

## Detección de Fibrilación Ventricular Mediante Tiempo-Frecuencia y Clasificador KNN sin Extracción de Parámetros

Azeddine Mjahad, Alfredo Rosado Muñoz\*, Manuel Bataller Mompeán, Jose V. Francés Vllora, Juan F. Guerrero Martínez

*GPDD, Grupo de Procesado y Diseño Digital, Escuela Técnica Superior de Ingeniería - ETSE.  
Universitat de Valencia. Av. Universitat, s/n, 46100, Burjassot, Valencia, España.*

### Resumen

Este trabajo propone la detección de FV y su discriminación de TV y otros ritmos cardíacos basándose en la representación tiempo-frecuencia del ECG y su conversión en imagen como entrada a un clasificador de vecinos más cercanos (KNN) sin necesidad de extracción de parámetros adicionales. Tres variantes de datos de entrada al clasificador son evaluados. Los resultados clasifican la señal en cuatro clases diferentes: 'Normal' para latidos con ritmo sinusal, 'FV' para fibrilación ventricular, 'TV' para taquicardia ventricular y 'Otros' para el resto de ritmos. Los resultados para detección de FV mostraron 88,27 % de sensibilidad y 98,22 % de especificidad para la entrada de imagen equivalente reducida que es la más rápida computacionalmente a pesar de obtener resultados de clasificación ligeramente inferiores a las representaciones no reducidas. En el caso de TV, se alcanzó un 88,31 % de sensibilidad y 98,80 % de especificidad, un 98,14 % de sensibilidad y 96,82 % de especificidad para ritmo sinusal normal y 96,91 % de sensibilidad con 99,06 % de especificidad para la clase 'Otros'. Finalmente, se realiza una comparación con otros algoritmos.

### Palabras Clave:

Sistemas biomédicos, Señales Electrocardiográficas, Representación tiempo-frecuencia, Señales no estacionarias, Análisis de imágenes, Clasificación

### Ventricular Fibrillation detection using time-frequency and the KNN classifier without parameter extraction.

### Abstract

This work describes new techniques to improve VF detection and its separation from Ventricular Tachycardia (VT) and other rhythms. It is based on time-frequency representation of the ECG and its use as input in an automatic classifier (K-nearest neighbours - KNN) without any further signal parameter extraction or additional characteristics. For comparison purposes, three time-frequency variants are analysed: pseudo Wigner-Ville representation (RTF), grey-scale image obtained from RTF (IRTF), and reduced image from IRTF (reduced IRTF). Four types of rhythms (classes) are defined: 'Normal' for sinus rhythm, 'VT' for ventricular tachycardia, 'VF' for ventricular fibrillation and 'Others' for the rest of rhythms. Classification results for VF detection in case of reduced IRTF are 88.27 % sensitivity and 98.22 % specificity. In case of VT, 88.31 % sensitivity and 98.80 % specificity is obtained, 98.14 % sensitivity and 96.82 % specificity for normal rhythms, and 96.91 % sensitivity and 99.06 % specificity for other rhythms. Finally, results are compared with other authors.

### Keywords:

Biomedical systems, Electrocardiographic signals, time-frequency representation, Non-stationary signals, Image analysis, Classification

\*Autor para correspondencia: Alfredo.Rosado@uv.es

To cite this article: Azeddine Mjahad, Alfredo Rosado Muñoz, Manuel Bataller Mompeán, Jose V. Francés Vllora, Juan F. Guerrero Martínez. 2018. Ventricular Fibrillation detection using time-frequency and the KNN classifier without parameter extraction. Revista Iberoamericana de Automática e Informática Industrial 15 (2018) 124-132. <https://doi.org/10.4995/riai.2017.8833>

Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0)

## 1. Introducción

Las arritmias cardíacas son anomalías en el funcionamiento normal del corazón consideradas como una de las principales causas de mortalidad en el mundo occidental. Una de las arritmias más mortíferas es la Fibrilación Ventricular (FV), producida por una actividad eléctrica desorganizada del corazón que puede desembocar en muerte súbita (Murakoshi and Aonuma, 2013; Jin et al., 2017). Durante la FV, los ventrículos se contraen de forma asíncrona con ausencia de latido efectivo, fallando el bombeo sanguíneo y produciendo la muerte en el paciente si no se trata de forma adecuada en el plazo de pocos minutos. Muchas de las víctimas pueden sobrevivir si los testigos actúan de forma inmediata después de la aparición de los primeros síntomas. La evidencia científica indica que la desfibrilación temprana es determinante en la recuperación de la víctima, siendo éste el único tratamiento definitivo posible para la FV: la aplicación de un choque eléctrico de alta energía sobre el pecho del paciente para facilitar el reinicio de la actividad eléctrica cardíaca normal (Jekova, 2007a; Othman et al., 2013; Jin et al., 2017).

Otra patología cardíaca considerada altamente peligrosa es la TV. En este caso, el corazón tiene muy poco tiempo para llenarse entre dos latidos consecutivos y la cantidad de sangre que envía al resto del cuerpo es mucho menor que la que enviaría en una situación normal (Mateo et al., 2016). En el caso de TV, los tratamientos serían el uso de medicamentos o de la cardioversión (se aplica una descarga eléctrica de menor voltaje), ya sea sobre el tórax o directamente a través del ventrículo, con el fin de recuperar el ritmo normal. El éxito en la desfibrilación ventricular es inversamente proporcional al intervalo de tiempo desde el comienzo del episodio de FV hasta la aplicación de la descarga. Habitualmente aparecen muchas dificultades a la hora de diagnosticar la FV: por una parte están las características intrínsecas de la FV (falta de organización, irregularidad, etc.), y por otra, la diferenciación entre FV y TV: el diagnóstico erróneo de la TV como FV en un paciente puede ocasionarle graves lesiones ya que la aplicación de una terapia contra la FV (desfibrilación) a un paciente que sufre TV puede causarle una fibrilación ventricular. El electrocardiograma (ECG) es un método básico, no invasivo y de bajo coste que se utiliza en el diagnóstico de desórdenes cardíacos de conducción eléctrica. Mediante el estudio de la frecuencia cardíaca y la morfología de las diferentes ondas que constituyen el ciclo cardíaco es posible conocer el estado de un paciente y detectar posibles anomalías. La señal ECG ofrece información de la actividad eléctrica del corazón a lo largo del tiempo, sin embargo, también existe información útil de la señal en el dominio de la frecuencia. El diagnóstico en el dominio de la frecuencia utiliza métodos como la transformada de Fourier (V.Oppenheim et al., 1998), y en particular, es muy adecuado para las señales estacionarias. Desafortunadamente, la mayoría de las señales ECG de interés presentan características no estacionarias. Por lo tanto, si bien el análisis en el dominio de la frecuencia permite determinar las frecuencias características de la señal, se pierde la información de tipo temporal siendo por ello un método muy limitado que no resulta útil para el análisis de señales no estacionarias (Cohen, 1989a; Mahmoud et al., 2006; Elhaj et al., 2016). Para superar las limitaciones del método espectral basado en la transformada

de Fourier surgen las transformadas tiempo-frecuencia, que representan de forma combinada la señal tanto en el dominio del tiempo como de la frecuencia, siendo aplicadas con éxito para el diagnóstico de señales ECG (Martin and Flandrin, 1985; Yochum et al., 2016).

Por otro lado, la señal ECG de un paciente suele incluir diferentes tipos de ruido y oscilaciones debidas a factores externos como el movimiento del paciente, ruido electromagnético o mala adherencia de electrodos, por lo que es de gran importancia realizar un buen procesamiento de la señal antes de aplicar algoritmos de clasificación para la reducción de las oscilaciones de la línea de base y de otras perturbaciones provenientes del exterior (von Borries et al., 2005).

El algoritmo KNN utilizado en este trabajo es un método de clasificación muy potente y a la vez muy simple usado en diferentes aplicaciones. Por ejemplo, para la detección y clasificación de etapas de sueño a partir del ECG (Yilmaz et al., 2010) y para la detección de períodos de apnea en combinación con AdaBoost Bootstrap (Kao et al., 2012). También se ha usado KNN para diagnosticar enfermedades del corazón de forma automática (Saini et al., 2015).

Habitualmente, tras el procesamiento inicial de la señal, se aplican diversos algoritmos para la obtención de características o parámetros que sirven como entrada a un clasificador encargado de separar las clases según el tipo de señal de entrada. Este trabajo plantea una nueva estrategia de detección de FV cuyos pasos son el procesamiento inicial de la señal y la obtención de su representación tiempo-frecuencia (RTF), con posibilidad de obtener en una imagen equivalente (IRTF) y una imagen equivalente reducida (IRTF reducida). En los tres casos, ésta será la entrada a un clasificador de vecinos más cercanos KNN sin necesidad de obtener parámetros ya que la representación tiempo-frecuencia o su equivalente (IRTF, IRTF reducida) ya contiene la información tanto temporal como espectral de la señal ECG, permitiendo al clasificador disponer de información suficiente para la detección de las diferentes clases de patologías cardíacas que se desea diferenciar.

Se realiza una comparativa entre los resultados obtenidos para RTF, IRTF e IRTF de tamaño reducido. Se muestran los resultados de clasificación (sensibilidad, especificidad y exactitud) y se analiza el tiempo de ejecución del algoritmo de clasificación KNN con vistas a su funcionamiento en tiempo real (diagnóstico inmediato).

Para alcanzar los objetivos buscados, el presente trabajo se estructura de la siguiente manera: en la sección 2 se describen los materiales y métodos, seguida de la sección 3 donde se detalla el procesamiento inicial aplicado a la señal ECG. En la sección 4 se presenta el algoritmo de clasificación KNN. La sección 5 muestra los resultados de clasificación, y finalmente en las secciones 6 y 7 se establecen las discusiones y conclusiones.

## 2. Materiales y Métodos

Los registros de las señales ECG se han tomado de las bases de datos estándar del MIT-BIH *Malignant Ventricular Arrhythmia Database* (<http://physionet.org>) y AHA 2000 series (<http://ecri.org>), generándose a partir de ellos tanto el conjunto de entrenamiento como el de prueba. En total, se han empleado 24 registros de monitorización continua (22 registros de

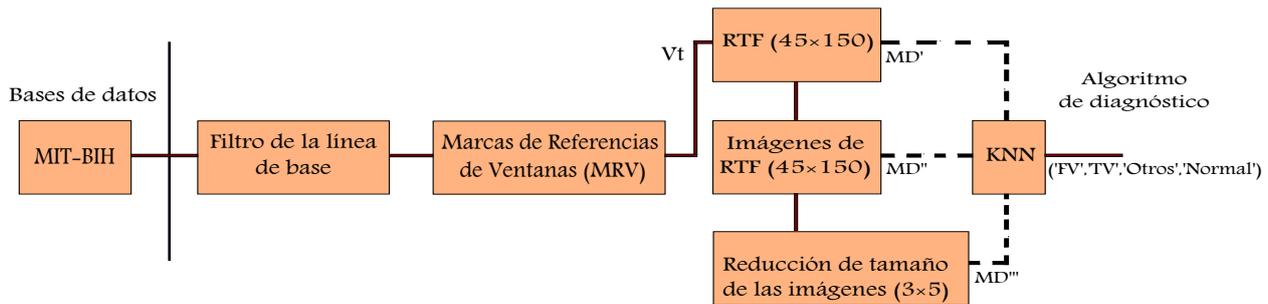


Figura 1: Diagrama general de las etapas de procesamiento realizadas para la detección de Fibrilación Ventricular. Tras la reducción de oscilación de la línea base y cálculo de marcas de referencia, se obtiene la representación tiempo-frecuencia (RTF) para una ventana temporal ( $V_t$ ). Opcionalmente, se muestra la posibilidad de obtener la imagen equivalente sin reducción de datos (IRTF) y con dimensionalidad reducida (IRTF reducida). Una de las tres se emplea como entrada al clasificador KNN.

MIT-BIH más dos adicionales de la base de datos AHA), con frecuencia de muestreo de 125 Hz. Todos los registros disponen de los episodios cardiacos ya etiquetados, lo que permite la comparación con otros algoritmos que usen estas bases de datos como datos de prueba. Los registros AHA tienen como objetivo aumentar el número de episodios de Taquicardia Ventricular (TV) para mejorar el equilibrio entre el tiempo registrado de TV y los episodios de FV.

Con los episodios etiquetados, cuatro grupos (clases) de señales fueron creados: 'FV' para tramos de registro en los que se ha producido fibrilación ventricular y flutter ventricular, 'TV' para tramos con taquicardia ventricular y que en muchos casos aparecen como una etapa previa a la fibrilación ventricular (en ocasiones, algunos tramos de TV presentan morfologías similares a la FV), 'Normal' para tramos etiquetados como ritmo sinusal normal, y finalmente 'Otros' para el resto de tramos no etiquetados como ninguna de las clases anteriores (otras arritmias, ruido, etc.). En total, se generaron 20040 segundos (s) para todos los registros de señal ECG, 3600 s correspondieron a la clase 'FV', 1380 s a 'TV', 10860 s a 'Normal' y 4200 s a 'Otros'.

### 3. Procesado de la señal ECG.

Para que el clasificador obtenga un resultado satisfactorio es necesario que los datos de entrada estén adecuadamente tratados. Por ello, tanto en la señal temporal de ECG como en su representación tiempo-frecuencia se realizan diversas etapas de acondicionamiento. La figura 1 muestra las diferentes etapas seguidas durante todo el proceso, desde la lectura de los registros de la base de datos hasta el resultado obtenido por el clasificador KNN. A continuación se detalla el funcionamiento de cada una de estas etapas, a saber: reducción de oscilaciones de la línea base, cálculo de marcas de referencia y obtención de la representación tiempo-frecuencia; opcionalmente, también se obtiene su imagen e imagen reducida para aplicarse como entrada al clasificador KNN.

#### 3.1. Reducción de las oscilaciones de la línea base

Las variaciones de la línea base son debidas a varios factores como la respiración, el movimiento del paciente durante la adquisición del electrocardiograma y los cambios en la impedancia de los electrodos (Rangayyan, 2002; Sornmo and Laguna, 2005). Estas variaciones crean interferencias de baja

frecuencia en el rango de 0 Hz a 0,5 Hz. Estas interferencias en la señal deben ser reducidas para no modificar el resultado de procesos posteriores (Sharma et al., 2010; Kabir and Shahnaz, 2012). En este caso, la primera etapa de procesamiento de la señal ECG consiste en un filtro de respuesta impulsional infinita (IIR) de orden 8 con una respuesta Butterworth (Kaur et al., 2011; Ravindra Pratap Narwaria and Singhal, 2011). Las figuras 2b y 2f muestran el efecto de la aplicación de este filtro de eliminación de la línea de base a una señal de ECG sinusal normal (figura 2a) y FV (figura 2e), respectivamente.

#### 3.2. Marcas de Referencia

Para que las Ventanas de tiempo ( $V_t$ ) de las señal ECG sobre las que se aplica la representación tiempo-frecuencia (RTF) sean comparables, es necesario obtener unas marcas de referencia de ventana (MRV) que indiquen el comienzo de dicha ventana  $V_t$ . Para poder analizar la señal de forma continuada evitando solapes en las ventanas o una distancia excesiva entre las mismas, se ha tenido en cuenta que los rangos normales de frecuencia cardiaca están situados entre 50 y 120 latidos por minutos (lpm) (Viitasalo and Karjalainen, 1992), definiendo los parámetros  $MRV_{min}$  y  $MRV_{max}$  como las distancias mínima y máxima que puede existir entre dos marcas MRV consecutivas. En este caso  $MRV_{min} = 0,5$  s y  $MRV_{max} = 1,2$  s.

El procedimiento para calcular las marcas de referencia de las ventanas (MRV) consta de cuatro etapas:

- Primera Etapa: Se utiliza un detector de máximos locales (ML) de la señal de entrada (las figuras 2c y 2g muestran un ejemplo para tipo 'Normal' y 'FV', respectivamente). El detector de máximos locales fue implementado utilizando la función *findpeaks* de Matlab. De este modo, se obtiene un vector de marcas  $ML = [ML_i; i = 1..N_{ML}]$ , siendo  $N_{ML}$  el número de marcas ML encontradas.
- Segunda Etapa: Se mide la distancia entre dos máximos locales ML consecutivos:  $DML_i = ML_{i+1} - ML_i; i = 1, \dots, N_{ML} - 1$ . En algunos casos no aparecen puntos ML por un largo tiempo y se generan distancias grandes que se denominan DAG (Distancia Atípica Grande). En otros casos aparecen ML muy cercanos entre sí produciendo distancias muy cercanas entre puntos ML, denominadas DAP (Distancia Atípica Pequeña). Si la distancia está dentro del rango  $[MRV_{min} MRV_{max}]$ , se genera lo que denominamos como DRM (Distancia Regular Mediana).

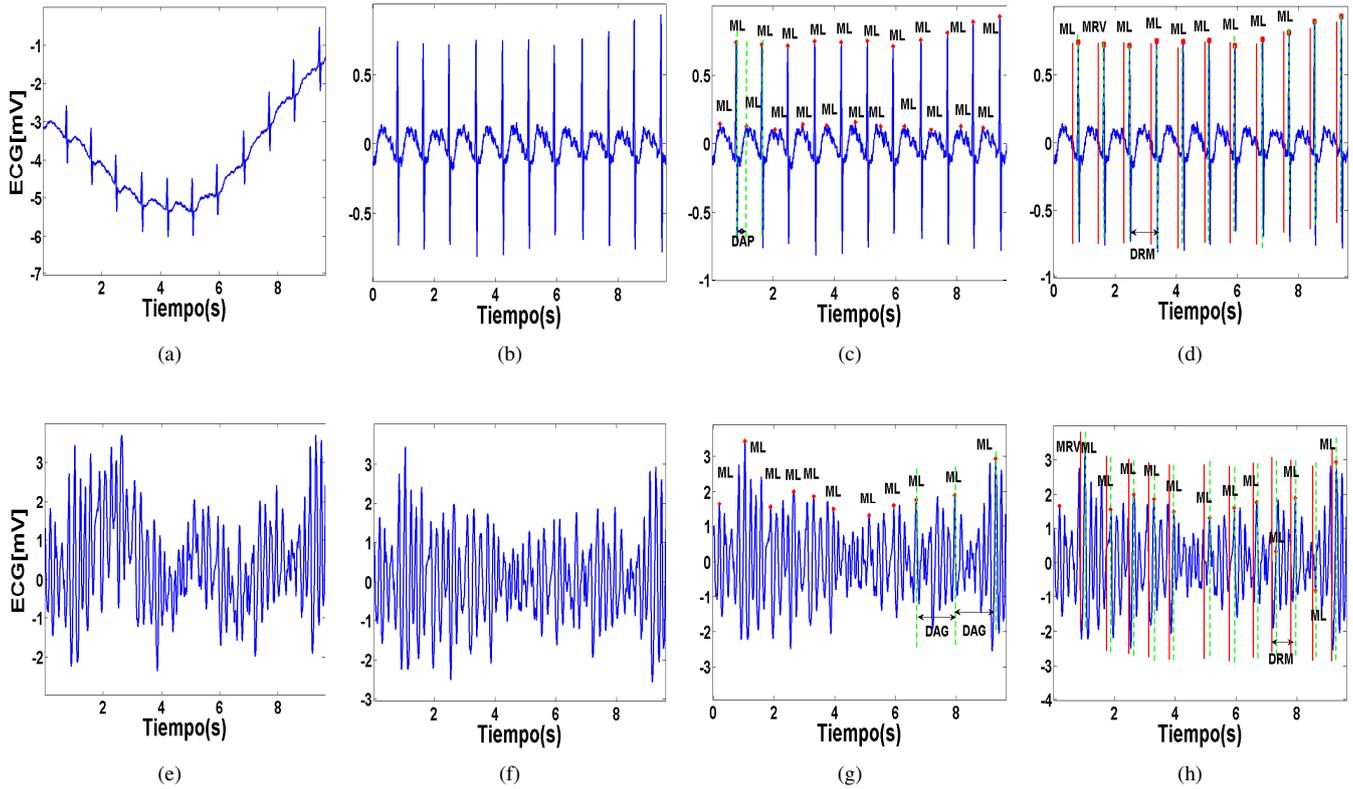


Figura 2: Etapas de procesado inicial de señal ECG de tipo 'Normal' (a-d) y 'FV' (e-h). Cada columna representa la misma etapa, de izquierda a derecha: señal original (a y e), etapa de eliminación de oscilación de línea base (b y f), puntos *ML* (puntos rojos) del algoritmo de detección de marcas (c y g), y marcas *MRV* (líneas rojas) después de aplicar el algoritmo de corrección de marcas (d y h). La figura c muestra una distancia *DAP* en la señal normal y la figura g una distancia *DAG* que son ambas corregidas posteriormente como se aprecia en las figuras d y h.

En (1) se describe el procedimiento para establecer estas marcas.

$$DML := \begin{cases} DAG & \text{si } LMD_i > MRV_{Max} \\ DAP & \text{si } LMD_i < MRV_{Min} \\ DRM & \text{si Otros casos} \end{cases} \quad (1)$$

- Tercera Etapa: Si existen puntos DAG ó DAP, se desarrolla un sistema corrector iterativo que analiza las distancias *DML*. Cuando se detecta un *DAP*, se elimina uno de ellos de acuerdo a la distribución de los *ML* vecinos. Si la distancia detectada es de tipo *DAG*, se introduce un *ML* entre los dos puntos *ML* que determinan dicha distancia. Si las *DML* generadas son también de tipo *DAG*, estarán sujetas a la misma operación iterativa. Al finalizar el proceso iterativo, todos los valores de las distancias *DML* producidos cumplen la condición indicada en (2).

$$DML := \begin{cases} MRV_{min} \leq DML_j \leq MRV_{max} \\ DML_j = ML_{j+1} - ML_j \end{cases} \quad (2)$$

Donde  $j = 1, \dots, N_{MLC}$  y  $N_{MLC}$  es el número de marcas *ML* corregidas

- Finalmente, las marcas *MRV* se obtienen a partir de las *ML* corregidas. Las figuras 2d y 2h muestran un ejemplo del resultado obtenido.

Dado que es habitual que la marca *ML* coincida con un complejo QRS, se aplica un desplazamiento de tiempo ( $t_{offset} = 150$  milisegundos(*ms*)) en la obtención de la ventana  $V_i$  para asegurar que se incluye en la misma ventana un complejo QRS completo en el caso de ritmo sinusal normal. Por tanto, las marcas *MRV* se definen según (3).

$$MRV_j = [ML_j - t_{offset}; j = 1, \dots, N_{MLC}] \quad (3)$$

### 3.3. Representación tiempo-frecuencia.

Estas representaciones permiten obtener simultáneamente el contenido espectral y temporal de una señal (ECG, en este caso). Principalmente existen dos tipos de distribuciones tiempo-frecuencia: lineales y cuadráticas (Cohen, 1989b; Poularikas, 1999; Hlawatsch and Boudreaux-Bartels, 1992). Las distribuciones cuadráticas generan términos cruzados que dificultan la interpretación de la señal. Esto constituye una desventaja y por este motivo se han propuesto las llamadas distribuciones de interferencias reducidas que permiten disminuir la contribución de estos términos. La distribución más representativa es la llamada Wigner-Ville (*WV*), pudiéndose usar como una herramienta para analizar señales no estacionarias donde se representa la densidad de energía de la señal en función del tiempo y de la frecuencia. La distribución de *WV* correspondiente a la señal analítica  $S(t)$  de una señal temporal  $x(t)$  se define según

(4).

$$WV(t, \nu) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S(t + \frac{\tau}{2}) S^*(t - \frac{\tau}{2}) e^{-j2\nu\pi\tau} d\tau \quad (4)$$

Para disminuir los términos cruzados se emplean ventanas suavizantes en el dominio del tiempo antes de calcular la distribución de  $WV$ , dando lugar a la representación Pseudo-Wigner-Ville  $PWV$  (5) (Rosado et al., 2001; Classen and Mecklenbrauer, 1980).

$$PWV_x(t, \nu) = \int_{-\infty}^{+\infty} h(\tau) S(t + \frac{\tau}{2}) S^*(t - \frac{\tau}{2}) e^{-j2\nu\pi\tau} d\tau \quad (5)$$

Siendo  $S(t)$  la señal analítica,  $\tau$  el intervalo de tiempo,  $t$  el instante de tiempo y  $h$  una ventana regular. La señal analítica  $S(t)$  que corresponde a la señal original  $x(t)$  se obtiene según (6) donde  $H[x(t)]$  es la transformada de Hilbert de  $x(t)$ .

$$S[x(t)] = x(t) + jH[x(t)] \quad (6)$$

Una vez obtenidas las marcas  $MRV$  a partir de los  $ML$  corregidos (ver sección anterior), esta marca es el inicio de una ventana  $V_t$  de longitud de 1, 2 s (150 muestras según la frecuencia de muestreo de los datos) (Viitasalo and Karjalainen, 1992), tal y como se muestra en (7).

$$Vt_j = [MRV_j, MRV_j + 1, 2 \text{ s}]; j = 1, \dots, N_{MLC} \quad (7)$$

Para cada ventana  $V_t$  se calcula la transformada de Hilbert y después se calcula la  $RTF$  de tipo  $PWV$ . Una vez obtenida la  $RTF$ , dado que la señal de interés se encuentra en valores por debajo de la frecuencia de 45 Hz (ver figuras 3(a, b, c, d)), se han cancelado las contribuciones en frecuencia por encima de 45 Hz, eliminando además la interferencia de red (50 Hz, 60 Hz) y el electromiograma (EMG). Finalmente, se dispone de una Matriz de Datos ( $MD'$ ) de  $RTF$  de tamaño  $45 \times 150$ .

### 3.4. Extracción de imágenes

Una vez obtenida la matriz  $MD'$  de  $RTF$  para cada ventana  $V_t$  (ver sección anterior), se convierte dicha matriz de datos a una imagen  $IRTF_{L_f \times L_t}$  de tamaño  $L_f \times L_t$  píxeles con  $L_f = 45$  y  $L_t = 150$  convirtiendo los niveles de energía de la señal dentro del rango que va desde 0 a 255. Estos valores se corresponden con distintos niveles de gris en una imagen tal y como muestran las figuras 3(e, f, g, h). Cada imagen se almacena en una matriz de datos ( $MD''$ ) de tamaño  $45 \times 150$  que será utilizada como matriz de entrada al clasificador.

### 3.5. Reducción del tamaño de las imágenes

Dado el tamaño de la matriz  $MD''$  de  $IRTF$  obtenida anteriormente ( $45 \times 150$ ), la dimensionalidad de dichas matrices para aplicar al clasificador es muy grande ( $45 \times 150 = 6750$  características de entrada), lo que implica una elevada carga computacional. Por tal motivo, se utilizan técnicas que reduzcan la dimensión  $MD''$ . Algunas de las técnicas de reducción de dimensionalidad de las imágenes más utilizadas son: Análisis de componentes principales (PCA), interpolación por vecino más próximo, interpolación bilineal e interpolación bicúbica (Valenzuela, 2008). La técnica de reducción de datos empleada en este trabajo es relativamente simple en comparación con otras técnicas, con el objetivo de reducir el coste computacional. Sobre la

$IRTF_{L_f \times L_t}$  se efectúa una división de la imagen en rectángulos  $R_{nm}$  de tamaño  $K \times J$  píxeles según (8), donde  $L_a = \frac{L_f}{K}$ ,  $L_b = \frac{L_t}{J}$  con  $K = 15$ ,  $J = 30$  y  $L_a \times L_b$  es el tamaño reducido  $IRTF_{L_a \times L_b}$ .

$$IRTF_{L_f \times L_t} = \sum_{n=1}^{L_a} \sum_{m=1}^{L_b} R_{nm} \quad (8)$$

Seguidamente, se calcula la media de la intensidad de los píxeles del rectángulo  $R_{nm}$  utilizando la expresión (9) donde  $I\_MediaPíxeles_{nm}(R_{nm})$  es la intensidad media de los píxeles en el rectángulo  $R_{nm}$  y  $K \times J$  es el tamaño del rectángulo  $R_{nm}$ , siendo  $I\_Pixel_{kj}$  la intensidad del  $pixel_{kj}$  en el rectángulo  $R_{nm}$  y  $[k = 1, \dots, K; j = 1, \dots, J]$ .

$$I\_MediaPíxeles_{nm}(R_{nm}) = \frac{\sum_{kj} I\_Pixel_{kj}(R_{nm})}{K \times J} \quad (9)$$

Este proceso se repite para todos los rectángulos de la imagen, obteniendo como resultado una imagen  $IRTF_{L_a \times L_b}$  de tamaño  $L_a \times L_b$  con ( $L_a = 3$ ,  $L_b = 5$ ), como ilustran las figuras 3(i, j, k, l). Así, cada  $IRTF$  reducida se transforma a una Matriz de Datos ( $MD'''$ ) de tamaño ( $3 \times 5$ ) y por tanto, el número de características de entrada al clasificador es de 15.

## 4. Algoritmo KNN

El algoritmo KNN clasifica un nuevo vector aplicando un conjunto de entrenamiento sin necesidad de aprender parámetros, a diferencia de otros algoritmos que aplicando un conjunto de entrenamiento aprende algunos parámetros y luego utilizando estos últimos se procede a la clasificación. El algoritmo KNN es el siguiente: dado un conjunto de entrenamiento  $D = (V_i, etiqueta_i)$  con  $i = 1, \dots, N$  donde  $N$  es el número de vectores de características, cada vector de características  $V_i$  está definido por  $n$  variables atributos ( $V_i = (p_{ij}, \text{ con } j = 1, 2, \dots, n)$ ) correspondiente a una  $etiqueta_i$  perteneciente a una de las  $m$  clases definidas en el conjunto  $C = (etiqueta_i \text{ con } i = 1, \dots, m)$ .

Para definir la clase a la que pertenece un nuevo vector  $V = ((p_1, \dots, p_n))$  que no pertenece al conjunto  $D$  de entrenamiento, en primera instancia se fijan las distancias de todos los casos que fueron clasificados con respecto al nuevo caso  $V$ , que se busca clasificar. Posteriormente, el algoritmo KNN busca los  $K$  vecinos más cercanos al vector  $V$ , y posteriormente hace una valoración de las clases a las que están integradas estos vectores vecinos. Esta valoración se basa en comparar las distancias que existen entre las clases.

Los algoritmos usados en esta valoración pueden ser varios: distancia mahalánobis, distancias usando la función delta, distancia del coseno, distancia euclídea, etc. La distancia euclídea es una de las más empleadas, se calcula a partir de una generalización del teorema de Pitágoras como se puede ver en (10).

$$d(V, V_i) = \sqrt{\sum_{j=1}^n (p_{ij} - p_j)^2} \quad (10)$$

En este caso, las matrices de datos  $MD$  de tipos ( $MD'$ ,  $MD''$ ,  $MD'''$ ) de cada ventana  $V_t$  se emplean como entrada al clasificador (ver figura 1). En este trabajo se ha utilizado el clasificador KNN con  $K=1$  y distancia euclídea.

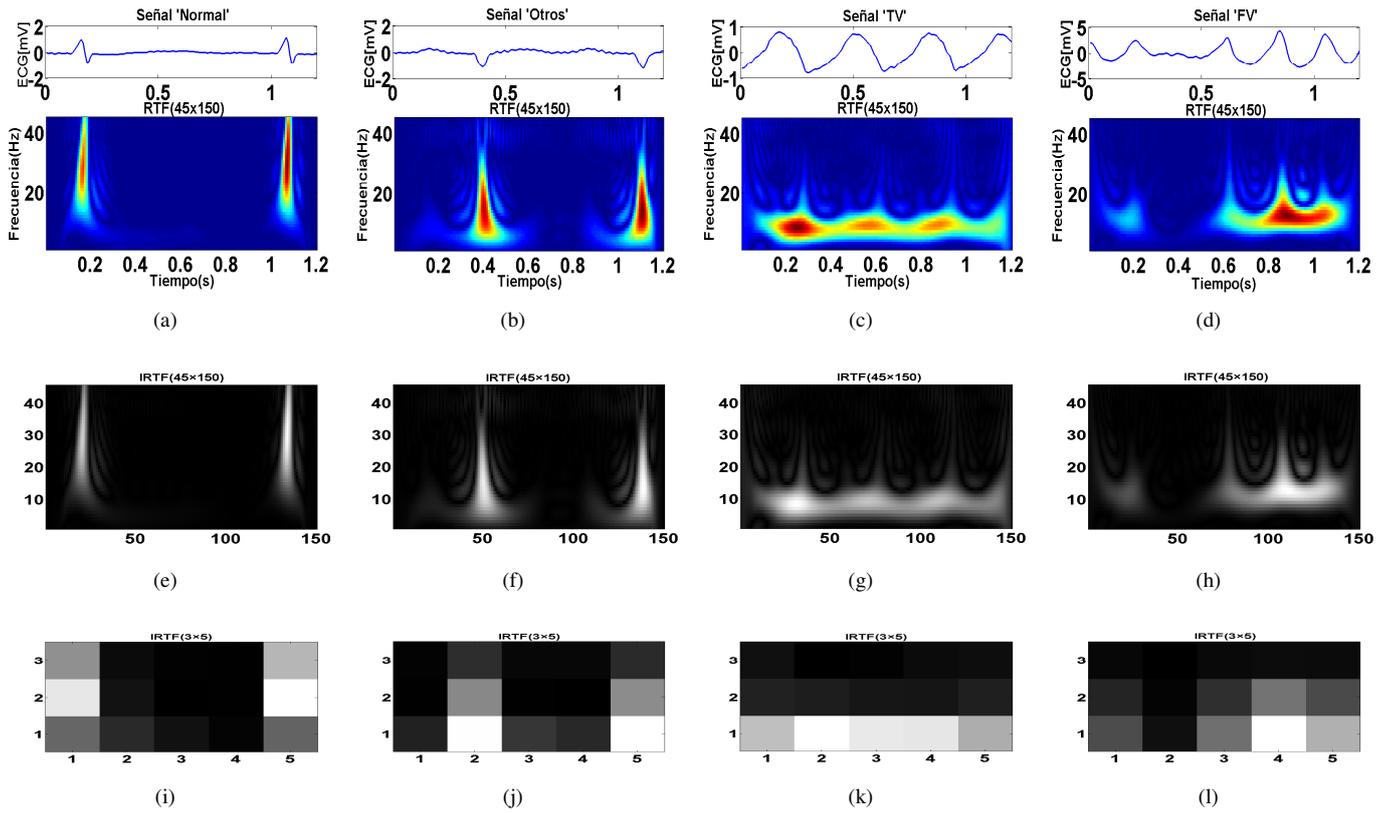


Figura 3: De arriba a abajo: las ventanas de señal temporal y sus correspondientes RTF, IRTF de tamaño 45 × 150 e IRTF de tamaño reducido 3 × 5 para señales de tipo 'Normal', 'Otros', TV y FV (en columnas).

Tras el procesado inicial con el establecimiento de las marcas de inicio de ventana temporal, se obtuvieron las ventanas  $V_t$  que a su vez generaron tres conjuntos de matrices de datos  $MD$ :  $MD'$ ,  $MD''$  y  $MD'''$  para los casos de RTF, IRTF de tamaño 45 × 150 e IRTF de tamaño reducido 3 × 5, respectivamente. Cada conjunto  $MD$ , con un tamaño total de 28507 matrices estaba distribuido del siguiente modo: 5309 matrices de la clase 'FV', 1987 de 'TV', 6051 'Otros' y 15160 de tipo 'Normal'. Para cada clase, el 67% de los datos se utilizó para el entrenamiento y el resto para prueba con repetición de 10 veces usando validación cruzada. El clasificador KNN se evalúa tomando el promedio de estas 10 iteraciones. Una vez finalizado el entrenamiento, se genera una función de predicción que posteriormente se utiliza para evaluar nuevos datos introducidos al clasificador KNN.

La figura 4 muestra los resultados para una iteración del entrenamiento y los resultados de validación (prueba) para un conjunto de datos asignados aleatoriamente. Esta figura indica el número de casos clasificados como éxito y error para cada una de las clases.

### 5. Evaluación del Desempeño

Para evaluar el rendimiento del clasificador, se utilizan índices estadísticos estándar como la Sensibilidad (Sen), Especificidad (Esp) y Exactitud (Exa) (11) donde VP son los Verdaderos Positivos, FN los Falsos Negativos, VN los Verdaderos Negativos, y FP los Falsos Positivos (Labatut and Cherifi, 2011).

El valor de la *Especificidad Global* y *Exactitud Global* de cada uno de los tipos ('FV', 'TV', 'Otros', 'Normal') se obtuvo calculando la *Especificidad* y *Exactitud* de dicho tipo de patología ante la suma de los tipos de patología restantes, es decir, sumando todos los casos de FP y FN.

$$\begin{aligned}
 \text{Sensibilidad}(\%) &= \frac{VP}{VP + FN} \times 100 \\
 \text{Especificidad}(\%) &= \frac{VN}{VN + FP} \times 100 \\
 \text{Exactitud}(\%) &= \frac{VP + VN}{VP + FN + VN + FP} \times 100
 \end{aligned}
 \tag{11}$$

El tiempo de ejecución de cada una de las pruebas realizadas se midió empleando un PC de tipo Intel(R) Core(TM) i7-3612QM CPU@2.10 GHz con Memoria RAM de 8GB, sistema operativo de 64 bits y ejecución usando Matlab(R).

### 6. Resultado y discusión

Se realizaron comparaciones entre los valores de la sensibilidad, especificidad y exactitud global de los resultados logrados en las respectivas clases ('FV', 'TV', 'Otros' y 'Normal'). Los resultados que se obtienen para los tres tipos diferentes de  $MD$  como entrada al clasificador KNN se muestran en la tabla 1.

Los valores de sensibilidad (Sen) para las cuatro clases obtenidos por el clasificador empleando la matriz  $MD'$  de RTF y  $MD''$  de IRTF (45 × 150), están por encima del 93%, con una

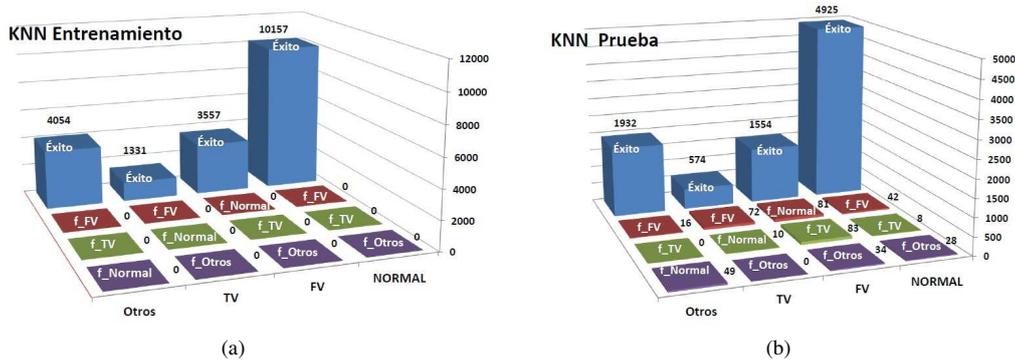


Figura 4: Número de casos obtenidos por el clasificador KNN para entrada de datos IRTF de  $45 \times 150$ : a) Fase de entrenamiento, b) Fase de prueba o validación. Para cada patología mostrada en el eje de coordenadas se muestra el número de casos de éxito (verdaderos positivos) y errores cometidos (falsos positivos).

sensibilidad del (94,97%; 95,36%), una especificidad global del (99,27%; 99,24%) y una exactitud global del (98,47%; 98,51%) para 'FV' y una sensibilidad del (93,47%; 93,11%), especificidad global del (99,39%; 99,42%) y una exactitud global del (98,97%; 99,97%) para 'TV', respectivamente.

Tabla 1: Sensibilidad, especificidad y exactitud global en la detección de las patologías FV, TV, Otros y Normal obtenidos por el clasificador KNN en la fase de validación (test) usando como entrada al clasificador las MD de los tipos: RTF  $45 \times 150$ , IRTF  $45 \times 150$  e IRTF reducida ( $3 \times 5$ ).

Clases	índices estadísticos		RTF( $45 \times 150$ )	IRTF( $45 \times 150$ )	IRTF( $3 \times 5$ )
FV	Sen %	FV	94,97	95,36	88,27
		Global	99,27	99,24	98,22
	Esp %	TV	95,21	94,68	89,86
		Otros	99,63	99,63	99,91
		Normal	99,66	99,68	98,91
Exa %	Global	98,47	98,51	96,35	
TV	Sen %	TV	93,47	93,11	88,31
	Esp %	Global	99,39	99,42	98,80
		FV	96,98	97,16	94,18
		Otros	99,99	100	99,95
		Normal	99,98	99,97	99,88
Exa %	Global	98,97	99,97	98,05	
Normal	Sen %	Normal	99,07	99,16	98,14
	Esp %	Global	98,29	98,39	96,82
		TV	98,11	98,30	98,20
		Otros	98,03	98,09	97,70
		FV	98,70	98,80	95,20
Exa %	Global	98,71	98,80	97,53	
Otros	Sen %	Otros	97,69	97,75	96,91
	Esp %	Global	99,40	99,48	99,06
		TV	99,87	99,93	99,87
		FV	99,28	99,29	97,93
		Normal	99,42	99,50	99,28
Exa %	Global	99,03	99,11	98,59	

En el caso de  $MD'''$  correspondiente a la IRTF reducida ( $3 \times 5$ ), los resultados obtenidos muestran una sensibilidad del 88,27%, una especificidad global del 98,22% y una exactitud global del 96,35% para 'FV'. Para 'TV' se muestra una sensibilidad del 88,31%, especificidad global del 98,80% y una exactitud global del 98,05%.

La tabla 2 muestra el tiempo de ejecución medio de todo el proceso de cálculo obtenido para cada ventana  $V_i$  de la señal ECG. Se aprecia que el clasificador con entrada de datos IRTF de tamaño reducido tiene un menor coste computacional, con un tiempo ejecución  $t = 0,020$  s. También se observan unos tiempos  $t = 0,1763$  s y  $t = 0,1682$  s obtenidos por RTF e IRTF no reducida, respectivamente. En general, se puede decir que

una clasificación satisfactoria debería cumplir que el tiempo de respuesta para detectar un ritmo ECG debe ser el mínimo tiempo posible, pues de lo contrario el paciente puede estar en riesgo de muerte si se presenta 'FV', con una correcta separación entre un ritmo 'TV' y 'FV'.

Tabla 2: Tiempo de ejecución medio para cada ventana  $V_i$  obtenidos por el clasificador KNN con entrada de MD de los tipos: RTF ( $45 \times 150$ ) e IRTF de tamaños ( $45 \times 150$ ) y ( $3 \times 5$ ).

	RTF ( $45 \times 150$ )	IRTF ( $45 \times 150$ )	IRTF ( $3 \times 5$ )
Tiempo de ejecución(s)	0,1763	0,1682	0,020

Se puede apreciar que los resultados conseguidos mediante la técnica de dimensionalidad reducida son ligeramente menores a los resultados que se obtienen mediante el uso de la RTF e IRTF no reducidas. Esto es debido a que en la técnica de dimensionalidad reducida no se utilizan todos los datos de entrada que se utilizan en las técnicas no reducidas, lo que se traduce en una pérdida de información. Por otro lado, la reducción en el volumen de datos que se utiliza en las técnicas con dimensionalidad reducida permite disminuir el tiempo de ejecución hasta diez veces menos que en el caso de las técnicas no reducidas, lo que se traduce en un menor coste computacional y aumento de la velocidad de procesamiento.

### 6.1. Comparación con otros métodos

En la Tabla 3 se presenta una comparación del algoritmo propuesto en cuanto a sensibilidad (Sen) y especificidad (Esp) con diferentes métodos que son frecuentemente citados en la literatura. En esta tabla aparecen los resultados del clasificador KNN obtenidos mediante los datos de RTF  $45 \times 150$ , IRTF  $45 \times 150$  e IRTF reducida de  $3 \times 5$ .

En (Xie et al., 2011) utilizan la entropía aproximada para distinguir entre 'FV' y 'TV' con buenas tasas de clasificación de 'FV' ( $Sen = 91,8\%$ ,  $Esp = 90,2\%$ ,  $Exa = 91\%$ ) empleando la misma base de datos de señal. Además, también proponen una versión modificada utilizando entropía difusa aproximada basada en la similitud, que a su vez ha conseguido un alto valor de clasificación de 'FV' ( $Sen = 97,98\%$ ,  $Esp = 97,03\%$ ,  $Exa = 97,5\%$ ). Aunque se obtuvieron valores más altos que en este trabajo, para hacer una comparación equitativa entre ambos análisis se ha de tener cuenta que el análisis realizado utiliza episodios limpios de dos tipos como datos de entrada: 'TV' y

Tabla 3: Resumen de resultados obtenidos para clasificación de las arritmias cardiacas por el método propuesto en este trabajo, y otros métodos.

Tipos	FV			TV			Otros			Normal			Base de datos
	Sen %	Esp %	Exa %	Sen %	Esp %	Exa %	Sen %	Esp %	Exa %	Sen %	Esp %	Exa %	
Este trabajo,KNN,RTF: 45 × 150	94,97	99,27	98,47	93,47	99,39	98,97	97,69	99,40	99,03	99,07	98,29	98,71	AHA & MIT-BIH
Este trabajo,KNN,IRTF: 45 × 150	95,36	99,24	98,51	93,11	99,42	99,97	97,75	99,48	99,11	99,16	98,39	98,80	AHA & MIT-BIH
Este trabajo,KNN,IRTF: 3 × 5	88,27	98,22	96,35	88,31	98,80	98,05	96,91	99,06	98,59	98,14	96,82	97,53	AHA & MIT-BIH
(Mjahad et al., 2015), usando Boltzmann	92,52			76,01			81,04						MIT-BIH
(Jekova, 2007b), usando Discriminant Analysis	94,10	93,80											AHA & MIT-BIH
(Jekova and Krasteva, 2004), usando Filter and Counts	94,40	95,90	94,7										AHA & MIT-BIH
(Li et al., 2014), usando SVM	96,20	96,20	96,3										AHA & MIT-BIH
(Xia et al., 2014), usando Lempel-Ziv and EMD	98,15	96,01	97,1										CU & MIT-BIH
(Tan et al., 2007), usando Type 2 fuzzy			90,9			84,0						100,0	MIT-BIH
(Tan et al., 2007), usando Neural SOM			100,0			48,0						88,0	MIT-BIH
(Phong and Thien, 2009), usando Type 2 TSK Fuzzy			93,3			92,0						100,0	MIT-BIH
(Phong and Thien, 2009), usando Type 2 Mamdani Fuzzy			86,6			88,0						100,0	MIT-BIH
(Xie et al., 2011), usando Fuzzy Simil App Entropy	97,98	97,03	97,5										CU & MIT-BIH
(Xie et al., 2011), usando Approximate Entropy	91,84	90,2	91,0										MIT-BIH
(Kaur and Singh, 2013), usando EMD & App Entropy	90,47	91,66	91,2										MIT-BIH
(Ibaida and Khalil, 2010), usando KNN	98,10	88,00	93,2										MIT-BIH
(Ibaida and Khalil, 2010), usando RBF	91,53	90,91	91,3										MIT-BIH

'FV' únicamente, mientras que este trabajo usa una clasificación de cuatro clases ('FV', 'TV', 'Otros', 'Normal').

Lo mismo ocurre para otros estudios que distinguen entre ritmos 'FV' y 'TV'. Así, (Kaur and Singh, 2013) utiliza entropía aproximada con descomposición empírica de modo (EMD) y un conjunto de datos de Xie más reducido, que tiene buenos valores de clasificación de 'FV' ( $Sen = 90,47\%$ ,  $Esp = 91,66\%$ ,  $Exa = 91,2\%$ ). En (Xia et al., 2014) también utilizan, en la misma línea, la complejidad Lempel-Ziv y EMD en las mismas condiciones que hizo antes Xie, usando un número representativo de episodios limpios de cada patología, obteniendo para 'FV'  $Sen = 98,15\%$ ,  $Esp = 96,01\%$ ,  $Exa = 97,08\%$ . Lo mismo ocurre con (Li et al., 2014) que utilizaron máquinas de vectores soporte SVM y obtuvieron buenos valores de clasificación de 'FV' ( $Sen = 96,2\%$ ,  $Esp = 96,2\%$ , y  $Exa = 96,3\%$ ) para una ventana de datos de 2 s de duración. Otros trabajos ofrecen buenas tasas de rendimiento que distinguen entre 'FV' y 'TV' (Ibaida and Khalil, 2010).

Siguiendo esta línea, nos encontramos con otros trabajos comparables con el objetivo de distinguir también entre el ritmo sinusal normal ('N'), aparte de 'TV' o 'FV'. Dentro de estos trabajos, (Tan et al., 2007) obtuvo buenos resultados de exactitud ( $Exa_{FV} = 90,9\%$ ,  $Exa_{TV} = 84,0\%$ ,  $Exa_N = 100\%$ ) usando un clasificador tipo-2 basado en la lógica difusa para una clasificación de tres clases ('FV', 'TV' y 'N'). También describieron los resultados de la utilización de una red neuronal SOM, pero con malos valores de exactitud para TV. Posteriormente, (Phong and Thien, 2009) siguieron la misma línea en la aplicación de multi-clase utilizando el clasificador 'sistema difuso tipo-2 TSK', con mejores valores de exactitud ( $Exa_{FV} = 93,3\%$ ,  $Exa_{TV} = 92,0\%$ ,  $Exa_N = 100\%$ ). De este modo, los resultados producidos en este trabajo son comparables con los que han sido obtenidos por otros investigadores que han trabajado en el mismo campo. En cambio, no existen referencias sobre el tiempo de ejecución de los clasificadores empleados por otros autores. En este caso, la IRTF de tamaño reducido proporciona resultados de clasificación elevados con un tiempo de cálculo del orden de 20 ms en el PC empleado.

## 7. Conclusiones

La detección rápida y correcta de la fibrilación ventricular (FV) y la taquicardia ventricular (TV) es de fundamental im-

portancia tanto para la utilización de un desfibrilador externo automático como para la monitorización del paciente. En este trabajo se ha propuesto un detector de FV fiable que presenta además una baja carga computacional para la detección en tiempo real de la fibrilación ventricular mediante un método tiempo-frecuencia, eliminando previamente las perturbaciones de la línea de base y la interferencia de red.

Además, se ha desarrollado un nuevo algoritmo para la detección de las marcas de referencia correspondientes a las ventanas de tiempo, a partir de las que se calcula la RTF, y posteriormente las imágenes IRTF en diferentes tamaños (45 × 150 y 3 × 5) para comparar resultados de tres variantes. Finalmente, se ha realizado la detección y clasificación de la señal ECG en cuatro clases, mediante el clasificador KNN.

Como novedad, al algoritmo de clasificación se le aplica como entrada cada uno de los valores obtenidos en la matriz de la representación tiempo-frecuencia, en tres variantes: RTF, IRTF e IRTF de tamaño reducido. Ello implica que no es necesario obtener parámetros de entrada al clasificador tal y como habitualmente se plantea en los sistemas de clasificación. Los resultados indican que esta metodología de detección propuesta ofrece elevados porcentajes de detección correcta.

Finalmente, se ha realizado una comparativa de los resultados obtenidos con trabajos similares conocidos en la literatura. Se indicaron los valores de la sensibilidad, especificidad y tiempos de ejecución que se obtuvieron durante los diferentes episodios posibles. Los resultados muestran que las patologías 'FV' y 'TV' se pueden separar satisfactoriamente del resto de patologías cardiacas a la hora de realizar un diagnóstico. Esto mejora significativamente las posibilidades del paciente de ser tratado eficazmente. Adicionalmente, dado que es posible realizar la detección de 'FV' con un reducido tiempo de cálculo, el algoritmo se puede incorporar en sistemas de diagnóstico en tiempo real como los que actualmente se instalan en lugares de gran afluencia de público (estadios, centros comerciales, aeropuertos, etc.) para mejorar su eficacia y ayuda al tratamiento de la fibrilación ventricular.

## Referencias

- Classen, T. A. C. M., Mecklenbrauker, W. F. G., 1980. The Wigner Distribution: A Tool for Time-Frequency Signal Analysis - Part 2: Discrete-Time Signals. Philips Journal of Research 35, 276-350.

- Cohen, L., Jul 1989a. Time frequency distributions a review. Proceedings of the IEEE 77 (7), 941–981.
- Cohen, L., 1989b. Time-frequency distributions-a review. Proceeding of the IEEE 77 (7), 941–981.
- Elhaj, F. A., Salim, N., Harris, A. R., Swee, T. T., Ahmed, T., 2016. Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. *Computer Methods and Programs in Biomedicine* 127, 52–63.  
DOI: <http://dx.doi.org/10.1016/j.cmpb.2015.12.024>
- Hlawatsch, F., Boudreaux-Bartels, G. F., April 1992. Linear and quadratic time-frequency signal representations. *IEEE Signal Processing Magazine* 9 (2), 21–67.  
DOI: 10.1109/79.127284
- Ibaida, A., Khalil, I., Aug 2010. Distinguishing between Ventricular Tachycardia and Ventricular Fibrillation from Compressed ECG Signal in Wireless body Sensor Networks. In: *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*. pp. 2013–2016.  
DOI: 10.1109/IEMBS.2010.5627888
- Jekova, I., 2007a. Shock advisory tool: Detection of life-threatening cardiac arrhythmias and shock success prediction by means of a common parameter set. *Biomedical Signal Processing and Control* 2 (1), 25–33.  
DOI: <http://dx.doi.org/10.1016/j.bspc.2007.01.002>
- Jekova, I., 2007b. Shock advisory tool: Detection of life-threatening cardiac arrhythmias and shock success prediction by means of a common parameter set. *Biomedical Signal Processing and Control* 2 (1), 25–33.
- Jekova, I., Krasteva, V., 2004. Real time detection of ventricular fibrillation and tachycardia. *Physiological measurement* 25 (5), 1167.
- Jin, D., Dai, C., Gong, Y., Lu, Y., Zhang, L., Quan, W., Li, Y., 2017. Does the choice of definition for defibrillation and CPR success impact the predic-tability of ventricular fibrillation waveform analysis? *Resuscitation* 111, 48–54.  
DOI: <http://dx.doi.org/10.1016/j.resuscitation.2016.11.022>
- Kabir, M. A., Shahnaz, C., 2012. Denoising of ecg signals based on noise reduction algorithms in emd and wavelet domain. *Biomedical Signal Processing and Control* 17 (5).  
DOI: <http://dx.doi.org/10.1016/j.bspc.2011.11.003>
- Kao, T.-P., Wang, J.-S., Lin, C.-W., Yang, Y.-T., Juang, F.-C., June 2012. Using bootstrap adaboost with knn for ecg-based automated obstructive sleep apnea detection. In: *The 2012 International Joint Conference on Neural Networks (IJCNN)*. pp. 1–5.  
DOI: 10.1109/IJCNN.2012.6252716
- Kaur, L., Singh, V., May 2013. Ventricular Fibrillation Detection using Empirical Mode Decomposition and Approximate Entropy. *International Journal of Emerging Technology and Advanced Engineering* 3 (5), 260–268.
- Kaur, M., Singh, B., Seema, 2011. Comparison of different approaches for removal of baseline wander from ecg signal. In: *Proceedings of the International Conference &#38; Workshop on Emerging Trends in Technology. IC-WET '11*. ACM, New York, NY, USA, pp. 1290–1294.  
DOI: 10.1145/1980022.1980307
- Labatut, V., Cherifi, H., May 2011. Accuracy measures for the comparison of classifiers. In: Ali, A.-D. (Ed.), *The 5th International Conference on Information Technology*. Al-Zaytoonah University of Jordan, Amman, Jordan, pp. 1,5.
- Li, Q., Rajagopalan, C., Clifford, G. D., 2014. Ventricular fibrillation and tachycardia classification using a machine learning approach. *Biomedical Engineering, IEEE Transactions on* 61 (6), 1607–1613.
- Mahmoud, S. S., Hussain, Z. M., Cosic, I., Fang, Q., 2006. Time-frequency analysis of normal and abnormal biological signals. *Biomedical Signal Processing and Control* 1 (1), 33–43.  
DOI: <http://dx.doi.org/10.1016/j.bspc.2006.02.001>
- Martin, W., Flandrin, P., Dec 1985. Wigner-ville spectral analysis of nonstationary processes. *IEEE Transactions on Acoustics, Speech, and Signal Processing* 33 (6), 1461–1470.  
DOI: 10.1109/TASSP.1985.1164760
- Mateo, J., Torres, A., Aparicio, A., Santos, J., 2016. An efficient method for ECG beat classification and correction of ectopic beats. *Computers and Electrical Engineering* 53, 219–229.  
DOI: <http://dx.doi.org/10.1016/j.compeleceng.2015.12.015>
- Mjahad, A., Rosado-Muñoz, A., Guerrero-Martinez, J., Bataller-Mompean, M., Frances-Villora, J. V., 2015. ECG Analysis for Ventricular Fibrillation Detection Using a Boltzmann Network. In: Braidot, A., Hadad, A. (Eds.), *VI Latin American Congress on Biomedical Engineering CLAIB 2014*, Parana, Argentina 29, 30, 31 October 2014. Vol. 49 of IFMBE Proceedings. Springer International Publishing, pp. 532–535.  
DOI: 10.1007/978-3-319-13117-7\_136
- Murakoshi, N., Aonuma, K., 2013. Epidemiology of arrhythmias and sudden cardiac death in asia. *Circulation Journal* 77 (10), 2419–2431.  
DOI: 10.1253/circj.CJ-13-1129
- Othman, M. A., Safri, N. M., Ghani, I. A., Harun, F. K. C., Ariffin, I., 2013. A new semantic mining approach for detecting ventricular tachycardia and ventricular fibrillation. *Biomedical Signal Processing and Control* 8 (2), 222–227.
- Phong, P. A., Thien, K. Q., Oct 2009. Classification of Cardiac Arrhythmias Using Interval Type-2 TSK Fuzzy System. In: *Knowledge and Systems Engineering, 2009. KSE '09. International Conference on*. pp. 1–6.  
DOI: 10.1109/KSE.2009.19
- Poularikas, A. D., 1999. *The transforms and applications handbooks*. ACRC Handbook published in cooperatio with IEEE Press, Department of electrical and computer engineering the university of Alabama in Huntsville.
- Rangayyan, R. M., 2002. *Biomedical signal analysis: A case-study approach*. In: *IEEE Press Series in Biomedical Engineering*.
- Ravindra Pratap Narwaria, S. V., Singhal, P. K., 2011. Removal of baseline wander and power line interference from ecg signal - a survey approach. *International Journal of Electronics Engineering* 3, 107–111.
- Rosado, A., Guerrero, J., Bataller, M., Chorro, J., 2001. Fast non-invasive ventricular fibrillation detection method using pseudo wigner-ville distribution. In: *Computers in Cardiology 2001*. pp. 237–240.  
DOI: 10.1109/CIC.2001.977635
- Saini, R., Bindal, N., Bansal, P., May 2015. Classification of heart diseases from ecg signals using wavelet transform and knn classifier. In: *Computing, Communication Automation (ICCCA), 2015 International Conference on*. pp. 1208–1215.  
DOI: 10.1109/CCAA.2015.7148561
- Sharma, L., Dandapat, S., Mahanta, A., 2010. Ecg signal denoising using higher order statistics in wavelet subbands. *Biomedical Signal Processing and Control* 5 (3), 214–222.  
DOI: <http://dx.doi.org/10.1016/j.bspc.2010.03.003>
- Sornmo, L., Laguna, P., 2005. *Bioelectrical signal processing in cardiac and neurological applications*. In: Elsevier Academic Press.
- Tan, W., Foo, C. L., Chua, T. W., July 2007. Type-2 Fuzzy System for ECG Arrhythmic Classification. In: *Fuzzy Systems Conference, 2007. FUZZ-IEEE 2007*. IEEE International. pp. 1–6.  
DOI: 10.1109/FUZZY.2007.4295478
- Valenzuela, J. V., 2008. *Interpolacion de Formas en Imagenes Usando Morfologia Matematica*. Ph.D. thesis, Departamento de Lenguajes, Sistemas Informaticos e Ingeniera de Software Facultad de Informatica Universidad Politecnica de Madrid, Director de Tesis: Jose Crespo del Arco.
- Viitasalo, M., Karjalainen, J., 1992. Q T intervals at Heart rates From 50 to 120 Beats per Minute During 24 Hour Electrocardiographic Recordings in 100 Healthy Men Effects of Atenolol. *American Heart Association* 86 (5), 1439–1442.
- von Borries, R. F., Pierluissi, J. H., Nazeran, H., Jan 2005. Wavelet transform-based ecg baseline drift removal for body surface potential mapping. In: *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*. pp. 3891–3894.  
DOI: 10.1109/IEMBS.2005.1615311
- V. Oppenheim, A., Willsky, A. S., Nawab, S. H., 1998. *Signals and systems*. Prentice Hall Internationa, Inc, Massachusettes Intitue Technology with Boston Univeristy.
- Xia, D., Meng, Q., Chen, Y., Zhang, Z., 2014. Classification of Ventricular Tachycardia and Fibrillation Based on the Lempel-Ziv Complexity and EMD 8590, 322–329.  
DOI: 10.1007/978-3-319-09330-7-39
- Xie, H.-B., Zhong-Mei, G., Liu, H., 2011. Classification of Ventricular Tachycardia and Fibrillation Using Fuzzy Similarity-based Approximate entropy. *Expert Systems with Applications* 38 (4), 3973–3981.  
DOI: <http://dx.doi.org/10.1016/j.eswa.2010.09.058>
- Yilmaz, B., Arikan, E., Asyali, M. H., April 2010. Use of knn and quadratic discriminant analysis methods for sleep staging from single lead ecg recordings. *Biomedical Engineering Meeting (BIYOMUT), 2010 15th National*, 1–4.  
DOI: 10.1109/BIYOMUT.2010.5479833
- Yochum, M., Renaud, C., Jacquir, S., 2016. Automatic detection of p, QRS and t patterns in 12 leads ECG signal based on CWT. *Biomedical Signal Processing and Control* 25, 46–52.  
DOI: <http://dx.doi.org/10.1016/j.bspc.2015.10.011>