

Clasificación de arritmias ventriculares empleando *clustering* particional y características morfológicas del QRS

D. Peluffo-Ordóñez, J. L. Rodríguez-Sotelo y G. Castellanos-Domínguez

Resumen—En este trabajo se desarrolla una metodología para la clasificación de arritmias ventriculares de tipo extrasístole ventricular y bloqueo de rama izquierda y derecha con respecto a latidos normales de la base de datos de arritmias MIT-BIH, empleando características morfológicas del complejo QRS y clasificación no supervisada de tipo particional. El sistema propuesto incluye etapas de preproceso, extracción de características y clasificación no supervisada. El preproceso consiste en centrar y normalizar todas las señales. La extracción de características se realiza utilizando la reconstrucción de la señal a través del modelo paramétrico de Hermite con parámetros óptimos y características morfológicas. En la etapa de *clustering* se aplican los algoritmos H-means y K-harmonics deducidos del *clustering* iterativo (genérico) basado en centroides. Además, se realiza una modificación del algoritmo en el sentido de su inicialización utilizando el criterio max-min para garantizar y mejorar la convergencia. El desempeño del sistema para registros de la base de datos MIT/BIH, en promedio es de $Se = 97,53\%$, $Sp = 93,7\%$, siendo comparable con resultados publicados en la literatura.

Index Terms—Arritmias cardíacas, Clustering, Max-Min, Modelo Hermite, QRS

I. INTRODUCCIÓN

ALGUNAS patologías cardíacas se presentan por trastornos en la conducción del impulso eléctrico en los ventrículos. El impulso cardíaco, en el caso normal, debe propagarse a través del haz de His y sus divisiones (rama derecha e izquierda) atravesando las fibras de Purkinje. Sin embargo, cuando uno de los elementos de este sistema de conducción se altera, el impulso eléctrico puede dejar su trayectoria normal y propagarse a través del propio músculo ventricular lo que generaría un retraso y cambios morfológicos (melladuras) en el complejo QRS y podría atribuírsele a contracciones ventriculares prematuras (*V*), o un bloqueo de rama derecha (*R*) o izquierda (*L*). A este tipo de arritmias se les denomina ventriculares y pueden detectarse analizando el ritmo, frecuencia y contorno de los complejos QRS [1], debido a que el trazo del QRS se genera cuando el flujo de despolarización atraviesa los ventrículos [2]. En Fig.1 se muestra la forma de los complejos QRS asociados a las arritmias ventriculares consideradas en este estudio.

Para el análisis de señales ECG se prefieren las técnicas no supervisadas porque la detección de latidos específicos exige un análisis detallado de cada latido considerando factores




Fig 1. Complejos de algunas arritmias ventriculares

como la alta variabilidad morfológica, gran cantidad de latidos y ruido, por tanto un esquema supervisado necesitaría entrenamiento para cada paciente o registro haciendo la tarea más compleja para el especialista. Sin embargo, aún existen problemas abiertos relacionados, entre otros aspectos, a la variabilidad, clases desequilibradas y longitud de la señal.

En el análisis no supervisado, el *clustering* ha exhibido buenos resultados en la exploración de datos aunque aún representa un problema combinatorio grande en orden a agrupar los patrones más representativos.

En este trabajo se desarrolla una metodología para la clasificación no supervisada de arritmias cardíacas empleando *clustering* particional basado en el modelo iterativo genérico (GIC) [3]. El conjunto de características se obtiene de características morfológicas y de representación empleando el modelo paramétrico de Hermite. En la etapa de clasificación se emplean los algoritmos H-means y K-harmonics. El desempeño del *clustering* es evaluado en términos de sensibilidad y especificidad.

II. MATERIALES Y MÉTODOS

A. Extracción del complejo QRS

La extracción de los complejos QRS se realizó aplicando:

$$\text{QRS}_i = y(p_i - \alpha Fs : p_i + \beta Fs) = y_i \quad (1)$$

donde p_i es la ubicación del pico R del i -ésimo latido del registro y , Fs es la frecuencia de muestreo y $\alpha = \beta = 0,1$ s.

Adicionalmente, se realizó una normalización de manera que:

$$y \leftarrow \frac{y - \mu(x)}{\max |y|} \quad (2)$$

donde $\mu(\cdot)$ es la media.

B. Coeficientes de Hermite

En este trabajo se aplicó la ecuación recursiva de los polinomios de Hermite como sigue:

$$H_n(z) = 2zH_{n-1}(z) - 2(n-1)H_{n-2}(z) \quad (3)$$

con $H_0 = 1$ y $H_1 = 2z$.

Las bases de Hermite son de la forma ($z = \frac{t}{\sigma}$)

$$\phi_n^\sigma(t) = \frac{e^{-t^2/2\sigma^2}}{\sqrt{2^n \sigma n! \sqrt{\pi}}} H_n(t/\sigma) \quad (4)$$

donde σ es el parámetro de escala para ajustar la longitud de la ventana. En este trabajo se emplea un valor óptimo de este parámetro (σ_{opt}) estimado con el método explicado en [4].

En Fig.2 se muestran algunos ejemplos de las bases de Hermite. Las bases son extendidas en el intervalo $(-t_0, t_0)$ con $t_0 = 100$ ms.




Fig 2. Bases de Hermite obtenidas con $\sigma = 15$ ms (a) $n = 2$ (b) $n = 4$

Los coeficientes de Hermite se obtuvieron aplicando:

$$C_n^\sigma = \frac{1}{F_s} \sum_{i=-t_0}^{t_0} y_i \cdot \phi_n^\sigma(i) = \frac{1}{F_s} y \cdot \phi_n^\sigma \quad (5)$$

C. Clustering basado en centroides

La técnica clásica de clustering es la basada en centroides, también denominada particional. La idea general del clustering basado en centroides (CBC) es minimizar una función objetivo que define qué tan buena es la solución del clustering, dicha solución se obtiene iterativamente a través de la actualización de centroides. Las variantes de los algoritmos CBC consisten en cambios de la función objetivo y, por tanto, la función de actualización de los centroides.

Por ejemplo, en el clustering basado en la mínima suma de cuadrados (MSSC), explicado ampliamente en [5], la función objetivo se puede expresar como:

$$\min_{P_k \in P_k} \sum_{j=1}^k \sum_{x_l \in C_j} \|x_l - q_j\|^2 \quad (6)$$

donde $\|\cdot\|$ denota la norma Euclideana, P_k denota el conjunto de todas las particiones del conjunto de datos X de n puntos en el espacio Euclideano R^d ($X = \{x_1, \dots, x_n\}$, $x_i = (x_{1i}, \dots, x_{di})$), C es el conjunto de subconjuntos o clusters $C = \{C_1, \dots, C_k\}$ y el centroide q_j ($Q = q_1, \dots, q_k$) se obtiene con:

$$\bar{x}_j = \frac{1}{|C_j|} \sum_{l: x_l \in C_j} x_l = q_j, \quad j = 1, \dots, k \quad (7)$$

C1. Clustering iterativo: Una forma generalizada de realizar CBC puede obtenerse estudiando la proporción o grado de pertenencia de un punto a un cluster, dicha proporción se denomina función de membresía y se denota como $m(q_j/x_i)$ (grado de pertenencia de x_i al cluster cuyo centroide es q_j), y debe cumplir que $m(q_j/x_i) \geq 0$ y $\sum_{j=1}^k m(q_j/x_i) = 1$. Además, también debe considerarse el grado de influencia o peso de cada punto $w(x_i)$ en el cálculo de los nuevos centroides por cada iteración, que no es más que una ponderación de los datos x_i [3].

Con esto, la actualización de los centroides sería:

$$q_j = \frac{\sum_{i=1}^n m(q_j/x_i) w(x_i) x_i}{\sum_{i=1}^n m(q_j/x_i) w(x_i)} \quad (8)$$

La aplicación del modelo CBC iterativo puede resumirse en los siguientes pasos:

1. Inicialización de los centroides.
2. Calcular las funciones de membresía $m(q_j/x_i)$ y pesos $w(x_i)$ para cada punto.
3. Actualizar los centroides empleando (8).
4. Repetir los pasos 2 y 3 hasta que el algoritmo converja o hasta un máximo número de iteraciones predeterminado N_{iter} .

C2. H-means: El algoritmo *H-means* es una variante del algoritmo *K-means*, que mejora el costo computacional, calculando el valor de los centroides una vez por cada ciclo, donde se obtienen resultados similares al *K-means* pero de manera más rápida. Entre los diferentes algoritmos de clustering desarrollados en los últimos años es uno de los métodos más conocidos aceptado por muchas aplicaciones entre ellas las de clasificación de datos biomédicos. El objetivo del algoritmo *H-means* es encontrar una partición P_k de X con k conjuntos disjuntos tal que minimice su función

de costo, que podría ser la de *MSSC*. La función objetivo del algoritmo *H-means* puede escribirse como:

$$HM(X, Q) = \sum_{i=1}^n \min_{j \in \{1, \dots, k\}} \|x_i - q_j\|^2 \quad (9)$$

donde $\|\cdot\|$ representa la norma Euclídeana en el caso de *MSSC*.

Con esto la función de membresía y peso para cada x_i son:

$$m_{HM}(q_j/x_i) = \begin{cases} 1 & \text{si } l = \arg \min_j \|x_i - q_j\|^2 \\ 0 & \text{otro caso} \end{cases} \quad (10)$$

y

$$w_{HM}(x_i) = 1 \quad (11)$$

Puede apreciarse que al evaluar las expresiones (10) y (11) en (8) se obtiene la misma ecuación para el cálculo de los centroides que se emplea en *MSSC* (7), generalizando la ecuación de clustering iterativo.

En el caso del H-means, la función de membresía podría denominarse “fuerte” (*hard membership function*) porque toma valores discretos (0 y 1).

C3. *K-harmonic means*: Uno de los mayores problemas del algoritmo *H-means* es la sensibilidad a la selección de la partición inicial, lo que hace converger a un mínimo local de la función objetivo si los centroides no son escogidos de manera apropiada, por tal razón, se han desarrollado diversas alternativas al *H-means* empleando el modelo GIC, como el clustering de máxima esperanza Gaussiana (GEMC), H-means difuso (FKM), entre otros. En este trabajo se emplea el algoritmo K-harmonic means, el cual soluciona el problema usando en lugar del criterio de *MSSC*, la media armónica de la distancia de cada punto a los centroides [6]. Por tanto, la función objetivo puede escribirse como:

$$KHM(X, Q) = \sum_{i=1}^n \frac{k}{\sum_{j=1}^k \frac{1}{\|x_i - q_j\|^p}} \quad (12)$$

donde p ($p \geq 2$) es un parámetro de entrada que puede ser sintonizado usando validación cruzada. En este trabajo se empleó $p = 3,5$.

La función de membresía y peso del algoritmo KHM son:

$$m_{KHM}(q_j/x_i) = \frac{\|x_i - q_j\|^{-p-2}}{\sum_{j=1}^k \|x_i - q_j\|^{-p-2}} \quad (13)$$

y

$$w_{KHM}(x_i) = \frac{\sum_{j=1}^k \|x_i - q_j\|^{-p-2}}{(\sum_{j=1}^k \|x_i - q_j\|^{-p})^2} \quad (14)$$

La función objetivo de los algoritmos H-means y KHM son similares, pero la del KHM tiene una naturaleza “suave” como puede apreciarse en las ecuaciones 13 y 14.

D. Criterio de inicialización

Para mejorar la convergencia del algoritmo, se emplea una etapa de inicialización basada en el criterio Max-Min [7]. En este algoritmo se busca en el conjunto X , los k elementos más alejados con un criterio de distancia preestablecido, mejorando la cantidad de clusters necesarios para separar las clases y el valor de convergencia.

El algoritmo opera como sigue: Se escoge un punto arbitrario de X como primer centroide y el resto de centroides se escogen siguiendo una estrategia en la que el elemento elegido en la i -ésima iteración es aquel cuyo elemento más cercano de los $i-1$ ya elegidos se encuentra más alejado [7]. Para esto se selecciona aleatoriamente el primero centroide q_1 del conjunto X , y el segundo centroide q_2 se obtiene como el elemento que presenta la máxima distancia entre q_1 y $X - q_1$ [8]. A partir de estos dos centroides se encuentran los centroides restantes aplicando el criterio Max-Min, así:

$$f(x_l) = \max_{x_l \in X - Q} \{ \min_{q_i \in Q} \|x_l - q_i\|^2 \} \quad i = 1, \dots, k \quad (15)$$

III. RESULTADOS Y DISCUSIÓN

Para este trabajo se seleccionaron aleatoriamente registros correspondientes a la base de datos MIT/BIH de arritmias. Se utilizó para todos los experimentos el canal 0 que en la mayoría de los casos es la derivación MLII. En la tabla 1 se relaciona la cantidad y tipos de latido con los registros empleados.

Registro	Latidos			
	N	R	L	V
118	–	2164	–	16
124	–	1529	–	47
207	–	85	1457	105
214	–	–	200	256
215	3194	–	–	164
217	244	–	–	162
219	2080	–	–	64
221	2029	–	–	396
223	2027	–	–	473
228	1686	–	–	362
230	2253	–	–	1
233	2229	–	–	830
234	2698	–	–	3

TABLA I
REGISTROS EMPLEADOS

Para evaluar los resultados del clustering se empleó el siguiente conjunto de características descrito en [4]:

- Energía del QRS:
La morfología de las arritmias ventriculares sugiere que la energía es una característica adecuada:

$$E(x) = \sum_{i=1}^{L_{QRS}} y_i^2$$

- σ_{opt} [4]
- C_{σ}^n con $n = 6$

- Diferencia espectral de y_i y un complejo plantilla y_{temp} como se explica en [4], donde:

$$y_{temp} = \mu(\mathbf{y}_i)$$

Para evaluar los resultados del método se usaron medidas de sensibilidad (Se), especificidad (Sp) y porcentaje de clasificación (CP):

TP : Verdaderos positivos. Un latido normal clasificado como normal. En caso de que no existan normales, se aplica como latidos V clasificados como V.

TN : Verdaderos negativos. Un latido patológico es clasificado como patológico. En caso de que no existan normales, se aplica como latidos diferentes de V (noV) clasificados como noV.

FP : Falsos positivos. Un latido patológico es clasificado como normal o un latido noV es clasificado como V.

FN : Falsos negativos. Un latido normal es clasificado como patológico o un latido V es clasificados como noV.

$$Se = \frac{TN}{TN + FP} * 100$$

$$Sp = \frac{TP}{TP + FN} * 100$$

$$CP = \frac{TN + TP}{TN + TP + FN + FP} * 100$$

Las tablas II y III muestran los resultados del clustering. Las tres primeras columnas de cada tabla corresponden al desempeño del algoritmo sin el criterio de inicialización Max-Min y las tres columnas restantes corresponden al desempeño del algoritmo con el criterio de inicialización Max-Min. El procedimiento se iteró 10 veces para los dos algoritmos de clustering y se registraron los valores de la media y la desviación estándar de los índices de desempeño. En las pruebas realizadas sin aplicar el criterio de inicialización no se consideraron criterios de convergencia del clustering y se usó $N_{iter} = 20$. Los resultados empleando Max-Min se obtuvieron con un valor tope de $N_{iter} = 100$ y evaluando la convergencia del algoritmo mediante el valor de la función objetivo, teniendo en cuenta que al aplicar inicialización Max-Min la convergencia se encuentra en las primeras 10 iteraciones.

En Fig. 3 se muestra como ejemplo la dispersión de las características más relevantes obtenidas para el registro 207.

Las características morfológicas y de representación del complejo QRS brindan buena separabilidad en la clasificación de las arritmias ventriculares tratadas en este trabajo, debido a la naturaleza fisiológica de estas patologías y su relación directa con la generación del trazo del QRS. En este caso, la energía, las características de Hermite (C_n^σ, σ_{opt}) y las

Reg.	Inicialización aleatoria ($\mu - \sigma$)			Max - Min ($\mu - \sigma$)		
	$Se(\%)$	$Sp(\%)$	$CP(\%)$	$Se(\%)$	$Sp(\%)$	$CP(\%)$
118	99,26- 0	38,46- 16,97	98,75- 0,12	99,26- 0	51,61- 0	98,85- 0
124	99,48- 0,14	72,34- 6,73	95,77- 0,002	99,54- 0	74,75- 0,12	95,94- 0,002
207	98,4- 0,1	99,1- 0,01	99,5- 0,002	98,9- 0,01	99,5- 0,002	99,5- 0,001
214	69,5- 0,0474	77,94- 0,09	75,64- 0,009	70,12- 0,021	79,35- 0,09	78,2- 0,008
215	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
217	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
219	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
221	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
223	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
228	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
230	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
233	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
234	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0

TABLA II
RESULTADOS OBTENIDOS EMPLEANDO EL ALGORITMO H-MEANS SIN INICIALIZACIÓN Y CON INICIALIZACIÓN MAX-MIN

Reg.	Inicialización aleatoria ($\mu - \sigma$)			Max - Min ($\mu - \sigma$)		
	$Se(\%)$	$Sp(\%)$	$CP(\%)$	$Se(\%)$	$Sp(\%)$	$CP(\%)$
118	99,26- 0	63,19- 3,7	99,6- 0,02	99,26- 0	63,2- 0,1	99,72- 0,001
124	99,53- 0,1	74,86- 1,2	95,94- 0,0009	99,54- 0	74,87- 0,08	95,94- 0,001
207	98,9- 0,1	99- 1,2	99,5- 0,0009	98,9- 0	99- 0,08	99,5- 0,001
214	69,9- 0,009	80,94- 0,05	78,14- 0,009	70,2- 0,008	80,94- 0,092	78,2- 0,002
215	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
217	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
219	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
221	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
223	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
228	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
230	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
233	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0
234	100- 0	100- 0	100- 0	100- 0	100- 0	100- 0

TABLA III
RESULTADOS OBTENIDOS EMPLEANDO EL ALGORITMO K-HARMONICS SIN INICIALIZACIÓN Y CON INICIALIZACIÓN MAX-MIN

diferencias espectrales empleando plantillas del QRS fueron características adecuadas para esta tarea de clasificación.

En general, los dos métodos de clustering aplicados generan resultados similares de acuerdo a las Tablas II y III cuando se aplica el criterio de inicialización Max-Min. Esto se debe a que la principal fortaleza del algoritmo K-harmonics sobre el H-means es la sensibilidad a la inicialización debido a la media armónica y la naturaleza suave de sus funciones de membresía y peso. Sin embargo se puede apreciar que sin utilizar inicialización el algoritmo H-means baja el




Fig 3. Características de los registros 207(R, L, V) y 215 (N)

rendimiento, mientras que el algoritmo K-harmonics mantiene su desempeño. De esta manera se puede concluir que es posible obtener iguales resultados con los algoritmos pero sacrificando costo computacional debido a que el algoritmo k-harmonics puede obviar este paso, mientras que el H-means necesariamente debe incluir la inicialización para garantizar buenos resultados.

Los resultados de desempeño son similares para todos los casos (9 últimas filas, registros 215 al 234), aunque en los registros 118, 124 y 214 se aprecia que la S_p fue baja. Esto ocurre porque las características consideradas no generan, en todos los casos, buena separabilidad de los latidos V con respecto de los otros latidos considerados en este estudio. En los registros 118 y 124 el valor de S_e es alto en contraste con el valor bajo de S_p , debido a que la cantidad de latidos V de estos registros es mucho menor en comparación a la cantidad de los otros latidos (ver Tabla I).

IV. CONCLUSIONES Y TRABAJO FUTURO

Se desarrolló un esquema de análisis no supervisado para la detección de arritmias de tipo ventricular empleando características morfológicas y de representación y algoritmos de clustering particional. Se obtuvieron resultados similares para los dos esquemas de algoritmos de clustering debido a la inicialización de centroides, sin embargo, el algoritmo k-harmonics genera resultados similares sin la inicialización lo que representa una ventaja sobre el K-means desde el punto de vista de costo computacional.

En el método de clasificación de arritmias ventriculares descrito en este trabajo, se emplearon técnicas de clasificación no supervisada como el clustering particional, porque la detección de un latido específico requiere de un análisis detallado de cada latido considerando factores como gran cantidad de latidos, clases desequilibrados y variabilidad de la señal.

Se pretende continuar con este estudio con el fin de desarrollar un sistema no supervisado de asistencia diagnóstica que permita detectar los principales tipos de arritmia (N, A, V, L, R) como lo sugiere la AAMI (*Association for the Advanced of Medical Instrumentation*). Este sistema debe incluir etapas óptimas de pre-procesamiento, segmentación, caracterización, selección de características y clasificación no supervisada.

AGRADECIMIENTOS

Los autores agradecen al programa de beca para estudiantes sobresalientes de posgrado de la Universidad Nacional de Colombia y al programa de financiación para Doctorados Nacionales de Colciencias.

REFERENCIAS

- [1] E. Braunwald, *Tratado de Cardiología*, 1993.
- [2] A. Guyton and J. E. Hall, *Tratado de fisiología médica*.
- [3] G. Hamerly and C. Elkan, "Alternatives to the k-means that find better clusterings," *Pattern Recognition*, 2002.
- [4] D. Peluffo, J. L. Rodríguez, and G. Castellanos, "Metodología para la reconstrucción y extracción de características del complejo qrs basada en el modelo paramétrico de hermite," *V Semana Técnica de Ingenierías Eléctrica y Electrónica*, 2008.
- [5] P. Hansen and N. Mladenovic, "J-means: a new local search heuristic for minimum sum of squares clustering," *Pattern Recognition*, pp. 405 – 413, 2001.
- [6] B. Zhang, "Generalized k-harmonic means - boosting in unsupervised learning," *Software technology laboratory HP*, 2000.
- [7] D. Cuesta, J. Pérez-Cortés, and G. Andreau-García, "Clustering of ecg signals in computer-aided holter analysis," *Computer Methods and Programs in Biomedicine*, vol. 72, pp. 179–196, 2003.
- [8] D. Peluffo, J. L. Rodríguez, and G. Castellanos, "Detección de arritmias de tipo bloqueo de rama mediante análisis no supervisado y morfología del qrs," *III Congreso Colombiano de Bioingeniería e Ingeniería Biomédica*, 2008.