

**EXTRACCIÓN DE CARACTERÍSTICAS DESCRIPTORAS DE MOVIMIENTOS DE  
LA MANO A PARTIR DE SEÑALES ELECTROMIOGRÁFICAS (EMG)  
APLICANDO TÉCNICAS WAVELETS**

**ANEXO A. METODOS DE EXTRACCIÓN DE CARACTERÍSTICAS**



**DIANA PAOLA GASCA DURAN  
LUIS ALVARO ROJAS ROJAS**

**Director  
Ing. HAROLD ARMANDO ROMO ROMERO**

**UNIVERSIDAD DEL CAUCA  
FACULTAD DE INGENIERÍA ELECTRÓNICA Y TELECOMUNICACIONES  
DEPARTAMENTO DE TELECOMUNICACIONES  
GRUPO I+D NUEVAS TECNOLOGÍAS EN TELECOMUNICACIONES  
POPAYÁN  
2007**

## TABLA DE CONTENIDO

|   |           |
|---|-----------|
| <b>A.1. ANALISIS TEMPORAL .....</b>   | <b>1</b>  |
| A.1.1. <i>Características de Hudgins en el Dominio del Tiempo</i> .....   | 7         |
| A.2.1. Series De Fourier .....  | 9         |
| A.2.2. Transformada De Fourier .....  | 10        |
| <b>A.3. COMPARACIÓN DE LOS ÍNDICES CSI DE LAS CARACTERÍSTICAS EN EL<br/>DOMINIO DEL TIEMPO Y LA FRECUENCIA.....</b> | <b>13</b> |
| A.3.1. Comparación WPT-STFT .....   | 13        |
| A.3.2. Comparación DWT-STFT.....  | 14        |
| A.3.3. Comparación WPT-DWT-STFT.....  | 16        |
| A.3.4. Comparación DT - DWT - WPT.....  | 16        |
| <b>REFERENCIAS.....</b>   | <b>20</b> |

## LISTA DE FIGURAS

|  |    |
|--|----|
| Figura 1 Representación de una señal $x(t)$ en el tiempo.....                      | 2  |
| Figura 2. Extracción de características por segmentación de la forma de onda ..... | 7  |
| Figura 3. Señal $x(t)$ y función tiempo-ventana.....                               | 11 |
| Figura 4. Representación Tiempo-Frecuencia con la STFT.....                        | 12 |
| Figura 5. Comparación CSI, WPT-STFT.....   | 14 |
| Figura 6. Comparación CSI, DWT-STFT .....  | 15 |
| Figura 7. Comparación WPT-DWT-STFT .....   | 16 |
| Figura 8. Comparación DT-DWT-WPT .....   | 17 |

## **ANEXO A. METODOS DE EXTRACCIÓN DE CARACTERÍSTICAS**

Existen una gran cantidad de métodos de extracción de características y la selección del método a utilizar depende del tipo de información que se analice (señales, imágenes, entre otros). Además, los métodos que usualmente se aplican están soportados en un análisis temporal (modelos paramétricos, momentos, entre otros) o un análisis frecuencial (transformada de Fourier, transformada wavelets, entre otros).

### **A.1. ANALISIS TEMPORAL**

Cuando se habla de una secuencia de valores observados a lo largo del tiempo, y por tanto ordenados cronológicamente, se le denomina serie temporal. De tal manera que si se conocen los valores pasados de la serie, y no es posible predecir con total certeza el próximo valor de la variable, decimos que la serie es no determinística o aleatoria. Evidentemente aunque el valor futuro de una serie temporal no sea predecible con total exactitud, para que tenga interés su estudio, el resultado tampoco puede ser completamente aleatorio, existiendo alguna regularidad en cuanto a su comportamiento en el tiempo. Por lo tanto, si se pueden encontrar patrones de regularidad, se pueden conformar conjuntos descriptores, que se utilizan en la caracterización de la información sometida al análisis temporal [1].

El primer paso obligatorio para análisis temporal es tener la información de la evolución de la señal a lo largo del tiempo, pudiendo ser representada gráficamente de la siguiente forma:




Figura 1 Representación de una señal  $x(t)$  en el tiempo.

Las características en el dominio del tiempo son generalmente calculadas rápidamente, por que ellas no necesitan ninguna transformación. Algunas de esas características han sido ampliamente investigadas y utilizadas [2], entre las características temporales tenemos:

- *Valor Medio Absoluto (VMA)*: Este es un estimador del valor medio absoluto de la señal  $x_i$ , en el segmento  $i$ , el cual tiene una longitud de  $N$  muestras. Este se puede ser expresada de la siguiente forma:

$$\bar{X}_i = \frac{1}{N} \sum_{k=1}^N |x_k| \quad (1)$$

Donde  $x_k$  es la muestra  $k$ -ésima en el segmento  $i$ .

- *Valor Medio Absoluto de la Diferencia (VMAD)*: Este es el valor medio absoluto de la diferencia entre muestras adyacentes,  $k$  y  $k+1$  y esta definido por [2]:

$$\Delta \bar{X}_i = \frac{1}{N-1} \sum_{k=1}^{N-1} |x_{k+1} - x_k| \quad (2)$$

- *Cruces por cero (CC)* : Es una medida simple de frecuencia y puede ser obtenida por el número de veces que la onda o la señal cruza por cero, a fin

de reducir el ruido inducido por el cruce por cero, se incluye un umbral  $\varepsilon$ . Al considerar dos muestras consecutivas  $x_k$  y  $x_{k+1}$ , CC es incrementado si:

$$\{x_k > 0 \text{ y } x_{k+1} < 0\} \text{ o } \{x_k < 0 \text{ y } x_{k+1} > 0\} \text{ y } |x_k - x_{k+1}| \geq \varepsilon \quad (3)$$

- *Longitud de la Forma de Onda:* es una característica que proporciona información sobre la complejidad de la forma de onda en cada segmento, está se calcula sobre un segmento de tiempo y se define como:

$$l_0 = \sum_{k=1}^N |\Delta x_k| \quad (4)$$

Donde  $\Delta x_k = x_k - x_{k-1}$ . Los valores resultantes indican una medida de la amplitud, frecuencia y duración de la forma de onda, todo esto sobre un solo parámetro.

- *Momentos:*

Los momentos son valores numéricos, que suministran cierta información sobre el comportamiento de una variable. Además, se distinguen dos tipos de momentos, los momentos centrados con respecto del origen y los momentos centrados con respecto de la media [3].

Definición. Dada la variable aleatoria  $X$ , con función de distribución  $F_X(x)$ , se llamara momento de orden  $k$  con respecto al origen a  $m_k$ , siendo  $k$  un número entero positivo. El momento de orden  $k$  se define de la siguiente forma:

$$m_k = \int_{-\infty}^{\infty} x^k dF_X(x) = \begin{cases} \sum_{i=1}^n (x_i)^k P[X = x_i] & \text{cuando } X \text{ es una v.a. discreta} \\ \int_{-\infty}^{\infty} x^k f_X(x) dx & \text{cuando } X \text{ es una v.a. continua} \end{cases} \quad (5)$$

Especial importancia se le suele dar al momento de orden 1 con respecto al origen, que recibe el nombre de valor esperado de la variable aleatoria  $X$  y se le representa generalmente por  $E[X]$ . Con la definición del valor esperado, se deduce que  $m_k = E[X^k]$ .

Definición. Dada la variable aleatoria  $X$ , con función de distribución  $F_X(x)$  y el valor esperado  $E[X]$ , se le llama momento de orden  $k$  con respecto de la media, o simplemente momento centrado de orden  $k$  a  $\alpha_k$ , definido como [3]:

$$\alpha_k = E[(X - E(X))^k] = \int_{-\infty}^{\infty} (x - \mu_x)^k f_x(x) dx \quad (6)$$

El momento con respecto de la media más utilizado es la varianza, que es el momento centrado de orden 2, y se le suele denominar  $V[X]$ . La varianza cumple que:  $V[X] = E[X^2] - (E[X])^2$ . Esta formula, facilita la obtención de la varianza [3].

- *Modelos paramétricos*

Los modelos paramétricos son ampliamente utilizados en diversas áreas para el modelado de procesos, entre las que se pueden nombrar: ingeniería, biología, química, etc. Además son fáciles de analizar y cuentan con técnicas desarrolladas para su análisis. Por otro lado, muchas veces permiten describir de manera simple las características esenciales y por lo tanto generalmente admiten interpretaciones más directas. No obstante, los modelos paramétricos parten de una función de distribución conocida, y reducen el problema a estimar los parámetros que mejor ajusten las observaciones de la muestra. Dichos modelos resultan muy potentes cuando

el proceso generador de datos sigue la distribución propuesta, aunque pueden llegar a ser muy sensibles frente a la violación de las hipótesis de partida cuando se utilizan muestras de reducido tamaño [4].

Supongamos que la variable dependiente  $Y$  puede ser explicada mediante la expresión:

$$Y = f(x_1, x_2, \dots, x_k) + \varepsilon \quad (7)$$

Donde:  $x$  son las variables explicativas

$\varepsilon$  es la perturbación aleatoria

$f(x)$  determina la relación existente entre las variables utilizadas.

Los modelos paramétricos suponen conocida la forma funcional de  $f(x)$ , reduciéndose el problema a determinar los parámetros que la definen. Es necesario estimar los parámetros de los que depende la forma funcional. Sin embargo, la selección de dicha forma funcional se establece a priori, por lo que una elección inadecuada se traducirá en un modelo que no ajuste los datos (por ejemplo, supuesta una relación lineal entre las variables, dicha función presentará un mal ajuste cuando la respuesta es, entre otras, cuadrática).

- *Modelos Autorregresivos*

Dentro de los modelos paramétricos, se encuentran los parámetros autorregresivos, se pueden utilizar para identificar fenómenos transitorios dentro de una señal básicamente ruidosa. Esto se lleva a cabo calculando los coeficientes AR para un tramo corto de la señal y realizando luego un filtrado de la señal completa. La señal es considerada estacionaria, o por lo menos, con variaciones lentas de su nivel continuo [5].



Los coeficientes de un modelo paramétrico AR contienen información acerca de la localización de los picos de la señal. Se ha propuesto [6] que La señal EMG obtenida desde electrodos de superficie sea modelada como una serie de tiempo estocástica. El modelo AR es un modelo estacionario lineal. Aunque la señal EMG no es lineal ni estacionaria, el modelo AR la considera como tal en cortos intervalos de tiempo (100 a 500ms). Por ende, se puede realizar un análisis apropiado de la señal EMG utilizando un modelo AR.

El modelo AR para una señal es:

$$y(k) = -\sum_{i=1}^P a_i y(k-i) + e(k) \quad k = 0, 1, 2, 3, \dots \quad (8)$$

Donde,  $y(k)$  denota la señal,  $a_i$  son los coeficientes AR,  $P$  es el orden del modelo AR y  $e(k)$  es el error de predicción para la señal, cuando la predicción se realiza desde muestras anteriores.

- *Coefficientes Ceptrales (CEP).*

Los coeficientes ceptrales también son obtenidos de métodos paramétricos y contienen información del espectro de la señal. La función Cepstrum está definida como la transformada inversa de Fourier del logaritmo del espectro de potencia de la señal. Para una función de transferencia (todos polos), el primer coeficiente Cepstral puede ser obtenido directamente desde los coeficientes AR de un modelo de orden  $P$ . A partir de este, pueden calcularse el resto de los coeficientes de la siguiente manera [2].

$$c_1 = -a_1 \quad (9)$$

$$c_i = -a_1 - \sum_{n=1}^{i-1} \left(1 - \frac{n}{i}\right) a_n c_{i-n} \quad l < i \leq P \quad (10)$$

En general el uso del método de coeficientes cepstrales permite estadísticamente un mejor reconocimiento, con respecto al uso de los métodos autorregresivos.

### A.1.1. Características de Hudgins en el Dominio del Tiempo

Bernard Hudgins descubrió una componente determinística en la forma de onda del transiente de la señal EMG, impulsando nuevos retos, que dieron origen al siguiente interrogante: ¿Cómo se pueden capturar estructuras temporales en un conjunto de características?. Si se calculan las características en un conjunto de datos completo, la estructura temporal podría perderse, debido a la elevada dimensión del espacio de entrada y la variabilidad del conjunto de características. Por esta razón, se toma el segmento del transiente de la forma de onda y se calculan un conjunto de características basadas en estadísticas sobre cada segmento, esto se ilustra en la figura 2 [8].




Figura 2. Extracción de características por segmentación de la forma de onda

Hudgins intentando minimizar el error de clasificación experimento con diferentes segmentos de longitud. De tal manera, que para patrones altamente estructurados se incrementa el número de segmentos, aumentando la dimensión del conjunto de características y por lo tanto la cantidad de información disponible para el clasificador; para patrones poco estructurados temporalmente, se encuentran segmentos de tiempo más pequeños, resultando una mayor varianza en el conjunto de características, por consiguiente se reduce la separabilidad de clases y se degrada la precisión del clasificador. De acuerdo a resultados empíricos, Hudgins decidió utilizar un esquema de cinco segmentos de 40 ms, mas un segmento extra, incluyendo el valor medio de las características calculadas sobre los 6 segmentos. Las características escogidas para representar los patrones MES fueron: Valor Medio Absoluto (VMA), Valor Medio Absoluto de la Diferencia (VMAD), Cruces por cero (CC) y Longitud de la Forma de Onda [8].

El vector descriptor esta constituido por las características calculadas en cada segmento, por la segmentación de la forma de onda dentro de  $I$  tramas, se especifica un conjunto de características de dimensión:

$$((I + 1)\text{segmentos}) * (F \text{ características}) / \text{segmento} \quad (11)$$

Los segmentos extras incluyen las características promedio. En el análisis de Hudgins se utilizaron cinco segmentos, con una dimensión del conjunto de características igual a 30. Cuando se procesan dos canales de datos, cada canal es sujetó a segmentación y a la extracción de características independientemente, por consiguiente se aumenta la dimensión del conjunto de características, por ejemplo, si 5 segmentos de 40ms se usan en cada canal, el conjunto de características estaría constituido por:

$$((5 + 1)\text{segmentos}) * (5 \text{ características}) / 2 \text{ canales} = 60 \text{ características} \quad (12)$$

## A.2. ANÁLISIS ESPECTRAL.

El Análisis Espectral se define como la transformación de una señal de la representación en el dominio del tiempo hacia la representación en el dominio de la frecuencia, tiene sus raíces a principio del siglo XIX, cuando varios matemáticos lo investigaron desde una base teórica. Pero fue un hombre práctico, un ingeniero con una educación matemática, que desarrolló la teoría en que están basadas casi todas las técnicas modernas de análisis de espectro. Este ingeniero era Jean Baptiste Fourier [9].

### A.2.1. Series De Fourier

La idea básica de las series de Fourier es que una función periódica puede ser representada como una suma ponderada de senos y cosenos. Obteniendo una serie de la forma:

$$x(t) = \frac{a_0}{2} + \sum_1^{\infty} \{ \hat{a}_n \cos(nt) + b_n \text{sen}(nt) \} \quad (13)$$

Esta serie es denominado serie trigonométrica, sin embargo es llamada serie de Fourier, si es posible obtener todos los coeficientes  $a_n$  y  $b_n$  mediante una integración de la función  $x(t)$  de la siguiente manera:

$$a_0 = \frac{1}{\pi} \int_0^{2\pi} x(t) dt \quad (n = 0, 1, 2, \dots) \quad (14)$$

$$a_n = \frac{1}{\pi} \int_0^{2\pi} x(t) \cos(nt) dt \quad (n = 0, 1, 2, \dots) \quad (15)$$

$$b_n = \frac{1}{\pi} \int_0^{2\pi} x(t) \text{sen}(nt) dt \quad (n = 0, 1, 2, \dots) \quad (16)$$

La obtención de los coeficientes de la forma en que se expresa la ecuaciones (11), (12), (13) es posible gracias a la ortogonalidad existente entre las funciones coseno y seno, y entre si mismas para valores de  $n$  diferentes [10].

### A.2.2. Transformada De Fourier

Uno de los procedimientos matemáticos con mayor aplicación en el procesamiento de señales esta basado en las variaciones de la transformada de *Fourier* (FT), la cual permite expresar una señal periódica como la suma de infinitas exponenciales complejas periódicas tal como se muestra en la siguientes ecuaciones:

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-2\pi \cdot ft} dt \quad (17)$$

$$x(t) = \int_{-\infty}^{+\infty} X(f) e^{2\pi \cdot ft} df \quad (18)$$

Donde las ecuaciones (17) y (18), corresponden a la transformada directa e inversa de Fourier, respectivamente. La información que se obtiene mediante esta transformada corresponde al contenido frecuencial de la señal y permite conocer sus respectivos aportes energéticos, es decir, presenta una perfecta resolución en frecuencia que la hace una herramienta muy útil para el análisis de señales estacionarias. No obstante, esta no permite conocer de manera precisa cuando se encuentran las diferentes componentes de frecuencia en la señal, como es el caso de señales cuasi-estacionarias o no estacionarias cuyo contenido espectral varia con el tiempo, lo cual significa que la transformada de fourier posee una muy pobre resolución en el tiempo.

Ante esto Dennis Gabor en 1946 realizó una adaptación a la transformada de Fourier para tratar de superar esa deficiencia, la nueva adaptación consistió en analizar la señal por secciones. El proceso se lleva a cabo mediante la multiplicación de una ventana con la señal. Gabor le llamó a esta técnica *Short-*

*Time Fourier Transform (STFT)*, la cual tiene su representación matemática como se muestra enseguida [11]:

$$STFT(T, W) = \int_{-\infty}^{\infty} x(t)h^*(\tau - t)e^{-j\omega t} dt \quad (19)$$

Ahora bien, el soporte de la ventana constituye un parámetro de gran importancia ya que establece un compromiso entre la resolución en el tiempo y la resolución en frecuencia, de tal manera que al establecer una ventana angosta se analiza una pequeña parte de la señal, teniéndose una buena resolución en tiempo pero pobre en frecuencia ya que se conoce solo una pequeña fracción del espectro de la señal. Por el contrario, si la ventana es muy ancha se tiene una buena resolución en frecuencia pero pobre en resolución en el tiempo. En el caso de una ventana de ancho infinito, corresponde a la transformada de Fourier clásica. Desafortunadamente, esta transformación no resuelve del todo las limitaciones que la FT presenta por que no hace una resolución adecuada en tiempo y frecuencia por ser la función ventana de ancho fijo, lo cual se refleja en la figura 3.





Figura 3. Señal  $x(t)$  y función tiempo-ventana.

Lo anterior también se puede ilustrar con el respectivo plano tiempo-frecuencia correspondiente a la transformada de Fourier de tiempo corto de una señal  $x(t)$ , lo cual se ilustra en la figura 4.



**Figura 4. Representación Tiempo-Frecuencia con la STFT**

Lo anterior contrasta con el principio de incertidumbre de *Heisenberg* [2]. Este principio, originalmente aplicado al momento y posición de una partícula, puede aplicarse a la información tiempo-frecuencia de una señal. Éste establece que no es posible conocer la representación tiempo-frecuencia exacta de una señal, es decir, no se puede saber qué componentes frecuenciales existen en ciertos instantes de tiempo. Sin embargo, es posible conocer los intervalos de tiempo en los cuales existen ciertas bandas de frecuencia. Debido a lo anterior el análisis de Fourier se queda corto cuando se desea analizar señales no estacionarias y por lo tanto la *teoría wavelets* es una excelente herramienta para analizar este tipo de señales, en nuestro caso las EMG.

### **A.2.3. MOMENTOS ESPETRALES DE UNA SEÑAL**

Se puede expresar una señal como una función del tiempo  $x(t)$  y por medio de su transformada de Fourier  $\hat{x}(\omega)$  describirla en función de la frecuencia. Multiplicando  $\hat{x}(\omega)$  por su conjugado se obtiene el espectro de potencia  $S(\omega) = \hat{x}(\omega)\hat{x}^*(\omega)$  de la señal. Se define el momento espectral de orden  $k$  como [12]:

$$m_k = \frac{1}{2\pi} \int_{-\infty}^{\infty} w^k S(w) dw. \quad (20)$$

La descripción de frecuencias obtenidas por medio de la transformada de Fourier es simétrica con respecto a la frecuencia 0, de manera que, por ser una señal real se verifica que  $\hat{x}(-w) = \hat{x}(w)$ , entonces  $S(-w) = S(w)$  y por lo tanto  $w^k S(w)$  es una función impar si  $k$  lo es. Como consecuencia, todos los momentos espectrales impares son cero [12].

### A.3. COMPARACIÓN DE LOS ÍNDICES CSI DE LAS CARACTERÍSTICAS EN EL DOMINIO DEL TIEMPO Y LA FRECUENCIA.

En esta parte se realizan algunas pruebas de comparación entre los índices CSI de características extraídas con las transformadas DWT, WPT, STFT y algunas características en el dominio del tiempo.

#### A.3.1. Comparación WPT-STFT

Al aplicar la STFT sobre las señales EMG que representan los diferentes movimientos, se observa que la caracterización con WPT es superior a la caracterización utilizando la STFT, como se aprecia en la tabla 1. En esta prueba se utiliza una ventana Hamming de 64 puntos, con un traslape del 50%. Se utiliza la STFT con estas condiciones porque con esta se obtuvo el mejor resultado en un trabajo realizado por Englehart [4].

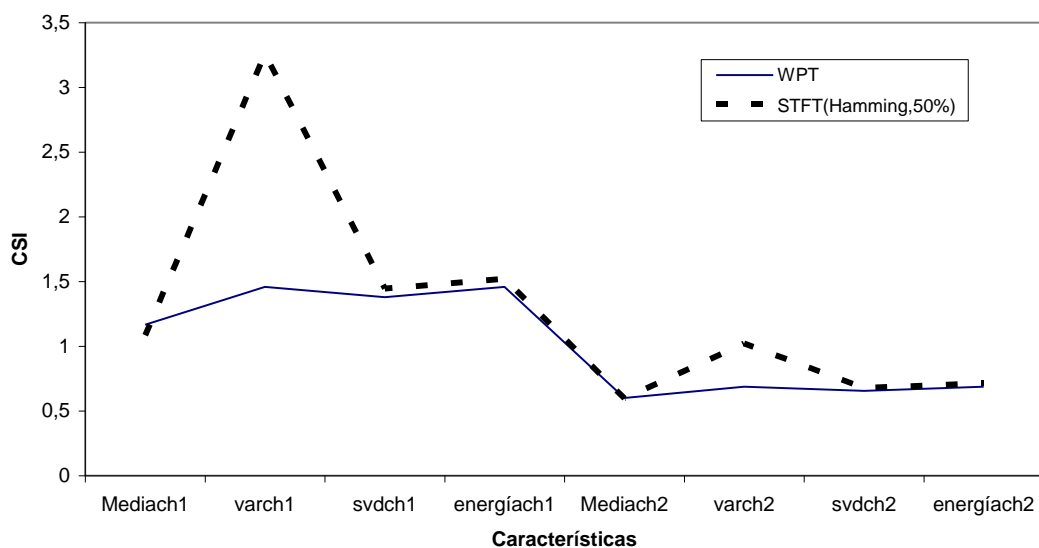
Tabla 1. Comparación CSI, WPT-STFT

|                 | WPT    | STFT(Hamming,50%) |
|-----------------|--------|-------------------|
| <i>Mediach1</i> | 1,1665 | 1,085             |
| <i>varch1</i>   | 1,4582 | 3,258             |
| <i>svdch1</i>   | 1,3782 | 1,446             |



|                   |        |        |
|-------------------|--------|--------|
| <i>energíach1</i> | 1,4590 | 1,521  |
| <i>Mediach2</i>   | 0,6005 | 0.5967 |
| <i>Varch2</i>     | 0,6873 | 1.0208 |
| <i>Svdch2</i>     | 0,6548 | 0.6779 |
| <i>Energíach2</i> | 0,6879 | 0.7136 |

Los resultados anteriores se pueden visualizar mejor en la figura 5.



**Figura 5. Comparación CSI, WPT-STFT**

En la figura 5 se observa que la curva del índice CSI de la WPT esta por debajo de la curva de la STFT, lo cual significa que se obtiene una mejor caracterización utilizando la WPT.

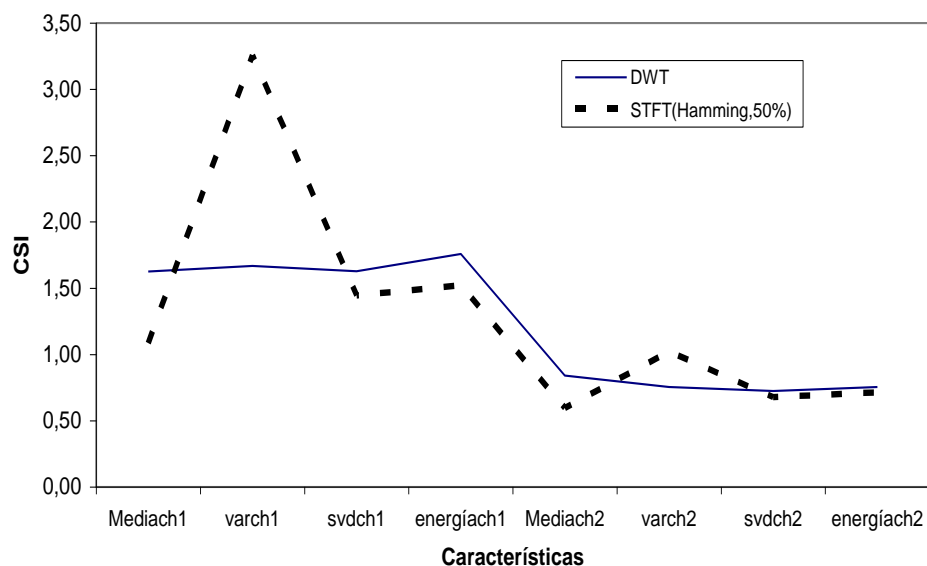
### A.3.2. Comparación DWT-STFT

Al comparar la caracterización utilizando STFT y la caracterización utilizando DWT se obtuvieron los resultados obtenidos en la tabla 2.

**Tabla 2. Comparación CSI, DWT-STFT**

|                   | DWT   | STFT(Hamming,50%) |
|-------------------|-------|-------------------|
| <i>Mediach1</i>   | 1,626 | 1,085             |
| <i>varch1</i>     | 1,667 | 3,258             |
| <i>svdch1</i>     | 1,629 | 1,446             |
| <i>energíach1</i> | 1,757 | 1,521             |
| <i>Mediach2</i>   | 0,608 | 0,423             |
| <i>Varch2</i>     | 0,596 | 1,171             |
| <i>Svdch2</i>     | 0,469 | 0,502             |
| <i>Energíach2</i> | 0,503 | 0,547             |

Los resultados de la tabla 2, se puede observar en la figura 6.



**Figura 6. Comparación CSI, DWT-STFT**

En la figura 6, se puede apreciar que la varianza en la STFT tiene un índice CSI muy alto, teniendo en cuenta que la varianza es una medida muy importante en un proceso de clasificación y caracterización debido a que esta mide la aleatoriedad de la señal se puede concluir que la DWT tiene un comportamiento regular lo cual es muy beneficioso en procesos de este tipo.

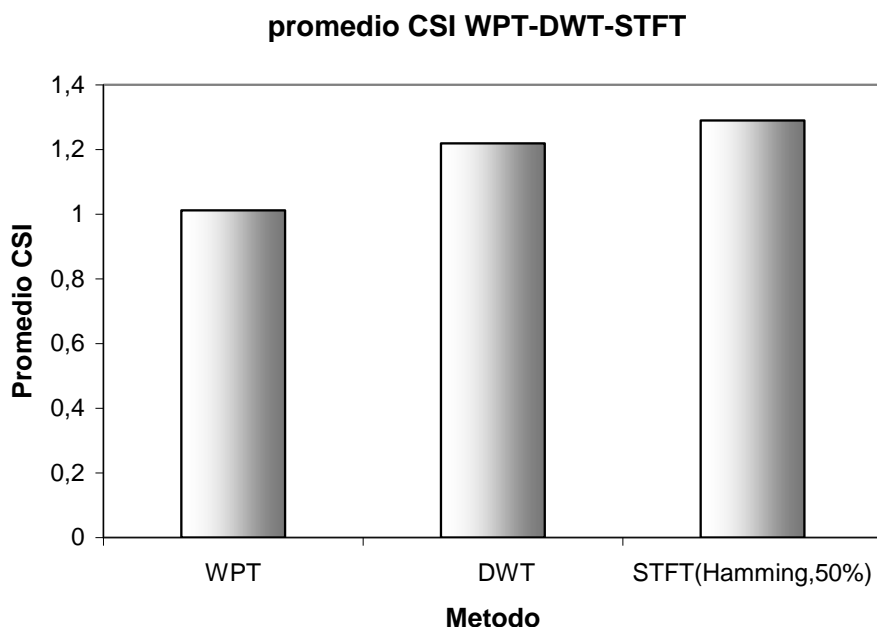
### A.3.3. Comparación WPT-DWT-STFT

Para apreciar con cual método se obtiene una mejor caracterización, se realiza un promedio de los diferentes CSI obtenidos en dos canales, los resultados se muestran en la tabla 3.

**Tabla 3. Comparación WPT-DWT-STFT**

|                     | WPT   | DWT   | STFT(Hamming,50%) |
|---------------------|-------|-------|-------------------|
| <i>promedio CSI</i> | 1,011 | 1,218 | 1,289             |

Los resultados de la tabla 3, se aprecian en la figura 7.



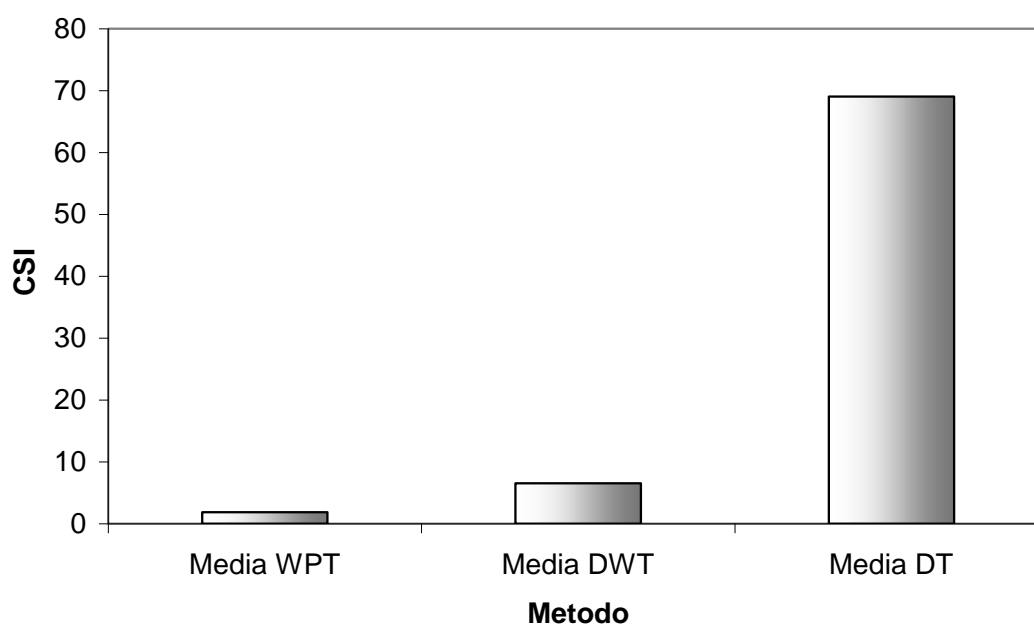
**Figura 7. Comparación WPT-DWT-STFT**

De la Figura 7, se concluye que la caracterización utilizando DWT y WPT es mejor que la caracterización utilizando STFT.

### A.3.4. Comparación DT - DWT - WPT.

En el dominio del tiempo se extrajeron las características de la media y la longitud onda, obteniendo una buena separabilidad entre clases. No obstante, al no extraer

las mismas características en el dominio wavelet no se puede realizar una comparación directa con este método, pero según pruebas realizadas se encontró que en determinados canales se encuentra índices CSI muy altos, para la media, y estos se disminuyen notablemente, cuando se implementan los métodos de DWT, WPT, lo anterior se ilustra en la figura 8.



**Figura 8. Comparación DT-DWT-WPT**

## REFERENCIAS

- [1] Molinero L. "Análisis de series temporales", Liga Española para la lucha contra la Hipertensión Arterial, 2004.
- [2] Zecca M., Micera S., Carrozza M. "Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal". ARTS Lab, Scuola Superiore Sant'Anna, Pontedera, Italy. 2002.  
Disponible en: [http://www.robocasa.net/people/zecca/2002/Zecca02\\_CRBE.pdf](http://www.robocasa.net/people/zecca/2002/Zecca02_CRBE.pdf)
- [3] Meyer L. "Probabilidad y Aplicaciones Estadísticas". Addison Wesley Iberoamericana. 1992.
- [4] Bonilla M., García L. Medina R. "La precisión de los Arboles de Regresión en la determinación del spread en un mercado primario de renta fija". Universidad Politécnica de Valencia. 2002.
- [5] Gutierrez J. "comparación De Métodos Autorregresivos Para La Detección De Artefactos En Señales ECG", Universidad Tecnológica
- [6] Farfán F., Politti J., Carmelo J. "Evaluación de Patrones Temporales y Espectrales para el Control Bioeléctrico". Departamento de Bioingeniería. 2002
- [8] Englehart K. "Signal Representation for Classification of the Transient Myoelectric Signal". Doctoral Thesis. University of New Brunswick, Fredericton, New Brunswick, Canada. 1998.  
Disponible en: <http://www.ece.unb.ca/kengleha/thesis/phd.htm>
- [9] <http://www.dliengineering.com/vibman-spanish/Análisis de Espectro.htm>
- [10] Castro R., Martínez J. "Análisis de la Teoría de Ondículas orientadas a las aplicaciones de ingeniería eléctrica". E T S I, Industriales Departamento de Ingeniería Eléctrica, Madrid. 2002.
- [11] Mertins A. "Signal Analysis Wavelets, Filter Banks, Time-Frequency Transforms and Applications". University of Wollongong, Australia. John Wiley & Sons. 1999.
- [12] Navascues M., Victoria M. "Formula Fractal De La Energía De Una Señal Muestreada". 2001.