

# Análisis de un Algoritmo para la Clasificación Semiautomática de Latidos en ECG

M.Llamedo Soria<sup>1,2,3</sup>, J.P.Martínez Cortés<sup>1,3</sup>

<sup>1</sup>Grupo de Tecnologías de las Comunicaciones, Instituto de Investigación en Ingeniería de Aragón, Universidad de Zaragoza, {llamedo, jpmart}@unizar.es

<sup>2</sup>Universidad Tecnológica Nacional, Buenos Aires, Argentina

<sup>3</sup>CIBER de Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN)

## Resumen

*En este trabajo se presenta un algoritmo para la clasificación de latidos en la señal de ECG, que puede operar tanto de manera automática como asistida. El mismo se compone por un clasificador automático previamente validado, y un algoritmo de clustering. Tanto el clasificador automático como el algoritmo de clustering utilizan características descriptivas del ritmo de los latidos y de su morfología. Mediante la integración de las decisiones de ambos algoritmos, el algoritmo presentado puede desempeñarse de manera automática o con diversos grados de asistencia, dependiendo de la idoneidad del usuario. El algoritmo fue evaluado en la base de datos de arritmias del MIT-BIH con el propósito de comparar su rendimiento. En el modo automático de funcionamiento, el algoritmo propuesto ha obtenido un rendimiento ligeramente superior al clasificador automático original; pero con solo 5 latidos anotados manualmente en 22 registros, se ha obtenido una mejora del 5% en exactitud ( $A$ ), sensibilidad ( $S$ ) y valor predictivo positivo ( $P^+$ ) globales. Para el modo completamente asistido, este algoritmo ha igualado el rendimiento de referencia con 55 veces menos esfuerzo manual y lo ha superado con 42. Estos resultados representan una mejora en el estado del arte, concluyendo que el rendimiento de un clasificador automático puede mejorarse mediante el uso eficiente de la ayuda provista por un experto.*

## 1. Introducción

Las enfermedades cardiovasculares son en la actualidad la principal causa aislada de muerte en los países desarrollados de acuerdo con sus agencias de salud. El análisis de la señal electrocardiográfica (ECG) es una técnica de bajo coste y no invasiva para el estudio de la función cardíaca. Un análisis de gran importancia para el estudio de arritmias es la clasificación de latidos. El estudio minucioso cada latido y su ritmo, es una actividad muy demandante incluso para cardiólogos expertos. Por este motivo es de gran importancia la automatización o reducción del esfuerzo que implica clasificar registros ECG de larga duración.

Diversos algoritmos para la clasificación de latidos fueron desarrollados en las últimas décadas (referencias en [1, 2])

utilizando mayormente la base de datos de arritmias del MIT-BIH. Algunos aspectos metodológicos clave para el desarrollo y evaluación han permitido la comparación de resultados entre trabajos [1–3]. Los aspectos más destacados han sido el uso de bases de datos públicas, la cumplimentación de las recomendaciones AAMI [4], la división de datos orientada a pacientes [1] y el estudio de la capacidad para generalizar del clasificador [2]. A pesar de respetar estos aspectos, algunos clasificadores publicados tienen limitaciones en cuanto a su rendimiento, su capacidad de generalización o ambos aspectos. Algunos trabajos han estudiado estrategias para mitigar las limitaciones de rendimiento mediante la asistencia de un experto [5, 6]. De esta manera, los clasificadores son capaces de adaptarse al paciente bajo estudio, mejorando el rendimiento y la generalización, a costa de perder la automaticidad.

El objetivo de este trabajo es el desarrollo y evaluación de un clasificador de latidos, basado en uno automático anteriormente desarrollado [2], capaz de incrementar su rendimiento con la menor asistencia posible, sin resignar la automaticidad. El rendimiento del algoritmo será comparado con otros representativos del estado del arte [1, 2, 5].

## 2. Metodología

### 2.1. Bases de datos de ECG

En este trabajo hemos utilizado la base de datos MIT-BIH Arrhythmia [7] tanto para entrenar como para evaluar al algoritmo. Se adoptó la misma división de entrenamiento ( $DS1$ ) y evaluación ( $DS2$ ) utilizada en [1] para facilitar la comparación de resultados. La clase Q ha sido descartada en este trabajo debido a que se encuentra marginalmente representada en ambas bases de datos. Una limitación similar ocurre con la clase F, que está pobremente representada en ambas bases de datos, razón por la cual se planteó un etiquetado alternativo al AAMI (denominado AAMI2 en este trabajo). El mismo consiste en considerar a las clases de fusión (entre un latido normal y ventricular) y ventricular como la misma clase ventricular extendida ( $V^*$ ). La división de los datos y la presencia de clases está resumida en la tabla 1.

	N	S	V	F	#Reg
DS1	45673	929	3755	412	22
DS2	44053	1833	3202	388	22
Total	88175	1635	7121	822	44

Clases de latidos N: normal, S: supraventricular, V: ventricular y F: fusión.  
DS1 incluye registros 101, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223, 230.  
DS2 incluye registros 100, 103, 105, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233, 234.

**Tabla 1.** Esquema de la división adoptada en MIT-BIH respecto a los conjuntos de entrenamiento (DS1) y evaluación (DS2).

## 2.2. Clasificación de latidos: clasificadores y características

El algoritmo propuesto esta compuesto por un clasificador basado en funciones discriminantes lineales (LDC) y un algoritmo de clustering basado en estimación-maximización (EMC). El LDC fue desarrollado y evaluado previamente [2]. Las etiquetas de clase obtenidas del LDC, como las de pertenencia a cada cluster del EMC, se integraran mediante un algoritmo de votación de acuerdo al escenario donde se desempeñe el algoritmo, obteniendo como resultado una etiqueta correspondiente a la clase de latido. Este algoritmo contempla 3 modos o escenarios de operación, 1) automático, 2) mínimamente asistido y 3) completamente asistido. Para los 3 modos de operación se realizan los siguientes procedimientos: a) clustering e identificación de centroides (realizado por EMC), b) clasificación automática (mediante LDC) y c) asistencia del experto.

Para el modo 1) se ejecutan los procedimientos a) y b). El resultado de a) es la clasificación de los latidos en  $K$  clusters, mientras que el de b) son las etiquetas de los latidos. Para cada cluster, se contabilizan las etiquetas generadas por b) y si son más de la mitad del cluster, todo el cluster es asignado con dicha etiqueta. En caso que no haya mayoría, se conservan las etiquetas del LDC obtenidas en b). El modo 2) de operación es similar al 1), salvo que en caso de no obtener la mayoría, se solicita la asistencia del experto. La asistencia del experto se simula en los experimentos mediante la observación de las etiquetas verdaderas provistas con la base de datos. Para el modo 3) solo se ejecutan los procedimientos a) y c). En este modo el experto será el encargado de clasificar los centroides obtenidos en a), propagándose dicha etiqueta al resto del cluster.

El LDC es utilizado bajo la asunción de características independientes y normalmente distribuidas, utilizando el criterio de máximo *a posteriori* (MAP) obtenemos las conocidas funciones de clasificación cuadráticas. La función discriminante cuadrática para un latido representado por un vector de características  $\mathbf{x}$ , de la clase  $i$ -ésima puede escribirse

$$g_i(\mathbf{x}) = -\frac{1}{2}\mathbf{x}^T\boldsymbol{\Sigma}_i^{-1}\mathbf{x} + \boldsymbol{\mu}_i^T\boldsymbol{\Sigma}_i^{-1}\mathbf{x} - \frac{1}{2}\boldsymbol{\mu}_i^T\boldsymbol{\Sigma}_i^{-1}\boldsymbol{\mu}_i - \frac{1}{2}\log(|\boldsymbol{\Sigma}_i|) + \log(P(\omega_i)). \quad (1)$$

La regla de clasificación asigna  $\mathbf{x}$  a la clase  $i$  que tenga máxima probabilidad *a posteriori*  $g_i(\mathbf{x})$ . Siendo  $\boldsymbol{\mu}_i$ ,  $\boldsymbol{\Sigma}_i$  y

Característica	Descripción
$\ln(RR[i])$	Intervalo RR actual
$\ln(RR[i+1])$	Intervalo RR siguiente
$\ln(RR_1)$	Intervalo RR promedio en el último minuto
$\ln(RR_{20})$	Intervalo RR promedio en los últimos 20 minutos
$\ln(k_{\frac{1}{2}}^1)$	Primer cruce por cero en la secuencia de autocorrelación de la WT derivación 1
$\ln(k_{\frac{1}{2}}^2)$	Primer cruce por cero en la secuencia de autocorrelación de la WT derivación 2
$k_M^1$	Posición del primer máximo en la secuencia de autocorrelación de la WT derivación 1
$k_M^2$	Posición del primer máximo en la secuencia de autocorrelación de la WT derivación 2

**Tabla 2.** Características usadas por el LDC en [2].

$P(\omega_i)$  el vector medio, la matriz de covarianza y la probabilidad *a priori* de la  $i$ -ésima clase. Los valores de  $\boldsymbol{\mu}_i$  y  $\boldsymbol{\Sigma}_i$  se calculan como la media y la matriz de covarianza muestral, mientras que las probabilidades *a priori* se consideraron iguales para todas las clases. En el caso que la matriz de covarianza  $\boldsymbol{\Sigma}$  sea la misma para todas las clases ( $\boldsymbol{\Sigma}_i = \boldsymbol{\Sigma}_j = \boldsymbol{\Sigma}$ ,  $\forall i \neq j$ ), el clasificador discriminante cuadrático (QDC) se convierte en lineal en  $\mathbf{x}$  dando lugar al LDC. En este caso  $\boldsymbol{\Sigma}$  puede estimarse como la matriz de covarianza muestral pesada

$$\boldsymbol{\Sigma} = \frac{\sum_{i=1}^C w_i \sum_{m=1}^{M_i} (\mathbf{x}_i(m) - \boldsymbol{\mu}_i) \cdot (\mathbf{x}_i(m) - \boldsymbol{\mu}_i)^T}{\sum_{i=1}^C w_i \cdot M_i}. \quad (2)$$

La posibilidad de asignar más relevancia a algunas clases es de mucha importancia en esta aplicación dado que la clase normal por lo general está al menos un orden de magnitud más representada que el resto.

En trabajos anteriores hemos desarrollado un modelo que incluye características de ritmo y morfología, con buena capacidad de generalización [2]. En este trabajo utilizamos las mismas características descritas en la Tabla 2 para el LDC.

El algoritmo EMC utilizado asume que la información puede ser modelada por mezclas de Gaussianas [8]. Esto consiste en estimar los parámetros de una función densidad modelada por

$$p(\mathbf{x}|\Psi) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k),$$

donde  $K$  Gaussianas se mezclan mediante el coeficiente  $\pi_k$  de modo de retener lo mejor posible la estructura de la información. Considerando el set de parámetros  $\Psi = \{\pi_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k | k = 1, \dots, K\}$ , una forma de estimar  $\Psi$  es mediante el criterio de máxima verosimilitud que maximiza

$$L(X|\Psi) = \ln \prod_{n=1}^N p(\mathbf{x}|\Psi),$$

para los  $N$  latidos en cada registro llamado  $X = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ . Como no es posible obtener una expresión

Característica	# caract.	Descripción
$\ln(RR[i-1])$	1	Intervalo RR previo
$\ln(P_{RR})$	2	Prematuridad del latido
$\ln(dRR_L)$	1	Variación local del intervalo RR
$\ln(RR_{1,5})$	2	Intervalo RR promedio en los últimos 1 y 5 minutos
$\ln(\sigma_{RR_{10}})$	1	Desv. estandard del intervalo RR en los últimos 10 minutos
$\ln(QRS_W)$	1	Anchura del QRS medida de según [10]
$\ln(S_{QRS}^{1,2})$	2	Escala promedio del complejo QRS en las derivaciones 1 y 2
$\ln(t_2^1)$	1	Posición del segundo máximo en la cuarta escala de la WT del QRS derivación 1
$W_4x(t_1^{1,2})$	2	Valor del primer máximo en la cuarta escala de la WT del QRS derivación 1 y 2
$r_T(k_M^1)$	1	Valor del primer máximo en la secuencia de autocorrelación de la WT derivación 1 de la onda T
$r_{QRST}(k_M^1)$	1	Valor del primer máximo en la secuencia de autocorrelación de la WT derivación 1 del complejo QRST

Tabla 3. Características usadas por el EMC.

exacta para  $\Psi$  tras optimizar  $L(X|\Psi)$ , mediante el algoritmo iterativo de estimación maximización (EM) es posible obtener una expresión para cada parámetro de  $\Psi$  [8]. El lector interesado puede consultar [8] para examinar los detalles teóricos y las expresiones exactas. Respecto a la implementación de los algoritmos, se ha utilizado el PRtools toolbox [9] para Matlab (The Mathworks Inc., Massachusetts).

El modelo de características utilizado por el EMC fue obtenido de manera similar a la descrita en [2] para el LDC, por medio de un algoritmo secuencial de búsqueda flotante (SFFS). Sin embargo para este modelo estaremos interesados en encontrar aquellas características con mejor separación intrapaciente, en lugar de las características con mejor generalización buscadas para el LDC. Como resultado se obtuvo un modelo de 15 características, también compuestas por características de ritmo y morfología, como puede verse en la Tabla 3.

Entre las características de ritmo usadas, dos describen la prematuridad del latido

$$P_{RR}^1[i] = \frac{RR[i]}{\sum_{k=i-1}^{i+1} RR[k]}$$

y

$$P_{RR}^2[i] = \frac{RR[i]}{RR[i] + RR_{30s} + \text{máx}_{10s}(RR)}.$$

La primera mide la prematuridad respecto al intervalo anterior y el siguiente, mientras que la segunda lo hace respecto al intervalo máximo en los últimos 10 segundos y el intervalo medio en los últimos 30 segundos. La variación local del intervalo RR se define  $dRR_L[i] = \sum_{k=i-1}^{i+1} |dRR[k]|$ , siendo  $dRR[i] = RR[i] - RR[i-1]$ . Una de las características morfológicas es la escala wavelet donde el complejo QRS se proyecta mayormente. Esta característica se calcula como una suma pesada donde

$$A_i = \frac{1}{M} \sum_{m=1}^2 |W_i x(t_m)|$$

son la media de las máximas amplitudes absolutas para las escalas  $i = 1, 2, \dots, 6$ , siendo 2 los máximos calculados por escala en las posiciones  $t_m$ . Luego la escala media ( $S_{QRS}^{lead}$ ) se calcula para cada derivación como

$$S_{QRS} = \frac{\sum_{i=1}^6 A_i \cdot i}{\sum_{i=1}^6 A_i}.$$

Otras características morfológicas son las  $k$ -ésimas posiciones en la escala 4 de la WT del ECG, derivación 1 ( $t_k^l$ ), o el valor en dichas posiciones ( $W_4x(t_k^l)$ ). La última característica es el máximo de la secuencia de autocorrelación calculada en la escala 4 de la WT ( $r_C(k_M^l)$ ), similar a  $r(k_M^l)$  calculada en [2]. En este trabajo  $C$  se refiere a las ondas o complejos T, QRS y QRST; mientras que  $l$  es la derivación donde ha sido calculada. Los detalles respecto al cálculo de las características morfológicas puede encontrarse en [2].

La evaluación del rendimiento de este algoritmo se llevó a cabo de manera similar a la descrita en [2]. Dado que la inicialización del algoritmo EMC es aleatoria, los resultados de este algoritmo no son determinísticos. Por este motivo, todas las evaluaciones han sido repetidas 30 veces de manera de calcular media y desvío estándar del rendimiento. También se ha medido para cada evaluación en los modos semiautomáticos la cantidad de asistencia requerida.

### 3. Resultados

El algoritmo presentado en este trabajo ha sido evaluado en DS2 de la MITBIH para los tres posibles modos de operación. Los resultados de estos experimentos se presentan en la tabla 4 para su comparación con los resultados obtenidos de [2,5].

### 4. Discusión y conclusiones

En este trabajo hemos presentado un algoritmo versátil para la clasificación de latidos en ECG, pudiendo desempeñarse tanto automáticamente, como también de manera asistida. La parte automática del algoritmo se basa en otro clasificador previamente validado respecto a su rendimiento como a su capacidad de generalización [2]. La parte asistida del algoritmo está basada en un algoritmo de clustering, y es la responsable de retener la mayor parte de las características específicas del paciente bajo estudio. Por este motivo la búsqueda de características del EMC se realizó con la finalidad de obtener el modelo que maximice la separación de clases intra-paciente. Este enfoque difiere del utilizado para la búsqueda de características del LDC, en cuyo caso se buscó la mayor capacidad de generalización [2]. Sin embargo, el set completo de características donde se realizó la búsqueda ha sido el mismo que para el LDC, probablemente otras características diseñadas específicamente para la finalidad del EMC redunden en un mejor rendimiento final del modelo.

En modo automático el rendimiento alcanzado por el algoritmo es ligeramente superior al obtenido solo por el LDC [2], de alrededor de 84% en  $A$ ,  $S$  and  $P^+$  a alrededor de 87% como puede observarse en la Tabla 4. Esto

Modo de operación	Observación	# Clusters	# MAHB	Normal		Suprav.		Ventricular		Total		
				S	P+	S	P+	S	P+	A	S	P+
Semiautomatic	de Chazal 2006	–	500	94	89	88	93	95	96	92	92	93
	FA	12	12±0	99±0	86±2	87±3	99±0	95±1	99±0	94±1	94±1	95±1
		9	9±0	99±0	84±4	86±4	99±0	94±1	99±0	93±1	93±1	94±1
	SA	12	0.3±0	97±0	80±2	81±4	96±0	88±3	93±5	89±2	89±2	90±1
		9	0.3±0	97±1	78±3	82±4	96±1	89±3	99±0	89±2	89±2	91±1
	Automatic		12	0	97±0	78±3	77±6	95±1	87±3	92±4	87±2	87±2
		9	0	97±1	73±3	74±6	95±1	84±4	96±1	85±2	85±2	88±1
Llamedo 2011		–	0	95	79	77	88	81	88	84	84	85

MAHB: latidos anotados manualmente. FA: completamente asistido. SA: levemente asistido.

**Tabla 4.** Comparación entre los 3 modos de operación separando las clases AAMI2 (N, S, V') con diferentes grados de asistencia de un experto. Los resultados se han obtenido tras evaluar 30 veces el algoritmo en los 22 registros de DS2. Se muestra la media y desvío estándar del rendimiento donde corresponde.

significa que por si solo el algoritmo propuesto es levemente beneficioso. Sin embargo con un pequeño grado de asistencia, 5 latidos anotados manualmente (MAHB) en 22 registros, el rendimiento aumenta de alrededor de 87 % a 89 %. Estos resultados evidencian que el algoritmo es capaz de utilizar adecuadamente la asistencia provista por un experto para incrementar el rendimiento. Finalmente, para el modo completamente asistido el algoritmo necesita de 9 MAHB por registro para obtener un rendimiento comparable al obtenido en [5]. Sin embargo en este trabajo el esfuerzo requerido fue de 500 MAHB, lo que significa una reducción del esfuerzo de 55 veces. Además, con 12 MAHB, este algoritmo es capaz de superar el rendimiento de [5], pero con 42 veces menos esfuerzo. Sin embargo, estos resultados deberían corroborarse en otras bases de datos para evaluar la capacidad de generalización de este algoritmo, como ya se hizo para el LDC en [2].

Estos resultados representan una mejora en el campo de la clasificación automática y semiautomática de latidos en ECG respecto a [2, 5], concluyendo que el rendimiento de un clasificador automático, como el LDC, puede ser mejorado mediante el uso adecuado de la asistencia provista por un experto.

## Agradecimientos

Este trabajo fue financiado por los proyectos TEC2010-21703-C03-02 de CICYT y GTC T-30 de la DGA. El CIBER de Bioingeniería, Biomateriales y Nanomedicina es una iniciativa de ISCIII.

## Referencias

[1] de Chazal P, O'Dwyer M, Reilly RB. Automatic classification of heartbeats using ecg morphology and heartbeat interval features. *IEEE Transactions on*

*Biomedical Engineering* 2004;51:1196–1206.

[2] Llamedo M, Martínez J. Heartbeat classification using feature selection driven by database generalization criteria. *IEEE Transactions on Biomedical Engineering* 2011;58:616–625.

[3] Park K, Cho B, Lee D, Song S, Lee J. Hierarchical support vector machine. In *Computers in Cardiology 2008*, volume 35. IEEE Computer Society Press, 2008; 229–232.

[4] Testing and reporting performance results of cardiac rhythm and st-segment measurement algorithms. American National Standard, ANSI/AAMI/ISO EC57, 1998–(R)2008.

[5] de Chazal P, Reilly RB. A patient-adapting heartbeat classifier using ecg morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering* 2006;53:2535–2543.

[6] Hu YH, Palreddy S, Tompkins W. A patient-adaptable ecg beat classifier using mixture of experts approach. *IEEE Transactions on Biomedical Engineering* 1997;44:891–899.

[7] Mark R, Moody G. Mit-bih arrhythmia database. <http://ecg.mit.edu/dbinfo.html>, 1997.

[8] van der Heijden F, Duin R, de Ridder D, Tax D. *Classification, Parameter Estimation and State Estimation*. John Wiley & Sons, 2005.

[9] Duin R, Juszczak P, Paclik P, Pekalska E, deRidder D, Tax D, Verzakov S. *Pr-tools, a matlab toolbox for pattern recognition*, 2008. URL <http://www.prtools.org>.

[10] Martínez JP, Almeida R, Olmos S, Rocha A, Laguna P. A wavelet-based ecg delineator: Evaluation on standard databases. *IEEE Transactions on Biomedical Engineering* 2004;51:570–581.