

SEGMENTACIÓN AUTOMÁTICA DE SEÑALES NO ESTACIONARIAS UTILIZANDO LA TRANSFORMADA WAVELET ESTACIONARIA

RESUMEN

Las señales bioeléctricas contienen información de procesos fisiológicos representados por eventos relevantes para los especialistas de acuerdo a la señal analizada. Debido a que las señales fisiológicas se caracterizan por eventos o cambios fuertes (complejo QRS en señales electrocardiográficas (ECG), potenciales de acción en microelectrodos de registro (MER)) se emplea la transformada wavelet que representa mejor estos cambios que otras transformadas. Teniendo en cuenta la representación tiempo – frecuencia de la transformada wavelet estacionaria se utilizan algoritmos de detección de cambios abruptos sobre los coeficientes entregados por nivel, con el objetivo de localizar los cambios abruptos no solo en el tiempo sino también en la frecuencia.

PALABRAS CLAVES: Wavelets, MER, ECG, voz, segmentación.

ABSTRACT

Bioelectric signals carry events which deliver relevant information to specialists, depending on the analyzed signal. Due to physiological signals are characterized by events or abrupt changes (QRS complex in ECG, action potential in MER), the wavelet transform is employed to get a better representation of these events. Taking advantage of undecimated wavelet transform representation in the time-frequency plane we use abrupt change detection algorithms on the coefficients of each scale, for locating abrupt changes not just in the time plane but also in the frequency plane.

KEYWORDS: wavelets, MER, ECG, speech, segmentation.

1. INTRODUCCIÓN

En el procesamiento de señales en general se necesita extraer de las señales los segmentos que contengan la información necesaria para caracterizarlas. La segmentación de señales consiste en dividir la señal en segmentos que posean cierta estacionariedad (momentos estadísticos de la señal no varíen con el tiempo o varíen lenta y suavemente) [1].

La segmentación de bioseñales dependiendo del tipo de señal tiene un objetivo diferente, i.e. para el caso de las señales electrocardiográficas (ECG) se pretende determinar del registro los segmentos correspondientes a los diferentes complejos presentes en la forma de onda de los latidos captados (P-Q, Q-R-S, S-T) [2]. Para las grabaciones de voz se requiere indicar los segmentos que contienen sonido de los espacios de silencio, o también, encontrar los segmentos correspondientes a los diferentes fonemas contenidos en los segmentos de sonido [3]. Por último para las señales provenientes de microelectrodos de registro se requiere determinar de un registro que contiene señales generadas por diferentes zonas del cerebro los segmentos pertenecientes a dichas zonas [4]. En este documento se presenta una metodología de segmentación basada en la transformada wavelet

CRISTIAN GUARNIZO

Ingeniero Electricista.

Estudiante Maestría

Profesor

Universidad Tecnológica de
Pereira

cdguarnizo@ohm.utp.edu.co

estacionaria combinada con algoritmos de detección de cambios abruptos para la segmentación de las bioseñales anteriormente mencionadas. La motivación surge de trabajos donde se emplean transformadas tiempo - frecuencia para detectar cambios en los momentos estadísticos de la señal no solo en el dominio del tiempo sino también en la frecuencia [5, 6].

2. METODOLOGÍA

El método de segmentación propuesto busca cambios abruptos comparando diferentes funciones de medida o distancia sobre el dominio de la transformada wavelet estacionaria.

2.2 Transformada Wavelet Estacionaria

La transformada wavelet estacionaria (SWT) se puede obtener modificando el esquema básico de la transformada wavelet discreta (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 [7].

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:

$$g_{j+1} = \uparrow 2(g_j)$$

$$h_{j+1} = \uparrow 2(h_j)$$

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.

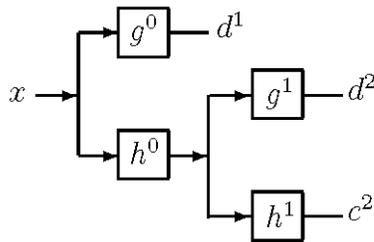


Figura 1. Transformada wavelet estacionaria con 2 niveles de descomposición.

Los coeficientes d_k^l y c_k^l de la SWT a diferencia de la DWT tienen una cantidad igual a la longitud de la señal analizada. Esta última característica permite realizar la detección de cambios abruptos sobre los coeficientes de las diferentes escalas.

2.3 Algoritmos de Detección

Los algoritmos de detección de cambios abruptos en general determinan cambios en una serie de tiempo observando variaciones en los parámetros que definen las funciones de densidad de probabilidad estimadas de dos ventanas (s_1 y s_2) que se deslizan por la señal (ver figura 2).

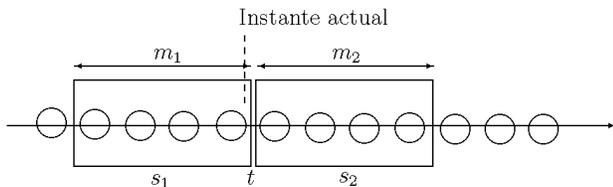


Figura 2. Esquema de ventanas deslizantes.

Los resultados del análisis varían de acuerdo al tamaño de las ventanas (m_1 y m_2), el traslape y la función de medida o distancia empleada [1].

Las funciones de distancia empleadas son:

2.3.1 Prueba F modificada

La medida de la prueba F modificada se obtiene a partir de la relación entre las varianzas extraídas de cada

ventana, ubicando en el numerador el mayor de los dos valores [4]:

$$V_N = \max(\sigma_{s_1}^2, \sigma_{s_2}^2)$$

$$V_D = \min(\sigma_{s_1}^2, \sigma_{s_2}^2)$$

$$g[k] = \frac{V_N}{V_D}$$

Donde $\sigma_{s_1}^2$ y $\sigma_{s_2}^2$ son las varianzas de las ventanas s_1 y s_2 , respectivamente. Los valores de $g[k]$ son mayores o iguales a uno. Se toman como instantes de cambio entre un segmento a otro los máximos locales mayores a un umbral de la función $g[k]$.

2.3.2 Suma acumulativa (CUSUM)

Sean las secuencias de tiempo de las ventanas analizadas caracterizadas por una función de densidad de probabilidad Gaussiana (con varianza σ^2 y media μ), que responden a variaciones en la media, y con una varianza conocida y constante, se tiene [1]:

$$v[k] = \frac{\mu_1 - \mu_0}{\sigma^2} \left(y[k] - \frac{\mu_1 + \mu_0}{2} \right)$$

$$g[k] = v[k] + g[k-1]$$

Donde μ_0 y μ_1 son las medias de las ventanas s_1 y s_2 , respectivamente, y σ^2 es la varianza de s_1 o s_2 debido a que se asume que el proceso tiene varianza constante.

2.3.2 Información de Kullback

La distancia de Kullback Leibler entre dos funciones de densidad de probabilidad p_{θ_0} y p_{θ_1} , estimadas a partir de las ventanas s_1 y s_2 , se define como:

$$K(\theta_0, \theta_1) = E_{\theta_0} \left[\ln \frac{p_{\theta_1}}{p_{\theta_0}} \right] \geq 0$$

La función se hace cero cuando las dos densidades son iguales. Asumiendo que las densidades sean Gaussianas, con varianza σ^2 conocida, la información de Kullback se establece como:

$$K(\theta_0, \theta_1) = \frac{(\theta_1 - \theta_0)^2}{2\sigma^2}$$

Donde el parámetro θ puede ser la media de cada uno de los procesos que se comparan [1].

2.4 Segmentación en el Dominio de la Transformada Wavelet Estacionaria

La metodología propuesta para la detección de cambios abruptos empleando la transformada wavelet se basa en la representación espacio-temporal de la transformada

wavelet, en donde los coeficientes dan información no solo del contenido temporal sino también frecuencial de la señal a través de los diferentes niveles de descomposición (subbandas). Algunos trabajos presentan esquemas para determinar cambios abruptos en señales no estacionarias utilizando la transformada wavelet [6], debido a que se utiliza la DWT se necesita reconstruir (no se puede realizar el análisis en el dominio de la transformada por el submuestreo) algunas bandas de análisis para posteriormente detectar los cambios en estas señales reconstruidas. Para eliminar el paso de la reconstrucción de señales se propone utilizar la SWT, que permite realizar los algoritmos de detección de cambios abruptos en el dominio de la transformada sin pérdida de información temporal.

2.4.1 Extracción de los instantes por escala

Debido a la propiedad de persistencia de la transformada wavelet [8], y dependiendo de las características de la señal, los instantes de interés se pueden determinar analizando una sola escala de la SWT. Si la señal posee discontinuidades o cambios fuertes y estos son relevantes para el proceso de segmentación, se verán reflejados en todos los coeficientes de todas las escalas en la vecindad de la discontinuidad (persistencia a través de las escalas). A partir de lo anterior se plantea una detección de los cambios abruptos de la señal en una escala analizando las variaciones presentes en la representación temporo espacial, además los cambios fuertes de corto tiempo de la señal.

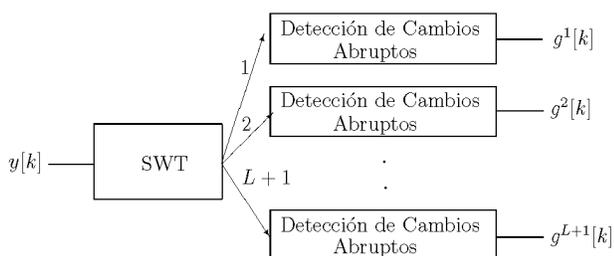


Figura 3. Esquema de segmentación utilizando la transformada wavelet estacionaria.

2.4.2 Promedio de las funciones de medida de las escalas

Para determinar en conjunto una función de medida que facilite la detección de los cambios abruptos temporales y frecuenciales presentes en las diferentes escalas de análisis se propone realizar un promedio de las funciones de medida obtenidas por escala (ver figura 3) de esta forma se obtiene una sola función de medida que contiene los posibles cambios que se pueden determinar por escala.

$$\hat{g}[k] = \frac{1}{N} \sum_{l=1}^N g^l[k]$$

Donde N es el número de escalas seleccionadas y $\hat{g}[k]$ es la función de medida estimada.

3. VALIDACIÓN

El resultado de la segmentación puede contener dos posibles tipos de error. Los errores Tipo I ocurren si un límite de un segmento verdadero no ha sido detectado por el segmentador (falso negativo FN). Los errores Tipo II ocurren si un límite de un segmento no corresponde a un límite de un segmento de la referencia (falso positivo FP). Para indicar el correcto funcionamiento de los procedimientos de segmentación se utilizó el análisis basado en las curvas PR (Precision - Recall).

Las curvas precisión y sensibilidad se expresan a partir de la razón de los errores Tipo I y la razón de los errores Tipo II, y viceversa. Se definen como [3]:

$$PRC = \frac{TP}{TP + FN}$$

$$RCL = \frac{TP}{TP + FP}$$

Donde PRC es la precisión y RCL es la sensibilidad, TP es el número de detecciones correctas. La mayoría de los algoritmos de segmentación se diseñan para trabajar en diferentes puntos de operación. Cada punto de operación corresponde a un par (PRC, RCL). Como el costo relativo de los límites no detectados contra el costo de las falsas alarmas depende de la aplicación, un segmentador esta completamente caracterizado por un gráfico de Precisión sobre Sensibilidad para todos los posibles puntos de operación. Para obtener un conocimiento del funcionamiento del segmentador se utiliza la medida F

$$F = \frac{2 \cdot PRC \cdot RCL}{PRC + RCL}$$

Para la selección del umbral en el cual se comporte mejor el segmentador, se toma como criterio el umbral que entregue el mayor valor de F.

La correcta posición del límite de un segmento no esta exactamente definida. En la mayoría de los casos, dos segmentos son separados por un periodo corto de silencio. Cualquier límite de un segmento entre un periodo de silencio debe ser registrado como correcto. Entonces, se define una tolerancia Δt . Si el límite hipotético esta en el intervalo $t_0 - \Delta t < t < t_0 + \Delta t$ del límite de referencia t_0 , se clasifica como correcto.

4. RESULTADOS

La metodología de segmentación se realizó sobre 3 tipos de señales diferentes:

4.1 Señales Mer

Para las señales MER se utilizó un paso de 0.1s para el avance de las ventanas y un tamaño de ventana igual a 0.1s. Se generó una base de datos sintética compuesta por 50 señales de 12 s cada una de manera similar a la presentada en [4], las señales contienen segmentos de registros tomados de diferentes zonas del cerebro (subtálamo, tálamo y sustancia negra), con una frecuencia de muestreo igual a 24 KHz.

| Esquema | F. de distancia | Medida F | RCL | PCR | Valor umbral |
|---------|-------------------|----------|--------|--------|--------------|
| Tiempo | Prueba F | 0.7778 | 1 | 0.6364 | 2.387 |
| SWT | Prueba F (3 niv.) | 0.8621 | 1 | 0.7576 | 1.412 |
| SWT | Prueba F (8 niv.) | 0.9207 | 0.9667 | 0.8788 | 1.568 |

Tabla 1. Desempeño en la segmentación de señales MER

El desempeño de los métodos de segmentación también se puede visualizar en una gráfica de Precisión contra Sensibilidad ver figura 4, donde la curva más cercana a la coordenada (1,1) presenta el mejor funcionamiento.

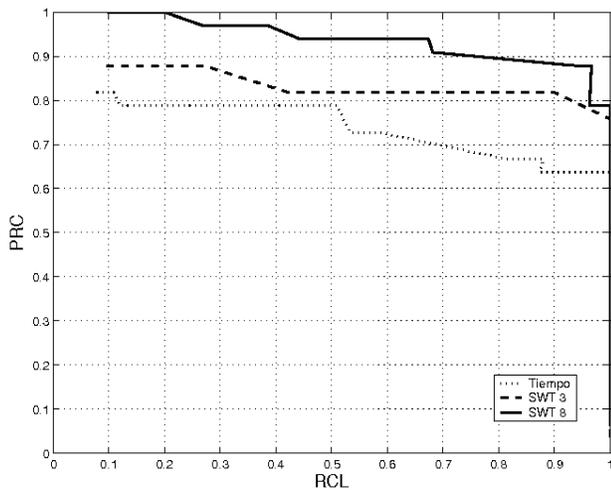


Figura 4. Curvas PR para diferentes valores de umbral.

4.2 Señales Ecg

Se empleó la base de datos de MIT BIH de arritmias, se tomaron 2 registros de electrocardiogramas normales, cada uno con más de 50 latidos. En las tablas 2 y 3 se observa el desempeño de la metodología de segmentación para la extracción del complejo QRS y QRS con la onda T. El tamaño de la ventana es igual a la cantidad de muestras que describen el evento QRS (20 muestras) y el paso igual a una muestra.

| Segmentación | Medida F | RCL | PCR | Valor umbral |
|-----------------------|----------|--------|---------|--------------|
| Prueba F (1ra escala) | 0.97866 | 0.98 | 0.97727 | 5.755 |
| Cusum (1ra escala) | 0.61101 | 0.92 | 0.45739 | 34.33 |
| Kullback (1ra escala) | 0.25673 | 0.1696 | 0.52841 | 0.257 |

Tabla 2. Desempeño en la segmentación del segmento QRS.

El mejor desempeño se obtiene empleando la prueba F modificada sobre los coeficientes de detalle de la primera descomposición.

| Segmentación | Medida F | RCL | PCR | Valor umbral |
|----------------------------|----------|-------|--------|--------------|
| Prueba F (coef. de aprox.) | 0.7596 | 0.761 | 0.7596 | 54.69 |
| Cusum (coef. de aprox.) | 0.4881 | 0.379 | 0.6847 | 0.595 |
| Kullback (coef. de aprox.) | 0.4911 | 0.372 | 0.723 | 1.355 |

Tabla 3. Desempeño en la segmentación del segmento QRS e inicio y final de la onda T.

Para la extracción de los segmentos QRS y T el mejor desempeño se obtiene empleando la prueba F modificada sobre los coeficientes de aproximación al realizar 3 niveles de descomposición.

4.3 Señales de Voz

Para la segmentación de voz se utilizaron 10 registros donde se pronunciaban diferentes palabras (p.e. *coco*, *cocacola*, *papá*). Se evaluó la segmentación de inicio y final de las palabras como los fonemas.

| Segmentación | Medida F | RCL | PCR | Valor umbral |
|----------------------------|----------|--------|--------|--------------|
| Prueba F (coef. de aprox.) | 0.7046 | 0.7307 | 0.6804 | 3.54 |
| Cusum (1ra escala) | 0.5681 | 0.5511 | 0.5862 | 0.5475 |
| Kullback (3ra escala) | 0.556 | 0.5054 | 0.618 | 0.157 |

Tabla 4. Desempeño en la segmentación de señales de voz.

Igual que en los casos anteriores la función de medida sobre el dominio de la transformada que presenta la mejor estimación de los límites de los segmentos es la prueba F modificada.

5. 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 análisis de la varianza de los coeficientes presenta una mejor estimación de los límites de los segmentos en señales provenientes de diferentes procesos fisiológicos.

6. 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 Colciencias código 1110-14-17904.

7. BIBLIOGRAFIA

- [1] M. Basseville and I. V. Nikiforov, "Detection of Abrupt Changes Theory and Applications". Prentice Hall, 2000.
- [2] P. de Chazal and R. B. Reilly, "Automatic classification of heart-beats using ECG morphology and heart-beat interval features," *IEEE Trans on Biomedical Engineering*, vol. 51, no. 7, pp. 1196–1206, 2004.
- [3] T. Kemp, P. Schhmidt, M. Westphal, and A. Waibel, "Strategies for automatic segmentation of audio data," *Proc. of the ICASSP 2000*, vol. 3, no. 3, pp. 1423–1426, 2000.
- [4] M. Aboy and H. Falkenberg, "An automatic algorithm for stationary segmentation of extracellular microelectrode recordings," *Medical & Biological Engineering and Computing*, vol. 44, no. 6, pp. 511–515, 2006.
- [5] B. Lovell and B. Boashash, "Segmentation of non-stationary signals with applications," *Proc. of the ICASSP*, vol. 3, no. 3, pp. 2685–2688, 1988.
- [6] E. Hitti and M.-F. Lucas, "Wavelet-packet basis selection for abrupt changes detection in multicomponent signals," *EUSIPCO-98*, September 1998.
- [7] G. P. Nason and B. W. Silverman, "The stationary wavelet transform and some statistical applications," *Notes in Statistics*, vol. 108, pp. 281–289, 1995.
- [8] M. S. Crouse, R. D. Nowak, and R. G. Baraniuk, "Wavelet-based statistical signal processing using hidden markov models," *IEEE Transactions on Signal Processing*, vol. 46, no. 4, pp. 886–902, 1998.