

Comando de un cursor en 2-D mediante señales EEG¹

Command of a 2-D cursor through EEG signals

L.C. Barrera, H. Loaiza y S.E. Nope

Recibido Noviembre 9 de 2013 – Aceptado Junio 6 de 2014

Resumen—Se presenta el diseño e implementación de una interfaz de control mediante señales EEG que permite el comando de los movimientos horizontales, verticales y clic de un cursor en 2-D. La interfaz permite la adquisición, filtrado, remoción de artefactos y extracción de características a partir de la transformada wavelet discreta. La búsqueda de características se centra en parámetros del dominio del tiempo (P300) y en el dominio de la frecuencia (Beta y Mu) dependiendo si se trata de un estímulo visual o de la imaginación de movimiento, respectivamente. Para la identificación, se usaron dos etapas de clasificación basadas en redes neuronales artificiales, a través de las cuales se obtuvo un desempeño global del 78.57% para el movimiento horizontal, 52.38% para el movimiento vertical y 100% para clic.

Palabras Clave— electroencefalografía (EEG), interfaz cerebro computador (ICC), redes neuronales artificiales, transformada wavelet.

Abstract—The design and implementation of a control interface by EEG signals which command allows horizontal, vertical movements of a cursor and clicking on 2-D is presented. The interface allows the acquisition, filtering, artifact removal and extraction of characteristics from the discrete wavelet transform. The search feature focuses on time domain

parameters (P300) and the frequency domain (Beta Mu) depending on whether it is a visual stimulus or imagination of movement, respectively. For identification, two stages of classification based on artificial neural networks are used, through which a 78.57% overall performance for horizontal movement, 52.38% for the vertical movement and click 100% was obtained.

Key Words—Electroencephalography (EEG), brain computer interface (BCI), artificial neural networks, wavelet transform.

I. INTRODUCCIÓN

EN 1920 el psiquiatra australiano Hans Berger empezó a estudiar el electroencefalograma humano, demostrando por primera vez, en 1929, que la actividad eléctrica del cerebro estaba relacionada con el estado mental del sujeto. Sus primeros estudios concluyeron que cuando un sujeto se encontraba en estado relajado, las señales eléctricas predominantes consistían en una onda de unos 10 Hz y con una amplitud de 50 microvoltios, a la cual llamó onda alfa. Por otro lado, cuando el sujeto estaba envuelto en alguna actividad mental, aparecía una onda de mayor frecuencia y menor amplitud que la alfa, a la cual llamó onda beta. Estos descubrimientos corresponden a los orígenes del principio básico de las interfaces cerebro-computador, conocidas como BCI (Brain Computer Interface).

Las BCI se basan en el análisis de las señales procedentes de la actividad eléctrica del cerebro, especialmente de las señales electroencefalográficas (EEG), las cuales pueden ser modificadas intencionadamente, con entrenamiento por el usuario.

De esta manera, la intención del desarrollo de interfaces cerebro computador es la captura de señales EEG a través

¹ Producto derivado del proyecto de Investigación “Comando de un Cursor en 2-D mediante señales EEG”, apoyado por la Escuela de Ingeniería Eléctrica y Electrónica, Universidad del Valle a través del Grupo de Investigación Percepción y Sistemas Inteligentes (PSI).

H. Loaiza y S.E. Nope son profesores de la Escuela de Ingeniería Eléctrica y Electrónica de la Universidad del Valle, Cali - Colombia (correos e.: humberto.loaiza@correounivalle.edu.co; sandra.nope@correounivalle.edu.co).

L.C. Barrera. trabaja en Movistar (correo e.: barreraupeg@hotmail.com)

de un dispositivo, las cuales se interpretan y se relacionan con una acción pretendida por el usuario. No obstante, esta acción puede abarcar diferentes objetivos, como el control de sillas de ruedas [9], [11], control de un cursor en una pantalla [4], [21], control de prótesis [13] y la mejora en la accesibilidad a personas discapacitadas [13], [23] entre otras. En los últimos años, el interés que han provocado los sistemas BCI ha ido creciendo de manera acelerada, aunque persisten algunos aspectos que merecen ser abordados en especial aquellos relacionados con el entrenamiento de las personas [15].

Una de las aplicaciones más importantes de las BCI está en el campo de la medicina, en particular en la rehabilitación: al contribuir en el establecimiento de un medio de comunicación y control para aquellos individuos con importantes deficiencias motoras. Este es el caso de personas afectadas por esclerosis lateral amiotrófica o ALS (Amyotrophic Lateral Sclerosis).

Por otro lado, las tecnologías BCI también permiten la rehabilitación de personas con desórdenes neurológicos como la epilepsia, parkinson, trastorno por déficit de atención (hiperactividad) y la comunicación con personas que padecen de parálisis cerebral.

Este documento está constituido por tres secciones: en la sección uno se presenta la descripción del sistema donde se exponen los protocolos utilizados para la presentación de estímulos tanto del movimiento horizontal como el vertical, las características utilizadas en el dominio temporal y frecuencial, también el sistema de clasificación con redes neuronales MLP y LVQ. La sección dos describe las pruebas y resultados para validar la interfaz y en la sección tres se presentan las conclusiones.

II. DESCRIPCIÓN DEL SISTEMA

El sistema inicia con la captura de las señales EEG resultantes de estimular visualmente al sujeto o ante la solicitud de imaginar que realiza un movimiento. Posteriormente se extraen un grupo de características que sintetiza la información más relevante para ser usada por el bloque de identificación del movimiento [4]. La arquitectura del sistema se ilustra en la Fig. 1.




Fig. 1. Diagrama del sistema

A. Bloque Registros EEG

Las señales EEG se obtuvieron mediante dos protocolos de estímulos diferentes presentados a los sujetos, estas son potenciales evocados, producidos por la visualización de imágenes o por la imaginación de movimientos, dependiendo si se trata de un movimiento horizontal o vertical.

En el protocolo 1 se captura la señal P300 que se genera durante la visualización de imágenes asociadas al movimiento vertical (arriba, abajo) y clic. El P300 es un potencial evocado cognitivo que aparece como un pico positivo en el registro de electroencefalografía alrededor de los 300 ms después de producido el estímulo. La presencia, magnitud y duración de esta señal se utiliza a veces en la medición de la función cognitiva de los procesos de toma de decisiones.

En el protocolo 2 se capturan ondas Mu y Beta resultantes de la imaginación de movimientos horizontales (derecha, izquierda).

Es importante que el ambiente donde se realicen los registros de las señales EEG sea tranquilo, para atenuar lo máximo posible el ruido externo y facilitar la concentración.

1) Protocolo 1

En la Fig. 2 se aprecian los símbolos utilizados en cada secuencia para movimientos verticales y clic. El primer símbolo es un cuadro con borde blanco que indica el inicio del ejercicio. El segundo símbolo es un cuadro con borde blanco con el símbolo de una suma en el centro, con el objeto de que el sujeto fije su mirada en ese signo. El tercer símbolo es una flecha apuntando hacia arriba e indica un movimiento en esa dirección. El cuarto símbolo es una flecha apuntando hacia abajo e indica un movimiento en esa dirección. El quinto símbolo es una mano apuntando a un objetivo circular que representa el clic.



Fig. 2. Símbolos presentados para movimiento vertical

Los símbolos fueron presentados durante 0.1 s a los sujetos en 9 secuencias en orden aleatorio, cada una de 9 símbolos, tal como se muestra en la Fig. 3.




Fig. 3. Secuencias de estímulos visuales para movimientos verticales
Para obtener el data set correspondiente, se grabaron las

señales EEG de 10 sujetos. Se llevaron a cabo tres sesiones de captura por sujeto: la primera para los potenciales P300 con flecha hacia arriba; la segunda sesión para la captura del P300 con flecha hacia abajo y la tercera sesión para la captura del clic. Los potenciales evocados se registraron a través de los canales F3, FC5, P7, O1, O2, P8, FC6 y F4 a una frecuencia de 128 Hz.

2) Protocolo 2

La interpretación de los símbolos usados para este protocolo es similar a la del protocolo 1, remplazando las flechas verticales por dos flechas horizontales que indican que el sujeto debe imaginar el movimiento en la dirección correspondiente.

Se realizaron 2 secuencias, una para el movimiento a la derecha y otra para el movimiento a la izquierda, cada una de 9 s de duración, tal como se muestra en la Fig. 4. De acuerdo a la indicación, el sujeto debe imaginar que realiza un movimiento del cursor con la mano correspondiente durante 6 s. El ejercicio se llevó a cabo, primero imaginando el movimiento con la mano derecha y posteriormente con la mano izquierda. En este caso, la actividad cerebral de los sujetos se registró en los canales FC5, FC6 a una frecuencia de muestreo de 128 Hz.




Fig. 4. Configuración en tiempo para la obtención de ondas β y μ .

B. Bloque extracción de características

La extracción de características constituye una de las fases más importantes del proceso de clasificación, ya que determina, directamente, tanto el rendimiento como la precisión del algoritmo de clasificación utilizado.

La interfaz pretende identificar autónomamente el movimiento del cursor a partir de estímulos visuales y la imaginación del movimiento, por lo que se integran las características que se extraen de todos los canales que intervienen en cada uno de los dos procesos mentales. A continuación, se describen las características utilizadas.

1) Características a partir de la imaginación de movimientos

Las características extraídas para la imaginación de movimientos corresponden a la energía y la potencia [3], [18] de los coeficientes de aproximación cA3, y de detalle cD2 y cD3 de la descomposición wavelet de 3 niveles. La energía y la potencia se calculan según (1).

$$P_x = \frac{1}{L} \sum_{i=1}^L |X_i|^2 \quad E_x = \sum_{i=1}^L |X_i|^2 \quad (1)$$

La elección de la transformada se apoyó en los resultados reportados por [1], [2], [3] y [18]. En este último utilizaron la wavelet madre "Daubechies10" que tiene similitud con la forma de la señal EEG.

La tabla 1 presenta la relación de los coeficientes wavelet y el rango de frecuencia. Puede verificarse que las ondas cerebrales μ (8-13 Hz) y β (18-25 Hz) corresponden con el rango de los coeficientes cD3 y cD2, respectivamente.

TABLA I. BANDAS GENERADAS POR LA DESCOMPOSICIÓN WAVELET

Descomposición	cD1	cD2	cD3	cA3
Rango de frecuencia (Hz)	32-64	16-32	8-16	0-8

En la tabla II se describe el vector de características para cada protocolo.

TABLA II. VECTOR DE CARACTERÍSTICAS

Movimiento Horizontal (derecha, izquierda)	
Canal	Método
FC5_EnergíaA3	Energía de los coeficientes DWT
FC5_EnergíaD2	
FC5_EnergíaD3	
FC6_EnergíaA3	
FC6_EnergíaD2	
FC6_EnergíaD3	
FC5_D2	Potencia, promedio y desviación estándar de los coeficientes DWT
FC5_D3	
FC6_D3	
Movimiento Vertical (Arriba, abajo, click)	
F3,FC5,P7,P8,FC6,F4	Energía de los coeficientes DWT
O1,O2	Vector cA3 de los coeficientes DWT
F3,FC5,P7,O1,O2,P8,FC6,F4	Valor Promedio y desviación estándar del potencial Evocado (P300)

2) Características a partir de estímulos visuales

Las características extraídas (P300) para los estímulos visuales se calcularon para los 8 canales: F3, FC5, P7, O1, O2, P8, FC6, F4 de acuerdo con (2).

$$P_{300} = \frac{1}{N} \sum_{i=1}^N X_i \quad (2)$$

Donde,

N = número de estímulos target durante toda la secuencia
X = la señal por canal con una ventana de 600 ms.

A esta señal (P300) se le aplicó la transformada wavelet discreta y se calculó la energía de los coeficientes de aproximación y detalle de acuerdo con (1). También se calculó el promedio y la desviación estándar del P300, según (3) y (4) respectivamente.

$$\bar{X}_{P300} = \frac{1}{N} \sum_{i=1}^N X_i \quad (3)$$

$$P_{300} = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{N}} \quad (4)$$

En la Fig. 5 se puede observar la onda P300 asociadas a los canales Fz, Cz y Pz, sobre las que se calcula el promedio.




Fig. 5. Promedios de los potenciales relacionados a eventos (ERP) de estímulos objetivo y no objetivo

C. Bloque de identificación del movimiento

Consta de dos etapas: la primera etapa se implementó con una red MLP para identificar las opciones de movimiento horizontal, vertical + clic y salida nula (no reconocido). La segunda etapa consta de dos redes especializadas LVQ que discriminan los sub-movimientos horizontales y verticales + clic. La arquitectura usada por el bloque de clasificación se ilustra en la Fig. 6.

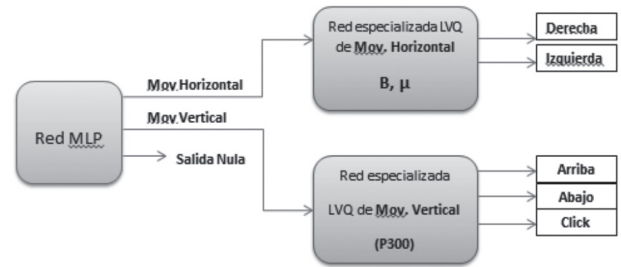


Fig. 6. Arquitectura del bloque de clasificación

Se utilizaron dos etapas de clasificación debido a que el vector de características de movimiento horizontal (18) es menor que el vector de características de movimiento vertical (650), por tal motivo se diseñó una red MLP con 18 características que pretende identificar entre movimientos horizontal y vertical + clic.

La tabla III muestra el vector de características de la red MLP, donde el tamaño es de [18x99] los 99 corresponden a los movimientos verticales (57) y horizontales (42); para la discriminación de los movimientos se utilizó los canales P7, P8 para movimiento vertical y FC5, FC6 para movimiento horizontal.

La red MLP tiene 2 capas, cuyas capas oculta y de salida usaron funciones de activación lineales con 10 y 2 neuronas respectivamente. El número de neuronas en la capa oculta se escogió con base en el desempeño de la red durante su entrenamiento en 300 épocas, incrementando las neuronas desde 5 hasta 50. De este estudio, se encontró que a partir de 10 neuronas el desempeño de la red se mantuvo casi constante.

TABLA III. VECTOR DE CARACTERÍSTICAS DE LA RED MLP

Canal	Características de Movimiento Vertical	Canal	Características de Movimiento Horizontal
P7	Px_up, Promed_up, Devst_up	FC5	Px_D2, Px_D3, Ea, Ed_D2, Ed_D3, Promed_D2, Promed_D3, Devst_D2, Devst_D3
P8	Px_up, Promed_up, Devst_up	FC6	Px_D2, Px_D3, Ea, Ed_D2, Ed_D3, Promed_D2, Promed_D3, Devst_D2, Devst_D3
P7	Px_down, Promed_down, Devst_down		
P8	Px_down, Promed_down, Devst_down		
P7	Px_clic, Promed_clic, Devst_clic		
P8	Px_clic, Promed_clic, Devst_clic		

La tabla IV muestra el vector de características de la red LVQ especializada para el movimiento horizontal, donde el tamaño es de $[18 \times 42]$, en donde el 42 corresponde a las direcciones derecha e izquierda 21 para cada subclase.

TABLA IV. VECTOR DE CARACTERÍSTICAS DE LA RED LVQ ESPECIALIZADA PARA EL MOVIMIENTO HORIZONTAL

Canal	Características usadas para el movimiento Horizontal
FC5	Px_D2, Px_D3, Ea, Ed_D2, Ed_D3, Promed_D2, Promed_D3, Devst_D2, Devst_D3
FC6	Px_D2, Px_D3, Ea, Ed_D2, Ed_D3, Promed_D2, Promed_D3, Devst_D2, Devst_D3

La tabla V describe el vector de características de la red LVQ de movimiento vertical, donde el tamaño es de $[650 \times 57]$ los 57 corresponden a las direcciones arriba, abajo y clic, 19 para cada subclase. En la tabla se puede apreciar que se utilizaron los 8 canales para poder obtener una mayor discriminación de las direcciones, obteniendo una red más robusta.

TABLA V. VECTOR DE CARACTERÍSTICAS DE LA RED LVQ ESPECIALIZADA PARA EL MOVIMIENTO VERTICAL

Canal	Características usadas para el Movimiento Vertical
F3	cA3, Ea, Ed_D2, Ed_D3, Promed, Devst
FC5	cA3, Ea, Ed_D2, Ed_D3, Promed, Devst
P7	cA3, Ea, Ed_D2, Ed_D3, Promed, Devst
O1	cA3, Promed, Devst
O2	cA3, Promed, Devst
P8	cA3, Ea, Ed_D2, Ed_D3, Promed, Devst
FC6	cA3, Ea, Ed_D2, Ed_D3, Promed, Devst
F4	cA3, Ea, Ed_D2, Ed_D3, Promed, Devst

La tabla VI describe las topologías de las redes neuronales LVQ especializadas.

TABLA VI. TOPOLOGÍAS E LAS REDES NEURONALES PARA LA IDENTIFICACIÓN

Características	Red Movimiento	
	Vertical	Horizontal
Entradas	650	18
Salidas	3	2
Capas ocultas	1	1
Neuronas en capas ocultas	17	10
Función de activación capas ocultas	competitiva	competitiva
Tasa de aprendizaje	0.01	0.01
Número de épocas	890	360
Performance	0.0702	0.125

III. PRUEBAS Y RESULTADOS

El sistema se entrenó con 134 registros de 10 sujetos (7 para entrenamiento y 3 para validación), de los cuales 99 (73.9%) se usó para entrenamiento y 35 (26.1%) para validación, tal como se muestra en la tabla VII.

TABLA VII. DISTRIBUCIÓN DE REGISTROS DE ENTRENAMIENTO Y VALIDACIÓN

Movimiento	Registros de Entrenamiento	Registros de Validación	Total
Derecha	21	7	28
Izquierda	21	7	28
Arriba	19	7	26
Abajo	19	7	26
Clic	19	7	26
Total	99	35	134

A. Red MLP

La tabla VIII presenta la matriz de confusión para la clasificación inicial entre movimientos verticales y horizontales, donde puede verificarse que se obtiene una clasificación perfecta para el movimiento horizontal, mientras que el 12,28% de las veces el movimiento vertical fue confundido con el movimiento horizontal. Lo anterior puede ser el resultado de utilizar el mismo número de características de entrada que el usado por el movimiento horizontal.

TABLA VIII . MATRIZ DE CONFUSIÓN RED MLP

		Movimiento Identificado	
		Horizontal	Vertical
Movimiento real	Horizontal	100 %	0 %
	Vertical	12.28%	87.72 %

La tabla IX muestra el porcentaje de éxito por clase en la validación para la red de entrada MLP.

TABLA IX. PORCENTAJE DE ÉXITO POR CLASE EN VALIDACIÓN

Validación			
Clase	Éxito (%)	Ejemplos	Error (%)
Horizontal	85.72	14	14.28
Vertical	95.24	21	4.76
Total	91.43	35	8.57

B. Resultados y análisis de movimiento vertical + clic

La tabla X presenta la matriz de confusión para la clasificación realizada por la red neuronal LVQ especializada para los movimientos verticales + clic. La sub-clase “Clic” logra una clasificación perfecta, mientras que la sub-clase con mayor error corresponde a la sub-clase “Abajo” que fue clasificada erróneamente como “arriba” en un 15.79% de los 19 casos, y como “Clic” en un 10.53%.

Es importante mencionar que los estímulos visuales para los movimientos sólo difieren en la dirección de la flecha. Esto significa que es muy probable que estos resultados puedan mejorarse al usar símbolos con características diferenciadoras, como el color.

TABLA X. MATRIZ DE CONFUSIÓN RED ESPECIALIZADA DE MOVIMIENTO VERTICAL + CLIC

		Movimiento identificado		
		Arriba	Abajo	Clic
Movimiento real	Arriba	94.74%	0 %	5.26%
	Abajo	15.79%	73.68%	10.53%
	clic	0	0	100%

La tabla XI presenta el porcentaje de éxito para la red de movimiento vertical + clic con 3 sujetos de prueba. Se puede apreciar que los mejores desempeños corresponde a la orden “clic” con un 71.43% de éxito, seguido por la sub-clase arriba con 57.14%. El desempeño general de la red fue de **52.38%**, los errores para las clases se deben a la acumulación del error desde la etapa de clasificación de la red de entrada.

TABLA XI. PORCENTAJE DE ÉXITO POR CLASE EN VALIDACIÓN

Validación			
Clase	Éxito (%)	ejemplos	Error (%)
Arriba	57.14	7	42.86
Abajo	28.57	7	71.43
Clic	71.43	7	28.57
Total	52.38	21	47.62

C. Resultados y análisis de movimiento horizontal

La tabla XII presenta la matriz de confusión para la clasificación de los movimientos horizontales. La sub-clase derecha logra un desempeño del **71.43%** al igual que la sub-clase izquierda.

TABLA XII. MATRIZ DE CONFUSIÓN RED NEURONAL ESPECIALIZADA MOVIMIENTO HORIZONTAL

		Movimiento identificado	
		Derecha	Izquierda
Movimiento real	Derecha	71.43	28.57
	Izquierda	28.57	71.43

La tabla XIII presenta el porcentaje de éxito por clase en la fase de validación de la red de movimiento horizontal. La tabla muestra que para los 7 ejemplos de validación de la sub-clase derecha pudo clasificar 6 de manera correcta y 1 de manera incorrecta obteniendo un porcentaje de éxito de **85.72 %**. Para los 7 ejemplos de la sub-clase izquierda el sistema pudo clasificar 5 de manera correcta y 2 de manera incorrecta obteniendo un porcentaje de éxito de **71.43 %**. El desempeño general de la red en la fase de validación fue de **78.57%**. Los errores obtenidos están relacionados con el hecho que la solicitud de “imaginar un movimiento” es poco intuitiva para un sujeto.

TABLA XIII. PORCENTAJE DE ÉXITO POR CLASE EN VALIDACIÓN

Validación			
Clase	Éxito (%)	Ejemplos	Error (%)
Derecha	85.72	7	14.28
Izquierda	71.43	7	28.57
Total	78.57	14	21.43

Con las pruebas realizadas se obtuvieron resultados muy relevantes en comparación con los antecedentes [1], [12]. En [1] lograron un desempeño del 53% y 61% para movimiento vertical y horizontal respectivamente con 5 sub-clases. En [12] alcanzaron un desempeño de 72% y 45% para 2 y 4 sub-clases, respectivamente. En el presente trabajo realizado para 5 sub-clases, se logró un desempeño de **52.38%** y **78.57%** para el movimiento vertical y horizontal respectivamente. El menor porcentaje de acierto se obtuvo para el movimiento hacia abajo con un valor de 73.68% con los datos de entrenamiento; esto puede ser debido al tipo de características escogidas, el color y la forma del estímulo, como también al clasificador seleccionado.

D. Cuadro comparativo

La tabla XIV consigna un comparativo de diferentes trabajos que han abordado el movimiento de un cursor mediante señales EEG. En el trabajo desarrollado el porcentaje de éxito de **52.38%** y **78.57%** se obtiene utilizando el emotiv EPOC el cual solo posee 14 electrodos mientras que en [21] el porcentaje de éxito de **91.25%** se obtiene utilizando un gorro de un centro médico el cual posee 64 electrodos donde en él se puede localizar la zona central del cerebro (C3, C4) frontal (Fz) y parietal (Pz) del sistema internacional 10-20 donde en estas áreas hay mayor información de la distinción del movimiento horizontal y vertical. En la Tabla 14 se resalta que las máquinas de soporte vectorial (SVM) presentan una mejoría en desempeño que los resultados reportados con redes neuronales.

TABLA XIV. CUADRO COMPARATIVO

Trabajos realizados	Electrodos	Tipo de clasificador	Momentos a clasificar	Porcentaje Aciertos
Jorge Andrés Zaccaro Javier Hernán Cárdenas Laura Marcela Salazar	2 (C3,C4)	LDA,SVM, MLP	2	85.71%,85.71%, 83.21%
paulo Andrés Vélez ángel Haeders Saldarriaga Villafañe	6 (O1,O2,F3,F4, C3,C4)	LVQ	5	53% y 61%
Avid Román G	2 (C3,C4)	LDA y redes neuronales	2	87.14% y 84.29%
Yuanqing Li,Jinyi Long, Tianyou Yu,Zhuliang Yu, Chuanchu Wang, Cuntai Guan, Senior Member, IEEE	(4) Pz,CPz,C3,F C4	SVM	5	91.25%
Rasmussen Robert, Soumyadipta A, Nitish Thakor	(3) C3,Cz,C4	Filtros IIR para frecuencias	2	72%
Rasmussen Robert, Soumyadipta A, Nitish Thakor	(3) C3,Cz,C4	Filtros IIR para frecuencias	4	45%
Luis Carlos Barrera Humberto Loaiza Sandra Nope	8 (F3,FC5,P7, O1,O2,P8,FC 6,F4)	LVQ	5	52.38% Mov. V 78.57% Mov. H

IV. CONCLUSIONES

- La interfaz BCI desarrollada permitió comandar el movimiento del cursor en una pantalla mediante la información extraída de señales EEG y el reconocimiento de cinco sub-clases, logrando un porcentaje de acierto de 78.57% para el movimiento horizontal y de 52.38% para el movimiento vertical.
- Se constató que las señales en la imaginación de movimientos corresponden a los canales FC5 y FC6, para el pre-procesamiento, se logró encontrar que la wavelet daubechies10 permite implementar un filtrado adecuado de las señales.
- Las características extraídas de la descomposición a través de la transformada Wavelet con la wavelet madre Daubechies 10, facilitaron el reconocimiento de la intensidad de cinco sub-clases para comandar el movimiento de un cursor, requiriéndose sólo tres niveles de descomposición.
- La relación directa entre los coeficientes de descomposición wavelets y las frecuencias de las ondas cerebrales Beta y Mu, potenció la detección de la intensidad de movimiento, mejorando significativamente el desempeño de la red neuronal.
- Fue posible obtener señales más limpias mediante el Análisis de Componentes Independientes (ICA), que permitió la detección de artefactos y su posterior remoción.

- Debido a la utilización de dos tipos de estímulos diferentes para generar los potenciales evocados que permitieron extraer características diferentes, se utilizaron redes LVQ especializadas por el potencial que resulta de combinar los modelos de aprendizaje supervisado y no supervisado; con la ventaja adicional de requerir pocos registros de entrenamiento para lograr una buena generalización. El uso de redes especializadas con entradas diferentes requirió de una primera etapa MLP para diferenciar entre las clases horizontal y vertical + clic, pero se incurre en el costo de la propagación del error en las siguientes etapas de clasificación.
- El entrenamiento para manejar una interfaz BCI requiere de un esfuerzo considerable por parte del sujeto. La concentración, frustración, cansancio, distracción, motivación, son algunos de los factores que pueden afectar la capacidad del sujeto para controlar sus señales EEG, los cuales merecen ser tenidos en cuenta a la hora de establecer un protocolo de entrenamiento que garantice un aprendizaje eficaz.

REFERENCIAS

- [1] A. P. Ángel Vélez, H. Villafañe Saldarriaga, “Clasificación Básica de Neuroseñales”, Universidad Tecnológica de Pereira, Facultad de Ciencias Básicas, 2010.
- [2] H. F. Arias García, L. S. Alzate, B. J. Padilla Bejarano, “Detección y Clasificación de Artefactos en Señales EEG”, XIV Simposio de tratamiento de señales, imágenes y visión artificial-STSIVA 2009.
- [3] D. Ballesteros, H. Pardo, “Software de Análisis de Energía en Señales Electroencefalográficas basado en la transformada wavelet discreta”, Fundación Universitaria Manuela Beltrán, Bogotá, Colombia 2005.
- [4] L. C. Barrera Upegui, “Comando de un cursor en 2-D mediante señales EEG”, Escuela de Ingeniería Eléctrica y Electrónica, Cali, Colombia, 2013.
- [5] C. Chia-Jung, “Time-Frequency Analysis for Biomedical Engineering”. National Taiwan University.
- [6] T. Fernsler, D. Arnaud, H. Serby and M. Scott. EEGLAB tutorial, University of San Diego California.
- [7] R. A. González, “Sistema de comunicación y control basado en el pensamiento”, Universidad Paul Verlaine de Metz.
- [8] J. L. Martín, S. Palazuelos, L. Boquete, “Estudio comparativo de dos técnicas de procesamiento de señales EEG para la discriminación de estados mentales”, Dpto de Electrónica, Universidad de Alcalá, Madrid-España.
- [9] J. Z. Mínguez, “interfaces cerebro-computador no invasivos y robótica para sustitución motora”. Universidad de Zaragoza, España.
- [10] J. Mínguez, “Tecnología de Interfaz Cerebro-Computador”, Grupo de Robótica, Percepción y Tiempo real, Universidad de Zaragoza, España.
- [11] S. Guevara Mosquera, “Adquisición de señales EEG para el movimiento de un prototipo de silla de ruedas en un sistema BCI”, Universidad Politécnica Salesiana, sede Cuenca.
- [12] R. Rasmussen, A. Soumyadipita, T. Nitish, “Accuracy of Brain-Computer Interface in Subjects with Minimal Training”, Department of Biomedical Engineering, Johns Hopkins University.
- [13] S. Reinhold, C. Neuper, G. Pfurtscheller, “Rehabilitation with Brain-Computer Interface Systems”, Graz University of Technology.
- [14] N. L. Rodríguez, Teoría y Aplicación de la Informática II, Universidad Católica “Nuestra Señora de la Asunción”, Asunción-Paraguay 2009.
- [15] R. A. Ron, “Retroatimentación de una interfaz cerebro computador usando técnicas basadas en realidad virtual”, Universidad de Málaga.
- [16] B. Medina Salgado, D. L. Muñoz, H. Fandiño Toro, “Characterization of EEG signals using wavelet transform for motor imagination tasks in BCI systems”, Instituto Tecnológico Metropolitano, Medellín, Colombia.
- [17] K. Sharman, A. Esparcia, Grupo de Sistemas Adaptativos Complejos @ ITI. Interfaz Cerebro-Computadora.
- [18] J. A. Valverde Zaccaro, H. Díaz Cárdenas, M. L. Cruz Salazar, “Clasificación de Señales cerebrales relacionadas con la imaginación de movimientos para aplicaciones BCI”, Pontificia Universidad Javeriana, Departamento de Electrónica, Bogotá DC, 2011.
- [19] J. D. Vargas Hernández, “Implementación de una interfaz BCI utilizando el procesamiento de señales P300 y la adquisición de señales con electrodos activos en EEG”, Escuela de ingeniería eléctrica, universidad de costa rica, Julio del 2012.
- [20] J. R. Wolpaw, D. J. McFarland, “Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans”, Proceedings of the National Academy of Sciences, December 21, 2004 vol. 101.
- [21] L. Yuanqing, J. Long, T. Yu, Z. Yu, “An EEG-Based BCI System for 2-D Cursor Control by Combining Mu-Beta Rhythm and P300 Potential”, IEEE transactions on biomedical engineering, Vol.57. No.10. 2010.
- [22] <http://www.beta-lab.nl/content/software>
- [23] R. Hornero, R. Corralejo, D. Álvarez, “Brain -Computer Interface (BCI) aplicado al entrenamiento cognitivo y control doméstico para prevenir los efectos del envejecimiento”, Grupo de Ingeniería Biomédica (GIB), Universidad de Valladolid. Disponible: http://www.fgcsic.es/lychnos/es_ES/articulos/Brain-Computer-Interface-aplicado-al-entrenamiento-cognitivo.



Luis C. Barrera recibió el título de B. S. en Ingeniería Electrónica de la Universidad del Valle, Cali, Colombia, en el año 2013. Actualmente, es empleado de Movistar en el área de Operaciones.



Humberto. L. Correa es Ingeniero Electricista de la Universidad del Valle, tiene un Master en Automática de la Universidad del Valle y Doctorado en Robótica de la Universidad de Evry, Francia. Actualmente, es profesor titular, Escuela Ingeniería Eléctrica y Electrónica de la Universidad del Valle. Sus principales intereses de investigación se encuentran en Robótica Móvil, Procesamiento de Señales e Imágenes, Visión Artificial y Reconocimiento de Patronos.



Sandra E. Nope Rodríguez es Ingeniera en Electrónica y Telecomunicaciones de la Universidad del Cauca, tiene una Especialización en Gerencia de Proyectos de la Universidad del Cauca y Doctorado en Ingeniería de la Universidad del Valle. Actualmente, es profesora asociada, Escuela Ingeniería Eléctrica y Electrónica de la Universidad del Valle. Sus principales intereses de investigación se encuentran en Inteligencia Computacional, Robótica y Procesamiento de Imágenes.