

COMPARACIÓN DE MÉTODOS DE CARACTERIZACIÓN DE SEÑALES MER

Feature extraction methods comparison on MER signals

RESUMEN

En este documento presenta una comparación de los métodos propuestos para la caracterización de señales provenientes de microelectrodos de registro (MER) para la identificación de zonas cerebrales que intervienen en la cirugía de la enfermedad de Parkinson. Los mejores porcentajes de acierto se obtienen utilizando como método de caracterización la transformada wavelet, 97.37% y 71.4% para 2 y 4 clases respectivamente.

PALABRAS CLAVES: caracterización, MER, enfermedad de parkinson.

ABSTRACT

This document presents a microelectrode registers feature extraction methodologies comparison for brain zones identification found in Parkinson's disease surgery. Best results are obtained using wavelet transforms, 97.37% and 71.4% for 2 and 4 classes, respectively.

KEYWORDS: *feature extraction ,MER signals, Parkinson's Disease..*

CRISTIAN GUARNIZO

Ingeniero Electricista, M. Sc.
Profesor Catedrático
Universidad Tecnológica de Pereira
cdguarnizo@ohm.utp.edu.co

ALVARO A. OROZCO

Ingeniero Electricista, Ph.D(c).
Profesor Titular
Universidad Tecnológica de Pereira
aaog@utp.edu.co

JULIAN D. ECHEVERRY

Ingeniero Electrónico, M. Sc.
Profesor Auxiliar
Universidad Tecnológica de Pereira
jdec@ohm.utp.edu.co

1. INTRODUCCIÓN

La enfermedad de Parkinson (EP) es un grupo de desórdenes neurológicos caracterizados por hipoquinesia, temblor y rigidez muscular. Produciendo una lesión, una estimulación, o bien depositando células en las zonas conocidas como globus pallidus internus (GPi), núcleo subtalámico (STN) y/o Ventral Intermedio (Vim) Talámico es posible aliviar los síntomas de la EP. Con el fin de localizar estas zonas, la neurocirugía requiere inicialmente una trayectoria estimada a partir de una comparación entre el atlas del cerebro e imágenes de resonancia magnética, pero el punto exacto de la zona objetivo presenta errores debido a diferencias fisiológicas en las imágenes [1].

Para identificar correctamente las zonas se inserta un microelectrodo que estimula y registra la actividad bioeléctrica de las neuronas que lo rodean y dicha actividad almacenada permite al neurofisiólogo interpretar los registros para determinar la zona objetivo con cierto grado de subjetividad [1]. En trabajos previos se ha analizado este tipo señales observando el comportamiento estadístico de los disparos generados por la región neuronal más cercana al microelectrodo [2, 3]. También se han presentado trabajos donde se analiza el comportamiento frecuencial del ruido de fondo [4] o se estiman los parámetros de un modelo autoregresivo que representa la función de transferencia de un sistema [5].

2. MATERIALES Y MÉTODOS

2.1 Base de datos MER

Para la validación de los resultados se cuenta con registros electrónicos de las zonas cerebrales tálamo (TAL) 43 registros, subtalamo (STN) 25 registros, sustancia negra (SN) 24 registros y zona incerta (ZI) 85 registros, muestreados a 24kHz.

Los primeros métodos de caracterización propuestos para este tipo de señales se basan en extraer la información temporal dada por los potenciales de acción presente en los registros [2, 3]. Los otros métodos consisten en extraer información frecuencial de las señales, utilizando ventanas de tamaño fijo que se desplazan sobre la señal [5]. A continuación se describen los métodos empleados para caracterizar estas señales:

2.2 Intervalo entre espigas

El intervalo entre espigas (ISI – Inter Spike Interval), se genera a partir de la señal como un vector de tiempos que contienen las diferencias temporales entre una espiga y la previa. De este vector se extraen los siguientes parámetros [2]:

1. Longitud promedio del ISI.
2. Desviación estándar del ISI.
3. Máxima longitud del ISI.
4. Mínima longitud del ISI.
5. Promedio de la frecuencia instantánea. La frecuencia instantánea (IF) se define como el valor del recíproco de los valores del ISI. El

- promedio de la frecuencia instantánea se calcula como la media de los valores de los valores IF .
6. Desviación estándar de la frecuencia instantánea.
 7. Relación de contenido de alta frecuencia (HFCR - *High Frequency Content Ratio*). Se calcula como el número de datos del vector del ISI menores al parámetro HFCR (definido como 5ms), dividido por el número total de datos de ISI en cada vector.
 8. Relación de contenido de baja frecuencia (LFCR - *Low Frequency Content Ratio*). Se calcula como el número de datos del vector del ISI mayores al parámetro LFCR (definido como 300ms), dividido por el número total de datos de ISI en cada vector.
 9. Dispersión. Definida como la varianza de los valores del ISI dividida por la longitud promedio del ISI.
 10. Índice de dispersión. La diferencia entre la máxima longitud del ISI y la mínima longitud del ISI dividida entre la longitud media.
 11. Índice de ruptura (*Burst Index*). Se calcula como el número de valores del ISI menores que el parámetro *Burst* (definido como 10ms) dividido por el número de valores del ISI mayores a este parámetro.
 12. Índice de asimetría. La moda del ISI se define como el intervalo del histograma con mayor valor; de esta forma el índice de asimetría se calcula como la moda dividido por el valor medio del ISI. Si varios intervalos del histograma tienen el mismo número de valores de ISI, el índice de asimetría toma el valor de cero.
 13. Índice de pausa. Es el número de valores del ISI mayores que el parámetro de pausa (definido como 50 ms) dividido por el número de valores del ISI menores que el parámetro de pausa.
 14. Relación de pausa. Es el tiempo acumulativo de los valores del ISI mayores que el parámetro de pausa, dividido por el tiempo acumulativo de los valores del ISI menores que el parámetro de pausa.

2.3 Tren binario de espigas

Este método al igual que el anterior utiliza la información temporal dada por las espigas [3]. A continuación se explica con más detalle este procedimiento:

1. El tren de espigas se convierte es una señal digital binaria. Esto involucra configurar un arreglo de ceros, donde cada elemento representa un intervalo de tiempo. Si en dicho intervalo aparece una espiga, entonces a esta posición se le asigna un uno.
2. Posteriormente la señal digital binaria es muestreada con dos ventanas móviles de tamaño finito. Por ejemplo, una ventana de tamaño 8

3. El número de unos en cada palabra binaria se cuenta convirtiendo cada de palabras binarias de 8 bit en un par de enteros. Por ejemplo si un par de palabras de 8 dígitos fueran 01110101 y 10011001, esto será convertido al par entero 5,4.
4. Los enteros generados por cada ventana son utilizados para crear un histograma de dos dimensiones.
5. Las entradas 0,0 fueron eliminadas para el cálculo del histograma, debido a que el par más común eran todo ceros, lo cual no aportaba información sobre el tren de espigas. Adicionalmente el histograma fue normalizado dividiendo por el número de entradas y haciendo una conversión en logaritmo natural. Este último paso se hace para evitar problemas con histogramas generados de diferentes trenes de espigas de duraciones diferentes.

Cada histograma se genera con 21 divisiones, obteniéndose así $21 \times 21 = 441$ valores. Estos 441 valores forman un solo punto en el espacio de características.

2.4 Coeficientes de predicción lineal

La forma de caracterización utilizada en [5] consiste en obtener un modelo auto regresivo para cuantificar la estructura temporal de las señales neuronales. Este aproxima muestras futuras como una combinación lineal de muestras previas usando la siguiente ecuación:

$$\hat{s} = \sum_{k=1}^p a_k s(n-k)$$

donde $s(n)$ es la señal original, \hat{s} es la señal predicha, a_k son los coeficientes del predictor y p es el orden de predicción. Se determina un conjunto único de coeficientes de predicción para cualquier señal minimizando la suma del cuadrado de las diferencias entre la muestra actual y las predichas linealmente. Estos coeficientes sirven como un criterio de identificación. Se utiliza el método de autocorrelación para calcular los coeficientes del predictor. Minimizando el error de predicción con este procedimiento lleva a la matriz Toeplitz de la forma:

$$\begin{bmatrix} R(0) & R(1) & \cdots & R(p-1) \\ R(1) & R(0) & \cdots & R(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ R(p-1) & R(p-2) & \cdots & R(0) \end{bmatrix}$$

R en la ecuación anterior representa la función de autocorrelación de tipo corto. Al algoritmo recursivo de Levinson-Durbin es utilizado para solucionar el sistema de ecuaciones [5]. Se recuerda que el análisis LPC estima filtros con respuesta en frecuencia de la forma:

$$H(z) = \frac{1}{1 - a_1 z^{-1} + a_2 z^{-2}}$$

Si existe alguna diferencia en las componentes frecuenciales (ancho de banda) encontradas en cada tipo de señal, se verá reflejado en los valores de los coeficientes.

2.5 Coeficientes Wavelet

Para este método no es necesario determinar la ubicación temporal de las espigas. La caracterización se realiza calculando la transformada wavelet (3 niveles de descomposición usando como base la wavelet Daubechies 10) de segmentos de 800ms traslapados un 50% para cada señal. A cada segmento transformado en el espacio wavelet, se le calculan los siguientes parámetros por nivel de descomposición: de los coeficientes de los diferentes niveles de descomposición realizados sobre el segmento de la señal, se extraen características de los coeficientes wavelet son [6]:

$$\begin{aligned} \mu_n^l &= \frac{1}{K} \sum_{k=1}^K |d_k^l| \\ E^l &= \frac{1}{2} \sum_{k=1}^K (d_k^l)^2 \\ m_n^l &= \max(|d_k^l|) \\ SVD &= \sqrt{\lambda(C^T C)} \end{aligned}$$

Donde E^l es la energía, μ_n^l es la media normalizada y m_n^l es el máximo absoluto de los coeficientes de la escala l , SVD es la raíz cuadrada de los valores propios de la matriz $C^T C$. La matriz C se obtiene indexando en filas los coeficientes de los diferentes niveles descomposición como se muestra en la figura 1.

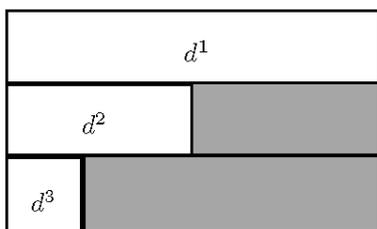


Figura 1. Construcción de la matriz C, región gris compuesta de ceros

3. RESULTADOS Y DISCUSIÓN

Se realizaron pruebas de clasificación utilizando los diferentes métodos descritos en la sección anterior empleando un clasificador bayesiano lineal. Este último para observar que características son más discriminantes. La validación se realiza utilizando validación simple 10 repeticiones (70% entrenamiento y 30% prueba). A continuación se muestran los porcentajes de acierto utilizando 2 clases y 4 clases:

Método	TAL	STN	Total
ISI	82.5	97.14	87.89±8.25
DST	100	1.43	63.68±1.66
LPC	96.67	97.14	96.84±2.72
Wavelet	95.83	100	97.37±2.77

Tabla 1. Porcentajes de acierto para 2 clases

Método	TAL	STN	SN	ZI	Total
DST	65	82.86	27.14	31.2	46.47±5.39
LPC	57.5	74.29	64.29	27.6	59.22±7.94
Wavelet	73.3	72.9	92.9	64	71.4±3.2

Tabla 2. Porcentajes de acierto para 4 clases

En la Tabla 1 y 2 se observa que el método que presenta mejor desempeño es la caracterización utilizando la transformada wavelet. Los métodos basados en extraer características a partir de la información temporal dada por la espigas presentan un porcentaje de acierto bajo debido que no consideran parte de la señal que permite discriminar las clases (ruido de fondo, componentes frecuenciales de la señal). Se puede mejorar la caracterización realizada con LPC si se utilizaran más parámetros (más grados de libertad) para estimar las funciones que representan cada tipo de señal.

4. CONCLUSIONES

Comparando los diferentes métodos de caracterización de señales MER de determina que la caracterización basada en la transformada wavelet supera los métodos anteriormente propuestos.

No se obtienen buenos resultados utilizando los métodos basados en la información temporal de las espigas, debido que no se procesa información que contiene las señales originales para ayudar a discriminarlas.

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

1. Las notas de pie de página deberán estar en la página donde se citan. Letra Times New Roman de 8 puntos

Colciencias código 1110-14-17904 y la Universidad Tecnológica de Pereira código 511-3-243-6.

6. BIBLIOGRAFÍA

- [1] Amimovin R, Williams ZM, Cosgrove GR, Eskandar EN. Experience with microelectrode guided subthalamic nucleus deep brain stimulation. *Neurosurgery*. 2006 Feb;58(1 Suppl).
- [2] Q. Fu, M. Clements, K. Mewes, "Neural Cell Type Recognition Between Globus Pallidus Externus and Globus Pallidus Internus By Gaussian Mixture Modeling." In: *Proceedings ICASSP*, Vol. 1, pp. 53–56, 2005.
- [3] Santiago, R., McNames, J., Burchiel, K., Lendaris, G., "Developments in understanding neuronal spike trains and functional specializations in brain regions," *Neural Networks* 16, 601–607, 2003.
- [4] P. Novak, S. Daniluk, S. Ellias and J. Nazzaro, "Detection of the subthalamic nucleus in microelectrographic recordings in Parkinson disease using the high frequency (> 500 Hz) neuronal background," *Journal of Neurosurgery*, 106, pp. 175-179, 2007.
- [5] J. Sanchez, J. Pukala, J.C. Principe, F. Bova, and M Okun, "Linear predictive analysis for targeting the basal ganglia in deep brain stimulation surgeries", In: *Proceedings of the conference on 2nd int ieee workshop on neural engineering*, 2005.
- [6] X. Zhang, Y. Yang, and X. XU, "Clinical detection and movement recognition of neuro signals," *Journal of Zhejiang University SCIENCE*, 2004.