

SEGMENTACIÓN AUTOMÁTICA DE SEÑALES NEUROFISIOLÓGICAS UTILIZANDO MÉTODOS BASADOS EN WAVELETS

RESUMEN

Las señales bioeléctricas contienen artefactos de una gran variedad de fuentes que traen consigo incertidumbre en las técnicas de procesamiento de señales y que requieren segmentos estacionarios de la señal para su análisis. En el presente artículo se desarrolla un algoritmo de segmentación basado en wavelets. Las pruebas desarrolladas sobre las bases de datos de pacientes parkinsonianos en las zonas de tálamo y subtálamo dan como resultado que la metodología propuesta permite segmentar de manera apropiada dichas señales..

PALABRAS CLAVES: wavelets, MER, segmentación.

ABSTRACT

Bioelectric signals contain artifacts from a width variety of sources which brings within uncertainty to signal processing techniques and require stationary signal segments for its analysis. The present article develops a segmentation algorithm based on wavelets. The tests were done on parkinsonian patients database in thalamus and subthalamus brain regions drop as result that the proposed methodology lets to segment in an appropriate way.

KEYWORDS: Wavelets, MER, segmentation.

1. INTRODUCCIÓN

En el tratamiento de la enfermedad de Parkinson, la estimulación cerebral profunda del globo pálido interno (GPi) y subtálamo (STN) ha mostrado una mejora en los síntomas de la enfermedad. Esta cirugía consiste en insertar un microelectrodo en la cabeza del paciente [1], el electrodo capta los impulsos neuronales generados por las neuronas cercanas a éste, y la señal capotada es comúnmente conocida como registro del microelectrodo (MER).

Para la localización de las zonas objetivos, un neurofisiólogo utiliza el registro tomado por el microelectrodo, lo escucha y observa las formas de ondas generadas en un osciloscopio; a partir de una apreciación subjetiva él indica la región del cerebro en la que se encuentra el microelectrodo, a veces necesitando muchos intentos para poder realizar la inferencia. El registro MER generalmente contiene artefactos por dispositivos electrónicos cercanos o movimientos del paciente, complicando el análisis de este tipo de señales y necesitando métodos que permitan separar o segmentar los eventos correspondientes a los artefactos.

En [2] se propone un algoritmo para la segmentación en el dominio del tiempo de señales MER. El método es capaz de encontrar instantes de cambio entre señales pertenecientes a diferentes estructuras o núcleos neuronales utilizando segmentos de 0.5 s y 1 s. El método necesariamente no separa señales estrictamente estacionarias sino que diferencia las señales no estacionarias generadas por diferentes estructuras neuronales.

ALVARO A. OROZCO

Ingeniero Electricista, M.Sc
Profesor Titular
Universidad Tecnológica de Pereira
aaog@utp.edu.co

CRISTIAN GUARNIZO

Ingeniero Electricista
Profesor
Universidad Tecnológica de Pereira
cdguarnizo@ohm.utp.edu.co

JULIAN D. ECHEVERRI

Ingeniero Electricista
Profesor
Universidad Tecnológica de Pereira
jdec@ohm.utp.edu.co

En [3] se propone un algoritmo de segmentación de señales no estacionarias basado en la transformada wavelet packet, donde se buscan componentes estacionarias en una señal. Para la detección de los instantes de cambio, se emplea una ventana deslizante sobre un conjunto de señales reconstruidas a partir de la descomposición realizada. Uno de los mayores problemas al tratar de realizar la segmentación en el dominio de la transformada wavelet discreta es la representación, ya que por cada nivel de descomposición que se aumente la cantidad de coeficientes se disminuye a la mitad por la decimación. Por esta razón se emplea la transformada wavelet estacionaria, ya que no incluye el proceso de decimación en su análisis.

2. METODOLOGÍA

El método de segmentación propuesto busca los instantes de cambio, observando la relación entre las varianzas de dos segmentos adyacentes sobre el dominio de la transformada wavelet estacionaria.

2.1 Transformada Wavelet Discreta

La transformada wavelet discreta (DWT) se basa en dos filtros, uno pasa bajo (H), otro pasa alto (G) y una decimación binaria ($\downarrow 2$). Los filtros H y G se definen con unos pocos coeficientes diferentes de cero h_n y g_n respectivamente. La acción del filtro H sobre una señal $x \in L^2$ se puede definir como [4]:

$$H_k x = \sum_n h_{n-k} x_n \quad (0.1)$$

Se asume que el filtro cumple con la relación de ortogonalidad interna

$$\sum_n h_n h_{n+2i} = 0 \quad (0.2)$$

para todo entero $i \neq 0$, y suma cuadrática $\sum h_n^2 = 1$.

El filtro pasa alto G se define por la secuencia

$$g_n = (-1)^n h_{1-n} \quad (0.3)$$

Los filtros construidos de esta manera se conocen como *filtros espejo en cuadratura*. El operador de decimación binario $\downarrow 2$ selecciona los elementos pares de una secuencia.

En la figura 1 se puede observar el esquema de análisis de la transformada wavelet discreta con dos niveles de descomposición.

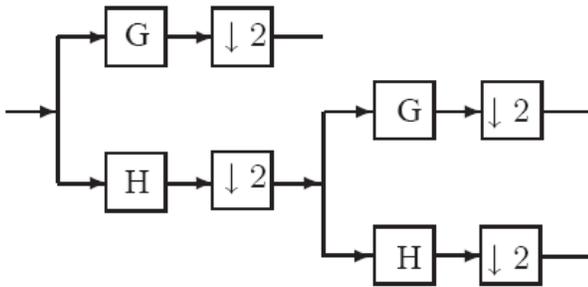


Figura 1. Transformada wavelet discreta con 2 niveles de descomposición.

Los coeficientes cD_j que se obtienen a la salida del filtro G se conocen como coeficientes de detalle, y los coeficientes cA_j que se obtienen a la salida del filtro H como coeficientes de aproximación.

2.2 Transformada Wavelet Estacionaria

La transformada wavelet estacionaria (SWT) se puede obtener modificando el esquema básico de la DWT. Se aplican los dos filtros para producir a la salida dos secuencias en cada nivel. Debido a que no se hace decimación se obtiene a la salida de cada nivel, secuencias de longitud igual a la señal original. Pero se modifican los filtros en cada nivel agregándole ceros [5]. Para explicar el procedimiento se introduce el operador $\uparrow 2$, este operador alterna una secuencia con ceros, por ejemplo si, $y = \uparrow 2(x)$ entonces $y_{2i} = x_i$ y $y_{2i+1} = 0$. Los filtros G y H para cada nivel de descomposición se calculan de la siguiente forma:

$$G_{j+1} = \uparrow 2(G_j) \quad (0.4)$$

$$H_{j+1} = \uparrow 2(H_j) \quad (0.5)$$

donde H_0 y G_0 son los filtros originales utilizados en la DWT. En la figura 2 se puede observar el esquema de análisis de la SWT.

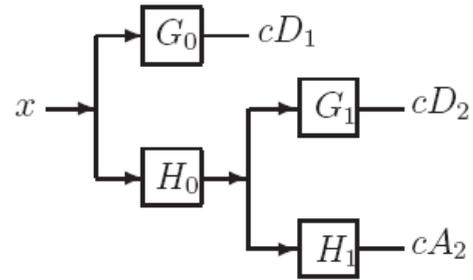


Figura 2. Transformada wavelet estacionaria con 2 niveles de descomposición.

Los coeficientes cA_j y cD_j de la SWT a diferencia de la DWT tienen una cantidad igual a la longitud de la señal analizada.

2.3 Algoritmo de Segmentación

El algoritmo busca en el dominio de la transformada wavelet estacionaria los segmentos pertenecientes a diferentes regiones del cerebro. Se desarrolla siguiendo algunos pasos de forma similar al algoritmo propuesto en [2]:

2.3.1 Transformada wavelet estacionaria de la señal

Cada señal antes de ser procesada es normalizada de la siguiente manera:

$$x_n = \frac{x - \mu_x}{\sigma_x}$$

La señal x_n normalizada se le calcula la SWT utilizando J niveles de descomposición. Posteriormente se dividen las señales obtenidas en cada descomposición en N_s segmentos de t s sin traslapes.

$$S_{l=1:N_s}^j = \{X^j[1], X^j[2], \dots, X^j[N_s]\} \quad (0.6)$$

donde $j = 1, \dots, J + 1$, $l = 1, \dots, N_s$, X es la SWT de x.

2.3.2 Varianza de los segmentos

Se calcula la varianza de cada de cada segmento X_l^j para generar un vector F que contenga las relaciones entre las varianzas de la siguiente manera

$$V_l^j = \text{var}(S_l^j) \quad (0.7)$$

$$F_l^j = \frac{V_{N_l}^j}{V_{D_l}^j} \quad (0.8)$$

Donde

$$V_{N_l}^j = \max(V_l^j, V_{l+1}^j) \quad (0.9)$$

$$V_{D_l}^j = \min(V_l^j, V_{l+1}^j) \quad (0.10)$$

La prueba estadística utilizada para determinar los instantes de transición se calcula analizando las relaciones entre las varianzas de dos segmentos adyacentes. La mayor varianza es ubicada en el numerador. La validación de los instantes de transición se puede realizar promediando F_l^j a través de las escalas j o seleccionando ciertas escalas en las que fácilmente se pueda encontrar los instantes. Se toman como instantes de cambios aquellos valores que sean máximos locales mayores a un umbral empírico γ .

3. RESULTADOS

El algoritmo de segmentación propuesto se probó sobre señales artificiales compuestas por señales reales provenientes de 3 regiones cerebrales diferentes Subtálamo (STN), Sustancia Negra (SN) y Tálamo (T). Se compararon los resultados obtenidos con el algoritmo de segmentación propuesto en [2].

En la figura 3(a) se puede observar la señal compuesta por los 3 segmentos de 3 s (0-3s STN, 3-6s SN y 6-9s T) muestreadas a 11025 Hz. El proceso de selección de instantes es correcto si los instantes seleccionados son 3 y 6 s. Como se puede observar en la figura 3(b) los valores (promedio de los F_l^j a través de todas las escalas j) que son mayores a un umbral $\gamma = 2$, son los valores correctos para segmentar esta señal. Mientras que en la figura 3(c) empleando el algoritmo de segmentación propuesto en [2] para un valor de umbral $\gamma = 3$, se toma como instantes de transición los tiempos 3, 4.5 y 6 s. Es claro que en el instante de tiempo 4.5 s no debería tomarse como instante de transición para segmentar la señal.

Para todas las pruebas se empleo la base wavelet Haar pero utilizando bases wavelet de orden pequeño por ejemplo db1, db2, coif1 y sym2 se obtiene un resultado

similar al de la figura 3(b). En número de niveles de descomposición utilizado fue J=10.

Se realizó otra prueba con una señal compuesta por 3 segmentos (0-4s STN, 4-7s SN y 7-11s T) muestreadas a 24000 Hz, registros de un paciente de la base de datos de la Universidad Politécnica de Valencia (ver figura 4(a)). El número de niveles utilizado para el algoritmo de segmentación en el dominio de la SWT, fue J=1. Para este caso se observa que no es necesario promediar los valores F_l^j , sino que simplemente observando los valores F_l^1 se determinan los instantes de transición en la señal.

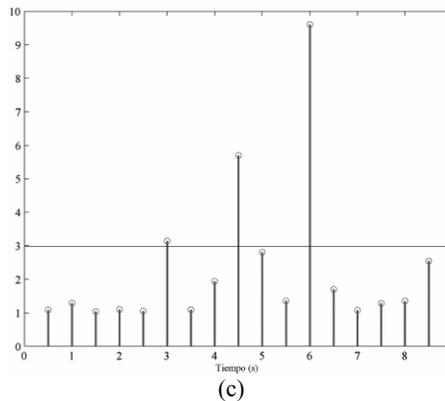
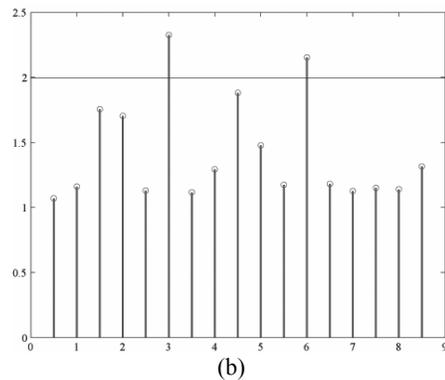
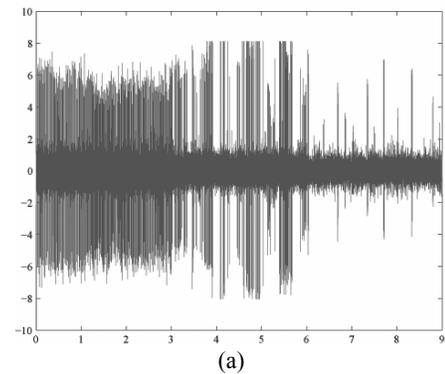


Figura 3. Resultado de la segmentación para $t=0.5s$. (a) Señal con 3 estructuras. (b) Segmentación en el dominio SWT. (c) Segmentación en el dominio del tiempo. La última prueba se hizo sobre los segmentos correspondientes a las regiones STN y T, de la señal de la figura 4(a).

Se utilizaron dos niveles de descomposición ($J=1$ y $J=10$) para la SWT. Se observa que la estimación hecha por el algoritmo empleando $J=10$ (ver figura 5(b)) niveles de descomposición es mejor que utilizando $J=1$ (ver figura 5(c)).

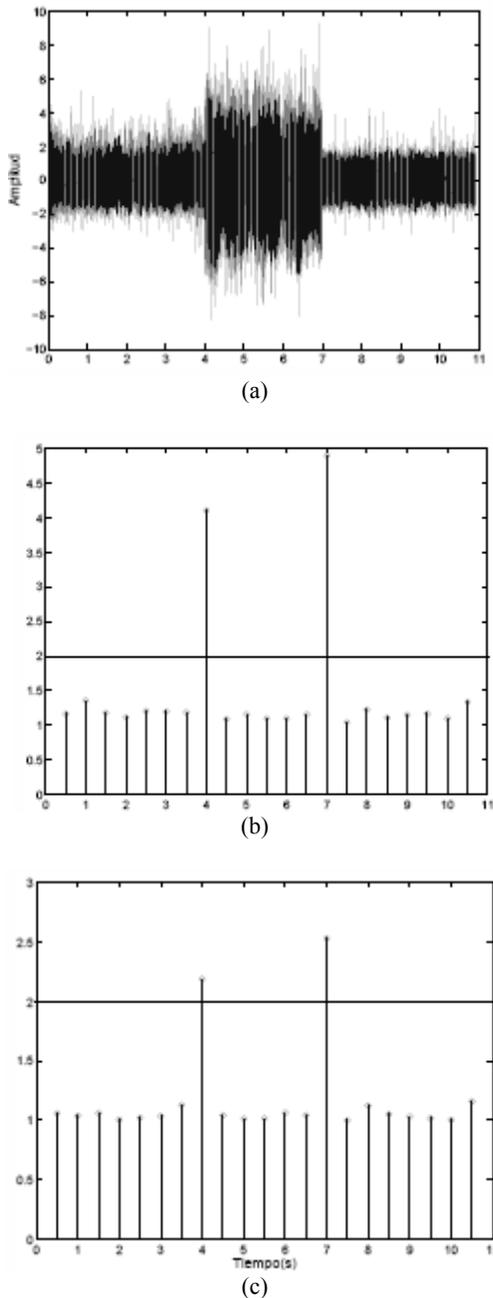


Figura 4. Resultado de la segmentación para $t=0,5$ s y $J=1$. (a) Señal con 3 estructuras neuronales. (b) Promedio de los valores F^j . (c) Valores de F^j .

Esto se debe a que las estimaciones hechas en cada F^j al promediarlas incrementan el valor del instante de transición.

Los resultados obtenidos en la segmentación sobre registros reales de las regiones cerebrales tálamo y subtálamo se pueden observar en las figuras 6 y 7,

respectivamente. Se seleccionaron los segmentos más largos entre los instantes de cambio que superan el umbral $\gamma = 2$. Como se puede observar en la figura 6, el algoritmo seleccionó el segmento del registro que no contiene artefactos tipo saturación (valores de gran amplitud en instantes cortos de tiempo).

4. CONCLUSIONES

La transformada wavelet presenta una mejor estimación de los instantes de transición en una señal compuesta por señales provenientes de diferentes regiones del cerebro que empleando la estimación de los instantes en el dominio del tiempo.

El empleo de la transformada wavelet estacionaria permite realizar procesos de detección de cambios abruptos en el dominio de la transformada, sin necesidad de reconstruir la señal después de ser analizada.

Para ciertos casos no es necesario utilizar toda la descomposición wavelet para identificar los instantes de transición sino analizando un nivel de descomposición, esto reduce considerablemente el costo computacional del algoritmo de segmentación.

5. AGRADECIMIENTOS

Este trabajo se realiza bajo el marco del proyecto Sistema automatizado de clasificación de eventos fisiológicos a partir de patrones bioeléctricos como soporte en el tratamiento de la enfermedad de parkinson y otros desórdenes neurológicos financiado por Conciencias código 1110-14-17904.

6. BIBLIOGRAFIA

- [1] R. Santiago, J. McNames, K. Burchiel, and G. Lendaris, "Developments in understanding neuronal spike trains and functional specializations in brain regions," *Neural Networks*, vol. 16, pp. 601–607, 2003.
- [2] J. H. Falkenberg, "Segmentation of extracellular microelectrode recordings with equal power," *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings, Cancun, Mexico*, pp. 2475–2478, 17-21 September 2003.
- [3] E. Hitti and M.-F. Lucas, "Wavelet-packet basis selection for abrupt changes detection in multicomponent signals," in *EUSIPCO-98*, Rhode Island, Greece, Septiembre 1998.
- [4] G. Strang and T. Nguyen, *Wavelets and Filter Banks*. Wellesley, MA, USA: Wellesley-Cambridge Press, 1996.
- [5] G. P. Nason and B. W. Silverman, "The stationary wavelet transform and some statistical applications," *Notes in Statistics*, vol. 108, pp. 281–289, 1995.

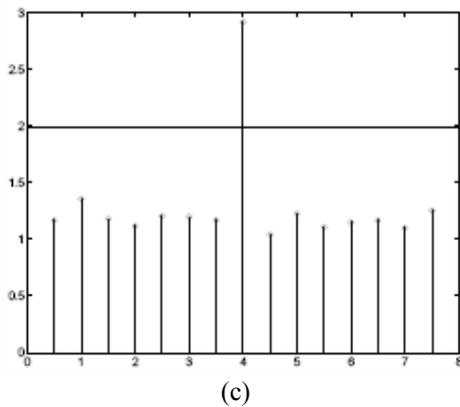
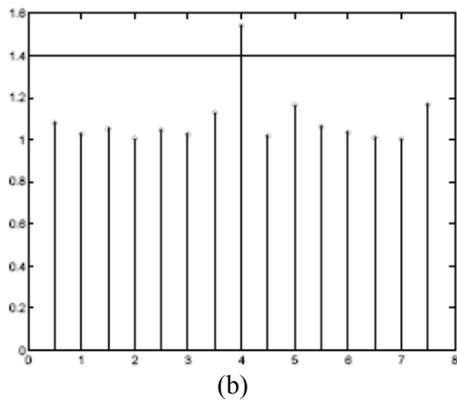
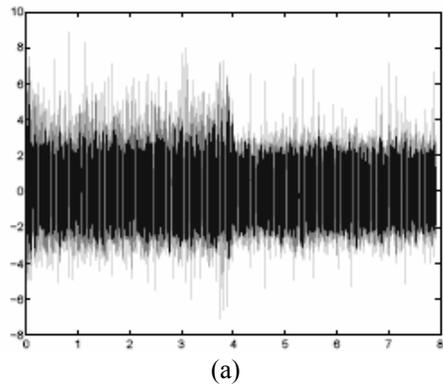


Figura 5. Resultado de la segmentación para $t=0,5$ s. (a) Señal con 2 estructuras neuronales. (b) Promedio de los valores F^j para $J=1$. (c) Promedio de los valores F^j para $J=10$.

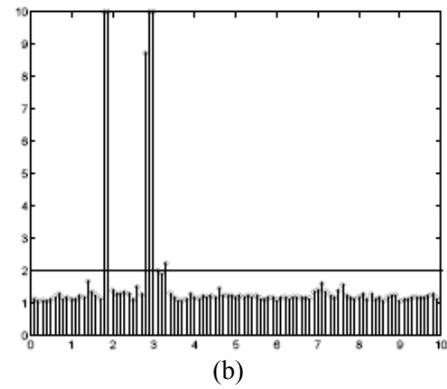
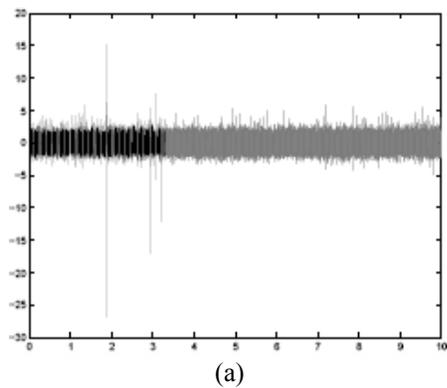


Figura 6. Resultado de la segmentación para $t=0,1$ s en un registro real de la región Tálamo. (a) Registro completo y segmento seleccionado. (b) Promedio de los valores F^j para $J=10$.

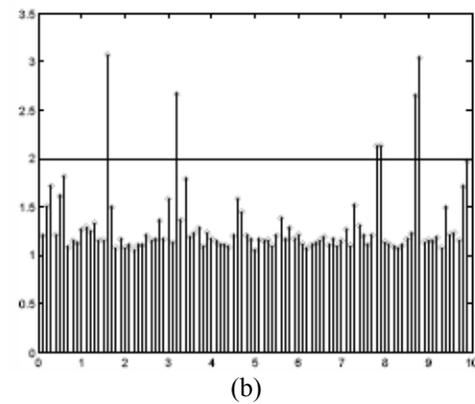
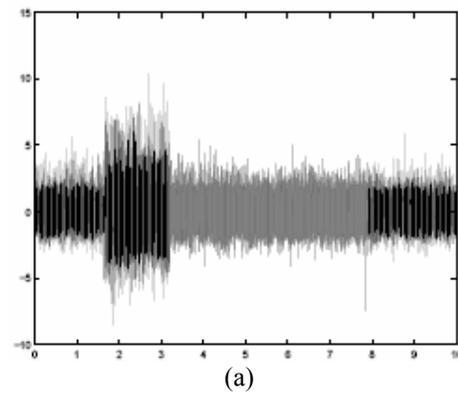


Figura 7. Resultado de la segmentación para $t=0,1$ s en un registro real de la región Subtálamo. (a) Registro completo y segmento seleccionado. (b) Promedio de los valores F^j para $J=10$.