

Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI

Extraction techniques of EEG signals characteristics in motion imagination for BCI systems

Boris MEDINA [1](#); Javier E. SIERRA [2](#); Alexis Barrios ULLOA [3](#)

Recibido: 29/01/2018 • Aprobado: 20/02/2018

Contenido

[1. Introducción](#)

[2. Técnicas de extracción](#)

[3. Resultados](#)

[4. Conclusiones](#)

[Referencias bibliográficas](#)

RESUMEN:

Los registros multicanal de las señales electroencefalográficas corrientemente generan una gran cantidad de datos. Los métodos de extracción de características pueden facilitar la representación e interpretación de estos datos para la posterior clasificación de los patrones de interés. Un gran número de técnicas se han empleado para la extracción de características EEG en tareas orientadas a la imaginación de movimiento que, aunque no han evidenciado estadísticamente resultados diferenciables, se pueden esperar en efecto diferentes grados de éxito por la elección de los algoritmos adecuados. Por ello, la utilización en conjunto de un buen método de extracción y clasificación puede influir considerablemente en los resultados de clasificación de los patrones de interés. El presente artículo propone las técnicas que actualmente se emplean para la extracción de características de señales de electroencefalografía (EEG) orientadas a la implementación de sistemas de interfaz cerebro computador, con énfasis en la imaginación del movimiento.

Palabras clave: Señales electroencefalográficas, EEG, imaginación de movimiento, reconocimiento de patrones

ABSTRACT:

Multichannel registers of electroencephalographic signals usually generate a large amount of data, and feature extraction methods can facilitate the representation and interpretation of these data for the subsequent classification of patterns of interest. Many EEG extraction techniques in the imagination of the movement have been used, achieving different classification accuracies, therefore, the appropriate selection of the extraction method can increase the performance in pattern recognition. This article proposes the best techniques that should be used for the extraction of characteristics of electroencephalography signals (EEG) for computer brain interface systems, with emphasis on the imagination of movement.

Keywords: Electroencephalographic signals, EEG, movement imagination, pattern recognition

1. Introducción

Los sistemas BCI (Brain Computer Interface – Interfaz cerebro computador) son aquellos que monitorizan la actividad cerebral y traducen determinadas características, correspondientes a las intenciones o sentimientos del usuario, en comandos de control hacia un dispositivo. Entre las diversas técnicas para registrar la actividad cerebral, el electroencefalograma (EEG) es una práctica no invasiva, de bajo costo, portátil y sencilla de usar. No obstante, dada la modesta velocidad y precisión de un BCI basado en EEG, se hace necesario el uso tanto de sistemas multicanal como de métodos adecuados de procesamiento de señal. El procesamiento de la señal EEG se divide en varias etapas: pre-procesamiento,

extracción de características, selección y clasificación de las mismas.

Los métodos de extracción sustraen determinadas características de la señal EEG que pueden ser útiles para discriminar entre las diferentes tareas mentales. Después, mediante el empleo de métodos de selección se escoge el subgrupo de características más relevantes y que proporcionarán una clasificación más eficiente.

Numerosas técnicas de extracción de características se han propuesto y aplicado a señales EEG para la imaginación motora en sistemas BCI, tales como: el análisis en el dominio del tiempo y frecuencia, filtros adaptados, potencia espectral, Patrones Espaciales Comunes (CSP), Transformada Rápida de Fourier (FFT), Modelos Autorregresivos (AR), Transformada Discreta de Wavelet (DWT), Transformada Discreta Wavelet Packet (DWPT), Entropía, Transformada de Hilbert, Redes Neuronales y difusas, y combinaciones entre ellas. Estas técnicas se pueden dividir en tres grupos principales, que son: 1) los métodos que sustraen información temporal de la señal, 2) métodos que extraen información frecuencial, y 3) métodos híbridos, basados en representaciones tiempo-frecuencia, que aprovechan tanto la información temporal y frecuencial (Lotte, 2008). Una cuarta categoría se podría haber añadido, la categoría de los métodos que aprovechan la información espacial para realizar un filtrado espacial antes de la extracción de características basadas en la información temporal y/o frecuencial (Lotte, 2008).

El presente documento muestra los métodos empleados en la extracción de características de señales EEG para la imaginación motora en sistemas BCI.

2. Técnicas de extracción

2.1. Técnicas en el dominio del tiempo

Estadística Instantánea

Los métodos temporales usan como características las variaciones temporales de las señales; estos son adaptados particularmente para describir las señales neurofisiológicas con un compás de tiempo preciso y específico. Diversas técnicas estadísticas permiten caracterizar la señal EEG, entre las cuales se encuentran el valor absoluto medio, longitud de onda, cambios en la pendiente de la señal, la integral cuadrada simple, La amplitud de Willison, Kurtosis (Khorshidtalab, Salami, & Hamedi, 2012). Otras técnicas estadísticas como cruce por cero, Varianza, Desviación Estándar, coeficiente de correlación y parámetros de Hjorth son empleadas para extraer características relevantes en la señal de EEG, con el objeto de alcanzar menos complejidad computacional (Diwaker, Gupta, & Gupta, 2016; Kousarrizi, Ghanbari, Teshnehlal, Shorehdeli, & Gharaviri, 2009; Xu, Song, & Wu, 2007).

El valor absoluto medio: estima el promedio del valor absoluto de la señal en el dominio del tiempo mediante la ecuación (1), donde N denota la longitud o número de muestras.

$$MAV = \frac{1}{N} \sum_{j=1}^N |x_j| \quad (1)$$

La longitud de onda: especifica la longitud acumulativa de la forma de la señal en un segmento particular, dado por la ecuación (2), donde Δx_j denota la diferencia de las muestras consecutivas.

$$WL = \sum_{j=1}^N |\Delta x_j| \quad (2)$$

Los cambios en la pendiente de la señal: identifican el número de veces que la pendiente de la señal cambia de signo y reduce el ruido inducido. Para las muestras dadas x_j , x_{j+1} y x_{j-1} , el signo de la pendiente cambia si la ecuación (3) y (4) se satisfacen, donde ϵ es el umbral incluido para eliminar el efecto del ruido inducido.

$$\{x_j < x_{j+1} \text{ y } x_j < x_{j-1}\} \text{ ó } \{x_j > x_{j+1} \text{ y } x_j > x_{j-1}\} \quad (3)$$

$$|x_j - x_{j+1}| \geq \epsilon \text{ y } |x_j - x_{j-1}| \geq \epsilon \quad (4)$$

La integral cuadrada simple: calcula la energía de la señal EEG acorde a la ecuación (5).

$$SSI_k = \sum_{i=0}^N (|x_i|^2) \quad (5)$$

La amplitud de Willison: calcula el número de veces que el valor absoluto de la diferencia entre la amplitud de la señal EEG de dos muestras consecutivas excede un determinado valor de umbral; el valor de la amplitud de Willison se calcula mediante la ecuación (6).

$$WAMP_k = \sum_{i=1}^{N-1} f(|x_i - x_{i+1}|) \quad (6)$$

$$f(x) = \begin{cases} 1, & x > \epsilon \\ 0, & \text{otro caso} \end{cases}$$

Los Parámetros de Hjorth (Hjorth, 1970): desarrolla las características mostradas en (7) para una serie de tiempo dada por $x(t)$ y un tamaño de muestra T .

$$\text{Actividad: } A_x = \frac{\sum_{t=1}^T (x(t) - \mu)^2}{T}$$

$$\text{Movilidad: } M_x = \sqrt{\frac{\text{var}(\dot{x}(t))}{\text{var}(x(t))}} \quad (7)$$

$$\text{Complejidad: } C_x = \frac{\dot{M}(x(t))}{M(x(t))}$$

$\dot{x}(t)$ representa la derivada de la serie de tiempo $x(t)$. El primer parámetro denominado Actividad, representa la medida de la energía promedio de la señal (varianza), el segundo parámetro conocido como Movilidad, es una estimación de la frecuencia media y el tercer parámetro conocido como Complejidad determina el ancho de banda de la señal. Estos parámetros han sido ampliamente empleados en la caracterización EEG (Gaur, Pachori, Hui Wang, & Prasad, 2015; Turk, Seker, Akpolat, & Ozerdem, 2017).

Modelos Autorregresivos (AR)

Los modelos autorregresivos (AR) son una pieza básica en el análisis de series temporales (de Lautour & Omenzetter, 2010). Estos modelos tienen en cuenta la correlación de las observaciones actuales

frente a sus antecesoras. Se utilizan los coeficientes del modelo como características en la discriminación de los patrones de pensamiento.

El modelo AR de orden p es descrito por la ecuación (8), donde a_i son los parámetros AR, x_i son los valores observados de la muestra, r_k es un término de error que representa un ruido blanco de media cero.

$$x_k = a_1 x_{k-1} + a_2 x_{k-2} + \dots + a_p x_{k-p} + r_k \quad (8)$$

De esta forma, los coeficientes son estimados a partir de la muestra actual y de un número finito de muestras anteriores, empleando algoritmos tales como el método de Burg, covarianza modificada y filtros de Kalman (Corralejo, Hornero, & Alvarez, 2011; Roy, Sikdar, Mahadevappa, & Kumar, 2017; Xu et al., 2007).

Los modelos autorregresivos han sido utilizados con éxito por muchos investigadores para el análisis de señales EEG en el contexto BCI (Corralejo et al., 2011; Krusienski, McFarland, & Wolpaw, 2006; Roy et al., 2017), y posee ventajas respecto a FFT en su resolución de frecuencia y buenas estimaciones espectrales a partir de segmentos cortos de la señal EEG (Krusienski et al., 2006). Sin embargo, no existen directrices claras sobre cómo elegir los parámetros de la estimación espectral; además, es importante determinar el orden óptimo del modelo AR ya que un orden de modelo demasiado bajo tiende a suavizar el espectro, y muy alto tiende a introducir picos espurios (Xu et al., 2007).

Los modelos autorregresivos adaptativos (AAR) y modelos autorregresivos Multivariantes (MVAR), son técnicas más recientes, en los cuales sus parámetros a_i cambian con el tiempo para adaptarse a la variación del espectro de EEG (Ahmad & Aqil, 2015; Bhattacharyya, Konar, & Tibarewala, 2017). Así mismo, estudios recientes sobre BCI basados en imágenes motoras (IM) reportan que la interacción variable en el tiempo (TV) de las áreas del cerebro separadas espacialmente en formas de conectividad funcional o efectiva conduce a una mejor comprensión de los patrones dinámicos neuronales cerebrales durante el IM y puede proporcionar características útiles para BCI (Billinger, Brunner, & Müller-Putz, 2013). Se han propuesto varios métodos para evaluar las interacciones de señales de TV EEG, la influencia causal de una región neuronal ejerciendo sobre las otras, que implican la direccionalidad del flujo de información (IF). Uno de los enfoques más prometedores es la TV multivariante autorregresiva (TV-MVAR) de modelado donde los coeficientes AR varían con el tiempo (Hamedi, Salleh, Ting, Samdin, & Mohd Noor, 2015).

2.2. Técnicas en dominio de la frecuencia

Transformada Rápida de Fourier (FFT)

La Transformada Rápida de Fourier (FFT) se utiliza para indagar la distribución de la amplitud de espectro en EEG y extraer el pico del espectro para reflejar las diferentes tareas del cerebro (Zhang, Yang, & Huang, 2008). Mediante el uso de la FFT, la señal de EEG puede mapearse desde el dominio del tiempo al dominio de la frecuencia. El espectro de frecuencia de la señal es reconocido por descomponer la señal en su correspondiente sinusoidal de diferentes frecuencias.

La FFT está dada por la ecuación (9), para una señal discreta x_n , donde k es cada valor discreto de la señal:

$$X(k) = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i}{N}nk} \quad \text{con } k = 0, 1, \dots, N-1 \quad (9)$$

En aplicaciones BCI, Huang (S. Huang & Wu, 2010) adopta la transformada de Fourier (TF) para la extracción de características en la clasificación de tareas motoras, resaltando que aunque FT juega un papel importante en el análisis de señales estacionarias, posee limitaciones en el análisis de espectro de una señal no estacionaria.

La FFT puede ser calculada de forma relativamente rápida o alrededor de un tiempo real. Sin embargo, la FFT tiene sus desventajas: las frecuencias utilizadas para descomponer una señal son una función de la frecuencia de muestreo de la señal y del número de frecuencias deseadas. Sin modificar estos dos parámetros, estas frecuencias no son seleccionables; una onda sinusoidal simple cuya frecuencia no cae en una de las frecuencias de la transformada producirá un espectro con dispersión de energía para muchas frecuencias.

La Transformada de Fourier de tiempo reducido (STFT)

Las funciones de Fourier no son adecuadas para representar señales no estacionarias cuyo contenido espectral varía con el tiempo. Para tener una representación de la señal no estacionaria, la STFT segmenta la señal en intervalos definidos a través del tiempo, de tal forma que se pueda asumir que la señal es estacionaria para cada segmento, y por cada porción de la señal aplicar la transformada de

Fourier. La división de la señal se realiza mediante una función ventana de tiempo $w(t)$ cuyo ancho representa la longitud del segmento.

La STFT está dada por la ecuación (10), donde $x[n]$ es la señal EEG, $w[n]$ es la ventana, y m es el índice de tiempo discreto que usualmente no se expresa con tan alta resolución como con el tiempo n .

$$STFT\{x[n]\} = X(m, w) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-jwn} \quad (10)$$

Obsérvese que los segmentos más largos pueden violar la suposición de cuasi estacionariedad requerida por la transformada de Fourier, por lo tanto, se deben tener en cuenta las resoluciones de tiempo y frecuencia además de la estacionariedad de la señal antes del análisis (Motamedi-Fakhr, Moshrefi-Torbati, Hill, Hill, & White, 2014). La STFT ha sido ampliamente utilizada en el análisis del EEG del sueño debido principalmente a su simplicidad y facilidad de implementación.

Potencia Espectral

La Densidad de Potencia Espectral (PSD - Power Spectral Density) de características, a veces llamado simplemente espectro, informa sobre la distribución de la potencia de una señal entre sus diferentes frecuencias. Las características PSD pueden ser calculadas, por ejemplo, elevando al cuadrado la transformada de Fourier de una señal (Lalor et al., 2005), o mediante el cálculo de la transformada de Fourier de la función de autocorrelación de la señal (Keirn & Aunon, 1990). Las características PSD son probablemente las características más utilizadas para BCI, y han demostrado ser eficaces para el reconocimiento de un gran número de señales neurofisiológicas.

Aplicaciones de PSD en sistemas BCI la encontramos en (Huaiyu Xu, Jian Lou, Ruidan Su, & Erpeng Zhang, 2009), donde combinan PSD con los coeficientes wavelet de la señal EEG para caracterizar una señal EEG, encontrando promedios de precisión hasta 82% en su clasificación; y Palaniappan (Palaniappan, n.d.) que calcula PSD usando la energía del filtro FIR (Finite Impulse response) elíptico para obtener precisiones de clasificación hasta el 97.5%, usando un clasificador de red neuronal.

2.3. Técnicas tiempo-frecuencia

Transformada Wavelet

De manera similar a la transformada de Fourier, la transformada wavelet de una función $f(t)$ descompone una señal en forma de funciones $\psi_{s,\tau}(t)$ (Samar, Bopardikar, Rao, & Swartz, 1999), que forman una función base y son denominadas "Wavelets". La Transformada Wavelet se define mediante la ecuación (11):

$$W_f(s, \tau) = \int f(t) \psi_{s,\tau}(t) dt \quad (11)$$

Esta base de las funciones es un conjunto de wavelets en escala y trasladadas de una función wavelet conocida como la wavelet madre, definida en la ecuación (12), donde s es el factor de escala, y τ es el factor de traslación.

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (12)$$

Las wavelets hacen posible el análisis de la señal en diferentes escalas simultáneamente. Además, la resolución depende de la escala: frecuencias altas, pueden ser analizadas con una alta resolución temporal, mientras que las bajas frecuencias, que corresponden a una escala gruesa, puede ser analizadas con una resolución frecuencial alta. Estos puntos hacen de las wavelets una herramienta muy interesante para el análisis de señales de EEG (Samar et al., 1999).

Múltiples autores han aplicado análisis wavelet para caracterizar señales EEG para la imaginación motora en sistemas BCI (Ming-Ai, Rui, Dong-Mei, & Jin-Fu, 2009; Zou, Wang, Shi, & Ma, 2010), cuyos resultados de clasificación, eligiendo una wavelet madre específica y un nivel de descomposición adecuado, mejoran respecto a otras técnicas como AAR, descomposición en subespacios espaciales comunes (CSSD) y entropía aproximada (ApEn).

Investigaciones han señalado que la wavelet madre Daubechies es una base adecuada para el análisis de datos de EEG respecto a otras wavelet madre para clasificar características orientadas a la imaginación motora (Adeli, Zhou, & Dadmehr, 2003).

Una generalización de la transformada wavelet es la Wavelet Packet, cuya diferencia radica en la descomposición de la señal: en el primer nivel, la señal se descompone en coeficientes de aproximación y de detalle igual que en wavelets, pero la descomposición de los niveles adicionales se hace tanto en los componentes de aproximación como en los de detalle (Riju, Sreevidya, & Smitha, 2015). Resultados en EEG (Qiao, Wang, Li, & Lifeng Tian, 2010) han demostrado que el método propuesto con precisión podría extraer características sustanciales EEG y proporcionar un medio eficaz para clasificar las tareas mentales motoras.

La Transformada Wavelet puede proporcionar una descomposición de las señales en tiempo-frecuencia multi-nivel. Esto permite el uso simultáneo de intervalos largos de tiempo para la información de baja frecuencia e intervalos cortos de tiempo para información de alta frecuencia (Ting, Guo-zheng, Bang-hua, & Hong, 2008). Uno de los inconvenientes de La transformada wavelet es el incremento de los requisitos de memoria debido a su algoritmo basado en la convolución de filtros. La adecuada selección de una wavelet madre y el número de niveles de descomposición son muy importantes en el análisis de señales de EEG para encontrar niveles de clasificación promisorios (Hu, Li, & Chen, 2011).

Transformada de Hilbert-Huang

La transformada de Hilbert-Huang (HHT), propuesta por Huang (N. E. Huang et al., 1998) es un método para el análisis de señales no estacionarias y no lineales. El análisis mediante HHT es adaptativo y no requiere ninguna función a priori y puede ser dividido en dos partes: descomposición por modos empíricos (EMD) y aplicación de la transformada Hilbert.

EMD es un algoritmo de procesamiento de señal utilizado para la descomposición adaptativa y multiescalar de datos en series de tiempo no lineales y no estacionarios. Un conjunto de datos puede ser descompuesto en un número finito de monocomponentes conocidos como IMF (funciones de modo intrínsecas). Los IMF representan una simple función armónica oscilatoria. Los IMF que son modulados en amplitud, fase y frecuencia se utilizan como las bases de la descomposición. Esta descomposición es intuitiva y adaptativa, es decir, la descomposición depende de la señal. Esta descomposición no requiere condiciones sobre linealidad y estacionariedad de la señal. El principio de esta técnica es descomponer iterativamente la señal no lineal complicada $x(t)$ en un conjunto de funciones limitadas de banda conocidas como IMF. Cada IMF satisface dos condiciones básicas: (i) el número de extremos y el número de cruces por cero en el conjunto de datos completo debe ser el mismo o diferir como máximo en uno, (ii) en cualquier punto, el valor medio del sobre definido por los máximos locales y la envolvente definida por los mínimos locales es cero (Li, Zheng, & Li, 2011). La sumatoria de todas las IMF producto de la descomposición más el residuo de la función, forman la señal original $x(t)$.

En el análisis EMD, la primera IMF tiene el contenido más alto de frecuencia. Este contenido de frecuencia disminuye con el aumento en el componente IMF hasta que el componente n -IMF, que es casi una función lineal del tiempo. En comparación con la descomposición Wavelet y FFT, los componentes del IMF tienen contenidos de más baja frecuencia, son útiles para analizar oscilaciones de baja frecuencia, y se pueden emplear en el análisis espectral de Hilbert para obtener frecuencia instantánea.

El espectro de Hilbert-Huang es capaz de reflejar la distribución de la energía de la señal en un número de escalas con precisión. La transformada Hilbert de una función $s(t)$ está dada mediante la ecuación (13):

$$s(t) = \frac{1}{\pi} \int \frac{s(\tau)}{t - \tau} d\tau \quad (13)$$

HHT se ha empleado para extraer las características de diferentes datos de EEG basados en imaginación motora, teniendo en cuenta que HHT posee la capacidad de analizar señales no lineales y no estacionarias para representarlas en el dominio tiempo-frecuencia. Wang (Wang, Xu, Wang, Yang, & Yan, 2011) y Liu (Liu, Cheng, & Huang, 2011) demuestran que en comparación con métodos tradicionales de extracción de características en el dominio de la frecuencia, HHT consigue una mayor precisión de clasificación utilizando el mismo conjunto de datos.

HHT ofrece mayores ventajas respecto a Wavelet o FFT, en el sentido de proporcionar estimaciones más precisas por la adaptabilidad en las resoluciones de tiempo y frecuencia, y puede la banda de frecuencia adaptada en función de la señal envolvente. Probablemente "el mayor reto que afronta la HHT y más específicamente la EMD, es el estar definida por un algoritmo iterativo y carecer de una formulación matemática formal. Al estar definida por un algoritmo iterativo, los resultados finales van a depender de la forma en la cual el algoritmo fue implementado y la definición de las variables y estructuras de control. El método es especialmente sensible cuando la señal está contaminada por ruido. En general, la HHT es una técnica que todavía está en desarrollo y que ha tenido un gran auge en los últimos años" (Ramírez-Castro & Montejo, 2011).

2.3. Técnicas espaciales

Patrones Espaciales Comunes (CSP – Common Spatial Patterns)

CSP, introducido a BCI por Ramoser (Ramoser, Muller-Gerking, & Pfurtscheller, 2000) es una poderosa técnica capaz de computar filtros espaciales que maximizan la relación de la varianza de los datos condicionados en una clase a la varianza de los datos condicionados a la otra clase, cuando se proporcionan datos de dos diferentes clases. CSP se aplica aproximadamente a señales filtradas pasa banda con el fin de obtener la discriminación eficaz de los estados mentales caracterizados por efectos ERD/ERS en señales EEG (Tae-Eui Kam & Seong-Whan Lee, 2011; Xinyang Li et al., 2011).

Han sido numerosos los aportes de CSP introducidos a la caracterización de señales EEG orientadas a las discriminaciones de patrones de imaginación motora. Aquí, CSP se centra en la proyección de las señales originales de altas dimensiones a varios filtros espaciales diseñados. La covarianza de las señales filtradas CSP se maximiza en una condición mientras que se reduce al mínimo en la otra condición (Hammon & de Sa, 2007).

CSP produce una descomposición supervisada de los datos de la señal parametrizada por una matriz $W \in RC \times C$ (siendo C el número de canales) que proyecta la señal $x(t) \in RC$ en el espacio original a $x_{CSP}(t) \in RC$, que vive en el espacio sustituto, como lo expresa la ecuación (14):

$$x_{CSP}(t) = W^T x(t) \quad (14)$$

Una limitación fundamental de CSP es que sólo puede manejar dos clases. No existe ningún método canónico para calcular los patrones CSP relevantes para la clasificación multiclase. Esto es porque la diagonalización simultánea, sobre la cual se basa CSP, puede llevarse a cabo sólo por dos matrices (Dornhege, Blankertz, Curio, & Muller, 2004).

El algoritmo CSP proyecta señales de EEG para las direcciones más discriminativas encontradas después de la diagonalización simultánea de las matrices de covarianza desde las diferentes categorías de la señal (Blankertz et al., 2004). Sin embargo, como el algoritmo CSP considera sólo los patrones espacialmente discriminativos, no tiene en cuenta las características espectrales y temporales de las señales de EEG, y el rendimiento del filtro depende altamente de la banda de frecuencia operativa (Novi, Guan, Huy Dat, & Xue, n.d.). Por lo tanto, se han propuesto patrones espaciales comunes con banco de filtros (FBCSP) (Kai Keng Ang, Zhang Yang Chin, Haihong Zhang, & Cuntai Guan, 2008) y CSP temporal local (Haixian Wang & Wenming Zheng, 2008) para resolver la limitación que descuida la información temporal en señales de EEG. Sin embargo, estos métodos, suponen que los patrones espaciales de las señales de EEG no cambian durante la imaginación motora debido a los filtros espaciales fijos en el dominio del tiempo (Tae-Eui Kam & Seong-Whan Lee, 2011).

Kam (Tae-Eui Kam & Seong-Whan Lee, 2011) propone CSP dependiente del tiempo (TDCSP) que optimizan los filtros CSP en varios rangos de tiempo locales de señales de EEG individualmente basados en análisis estadísticos para reflejar de forma efectiva los cambios de la distribución espacial discriminativa en el tiempo, cuyos resultados demuestran un alto rendimiento superando los métodos comunes.

El algoritmo de extracción de características de CSP tradicional trata de encontrar un filtro espacial calculado en base a una matriz de proyección, sin embargo, la proyección de la matriz esta siempre sin cambios dentro o en sesiones cruzadas, y el registro de estas señales EEG variaran con el tiempo (Chen, Song, Zhang, Hu, & Xu, 2010). Chen (Chen et al., 2010) y Sun (Sun & Zhang, 2006) proponen un método para resolver el problema de aprendizaje adaptativo en la clasificación de la señal EEG mediante extracción de características actualizadas. El método se realiza a través de patrones comunes espaciales adaptativo (ACSP) para adaptarse al cambio de EEG. Los resultados arrojan una ligera mejor eficiencia y capacidad de adaptación del algoritmo ACSP que el CSP tradicional.

2.4. Técnicas no lineales

Entropía

La entropía, basada en la teoría de la información de Shannon es un índice de medida de la complejidad de un sistema incierto. La entropía de Shannon da criterio útil para analizar y comparar la distribución de probabilidad, que proporciona una medida de la información de cualquier distribución (Zhao, Liu, Li, & Wang, 2010). La entropía de la información del sistema se puede expresar como en la ecuación (15), donde p_i es la correspondiente probabilidad de cada uno de los i -estados:

$$H = - \sum_{i=1}^n p_i \ln(p_i) \quad (15)$$

La entropía es un método estadístico para cuantificar la imprevisibilidad de las variaciones en las señales tanto deterministas y estocásticas (Wang et al., 2012), por lo tanto muchos investigadores han llevado este método hacia el análisis y discriminación de señales EEG. A partir de este concepto, se emplea la entropía en el espectro de potencia como una medida de la incertidumbre del tiempo en el dominio de frecuencia; el método es simple y rápido y proporciona ser prometedor para el sistema on-line de BCI. Así mismo, se utiliza el concepto de entropía de la energía para caracterizar la complejidad de la señal con los cambios en el tiempo, y también muchas de las características en el dominio frecuencial (Xiao, Mu, & Hu, 2009). La entropía de Kolmogorov (Gao, Wang, Zhang, Xu, & Zheng, 2011), cuantifica los cambios dinámicos de los eventos relacionados EEG. El concepto de entropía aplicada a los coeficientes wavelet se usa como una medida del grado de orden/desorden de la señal, lo que puede proporcionar información útil sobre el proceso subyacente dinámico asociado con la señal (Zhao et al., 2010).

De acuerdo con el hecho de que el EEG es una señal no estacionaria y no lineal, se aplican métodos dinámicos no lineales como el denominado Entropía Muestral (SampEn) (Wang et al., 2012) y el concepto de Entropía Aproximada (ApEn) para extraer características EEG (Wang, Xu, Wang, Yang, & Yan, 2007); sin embargo en ambos métodos, es necesario definir primeramente los parámetros de longitud del vector y su tolerancia, que pueden influir drásticamente el valor de la medida de la entropía.

Exponentes de Lyapunov

Los exponentes de Lyapunov pueden estimarse a partir de las series de tiempo EEG observadas. Son medidas cuantitativas para distinguir entre los diversos tipos de órbitas basándose en su dependencia sensible de las condiciones iniciales y se utilizan para determinar la estabilidad de cualquier comportamiento en estado estacionario, incluidas las soluciones caóticas (Muthanatha Murugavel, Ramakrishnan, Balasamy, & Gopalakrishnan, 2011). Los exponentes de Lyapunov cuantifican el grado caótico de un atractor en el espacio de estados de las EEG, midiendo la tasa promedio de expansión y plegado que ocurre a lo largo de las direcciones propias locales dentro de un atractor en el espacio de estados (Kang, Lee, & Kim, 2016). Generalmente, los exponentes de Lyapunov pueden extraerse de las señales observadas de dos maneras diferentes: la primera se basa en la idea de seguir la evolución temporal de puntos cercanos en el espacio de estado. Este método proporciona una estimación del mayor exponente de Lyapunov y significa que la velocidad de expansión es mayor que la velocidad de plegado. El segundo método se basa en la estimación de matrices locales de Jacobi y es capaz de estimar todos los exponentes de Lyapunov. Los cálculos mostraron que hay exponentes positivos de Lyapunov en EEG y confirman la naturaleza caótica de estas señales de EEG, así mismo, por el uso de estas características se puede obtener una buena distinción entre clases. Sin embargo, se deben hacer mayores esfuerzos para encontrar los parámetros óptimos para calcular los exponentes de Lyapunov y mejorar su desempeño (Kang et al., 2016; Muthanatha Murugavel et al., 2011; Übeyli, 2010).

3. Resultados

Es evidente que, a partir de las diferentes técnicas y combinaciones entre ellas, aplicadas por sus autores, los estudios benefician la extracción de información alrededor de los ritmos de importancia clínica μ y β . Sus resultados prometen ser alentadores para tenerlos en cuenta en trabajos futuros para la implementación de interfaces online de sistemas BCI. Sin embargo, los resultados de precisión entre las distintas técnicas, aunque se tienen diferentes rendimientos, no han evidenciado estadísticamente resultados diferenciados y se pueden esperar en efecto diferentes grados de éxito por la elección de los algoritmos adecuados para la extracción de las características. Por ello, la utilización en conjunto de un buen método de extracción y clasificación puede influir considerablemente en los resultados de clasificación de los patrones de pensamiento de interés. La tabla 1 muestra las ventajas y las limitantes de cada uno de los métodos indicados.

Ventajas y limitación de los métodos usados en la extracción de características de señales EEG orientadas a tareas de imaginación motora.

Método		Ventajas	Limitaciones
Dominio del tiempo	AR	posee ventajas respecto a FFT en su resolución de frecuencia y mejores estimaciones espectrales a partir de segmentos cortos de la señal EEG (Krusienski et al., 2006).	No existen directrices claras sobre cómo elegir los parámetros de la estimación espectral; además, es importante determinar el orden óptimo del modelo AR ya que un orden de modelo demasiado bajo tiende a suavizar el espectro, y muy alto tiende a introducir picos espurios (Xu et al., 2007).
Dominio de la frecuencia	FFT	La señal de EEG puede mapearse desde el dominio del tiempo al dominio de la frecuencia, para indagar la distribución de la amplitud de espectro y reflejar las diferentes tareas del cerebro (Zhang et al., 2008).	Las funciones de Fourier no son adecuadas para representar señales no estacionarias cuyo contenido espectral varía con el tiempo. Las frecuencias utilizadas para descomponer una señal son una función de la frecuencia de muestreo de la señal y del número de frecuencias deseadas. Sufre de gran sensibilidad al ruido.
	SFFT	Simplicidad y facilidad de implementación. La STFT segmenta la señal en intervalos definidos a través del tiempo, de tal forma que se pueda asumir que la señal es estacionaria para cada segmento.	Los segmentos más largos pueden violar la suposición de cuasi estacionariedad requerida por la transformada de Fourier.
	PSD	PSD informa sobre la distribución de la energía de la señal entre sus diferentes frecuencias.	Técnica limitada para presentar información adicional en la escala de tiempo, teniendo en cuenta que las señales EEG poseen características no estacionarias y de no linealidad.
Tiempo-frecuencia	Wavelet	Especial para el tratamiento de señales no estacionarias. Puede proporcionar una descomposición de las señales en tiempo-frecuencia multi-nivel. Esto permite el uso simultáneo de intervalos largos de tiempo para la información de baja frecuencia e intervalos cortos de tiempo para información de alta frecuencia.	La adecuada selección de una wavelet madre y el número de niveles de descomposición son muy importantes en el análisis de señales de EEG para encontrar niveles de clasificación promisorios (Hu et al., 2011).
	HHT	No requiere condiciones sobre linealidad y estacionariedad de la señal Permite la descomposición adaptativa y multiescalar de la señal. No requiere ninguna función a priori para su descomposición.	Se define mediante un algoritmo iterativo y carece de una formulación matemática formal, cuyos resultados finales van a depender de la forma en la cual el algoritmo fue implementado y la definición de las variables y estructuras de control.
Técnicas espaciales	CSP	Tiene la capacidad de proyectar señales EEG procedentes de varios canales en un subespacio donde se destacan las diferencias entre las clases y se minimizan las similitudes. El método alternativo TDCSP optimiza los filtros CSP y refleja de forma efectiva los	Requiere no solo el entrenamiento de las muestras sino también la información de la clase a la que pertenecen las muestras para calcular la matriz de transformación lineal (entrenamiento supervisado). Requiere el uso de muchos electrodos.

		cambios de la distribución espacial discriminativa en el tiempo.	
Técnicas no lineales	Entropía	Robusto en el análisis de segmentos de datos cortos, resistente a los valores atípicos y fuertes transitorios, es capaz de lidiar con el ruido mediante la estimación adecuada de sus parámetros y se puede aplicar a señales estocásticas y determinísticamente caóticas. Presenta diversas alternativas que permiten caracterizar la complejidad de la señal con los cambios en el tiempo y cuantificar los cambios dinámicos de los eventos relacionados con la señal EEG.	No existen directrices claras sobre cómo elegir los parámetros m (longitud del vector de la serie) y r (tolerancia similar) antes de calcular la entropía aproximada o muestral; estos parámetros afectarán la entropía de cada registro de datos EEG durante diferentes tareas mentales, y por consiguiente, la precisión de clasificación en última instancia también se verá afectada.
	Coeficientes de Lyapunov	Aprovecha el comportamiento caótico de una señal EEG para realizar tareas de clasificación que combinados con otras características lineales o no lineales permiten obtener mejores resultados.	Se deben hacer mayores esfuerzos para encontrar los parámetros óptimos para calcular los exponentes de Lyapunov y mejorar su desempeño.

4. Conclusiones

Las señales de EEG se pueden utilizar eficazmente para estudiar la actividad cerebral en personas y detectar estados mentales o dolencias sin intervención quirúrgica. Teniendo en cuenta que las señales de EEG son de naturaleza altamente no lineal y sus interpretaciones pueden ser propensas a variaciones entre observaciones, investigadores han recurrido a distintas técnicas para su análisis tales como los métodos estadísticos, de frecuencia, tiempo-frecuencia y no lineales. En este artículo, exponemos las técnicas más representativas para extraer características de interés en las EEG, que permitan el reconocimiento de la actividad neuronal relacionada a la intención del paciente en la imaginación de movimientos, especialmente de la mano derecha e izquierda. Se presentan los hallazgos de las diversas técnicas automatizadas para la extracción de componentes que caracterizan la actividad de imaginación de movimiento que utilizan EEG como la señal base.

Referencias bibliográficas

- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, *123*(1), 69–87. [https://doi.org/10.1016/S0165-0270\(02\)00340-0](https://doi.org/10.1016/S0165-0270(02)00340-0)
- Ahmad, M., & Aqil, M. (2015). Implementation of nonlinear classifiers for adaptive autoregressive EEG features classification. In *2015 Symposium on Recent Advances in Electrical Engineering (RAEE)* (pp. 1–5). IEEE. <https://doi.org/10.1109/RAEE.2015.7352749>
- Bhattacharyya, S., Konar, A., & Tibarewala, D. N. (2017). Motor imagery and error related potential induced position control of a robotic arm. *IEEE/CAA Journal of Automatica Sinica*, *4*(4), 639–650. <https://doi.org/10.1109/JAS.2017.7510616>
- Billinger, M., Brunner, C., & Müller-Putz, G. R. (2013). Single-trial connectivity estimation for classification of motor imagery data. *Journal of Neural Engineering*, *10*(4), 46006. <https://doi.org/10.1088/1741-2560/10/4/046006>
- Blankertz, B., Müller, K.-R., Curio, G., Vaughan, T. M., Schalk, G., Wolpaw, J. R., ... Birbaumer, N. (2004). The BCI Competition 2003: Progress and Perspectives in Detection and Discrimination of EEG Single Trials. *IEEE Transactions on Biomedical Engineering*, *51*(6), 1044–1051. <https://doi.org/10.1109/TBME.2004.826692>
- Chen, C., Song, W., Zhang, J., Hu, Z., & Xu, H. (2010). An Adaptive Feature Extraction Method for Motor-Imagery BCI Systems. In *2010 International Conference on Computational Intelligence and Security* (pp. 275–279). IEEE. <https://doi.org/10.1109/CIS.2010.66>
- Corralejo, R., Hornero, R., & Alvarez, D. (2011). Feature selection using a genetic algorithm in a motor imagery-based Brain Computer Interface. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (Vol. 2011, pp. 7703–7706). IEEE. <https://doi.org/10.1109/IEMBS.2011.6091898>
- de Lautour, O. R., & Omenzetter, P. (2010). Damage classification and estimation in experimental

- structures using time series analysis and pattern recognition. *Mechanical Systems and Signal Processing*, 24(5), 1556–1569. <https://doi.org/10.1016/J.YMSSP.2009.12.008>
- Diwaker, S., Gupta, S. K., & Gupta, N. (2016). Classification of EEG Signal using Correlation Coefficient among Channels as Features Extraction Method. *Indian Journal of Science and Technology*, 9(32). <https://doi.org/10.17485/ijst/2016/v9i32/100742>
- Dornhege, G., Blankertz, B., Curio, G., & Muller, K.-R. (2004). Boosting Bit Rates in Noninvasive EEG Single-Trial Classifications by Feature Combination and Multiclass Paradigms. *IEEE Transactions on Biomedical Engineering*, 51(6), 993–1002. <https://doi.org/10.1109/TBME.2004.827088>
- Gao, L., Wang, J., Zhang, H., Xu, J., & Zheng, Y. (2011). Feature extraction and classification of Event-related EEG based on Kolmogorov entropy. In *2011 4th International Congress on Image and Signal Processing* (pp. 2650–2653). IEEE. <https://doi.org/10.1109/CISP.2011.6100663>
- Gaur, P., Pachori, R. B., Hui Wang, & Prasad, G. (2015). An empirical mode decomposition based filtering method for classification of motor-imagery EEG signals for enhancing brain-computer interface. In *2015 International Joint Conference on Neural Networks (IJCNN)* (pp. 1–7). IEEE. <https://doi.org/10.1109/IJCNN.2015.7280754>
- Haixian Wang, & Wenming Zheng. (2008). Local Temporal Common Spatial Patterns for Robust Single-Trial EEG Classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 16(2), 131–139. <https://doi.org/10.1109/TNSRE.2007.914468>
- Hamedi, M., Salleh, S.-H., Ting, C.-M., Samdin, S. B., & Mohd Noor, A. (2015). Sensor space time-varying information flow analysis of multiclass motor imagery through Kalman Smoother and EM algorithm. In *2015 International Conference on BioSignal Analysis, Processing and Systems (ICBAPS)* (pp. 118–122). IEEE. <https://doi.org/10.1109/ICBAPS.2015.7292230>
- Hammon, P. S., & de Sa, V. R. (2007). Preprocessing and Meta-Classification for Brain-Computer Interfaces. *IEEE Transactions on Biomedical Engineering*, 54(3), 518–525. <https://doi.org/10.1109/TBME.2006.888833>
- Hu, D., Li, W., & Chen, X. (2011). Feature extraction of motor imagery EEG signals based on wavelet packet decomposition. In *The 2011 IEEE/ICME International Conference on Complex Medical Engineering* (pp. 694–697). IEEE. <https://doi.org/10.1109/ICCME.2011.5876829>
- Huaiyu Xu, Jian Lou, Ruidan Su, & Erpeng Zhang. (2009). Feature extraction and classification of EEG for imaging left-right hands movement. In *2009 2nd IEEE International Conference on Computer Science and Information Technology* (pp. 56–59). IEEE. <https://doi.org/10.1109/ICCSIT.2009.5234611>
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995. <https://doi.org/10.1098/rspa.1998.0193>
- Huang, S., & Wu, X. (2010). Feature extraction and classification of EEG for imagery movement based on mu/beta rhythms. In *2010 3rd International Conference on Biomedical Engineering and Informatics* (pp. 891–894). IEEE. <https://doi.org/10.1109/BMEI.2010.5639888>
- Kai Keng Ang, Zhang Yang Chin, Haihong Zhang, & Cuntai Guan. (2008). Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. In *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)* (pp. 2390–2397). IEEE. <https://doi.org/10.1109/IJCNN.2008.4634130>
- Kang, J.-H., Lee, C. H., & Kim, S.-P. (2016). EEG feature selection and the use of Lyapunov exponents for EEG-based biometrics. In *2016 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)* (pp. 228–231). IEEE. <https://doi.org/10.1109/BHI.2016.7455876>
- Keirn, Z. A., & Aunon, J. I. (1990). Man-machine communications through brain-wave processing. *IEEE Engineering in Medicine and Biology Magazine*, 9(1), 55–57. <https://doi.org/10.1109/51.62907>
- Khorshidtalab, A., Salami, M. J. E., & Hamedi, M. (2012). Evaluation of time-domain features for motor imagery movements using FCM and SVM. In *2012 Ninth International Conference on Computer Science and Software Engineering (JCSSE)* (pp. 17–22). IEEE. <https://doi.org/10.1109/JCSSE.2012.6261918>
- Kousarrizi, M. R. N., Ghanbari, A. A., Teshnehlab, M., Shorehdeli, M. A., & Gharaviri, A. (2009). Feature Extraction and Classification of EEG Signals Using Wavelet Transform, SVM and Artificial Neural Networks for Brain Computer Interfaces. In *2009 International Joint Conference on Bioinformatics, Systems Biology and Intelligent Computing* (pp. 352–355). IEEE. <https://doi.org/10.1109/IJCBS.2009.100>
- Krusienski, D. J., McFarland, D. J., & Wolpaw, J. R. (2006). An Evaluation of Autoregressive Spectral Estimation Model Order for Brain-Computer Interface Applications. In *2006 International Conference of the IEEE Engineering in Medicine and Biology Society* (Vol. 1, pp. 1323–1326). IEEE.

<https://doi.org/10.1109/IEMBS.2006.259822>

Lalor, E. C., Kelly, S. P., Finucane, C., Burke, R., Smith, R., Reilly, R. B., & McDarby, G. (2005). Steady-State VEP-Based Brain-Computer Interface Control in an Immersive 3D Gaming Environment. *EURASIP Journal on Advances in Signal Processing*, 2005(19), 706906. <https://doi.org/10.1155/ASP.2005.3156>

Li, X., Zheng, Y., & Li, X. (2011). Extraction of novel features for emotion recognition. *Journal of Shanghai University (English Edition)*, 15(5), 479–486. <https://doi.org/10.1007/s11741-011-0772-3>

Liu, Y.-H., Cheng, C.-A., & Huang, H.-P. (2011). Novel feature of the EEG based motor imagery BCI system: Degree of imagery. In *Proceedings 2011 International Conference on System Science and Engineering* (pp. 515–520). IEEE. <https://doi.org/10.1109/ICSSE.2011.5961957>

Lotte, F. (2008, December 4). *Study of Electroencephalographic Signal Processing and Classification Techniques towards the use of Brain-Computer Interfaces in Virtual Reality Applications*. INSA de Rennes. Retrieved from <https://hal.inria.fr/tel-00356346/en>

Ming-Ai, L., Rui, W., Dong-Mei, H., & Jin-Fu, Y. (2009). Feature Extraction and Classification of Mental EEG for Motor Imagery. In *2009 Fifth International Conference on Natural Computation* (pp. 139–143). IEEE. <https://doi.org/10.1109/ICNC.2009.220>

Motamedi-Fakhr, S., Moshrefi-Torbati, M., Hill, M., Hill, C. M., & White, P. R. (2014). Signal processing techniques applied to human sleep EEG signals—A review. *Biomedical Signal Processing and Control*, 10, 21–33. <https://doi.org/10.1016/J.BSPC.2013.12.003>

Muthanantha Murugavel, A. S., Ramakrishnan, S., Balasamy, K., & Gopalakrishnan, T. (2011). Lyapunov features based EEG signal classification by multi-class SVM. In *2011 World Congress on Information and Communication Technologies* (pp. 197–201). IEEE. <https://doi.org/10.1109/WICT.2011.6141243>

Novi, Q., Guan, C., Huy Dat, T., & Xue, P. (n.d.). Sub-band Common Spatial Pattern (SBCSP) for Brain-Computer Interface. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.417.3167&rep=rep1&type=pdf>

Palaniappan, R. (n.d.). Brain Computer Interface Design Using Band Powers Extracted During Mental Tasks. In *Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering, 2005*. (pp. 321–324). IEEE. <https://doi.org/10.1109/CNE.2005.1419622>

Qiao, X., Wang, Y., Li, D., & Lifeng Tian. (2010). Feature extraction and classifier evaluation of EEG for imaginary hand movements. In *2010 Sixth International Conference on Natural Computation* (pp. 2112–2116). IEEE. <https://doi.org/10.1109/ICNC.2010.5582453>

Ramírez-Castro, R. I., & Montejo, L. A. (2011). Transformada de Hilbert, descomposición modal empírica y sus aplicaciones en el análisis de vibraciones libres. *Revista Internacional de Desastres Naturales, Accidentes E Infraestructura Civil*. Retrieved from https://www.scipedia.com/public/Ramírez-Castro_Montejo_2011a

Ramoser, H., Muller-Gerking, J., & Pfurtscheller, G. (2000). Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Transactions on Rehabilitation Engineering*, 8(4), 441–446. <https://doi.org/10.1109/86.895946>

Riju, B., Sreevidya, P., & Smitha, K. (2015). Compression and Comparison of ECG Signals using DWT and DWPT. *Indian Journal of Science and Technology*, 8(24). <https://doi.org/10.17485/ijst/2015/v8i24/83319>

Roy, R., Sikdar, D., Mahadevappa, M., & Kumar, C. S. (2017). EEG based motor imagery study of time domain features for classification of power and precision hand grasps. In *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)* (pp. 440–443). IEEE. <https://doi.org/10.1109/NER.2017.8008384>

Samar, V. J., Bopardikar, A., Rao, R., & Swartz, K. (1999). Wavelet Analysis of Neuroelectric Waveforms: A Conceptual Tutorial. *Brain and Language*, 66(1), 7–60. <https://doi.org/10.1006/brln.1998.2024>

Sun, S., & Zhang, C. (2006). Adaptive feature extraction for EEG signal classification. *Medical & Biological Engineering & Computing*, 44(10), 931–935. <https://doi.org/10.1007/s11517-006-0107-4>

Tae-Eui Kam, & Seong-Whan Lee. (2011). Time-Dependent Common Spatial Patterns optimization for EEG signal classification. In *The First Asian Conference on Pattern Recognition* (pp. 643–646). IEEE. <https://doi.org/10.1109/ACPR.2011.6166621>

Ting, W., Guo-zheng, Y., Bang-hua, Y., & Hong, S. (2008). EEG feature extraction based on wavelet packet decomposition for brain computer interface. *Measurement*, 41(6), 618–625. <https://doi.org/10.1016/J.MEASUREMENT.2007.07.007>

Turk, O., Seker, M., Akpolat, V., & Ozerdem, M. S. (2017). Classification of mental task EEG records

- using Hjorth parameters. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1–4). IEEE. <https://doi.org/10.1109/SIU.2017.7960608>
- Übeyli, E. D. (2010). Lyapunov exponents/probabilistic neural networks for analysis of EEG signals. *Expert Systems with Applications*, 37(2), 985–992. <https://doi.org/10.1016/J.ESWA.2009.05.078>
- Wang, L., Xu, G., Wang, J., Yang, S., & Yan, W. (2007). Feature Extraction of Mental Task in BCI Based on the Method of Approximate Entropy. In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (Vol. 2007, pp. 1941–1944). IEEE. <https://doi.org/10.1109/IEMBS.2007.4352697>
- Wang, L., Xu, G., Wang, J., Yang, S., & Yan, W. (2011). Motor Imagery BCI Research Based on Hilbert-Huang Transform and Genetic Algorithm. In *2011 5th International Conference on Bioinformatics and Biomedical Engineering* (pp. 1–4). IEEE. <https://doi.org/10.1109/icbbe.2011.5780181>
- Wang, L., Xu, G., Yang, S., Wang, J., Guo, M., & Yan, W. (2012). Motor Imagery BCI Research Based on Sample Entropy and SVM. In *2012 Sixth International Conference on Electromagnetic Field Problems and Applications* (pp. 1–4). IEEE. <https://doi.org/10.1109/ICEF.2012.6310370>
- Xiao, D., Mu, Z., & Hu, J. (2009). Classification of Motor Imagery EEG Signals Based on Energy Entropy. In *2009 International Symposium on Intelligent Ubiquitous Computing and Education* (pp. 61–64). IEEE. <https://doi.org/10.1109/IUCE.2009.57>
- Xinyang Li, Shuzhi Sam Ge, Yaozhang Pan, Keum-Shik Hong, Zhengchen Zhang, & Xiaosu Hu. (2011). Feature extraction based on common spatial analysis for time domain parameters. In *2011 8th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)* (pp. 377–382). IEEE. <https://doi.org/10.1109/URAI.2011.6145846>
- Xu, B., Song, A., & Wu, J. (2007). Algorithm of Imagined Left-Right Hand Movement Classification Based on Wavelet Transform and AR Parameter Model. In *2007 1st International Conference on Bioinformatics and Biomedical Engineering* (pp. 539–542). IEEE. <https://doi.org/10.1109/ICBBE.2007.141>
- Zhang, A., Yang, B., & Huang, L. (2008). Feature Extraction of EEG Signals Using Power Spectral Entropy. In *2008 International Conference on BioMedical Engineering and Informatics* (pp. 435–439). IEEE. <https://doi.org/10.1109/BMEI.2008.254>
- Zhao, H., Liu, C., Li, C., & Wang, H. (2010). Feature extraction using wavelet entropy and band powers in brain-computer interface. In *2010 2nd International Conference on Signal Processing Systems* (pp. V2-670-V2-673). IEEE. <https://doi.org/10.1109/ICSPS.2010.5555724>
- Zou, L., Wang, X., Shi, G., & Ma, Z. (2010). EEG feature extraction and pattern classification based on motor imagery in brain-computer interface. In *9th IEEE International Conference on Cognitive Informatics (ICCI'10)* (pp. 536–541). IEEE. <https://doi.org/10.1109/COGINF.2010.5599682>

1. Ingeniero Electrónico. Magíster en Automatización y Control Industrial. Docente Investigador. Universidad de Sucre. Facultad de Ingeniería. Email: boris.medina@unisucre.edu.co

2. Ingeniero Electrónico. Magíster en Ingeniería. Doctor en Ingeniería. Docente Investigador. Universidad de Sucre. Facultad de Ingeniería. Email: javier.sierra@unisucre.edu.co

3. Ingeniero Electrónico y Telecomunicaciones. Magíster en Ingeniería. Docente Investigador. Universidad de Sucre. Facultad de Ingeniería. Email: alexisbarriosu@hotmail.com

Revista ESPACIOS. ISSN 0798 1015
Vol. 39 (Nº 22) Año 2018

[Índice]

[En caso de encontrar algún error en este website favor enviar email a webmaster]

©2018. revistaESPACIOS.com • Derechos Reservados