

Reconocimiento de patrones de actividad cerebral asociados a tareas mentales mediante RNA para una interfaz cerebro computador

Angel Villegas, Elvis Salvatierra, Alejandro Gubyk, Edgar Lugo, José Pacheco

*Centro de Procesamiento de Imágenes, Facultad de Ingeniería
Universidad de Carabobo, Valencia, Venezuela*

Email: {avillegas, ealugo, jpacheco}@uc.edu.ve, elvis.salvatierra@gmail.com, agubyk@hotmail.com

Resumen

El diseño de un clasificador para el reconocimiento de las tareas mentales es una parte muy importante en el desarrollo de una interfaz cerebro computador (ICC) basada en el reconocimiento de patrones, debido al hecho de que esta parte del sistema tiene que ser capaz de interpretar la tarea mental específica que el sujeto está en ejecución un determinado momento. Por este motivo, diversos enfoques se han utilizado al momento de buscar la mejor manera de clasificar los patrones de actividad cerebral asociados a las tareas mentales. Este artículo describe el uso de dos tipos de redes neuronales artificiales (perceptrón multicapa y base radial) para efectuar esta clasificación. La tasa de aciertos obtenidos en la clasificación, asciende en algunos casos a un 79.43%. Los resultados indican que al tratar de generalizar el clasificador para que trabaje con varios usuarios, se pierde la capacidad de generar una respuesta acertada, permitiendo concluir que al utilizar clasificadores adaptativos, entrenados y ajustados para cada usuario se logra obtener una tasa de clasificación acertada más elevada.

Palabras clave: clasificación de tareas mentales, interfaz cerebro computador (ICC), redes neuronales.

Recognition of brain activity patterns associated to mental tasks using ANNs for a brain computer interface

Abstract

The design of a classifier for mental tasks recognition is a very important part on the development of a brain computer interface (BCI) based on patterns recognition due to the fact that this part of the system must be capable of interpreting the specific mental task that the subject is executing in a certain moment. For this reason, various approaches have been used looking for the best way to classify the patterns of brain activity associated with mental tasks, this paper describes the use of two types of artificial neural networks (backpropagation and radial basis networks) for this purpose. In our experiments the rate of successes in classifications, in some cases achieves up to 79.43% of success. The results shows that when we trying to generalize the classifier to work with multiple users, the ability to generate a correct classification was poor, allowing to conclude that by using adaptive classifiers, trained and adjusted for each user it is possible to obtain a higher successful classification rate of mental tasks.

Keywords: mental tasks recognition, brain computer interface (BCI), neural networks.

1. INTRODUCCIÓN

En la implementación de una interfaz cerebro computador (ICC) existe una etapa llamada clasificación que consiste en la discriminación o identificación de patrones provenientes de la actividad cerebral realizada por el individuo en un momento determinado. Para obtener una mínima tasa de error en la interpretación de las tareas mentales, la clasificación de patrones

(asociados a la realización de tareas mentales) ha sido estudiada por diversos grupos de investigación que han utilizado diferentes métodos, como por ejemplo: Clasificadores Lineales [1], Clasificador Logístico Bayesiano [2-3] y clasificadores basados en redes neuronales [4-7]. Las experiencias obtenidas por estos grupos de investigación indican la factibilidad de utilizar redes neuronales artificiales para la clasificación de tareas mentales.

Ante esta situación, se implementó un prototipo de sistema de clasificación para tres tareas mentales a través de sus respectivos patrones de actividad registrados en el electroencefalograma (EEG), utilizando el “toolbox” de redes neuronales del ambiente Matlab.

2. METODOLOGÍA

2.1. Descripción de los datos

Para el desarrollo de este trabajo, se utilizaron datos adquiridos del evento “BCI Competition 2003” [8]. Proviene de tres individuos normales y fueron registrados durante cuatro sesiones sin suministrar ningún tipo de realimentación a los mismos. Los sujetos fueron sentados en una silla, con sus brazos y piernas relajadas mientras realizaban estas tres tareas:

- Imaginación del movimiento de la mano izquierda repetidamente. (Clase 2)
- Imaginación del movimiento de la mano derecha repetidamente. (Clase 3)
- Generación de palabras que comienzan con la misma letra al azar. (Clase 7)

Los datos usados se encontraban pre-procesados de la siguiente manera: Las señales de EEG crudas fueron filtradas espacialmente por medio de un filtro Laplaciano de Superficie [8]. Luego fue estimada la densidad de potencia espectral (PSD) en la banda de 8-30 Hz en intervalos de 62.5 ms utilizando para la estimación el último segundo de datos. Esta estimación se realizó con una resolución de 2 Hz y fue aplicada únicamente en 8 canales centro-parietales (C3,Cz,C4,CP1,CP2,P3,Pz y P4) del registro EEG [8].

Como resultado de esto, se obtiene un vector constituido de 96 elementos (8 canales cada uno con 12 componentes frecuenciales).

2.2. Formato de los Datos

Para cada sujeto se obtuvieron tres (3) archivos de entrenamiento y uno (1) de prueba. Los archivos de entrenamiento contienen la clase o tarea mental a la cual pertenece cada segmento de datos. Los archivos de datos se encontraban en formato ASCII.

2.3. Selección de los canales

Para el diseño del clasificador, se decidió reducir la cantidad de datos a los más representativos. Para ello se estudió la amplitud del espectro de las señales provenientes de los ocho canales utilizados. La Figura 1 muestra el comportamiento de una componente del espectro (10 Hz), registrada en los canales C3,C4 y CP1 para cada una de las tareas mentales realizadas por uno de los sujetos. El análisis visual de este comportamiento fue utilizado para descartar aquellos canales en los cuales no existía una diferencia apreciable en el patrón registrado al cambiar la tarea mental realizada por el sujeto. Por ejemplo, en la figura 1 se observa como al imaginar el movimiento de la mano izquierda repetidamente (Clase 2) se produce un aumento de la actividad registrada en el canal C3 junto con una disminución apreciable de la señal registrada por el electrodo C4.




Figura 1. Gráficas de ondas EEG en la banda de 10Hz de los canales C3, C4 y CP1. .

2.4 Selección de la red neuronal a utilizar

Se decidió implementar dos clasificadores diferentes para evaluar su desempeño en la clasificación de los patrones cerebrales. Estos están basados en una red neuronal del tipo Backpropagation (Retropropagación) y una red de Base Radial, respectivamente.

Una de las redes neuronales más utilizadas hoy en día es la red Backpropagation [9] (Figura 2), debido a que es una red que permite trabajar con sistemas no lineales y que además es una red de propagación-adaptación, lo que significa que una vez mostrado un estímulo a la entrada de la red, ésta compara la salida obtenida con la deseada, calcula el error y lo propaga a las capas anteriores para que las neuronas se adapten y

así reducir este error [10].

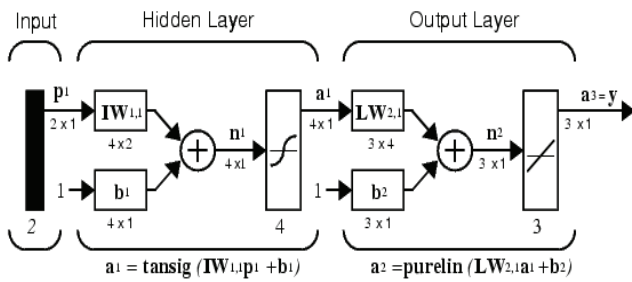


Figura 2. Esquema de una red Backpropagation. Tomado de [10].

Aparte de seleccionar la red Backpropagation por su importancia y ventajas que aporta, se decidió trabajar con otra red que proporcionara un punto de vista diferente y comparable con los resultados de la Backpropagation, por ello se utilizó la red de Base Radial cuya estructura genérica se muestra en la Figura 3.

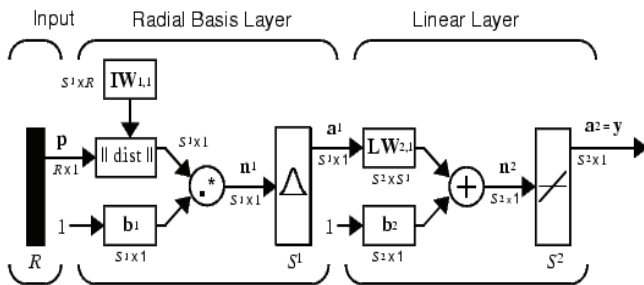


Figura 3. Esquema de una red de Base Radial. Tomado de [10].

2.5. Entrenamiento de la red neuronal

Una vez seleccionados los canales, se procedió a ordenar los datos de entrada para la red. El vector de características del clasificador está formado por 8 valores consecutivos por cada canal (8 valores de C3, C4 y CP1), formando un vector de 24 elementos correspondientes a medio segundo de señal. Para la construcción de los vectores de objetivos para la red neuronal, se seleccionó la clase o tarea mental predominante en el segmento de medio segundo de datos correspondiente.

Para lograr un entrenamiento exitoso de las redes neuronales se aleatorizaron los datos de manera que los vectores representativos de cada clase o tarea no fuesen presentados secuencialmente a la red neuro-

nal, para evitar el sobre ajuste a una determinada clase y pérdidas de la sensibilidad en la clasificación. Se utilizó la técnica de detección anticipada (*early stopping*) para lograr disminuir el efecto de sobreentrenamiento (*overfitting*) durante el entrenamiento de la red neuronal. Esta técnica se basa en la utilización de un sub-conjunto de los datos de entrada como datos de validación cruzada para determinar el punto donde la red neuronal puede generalizar de forma correcta [10].

En la Figura 4 se muestra una grafica del entrenamiento de la red Backpropagation, donde se alcanza el objetivo preestablecido.

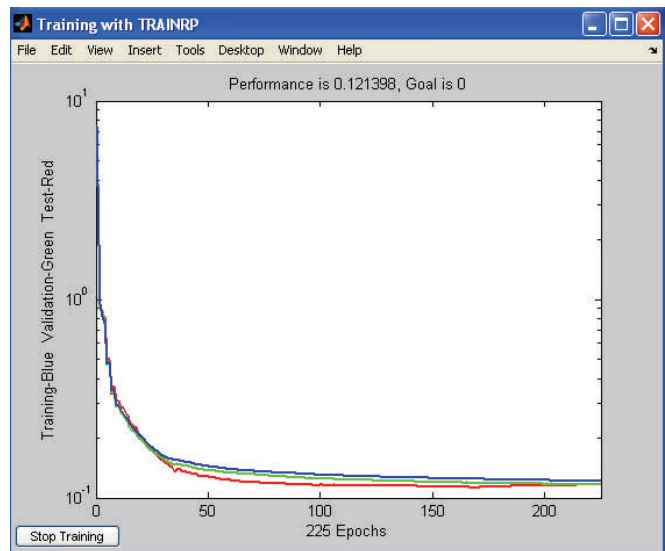


Figura 4. Gráfica de Entrenamiento

2.6. Simulación

Luego de creada y entrenada la respuesta de la red neuronal es evaluada con un patrón diferente al que se utilizó en el entrenamiento. Estos valores de salida de la red son comparados con una matriz de objetivos conocida, que contiene los valores reales con que la red no fue entrenada, para verificar el grado de aciertos de la red que en ese momento es estudiada.

Para facilitar la tarea de comparar la salida de la red con los valores reales, se generó una matriz de 3x3 conocida como matriz de confusión donde la diagonal principal es el porcentaje de aciertos de cada clase, y los demás valores corresponden al porcentaje de confusión entre una clase y otra.

3. RESULTADOS

En las tablas 1,2 y 3 se muestran los porcentajes de reconocimiento obtenidos para una red neuronal que fue entrenada con datos de los tres sujetos, en búsqueda de una red adaptativa del tipo Backpropagation que pudiera servir para múltiples usuarios.

Esta red posee dos capas, la primera contiene 34 neuronas con función tangencial sigmoidea (Tansig) y la segunda capa de tres neurona con función lineal (Purelin), el algoritmo de entrenamiento de esta red fue el llamado retropropagación resistente o "Trainrp".

Tabla 1. Respuesta de la red BP para el sujeto #1.

	Clase 7	Clase 3	Clase 2
Clase 7	81.11	11.72	19.23
Clase 3	16.67	78.91	13.85
Clase 2	2.22	9.38	66.92

Tabla 2. Respuesta de la red BP para el sujeto #2.

	Clase 7	Clase 3	Clase 2
Clase 7	81.11	11.72	19.23
Clase 3	16.67	78.91	13.85
Clase 2	2.22	9.38	66.92

Tabla 3. Respuesta de la red BP para el sujeto #3.

	Clase 7	Clase 3	Clase 2
Clase 7	4.29	6.16	11.44
Clase 3	47.86	64.38	59.33
Clase 2	7.86	29.45	26.67

Se observa que la tasa promedio de clasificación exitosa por cada sujeto es de 78.65%, 64.10% y 31.78%, respectivamente. De igual manera se obtuvo un promedio general de clasificación exitosa de 58,18%

Al repetir el experimento utilizando una red neuronal del tipo base radial, se obtuvieron los resultados presentados en las tablas 4,5 y 6.

Para este caso, la tasa promedio de clasificación exitosa por cada sujeto es de 68.96%, 56.20% y

Tabla 4. Respuesta de la red base radial para el sujeto #1.

	Clase 7	Clase 3	Clase 2
Clase 7	72.78	22.66	24.62
Clase 3	17.78	65.63	6.92
Clase 2	9.44	11.72	68.46

Tabla 5. Respuesta de la red base radial para el sujeto #2.

	Clase 7	Clase 3	Clase 2
Clase 7	54.95	30.56	17.59
Clase 3	10.99	47.92	16.67
Clase 2	34.07	21.53	65.74

Tabla 6. Respuesta de la red base radial para el sujeto #3.

	Clase 7	Clase 3	Clase 2
Clase 7	16.43	16.44	14.67
Clase 3	42.14	54.11	51.33
Clase 2	41.43	29.45	34

34.85%, respectivamente. De igual manera se obtuvo un promedio general de clasificación exitosa de 53,34%

En vista de estos resultados, se decidió repetir los experimentos pero entrenando a cada red para responder a los patrones de un sólo sujeto en particular. Se personalizó para cada usuario variando el número de neuronas. Los resultados obtenidos para la red neuronal de retro-propagación se muestran en las Tablas 7,8 y 9.

Tabla 7. Respuesta de la red BP para el sujeto #1.
Neuronas usadas = 54.

	Clase 7	Clase 3	Clase 2
Clase 7	83.33	11.72	9.23
Clase 3	11.67	72.66	8.46
Clase 2	5.00	15.62	82.31

Tabla 8. Respuesta de la red BP para el sujeto #2.
Neuronas usadas = 36.

	Clase 7	Clase 3	Clase 2
Clase 7	67.03	12.50	11.11
Clase 3	16.49	78.47	20.37
Clase 2	16.48	9.028	68.52

Tabla 9. Respuesta de la red BP para el sujeto #3.
Neuronas usadas = 24.

	Clase 7	Clase 3	Clase 2
Clase 7	35.71	23.97	37.33
Clase 3	35.71	49.32	32.00
Clase 2	28.58	26.71	30.67

La tasa promedio de clasificación exitosa por cada sujeto es de 79.43%, 71.34% y 38,57%, respectivamente. El promedio general de clasificación exitosa fue 63,11%.

4. CONCLUSIONES

A partir de los resultados obtenidos, se concluye que la información proveniente de los canales C3, C4 y CP1 en la banda de 10 Hz (ritmo Mu) es suficiente para construir un clasificador de las tareas mentales descritas en la base de datos experimental utilizada. Esta reducción ahorra tiempo de procesamiento y hardware en la construcción de un ICC, además aumenta la rapidez de respuesta de la red y su arquitectura disminuye.

Es importante hacer un estudio previo del EEG de cada individuo, ya que esto permitirá ahorrar tiempo en el diseño de la red neuronal y dará más posibilidad de que su aprendizaje en el proceso de entrenamiento, converja para un error cercano al establecido.

Se observa que utilizando la red neuronal Back-propagation se lograron mejores resultados de clasificación de las tareas mentales en comparación con la red de base Radial.

Observando los resultados obtenidos en el experimento donde se implementó una red para cada sujeto (Tablas 7, 8 y 9), podemos aseverar que los resultados presentan un menor porcentaje de error en el reconocimiento de las clases o tareas, comparado con los experimentos realizados usando una red neuronal general (Tablas de la 1-6). Por este motivo no es muy factible construir una red universal para un caso donde se necesiten resultados precisos y/o con poco error de acierto.

5. REFERENCIAS

[1] Babiloni F., et al. (2000): "Linear Classification of Low-Resolution EEG Patterns Produced by Imagined Hand Movements". *IEEE Transac-*

tions on Rehabilitation Engineering, Vol. 8, No. 2, pp. 186-188.

[2] Penny W.D. y Roberts S.J. (1999): "Experiments with an EGG-based computer interface". Technical report, Department of Electrical and Electronic Engineering, Imperial College.

[3] Penny W.D., et al. (2000): "EEG-based communication: a pattern recognition approach". *IEEE Transactions on Rehabilitation Engineering*. Vol 8, No 2, pp. 214 – 215.

[4] Anderson C.W et al. (1995): "Determining Mental state from EEG signals using parallel implementation of neuronal networks". *Scientific Programming*, Special Issue on Applications Analysis, Vol. 4, No. 3, pp. 171–183.

[5] Anderson C.W. (1997) Effects of variations in neural network topology and output averaging on the discrimination of mental tasks from spontaneous electroencephalogram. *Journal of Intelligent Systems*, Vol 7, No 1-2, pp. 165–190.

[6] Millan José del R., et al. (2000): "Local Neural Classifier for EEG-based Recognition of Mental Tasks". Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks IJCNN 2000, Vol. 3, pp. 632-636.

[7] Ortega P.A. (2005). "Diseño de mecanismos de procesamiento interactivos para el análisis de ondas cerebrales". Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Ciencias de la Computación, Trabajo Especial de Grado.

[8] "BCI Competition III" (2003) http://ida.first.fraunhofer.de/projects/bci/competition_iii

[9] Martín del Brio, B y Sanz A(2002): "Redes Neuronales y Sistemas Difusos". Editorial Alfaomaga, Segunda Edición.

[10] Mathwoks (2007): "Neural Network Toolbox 5.1". Disponible en línea : http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf