de discernir entre tres condiciones. Se diseñó un tipo de SOM por participante. SSF es sujeto sano femenino, SSM es sujeto sano masculino, PF es paciente femenino, y PM es paciente masculino. Las desviaciones estándar se marcan arriba de cada columna. La línea punteada representa el nivel de aleatoriedad calculado.

Discusión de resultados

Los SOMs diseñados y evaluados con los datos de EEG de los pacientes con EVC, tuvieron un mejor desempeño que los que se diseñaron con los datos de los sujetos sanos. Los SOMs de dos y tres clases diseñados con los datos del paciente masculino, tuvieron un buen desempeño sobre todas las tareas de clasificación, llegando a un 80% para IMD vs. REP y, de igual manera, se obtuvo un 80% para el de tres clases. Por lo observado en la clasificación de los datos de este paciente, el usar LDA o un SOM, es equivalente en términos de %CC. Esto nos indica que una función lineal de discriminación, es suficiente para decodificar la IM en el EEG de este paciente.

El paciente femenino no fue tan beneficiado como el masculino con el uso de SOMs, ya que el máximo %CC para dos clases fue de 74% en IMD vs. REF, mientras que el clasificador de 3 clases tuvo un pobre desempeño al clasificar correctamente sus intenciones. Lo cual puede indicar que los patrones generados en su señal de EEG, durante las tareas de IMD e IMI, son muy parecidos. El usar un LDA o un SOM en la clasificación de IM de esta paciente son equivalentes. Al igual que con el paciente masculino, esto posiblemente refleje que una función lineal, pueda ser suficiente para discriminar la IM de esta paciente.

En el caso de los sujetos sanos, los SOMs diseñados con los datos del sujeto femenino obtuvieron mejores desempeños, siendo mejor el de IMI vs. REP, con un 63% de %CC. El SOM para este sujeto sano permitió clasificar correctamente la IM, lo que no se pudo conseguir con el LDA. Esto probablemente se deba a que es necesario utilizar una función de clasificación no lineal (como lo es el SOM implementado) para decodificar correctamente los patrones de IM en la señal de EEG. Este hallazgo es importante, ya que, demuestra que un SOM puede obtener %CC para decodificar IM que no pueden obtenerse con un LDA.

El desempeño de los SOMs para el sujeto sano masculino no superó el 55%. Para una de las condiciones con el LDA se logró alcanzar el nivel práctico de aleatoriedad, mientras que con el SOM esto no fue posible. Lo cual muestra que el LDA puede llegar a mostrar un mejor desempeño que el SOM para la decodificación de IM de algunos sujetos.

Los porcentajes de exactitud en la clasificación obtenidos fueron mayores al nivel práctico de aleatoriedad calculado para cada experimento (57.6% para dos clases y 39.6% para el de tres clases) para los pacientes y el sujeto sano femenino, lo cual indica que los resultados son consecuencia del algoritmo implementado y del propio desempeño de los participantes.

El sujeto masculino tuvo un desempeño debajo del nivel de aleatoriedad, lo que podemos atribuir a que no tiene la habilidad de realizar IM, o, que no hay cambios significativos en su señal de EEG al realizarla.

Los SOMs diseñados para clasificar entre IMD vs. REP y para IMI vs. REP, obtuvieron los mejores %CC, mientras que los que presentaron menor desempeño fueron los de 3 clases y los diseñados para clasificar entre IMD vs. IMI. Lo cual nos sugiere que los participantes requieren de un proceso de entrenamiento para imaginar el movimiento de las manos de manera correcta.

Los resultados obtenidos en el caso de los pacientes son similares a los reportados usando la información de 32 o 64 canales, los cuales además, emplean algoritmos como patrones espaciales comunes y máquinas de soporte vectorial para procesar y clasificar los datos respectivamente (Edlinger et al., 2014) (Mo et al., 2015) (Yi et al., 2013). Mientras que en la obtención de resultados de este trabajo, se usaron únicamente los datos de 3 canales pre-procesados a partir de los 11 canales originales, lo cual implica una disminución del costo computacional en el procesamiento de los datos.

El algoritmo de entrenamiento de tipo batch requirió aproximadamente de 1 segundo para entrenar los SOMs de dos y tres clases. Por lo que este algoritmo podría ser implementado con el fin de actualizar los SOMs con nueva información, sin interrumpir una clasificación constante de los patrones de entrada. Esta característica podría ser de gran utilidad en la implementación de algoritmos de decodificación en línea.

Conclusiones

El SOM mostró ser una herramienta útil para la decodificación de la IM en sujetos sanos y pacientes con hemiparesia, en los últimos, tanto para la mano sana como para afectada. El que los datos de los pacientes con EVC hayan mostrado un mejor desempeño que los sujetos sanos, puede deberse a que los pacientes tienen más experiencia a la hora de realizar imaginación de movimiento de sus manos, puesto que, ellos han estado en la situación de no poder realizar movimiento de su mano a pesar de intentarlo.

Usar un SOM en lugar de un LDA como etapa de clasificación para un BCI, puede hacer posible que el usuario del BCI pueda controlar el sistema. Sin embargo, se debe de ampliar la muestra poblacional, y realizar una verificación de estos resultados. Es posible que integrando el SOM a un ensamble de clasificadores se puedan obtener mejores resultados, en comparación con utilizar un único clasificador para un BCI.

Los SOMs de dos clases para IMD vs. REP, e IMI vs. REP, tuvieron en general un desempeño mayor que los de IMD vs. IMI, lo cual refleja que existe una mayor diferencia entre la IM y un periodo de reposo con ojos abiertos. Esto era de esperarse tomando en cuenta que la zona dedicada al control de las dos manos se encuentra ubicada en la corteza motora central, y por tanto, existen similitudes entre las características espectrales de estas dos clases de IM. Los resultados obtenidos para los pacientes de EVC, son comparables con aquellos obtenidos utilizando esquemas de entrenamiento que involucran el doble de muestras y, con algoritmos que son computacionalmente más costosos que el procedimiento planteado en este trabajo, por lo que los SOMs son una alternativa prometedora para decodificar la IM y diseñar tecnologías de retro-alimentación a los pacientes que se someten a terapia basada en IM.

Agradecimientos

Roberto A. Vázquez agradece a la Universidad La Salle por el apoyo recibido bajo el Proyecto I-61/12 y NEC-03/15. Los autores agradecen al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo recibido por medio del proyecto SALUD-2015-2-262061. Los autores agradecen a los voluntarios que accedieron a participar en el trabajo.

Bibliografía

Cantillo-Negrete J.; Gutiérrez-Martínez J.; Flores-Reodriguez T.B.; Cariño-Escobar R.I.; Elías- Viñas D. (2014) Characterization of electrical brain activity related to hand motor imagery on healthy subjects. *Rev Invest Clin*, 66 (S1), 111-121.

Cantillo-Negrete J.; Gutiérrez-Martínez J.; Carino-Escobar R.I.; Paul Carrillo-Mora T.B.; Elías-Vinas D. (2014) Time-Frequency Analysis of EEG Signals from Healthy Subjects Allocated by Gender for a Subject-Independent BCI-Based on Motor Imagery. *BioMedical Engineering OnLine*, 13(158).

Carrilo-de-la-peña, M.T.; Galdo-Alvarez, S. y Lastra-Barreira, C.(2008). Equivalent is not equal: Primary motor cortex (MI) activation during motor imagery and execution of sequential movements, *Brain Research*, 1226, 134-143.

- Choi, D.; Ryu, Y.; Lee, Y.; Lee, M. (2011). Performance evaluation of a motor-imagery-based EEG-Brain computer interface using a combined cue with heterogeneous training data in BCI-Naïve subjects. *BioMedical Engineering OnLine*, 10(91), 1:12.
- Dijkerman H.C.; Wood V.A.; Langton-Hewer R. (1996). Long-term outcome after discharge from a stroke rehabilitation unit. *J R Coll Physicians Lond*, 30, 538-46.
- Duan, L.; Zhong, H.; Miao, J.; Yang, Z.; Ma, W.; Zhang, X. (2014). A Voting Optimized Strategy Based on ELM for Improving Classification of Motor Imagery BCI Data. *Cogn Comput*, 6, 477-483.
- Edlinger, G.; Allison, B.Z.; Guger, C. How Many People Can Use a BCI System?. *Clinical Systems Neuroscience*. Springer, Alemania. 33-66.
- Hjort, B. (1975). An on-line Transformation of EEG Scalp Potentials into Orthogonal Source Derivations. *Electroencephalography and Clinical Neurophysiology*, (39), 526-530.
- Hu, S.; Tian, Q.; Cao, Y.; Zhang, J.; Kong, W. (2013). Motor imagery classification based on joint regression model and spectral power. *Neural Comput & Applic*, 23(7), 1931-1936.
- Jeannerod M.; Frak V. (1999). Mental imaging of motor activity in humans. *Curr Opin Neurobiol*, 9(6), 735-739.
- Kraeutner, S.; Gionfriddo, A.; Bardouille, C. y Boe, S. (2014). Motor imagery-based brain activity parallels that of motor execution: Evidence from magnetic source imaging of cortical oscillations. *Brain Research*, 1588, 81-91.
- Kohonen, T. (2013). Essentials of the self-organizing map. *Neural Networks*, 37, 52- 65.
- Kohonen, T. (2001). *Self-Organizing Maps*, Berlin: Springer.
- Lemm, S.; Blankertz, B.; Curio, G.; Muller, K.R. (2005). Spatio-spectral filters for improving the classification of single trial EEG. *IEEE Trans. Biomed. Eng.*, 59(2), 1541-1548.
- Li, Yan.; Koike, Y. (2011). A real-time BCI with a small number of channels based on CSP. *Neural Comput & Applic*, 20, 1187-1192.
- Lu, Na.; Yin, Tao. (2015). Motor imagery classification via combinatory decomposition of ERP

- and ERSP using sparse nonnegative matrix factorization. *Journal of Neuroscience Methods*, 249, 41-49.
- Mo, H.; Zhao, Y. (2015). Motor Imagery Electroencephalograph Classification Based on Optimized Support Vector Machine by Magnetic Bacteria Optimization Algorithm. *Neural Process Lett.* DOI 10.1007/s11063-015-9469-7.
- Muller-Putz, G. R.; Scherer, R.; Brunner, C.; Leeb, R. y Pfurtscheller, G. (2008), Better than random? A closer look on BCI results. *International Journal of Bioelectromagnetism*, 10(1), 52–55, 2008.
- Nguyen, T.;Khosravi, A.; Creighton, D.; Nahavandi, S. (2015). Fuzzy System with tabu search learning for classification of motor imagery data. *Biomedical Signal Processing and Control*. 20, 61-70.
- Page S.J. (2000). Imagery improves upper extremity motor function in chronic stroke patients: a pilot study. *Occup Ther J Res*, 20, 200-215.
- Page S.J.; Levine P.; Sisto S.; Johnston M.V. (2001). A randomized efficacy and feasibility study of imagery in acute stroke. *Clin Rehabil*, 15(3), 233-240.
- Pfurtscheller, G.; Lopes da Silva, F.H. (1999). Event-related EEG/EMG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(11), 1842-1857.
- Pfurtscheller, G. y Neuper C. (2001). Motor imagery and direct brain-computer communication. *Proc. IEEE*, 89 (7), 1123-1134.
- Rodríguez-Bermúdez, G.; García-Laecina, P. (2012). Automatic and Adaptive Classification of Electroencephalographic Signals for Brain Computer Interfaces. *J Med Syst*, 36(1), 51-63.
- Rodriguez, M.; Llanos, C. y Sabate, M. (2009). The kinematics of motor imagery: Comparing the dynamics of real and virtual movements. *Neuropsychologia*, 47(2), 489-496.
- Song, X.; Yoon, S.K. (2015). Improving brain-computer interface classification using adaptive common spatial patterns. *Computers in Biology and Medicine*, 61, 150-160.
- Tallon-Baudry, C.; Bertrand, O.; Delpuech, C. y Pernier, J. (1997) Oscillatory gamma-band (30-70 Hz) activity induced by a visual search task in humans. *Journal of Neuroscience*, 17(2),722–734.

Vatanen et al. (2015). Self-organization and missing values in SOM and GTM. Retrieved February 10, 2015 from Research.ics.aalto.fi/software/somtoolbox.

Yi, W.; Qiu, S.; Qi, H.; Zhang, L.; Wan, B.; Ming, D. EEG feature comparison and classification of simple and compound limb motor imagery. *Journal of NeuroEngineering and Rehabilitation*, 10(106), 1-12.

Zhang, Y.; Zhou, G.; Jin, J.; Wang, X.; Cichocki, A. (2015). Optimizing spatial patterns with sparse filter bands for motor-imagery based brain-computer interface. *Computational Neuroscience*. 255, 85-91.