

CLASIFICACIÓN DE ARRITMIAS UTILIZANDO ANFIS, REDES NEURONALES Y AGRUPAMIENTO SUBSTRACTIVO

RESUMEN

Se presenta una metodología para la caracterización y clasificación de señales electrocardiográficas utilizando métodos no lineales tales como la entropía de Shannon y la complejidad de Lempel-Ziv, y se ilustra la efectividad de los sistemas de inferencia difusos y neuro difusos frente a las redes neuronales como clasificadores.

PALABRAS CLAVES: Clasificación, sistemas de inferencia neurodifusos, agrupamiento substractivo, redes neuronales.

ABSTRACT

We present a methodology to obtain features and classify electrocardiographic signals using non linear methods such as Shannon entropy and Lempel-Ziv complexity. We show the effectiveness of the fuzzy inference and neuro fuzzy systems against neural networks as classifiers.

KEYWORDS: *Classification, substractive clustering, neuro fuzzy inference systems, neural networks.*

ALFONSO ALZATE

Ingeniero Electricista, Ms.C
Profesor Titular
Universidad Tecnológica de Pereira
alalzate@utp.edu.co

EDUARDO GIRALDO

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

Grupo de Investigación en Control e Instrumentación.

1. INTRODUCCIÓN

La electrocardiografía permite conocer la actividad eléctrica del corazón. El estado de la salud cardiaca es generalmente reflejado por la forma de onda de la señal ECG y la variabilidad del ritmo cardiaco (HRV). Un electrocardiograma puede contener importantes avisos de la naturaleza de la enfermedad que afecta al corazón.

El sistema cardiovascular es demasiado complejo para ser lineal y si intuitivamente se trata como un sistema no lineal se puede obtener un mejor entendimiento de la dinámica del sistema. En el 2000, Sun y otros [1] desarrollaron una técnica no lineal para la detección de arritmias a partir de la señal ECG. Khadra y otros [2] en 1997 presentaron la clasificación de arritmias cardiacas usando la transformada wavelet y las redes neuronales de base radial. En el 2002, Dingfel y otros [3] clasificaron arritmias cardiacas en seis clases usando modelamiento paramétrico autoregresivo. En [4], se presenta una metodología para la clasificación de arritmias usando la entropía, el diagrama de Poincaré y el máximo exponente de Lyapunov.

En el presente trabajo, se utiliza la entropía de Shannon, y la complejidad de Lempel-Ziv como base para la clasificación de arritmias sobre señales ECG en cuatro clases. Se extraen dos parámetros o características no lineales para ser usados en la clasificación como lo propuso Acharya y otros en [4]. Se utilizan sistemas de inferencia difusos con agrupamiento substractivo y neuro difusos (ANFIS) para la clasificación, y finalmente se comparan los resultados obtenidos con las redes neuronales artificiales, evaluando su desempeño. En la

sección 2 se dan las definiciones necesarias referentes a la extracción de características no lineales, en la sección 3 se presenta el marco experimental, y en la sección 4 se muestran los resultados de clasificación obtenidos para cuatro clases de arritmias y se comparan con los porcentajes de clasificación al aplicar redes neuronales artificiales, finalmente en la sección 5 se presenta el análisis de los resultados obtenidos.

2. EXTRACCIÓN DE CARACTERÍSTICAS

El análisis de señales ECG desde el punto de vista de la dinámica no lineal presenta ventajas sobre el análisis lineal pues permite realizar una mejor descripción de la dinámica de cambio de las señales, si se considera este proceso un proceso no lineal [1]. A continuación se describen los métodos propuestos para el análisis de señales en este trabajo.

2.1. Entropía de Shannon

La entropía es una medida que cuantifica la incertidumbre presente en un conjunto de datos debido a su cantidad de información. Sea

$$f(p(X_k)) = -p(X_k) \log_2(p(X_k)), 0 \leq p(X_k) \leq 1$$

donde $p(X_k)$ es la probabilidad de que una variable aleatoria X tome el valor de k (que representa el tamaño del alfabeto), con $k = 1, 2, \dots, N$. Por lo tanto, la función $f(p(X_k))$ es igual a cero cuando $p(X_k) = 0$ y $p(X_k) = 1$, y positiva para valores intermedios,

hallándose su máximo valor ($f(p(X_k)) = 1$) cuando $p(X_k) = 0.5$. A partir de esta expresión, la entropía de Shannon (entropía de información) se define como

$$H(X_k) = \sum_k f(p(X_k))$$

De este modo, la entropía de un conjunto de datos se puede interpretar como el grado de información que proporciona su observación; entre mayor sea la incertidumbre en la observación del conjunto de datos, mayor es su valor de entropía.

2.2. Complejidad de Lempel-Ziv

El cálculo de la complejidad Lempel-Ziv permite estimar qué tan compleja o irregular es una serie de tiempo. En este sentido, el ruido blanco tiene la máxima complejidad posible. Se mide el número de patrones distintos que deben ser copiados para reproducir una secuencia dada. Sea una secuencia de datos $\mathbf{X} = x_1, x_2, \dots, x_n$, a la cual se le realiza un recorrido de izquierda a derecha, y cada vez que se encuentra una subsecuencia nueva, denotada como Q , se incrementa un contador de complejidad c . Para una misma secuencia se repite el procedimiento tomando segmentos cada vez mayores de la secuencia, partiendo siempre del primer elemento de la misma. Al terminarse la secuencia \mathbf{X} , el número resultante c es su medida de complejidad. Para completar el análisis, se debe tener en cuenta que solo tienen sentido los valores relativos de c , por tal motivo, este valor se divide entre el tamaño de la secuencia.

3. MARCO EXPERIMENTAL

Las pruebas para clasificación de arritmias se realizan sobre señales tomadas de la base de datos de arritmias del MIT. La base de datos de arritmias MIT-BIH contiene 48 fragmentos de media hora de dos canales de registros electrocardiográficos ambulatorios, obtenidos de 47 pacientes estudiados por el Laboratorio de Arritmias BIH entre 1975 y 1979. Los registros fueron digitalizados a 360 Hz por canal con una resolución de 11 bits sobre un rango de 10 mV. En el desarrollo de este trabajo se creó un subconjunto de datos de 4 tipos de latidos (3 diferentes arritmias y latidos normales) con 50 ejemplos para cada uno, así:

- Bloqueo de rama derecha (LBBB)
- Latido normal (N)
- Contracción ventricular prematura (PVC)
- Fibrilación ventricular (VF)

Se extraen 2 características por cada señal ECG segmentada como se observa en la figura 1, para un total de 50 patrones por arritmia. Las características no

lineales seleccionadas por señal son la entropía de Shannon y la complejidad de Lempel-Ziv.

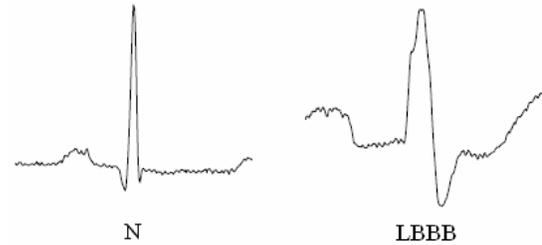


Figura 1. Segmentos de ECG normal (N) y con bloqueo de rama derecha (LBBB).

4. CLASIFICACIÓN

El conjunto de características extraídas para los cuatro tipos de arritmias (LBBB, N, PVC, VF) se muestra en la figura 2, donde se observa la separación entre clases

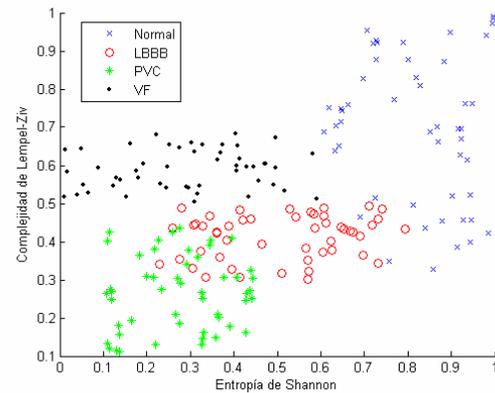


Figura 2. Entropía de Shannon vs. Complejidad de Lempel-Ziv.

Se seleccionaron 25 patrones por clase como conjunto de datos de entrenamiento. Los datos de entrenamiento se organizaron de tal forma que se lograra diferenciar las clases con una sola salida.

Se utilizó como clasificador un sistema de inferencia neuro-difuso del tipo Sugeno con 3 entradas, dos funciones de pertenencia por entrada del tipo gaussianas, y una salida del tipo constante, dado por [5] y [6], así

$$f(x) = \frac{\sum_{l=1}^M w^l \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)}{\sum_{l=1}^M \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)}$$

donde $f(x)$ es el valor de salida que corresponde a la clase, x_i es el valor de la entrada en la función de pertenencia i , w^l corresponde al valor de la constante

en la función de salida, μ_{A_i} es la función de pertenencia i para la entrada l , M es el número de entradas y n es el número de funciones de pertenencia por entrada. Para la base de reglas se tienen en cuenta todas las combinaciones posibles, en total M^n . La estructura del sistema difuso generado se observa en la figura 3.

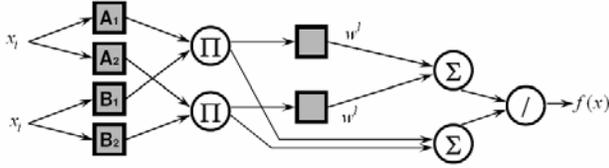


Figura 3. Estructura del sistema neurodifuso construido.

Las funciones de pertenencia se ubican inicialmente igualmente espaciadas. Después de ser entrenado, se logra un sistema del tipo Sugeno [7], con las funciones de pertenencia en las entradas como se muestra en las figuras 4 y 5.

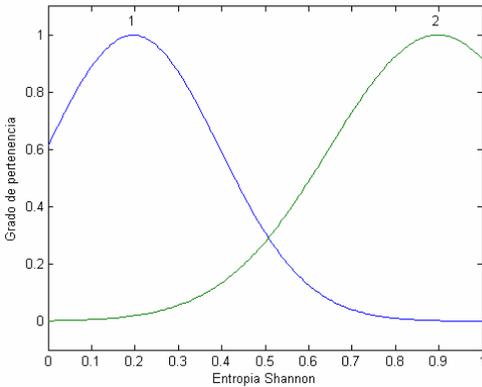


Figura 4. Funciones de pertenencia para la entrada 1 (Entropía de Shannon).

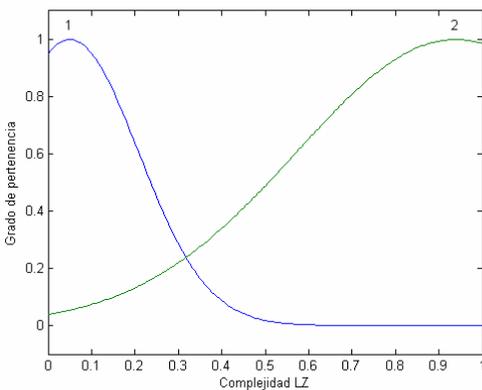


Figura 5. Funciones de pertenencia para la entrada 2 (Complejidad de Lempel-Ziv).

En las figuras 4 y 5, se observa como se adaptan las funciones de pertenencia del sistema difuso al conjunto de datos de entrenamiento. Se seleccionaron como criterios de parada para el entrenamiento un error menor

a 0.003 o 100 epochs (iteraciones completas). Se utilizó un algoritmo híbrido de entrenamiento backpropagation y mínimos cuadrados [5, 6].

Para la red neuronal artificial se utilizó una red multicapa con 3 entradas, 6 neuronas en la capa oculta y 1 salida. Las funciones de activación utilizadas fueron “logsig” y “tansig”, descritas en [6]. El algoritmo de entrenamiento utilizado fue gradiente descendente con momento y tasa adaptativa de aprendizaje. Se seleccionaron como criterios de parada para el entrenamiento un error de 0.003 o 100 epochs.

Utilizando agrupamiento subtractivo (subtractive clustering), se obtuvo un conjunto inicial de funciones de pertenencia en las entradas ubicadas de acuerdo a los conjuntos de características y se construyó una base de reglas. Los parámetros del consecuente se calcularon con el método del gradiente conjugado [7].

Las funciones de pertenencia obtenidas a partir de los datos de entrenamiento se observan en las figuras 6 y 7. La base de reglas en este caso es igual al número de funciones de pertenencia por entrada, que corresponde a la misma base de reglas del sistema neurodifuso para un número mayor de funciones de pertenencia [7].

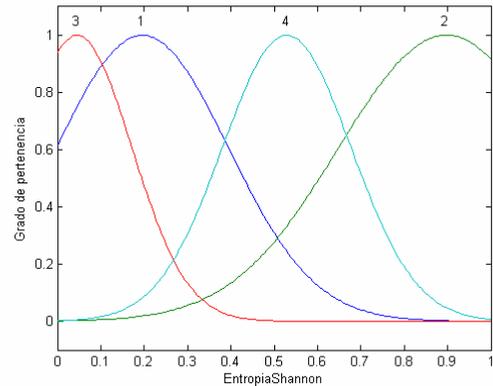


Figura 6. Funciones de pertenencia para la entrada 1 con agrupamiento subtractivo.

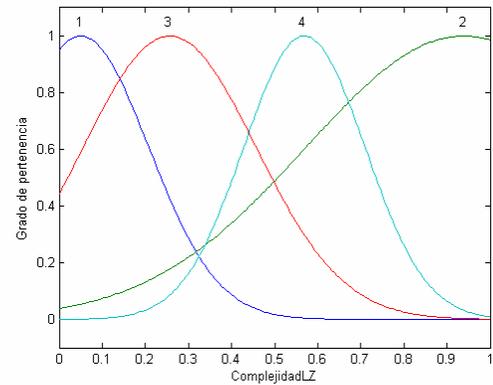


Figura 7. Funciones de pertenencia para la entrada 2 con agrupamiento subtractivo.

4. RESULTADOS Y ANÁLISIS

Se realizó prueba sobre el sistema entrenado con las características que no fueron utilizadas para el entrenamiento de los clasificadores. Como resultado se obtuvo un menor error para el sistema difuso entrenado que para la red neuronal. Los resultados obtenidos durante la clasificación se observan en las tablas 1 y 2.

Tipo arritmia	Número de datos de entrenamiento	Numero de datos de prueba	Porcentaje Clasificación
LBBB	25	25	100 %
N	25	25	92 %
PVC	25	25	96 %
VF	25	25	100 %

Tabla 1. Resultados de clasificación con el sistema de inferencia neurodifuso.

Tipo arritmia	Número de datos de entrenamiento	Numero de datos de prueba	Porcentaje Clasificación
LBBB	25	25	80 %
N	25	25	80 %
PVC	25	25	88 %
VF	25	25	84 %

Tabla 2. Resultados de clasificación con la red neuronal.

De los resultados anteriores se nota que aunque la red neuronal se adaptó mejor a los datos de entrenamiento, pues alcanzó un menor error durante el entrenamiento no lo logró con datos desconocidos. Mientras que el sistema difuso, aunque no alcanzó el error deseado en el entrenamiento, generalizó mejor para datos desconocidos, obteniendo un error menor durante la clasificación. Sin embargo, hay que tener cuidado con los datos que se encuentren por fuera del universo de discurso de las entradas.

Para el sistema difuso generado utilizando agrupamiento substractivo se obtuvo el error de clasificación mostrado en la tabla 3, lo cual es inferior a lo obtenido con la red neuronal.

Tipo arritmia	Número de datos de entrenamiento	Numero de datos de prueba	Porcentaje Clasificación
LBBB	25	25	96 %
N	25	25	96 %
PVC	25	25	92 %
VF	25	25	96 %

Tabla 3. Resultados de clasificación con agrupamiento substractivo.

5. CONCLUSIONES Y RECOMENDACIONES

La caracterización de señales bioeléctricas usando técnicas de dinámica no lineal pueden ofrecer una mejor representación de las señales, pues el origen de estas está dado por condiciones de no linealidad.

Los sistemas de inferencia difusos y neuro difusos presentan un mejor desempeño que las redes neuronales pues son más robustos a datos con ruido o mal etiquetados. Los métodos de agrupamiento substractivo permiten inferir reglas partir de los datos, así como la ubicación inicial de las funciones de pertenencia lo cual es suficiente para el entrenamiento del sistema, o como punto de inicio para un sistema neuro difuso.

Aunque los errores obtenidos durante el entrenamiento de las redes neuronales pueden ser menores a los errores obtenidos en los sistemas difusos, los sistemas difusos son más robustos para la clasificación de datos nuevos, además los sistemas neuro difusos generan una base de reglas que puede ser relacionada con el razonamiento humano y que permite entender la relación de las características no lineales con la clase.

6. BIBLIOGRAFÍA

- [1] SUN, Y. CHAN, K. Arrhythmia detection and recognition in ECG signals using nonlinear techniques, *Ann. Biomed. Eng.*, 28, pp. S-37, 2000.
- [2] KHADRA, L. AL-FAHOUM, A. S and AL-NASHASH, H. Detection of life-threatening cardiac arrhythmias using wavelets transformation, *Med. Biol. Eng. Comput.*, 35, pp. 626–632, 1997.
- [3] DINGFEL, G., SRINIVASAN, N. and KRISHNAN, S. M. Cardiac arrhythmia classification using autoregressive modeling, *Biomed Eng.* Disponible en: <http://www.pubmedcentral.nih.gov>, 2002.
- [4] ACHARYA, H., KUMAR, A, BHAT, P. S., Classification of cardiac abnormalities using heart rate signals, *Medical & Biological Engineering & Computing*, vol. 42, 2004.
- [5] ALZATE, ALFONSO. Control Difuso, Universidad Tecnológica de Pereira, 2004.
- [6] JANG, J; SUN, C; MIZUTANI, E, Neuro-Fuzzy and soft computing, a computational approach to learning and machine intelligence. Prentice Hall, New Jersey, 1997.
- [7] WANG, L. A Course in Fuzzy Systems and Control. Prentice Hall, New Jersey, 1997.