

## ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



### PROYECTO FIN DE CARRERA

### ESTUDIO DE MODELOS BASADOS EN DINÁMICA NO LINEAL EN LA DETECCIÓN DE PATOLOGÍAS CARDÍACAS

**Autora:** Raquel Plata Pérez

**Tutores:** Dr. D. Jesús B. Alonso Hernández

Dr. D. Carlos M. Travieso González

Dra. Dña. Patricia Henríquez Rodríguez

**Fecha:** Marzo 2017



## ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



### PROYECTO FIN DE CARRERA

## ESTUDIO DE MODELOS BASADOS EN DINÁMICA NO LINEAL EN LA DETECCIÓN DE PATOLOGÍAS CARDÍACAS

### HOJA DE FIRMAS

#### Alumna

Fdo.: Raquel Plata Pérez

#### Tutor

Fdo.: D. Jesús B. Alonso  
Hernández

#### Tutor

Fdo.: D. Carlos M.  
Travieso González

#### Tutora

Fdo.: Dña. Patricia Henríquez  
Rodríguez

**Fecha:** Marzo 2017



## ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



### PROYECTO FIN DE CARRERA

### ESTUDIO DE MODELOS BASADOS EN DINÁMICA NO LINEAL EN LA DETECCIÓN DE PATOLOGÍAS CARDÍACAS

### HOJA DE EVALUACIÓN

Calificación: \_\_\_\_\_

**Presidente**

**Vocal**

**Secretario/a**

**Fecha:** Marzo 2017



# ÍNDICE

<b>I</b>	<b>MEMORIA .....</b>	<b>0</b>
<b>1.</b>	<b>INTRODUCCIÓN .....</b>	<b>1</b>
1.1.	MOTIVACIONES .....	1
1.2.	ANTECEDENTES .....	2
1.3.	DESCRIPCIÓN .....	4
1.4.	OBJETIVOS .....	5
1.5.	METODOLOGÍA .....	5
1.5.1	Fase de documentación .....	6
1.5.2	Fase de estudio de parámetros .....	6
1.5.3	Fase de clasificación .....	7
1.5.4	Fase de estudio del sistema .....	7
1.6.	ESTRUCTURA DE LA MEMORIA .....	7
<b>2.</b>	<b>LA SEÑAL ELECTROCARDIOGRÁFICA Y LAS PATOLOGÍAS CARDÍACAS .....</b>	<b>11</b>
2.1.	EL LATIDO CARDÍACO .....	11
2.2.	CONFORMACIÓN DE LA SEÑAL DE ECG .....	11
2.2.1.	Sistema de conducción eléctrica .....	12
2.2.2.	Señal eléctrica cardíaca .....	12
2.3.	DESCRIPCIÓN DE LA SEÑAL DE ECG .....	14
2.3.1.	Conceptos básicos sobre la señal de ECG .....	14
2.3.2.	Significado e interpretación de la señal de ECG .....	16
2.4.	PATOLOGÍAS CARDÍACAS .....	16
2.4.1.	Introducción .....	16
2.4.2.	Latido normal o ritmo sinusal .....	17
2.4.3.	Latido auricular prematuro .....	19
2.4.4.	Contracción ventricular prematura .....	21
<b>3.</b>	<b>BASE DE DATOS .....</b>	<b>23</b>
3.1.	INTRODUCCIÓN .....	23
3.2.	CARACTERÍSTICAS DE LAS BASES DE DATOS DE ECG .....	23
3.3.	BASE DE DATOS UTILIZADA .....	24
3.3.1.	Motivos .....	24
3.3.2.	Características .....	25
3.4.	BASE DE DATOS PROPIA .....	28
<b>4.</b>	<b>PREPROCESADO DE LA SEÑAL DE ECG .....</b>	<b>35</b>
4.1.	INTRODUCCIÓN .....	35
4.2.	TIPOS DE PERTURBACIONES EN LA SEÑAL ECG .....	35
4.3.	TIPOS DE FILTRADO .....	37
4.3.1.	Métodos basados en técnicas clásicas de filtrado .....	37
4.3.2.	Filtros de media móvil .....	39

4.3.3.	Promediado de latidos .....	40
4.3.4.	Aproximación mediante funciones .....	41
4.3.5.	Filtrado mediante Wavelets .....	41
4.4.	FILTRADOS REALIZADOS .....	42
4.4.1.	Filtrado de las variaciones en la línea basal .....	42
4.4.2.	Filtrado del ruido muscular y de los amplificadores .....	45
4.4.3.	Filtrado de la interferencia de la red eléctrica.....	48
<b>5.</b>	<b>PARÁMETROS DE DINÁMICA NO LINEAL.....</b>	<b>51</b>
5.1.	INTRODUCCIÓN .....	51
5.2.	DINÁMICA NO LINEAL Y MEDIDAS DE COMPLEJIDAD .....	52
5.3.	EXTRACCIÓN DE LAS MEDIDAS DE COMPLEJIDAD .....	53
5.3.1.	Segmentado .....	53
5.3.2.	Extracción de parámetros .....	54
5.4.	ESTUDIO DE LOS PARÁMETROS CAÓTICOS .....	57
5.4.1.	Definición de los parámetros seleccionados .....	57
5.4.2.	Análisis paramétrico mediante estadística descriptiva.....	65
5.4.3.	Análisis paramétrico mediante simulaciones .....	68
<b>6.</b>	<b>DISEÑO DEL CLASIFICADOR.....</b>	<b>69</b>
6.1.	INTRODUCCIÓN .....	69
6.2.	ELECCIÓN DEL CLASIFICADOR .....	70
6.3.	REDES NEURONALES ARTIFICIALES .....	71
6.4.	MODELADO DE LA RED NEURONAL .....	73
6.4.1.	Consideraciones en los datos de entrada.....	73
6.4.2.	Consideraciones en la arquitectura .....	74
6.4.3.	Configuración utilizada .....	75
6.5.	SIMULACIONES DE LOS PARÁMETROS NO LINEALES.....	78
6.5.1.	Estudio de la duración óptima de la trama.....	79
6.5.2.	Simulación de cada parámetro con tamaño de trama óptimo .....	79
6.5.3.	Estimación del número óptimo de neuronas de la red neuronal .....	80
6.6.	EVALUACIÓN DEL SISTEMA CLASIFICADOR.....	84
<b>7.</b>	<b>ANÁLISIS DE RESULTADOS.....</b>	<b>89</b>
7.1.	RESULTADOS DEL ESTUDIO DEL TAMAÑO ÓPTIMO DE TRAMA .....	89
7.2.	RESULTADOS DE LA SIMULACIÓN DE CADA PARÁMETRO CON TAMAÑO DE TRAMA ÓPTIMO .....	91
7.3.	RESULTADOS DEL ESTUDIO DEL NÚMERO DE NEURONAS ÓPTIMO DE LA RED CON EL CONJUNTO DE PARÁMETROS.....	93
7.3.1.	Estudio balanceado .....	93
7.3.2.	Estudio desbalanceado.....	99
7.4.	RESULTADOS DEL ESTUDIO DEL NÚMERO DE NEURONAS ÓPTIMO DE LA RED PARÁMETRO A PARÁMETROS .....	101
7.4.1.	Complejidad Lempel-Ziv.....	101
7.4.2.	Exponente de Hurst, algoritmo RS .....	102
7.4.3.	Exponente de Hurst, algoritmo de Varianza Agregada.....	103

7.4.4.	Exponente de Hurst, algoritmo de Momento Absoluto .....	104
7.4.5.	Máximo Exponente de Lyapunov, algoritmo de Rosenstein .....	105
7.5.	RESULTADOS DEL SISTEMA DE DETECCIÓN .....	106
7.5.1.	Resultados de las curvas ROC .....	106
7.5.2.	Resultados del sistema de detección a modo de verificación .....	109
<b>8.</b>	<b>CONCLUSIONES Y LÍNEAS FUTURAS.....</b>	<b>111</b>
8.1.	CONCLUSIONES .....	111
8.2.	APORTACIONES .....	113
8.3.	LÍNEAS FUTURAS .....	114
<b>A1.</b>	<b>GRÁFICAS Y TABLAS DEL ESTUDIO ESTADÍSTICO .....</b>	<b>117</b>
A1.1	ENTROPÍA DE SHANNON .....	117
A1.2	MÁXIMO EXPONENTE DE LYAPUNOV CON ALGORITMO DE ROSESTEIN .....	119
A1.3	MÁXIMO EXPONENTE DE LYAPUNOV, CON ALGORITMO DE KANTZ .....	121
A1.4	DIMENSIÓN DE CORRELACIÓN.....	123
A1.5	ENTROPÍA DE CORRELACIÓN .....	125
A1.6	COMPLEJIDAD LEMPEL-ZIV .....	127
A1.7	EXPONENTE DE HURST CON ALGORITMO DE VARIANZA AGREGADA .....	129
A1.8	EXPONENTE HURST CON ALGORITMO DE MOMENTO ABSOLUTO .....	131
A1.9	EXPONENTE HURST CON ALGORITMO DE R/S.....	134
<b>A2.</b>	<b>GRÁFICAS Y TABLAS COMPLEMENTARIAS DE LAS SIMULACIONES .....</b>	<b>137</b>
A2.1	ESTUDIO DEL TAMAÑO DE TRAMA ÓPTIMO Y DE NÚMERO DE NEURONAS ÓPTIMO.....	137
A2.2	RESULTADOS COMPLEMENTARIOS DEL ESTUDIO PARAMÉTRICO CON TAMAÑO ÓPTIMO DE TRAMA .....	138
A2.3	RESULTADOS COMPLEMENTARIOS DEL ESTUDIO PARAMÉTRICO CON NÚMERO ÓPTIMO DE NEURONAS.....	139
	<b>BIBLIOGRAFÍA .....</b>	<b>145</b>
	<b>II. PROGRAMAS.....</b>	<b>151</b>
P.1	BASE DE DATOS.....	1
P.4.1	Cambio de formato .....	1
P.4.2	Separación de señales .....	2
P.2	PREPROCESADO .....	3
P.3	SEGMENTACIÓN Y OBTENCIÓN DE CARACTERÍSTICAS .....	4
P.4	SIMULACIONES .....	6
P.4.1	Formación de las entradas al clasificador .....	6
P.4.2	Estimación del tamaño óptimo de trama.....	8
P.4.3	Estimación el número óptimo de neuronas .....	9
	<b>III. PLIEGO DE CONDICIONES.....</b>	<b>0</b>
P.1	PLIEGO DE CONDICIONES TÉCNICAS.....	1
P.2	PLIEGO DE CONDICIONES LEGALES .....	2
	<b>IV. PRESUPUESTO .....</b>	<b>0</b>
P.1	TRABAJO TARIFADO POR TIEMPO EMPLEADO .....	1
P.2	AMORTIZACIÓN DEL HARDWARE .....	3

P.3	AMORTIZACIÓN DEL SOFTWARE.....	4
P.4	REDACCIÓN DEL PROYECTO .....	4
P.5	DERECHOS DE VISADO .....	5
P.6	GASTOS DE TRAMITACIÓN Y ENVÍO.....	6
P.7	APLICACIÓN DE IMPUESTOS .....	6
P.8	IMPORTE FINAL .....	7

## Índice de figuras

Figura 2. 1: Sistema de conducción eléctrica del corazón .....	12
Figura 2. 2: Potencial de acción de la célula contráctil ventricular .....	13
Figura 2. 3: Conformación de la señal de ECG .....	14
Figura 2. 4: Ondas, intervalos, segmentos y complejos de un ECG .....	15
Figura 2. 5: Señal de ECG para paciente sano.....	17
Figura 2. 6: Detalle de latido para paciente sano .....	18
Figura 2. 7 Señal de ECG de paciente con latido auricular prematuro .....	19
Figura 2. 8: Latido de paciente con contracción auricular prematura.....	20
Figura 2. 9: Señal de ECG de paciente con contracción ventricular prematura .....	21
Figura 2. 10: Latido de paciente con contracción ventricular prematura.....	22
Figura 3. 1: Interfaz de Physionet para obtener las anotaciones cardiológicas.....	30
Figura 3. 2: Tabla de tipos y resultado de separar en clases la primera señal.....	31
Figura 3. 3: Porcentaje de individuos con las distintas patologías y clase normal de la base de datos propia.....	32
Figura 3. 4: Distribución porcentual de las clases en la base datos .....	33
Figura 4. 1: Variaciones negativas y positivas en la línea basal (rojo) de un ECG y su correspondiente señal filtrada (azul) .....	44
Figura 4. 2: Densidad espectral de energía de la señal original (izquierda) y la señal filtrada a baja frecuencia (derecha) .....	44
Figura 4. 3: Comparativa entre técnicas de filtrado: señal original ruidosa (azul), señal filtrada mediante Wavelet (verde) y señal filtrada con filtro paso bajo (rojo)[26]. .....	46
Figura 4. 4 : espectro de la onda ruidosa (azul), de la onda filtrada mediante paso bajo (roja) y filtrada mediante Wavelet (verde)[26] .....	46
Figura 4. 5: Señal original (rojo) y su señal filtrada (azul) a alta frecuencia .....	47
Figura 4. 6: Densidad espectral de energía de la señal original (izquierda) y la señal filtrada a alta frecuencia (derecha) .....	48
Figura 4. 7: Señal original y su señal filtrada con filtro banda eliminada .....	49
Figura 4. 8: Densidad espectral de potencia de la señal original (izquierda) y la señal filtrada (derecha) con filtro banda eliminada .....	49
Figura 5. 1: Segmentación de las señales en tramas de diferente tamaño y extracción de sus parámetros caóticos.....	54
Figura 5. 2: Trama de la señal de ECG para paciente sano y su atractor.....	55
Figura 5. 3: Función densidad de probabilidad para el parámetro Entropía de Shannon para latidos sano y patológico .....	58
Figura 5. 4: Función densidad de probabilidad para el parámetro Máximo Exponente de Lyapunov con algoritmo Rosenstein para latidos sano y patológico.....	59
Figura 5. 5: Función densidad de probabilidad para el parámetro Máximo Exponente de Lyapunov con algoritmo de Kantz para latidos sano y patológico.....	60
Figura 5. 6 Función densidad de probabilidad para el parámetro Dimensión de Correlación para latidos sano y patológico.....	61
Figura 5. 7: Función densidad de probabilidad para el parámetro Dimensión de Correlación para latidos sano y patológico.....	62
Figura 5. 8 Función densidad de probabilidad para el parámetro Complejidad Lempel-Ziv para latidos sano y patológico.....	63
Figura 5. 9 Función densidad de probabilidad para el parámetro Exponente de Hurst con algoritmo de Varianza Agregada para latidos sano y patológico.....	64
Figura 5. 10 Función densidad de probabilidad para el parámetro Exponente de Hurst con algoritmo de Momento Absoluto para latidos sano y patológico .....	65
Figura 5. 11 Función densidad de probabilidad para el parámetro Exponente de Hurst con algoritmo de R/S para latidos sano y patológico .....	65
Figura 6. 1 Estructura de la red neuronal.....	71
Figura 6. 2 Funciones de activación escalón (izquierda) y sigmoidea (derecha).....	72
Figura 6. 3: Red multicapa en una RNA.....	72
Figura 6. 4: Funciones de activación escalón (izquierda) y sigmoidea (derecha) .....	76
Figura 6. 5 : Ejemplos de curvas ROC y su significado [59] .....	86

Figura 7. 1 : Porcentajes de éxitos obtenidos en la clasificación, por tamaño de trama (en segundos), para la clasificación de las 3 clases .....	89
Figura 7. 2 : Porcentajes de éxitos obtenidos en la clasificación, por tamaño de trama (en segundos), para la clasificación entre sano y patológico .....	90
Figura 7. 3 : Porcentaje de éxitos de cada parámetro para la clasificación de las tres clases, con tamaño de trama óptimo .....	91
Figura 7. 4 : Porcentaje de éxitos de cada parámetro para la clasificación de las clases Sano y Patológico, con tamaño de trama óptimo .....	93
Figura 7. 5 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta .....	95
Figura 7. 6 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta .....	95
Figura 7. 7 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta .....	96
Figura 7. 8 : Éxitos en la clasificación para clase Sano en función del número de neuronas de la capa oculta .....	97
Figura 7. 9 : Éxitos en la clasificación para clase Patológico en función del número de neuronas de la capa oculta .....	98
Figura 7. 10 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Complejidad Lempel-Ziv .....	101
Figura 7. 11 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Complejidad Lempel-Ziv .....	101
Figura 7. 12 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Complejidad Lempel-Ziv .....	102
Figura 7. 13 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para para Exponente de Hurst (R/S) .....	102
Figura 7. 14 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para para Exponente de Hurst (R/S) .....	102
Figura 7. 15 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para para Exponente de Hurst (R/S) .....	103
Figura 7. 16 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Exponente de Hurst (Varianza Agregada) .....	103
Figura 7. 17 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Exponente de Hurst (Varianza Agregada) .....	103
Figura 7. 18 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Exponente de Hurst (Varianza Agregada) .....	104
Figura 7. 19 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Exponente de Hurst (Momento Absoluto) .....	104
Figura 7. 20 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Exponente de Hurst (Momento Absoluto) .....	104
Figura 7. 21 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Exponente de Hurst (Momento Absoluto) .....	105
Figura 7. 22 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov (Rosenstein) .....	105
Figura 7. 23 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov (Rosenstein) .....	105
Figura 7. 24 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov (Rosenstein) .....	106
Figura 7. 25 : Representación ROC del sistema para clase N .....	107
Figura 7. 26 : Representación ROC del sistema para clase A .....	107
Figura 7. 27 : Representación ROC del sistema para clase V .....	107
Figura 7. 28 : Representación ROC del sistema para clase Sano .....	108
Figura 7. 29 : Representación ROC del sistema para clase Patológico .....	108
Figura AI. 1 Estadísticos obtenidos para Entropía de Shannon, para tramas de 2 a 20 s .....	118
Figura AI. 2 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Entropía de Shannon de clase normal (N) .....	119
Figura AI. 3 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Entropía de Shannon en pacientes patológicos, clases A y V .....	119
Figura AI. 4 : Estadísticos obtenidos para Máximo Exponente de Lyapunov (estimado con algoritmo de Rosenstein), para tramas de 2 a 20 s .....	120

Figura AI. 5 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con Rosenstein, de clase normal (N).....	121
Figura AI. 6 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con algoritmo Rosenstein, en pacientes patológicos (clases A y V) .....	121
Figura AI. 7 : Estadísticos obtenidos para Máximo Exponente de Lyapunov (estimado con algoritmo de Kantz), para tramas de 2 a 20 s.....	122
Figura AI. 8 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con Kantz, de clase normal (N).....	123
Figura AI. 9 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con algoritmo Kantz, en pacientes patológicos (clases A y V) .....	123
Figura AI. 10 : Estadísticos obtenidos para Dimensión de Correlación, para tramas de 2 a 20 s.....	124
Figura AI. 11 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Dimensión de correlación, de clase normal (N). .....	125
Figura AI. 12 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Dimensión de correlación, en pacientes patológicos (clases A y V) .....	125
Figura AI. 13 : Estadísticos obtenidos para Entropía de correlación para tramas de 2 a 20 s .....	126
Figura AI. 14 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos .....	127
Figura AI. 15 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro entropía de correlación, en pacientes patológicos (clases A y V).....	127
Figura AI. 16 : Estadísticos obtenidos para Complejidad Lempel-Ziv, para tramas de 2 a 20 s .....	128
Figura AI. 17 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro complejidad Lempel-Ziv, de clase normal (N). .....	129
Figura AI. 18 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro complejidad Lempel-Ziv, en pacientes patológicos (clases A y V).....	129
Figura AI. 19 : Estadísticos obtenidos para Exponente de Hurst, con algoritmo de Varianza Agregada, para tramas de 2 a 20 s .....	130
Figura AI. 20 : Valores de curtosis obtenidos en tramas de 2 a 20 segundos, para el parámetro de Hurst con algoritmo de varianza agregada, de clase normal (N).....	131
Figura AI. 21 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo de varianza agregada, en pacientes patológicos (clases A y V).....	131
Figura AI. 23 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo de momento absoluto, de clase normal (N). .....	133
Figura AI. 22 : Estadísticos obtenidos para Exponente de Hurst, con algoritmo de Momento Absoluto, para tramas de 2 a 20 s .....	133
Figura AI. 24 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo de momento absoluto, en pacientes patológicos (clases A y V) .....	134
Figura AI. 25 : Estadísticos obtenidos para Exponente de Hurst, con algoritmo de R/S, para tramas de 2 a 20 s .....	135
Figura AI. 26 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo R/S, de clase normal (N). .....	136
Figura AI. 27 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo R/S, en pacientes patológicos (clases A y V) .....	136
Figura AII. 1 : Tasa de acierto media (en %), parámetro a parámetro, con tamaño óptimo de trama ....	138
Figura AII. 2 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Entropía de Shannon .....	139
Figura AII. 3 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Entropía de Shannon .....	140
Figura AII. 4 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Entropía de Shannon .....	140
Figura AII. 5 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Entropía de Correlación .....	140
Figura AII. 6 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Entropía de Correlación .....	141
Figura AII. 7 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Entropía de Correlación .....	141
Figura AII. 8 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Dimensión de Correlación .....	141
Figura AII. 9 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Dimensión de Correlación .....	142

Figura AII. 10 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Dimensión de Correlación .....	142
Figura AII. 11 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov, con algoritmo de Kantz.....	142
Figura AII. 12 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov, con algoritmo de Kantz.....	143
Figura AII. 13 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov, con algoritmo de Kantz.....	143

## Índice de tablas

Tabla 3. 1 : Tipos de latidos disponibles en la base de datos de MIT-BIH.....	27
Tabla 4. 1 : Tiempo de cómputo de las diferentes técnicas [26] .....	47
Tabla 6. 1 : Configuración para el estudio de tamaño de trama óptimo entre clases y sano – patológico .....	79
Tabla 6. 2 : Configuración para el estudio parámetro a parámetro entre clases y sano - patológico .....	80
Tabla 6. 3 : Número de neuronas de la capa oculta estimado de manera teórica .....	81
Tabla 6. 4 : Configuraciones testeadas para el estudio balanceado utilizando el conjunto de parámetros.....	83
Tabla 6. 5 : Configuraciones testeadas para el estudio balanceado parámetro a parámetro .....	84
Tabla 6. 6 Evaluación del test en función de los intervalos AUC [59]: .....	86
Tabla 7. 1 : Tabla resumen de resultados en la estimación del tamaño óptimo de trama, para las clasificaciones entre clases y sano-patológico .....	91
Tabla 7. 2 : Número de neuronas óptimo obtenido para la discriminación de las clases N, A y V con un número de muestras balanceado .....	94
Tabla 7. 3 : Número de neuronas óptimo obtenido para la discriminación de las clases Sano y Patológico con un número de muestras balanceado .....	97
Tabla 7. 4 : Comparativa de número óptimo de neuronas teórico y práctico para balanceado .....	99
Tabla 7. 5 : Número de neuronas óptimo obtenido para el estudio entre clases con un número de muestras desbalanceado.....	99
Tabla 7. 6 : Número de neuronas óptimo obtenido para el estudio sano-patológico con un número de muestras desbalanceado.....	100
Tabla 7. 7 : Comparativa de número óptimo de neuronas teórica y práctica .....	100
Tabla 7. 8: AUC del sistema de clasificación, para cada clase .....	108
Tabla 7. 9: Resultados del sistema de detección a modo de verificación.....	109
Tabla AI. 1 : Valores máximo y mínimo de cada estadístico por clase, para Entropía de Shannon .....	118
Tabla AI. 2 : Valores máximo y mínimo de cada estadístico por clase, para Máximo Exponente de Lyapunov con algoritmo de Rosestein .....	120
Tabla AI. 3 : Valores máximo y mínimo de cada estadístico por clase, para Máximo Exponente de Lyapunov con algoritmo de Kantz .....	122
Tabla AI. 4 : Valores máximo y mínimo de cada estadístico por clase, para Dimensión de Correlación.....	124
Tabla AI. 5 : Valores máximo y mínimo de cada estadístico por clase, para Entropía de Correlación .....	126
Tabla AI. 6 : Valores máximo y mínimo de cada estadístico por clase, para Complejidad Lempel-Ziv .....	128
Tabla AI. 7 : Valores máximo y mínimo de cada estadístico por clase, para Exponente de Hurst, con algoritmo de Varianza Agregada .....	130
Tabla AI. 8 : Valores máximo y mínimo de cada estadístico por clase, para Exponente de Hurst, con algoritmo de Momento Absoluto .....	132
Tabla AI. 9 : Valores máximo y mínimo de cada estadístico por clase, para Exponente de Hurst, con algoritmo de R/S .....	135
Tabla AII. 1: Éxitos obtenidos y número de neuronas en el estudio entre clases .....	137

Tabla AII. 2: Éxitos obtenidos y número de neuronas en el estudio sano-patológico .	138
Tabla AII. 3: Tasa de acierto, por clase y parámetro, con tamaño óptimo de trama....	139
Tabla P. 1: Relación entre horas trabajadas y factor de correlación.....	2
Tabla P. 2: Gastos de amortización del hardware .....	4
Tabla P. 3: Gastos de amortización del software.....	4
Tabla P. 4: costes de redacción.....	5
Tabla P. 5: Importe final.....	7

# I MEMORIA



# Capítulo 1

## 1. INTRODUCCIÓN

### 1.1. MOTIVACIONES

Según fuentes de la Organización Mundial de la Salud (OMS), las enfermedades cardiovasculares son en la actualidad la principal causa de muerte en todo el mundo. Esto se traduce en que, cada año, mueren más personas por este motivo que por cualquier otra causa, suponiendo el 31% del total de los fallecimientos a nivel mundial en el año 2012. Además, esta misma fuente ha previsto que, para el año 2030, el número de fallecimientos debido a estas afecciones será de casi 23,3 millones de personas y que, asimismo, seguirá siendo la principal causa de defunciones en el futuro [1]. Cabe destacar también que la OMS ha presentado, como primera meta mundial, la reducción relativa de la mortalidad por enfermedades cardiovasculares (además de otras no transmisibles) en un 25% para el año 2025 [2]. Además, otra de las metas mundiales que se propone llevar a cabo la OMS para el año 2025 es el tratamiento farmacológico y asesoramiento de al menos un 50% de las personas que lo necesitan para prevenir ataques cardíacos y accidentes cerebrovasculares. Esto último se recoge en el “Informe sobre la situación Mundial de las enfermedades no transmisibles” de 2014 y deja constancia de la necesidad de unos medios que faciliten tal labor.

En cuanto al ámbito nacional, el Instituto Nacional de Estadística (INE), en una nota de prensa publicada en febrero de 2015, indicaba que en el año 2013 se produjeron en España un total de 117.484 fallecimientos debido a enfermedades cardíacas. Esto supone un 30,1% de los fallecimientos en nuestro país. Y, aunque ese año ya se registraba un descenso del 3,9% respecto al año anterior, este tipo de enfermedades sigue siendo la que continúa ocupando el primer lugar en cuanto a número de defunciones en mujeres y el segundo en varones [3].

Es por lo anterior por lo que se advierte la necesidad e importancia de elaborar mejoras en la prevención y en la investigación, con la finalidad de reducir tales estadísticas, tanto a nivel nacional como internacional.

## **1.2. ANTECEDENTES**

Uno de los mayores problemas en la detección de anomalías cardíacas viene dado por la subjetividad con la que el médico especialista analiza la señal electrocardiográfica (ECG). Afortunadamente, hoy en día existen diferentes técnicas para la detección de patologías que ayudan en la labor del experto. La cardiología se decanta por la obtención de métodos no invasivos que eviten cualquier posible riesgo al paciente y que, al mismo tiempo, sean capaces de aportar la mayor cantidad de información para la realización de un buen diagnóstico. Asimismo, la bioingeniería muestra especial interés por las señales ECG al tratarse de un método no invasivo y por la posibilidad de análisis desde el punto de vista del procesado de señal. Son cuantiosos los estudios realizados bajo análisis lineales de la señal ECG para la realización de diferentes diagnósticos, tales como para arritmias [4], [5], o en ámbitos diferentes (como en la apnea del sueño [6]), pero el sistema cardiovascular es en realidad demasiado complejo como para ser considerado absolutamente lineal. Los modelos no lineales han posibilitado un nuevo enfoque de algunos sistemas y han permitido cuantificar características de los datos bajo estudio que con los métodos lineales se era incapaz de lograr, revelando muchas veces que estos sistemas presentan componentes altamente no lineales o caóticas que determinan su comportamiento. Además, 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 [7].

Aunque el estudio de técnicas no lineales basadas en la teoría del caos es un tema de gran interés actual para muchos investigadores y existe una gran cantidad de trabajos desarrollándose en diferentes áreas de conocimiento basadas en estas técnicas, el estudio de la dinámica caótica aplicada a la señal ECG tiene relativamente pocos antecedentes en la investigación. Fue en 1997 cuando se presentó la clasificación de arritmias cardíacas usando redes neuronales de base radial (que realizan una transformación no lineal de algunas señales) [8]. Por otra parte, también se han realizado clasificaciones de ciertos

tipos de arritmias usando algunos tipos de medidas de complejidad. Por citar algunos ejemplos, se han empleado para la clasificación de un modelamiento paramétrico autorregresivo (en 2002) [9]; posteriormente, se aplicaron en dichos métodos parámetros como la entropía, el diagrama de Poincaré y el máximo exponente de Lyapunov (2004 y 2008) [10], [11]; y por último (2006), también la entropía de Shannon y la complejidad de Lempel-Ziv [12].

En el ámbito nacional, más concretamente a nivel regional, el Grupo de Procesado Digital de Señal (GPDS) de la ULPGC lleva investigando en el campo de las señales biomédicas desde 1993, y en el área de patologías cardíacas desde 2005. Desde entonces se han desarrollado estudios para la detección de este tipo de patologías mediante el análisis de la señal ECG, utilizando exclusivamente modelos lineales. En 2006 se presentó un estudio analítico de la señal ECG, en el que se consiguió realizar una extracción fiable de sus parámetros característicos para poder obtener un clasificador de precisión [13]. En 2007 se da un paso más, logrando el reconocimiento automático de arritmias específicas, basado en ECG, usando teorías lineales como la transformada de Wavelet [14], [15], [16]. Ya en 2011 se incorpora una mejora a este trabajo obteniendo la diagnosis de arritmias con el mínimo esfuerzo computacional y la creación de una base de datos propia [17]. Ese mismo año, se diseña también un detector de cardiopatías en tiempo real con el uso novedoso de dispositivos programables (FPGA) en este tipo de diagnóstico [18]. En cuanto a la aplicación de modelos no lineales, el departamento ha realizado hasta ahora estudios aplicados solamente a la señal de voz, ofreciendo como aporte parámetros basados en dinámica caótica no presentes en la literatura hasta entonces, aunque restringidos a la finalidad de clasificar en sana o patológica exclusivamente la señal de voz [19], [20], [21] y modelado de ruido en maquinaria [22].

En el presente proyecto fin de carrera se propone, en cambio, un estudio de modelos no lineales en la detección de patologías cardíacas. Además del estudio de la viabilidad de dicho fin, se tiene el objeto de clasificar si la señal electrocardiográfica bajo análisis se trata de un paciente sano o patológico, y asimismo de ser capaz de diagnosticar el tipo de patología.

### 1.3. DESCRIPCIÓN

En este documento se expone la realización de un Proyecto Fin de Carrera (PFC) que consiste en el desarrollo de una aplicación, bajo el entorno Matlab, para obtener una herramienta de detección y diagnóstico de distintas patologías cardíacas, basándose en medidas de complejidad (no linealidad). Más concretamente, se trata de detectar automáticamente la existencia de anomalías cardíacas y su clasificación, a partir de muestras de normalidad, o control, de la señal ECG y de muestras con diferentes tipos de patología cardíacas.

En primer lugar se obtendrán las señales electrocardiográficas (ECG) desde bases de datos de repositorios disponibles en Internet. Puesto que se trabajará con bases de datos con su propio formato, será necesaria la adaptación de dicho formato para poder trabajar con ellas en el software Matlab.

Seguidamente, se realizará un preprocesado de la señal. Diferentes tipos de filtrado serán necesarios para eliminar las típicas perturbaciones que tienen lugar durante el registro de una señal ECG.

De las señales adquiridas se extraerán medidas de complejidad con el fin de obtener la información que permita discriminar entre señales ECG de pacientes sanos de señales con algún tipo de patología cardíaca.

Para ello, se hará un estudio de diferentes medidas de complejidad presentes en la literatura actual. La utilización de nuevos instrumentos matemáticos procedentes de la teoría del caos son algunos de los aspectos cuyo desarrollo proporcionará un mayor grado de precisión en la simulación de los fenómenos reales que rigen el funcionamiento cardíaco. Las medidas de complejidad con las que se trabajará son: máximo exponente de Lyapunov, dimensión correlación, entropía de correlación, complejidad de Lempel-Ziv, y exponente de Hurst.

Posteriormente se realiza un estudio de la no linealidad de los parámetros caóticos extraídos de las señales ECG mediante el cálculo de diferentes estimadores matemáticos: media, varianza, asimetría (*skewness*) y curtosis. Tras ello se realiza un estudio de la duración óptima de trama, definiendo como tamaño óptimo de trama aquel que ofrece una mayor tasa de acierto a través de simulaciones.

Seguidamente, se utilizarán clasificadores para evaluar el grado de discriminación de los parámetros estudiados. Para ello se analizan diferentes clasificadores y se ensaya la configuración óptima que ha de tener el clasificador elegido.

Por último se evaluarán los resultados obtenidos para determinar la viabilidad del proyecto y poder extraer las conclusiones. Tras esto se propondrán cambios o mejoras.

#### **1.4. OBJETIVOS**

El objetivo principal de este trabajo es el estudio de nuevas medidas basadas en la teoría del caos con la finalidad de distinguir entre señales de ECG de pacientes sanos y señales de pacientes con alguna patología cardíaca, mediante la utilización de un clasificador no lineal.

Los objetivos específicos son:

- La adquisición de conocimientos sobre modelos no lineales y sus técnicas de procesado para las señales de ECG
- El aprendizaje del uso de los algoritmos de parametrización basados en la teoría del caos.
- La realización del sistema parametrización-clasificación que detecte automáticamente patologías cardíacas.
- El estudio de las prestaciones de las medidas no lineales en patologías cardíacas.

Lo que se propone en este Proyecto Fin de Carrera (PFC) es añadir un aporte al campo de la Biomedicina mediante el desarrollo de un software con la finalidad de resolver los problemas de subjetividad en el diagnóstico de cardiopatías y facilitar la labor del médico especialista usando modelos basados en dinámica no lineal.

#### **1.5. METODOLOGÍA**

El desarrollo del presente Proyecto Fin de Carrera se puede dividir en cuatro fases atendiendo a las tareas realizadas y su planificación temporal:

1. Fase de documentación.
2. Fase de estudio de los parámetros.
3. Fase de estudio del clasificador.
4. Fase de estudio del sistema.

### **1.5.1 Fase de documentación**

En la fase de documentación se adquirirán los conocimientos teóricos básicos que permitirán el desarrollo y realización del presente trabajo.

En primer lugar se realizará un estudio de la teoría de sistemas no lineales, especialmente de los sistemas no lineales caóticos. Además, es necesaria la comprensión de los mismos en su aplicación sobre series temporales.

En segundo lugar, se adquirirá la información necesaria para el reconocimiento, comprensión y tratamiento de la señal de electrocardiograma.

Por otra parte, se estudiarán los sistemas de clasificación y su manejo. Se profundizará concretamente acerca del sistema de clasificación basado en redes neuronales y su utilización con Matlab.

Dicha documentación se adquirirá principalmente de libros especializados, así como documentos publicados por IEEE y de buscadores como scholar y scopus.

### **1.5.2 Fase de estudio de parámetros**

La fase de estudio de parámetros consiste, en primer lugar, en el aprendizaje del manejo de las funciones proporcionadas por el paquete TISEAN (Time Series ANalysis) [23] y la herramienta Caos, proporcionada por el departamento de GPDS de la ULPGC. Con este conocimiento más el obtenido en la fase de documentación, se estudiarán distintos parámetros basados en la teoría del caos.

Para la extracción de dichos parámetros se utilizarán las herramientas TISEAN y Caos sobre el entorno matemático Matlab. Para llevarlo a cabo será necesario la creación previa y utilización de una base de datos.

Tras la extracción y la evaluación de la no linealidad de cada parámetro en base a los resultados obtenidos de estadísticos matemáticos, se efectuarán simulaciones para estudiar la viabilidad de cada parámetro.

Finalmente, con los parámetros propuestos se realizará un estudio del tamaño temporal óptimo de la trama de la señal de ECG.

### **1.5.3 Fase de clasificación**

En la fase de clasificación se estudian varios clasificadores y sus diferencias, y finalmente se optó por la utilización de un método de clasificación no lineal, concretamente redes neuronales. Esta elección se debió a que ha sido demostrado que las redes neuronales son capaces de modelar y predecir series temporales generadas por sistemas caóticos [20] y porque se trata de una herramienta que se encuentra estandarizada.

Para llevar a cabo la clasificación, el punto de partida son los parámetros seleccionados en la fase anterior. Se eligió la topología de la red neuronal más óptima así como el algoritmo de decisión para conseguir una mayor tasa de éxito con los parámetros caóticos usados.

### **1.5.4 Fase de estudio del sistema**

En esta fase se elabora un análisis acerca del comportamiento del sistema en base a los resultados obtenidos y se extraerán conclusiones.

## **1.6. ESTRUCTURA DE LA MEMORIA**

La redacción del presente Proyecto Fin de Carrera se estructura en cuatro bloques: Memoria (junto con sus Anexos), Pliego de Condiciones, Planos y Programas, y Presupuesto.

- En la Memoria se realiza una descripción detallada del trabajo desarrollado y los resultados obtenidos. En los Anexos se muestran resultados secundarios obtenidos en el proyecto.
- En el Pliego de Condiciones se especifica los requerimientos, *software y hardware*, necesarios para poder desarrollar el presente Proyecto, además de las condiciones legales.
- En el bloque de Planos y Programas se muestran las interfaces del código desarrollado, además de una breve descripción de la funcionalidad de cada programa.
- En el Presupuesto se estima la cuantificación económica total del desarrollo de este Proyecto Fin de Carrera.

El bloque Memoria, el más extenso, se estructura a su vez en 8 capítulos y de dos anexos.

- En el primer capítulo, *Introducción*, se justifica la relevancia que tiene la elaboración de este proyecto y los objetivos que se han propuesto. Además se cita brevemente el estado del arte y se describe cómo se procederá para desarrollar el trabajo.
- En el segundo capítulo, *La señal electrocardiográfica y las patologías cardíacas*, se hace una descripción de cómo se conforman las señales de ECG y el significado de su morfología. Se explica además los conceptos básicos y las notaciones de las señales ECG que se utilizarán a lo largo de este proyecto. Por último, se resumen las características de las patologías cardíacas que componen la base de datos.
- En el tercer capítulo, *Base de datos*, se indica los requerimientos necesarios que ha de tener una base de datos y se describe la base de datos que se ha utilizado para crear la nueva base de datos que se empleará en la extracción de parámetros. Además, se explica el procedimiento empleado en la elaboración y las características de esta nueva base de datos.
- En el cuarto capítulo, *Preprocesado de la señal de ECG*, se plantea el problema de las perturbaciones de las señales de ECG. Se describen las más usuales y los diferentes tipos de filtrados que se realizaron para eliminarlas. Por último, se muestran los resultados obtenidos tras los filtrados.

- En el quinto capítulo, *Parámetros de dinámica no lineal*, se describe cómo se ha realizado la extracción de las medidas de complejidad de las señales de ECG. A continuación se elabora el estudio de los parámetros caóticos obtenidos aplicando diferentes estadísticos y se analizan los resultados.
- En el sexto capítulo, *Diseño del clasificador*, se efectúa la elección del clasificador, su topología y las razones por las que se ha llevado a cabo de tal forma. Se hacen dos estudios del número óptimo de neuronas del sistema, tanto entre clases como para la clasificación sano-patológico. Además, ambos estudios se realizan tanto para un número balanceado de muestras como para la totalidad de las muestras disponibles (desbalanceado).
- El séptimo capítulo, *Análisis de resultados*, se exponen y comentan los resultados obtenidos de los diferentes estudios que se llevaron a cabo en este proyecto.
- En el octavo capítulo, *Conclusiones y líneas futuras*, se extraen las conclusiones alcanzadas tras los resultados y se comentan las aportaciones de este proyecto. Se proponen algunas mejoras y se mencionan los problemas encontrados durante la implementación.
- En el Anexo I, *Gráficas y tablas del estudio estadístico*, se muestran gráficamente los resultados del estudio estadístico, junto con un breve análisis.
- En el Anexo II, *Gráficas y tablas complementarias de las simulaciones*, incluye aquellos resultados no principales del estudio del sistema clasificador de cardiopatías



## Capítulo 2

# 2. LA SEÑAL ELECTROCARDIOGRÁFICA Y LAS PATOLOGÍAS CARDÍACAS

### 2.1. EL LATIDO CARDÍACO

El latido cardíaco puede definirse como la acción de bombeo del corazón gracias al cual puede mantenerse el flujo sanguíneo en circulación por el cuerpo humano (y en animales con sistema circulatorio). Los latidos tienen su origen debido a la generación de una señal eléctrica en el nódulo sinoauricular, el cual se encuentra dentro de un sistema llamado sistema de conducción cardíaco. La señal, tras generarse, se propaga a través de dicho sistema a todas las partes del miocardio (músculo cardíaco). Esta acción se divide en dos fases: la primera, llamada sístole, de contracción y la segunda, diástole, de relajación.

La primera fase comienza cuando las aurículas se encuentran llenas de sangre y reciben una señal eléctrica enviada por el nódulo sinoauricular. La llegada de la señal a las mismas provoca que éstas se contraigan, y la sangre almacenada en ellas se impulse hacia los ventrículos. Esta señal continúa propagándose hacia los ventrículos, lo que provoca la contracción también de éstos, impulsando su salida al exterior por las válvulas pulmonar y aórtica.

La segunda fase, diástole, ocurre tras el vaciado de sangre, que permite que los ventrículos se relajen. La relajación ventricular posibilita asimismo la entrada de sangre nuevamente en las aurículas, con lo que el ciclo vuelve a empezar [24].

### 2.2. CONFORMACIÓN DE LA SEÑAL DE ECG

Para poder entender por qué la forma de onda de la señal electrocardiográfica tiene tal aspecto, es necesario conocer cómo es la señal eléctrica generada en el corazón. Se verá a

continuación la forma que tiene al originarse, y cómo va modificándose a su paso por el sistema de conducción.

### 2.2.1. Sistema de conducción eléctrica

Para el fin propuesto, no resulta de especial interés entrar en detalle en este tema. A modo de resumen, puede decirse que el sistema de conducción eléctrica no es más que un sistema formado por un conjunto de *fibras cardíacas* dispuestas de una manera organizada que permiten la propagación de la señal eléctrica cardíaca a través del músculo cardíaco [25].

En la siguiente figura [25] se muestra cómo es la red que forma el sistema de conducción eléctrica. El esquemático permite hacerse una idea de las distintas etapas por las que pasará la señal.

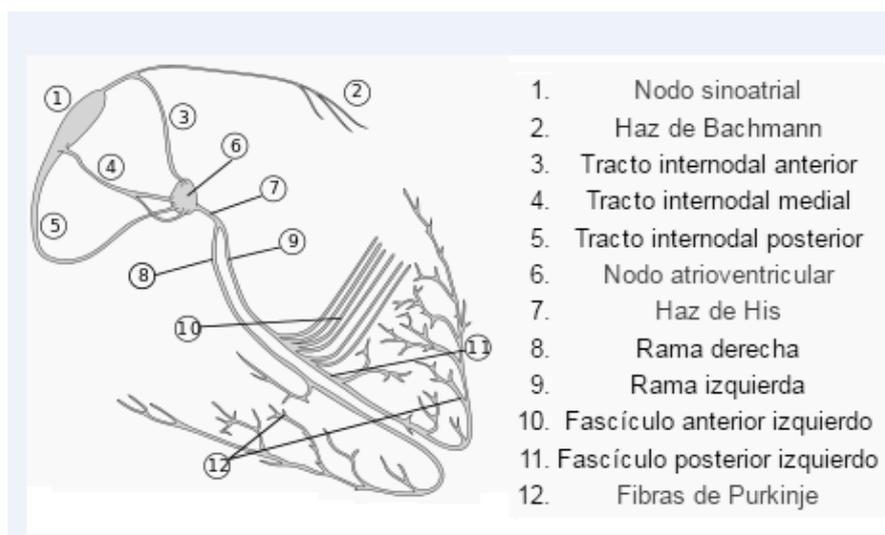


Figura 2. 1: Sistema de conducción eléctrica del corazón

### 2.2.2. Señal eléctrica cardíaca

Para conocer la forma inicial de dicha señal es necesario conocer cómo se origina. La señal eléctrica transmitida tiene su origen en el nódulo sinoauricular debido a un potencial llamado potencial de acción transmembrana. Este potencial se produce debido a una serie de cambios iónicos, concretamente de iones Calcio ( $Ca^{++}$ ) e iones Sodio ( $Na^{++}$ ), a través

de las membranas de las células musculares cardíacas. El proceso consta de dos fases: despolarización (o activación) y repolarización (o recuperación).

La despolarización es la fase de activación, en la que los iones calcio y sodio entran a la célula (fase 0). Tras esta ocurre la repolarización, que es la recuperación, en la que se restablece el equilibrio iónico inicial expulsando al exterior de la célula iones potasio ( $K^+$ ) en 4 etapas diferenciadas (fases 1, 2, 3 y 4). El registro de esta actividad se corresponde con la curva mostrada en la figura siguiente.

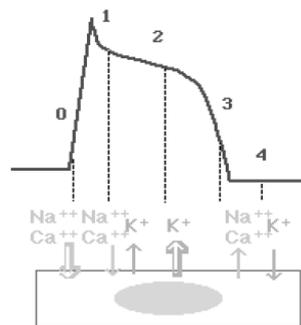


Figura 2. 2: Potencial de acción de la célula contráctil ventricular

Como ya se ha mencionado, tras producirse el potencial de acción transmembrana, éste se propagará a lo largo del sistema de conducción provocando los movimientos de sístole y diástole y, por tanto, el latido cardíaco.

Es el registro de la propagación del potencial, a lo largo de los distintos puntos del sistema de conducción, el que dará forma a la señal electrocardiográfica. En otras palabras, los potenciales de acción y la señal de ECG se alinean en el mismo eje de tiempo, pero con distintos puntos de origen. Por tanto, la suma de los potenciales de acción compone la señal ECG. La conformación de la señal de ECG se puede observar detalladamente en la figura 2.3.

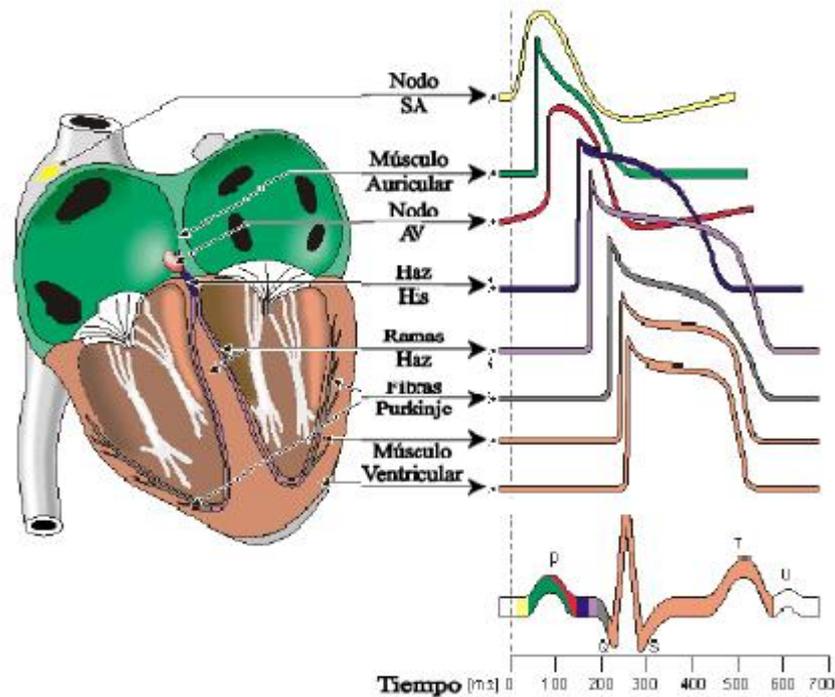


Figura 2. 3: Conformación de la señal de ECG

El resultado es una señal no uniforme compuesta por una serie de ondas o desnivelaciones, que se describirán en el siguiente apartado.

### 2.3. DESCRIPCIÓN DE LA SEÑAL DE ECG

La forma de onda de la señal electrocardiográfica se caracteriza por poseer un conjunto concreto de desnivelaciones respecto a la horizontal. En esta sección se definirán conceptos básicos, tales como línea basal, onda, segmento, intervalo, y complejo de una señal ECG; que resultarán de utilidad ya que serán manejados con posterioridad.

#### 2.3.1. Conceptos básicos sobre la señal de ECG

- **Línea basal.** La línea basal o isoeletrica puede definirse como la línea horizontal que muestra el aparato de medida cuando no hay actividad eléctrica

en el corazón. Dicho de otra forma, es la línea uniforme que separa un latido de otro [26].

- **Ondas.** Son las deflexiones sobre la línea basal, que pueden ser positivas o negativas. Tradicionalmente se designan a dichas ondas con las letras P, Q, R, S y T, como muestra la siguiente imagen.

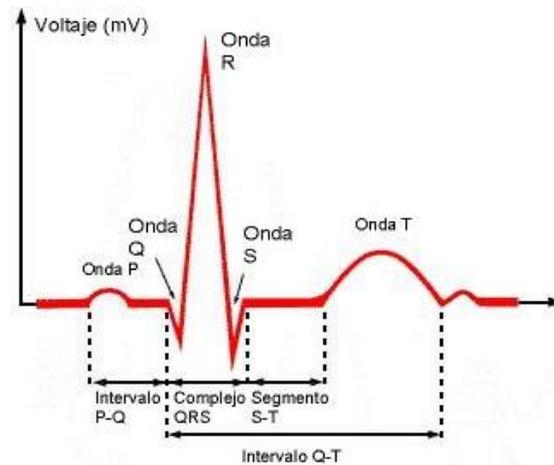


Figura 2. 4: Ondas, intervalos, segmentos y complejos de un ECG

- **Segmento.** Se define segmento como la distancia entre dos ondas
- **Intervalo.** Es la duración de una onda más un segmento.
- **Complejo.** Un complejo está formado por un grupo de ondas sin segmentos entre ellos, como lo es el complejo QRS.

Por último, es necesario indicar que la forma de onda obtenida depende de cómo haya sido tomado tal registro. Los electrodos pueden disponerse en diferentes puntos sobre el paciente, es decir, existen distintas derivaciones. Las que se utilizaron en la elaboración de este proyecto fueron las usadas mayoritariamente por el MIT-BIH, la derivación MLII (*Modified limb lead II*).

### **2.3.2. Significado e interpretación de la señal de ECG**

En este apartado se indica cómo interpretar una señal de ECG en función de la morfología que presenten sus ondas o el complejo QRS.

- La onda P representa la despolarización (activación) en la aurícula. Cualquier aumento en ella, ya sea en duración o amplitud, implica una anomalía en la aurícula. Tiene una duración normal de 0,1 s.
- El complejo QRS representa la despolarización (activación) de los ventrículos. Tiene una duración de alrededor de 100 ms y amplitud entre 6 y 8 mV, por lo tanto fuera de esos valores implicaría que existe anomalía cardíaca. Además, se ha de tener en cuenta que las ondas Q y S a menudo no suelen visualizarse.
- La onda T representa la repolarización (recuperación) de los ventrículos. Una anomalía en esta onda puede indicar anomalías cardíacas primarias, aunque también se da en pacientes sanos.

## **2.4. PATOLOGÍAS CARDÍACAS**

El objetivo de este apartado consiste en ofrecer una descripción muy breve de las distintas patologías que van a tratarse en este proyecto, así como tener conocimiento de la forma de onda característica de cada una de ellas.

### **2.4.1. Introducción**

Por definición, se dice que existe patología cardíaca cuando existe algún tipo de funcionamiento irregular del músculo cardíaco. Esto puede influir en el ritmo desembocando en arritmia cardíaca, la cual se define médicamente como una anomalía en el ritmo cardíaco, pudiendo afectar a la frecuencia, intensidad y/o regularidad de las contracciones del corazón. Cuando este ritmo se acelera y aumenta la frecuencia de latidos, esto es, sobrepasando los 100 latidos por minuto, se habla de taquicardia. En cambio, cuando existe desaceleración a menos de 60 latidos por minuto, se define como bradicardia. Por otra parte, existen además dos grandes categorías en las que se clasifican

las arritmias, determinada según dónde se produzca la anomalía. Cuando se origina en los ventrículos, se habla de arritmia ventricular y si, por el contrario, se producen en las aurículas o en las vías de conducción auricular, entonces son las llamadas arritmias supraventriculares.

Hoy en día existe gran variedad de patologías cardíacas, con mayor o menor incidencia en la población. Los dos tipos de latidos cardíacos ectópicos más comunes son los latidos ventriculares prematuros (LVP), considerados una arritmia ventricular, y los latidos auriculares prematuros (LAP), arritmia catalogada como supraventricular [27]. En este proyecto van a presentarse ambas patologías, las cuales se compararán con la señal de latido normal, que actuará como referencia.

#### 2.4.2. Latido normal o ritmo sinusal

El latido normal, también llamado ritmo sinusal, se caracteriza por tener una forma de onda tal como la mostrada en la siguiente figura. Este registro ha sido extraído de un paciente con pulso normal de la base de datos del MIT-BIH.

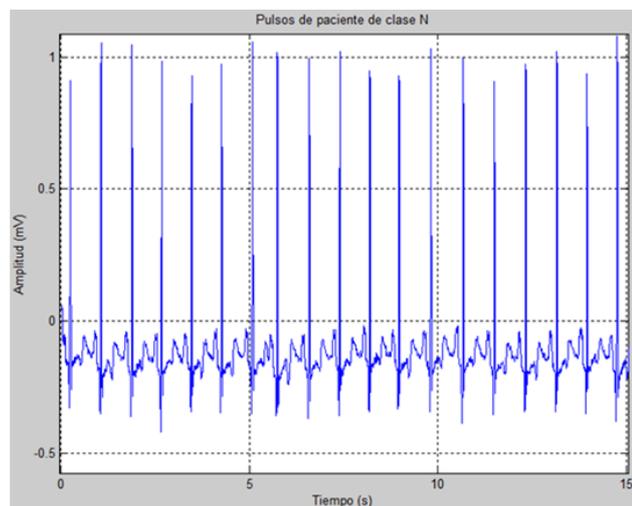


Figura 2. 5: Señal de ECG para paciente sano

Por otra parte, analíticamente y a modo de resumen, se identifica por:

- Una onda P antes de cada complejo QRS. Este hecho implica una relación normal entre la actividad auricular y la ventricular. Ha de ser, además, menor a 0,1 segundos.
- Un ancho del complejo QRS cuya duración oscile entre 0,06 y 0,1 segundos. Si el ancho del QRS es menor, el ritmo se origina en las aurículas; si mayor, en los ventrículos.
- Un intervalo PR de entre 0,12 y 0,20 segundos. Si el intervalo PR es mayor se debe a que el impulso se detiene demasiado tiempo en el nodo atrioventricular (AV); cuando es menor, el impulso se origina en el tejido del nodo AV, aunque también ocurre si el individuo tiene una anomalía congénita.
- En cuanto al intervalo QT, su duración varía en función de la frecuencia cardíaca: se vuelve más corto a medida que aumenta la frecuencia cardíaca.

En la figura 2.6 se muestra un ejemplo, extraído nuevamente de la base de datos del MIT-BIH, en el que se presentan tales características. La onda P es efectivamente menor a 100 ms y el complejo QRS se encuentra entre los 60 y 100 ms típicos para este tipo de latido. Además, la figura 2.5 muestra que el ritmo cardíaco es de 72 latidos por minuto, el cual se encuentra dentro de los márgenes de normalidad de 60-100 latidos por minuto.

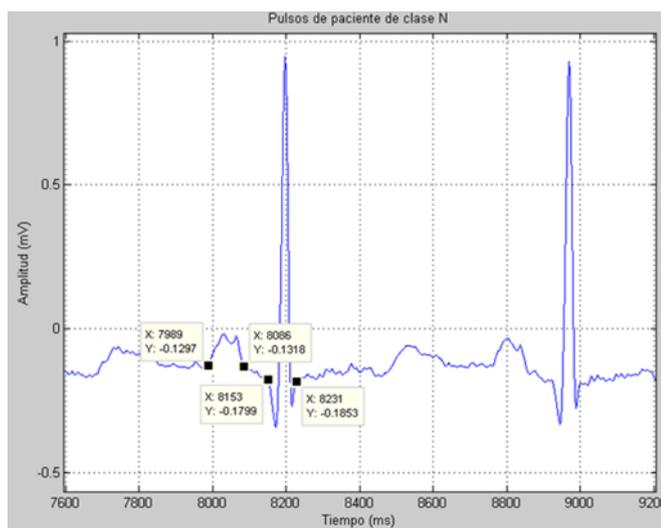


Figura 2. 6: Detalle de latido para paciente sano

### 2.4.3. Latido auricular prematuro

Se produce cuando las aurículas se contraen antes de lo debido, ocasionando un ritmo cardíaco irregular [27]. Aparecen con frecuencia en individuos sanos y pueden ser desencadenados por ansiedad, cansancio, ingestión de diversas sustancias (alcohol, tabaco, cafeína, o fármacos simpaticomiméticos), en presencia de un aumento del tamaño de la aurícula y por otros problemas cardíacos.

El especial interés en el tratamiento de este tipo de latidos se debe a que, entre otras causas, los latidos auriculares prematuros (LAP) son habitualmente asintomáticos (aunque los pacientes puedan sufrir palpitaciones ocasionalmente) y a que la exploración física es inespecífica, excepto por signos de las enfermedades subyacentes. Su forma de onda se muestra en la figura siguiente.

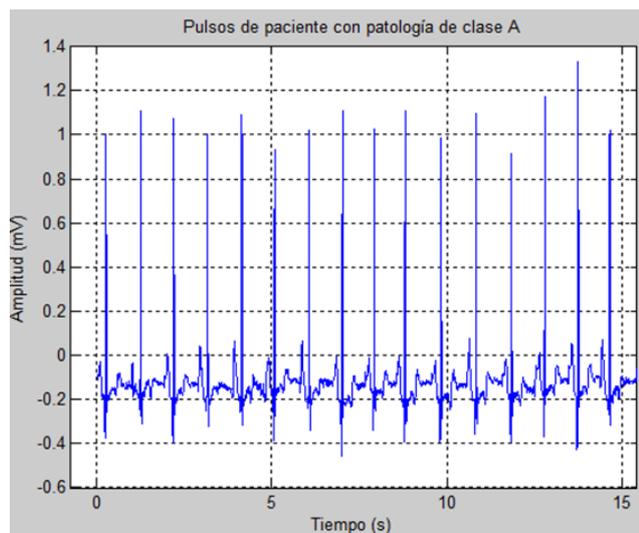


Figura 2. 7 Señal de ECG de paciente con latido auricular prematuro

Resumidamente, en el registro de ECG para LAP se identifica por:

- Las amplitudes y los ejes de las ondas P difieren de los que se observa en el ritmo normal, ya que se despolariza una parte diferente de la aurícula.
- El intervalo PR es habitualmente prolongado, ya que la conducción entre el foco ectópico y el nodo AV está enlentecida.

- Se observa a menudo un intervalo PP prolongado entre el LAP y el latido posterior.
- El complejo QRS es normal, si no existe también una conducción aberrante que rodee el nodo AV o un trastorno de la conducción ventricular.
- Los LAP pueden aparecer en patrones de bigeminismo o trigeminismo en parejas de corta duración [28], es decir, pueden aparecer una extrasístole auricular a continuación del latido sinusal, y así sucesivamente a lo largo del registro de ECG.

En la figura 2.8 se muestra un ejemplo de registro de ECG con latido atrial prematuro, extraído también de un individuo registrado en la base de datos del MIT-BIH. En la imagen se observa el intervalo PR prolongado, superior al límite de normalidad de 120 ms, al igual que el intervalo PP, que resulta mayor al habitual. Tampoco se observa la presencia de latidos ectópicos (es decir, de latidos adicionales o saltados) puesto que las pequeñas deflexiones que preceden al QRS son inferiores a 0.6 voltios y, por tanto, se trata de ondas P, cuyas amplitudes de ondas son, como se había presupuesto, superiores a las del ritmo normal.

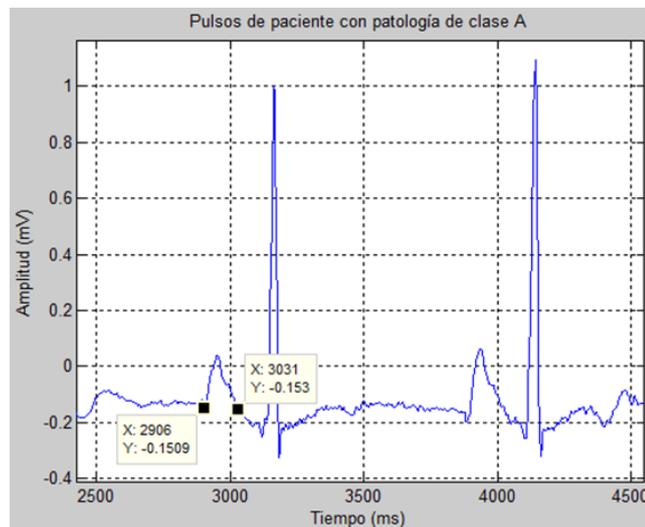


Figura 2. 8: Latido de paciente con contracción auricular prematura

#### 2.4.4. Contracción ventricular prematura

La contracción ventricular prematura (CVP), o latido ventricular prematuro, está considerada como la arritmia más común, pudiendo observarse hasta en un 50% de pacientes sanos durante un registro de 24 horas [29]. Pese a esto, se trata del tipo menos grave en cuanto a arritmias ventriculares. La CVP ocurre cuando los ventrículos se contraen antes de lo debido, adelantándose al ritmo basal del paciente.

Las CVP generalmente no son peligrosas, pero si el paciente sufre de alguna enfermedad cardiovascular o tiene antecedentes de taquicardia ventricular, las CVP pueden producir una arritmia más grave. Aunque la mayoría de las CVP se producen rápidamente y sin síntomas previos, también pueden ser debidas al consumo de cafeína y a algunos tipos de medicamentos de venta libre [28].

En la siguiente imagen se muestra la forma de onda del ECG extraído de paciente registrado en la base de datos del MIT-BIH.

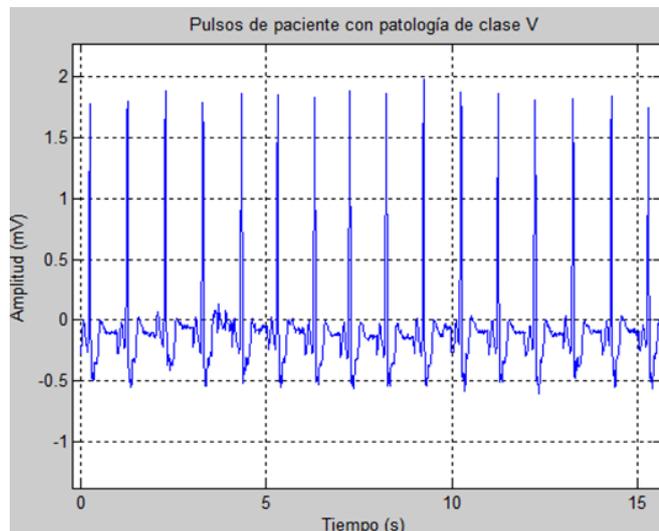


Figura 2. 9: Señal de ECG de paciente con contracción ventricular prematura

El electrocardiograma de un paciente con CPV muestra:

- Un QRS adelantado, mayor a 0,12 segundos, mellado, alterado, y que no va precedido de una onda P.
- La dirección de la onda T resulta a menudo contraria a la dirección del complejo QRS.

- La onda P puede encontrarse detrás del QRS u oculta en la onda T, y por tanto ausente.
- Se suprime un latido normal a causa del estado refractario del miocardio y del sistema de conducción, pero se mantiene el ritmo regular del nodo sinusal [28].

En la figura 2.10 se muestra un ejemplo de las características descritas para latido del tipo CVP. Se puede observar, además de la ausencia de onda P, que cada complejo dista del siguiente sin onda intermedia y que el complejo QRS en esta patología es mucho mayor que 120 ms, valor habitual de QRS.

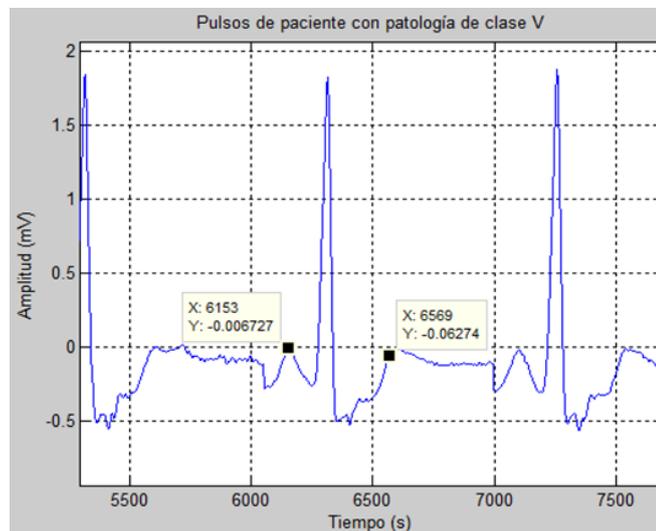


Figura 2. 10: Latido de paciente con contracción ventricular prematura

## Capítulo 3

### 3. BASE DE DATOS

#### 3.1. INTRODUCCIÓN

En la búsqueda de lograr resultados verdaderamente fiables a la hora de elaborar un clasificador de cardiopatías, es fundamental disponer de una base de datos adecuada. La correcta elección de los datos de la misma permite que los conjuntos de datos utilizados para el entrenamiento y la clasificación proporcionen una mayor eficiencia y rendimiento del clasificador [30]. Por todo esto surge la necesidad de conocer los criterios a seguir en la elaboración de bases de datos, y en particular de una base de datos de señales ECG, para poder conseguir el objetivo propuesto.

Por lo general, cualquier base de datos ha de presentar ciertos requisitos básicos que deberán tenerse en cuenta en la realización de una base de datos propia. En este capítulo se enumerarán y detallarán los requisitos necesarios para la creación de una base de datos propia. Además se realizará una descripción acerca de la base de datos que se ha empleado para conformar la base de datos propia y, finalmente, se explicará la elaboración de dicha base de datos propia.

En síntesis, en este trabajo se realizará una base de datos propia, creada a partir de otra base de datos extraída desde repositorios de internet. Para tal tarea se tendrán en cuenta las características básicas necesarias que se comentarán a continuación.

#### 3.2. CARACTERÍSTICAS DE LAS BASES DE DATOS DE ECG

En este apartado se hace una descripción acerca de cuáles son estos requisitos básicos para cualquier base de datos pero matizando para el caso particular de señales ECG [31]:

1. Contener señales que sean representativas. Para el caso de señales ECG es necesario disponer de un número suficiente de señales que sean reales y que permitan por tanto la correcta funcionalidad del clasificador.
2. Contener señales raramente observadas pero clínicamente significativas. Aunque no es difícil obtener registros de electrocardiogramas correspondientes a ciertas anomalías, a menudo aquellos más significativos son raramente registrados.
3. Contener señales estándar. Esto quiere decir que han de ser señales usadas por un amplio sector de la comunidad científica relacionada con el tratamiento de señales ECG. No tiene sentido llevar a cabo comparaciones entre distintos algoritmos o sistemas si éstos no han sido aplicados a un mismo conjunto de datos, ya que en muchas ocasiones, los resultados dependen del conjunto de datos utilizados.
4. Contener señales con anotaciones. En el caso de registros ECG, normalmente cada complejo QRS ha sido anotado por varios cardiólogos trabajando de manera independiente. Estas anotaciones sirven de referencia para comparar con los resultados producidos por el clasificador.
5. Contener señales almacenadas en formato digital accesibles a programas informáticos. Resulta de especial importancia en este trabajo ya que, de esta forma, es posible llevar a cabo diferentes test de manera automatizada y con la capacidad de poder efectuarse el número de veces que fuese necesario, permitiendo comparar resultados frente a modificaciones en los algoritmos.
6. Contener los parámetros de las señales. Los parámetros representativos como frecuencia de muestreo, ganancia, etc. deben ser conocidos, puesto que serán de utilidad para realizar el filtrado de las señales.

### **3.3. BASE DE DATOS UTILIZADA**

#### **3.3.1. Motivos**

A diferencia de otros tipos de bases de datos, la obtención de registros electrocardiográficos no es algo que pueda obtenerse de manera relativamente simple. Se precisa de aparatos e instrumentación médica que realice los registros de la señal.

Afortunadamente existe en la red un gran archivo, de libre acceso y aún en expansión, de grabaciones de señales fisiológicas en formato digital. Además éste también proporciona conjuntos de datos relacionados entre sí para que puedan ser usados por la comunidad de investigación biomédica. Se trata de PhysioBank, un repositorio de internet que incluye actualmente bases de datos de múltiples tipos (como la cardiopulmonar, del sistema nervioso y otras señales biomédicas) de sujetos sanos y de pacientes con diferentes patologías.

PhysioBank además contiene, entre sus numerosas bases de datos, una de las bases de datos más importantes y utilizadas en la comunidad científica: la base de datos del MIT (Massachusetts Institute of Technology) [32]. En 1975 el MIT inició, conjuntamente con los laboratorios del Beth Israel Hospital (BIH), su investigación sobre el análisis de arritmias en seres humanos. Uno de sus principales logros ha sido la creación de la base de datos de Arritmias MIT-BIH (Arrhythmia Database), disponible desde 1980, convirtiéndose en el primer conjunto de señales estándar para la detección de patologías mediante señales de ECG. De hecho, hoy en día es considerada una de las principales fuentes de señales ECG a nivel mundial.

En base a lo descrito, se ha considerado utilizar la base de datos del MIT-BIH, puesto que se dispone de un conjunto de señales lo suficientemente amplio y en formato digital como para poder llevar a cabo pruebas representativas. Además cuenta con un formato abierto y común a todas ellas, lo que reduce considerablemente el esfuerzo de desarrollo de aplicaciones, y sus correspondientes anotaciones elaboradas por cardiólogos. Es por esto por lo que finalmente será la base de datos empleada para la elaboración de una base de datos propia en el presente proyecto fin de carrera.

### 3.3.2. Características

Como se ha comentado, en este proyecto se conformará una base de datos propia a partir de la citada base de datos MIT-BIH Arrhythmia Database. Esta base de datos de internet está disponible a la comunidad desde el año 2005 y se compone de 48 registros de ECG de 30 minutos cada uno. Se trata de registros ambulatorios, ya que no requirió internación de los pacientes, en los que se recogen los registros de estos 48 individuos durante media hora. Cada registro del paciente consta a su vez de dos canales, puesto que se toman dos derivaciones por paciente. La primera derivación es del tipo II (tomada del brazo derecho a la pierna izquierda) y la segunda V1, y ocasionalmente V2, V4 y V5. Para conformar la

base de datos propia se ha tomado únicamente la señal proveniente de la primera derivación, ya que mantiene el mismo tipo de derivación en la totalidad de sus registros.

En cuanto a los parámetros de cada una de las señales, la frecuencia a la que se ha realizado el muestreo es de 360Hz, con 11 bits de resolución y un rango de 10 mV. También es relevante indicar que los registros de señal de cada paciente fueron inscritos en 3 ficheros, de extensiones '.atr', '.dat' y '.hea'. A continuación se hace una breve descripción de cada uno de ellos, comentando su aplicación en el presente trabajo.

### ***Tipos de fichero***

- Los archivos '.atr' contienen el etiquetado completo, en el que se incluyen anotaciones sobre los pulsos e información adicional de la señal, como el tipo de ritmo cardíaco y otras anotaciones médicas relevantes. De este archivo será relevante únicamente la información sobre qué pulsos son patológicos, cuáles no y su correspondiente patología.
- Los archivos '.hea' contienen la cabecera de la señal de ECG, aportando la información sobre la frecuencia de muestreo, número de canales disponibles, patologías presentes en la señal y medicación proporcionada al paciente. Proporciona los datos a usar para el diseño de los filtros del preprocesado de la señal.
- Los archivos '.dat' contienen la señal de ECG digitalizada correspondiente a los dos canales, registrados durante media hora. Estos archivos son los que contienen la información útil a los que se le aplicarán las distintas técnicas de procesado de este proyecto.

Por otra parte, las clases de latidos que incluye la base de datos del MIT-BIH se exponen en la siguiente tabla:

TABLA 3. 1 : TIPOS DE LATIDOS DISPONIBLES EN LA BASE DE DATOS DE MIT-BIH

Símbolo	Tipo de latido
N	Latido Normal
L	Bloqueo de rama izquierda
R	Bloqueo de rama derecha
A	Latido auricular prematuro
a	Latido auricular prematuro aberrado
J	Latido prematuro del Nodo
S	Latido prematuro supraventricular
V	Contracción ventricular prematura
F	Fusión de latido normal y ventricular
[	Inicio de palpitaciones/fibrilación ventricular
!	Palpitación
]	Fin de palpitación/fibrilación ventricular
e	Latido de escape auricular
j	Latido de escape nodal
E	Latido de escape ventricular
/ ó P	Latido retardado
f	Fusión de latido retardado y normal
x	No conducción de la onda P
Q	Latido inclasificable
	Artefacto aislado QRS
+	Continuación del tipo de pulso seguido de anotación de tipo de ritmo

En cuanto a los tipos de latidos contenidos en la base de datos MIT-BIH Arrhythmia Database, es preciso indicar que cada señal de ECG registrada en ella contiene diferentes tipos de patologías dentro de un mismo registro, puesto que fueron realizadas por individuo. Esto hace que sea necesario hacer una separación de las clases de patologías para conseguir diferenciarlas y poder así entrenar el clasificador. En el siguiente apartado se explica detalladamente cómo se realiza esta clasificación para conformar la base de datos propia.

### **3.4. BASE DE DATOS PROPIA**

La realización de la nueva base de datos consistirá fundamentalmente en cuatro pasos: obtener los ficheros, adecuar el formato, separar por clases, y realizar los filtrados necesarios.

#### **1. Obtención de los ficheros**

En primer lugar, se obtienen los ficheros a tratar mediante la descarga directa de los mismos desde el repositorio de internet PhysioBank [33]. Como se indicó anteriormente, existen tres tipos de fichero por cada registro que forman la base de datos de arritmias del MIT-BIH (descritos en el apartado anterior). Por tanto se obtienen 144 ficheros con la información de los 48 pacientes.

#### **2. Cambio de formato**

Tras la descarga, será necesario adecuar el formato con el objeto de que puedan ser legibles por el software que va a ser empleado para su procesado, Matlab. Para efectuar el cambio de formato se implementó una rutina que, de manera automatizada, recogiese los ficheros de extensiones ‘.atr’, ‘.dat’ y ‘.hea’ de cada registro y generase a partir de ellos una carpeta con nuevos registros convertidos en señales ‘.mat’.

#### **3. Clasificación de los tipos de pulsos**

Como se mencionó anteriormente, es necesario disponer de señales de cada clase diferenciadas entre sí, puesto que cada paciente presenta diferentes clases de latidos

a lo largo del registro de 30 minutos, alternándose el latido normal con la llegada de una o más clases de latidos patológicos durante el registro de la señal. En definitiva, lo que la base de datos del MIT-BIH ofrece son 48 señales (dobles), cada una con una gran variedad de clases. El objetivo de esta sección es la obtención de una base de datos conformada con una gran variedad de latidos de cada una de las clases, a partir de las señales disponibles en Physionet. Serán estas últimas la que se utilizarán para el procesado y la extracción de parámetros caóticos.

Para el objetivo marcado, ha resultado indispensable disponer de las anotaciones realizadas por los cardiólogos a través de una herramienta vía web de Physionet. En dicha herramienta se configura una serie de parámetros, como son:

- La base de datos de donde va a tomarse la señal: MIT-BIH Arrhythmia Database
- La señal a tratar: código con el que está etiquetado el individuo
- El tamaño: posibilidad de extracción de la información de la señal completa o un fragmento.
- El formato: en tiempo o en muestras.
- Tipo: de alta precisión o estándar
- La información requerida de dicha señal: en este caso, las anotaciones cardiológicas como texto.

En la figura, se muestra la interfaz usada para extraer los datos cardiológicos. Se tomó como ejemplo el paciente etiquetado como 100.

Como muestra la figura, el único formato disponible en la adquisición de estos archivos de anotaciones es en texto. Así pues, tras su descarga, se creó una rutina que permitió importarlos y hacerlos legibles por Matlab.

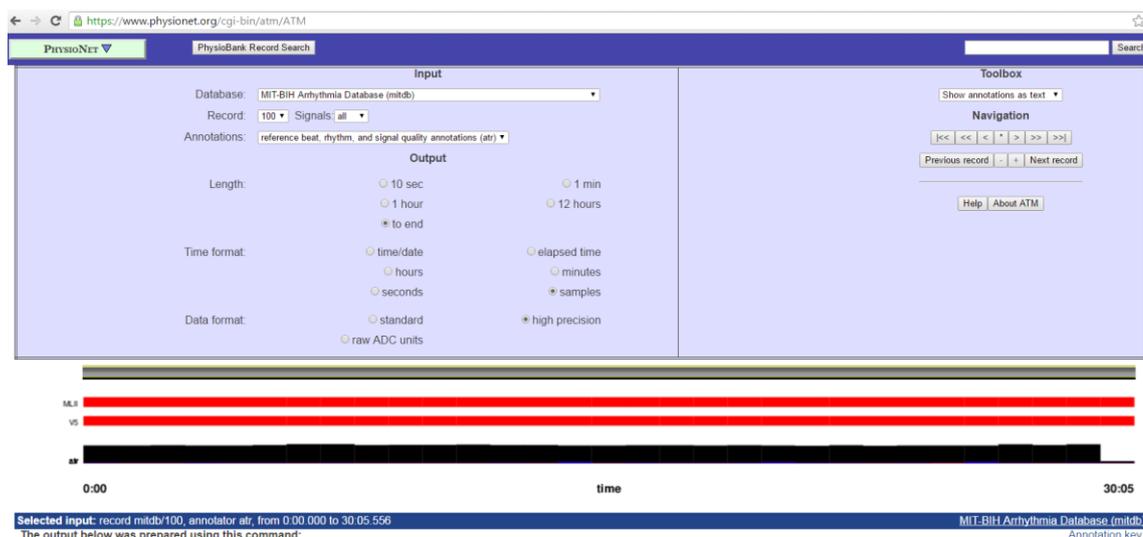


Figura 3. 1: Interfaz de Physionet para obtener las anotaciones cardiológicas

Con estos datos ya fue posible elaborar un sistema automatizado que extrajera, de cada uno de los ficheros descargados, la información cardiológica de interés para este proyecto. De dichas anotaciones, en las que se encuentra multitud de información médica irrelevante para este trabajo, se extrajo lo necesario para determinar la clase de patología correspondiente a cada pulso registrado. El proceso consiste en conservar los valores de las muestras donde se posicionan sus intervalos de RR (distancia entre dos ondas R sucesivas) y a qué clase de patología pertenece dicho intervalo.

Por último, se implementó un programa general que, accediendo a la información seleccionada, separase las diferentes clases de patologías en señales independientes. De esta forma se tiene una nueva base de datos con ficheros de clase N, L, R, A, V, F y f correspondiente a cada patología por paciente.

En la figura siguiente se muestra un ejemplo del funcionamiento del algoritmo creado para la elaboración de la base de datos propia. La señal del paciente etiquetado como 100, que contiene latidos de clase 'Normal' (N) y las patologías 'Latido Auricular Prematuro' (A) y 'Contracción Ventricular Prematura' (V), queda dividida en 3 señales: una de clase N, que pasará a formar parte de la base de datos de las señales clase N, y otras clase A y clase V, que formarán parte de la base de datos de las señales clase A y V respectivamente.

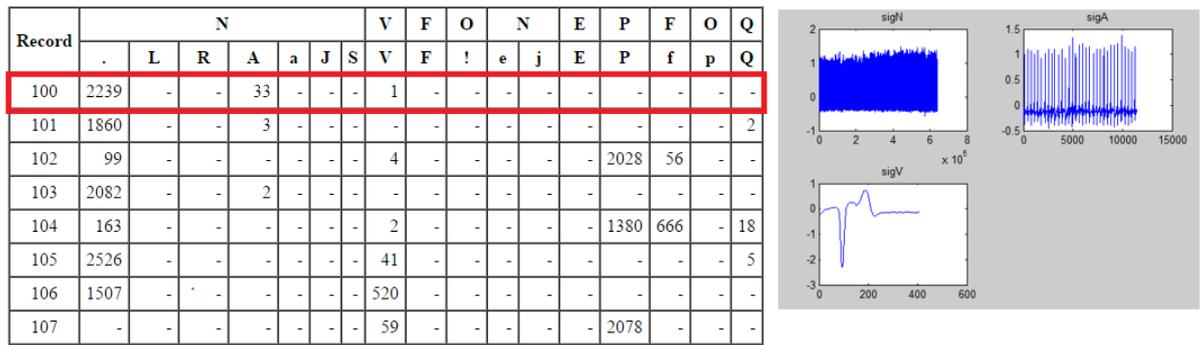


Figura 3. 2: Tabla de tipos y resultado de separar en clases la primera señal

A la izquierda de la figura se muestra un fragmento de la tabla de ‘Tipos de latidos’ proporcionada por Physionet (solamente los 8 primeros pacientes que conforman la base de datos de 48 individuos)[34]. En ella se especifica, para cada uno de los pacientes, el número de latidos para las diferentes clases que contiene. A la derecha se muestra el resultado de separar las distintas clases de la señal del individuo ‘100’ con la rutina implementada. Se puede comprobar que el resultado obtenido se corresponde con los datos cedidos en la tabla, el cual se compone de 2239 pulsos de clase N, de 33 de clase A y de 1 de clase V.

Este procedimiento se aplicará a la totalidad de las señales disponibles de MIT-BIH Arrhythmia DataBase de forma automatizada, conformando la base de datos con señales de clases N, L, R, A, V, F y f, diferenciadas y almacenadas en diferentes carpetas. Se escogieron estas 8 clases descartando el resto por ser las que ofrecían secuencias de grabación más largas, puesto que ello permitirá hacer un estudio de longitud de trama óptima para un amplio rango de longitudes de trama. Las clases que han sido descartadas, un total también de 8, contenían tamaños de secuencia insuficientes para tal fin, generalmente de 1 o 2 segundos, limitando el tamaño del posterior estudio a 2 segundos.

En síntesis, la base de datos propia está compuesta finalmente por 8 clases, de las cuales 7 son patologías y 1 es para paciente sano. En la siguiente figura se muestra qué tanto por ciento de pacientes presentan cada patología de la base de datos.

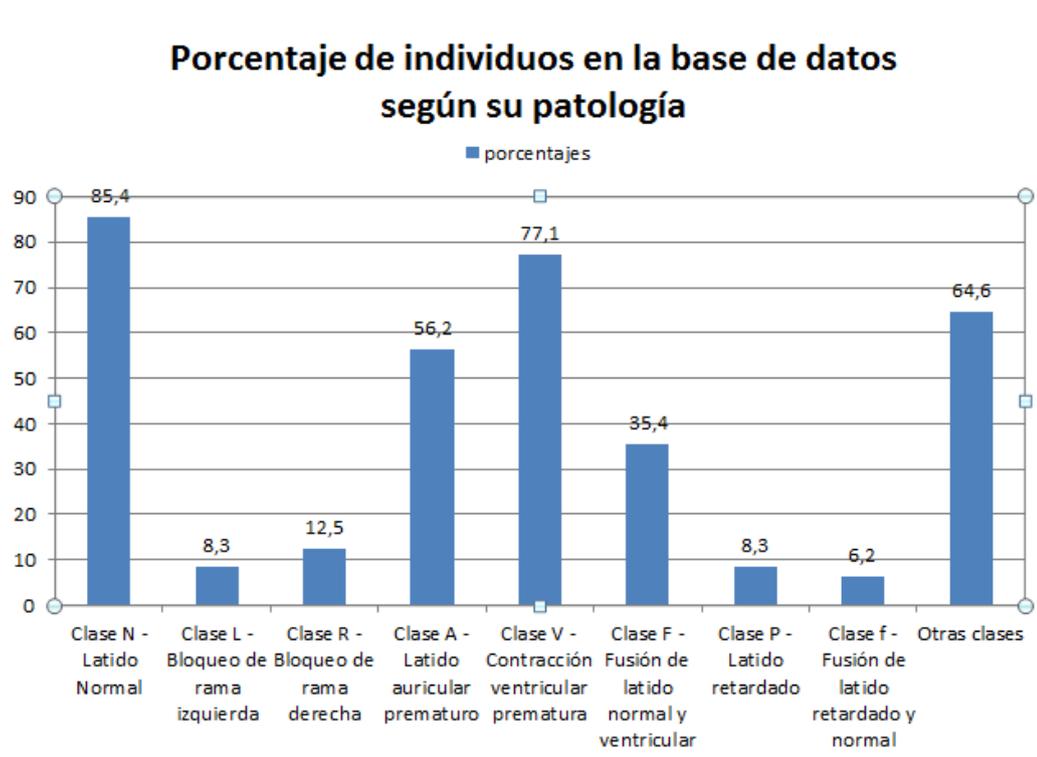
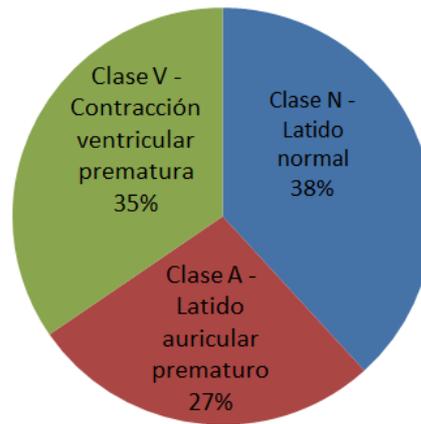


Figura 3. 3: Porcentaje de individuos con las distintas patologías y clase normal de la base de datos propia

Se observa que la mayoría de ellos presentan las patologías de clase A y clase V, además de latidos normales, N. Será, por tanto, de estas clases de las que mayor número de señales se dispondrá a la hora de hacer la clasificación. Aunque la base de datos creada ha sido formada por 8 clases, posteriormente se verá que para su clasificación se han utilizado tan sólo las 3 clases anteriormente mencionadas. Se ha decidido así puesto que de esta forma se proporcionará una mayor variedad de individuos, y por tanto diversidad, a la hora de entrenar y testear en el clasificador. Las clases descartadas muestran un número insuficiente de pacientes, de 3, 4 y 6 individuos, a diferencia de las clases N, A y V, de 41, 27 y 37 pacientes respectivamente.

En la siguiente figura se muestra la proporción existente entre el número de registros de pacientes sanos y los patológicos de clases A y V que se utilizarán finalmente en la base de datos. Es decir, cómo se distribuyen las clases que se introducirán en el clasificador. Se trata de un número de individuos más equilibrado que en el caso inicial.

### Distribución de clases en la base de datos



*Figura 3. 4: Distribución porcentual de las clases en la base datos*

## 4. Filtrado

Por último, se procedió al filtrado de las señales. Los diferentes tipos de filtrado que se aplicaron a las señales se tratan a continuación, en el capítulo de preprocesado.



## Capítulo 4

# 4. PREPROCESADO DE LA SEÑAL DE ECG

### 4.1. INTRODUCCIÓN

La señal electrocardiográfica está considerada hoy en día como una de las herramientas más importantes en el diagnóstico de patologías cardíacas. Es por esto que surge la necesidad de que ésta tenga el menor deterioro posible a la hora de procesarla, puesto que la cantidad de información extraída y la calidad de la misma dependerán de ello. Esta es la razón por la que la reducción del ruido en electrocardiogramas ha sido siempre uno de los temas más abordados en la bibliografía sobre procesado de señales de ECG.

En la práctica, la señal electrocardiográfica capturada es muy débil. Tanto es así que se encuentra muy contaminada con el ruido acoplado como interferencia (de 50 Hz o 60 Hz) procedente de la red eléctrica, debido a que no es totalmente eliminado por el amplificador diferencial de instrumentación. Por otra parte, la señal también presenta diversos artefactos de baja frecuencia generados como consecuencia de la respiración del paciente, entre otras causas. Por último, aparece también una cierta cantidad de ruido blanco que se genera en el propio sistema amplificador [16].

En este capítulo se analizarán los principales tipos de perturbaciones que afectan a las señales ECG y qué pautas de eliminación de las mismas son las aceptadas actualmente por la comunidad científica. Por último, dichas técnicas se aplicarán sobre la señal a procesar.

### 4.2. TIPOS DE PERTURBACIONES EN LA SEÑAL ECG

Los tipos de perturbaciones más comunes que aparecen en el registro de señales electrocardiográficas son las siguientes [35]:

1. **Interferencias por la red de alimentación:** Es una señal proveniente de la red eléctrica, de 50 o 60 Hz y sus armónicos, que se incorpora al ECG durante la captación del mismo. Su amplitud supera el 50% de la amplitud pico a pico ECG.
2. **Ruido por contacto de electrodos:** ocurre cuando se pierde el contacto entre el electrodo y la piel y se desconecta al sujeto del sistema de medición.
3. **Artefactos de movimiento:** los movimientos del paciente durante el registro de la señal provocan el movimiento del electrodo. Estos producen cambios transitorios en la señal ECG debidos a las variaciones en la impedancia electrodo-piel.
4. **Contracción muscular:** la actividad eléctrica producida por los músculos genera un ruido que puede ser registrado mediante un electromiograma, aunque normalmente se encuentra en un rango del orden de microvoltios y se suele considerar insignificante. En cambio, se puede apreciar con claridad en el espectro de la señal.
5. **Desplazamiento en la línea basal:** la respiración, entre otros factores, provoca que la línea basal del ECG se desplace. Este ruido puede representarse como una componente sinusoidal a la frecuencia de respiración, adherida a la señal ECG, que modula en amplitud al ECG. Variación de frecuencia: de 0.15 Hz a 0.3 Hz.
6. **Ruido electro-quirúrgico:** Este ruido destruye completamente la señal de ECG y se compone de una gran cantidad de sinusoides con frecuencias entre 100 Hz y 900 Hz.

Afortunadamente, de las fuentes de ruido descritas, algunas pueden minimizarse en la fase de adquisición de la señal. Por ejemplo, teniendo especial cuidado a la hora de colocar los electrodos, apantallando la sala, reduciendo el movimiento del paciente, etc. se consigue una reducción notoria de las perturbaciones. Sin embargo, algunas de ellas no pueden eliminarse o reducirse al máximo durante la fase de adquisición y se necesitan técnicas de procesado de señal para conseguir un nivel aceptable. Estas fuentes de ruido son las que se abordarán en este capítulo: el ruido muscular, el producido por la respiración y el introducido por la red.

### 4.3. TIPOS DE FILTRADO

En la búsqueda de encontrar el tipo de filtrado que mejor se adapte a las características del proyecto, se hace un repaso de las distintas técnicas existentes. En la bibliografía pueden encontrarse distintas metodologías para conseguir una reducción de ruido eficaz en señales ECG mediante técnicas de filtrado eficientes. A continuación se enumeran y describen algunas de las más utilizadas en señales electrocardiográficas:

- Técnicas clásicas de filtrado.
- Filtros de media móvil.
- Promedio de latidos.
- Aproximación mediante funciones.
- Transformada Wavelet.

#### 4.3.1. Métodos basados en técnicas clásicas de filtrado

##### 4.3.1.1. Filtros FIR

Los filtros FIR son filtros de respuesta finita al impulso. La función de transferencia que los caracteriza es:

$$H(z) = \sum_{k=0}^{N-1} h_k z^{-k}$$

siendo

$h_k$  : coeficientes de respuesta al impulso

$z^{-k}$ : retardo de la muestra de la señal de entrada, en función de k

Este tipo de filtros son más estables que los filtros IIR (de respuesta infinita), puesto que sus polos se encuentran en el origen, y son sistemas causales, ya que su salida depende

de las entradas actuales y anteriores. Además, como cualquier sistema LTI, los filtros FIR pueden ser implementados por su ecuación en diferencias mediante una estructura básica del diagrama de bloques o diagrama de flujo.

En cuanto a su estructura, Existen diferentes tipos, como la forma directa (del tipo I y II), la forma traspuesta (del tipo I y II), la forma en cascada, la forma en paralelo o la forma en celosía [18].

#### 4.3.1.2. Filtros IIR

Los filtros IIR son filtros de respuesta al impulso infinita. Requieren realimentación a la salida para conseguir una respuesta infinita al impulso. En el dominio discreto, la ecuación en diferencias se expresa de la siguiente forma:

$$y_n = b_0x_n + b_1x_{n-1} + \dots + b_Nx_{n-N} - a_1y_{n-1} - a_2y_{n-2} - \dots - a_My_{n-M}$$

siendo

$x$  : señal de entrada del filtro

$y$ : señal de salida del filtro

$b_k$ : coeficientes de entrada del filtro

$a_k$ : coeficientes de salida del filtro

$M$ : número de ceros de la función de transferencia

$N$ : número de polos de la función de transferencia

La función de transferencia de la ecuación en diferencias en dominio de la transformada Z es:

$$H(z) = \frac{\sum_{k=0}^M b_k z^{-k}}{1 + \sum_{k=1}^N a_k z^{-k}}$$

Este tipo de filtrado es inestable a bajas frecuencias, lo que hace que no sea propicio para sistemas de diagnóstico de patologías cardíacas en tiempo real [18].

### 4.3.2. Filtros de media móvil

El filtro de media móvil es uno de los más usados en el procesamiento digital de señales. Esta técnica modifica la señal para resaltar o atenuar ciertas características de la misma. Se trata de un filtro sencillo de implementar, indicado para reducir ruido aleatorio en la banda de bajas frecuencias.

Este tipo de filtro opera realizando una ponderación de las muestras vecinas a la muestra original de la señal de entrada, para producir una muestra de la señal de salida. Existen dos tipos de filtros de media móvil: los de media hacia la derecha o hacia la izquierda de la muestra de la señal de entrada y los de media simétrica.

La ecuación en diferencias que define al filtro de media hacia la derecha o izquierda, en el dominio de tiempo discreto es:

$$y[n] = \frac{1}{M} \sum_{k=0}^{M-1} x[n+k]$$

Donde M es el número de muestras vecinas a la muestra original de entrada o número de muestras a promediar.

La respuesta al impulso  $h[n]$  de este tipo de filtro de media móvil es:

$$h[n] = \begin{cases} \frac{1}{M} & \text{si } n = [0, \dots, (M-1)] \\ 0 & \text{en otro caso} \end{cases}$$

La ecuación en diferencias que define al filtro de promediado simétrico en el dominio del tiempo discreto  $n$  queda:

$$y[n] = \frac{1}{M} \sum_{k=-(M-1)/2}^{M-1/2} x[n+k]$$

Donde M, para el filtrado de media simétrica, debe ser necesariamente un número impar.

La respuesta al impulso  $h[n]$ , del filtro de media simétrica es:

$$h[n] = \begin{cases} \frac{1}{M} & \text{si } n = \left[ -\frac{M-1}{2}, \dots, \frac{M-1}{2} \right] \\ 0 & \text{en otro caso} \end{cases}$$

La respuesta en frecuencia general de los filtros de media móvil, en el dominio de la frecuencia  $f$ , se representa mediante la ecuación siguiente:

$$H(f) = \frac{\text{sen}(\pi f M)}{M \text{sen}(\pi f)}$$

Se caracteriza por una respuesta al impulso abrupta, lo que hace que su respuesta en la banda de paso está bien definida pero, por otra parte, su selectividad es muy baja y no proporciona buenos resultados en la banda atenuada puesto que es incapaz de eliminar las componentes espectrales. Además, tiene un ancho de banda de transición lento, lo que significa que es difícil la separación de componentes de frecuencia cercanas. Esto hace que los filtros de media móvil sean buenos eliminando el ruido de baja frecuencia pero no en el filtrado del ruido de alta frecuencia [18].

### **4.3.3. Promediado de latidos**

El promediado temporal de latidos es una técnica que se utiliza para mejorar la relación señal a ruido de las señales electrocardiográficas de alta resolución. Esta técnica se basa en que la señal ECG es cuasiperiódica y en que la perturbación y la señal no están correlacionadas.

Consiste en hacer un promediado de varios latidos semejantes siempre que el registro de ECG contenga una cantidad relativamente elevada de latidos.

Las condiciones necesarias son las siguientes [17]:

- Una señal de suficiente duración con un número elevado de latidos.
- La realización de una segmentación para extraer los latidos correspondientes de la señal.
- Un procedimiento de alineación temporal de los latidos para establecer un punto de sincronismo como referencia y evitar el filtrado no deseado debido al desalineamiento.

#### 4.3.4. Aproximación mediante funciones

El método de aproximación mediante funciones realiza el diseño de un filtro característico a partir de funciones o plantillas preestablecidas, basadas en el reconocimiento de formas. Por tanto, la función principal es obtener la función de transferencia que satisfaga las especificaciones.

Para obtener una función de transferencia que elimine el mayor ruido posible, se utilizan las plantillas, que limitan los parámetros de ganancia o atenuación para cada frecuencia. Algunas de estas técnicas incluyen el ajuste de curvas mediante segmentos, y el ajuste mediante polinomios y funciones ortogonales, las cuales también se usan para la comprensión de datos.

#### 4.3.5. Filtrado mediante Wavelets

Otro método consiste en emplear la teoría de wavelet para eliminar el ruido y la variación de la línea de base de las señales ECG. Para ello, se utiliza el método del par WT-IWT (*Wavelet Transform- Invert Wavelet Transform*), es decir, la transformada wavelet directa y su inversa.

Aplicar este método consiste en, tras escoger una familia wavelet y elegir un nivel de transformación ( $N=j$ ), se calcula la descomposición wavelet de la señal de entrada en un determinado nivel  $j$ , tomando los coeficientes de aproximación wavelets de cada nivel. A continuación, se aplica a los coeficientes de detalle un umbral ( $\delta_j$ ), desde el nivel 1 al  $j$ . El cálculo de este umbral y la forma de aplicarlo, determinará el resultado del proceso. El umbral es de la forma  $\delta = [\delta_1, \delta_2, \dots, \delta_j]$ , y se calculan mediante la expresión matemática  $\delta = \sqrt{2\sigma \log(N)}$ , donde  $\sigma$  es una estimación del nivel de ruido y  $N$  el nivel de transformación. De esta manera se obtienen los nuevos coeficientes de detalle que serán utilizados posteriormente para la reconstrucción de la señal del ECG sin ruido.

Existen dos técnicas de umbralización: umbralización restrictiva (*hard-thresholding*), que consiste en eliminar aquellos coeficientes que no superen el umbral y la umbralización suave (*soft-thresholding*), que consiste en escalar aquellos coeficientes que están por encima del umbral.

La señal es, por tanto, reconstruida basándose en los coeficientes de aproximación y los nuevos coeficientes de detalle calculados anteriormente, mediante la transformada inversa de wavelet.

#### **4.4. FILTRADOS REALIZADOS**

En esta sección se describirán los filtrados que se llevaron a cabo sobre las señales adquiridas desde MIT-BIH Arrhythmia Database para la creación de la base de datos propia.

##### **4.4.1. Filtrado de las variaciones en la línea basal**

###### **4.4.1.1. Características de este tipo de perturbación**

Las desnivelaciones en la línea basal son perturbaciones que se suceden muy frecuentemente a lo largo del registro de ECG, puesto que son debidas mayoritariamente a la respiración del paciente y a sus movimientos durante el proceso de adquisición. Se pretende corregir estas variaciones en la línea basal con un filtrado de baja frecuencia.

Un aspecto importante a tener en cuenta a la hora de modelar este tipo de filtrado es que resulta muy poco probable que la frecuencia cardíaca sea menor de 40 latidos por minuto (0,67 Hz) y, más aún, que sea inferior a 30 latidos por minuto (0,5 Hz). Sin embargo, con el filtrado tradicional, un punto de corte de 0,5 Hz para las señales de baja frecuencia se asocia a una distorsión considerable de la señal, particularmente en los componentes del electrocardiograma, en los que la frecuencia y la amplitud cambian abruptamente (fin del QRS e inicio del ST, desnivel del segmento ST). Por ello, la Asociación Americana del Corazón recomendó en 1975 (ratificado en 1990) un punto de corte de 0,05 Hz para la electrocardiografía diagnóstica. Se acepta, sin embargo, un filtro de hasta 0,5 Hz para equipos digitales nuevos que corrigen la fluctuación de la línea de base mientras preservan la fidelidad de registro del segmento ST [36]. Ha de tenerse especial cuidado en esta etapa puesto que un filtrado inadecuado de la señal de baja frecuencia puede afectar sensiblemente al intervalo QT (complejo QRS y onda T).

Los métodos empleados comúnmente en la eliminación de la línea basal en señales ECG son:

- Filtros FIR e IIR
- Filtros adaptativos
- Variantes en el tiempo
- Aproximación con *splines* cúbicos

Los filtros FIR son filtros generalmente eficaces, con el inconveniente de tener un elevado coste computacional y alto orden para conseguir selectividad. Contrariamente, los filtros IIR precisan un menor coste computacional, pero al no disponer de fase lineal, distorsionan la señal a su salida. Por otra parte, los filtros adaptativos tienen la desventaja de causar pérdida de datos hasta que el algoritmo consiga adaptarse a la señal. Los filtros variantes en el tiempo, por su parte, no resultan óptimos para señales con frecuencias menores a 0,5 Hz y, por tanto, para este caso. Por último, la técnica de filtrado mediante aproximación con *splines* cúbicos, aunque es el método más efectivo para frecuencias menores o iguales a 0,5 Hz, tiene una fuerte dependencia de la frecuencia cardíaca y por tanto de la patología [17].

#### 4.4.1.2. Procedimiento seguido

En el presente proyecto se ha optado por emplear un filtrado FIR. Se ha diseñado un filtro paso bajo a una frecuencia de 0,5 Hz y de orden 180, al ser el valor de frecuencia que mejor resultados ha obtenido en la práctica sin deteriorar la señal en el rango de 0,05Hz a 0,5 Hz.

Se comprobó que para valores de frecuencias superiores a 0,5 Hz existía atenuación en el segmento ST y por tanto deterioro de la señal. Sin embargo, si se tomaban frecuencias muy inferiores a 0,5 la eliminación de las fluctuaciones de la línea basal era imperceptible.

En la Figura 4.1 se muestra un ejemplo de cómo el filtro implementado corrige la desviación de la línea basal, tanto cuando existe una desnivelación negativa de la misma (figura de la izquierda) como cuando la desnivelación es positiva. Se comprueba además que se preserva la fidelidad de registro del segmento ST tras el filtrado. La señal de ECG mostrada en rojo es la perteneciente un individuo registrado en el banco de datos de MIT-BIH. En azul, el resultado obtenido tras aplicarle el filtrado.

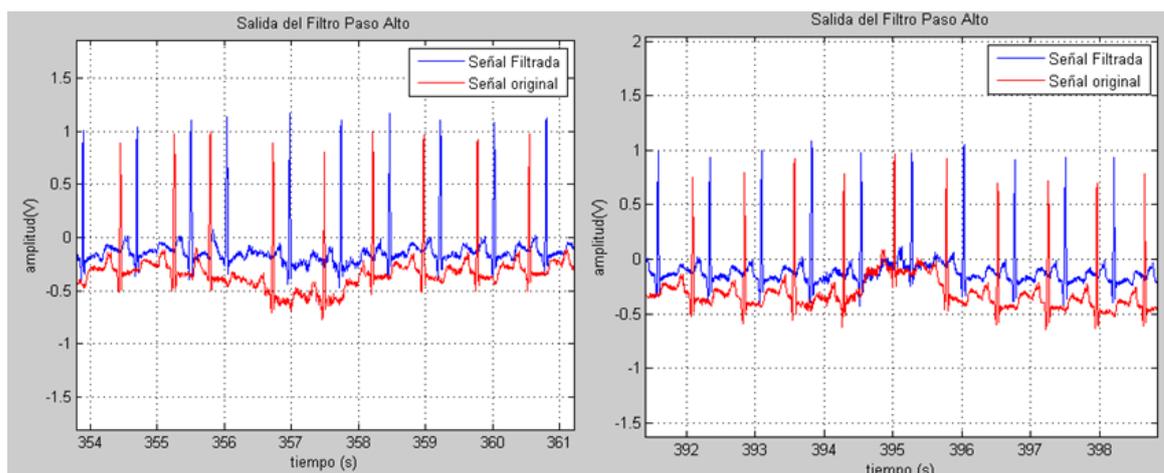


Figura 4. 1: Variaciones negativas y positivas en la línea basal (rojo) de un ECG y su correspondiente señal filtrada (azul)

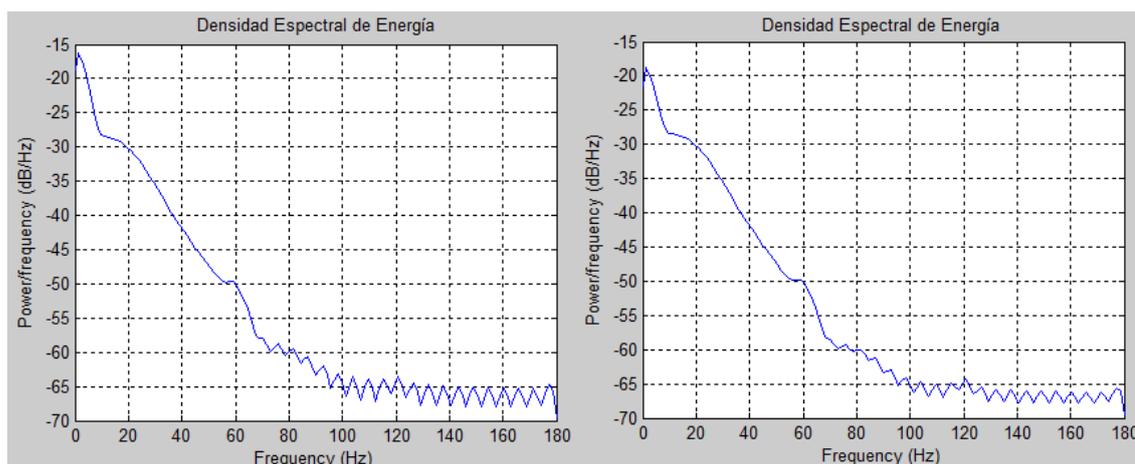


Figura 4. 2: Densidad espectral de energía de la señal original (izquierda) y la señal filtrada a baja frecuencia (derecha)

La Figura 4.2 muestra además la densidad espectral de energía (DEE) de la señal original y la DEE después del filtrado paso alto. Tras el filtrado, se observa atenuación de la densidad espectral en la banda de atenuación del filtro. Se midió la atenuación en esta banda de baja frecuencia, justamente a la frecuencia de corte de 0,5 Hz, teniendo una DEE de -17,8 dB/Hz en la señal original y atenuándose hasta -20,5 dB/Hz con el filtrado.

## 4.4.2. Filtrado del ruido muscular y de los amplificadores

### 4.4.2.1. Características de este tipo de ruido

Además del ruido a bajas frecuencias, existen otros tipos de ruido a frecuencias más altas que han de eliminarse. Estos son el ruido muscular y el ruido originado por los amplificadores que componen el sistema debido a interferencias electromagnéticas.

En este tipo de filtrado es importante prestar especial atención en la implementación, puesto que un filtrado inadecuado de la señal a alta frecuencia puede conllevar una infraestimación del pico de la onda R (y por tanto de la amplitud de la onda), además de amortiguamiento de la onda Q y de las muescas o empastamientos electrocardiográficos. En adultos y adolescentes se recomienda un punto de corte superior de 150 Hz, para los niños es más apropiado un punto de corte de 250 Hz [36].

Para la elección del tipo de filtrado, se analizó documentación sobre los filtros de señales ECG que se utilizan precisamente para eliminar este tipo de ruido [26][18][37]. Los filtrados clásico y Wavelet son generalmente los más empleados para esta tarea. De los estudios realizados acerca de los tipos de preprocesado para señales ECG puede extraerse lo siguiente:

- Desde el punto de vista temporal, la señal filtrada mediante filtros paso bajo sufre un retardo y una pérdida de ganancia, lo cual no tiene efecto alguno sobre el objetivo que se persigue, que es la extracción de las características de la señal. En cambio, la transformada de Wavelet introduce mayor cantidad de fluctuaciones temporales y por tanto una reducción del ruido menos eficiente.

Se muestra una imagen en la que se aprecian dichos efectos tras el filtrado con ambas técnicas.

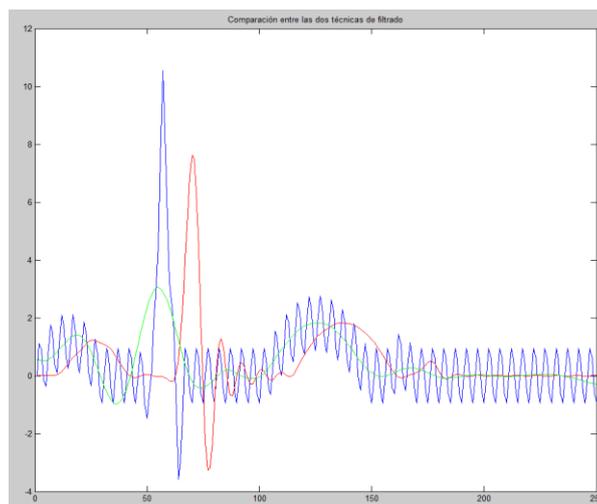


Figura 4. 3: Comparativa entre técnicas de filtrado: señal original ruidosa (azul), señal filtrada mediante Wavelet (verde) y señal filtrada con filtro paso bajo (rojo)[26].

- Desde el punto de vista espectral, tras aplicar a la señal ruidosa los filtros paso bajo y Wavelets se observa cómo el filtro paso bajo logra una mejor eliminación de las altas frecuencias.

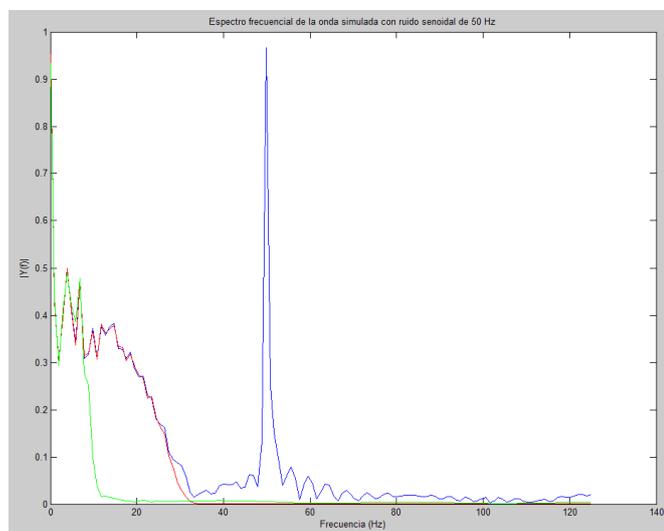


Figura 4. 4 : espectro de la onda ruidosa (azul), de la onda filtrada mediante paso bajo (roja) y filtrada mediante Wavelet (verde)[26]

- Desde el punto de vista de coste computacional, el estudio realizado muestra además que la técnica de filtrado mediante paso bajo requiere un esfuerzo de computación de aproximadamente la quinta parte que el filtrado Wavelet. Los resultados obtenidos se muestran en la tabla.

TABLA 4. 1 : TIEMPO DE CÓMPUTO DE LAS DIFERENTES TÉCNICAS [26]

	Tiempo (mseg)
Filtro paso bajo	32.08
Filtro Wavelet Daubechies 9 nivel 4	146.38

En conclusión, por todo lo anterior, se optó por el filtrado clásico.

#### 4.4.2.2. Procedimiento seguido

Puesto que en adultos y adolescentes se recomienda un punto de corte superior de 150 Hz y para los niños un corte de 250 Hz [36], en el diseño del filtro paso bajo utilizado en este proyecto se escogió, como punto de corte, aquel que ofrecía mejores resultados en tales rangos de frecuencias. Tras algunas pruebas se consiguieron resultados aceptables con una frecuencia de corte de 230 Hz y de orden 5. A pesar de que la frecuencia utilizada es menor que la de corte recomendada para señales ECG infantiles, no supone un problema puesto que la base de datos implementada en este proyecto está formada exclusivamente por pacientes mayores de edad.

Este filtro disminuye considerablemente el ruido de alta frecuencia de la señal electrocardiográfica. En la Figura 4.5 se muestra las señales original y filtrada en el dominio del tiempo y, en la Figura 4.6, dichas señales en el dominio de la frecuencia. El efecto del filtrado es más notorio en este último caso, donde la densidad espectral de energía disminuye de -65dB/Hz a -75dB/HZ aproximadamente a altas frecuencias. La observación del efecto del filtro en el dominio del tiempo está mucho menos definida.

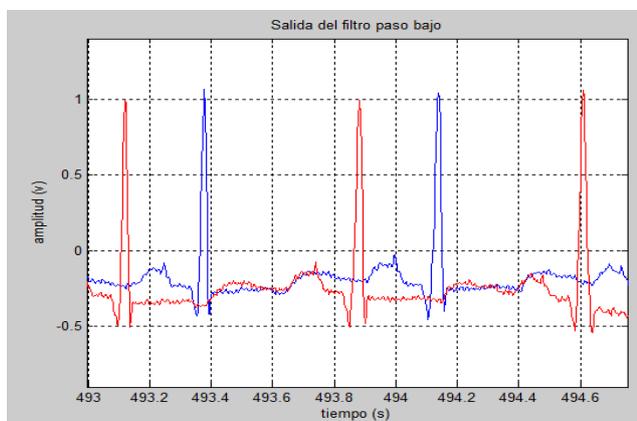


Figura 4. 5: Señal original (rojo) y su señal filtrada (azul) a alta frecuencia

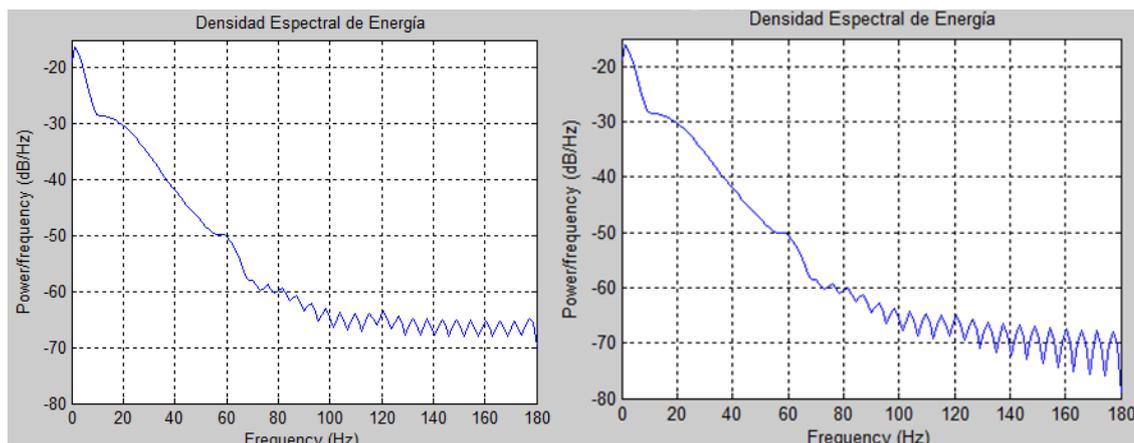


Figura 4. 6: Densidad espectral de energía de la señal original (izquierda) y la señal filtrada a alta frecuencia (derecha)

#### 4.4.3. Filtrado de la interferencia de la red eléctrica

##### 4.4.3.1. Características de filtrado para este tipo de ruido

La red eléctrica utilizada también produce una interferencia inevitable sobre la señal electrocardiográfica que requiere de un filtrado selectivo. La corriente eléctrica que circula por los conductores hace que, alrededor de ellos, se produzca un campo magnético a la frecuencia de 50 ó 60 Hz produciendo tal interferencia. Ha de tenerse en cuenta que, en el caso de Estados Unidos, ésta se encuentra en 60 Hz y, en Europa, en 50 Hz.

Para eliminar este tipo de interferencia, se diseñan filtros elimina banda. Estos filtros se diseñan centrados en la frecuencia de interferencia de la red y con un ancho de banda lo suficientemente estrecho para que no interfiera al resto de componentes de la señal.

##### 4.4.3.2. Procedimiento seguido

El diseño para el filtro empleado es, por tanto, un filtro Notch para una frecuencia de 60 Hz, puesto que la base de datos utilizada es extraída a partir de la base de datos del Instituto Tecnológico de Massachusetts (MIT), en EEUU.

Con este filtro se consigue eliminar significativamente la interferencia en la red eléctrica, como se muestra en la Figura 4.7, donde se aprecia la eliminación del rizado.

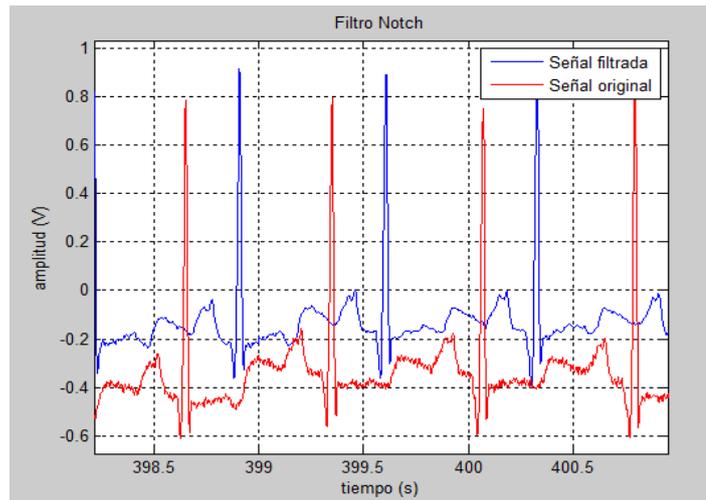


Figura 4. 7: Señal original y su señal filtrada con filtro banda eliminada

En la Figura 4.8 se observa también el efecto que hace filtro, cayendo la densidad espectral de potencia de  $-50$  dB/HZ a  $-55$  dB/HZ a  $60$  HZ.

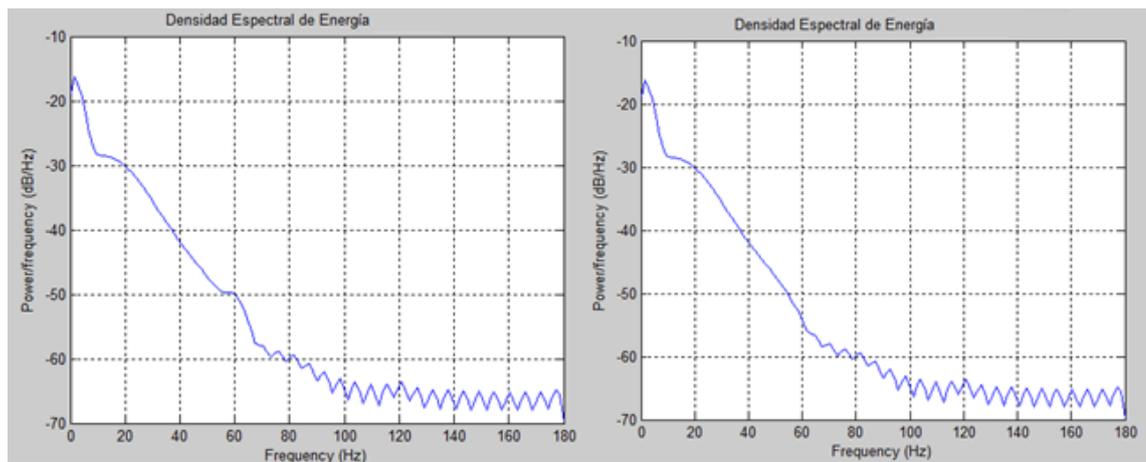


Figura 4. 8: Densidad espectral de potencia de la señal original (izquierda) y la señal filtrada (derecha) con filtro banda eliminada



## Capítulo 5

# 5. PARÁMETROS DE DINÁMICA NO LINEAL

### 5.1. INTRODUCCIÓN

El objetivo de este capítulo consiste en el análisis de una serie de parámetros no lineales (basados en la teoría del caos) con la finalidad de estudiar la viabilidad de dichos parámetros como discriminador de latidos sanos o patológicos de una señal de ECG. Si mediante un sistema de clasificación es posible obtener tasas de éxito aceptables en la identificación de las diferentes clases, puede asumirse que en el vector de características de la serie (medidas de complejidad) existe suficiente información como para implementar un sistema capaz de actuar como detector de patologías cardíacas.

Para un mejor entendimiento de la metodología que se va a seguir, es necesaria una introducción a los sistemas dinámicos no lineales. En este capítulo se comentan los aspectos básicos y los conceptos necesarios para la comprensión de los sistemas caóticos, sus dificultades, y las herramientas necesarias para medir su complejidad.

En la elaboración del estudio, es necesario transformar la señal de ECG en series temporales para extraer de ellas sus parámetros caóticos y, con ello, formar los vectores de medidas de complejidad. Se explicará cómo se han obtenido las series a partir de las señales de ECG (segmentación), el procedimiento llevado a cabo para la extracción de los parámetros de dichas series (parametrización) y el significado de cada parámetro. Los parámetros no lineales que se han propuesto son del tipo entropías, exponentes, dimensiones y otros no pertenecientes a las categorías anteriores.

Tras ello, se realiza el análisis mediante estadística descriptiva de las medidas de complejidad para caracterizar estos parámetros. Se escogieron para ello una serie de estadísticos clásicos, como son la media, la varianza, el *skewness* y la curtosis.

El estudio queda completamente concluido con la simulación de los parámetros caóticos tratados. En función de los resultados obtenidos con los estadísticos y de la tasa de acierto alcanzada en las simulaciones, se extraen conclusiones. Las simulaciones se

abordan en el siguiente capítulo, *Diseño del Clasificador*, puesto que esta etapa se realiza en el clasificador.

## **5.2. DINÁMICA NO LINEAL Y MEDIDAS DE COMPLEJIDAD**

A través del estudio de los parámetros no lineales, los resultados que se obtengan permitirán no sólo determinar si éstos son aptos para la clasificación, sino que además podrán revelar si el sistema analizado se trata de un sistema complejo. Esto se debe a que los parámetros caóticos son capaces de llegar a estimar la complejidad de un sistema, por lo que son también llamados medidas de complejidad.

Las medidas de complejidad pueden definirse como aquellos parámetros que describen el conjunto de irregularidades de una entidad [38], de tal forma que algo completamente al azar o totalmente ordenado tendrá una medida cercana a cero. Por lo tanto, la complejidad efectiva sólo puede estar en la región intermedia entre el orden total y el desorden absoluto [39].

Conceptualmente, un sistema se considera complejo cuando no sólo está formado por las partes que lo integra, sino que además, los vínculos existentes entre dichas partes aportan información al sistema. Dicho de otro modo, un sistema es complejo cuando el todo es más que la suma de sus componentes.

Por otra parte, un sistema dinámico es aquel en el que existe cambio o evolución del propio sistema con el tiempo. Cuando estos sistemas poseen dinámica caótica, al contrario de lo que ocurre con la dinámica lineal, no se puede predecir fácilmente el futuro o evolución a partir del pasado aunque se traten de sistemas deterministas (deterministas no lineales). Esto se debe a que la dinámica caótica tiene una fuerte dependencia de las condiciones iniciales, de tal modo que pequeñas variaciones de éstas, desembocan en resultados muy dispares entre sí.

El estudio de series caóticas no se trata de una tarea sencilla. Por un lado, los sistemas complejos añaden la dificultad de que no existe la posibilidad de obtener un análisis de los mismos por la simple adición de estudios parciales de cada uno de los elementos, puesto que se trata de modelos no lineales. Esto hace que usualmente sean difíciles de modelar y que sus comportamientos con respecto a una variable dada (por ejemplo, el tiempo) sean extremadamente difícil de predecir. Por otro lado, la detección

empírica de la no linealidad requiere series relativamente largas para su estudio [40], que no siempre son posibles.

Algunas publicaciones han declarado tras el análisis de series temporales de señales de ECG que, aunque éstas presenten detalles aparentemente aleatorios, en realidad parecen estar generados por una dinámica que proviene de un sistema caótico [41], [42]. Investigadores como Ary L. Goldberger, junto a otros colaboradores, han encontrado evidencia de posibles atractores extraños analizando el ECG de individuos sanos y han concluido que el ritmo normal de los latidos del corazón puede ser caótico. Además, Babloyantz y Destexhe encontraron que la dimensión de correlación de un ECG variaba entre 3,5 y 5,2, lo cual indica que la dinámica está asociada a un atractor extraño de baja dimensionalidad. Es, por tanto, por lo que se procederá a su estudio, siendo el primer paso formar dichas series.

### **5.3. EXTRACCIÓN DE LAS MEDIDAS DE COMPLEJIDAD**

Como se ha mencionado, a la hora de la clasificación se hace necesaria la extracción de parámetros de una señal para el reconocimiento de patrones del clasificador. La parametrización consiste en la extracción de los valores de la señal que aporten información. En la teoría del caos, la extracción de parámetros caóticos o medidas de complejidad se realiza a través de una serie temporal no lineal con comportamiento caótico [43][20]. Por tanto, las señales de ECG bajo estudio se deben modelar de esta manera. Para ello, en una primera etapa de segmentado, se forman las series a partir de las señales de ECG. En una segunda etapa, se procede a la extracción de los parámetros caóticos de las mismas.

#### **5.3.1. Segmentado**

La generación de las series se llevó a cabo dividiendo en tramas de tamaño fijo las señales de ECG de la base de datos creada. Este proceso se efectuó para tamaños de trama de 2 a 20 segundos, con solapamiento de un segundo. De este modo, se generaron series de tales tamaños, cada una por separado, para su correspondiente tratamiento individualizado.

La razón de la elección de tales tamaños se debe a la decisión de incorporar en la trama al menos un latido. En general, un latido completo tiene una duración media de alrededor de un segundo. En cambio, en casos de bradicardia y en algunos tipos de arritmias, un ciclo de RR puede ser mayor a un segundo. Es por ello que, para asegurar al menos un ciclo completo, se fijó el límite inferior a dos segundos. Por otra parte, los períodos de tiempo en el que un individuo padece una arritmia no suelen tener una larga duración de manera continuada. Se analizó la duración de dichas arritmias en las señales de la base de datos y se fijó a la duración máxima que fuese suficiente para disponer de una cantidad de señales adecuada, siendo ésta de 20 segundos.

En el siguiente diagrama se muestra el esquemático del proceso seguido en esta etapa. En él se muestra el segmentado para una señal de ECG,  $X_i$ , donde  $X$  representa a las clases pertenecientes a la base de datos, y el subíndice  $i$  a qué individuo corresponde. Esto indica que el procedimiento mostrado en la imagen se va a repetir para cada uno de los elementos de la base de datos.

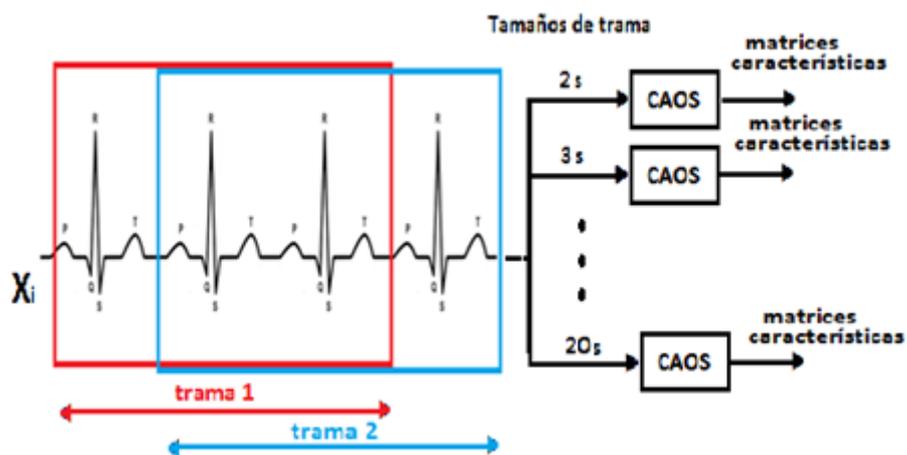


Figura 5. 1: Segmentación de las señales en tramas de diferente tamaño y extracción de sus parámetros caóticos

### 5.3.2. Extracción de parámetros

Tras el segmentado de la señal en tramas, es necesario modelarlas como series temporales no lineales con comportamiento caótico. Para ello se ha de transformar la trama de la señal de ECG, de forma que pase del dominio temporal al dominio del espacio de fase. En este espacio de fase, la señal se denomina atractor. Para reconstruir el espacio de fase a partir de

una serie temporal y representar el atractor se han de determinar la dimensión de inserción (*embedded*) y el retardo del espacio de fase.

La dimensión del espacio de fase reconstruido ( $d$ ) indica cuántas coordenadas son necesarias para representar el atractor, de tal forma que el espacio de fase habría de tener las suficientes coordenadas como para poder desplegar el atractor del sistema sin que haya solapamientos. El algoritmo que se ha utilizado para estimarla sigue el método de Falsos Vecinos.

El tiempo de retardo ( $T$ ) se define como el retardo necesario para que haya independencia entre una señal  $s(n)$  y sus versiones retardadas. Existen varias formas de estimar este valor, entre ellas, considerar su valor como el retardo en el que se produce el primer cero de la función de autocorrelación o bien considerarlo como el retardo en el que se produce el primer mínimo de la función de información mutua. El valor del retardo se escogió de forma que fuese un compromiso entre los valores obtenidos en el caso de estimarlo mediante el primer paso por cero de la autocorrelación y mediante el primer mínimo de la información mutua.

Tanto la dimensión del espacio de fase como el retardo dependen de la clase de señal ECG. Así, por ejemplo, para la clase tipo normal o tipo N se obtuvo  $d=7$  y  $T=31$ . Sin embargo, para su representación se ha tomado una  $d=2$  correspondiente al plano.

En la siguiente imagen, el espacio de fase reconstruido muestra el atractor para una trama conformada por latidos de clase N. A la izquierda de la imagen, la serie  $s(n)$  correspondiente.

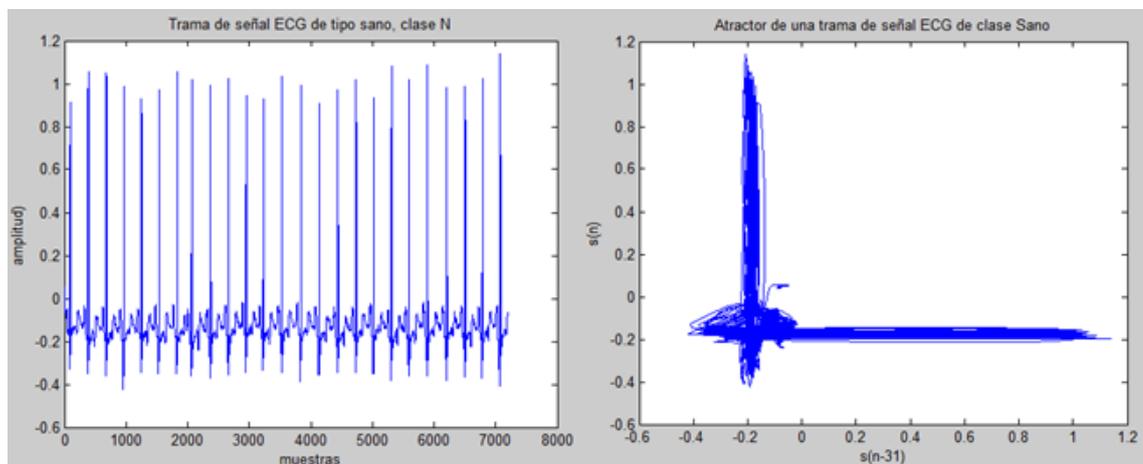


Figura 5. 2: Trama de la señal de ECG para paciente sano y su atractor

A continuación se extrajeron sus parámetros caóticos para, con ello, generar sus respectivas matrices características. Para realizar la extracción de los parámetros fue necesario el manejo de la *toolbox* Caos, proporcionada por el Grupo de Procesado Digital de Señal (GPDS) de la UPLGC, y el aprendizaje de las funciones del paquete TISEAN (*Nonlinear Time Series Analysis*) [23], de libre acceso.

Caos es una herramienta que dispone de multitud de aplicaciones en series no lineales. Entre ellas, permite extraer distintos parámetros caóticos a partir de una serie dada. La extracción se llevó a cabo desarrollando una rutina implementada en el entorno matemático Matlab que, de forma automatizada, realizase el segmentado y accediese a la función Caos para extraer los parámetros, conformando todas las matrices características de las tramas disponibles en la base de datos creada.

Las matrices características obtenidas están formadas por vectores que contienen los valores de los parámetros caóticos calculados a sus tramas. Es decir, por cada trama existe un vector de medidas de complejidad, cuyo contenido son los valores correspondientes de estimar todos los parámetros a dicha trama.

Los parámetros que se extrajeron para el estudio son seis: la Entropía de Shannon, el Máximo Exponente de Lyapunov, la Dimensión de Correlación, la Entropía de Correlación, la Complejidad Lempel-Ziv y el Exponente de Hurst. Sin embargo se han obtenido finalmente 9, puesto que el Máximo Exponente de Lyapunov y el Exponente de Hurst se han estimado varias veces haciendo uso de distintos algoritmos. En cuanto al Máximo exponente de Lyapunov, se calculó de dos formas: utilizando por un lado el algoritmo de Rosenstein y, por otro, el algoritmo de Kantz. El Exponente de Hurst, por su parte, fue estimado con tres métodos distintos: el método de Varianza Agregada, el método de Momento Absoluto y el método de R/S (Reescalado).

Además de los parámetros ya mencionados y que serán los utilizados en la clasificación, también se extrajeron otros parámetros asociados a éstos, que serán de utilidad a la hora de analizar correctamente los parámetros a emplear en el clasificador. Estos son el retardo y la dimensión de inserción, esta última estimada mediante la definición y por el método de Falsos Vecinos.

A modo de resumen, las características de esta etapa son:

- Tamaños de trama: de 2 a 20 s (con pasos de 1 s).
- Solapamiento: 1s
- Parámetros caóticos estudiados para la clasificación de patologías:
  - Entropía de Shannon
  - Máximo exponente de Lyapunov, estimado con algoritmo Rosestein
  - Máximo exponente de Lyapunov, estimado con algoritmo de Kantz
  - Dimensión de correlación
  - Entropía de correlación
  - Complejidad Lempel-Ziv
  - Exponente de Hurst, estimado con el método de Varianza Agregada
  - Exponente de Hurst, estimado con el método del Momento Absoluto
  - Exponente de Hurst, estimado con el método R/S
- Algunas medidas para el análisis de los parámetros:
  - Retardo
  - Dimensión de inserción
  - Dimensión de inserción, estimada por el método de Falsos Vecinos

## 5.4. ESTUDIO DE LOS PARÁMETROS CAÓTICOS

### 5.4.1. Definición de los parámetros seleccionados

En esta sección se documenta con una breve descripción el significado y la definición matemática de cada parámetro caótico a analizar.

Los parámetros que se verán a continuación pueden dividirse en dos: del tipo ‘entropías’, que determinan la predictibilidad de un sistema, y del tipo ‘variables’ (exponentes, dimensiones...), que describen el comportamiento del sistema.

### 5.4.1.1. Entropía de Shannon

La entropía es una medida que cuantifica la incertidumbre presente en un conjunto de datos debido a su cantidad de información, de modo que cuanto mayor sea la incertidumbre en la observación del conjunto de datos, mayor es su valor de entropía [44].

La Entropía de Shannon se define de la siguiente forma:

$$H = - \sum_i p_i \ln p_i$$

con

- $p_i$ : probabilidad de que en el intervalo  $i$ -ésimo en el que se ha dividido los valores del espacio de fase se encuentre un determinado valor

Con los resultados adquiridos en el apartado anterior se representa la función densidad de probabilidad (fdp) que se obtiene para la Entropía de Shannon aplicada a una señal ECG.

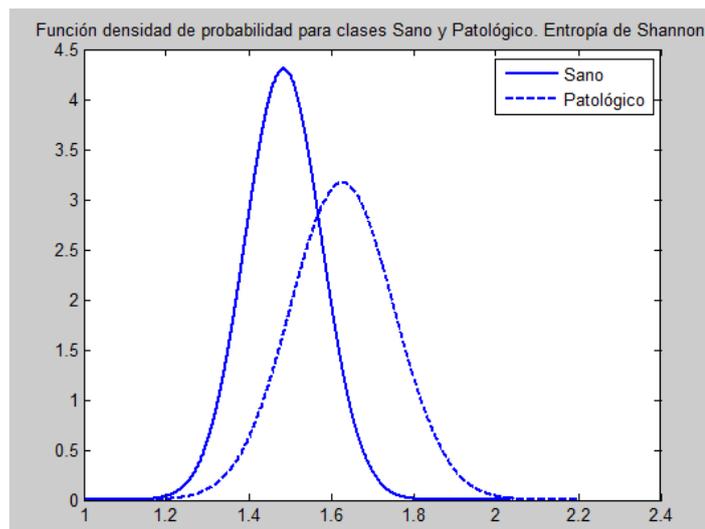


Figura 5. 3: Función densidad de probabilidad para el parámetro Entropía de Shannon para latidos sano y patológico

### 5.4.1.2. Máximo Exponente de Lyapunov

Los exponentes de Lyapunov son medidas extraíbles del espacio de fase reconstruido que cuantifican la divergencia o convergencia de trayectorias en un principio cercanas en el espacio de fase. El que dos trayectorias cercanas diverjan de forma exponencial al evolucionar el sistema es indicativo de caos [20].

El Máximo Exponente de Lyapunov (MLE) se define de la siguiente forma:

$$\lambda = \frac{1}{\Delta k} \ln \left( \frac{\varepsilon_{\Delta k}}{\varepsilon_0} \right), \quad \varepsilon_0 \ll 1, k \gg 1$$

donde

- $k$ : instante de tiempo
- $\varepsilon_0$ : distancia en el instante  $k_0$  de dos puntos en el espacio de fase que se encuentran cercanos
- $\varepsilon_{\Delta k}$ : distancia después de un tiempo  $\Delta k$

Cuando el MLE es positivo se suele asumir que el sistema es caótico [45].

Este parámetro se ha estudiado para dos algoritmos de estimación diferente, Rosenstein y Kantz. Las funciones densidad de probabilidad de cada uno de ellos son las siguientes:

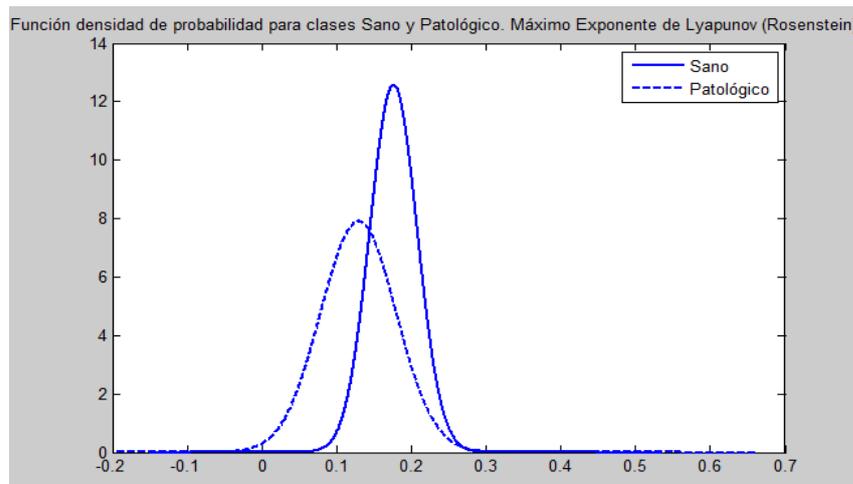


Figura 5. 4: Función densidad de probabilidad para el parámetro Máximo Exponente de Lyapunov con algoritmo Rosenstein para latidos sano y patológico

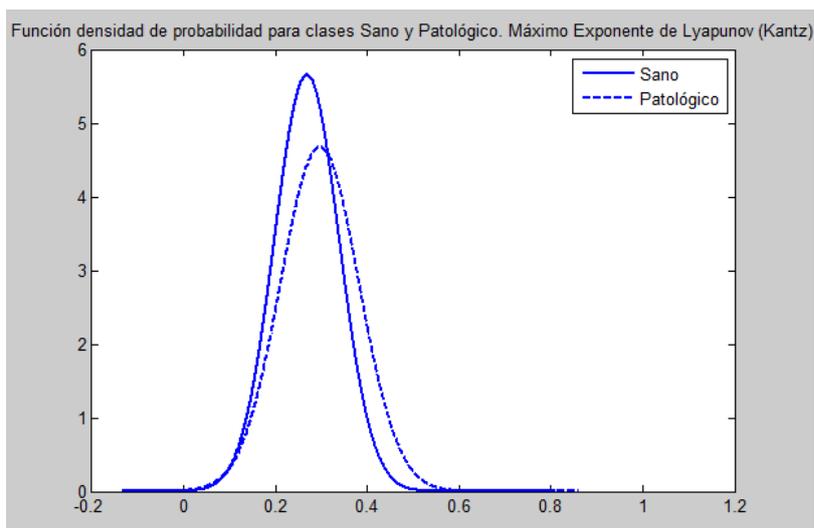


Figura 5. 5: Función densidad de probabilidad para el parámetro Máximo Exponente de Lyapunov con algoritmo de Kantz para latidos sano y patológico

### 5.4.1.3. Dimensión de Correlación

La Dimensión de Correlación cuantifica la organización espacial del atractor, de modo que a mayor complejidad, mayor dimensión de correlación.

Se define en función de la función escalón o Heaviside, que cuenta el número de puntos que se encuentran dentro del círculo de radio  $\varepsilon$  y centro  $X_i$  :

$$D_2 = \frac{d \ln C(\varepsilon)}{d \ln \varepsilon}$$

siendo

- $\varepsilon$  : radio del círculo que contiene los puntos de la función escalón
- $C(\varepsilon)$  : suma de correlación sobre un conjunto de  $N$  puntos del espacio de fase y que representa la fracción promedio de puntos dentro de  $\varepsilon$  [20]. Viene definida como:

$$C(\varepsilon) = \lim_{N \rightarrow \infty} \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N \theta(\varepsilon - \|X_i - X_j\|)$$

donde

- $N$  : conjunto de puntos del espacio de fase
- $\Theta$  : función escalón, con  $\Theta(x) = 0$  si  $x \leq 0$  y  $\Theta(x) = 1$  si  $x > 0$
- $X_i$  es el centro del círculo que contiene los puntos de la función escalón

A continuación, su función densidad de probabilidad:

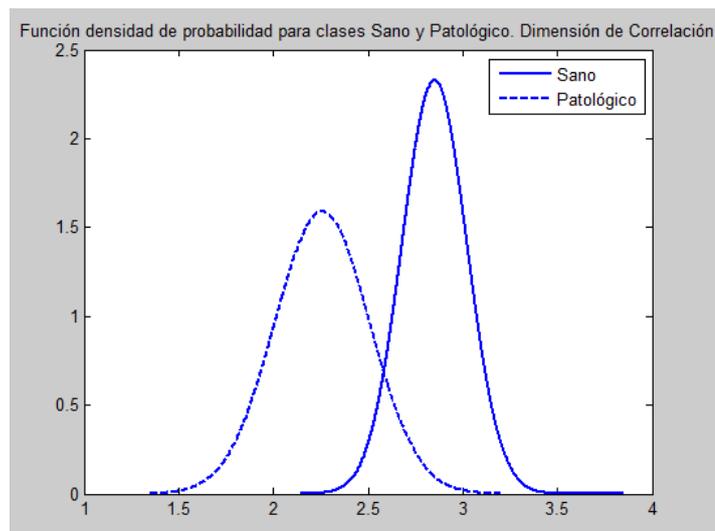


Figura 5. 6 Función densidad de probabilidad para el parámetro Dimensión de Correlación para latidos sano y patológico

#### 5.4.1.4. Entropía de Correlación

La Entropía de Correlación, también conocida como entropía diferencial de Rényi de orden 2, cuantifica la cantidad de desorden del sistema.

Se define como:

$$h_2 = \sup \lim_{m \rightarrow \infty} \frac{1}{m} \left( - \sum_{i_1, i_2, \dots, i_m} p_{i_1, i_2, \dots, i_m}^2 \right)$$

Con:

- $m$ : dimensión de inserción
- $p_{i_1, i_2, \dots, i_m}$ : probabilidad conjunta de que en un determinado instante de tiempo  $n$ , los observables caigan dentro del intervalo  $I_{i_1}$ ; en el instante de tiempo  $n + 1$  caigan en el intervalo  $I_{i_2}$ , y así sucesivamente.

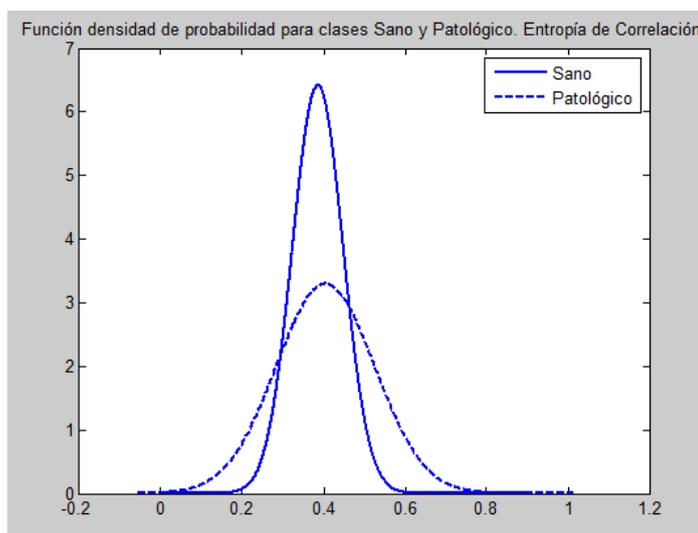


Figura 5. 7: Función densidad de probabilidad para el parámetro Dimensión de Correlación para latidos sano y patológico

#### 5.4.1.5. Complejidad Lempel-Ziv

La Complejidad Lempel-Ziv (LZC) es una técnica de análisis no lineal que evalúa la aleatoriedad de secuencias finitas en función del número de patrones distintos existentes en una señal [46]. Dicho de otra manera, relaciona el número de patrones distintos que se encuentran a lo largo de una secuencia [47]. Por lo tanto, se trata de una medida que permite estimar qué tan compleja o irregular es una serie de tiempo.

Para estimarla, se mide el número de patrones distintos que deben ser copiados para reproducir una secuencia dada. Sea una secuencia de datos  $x = x_1, x_2, \dots, x_n$ , a la cual se le realiza un recorrido de izquierda a derecha. 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  $x$ , el número resultante  $c$  es su medida de complejidad. Se debe tener en cuenta que solo

tienen sentido los valores relativos de  $c$ , por tal motivo, este valor se divide finalmente entre el tamaño de la secuencia.

Valores más elevados de complejidad LZC (en una escala de cero a uno) se corresponden con una mayor complejidad en los datos analizados. Esta medida no depende de si la señal a analizar ha sido generada por un proceso aleatorio o determinista [48].

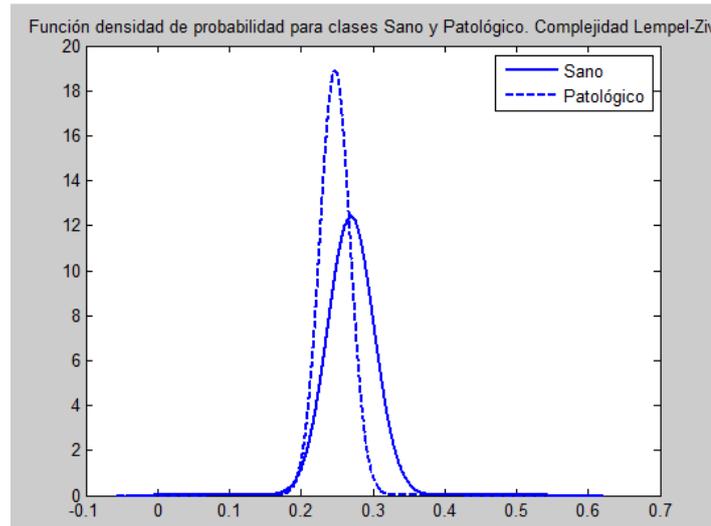


Figura 5. 8 Función densidad de probabilidad para el parámetro Complejidad Lempel-Ziv para latidos sano y patológico

#### 5.4.1.6. Exponente de Hurst

El exponente de Hurst se utiliza como una medida de la memoria a largo plazo de series de tiempo. Se relaciona con las autocorrelaciones de las series temporales y la velocidad a la que éstas disminuyen a medida que aumenta el desfase entre pares de valores.

El exponente de Hurst ( $H$ ) determina si la serie de tiempo puede ser representada por un movimiento aleatorio o determinista. Si  $H$  existe, su rango de valores está entre 0 y 1, y además mostrará la no linealidad de la serie de tiempo. Particularmente [49]:

- $0 \leq H < 0,5$ : las tendencias del pasado persisten en el futuro (persistente)
- $H=0,5$  : comportamiento totalmente aleatorio (movimiento browniano)
- $0,5 < H \leq 1$ : las tendencias del pasado tienden a invertirse en el futuro (proceso anti-persistente)
- $H=1$  : comportamiento determinístico

El cálculo del exponente de Hurst se calcula con la siguiente regresión empírica:

$$\frac{R}{\sigma} = (\tau/2)^H$$

Donde  $R$  es el rango (diferencia entre el mínimo y el máximo valor de la serie de tiempo);  $\sigma$  es la desviación estándar; y  $\tau$  es el tiempo de retardo usado en la reconstrucción del atractor. El valor del exponente de Hurst es definido como la pendiente resultante después de calcular el promedio de los  $R/\sigma$ , para diferentes escalas [50]

Se define como:

$$E \left[ \frac{R(n)}{S(n)} \right] = Cn^H \text{ con } n \rightarrow \infty$$

Donde

- $R(n)$  es el rango de los primeros  $n$  valores, y  $S(n)$  es su desviación estándar
- $E[x]$  es el valor esperado
- $n$  es el periodo de tiempo de observación (número de puntos de datos en la serie temporal)
- $C$  es una constante

La función densidad de probabilidad se representa para los tres algoritmos con el que se ha estimado el Exponente de Hurst: Varianza Agregada, Momento Absoluto y R/S (rango reescalado).

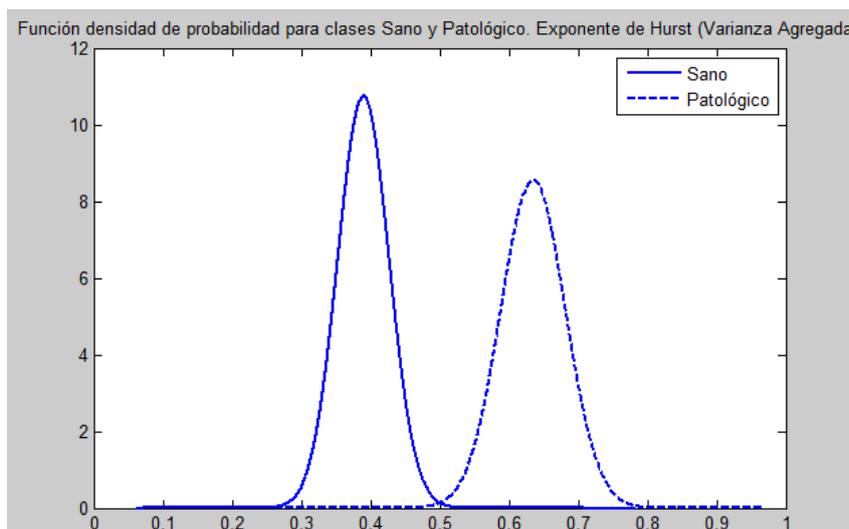


Figura 5. 9 Función densidad de probabilidad para el parámetro Exponente de Hurst con algoritmo de Varianza Agregada para latidos sano y patológico

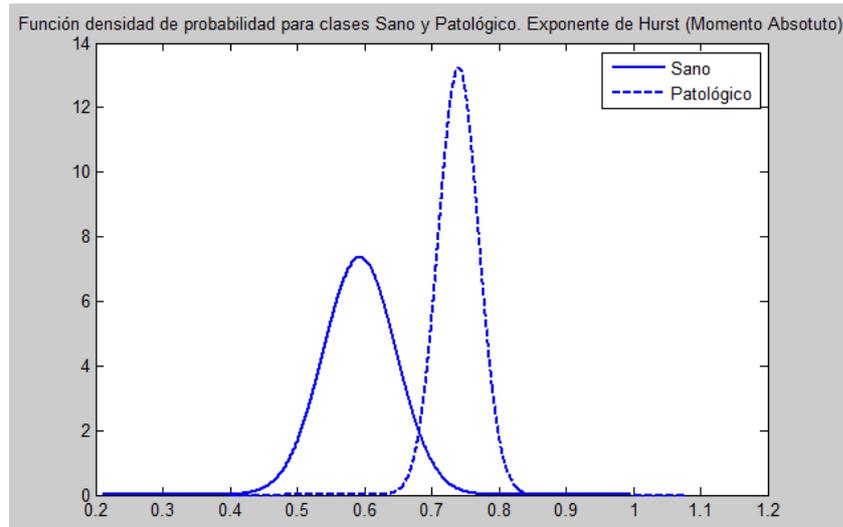


Figura 5. 10 Función densidad de probabilidad para el parámetro Exponente de Hurst con algoritmo de Momento Absoluto para latidos sano y patológico

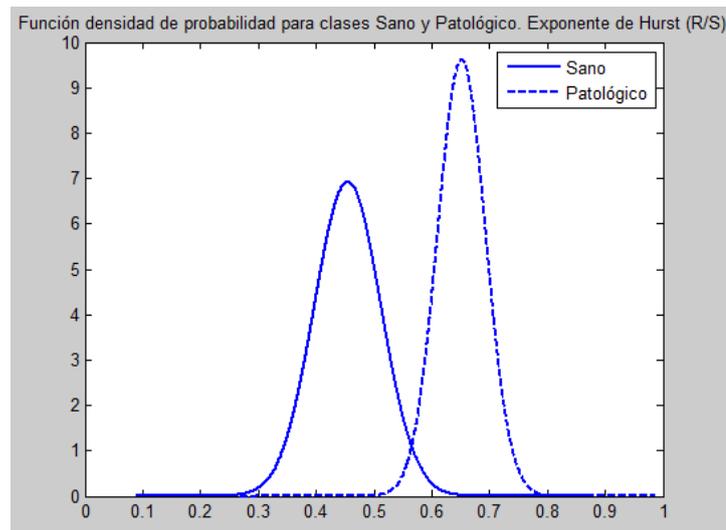


Figura 5. 11 Función densidad de probabilidad para el parámetro Exponente de Hurst con algoritmo de R/S para latidos sano y patológico

#### 5.4.2. Análisis paramétrico mediante estadística descriptiva

En esta sección se propone abordar el estudio de los parámetros caóticos y la dinámica no lineal del sistema cardíaco mediante su análisis estadístico descriptivo. Este tipo de estudio muestra las propiedades de las distribuciones de cada parámetro, lo que permite analizar la existencia de naturaleza caótica en la serie.

#### 5.4.2.1. Elección de estadísticos para el análisis

En el terreno no lineal, para evaluar la complejidad de una serie, el punto de partida es determinar una distribución asociada con la dinámica o la serie temporal en estudio [39]. A continuación, se debe hacer un análisis matemático mediante estadística descriptiva de las medidas de complejidad para caracterizar estos parámetros. Estadísticos descriptivos clásicos como la media, varianza, simetría estadística (*skewness*) y curtosis suelen aportar la información suficiente para realizar un análisis de las distribuciones paramétricas.

La media ofrece la magnitud media del parámetro caótico, lo que permite hacer una evaluación, por tamaño de trama, sobre su no linealidad tras las definiciones ya comentadas en el apartado anterior.

La varianza indica la dispersión de los valores obtenidos respecto de la media, o lo que es lo mismo, permite comprobar si existe mucha variedad o diferencia entre las magnitudes extraídas de los parámetros para un mismo tamaño de trama.

La asimetría estadística muestra si la distribución del parámetro es simétrica o por el contrario tiene colas pesadas. En este segundo caso, habría de desestimarse el valor de la varianza, pues se desaconseja su uso en tal caso.

La curtosis mide el grado de concentración que presentan los valores de la serie alrededor de la zona central de la distribución sin necesidad de generar el gráfico. Cuando el coeficiente de curtosis  $g_2$  es mayor que 3 (*leptocúrtica*), es más apuntada que para valores de  $g_2$  inferiores a 3, de colas más anchas (*platicúrtica*). Cuando  $g_2$  toma el valor 3, su distribución de frecuencias coincide con la distribución Normal (*mesocúrtica*).

Con estas medidas se procederá al análisis acerca de la no linealidad de las series generadas previamente.

#### 5.4.2.2. Procedimiento

El procedimiento que se ha seguido consiste en estimar, para cada uno de los parámetros, los estadísticos propuestos para todos los tamaños de tramas en los que se ha segmentado la señal, es decir, de 2 a 20 segundos. Para ello se creó una rutina en Matlab que calculase y almacenase dichos valores accediendo a los vectores de características y, finalmente, representase gráficamente la evolución del estadístico de dichos parámetros frente a los diferentes tamaños de trama. Asimismo, puesto que los valores de los parámetros caóticos dependen de cada patología, el cálculo del estadístico se ha realizado para cada clase individualmente.

Se ha elegido, para la representación de los resultados, además de la representación gráfica, la utilización de diagramas de cajas (*boxplot*). Esta herramienta facilita el análisis de la información, puesto que pone en una sola dimensión los datos de un histograma. Permite ver cómo es la dispersión de los puntos con la mediana (Q2), los percentiles 25 (Q1) y 75 (Q3) y los valores máximos y mínimos. Además, proporciona una visión general de la simetría de la distribución de los datos, ya que si la mediana no está en el centro del rectángulo, la distribución no es simétrica. También resulta útil para ver la presencia de valores atípicos (*outliers*).

### 5.4.2.3. Análisis

Se ha realizado un estudio de las series extraídas de las tramas de ECG en función de su tamaño de trama y se ha tratado de medir de alguna forma su grado de caoticidad. El propósito ha sido poder determinar si existe no linealidad en las series generadas para las clases N, A y V y en qué grado. Para ello se utilizó estadística descriptiva, medidas como la media, la varianza, la curtosis y la desviación estadística (*skewness*), cuya utilidad ha sido explicada en el apartado anterior. En el Anexo I se presentan los resultados conseguidos tras calcular los estadísticos a cada uno de los parámetros. A continuación se describen las observaciones realizadas.

En cuanto a la incertidumbre (Entropía de Shannon) que presentan las series, la clase N presenta una incertidumbre prácticamente invariable para todos sus tamaños de trama, ligeramente superior a la clase A e inferior a la clase V. Asimismo, presenta una divergencia en las trayectorias del espacio de fase (Máximo Exponente de Lyapunov) muy similar a la clase A y superior a la clase V (para ambos algoritmos). Por otra parte, las clases N y A son las que presentan mayor complejidad (Dimensión de Correlación) con respecto a la clase V. En cuanto al nivel de desorden (Entropía de Correlación), es la clase V la que obtiene mayores resultados, seguidos de las clases N y A. Se observa decrecimiento de la complejidad (Complejidad Lempel-Ziv) con el tamaño de trama, siendo la clase con mayor complejidad la clase A, seguida de la clase N y luego la clase V. Por último, en cuanto al comportamiento de la serie (Exponente de Hurst), se obtuvo que, para las tres clases, su comportamiento es mayoritariamente persistente al conseguir valores superiores a 0,5 (a excepción de cuando fue estimado con algoritmo R/S, para las clases A y N).

Además, para la clase N, la curtosis es superior al umbral 3 en todos los parámetros caóticos analizados, y más elevada que para el resto de las clases A y V. En general, la varianza es muy pequeña y generalmente la desviación estadística es positiva (o a la izquierda) para la mayoría de los parámetros y tamaños de trama, siendo la clase A la que en ocasiones presenta una asimetría negativa (o hacia la derecha).

### **5.4.3. Análisis paramétrico mediante simulaciones**

Finalmente, para concluir el estudio de los parámetros caóticos y con el objeto de comprobar su utilidad, éstos se han simulado en el clasificador. En el capítulo 6, destinado a la clasificación, se explica la variedad de configuraciones que se han empleado en el clasificador y las diferentes pruebas realizadas mediante simulaciones, bien parámetro a parámetro o bien en su conjunto. Los resultados obtenidos de este estudio se exponen en el capítulo 7.

## Capítulo 6

# 6. DISEÑO DEL CLASIFICADOR

### 6.1. INTRODUCCIÓN

La clasificación es el proceso de identificar y atribuir la clase a la cual pertenece un objeto a partir de un conjunto de rasgos o características observables. Para poder realizar la identificación de la clase, es necesario que el clasificador aprenda de alguna manera a distinguir de qué clase se trata. Los clasificadores, según su sistema de aprendizaje, pueden categorizarse en clasificadores con sistemas de aprendizaje supervisados y no supervisados.

El aprendizaje no supervisado trata de descubrir estructuras de elementos no etiquetados utilizando algoritmos matemáticos de clasificación automática, como pueden ser los de *clustering*. En cambio, en la clasificación supervisada, también conocida como clasificación con aprendizaje, el algoritmo de inducción recibe un conjunto de ejemplos, denominados conjunto de entrenamiento. Cada elemento de este conjunto está constituido por una lista de valores característicos y una etiqueta discreta que se emplearán en el entrenamiento. La tarea del algoritmo es aprender modelos que clasifiquen correctamente elementos sin etiquetar. Por lo tanto, el término supervisado implica que algún proceso ha etiquetado los ejemplos del conjunto de entrenamiento [51].

En los últimos años se han desarrollado múltiples algoritmos de clasificación que usan diversos métodos de Inteligencia Artificial. Cada uno de ellos presenta sus diferencias y, con ello, una serie de ventajas y desventajas respecto a los demás, por lo que se requiere un examen minucioso a la hora de la elección.

En este capítulo se presenta el tipo de clasificador que se ha seleccionado y se detallan las razones de su elección y modelado. Además se presentan las diferentes configuraciones empleadas en el estudio de los parámetros no lineales.

## **6.2. ELECCIÓN DEL CLASIFICADOR**

Para poder seleccionar adecuadamente el tipo de clasificador que se empleará en esta etapa, se debe realizar un análisis de los distintos tipos de clasificadores disponibles. Entre los más utilizados se encuentran las redes neuronales artificiales (RNA), en especial las redes Perceptrón Multicapas, las máquinas de vectores soporte (SVM), la lógica difusa, los modelos ocultos de Markov, los algoritmos genéticos y los algoritmos híbridos Neuro-Fuzzy [52]. Se analizan las características de dichos clasificadores, las ventajas e inconvenientes que presentan y, por otra parte, se hace una comparativa con las características y necesidades del clasificador que se quiere realizar. Tras ello, se han tomado las decisiones que se describen a continuación.

En primer lugar, en cuanto al sistema de aprendizaje, se ha optado por un sistema de clasificación supervisada. El motivo principal se debe a que las señales de ECG que formarán la entrada al clasificador disponen de un etiquetado ya realizado en la etapa de creación de la base de datos propia. Esto conseguirá que en el clasificador puedan fijarse fácilmente los criterios de aprendizaje de los algoritmos de inducción, o lo que es lo mismo, permitirá un cómodo entrenamiento.

Así pues, de entre los sistemas de clasificación supervisada, se optó por un clasificador formado por redes neuronales artificiales (RNA). Si bien es cierto que el uso de redes neuronales presenta numerosas ventajas, la más importante desde el punto de vista de este estudio y, por tanto, la que ha motivado su elección, ha sido que permite la solución de problemas no lineales. Su proceso iterativo no lineal las une de modo natural al caos y a la complejidad, siendo capaces de procesar información procedente de otros fenómenos no lineales [53] [54] [55]. Esto es, se ha demostrado que dichas redes son capaces de modelar y predecir series temporales generadas por sistemas caóticos. Es por esta razón por la que, aunque haya otros métodos mucho más potentes como las SVM, se han considerado a las RNA como las más adecuadas.

Las RNA, además de disponer de una gran capacidad para reconocer diferentes patrones y de aproximar cualquier forma funcional con un determinado grado de precisión, presentan diversas ventajas. Entre ellas, cabe mencionar la capacidad de aprender, generalizar y procesar en paralelo, que permiten su utilización en muchas aplicaciones de ingeniería. Por otra parte, destaca su robustez, que permite seguir trabajando aunque fallen

algunos elementos de procesamiento. Además, se encuentran más estandarizadas, puesto que su implementación es sencilla [53].

### 6.3. REDES NEURONALES ARTIFICIALES

La red neuronal artificial es un tipo de clasificador que trata de modelar el comportamiento de procesamiento de información del cerebro humano, de naturaleza compleja y no lineal. Al igual que en el sistema biológico, la RNA está constituida por un número determinado de neuronas interconectadas, formando una red, que funcionan como unidades de procesamiento para proporcionar conocimiento al sistema a través de la experiencia. El conocimiento adquirido en una RNA se traduce en forma de reconocimiento de patrones, lo que permite realizar una clasificación de datos.

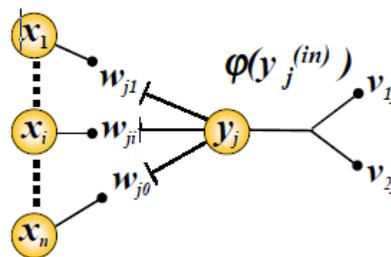


Figura 6. 1 Estructura de la red neuronal

La Figura 6.1 muestra cómo se dispone la estructura de la red neuronal. La transmisión de información de una neurona  $y_j$  cualquiera va a depender de la información procedente de sus neuronas predecesoras. La información total recibida por la neurona  $y_j$  es la suma de cada una de las neuronas anteriores ( $x_1, \dots, x_i, \dots, x_n$ ), multiplicadas por los pesos de cada una de ellas ( $w_{j1}, \dots, w_{ji}, \dots, w_{jn}$ ). Así pues, su información de entrada es  $y_j^{(in)} = \sum_{i=1}^n w_{ji} x_i$ .

Para que la neurona se active y transmita la información recibida es necesario que ésta supere cierto umbral. El umbral será diferente dependiendo del tipo de función de activación que se le asigne a la neurona, pudiendo ser estas funciones lineales o no lineales. Ejemplos de funciones no lineales son la función escalón o la sigmoidea (tangente hiperbólica), que se muestran en la siguiente imagen.

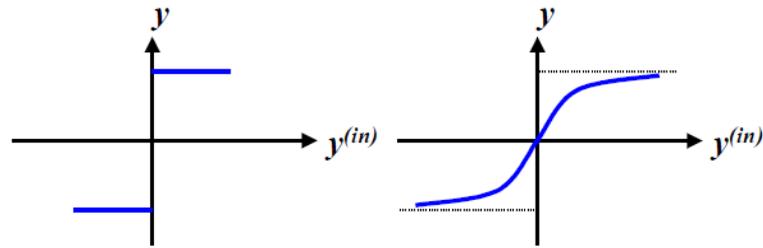


Figura 6. 2 Funciones de activación escalón (izquierda) y sigmoidea (derecha)

Las neuronas no se localizan de manera desordenada, sino que se disponen en forma de vectores de neuronas, llamados capas.

En el caso de red unicapa, cada entrada de la red neuronal va conectada a todas las neuronas de la capa y a su vez, cada una de éstas a todas las salidas. De esta forma, cada neurona de la capa tendrá el mismo número de entradas y salidas que la red de neuronal.

En las redes multicapa, las neuronas de la misma capa son independientes entre sí (no dependen de los pesos de las demás neuronas de la misma capa) y forman un entramado como se muestra en la Figura 6.3. Este tipo de redes resuelven problemas más complejos pero su proceso de aprendizaje es mucho más complicado.

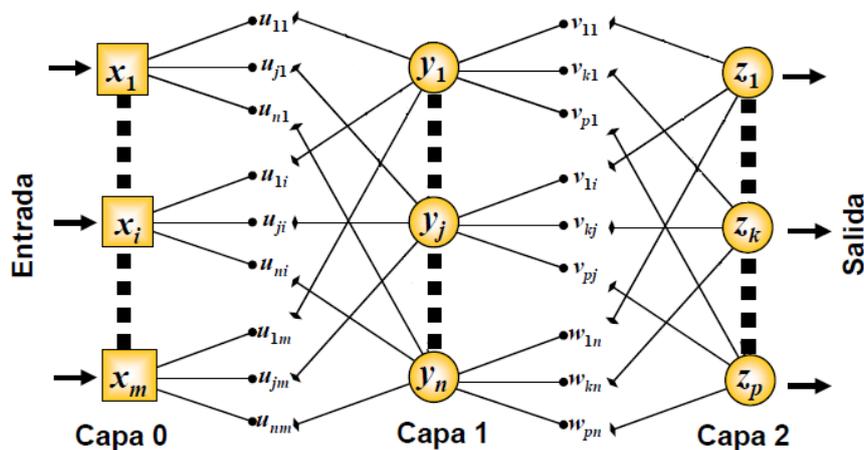


Figura 6. 3: Red multicapa en una RNA

El proceso de aprendizaje en una red RNA se realiza mediante entrenamiento. Para ello, la red utilizará un conjunto de  $N$  pares de muestras de cada tipo  $x_i(n)/o_i(n)$  (entrada/salida) de las que se conoce a priori su clase. Tras introducir la entrada se evalúa la respuesta de la red  $d_i(n)$  y, si la respuesta es errónea, se genera una señal de error

$e_j(n) = d_i(n) - o_i(n)$  que provocará que se reajusten los pesos utilizando algún algoritmo especificado en la configuración de la red.

Al conjunto de los  $N$  pares de entrenamiento se le conoce como época y es configurable en la RNA. En general se entrena con sucesivas épocas y el entrenamiento finaliza cuando los pesos se consideran ajustados.

Según el flujo de las señales, las redes pueden ser *feedforward* o recurrentes. Las redes *feedforward* consisten en redes en las que las neuronas predecesoras transmiten a sus sucesoras. Las redes recurrentes en cambio utilizan retroalimentación.

Uno de los algoritmos de aprendizaje de la red neuronal es el algoritmo *Backpropagation*, que se basa en el método de descenso según el gradiente. Los pesos y bías se ajustan iterativamente hasta que una función criterio, aplicada sobre estos, alcance su mínimo. Para llegar a ese mínimo, se aplica el negativo del gradiente a la función criterio, puesto que éste apunta en la dirección de la máxima velocidad de decremento de la función. En este algoritmo, los errores de los pesos y bías se van propagando hacia atrás en la red neuronal.

## 6.4. MODELADO DE LA RED NEURONAL

A la hora de modelar el clasificador, se ha tenido la precaución de tener en cuenta una serie de consideraciones, por un lado en cuanto a los datos de entrada, y por otro en cuanto a la arquitectura del clasificador.

### 6.4.1. Consideraciones en los datos de entrada

En cuanto a los datos de entrada, existe una serie de restricciones que deben cumplirse para obtener un mejor rendimiento en el clasificador. Éstas se pueden resumir en:

- *Diversidad*. En la fase de entrenamiento se ha de disponer de suficientes muestras de las distintas clases con el fin de poder extraer conclusiones lo más generales posibles. Es decir, la base de datos ha de ser lo suficientemente grande como para conseguir una mayor "generalización" en el proceso de entrenamiento, y evitar problemas como el sobreentrenamiento de un conjunto pequeño de muestras.

- *Volumen*. Con el propósito de garantizar la exactitud desde el punto de vista estadístico, resulta necesario un número significativamente alto de muestras que permita obtener resultados lo más consistentes posibles.
- *Compensación*. Es necesario que las diferentes clases estén balanceadas (es decir, que exista un número similar de unidades de cada tipo) para que no predomine una determinada clase sobre otra, tanto en la caracterización como en el entrenamiento.

#### 6.4.2. Consideraciones en la arquitectura

En cuanto a la arquitectura del clasificador, para la elección de su correcta configuración, se ha de tener en cuenta lo siguiente:

- *Número de neuronas*. Se ha de prestar especial atención al número de neuronas que va a emplearse puesto que un número muy bajo de ellas no resuelve el problema planteado y un número excesivo puede llevar al sobreajuste. El sobreajuste u *overfitting* es el efecto que se produce cuando un algoritmo, tras ser sobreentrenado, se ajusta demasiado a las características propias de los datos de entrenamiento y pierde causalidad con la función objetivo. Es decir, el algoritmo no generaliza sino que particulariza al enfocarse excesivamente en ejemplos individuales, obteniendo cada vez mejor tasa de éxito con el mismo tipo de muestras pero empeorando cuando las muestras son nuevas.

Se sugiere además utilizar el menor número de neuronas posible, dado el coste computacional que supone, e incidir sobre todo en el entrenamiento para conseguir resultados aceptables.

- *Número de capas*. Algunas bibliografías recomiendan como regla general el uso de una única capa oculta [56] [57]. Esto es así puesto que se asevera que la mayoría de los problemas prácticos pueden resolverse con una única capa. Además, la incorporación de una segunda capa no sólo ralentiza el entrenamiento, sino que hace el gradiente del error más inestable.
- *Número de entradas*. El número de entradas no ha de sobrepasar la relación 10 a 1 con respecto al número de clases, puesto que en el entrenamiento, el número de entradas coincidirá con el número de pesos, pudiendo provocar sobreajuste.

- *Ajuste de parámetros.* Para el entrenamiento de la red, se ha de especificar previamente parámetros como el número de épocas, el tipo de función de transferencia, el error mínimo y el error absoluto mínimo. Ajustar con precisión estos parámetros es la clave para optimizar el rendimiento del clasificador.

### **6.4.3. Configuración utilizada**

#### **6.4.3.1. Datos de entrada**

Debido a las dos primeras restricciones en los datos de entrada, a pesar de que se dispone de una base de datos compuesta por 8 clases diferentes, se han descartado gran parte de ellas en la clasificación por contener un conjunto de muestras insuficiente. Así pues, se han seleccionado finalmente para el clasificador las 3 clases con mayor número de muestras y de individuos por clase, que son las clases Latido Normal (N), Latido Atrial Prematuro (A) y Contracción Ventricular Prematura (V). De este modo, se espera evitar el problema de sobreentrenamiento y obtener mayor consistencia en los resultados.

Considerando la segunda restricción, se realizará un estudio balanceado para evitar el problema de predominio de una clase frente a otra. No obstante, se realizará aparte un estudio entre las clases de forma desbalanceada puesto que, en el caso real, el número de pulsos entre las clases no es similar, siendo muy predominante el latido normal o clase N. De esta forma se pone a prueba y se analiza la capacidad de la red neuronal con este tipo de configuración.

#### **6.4.3.2. Arquitectura**

Se ha utilizado la Neural Networks Toolbox de Matlab para efectuar las simulaciones. En este apartado se desglosa cada uno de las elecciones realizadas en su configuración.

- Número de neuronas

Dada la importancia que tiene el número de neuronas en una red neuronal, en este capítulo se desarrollará un estudio del número de neuronas óptimo que debe contener la capa oculta. Por otra parte, se ha seguido la recomendación y se ha utilizado una única capa en la red neuronal.

- Número de entradas

En cuanto al número de entradas, ninguna de las configuraciones sobrepasa la relación recomendada 10 a 1, puesto que se dispone de 9 parámetros (entradas), que se usaran en su totalidad bien simultáneamente o bien uno a uno. Por tanto, las configuraciones empleadas fueron 9 a 3 cuando se utilizaron todos los parámetros, 1 a 3 en el caso de testeo parámetro a parámetro o 9 a 2 para la clasificación sano-patológico.

- Función de transferencia

La función de transferencia escogida para la capa oculta ha sido la función logarítmica sigmoidea (*logsig*) por su simplicidad, puesto que acota su salida a valores entre 0 y 1. Otras funciones disponibles en Matlab como la tangente hiperbólica (*tansig*) ofrecen resultados entre -1 y 1 y, por otra parte, se descartan para esta capa funciones lineales (*purelin*).

Para la capa de salida se configuró una función de transferencia lineal de saturado simétrico (*satlins*) puesto que en esta capa no se realiza clasificación. En la Figura 6.4 se muestran ejemplos de funciones de transferencia no lineales.

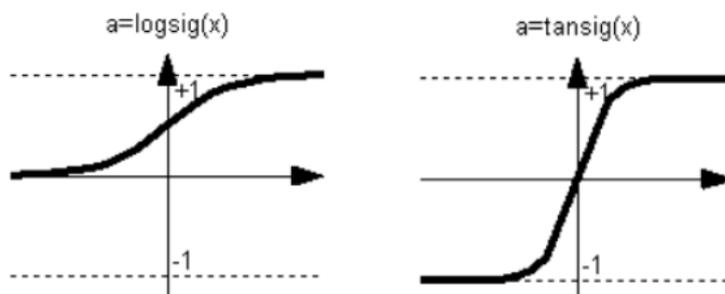


Figura 6. 4: *Funciones de activación escalón (izquierda) y sigmoidea (derecha)*

- Función de entrenamiento

La función de entrenamiento de la red escogida (*trainrp*) actualiza los pesos y los bias de acuerdo al algoritmo *resilient backpropagation*, que es de tipo *feedforward*. Se eligió esta función porque, aunque es más lenta en ejecución que otras funciones disponibles (como *trainlm*, *trainbfg*), requiere menos recursos de memoria. El algoritmo está configurado para detenerse en los siguientes casos:

1. Cuando alcance el máximo número de épocas
2. Cuando se excede el tiempo máximo
3. Cuando la función ha alcanzado la meta
4. Cuando la función gradiente cae por debajo del gradiente mínimo
5. Cuando el resultado de la validación sobrepasa el valor especificado como máximo número de fallos, desde la última vez que se decrementó (se inicializa cada vez que el error obtenido para el ajuste de pesos es cero o el permitido).

Todos estos parámetros son, a su vez, configurables por usuario. Para el número de épocas, se ha utilizado 500 en el caso de simulaciones de los parámetros en su conjunto, tanto la separación entre clases como en las clasificaciones sano-patológico, y 200 para las simulaciones parámetro a parámetro. Además, la meta de entrenamiento se ha fijado en  $10^{-18}$ , el gradiente mínimo a  $10^{-14}$  y el máximo número de fallos permisibles se fijó a 50. No se impuso ninguna limitación en tiempo de ejecución.

- Función de aprendizaje

Para determinar los pesos y las polarizaciones (*bias*) de la red, se escogió una función que realizara el aprendizaje mediante el descenso del gradiente utilizando el método momentum (*learnngdm*). El algoritmo calcula el cambio en el peso de una neurona (*dW*) de acuerdo a:

$$dW = mc*dW_{prev} + (1-mc)*lr*gW$$

Siendo

*mc*: constante momentum

*lr*: tasa de aprendizaje

*gW*: gradiente con respecto al rendimiento

- *Función de activación*

La función de activación elegida (*mse*) se encarga de activar la neurona de acuerdo al error cuadrático medio que haya obtenido.

- *Funciones de procesado de la entrada*

Se utilizó por un lado una función que estandarizara la entrada (*mapstd*), ya que de este modo se facilita la detección de atípicos, permitiendo modificarlos o eliminarlos.

Por otra parte se eliminaron las filas que tuvieran todos sus valores constantes (*removeconstantrows*) para desechar valores no válidos (como NaN).

## **6.5. SIMULACIONES DE LOS PARÁMETROS NO LINEALES**

Para poder medir la utilidad de los parámetros bajo estudio es necesario simularlos y comprobar su tasa de éxito. Como se ha comentado, la extracción de las medidas de complejidad se realizó para diferentes tamaños de trama, que fueron segmentadas entre 2 y 20 segundos. Antes de llevar a cabo las simulaciones, es necesario conocer qué tamaño de trama es el que ofrecerá los mejores resultados en el clasificador, esto es, el tamaño óptimo de trama. Este será, por tanto, el primer estudio a abordar con el simulador.

Por otra parte, para poder determinar completamente la configuración, se ha de conocer el número de neuronas que debe tener la capa de la red neuronal que maximiza los porcentajes de éxito en la clasificación. Por lo tanto, se ha de realizar además un estudio del número óptimo de neuronas.

Tras esto, se procede a testear cada uno de los parámetros no lineales, tanto separadamente como en su conjunto, y evaluar su porcentaje de éxito en la clasificación. Para ambos se mide el nivel de acierto que tiene el simulador para discriminar entre las tres clases y para distinguir entre latidos sanos y patológicos.

### 6.5.1. Estudio de la duración óptima de la trama

Se ha desarrollado un estudio de la duración óptima de la trama mediante simulaciones independientes para cada uno de los tamaños de trama.

En cuanto al número de neuronas, al ser desconocido, se ha realizado un barrido de 1 a 50 neuronas (de una en una) por cada tamaño de trama.

Por otra parte, se utilizaron en las simulaciones todos los parámetros conjuntamente puesto que, de esta forma, la red neuronal tiene mayor información para realizar la clasificación. Para el entrenamiento se definió el número de épocas a 500, simulando el sistema 50 veces para tener resultados de confianza.

Se realizaron dos tipos de clasificación, una entre clases (N, A y V) y otra que fuera capaz de identificar entre latidos sanos y patológicos. En ambas se utilizaron la totalidad de las muestras disponibles en la base de datos para cada una de las clases.

Las configuraciones para ambos casos se muestran resumidas en la siguiente tabla.

TABLA 6. 1 : CONFIGURACIÓN PARA EL ESTUDIO DE TAMAÑO DE TRAMA ÓPTIMO ENTRE CLASES Y SANO – PATOLÓGICO

Estudio	Neuronas			Ratios (%)			Épocas	Iteraciones
	Entrada	Ocultas	Salida	Entrenamiento	Validación	Test		
Entre clases	9	1-50	3	70	10	20	500	50
Sano-Patológico			2					

Como resultados, se recogieron tanto el tamaño de trama que consiguió mejores porcentajes de éxitos así como el número de neuronas con el que se obtuvo, a la vez que dichos porcentajes.

### 6.5.2. Simulación de cada parámetro con tamaño de trama óptimo

Tras obtener el tamaño óptimo que ha de tener la trama en el clasificador y el número de neuronas que ofrece los mejores resultados para este tamaño de trama, éstos se utilizarán para simular cada uno de los 9 parámetros por separado y conocer su tasa de éxito.

En esta ocasión se determinó un menor número de épocas, 200, y el sistema se simuló la mitad de veces, 25, para tener resultados de confianza. Se utilizaron la totalidad de las muestras disponibles en la base de datos para cada una de las clases.

Al igual que para la estimación del tamaño óptimo de trama, se realizaron dos tipos de clasificación, una con el objetivo de conocer el porcentaje de éxito en la ésta cuando se testean las tres clases y otra que fuera capaz de identificar entre latidos sanos y patológicos. Las configuraciones para ambos casos se muestran resumidas en la siguiente tabla.

*TABLA 6. 2 : CONFIGURACIÓN PARA EL ESTUDIO PARÁMETRO A PARÁMETRO ENTRE CLASES Y SANO - PATOLÓGICO*

Estudio	Neuronas			Ratios (%)			Épocas	Iteraciones
	Entrada	Ocultas	Salida	Entrenamiento	Validación	Test		
Entre clases	1	45	3	70	10	20	200	25
Sano-Patológico		29	2					

Como resultados, se recogieron los éxitos que obtuvo cada parámetro en la clasificación de cada una de las clases.

### **6.5.3. Estimación del número óptimo de neuronas de la red neuronal**

#### **6.5.3.1. Estimación teórica**

En lo referente al cálculo del número óptimo de neuronas que ha de tener una red neuronal, se debe tener en cuenta que un número excesivo de ellas aumenta considerablemente el tiempo de simulación y que un número insuficiente de las mismas no resuelve el problema. Por lo tanto, se hace necesario un compromiso entre ambas y es por ello que se estimará en primer lugar el número óptimo de neuronas de forma teórica, como primera aproximación.

En la bibliografía existen diferentes métodos que tratan de aproximar cuántas neuronas debe tener dicha red. Entre ellos se encuentran la regla de la pirámide geométrica, la regla de la capa oculta-capas de entrada y la regla de la capa oculta- número de patrones entre otros [58].

- La **regla de la pirámide geométrica** se basa en la suposición de que el número de neuronas de la capa oculta ha de ser inferior al total de variables de entrada pero superior al número de variables de salida. Se considera que el número de neuronas en cada capa sigue una progresión geométrica, tal que, para una red con una única capa oculta, el número de neuronas intermedias debe ser próximo a  $h = \sqrt{N \cdot M}$  siendo N el número de variables de entrada y M el total de neuronas de salida.
- La **regla de la capa oculta-capas** entrada indica que el número de neuronas ocultas está relacionado con el número de neuronas de entrada. En particular suele aplicarse la regla 2x1, de forma que el número de neuronas ocultas no puede ser superior al doble del número de variables de entrada.  
  
Para clasificación entre las 3 clases y sano-patológico, al ser el número de entradas el mismo, el número de neuronas debe ser  $h < 18$ .
- La **regla de la capa oculta-número de patrones** relaciona el número de neuronas de la capa oculta con el total de patrones presentados al sistema, siendo habitual la relación 1/30 (una neurona oculta por cada 30 patrones).

En este proyecto, como una primera aproximación teórica, se siguió la regla de la pirámide geométrica para obtener una estimación acerca de cuántas neuronas serían suficientes y la regla de la capa oculta-capas entrada para conocer el número máximo de neuronas. Los cálculos se elaboraron tanto para el caso del diseño de una red neuronal entre clases como para la red de clasificación entre latidos sanos y patológicos. El número de entradas para ambas clases coincide con el número de parámetros bajo estudio. El número de salidas, por su parte, se corresponde con el número de clases a identificar, siendo 3 y 2 respectivamente. Los resultados se muestran en la tabla.

TABLA 6. 3 : NÚMERO DE NEURONAS DE LA CAPA OCULTA ESTIMADO DE MANERA TEÓRICA

Método	Tipo de Clasificación	Número de entradas	Número de salidas	Número de neuronas
<i>Pirámide geométrica</i>	entre clases	9	3	6
	sano-patológico		2	5
<i>Capa oculta-capas entrada</i>	entre clases		3	<18
	sano-patológico		2	

Los resultados obtenidos de manera teórica limitan a 18 el número máximo de neuronas en la capa oculta y determina como suficiente capas de 6 y 5 neuronas para resolver el problema.

Tras ello, se efectuaron de manera práctica simulaciones del sistema, realizando un primer barrido de 1 a 10 neuronas. Los resultados prácticos de esta prueba preliminar indicaron que las tasas de acierto no eran aceptables, pero que existía un aumento progresivo en el porcentaje de éxitos a medida que se incrementaba el número de neuronas de la capa. Por ello se procedió a un segundo barrido, esta vez de hasta 60 neuronas.

### **6.5.3.2. Estudio balanceado**

Se ha realizado en primer lugar un estudio del número óptimo de neuronas de tipo balanceado. Esto quiere decir que se ha tomado, para hacer las simulaciones, un número de muestras similar para cada clase. Con esto se pretende que no predomine un determinado tipo, tanto en la caracterización como en el entrenamiento [21].

Al igual que para el estudio del tamaño óptimo de trama, el procedimiento se ha elaborado tanto para las tres clases que forman la base de datos como para la clasificación de pulsos entre latidos sanos y patológicos.

Para la clasificación de las tres clases se ha fijado el número de muestras al número de muestras de la clase menor, la clase Contracción Ventricular Prematura (V). Por lo tanto, para las otras clases Normal (N) y Latido Atrial Prematuro (A) se ha tomado el mismo número, pero las muestras para la clasificación se han extraído de manera aleatoria de entre el total de las muestras de cada una de sus clases.

Para la clasificación Sano-Patológico, se toma la totalidad de las muestras de las dos clases patológicas y se fija a este valor el número de muestras de la clase N. Al igual que en el caso anterior, para la clase N se toman sus muestras de manera aleatoria.

Con el objeto de adquirir mayor información y obtener los mejores resultados posibles, se han ensayado además distintos valores de porcentajes de entrenamiento, test y validación y se efectuaron los barridos de neuronas. Es decir, para cada configuración de entrenamiento, validación y test se simularon de 1 a 60 neuronas (de una en una) utilizando todos los parámetros conjuntamente. Aquella configuración que ofrecía mejores tasas de

éxito se fijó para efectuar el posterior estudio de número óptimo de neuronas para cada parámetro individualmente.

Las configuraciones ensayadas fueron las siguientes:

*TABLA 6. 4 : CONFIGURACIONES TESTEADAS PARA EL ESTUDIO BALANCEADO UTILIZANDO EL CONJUNTO DE PARÁMETROS*

<i>Estudio</i>	<i>Neuronas</i>			<i>Ratios (%)</i>			<i>Épocas</i>	<i>Iteraciones</i>
	<i>Entrada</i>	<i>Ocultas</i>	<i>Salida</i>	<i>Entrenamiento</i>	<i>Validación</i>	<i>Test</i>		
<i>Entre clases</i>	9	1-60	3	70	10	20	500	50
				60	20	20		
				60	10	30		
				60	30	10		
<i>Sano-Patológico</i>			2	70	10	20		
				60	20	20		
				60	10	30		
				60	30	10		

De esta prueba se extrajeron conjuntamente a los porcentajes de éxitos más altos conseguidos, el número de neuronas para tales porcentajes de éxitos y la configuración empleada.

Con la configuración de mayor tasa de acierto se representó gráficamente la evolución de los éxitos que se conseguían en la clasificación en función del aumento progresivo del número de neuronas. Este procedimiento se hizo para cada una de sus clases y para las clases Sano y Patológico.

Tras ello, se hizo una comparativa de los estudios del número óptimo de neuronas teórico y práctico.

Por último se estimó el número óptimo de neuronas necesario para obtener las mejores tasas de éxito utilizando en el clasificador cada parámetro por separado. La configuración empleada es:

TABLA 6. 5 : CONFIGURACIONES TESTEADAS PARA EL ESTUDIO BALANCEADO PARÁMETRO A PARÁMETRO

Estudio	Capas			Ratios (%)			Épocas	Iteraciones
	Entrada	Ocultas	Salida	Entrenamiento	Validación	Test		
Entre clases	1	1-60	3	70	10	20	200	25
Sano-Patológico			2					

### 6.5.3.3. Estudio desbalanceado

El estudio desbalanceado ha sido motivado puesto que en el caso real, las diferentes clases de pulsos se encuentran desbalanceadas, siendo predominante la clase N (latido normal). Por lo tanto, en este estudio se ha tomado la totalidad de las muestras disponibles de cada clase en la base de datos y se han simulado.

Se utilizó la misma metodología que para el caso balanceado. Esto es, se realizaron las simulaciones de las tres clases y para las clases sano-patológico, se ensayaron los mismos valores de porcentajes de entrenamiento, test y validación para un barrido de hasta 60 neuronas y, por último, se representó la evolución de los éxitos que se conseguían en la clasificación en función del aumento progresivo del número de neuronas.

## 6.6. EVALUACIÓN DEL SISTEMA CLASIFICADOR

Para valorar el comportamiento del sistema de clasificación se analizaron una serie de medidas. Por una parte se representó la curva del sistema en un espacio ROC (Característica Operativa del Receptor), también denominada curva de rendimiento diagnóstico en el ámbito de investigaciones clínicas. Por otra parte se calcularon sus valores predictivos a partir de las matrices de confusión.

Para la representación de una ROC se requiere conocer previamente el número de verdaderos positivos (VP), falsos positivos (FP), verdaderos negativos (VN) y de falsos negativos (FN) en la clasificación de cada una de las clases, puesto que un espacio ROC se define por la FPR (tasa de falsos positivos) y la VPR (tasa de verdaderos positivos) como ejes  $x$  e  $y$  respectivamente. Dado que VPR es también llamado sensibilidad y FPR es igual a la diferencia entre uno y la especificidad, el gráfico ROC también es conocido como la

representación de sensibilidad frente a (1-especificidad). Cada resultado de predicción de la matriz de confusión representa un punto en el espacio ROC [59].

La sensibilidad y especificidad se definen de la siguiente manera:

- *Sensibilidad o tasa de verdaderos positivos (VPR)*: indica la capacidad del test para identificar correctamente las clases.

$$VPR = \frac{VP}{VP + FN}$$

- *Especificidad o tasa de verdaderos negativos (SPC)*: indica la capacidad del test para excluir correctamente una clase.

$$SPC = \frac{VN}{FP+VN} = 1 - FPR$$

Siendo por tanto FPR:

$$FPR = \frac{FP}{FP + VN}$$

Los resultados alcanzados se han evaluado teniendo en cuenta que el mejor resultado posible de predicción (clasificación perfecta) se situaría en un punto en la esquina superior izquierda del espacio ROC, la coordenada (0,1). Este representa un 100% de sensibilidad (ningún falso negativo) y un 100% de especificidad (ningún falso positivo). Por el contrario, una clasificación totalmente aleatoria daría un punto a lo largo de la línea diagonal (línea de no-discriminación), desde el extremo inferior izquierdo hasta la esquina superior derecha.

En la Figura 6.5 se muestran ejemplos de curvas ROC y la valía que tendría el sistema clasificador para evaluar la diagnóstico.

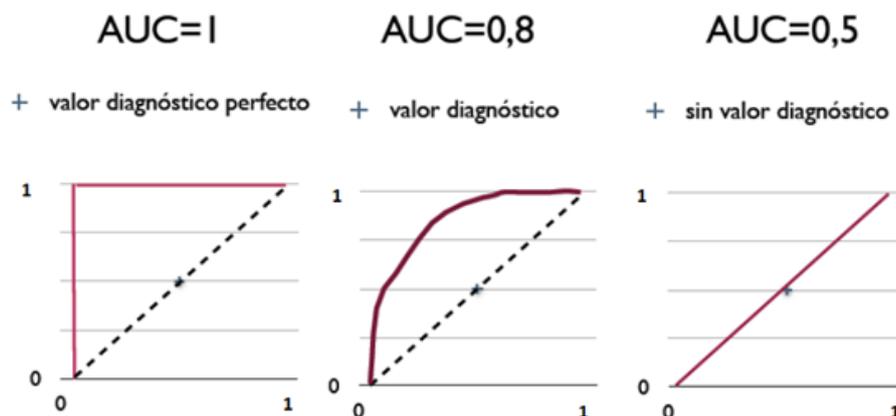


Figura 6. 5 : Ejemplos de curvas ROC y su significado [59]

En la Figura 6.5 se muestran los valores obtenidos del área bajo la curva (AUC) para las distintas curvas de ROC. Existen unos intervalos, a modo de guía, en el que el AUC indica la efectividad del clasificador en función al intervalo al que pertenezca este valor. Éstos se muestran en la Tabla 6.6.

TABLA 6. 6 EVALUACIÓN DEL TEST EN FUNCIÓN DE LOS INTERVALOS AUC [59]:

Intervalos de AUC	Evaluación del test
[0,5 – 0,6]	Insuficiente
[0,6 – 0,7]	Pobre
[0,7- 0,8]	Justo
[0,8 – 0,9]	Bueno
[0,9 -1,0]	Excelente

Por otra parte, dado que la sensibilidad, especificidad y el AUC son valores intrínsecos (no varían entre poblaciones) se utilizaron además otras medidas de interés, como los valores predictivos. Estos valores son índices que miden la eficacia real de la prueba diagnóstica puesto que evalúan el comportamiento de dicha prueba en una población con una determinada proporción de enfermos, por lo que sirven para medir la relevancia de la sensibilidad y especificidad en una determinada población.

El valor predictivo positivo y el valor predictivo negativo, junto con la exactitud, se definen como:

- *Valor predictivo positivo (PPV)*: probabilidad de tener una patología (o clase) si el resultado de la prueba diagnóstica es positivo.

$$PPV = \frac{VP}{VP + FP}$$

- *Valor predictivo negativo (NPV)*: probabilidad de no tener la patología si el resultado de la prueba diagnóstica es negativo.

$$NPV = \frac{VN}{VN + FN}$$

- *Exactitud*: Mide el grado de cercanía entre la medida de una cantidad y el valor real de dicha cantidad.

$$ACC = \frac{VP + VN}{P + N}$$

A partir de las matrices de confusión obtenidas en la clasificación se extrajeron los valores de VP, FP, VN, FN y se calcularon las medidas anteriores.

Son con estos criterios con los que se ha evaluado el sistema de clasificación implementado. En el siguiente capítulo se muestra una tabla con los resultados que se han obtenido de dichas medidas, junto con los gráficos ROC para cada una de las clases.



## Capítulo 7

# 7. ANÁLISIS DE RESULTADOS

### 7.1. RESULTADOS DEL ESTUDIO DEL TAMAÑO ÓPTIMO DE TRAMA

La Figura 7.1 muestra la capacidad del sistema para clasificar por tipo de cardiopatía según el tamaño de trama utilizado. Se representan los éxitos obtenidos, en tanto por ciento, frente a los tamaños de trama empleados, en segundos.

Las clases se corresponden con Latido Normal (N), Latido Atrial Prematuro (A), y Contracción Ventricular Prematura (V).

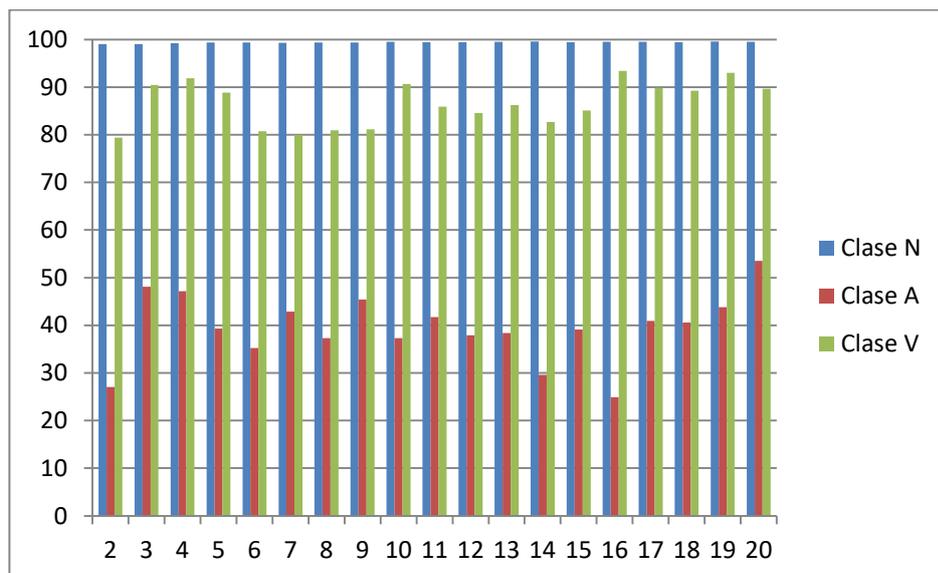


Figura 7. 1 : Porcentajes de éxitos obtenidos en la clasificación, por tamaño de trama (en segundos), para la clasificación de las 3 clases

En el Anexo II se incluye una tabla detallada con los valores porcentuales de éxito en esta clasificación, junto con el número de neuronas que ha sido necesario para cada uno de ellos.

Del diagrama se concluye que el tamaño óptimo de trama se consigue para 20 segundos, obteniendo tasas de acierto de 99,5%, 53,5%, 89,6% para las clases N, A y V respectivamente. Estos resultados se han alcanzado con 45 neuronas en la capa oculta.

Por otra parte, la Figura 7.2 muestra la capacidad que tiene el clasificador de distinguir entre latidos sanos y patológicos. Igualmente, se representan los éxitos obtenidos, en tanto por ciento, frente a los tamaños de trama empleados, en segundos. La clase Sano está formado por latidos de la clase Normal (N) y, la clase Patológico, está formada por el conjunto de las clases Latido Atrial Prematuro (A) y Contracción Ventricular Prematura (V).

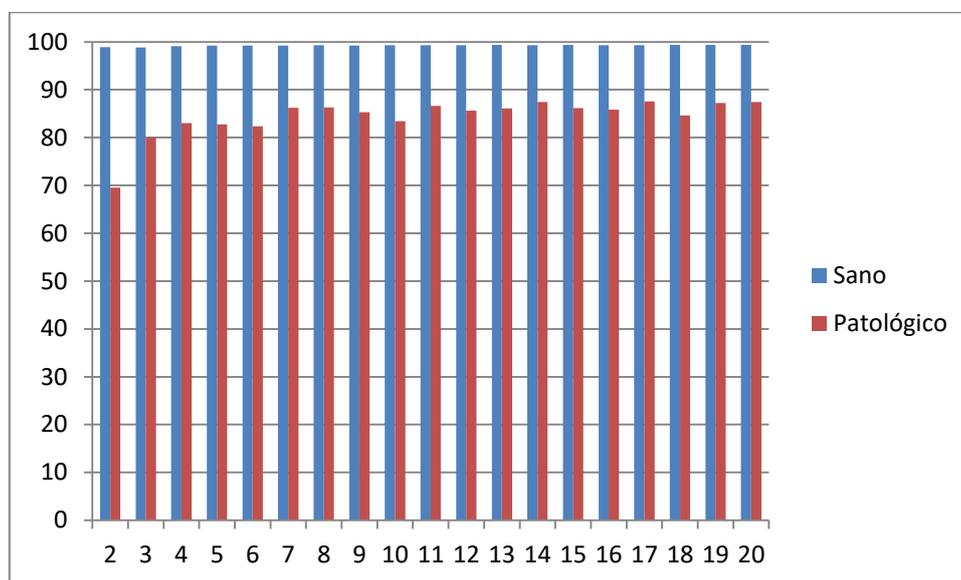


Figura 7. 2 : Porcentajes de éxitos obtenidos en la clasificación, por tamaño de trama (en segundos), para la clasificación entre sano y patológico

Del diagrama muestra que el tamaño óptimo de trama se consigue también para 20 segundos, obteniendo tasas de acierto de 99,4% y 87,4% para las clases Sano y Patológico respectivamente, y utilizando 29 neuronas en la capa oculta.

Igualmente, en el Anexo II se incluye una tabla con éstos resultados, junto con el número de neuronas para cada uno de ellos. De los resultados obtenidos se concluye que para tamaños de trama mayores se obtienen mejores resultados, aunque no se trata de una correspondencia lineal. Así pues, la duración de trama óptima a emplear en el clasificador será de 20 segundos.

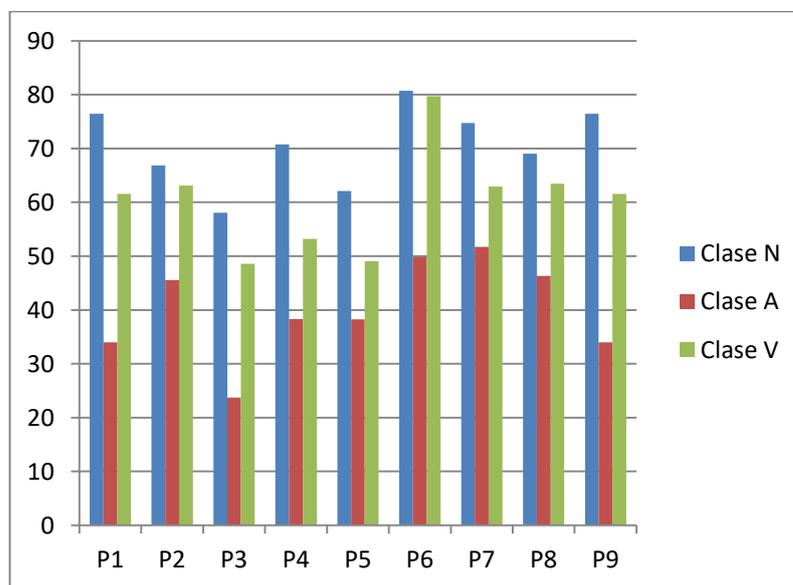
En resumen, los resultados del estudio del tamaño óptimo de trama son:

*TABLA 7. 1 : TABLA RESUMEN DE RESULTADOS EN LA ESTIMACIÓN DEL TAMAÑO ÓPTIMO DE TRAMA, PARA LAS CLASIFICACIONES ENTRE CLASES Y SANO-PATOLÓGICO*

Estudio	Tamaño de trama óptimo	Nº de neuronas en la capa oculta	Tasa de cierto (%)		
			Clase N	Clase A	Clase V
Entre clases	20 s	45	99,5	53,5	86,6
Sano - Patológico	20 s	29	99,4	87,4	-

## 7.2. RESULTADOS DE LA SIMULACIÓN DE CADA PARÁMETRO CON TAMAÑO DE TRAMA ÓPTIMO

La Figura 7.3 representa la tasa de éxito que se consigue tras simular cada parámetro no lineal utilizando tramas de tamaño óptimo y, como número de neuronas, aquel número con el que se alcanzaron los mejores éxitos para dicho tamaño de trama.



*Figura 7. 3 : Porcentaje de éxitos de cada parámetro para la clasificación de las tres clases, con tamaño de trama óptimo*

Los parámetros utilizados se codificaron de la siguiente manera:

- P1: Entropía de Shannon
- P2 y P3: Máximo Exponente de Lyapunov, con algoritmos Rosenstein y Kantz respectivamente
- P4: Dimensión de correlación
- P5: Entropía de correlación
- P6: Complejidad Lempel-Ziv
- P7, P8 y P9: Exponente de Hurst, con algoritmos de Varianza Agregada, Momento Absoluto y R/S respectivamente

Las mayores tasas de éxito se obtuvieron, por este orden, para los parámetros Complejidad de Lempel-Ziv, Exponente de Hurst (R/S, Varianza Agregada y Momento Absoluto) y Máximo Exponente de Lyapunov (Rosenstein). Las tasas más bajas, para Máximo Exponente de Lyapunov (Kantz), seguido de la Entropía de Correlación, la Dimensión de Correlación y la Entropía de Shannon.

Además del gráfico presentado, se exponen la totalidad de porcentajes obtenidos para cada uno de los parámetros en el Anexo II.

Por otra parte, se procede del mismo modo en cuanto al estudio Sano-Patológico. En la Figura 7.4 se muestran los resultados, en porcentajes, de cada parámetro para clasificación entre latidos sanos y latidos patológicos.

En este caso, las mayores tasas de éxito se obtuvieron para los parámetros Exponente de Hurst (Varianza Agregada y R/S), Máximo Exponente de Lyapunov (Rosenstein), Exponente de Hurst (Momento Absoluto) y Complejidad de Lempel-Ziv. Las tasas más bajas se obtuvieron, a su vez, para los mismos parámetros que en el estudio entre clases y en el mismo orden: Máximo Exponente de Lyapunov (Kantz), Entropía de Correlación, la Dimensión de Correlación y la Entropía de Shannon.

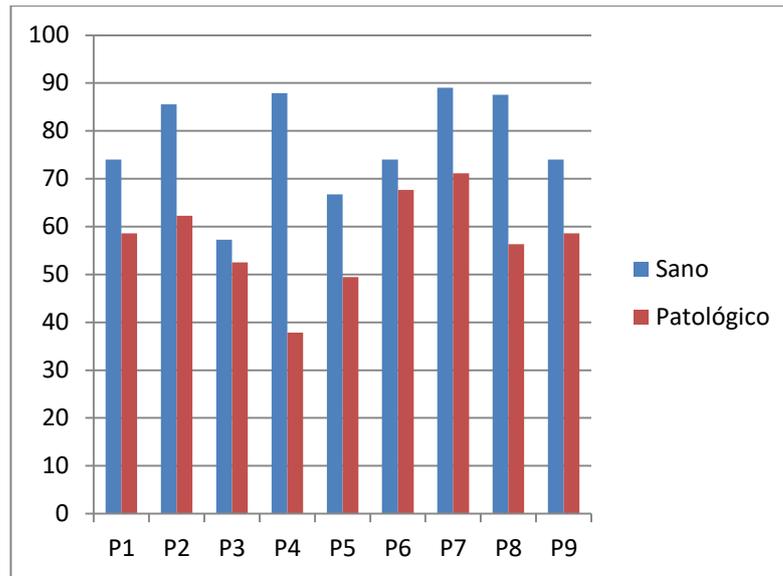


Figura 7. 4 : Porcentaje de éxitos de cada parámetro para la clasificación de las clases Sano y Patológico, con tamaño de trama óptimo

A modo de resumen, ambos estudios arrojan resultados muy similares. Para ambos, las mayores tasas de acierto se tienen para el Exponente de Hurst (para sus 3 algoritmos), el Máximo Exponente de Lyapunov (Rosenstein) y la Complejidad Lempel-Ziv. Los porcentajes de éxito más bajos se tienen para el Máximo Exponente de Lyapunov (Kantz), la Entropía de Correlación, la Dimensión de Correlación y la Entropía de Shannon.

### 7.3. RESULTADOS DEL ESTUDIO DEL NÚMERO DE NEURONAS ÓPTIMO DE LA RED CON EL CONJUNTO DE PARÁMETROS

#### 7.3.1. Estudio balanceado

##### 7.3.1.1. Clasificación de las clases $N$ , $A$ y $V$

Los resultados de ensayar distintas configuraciones se muestran en la Tabla 7.2. Se han remarcado los mayores porcentajes de éxito, junto con la configuración y el número de neuronas que han sido necesarios para obtenerlos.

TABLA 7. 2 : NÚMERO DE NEURONAS ÓPTIMO OBTENIDO PARA LA DISCRIMINACIÓN DE LAS CLASES N, A Y V CON UN NÚMERO DE MUESTRAS BALANCEADO

Entrenamiento (%)	Test (%)	Validación (%)	Éxitos (%)			N° de neuronas
			Clase N	Clase A	Clase V	
70	10	20	97,2368	88,3403	88,5151	53
60	20	20	97,2497	86,7018	88,0544	20
60	10	30	95,1430	86,5066	88,8658	40
60	30	10	95,4638	86,0640	88,7777	57

Los resultados obtenidos se consideran aceptables en todos los casos, siendo la clase N la que mayor porcentaje de éxito obtiene en todas las configuraciones utilizadas. Se observa que, aunque la primera configuración consigue mejores resultados, la diferencia entre los porcentajes de éxitos de ésta con respecto a la segunda no es muy significativa y, en cambio, sólo requiere de 20 neuronas frente a las 53 que requiere la primera. En cuanto a tiempo de cómputo, podría considerarse más adecuada la segunda configuración y utilizarse como número de neuronas óptimo 20 neuronas.

En este proyecto se ha usado la primera configuración, puesto que en principio se ha dado prioridad a conseguir una tasa de aciertos en el clasificador lo más aceptable posible frente al tiempo de cómputo.

Para la configuración elegida se representa la evolución de los éxitos conseguidos en función del número de neuronas de la capa oculta. En las siguientes figuras se muestra esta evolución para cada una de las clases:

- **Clase N**

La Figura 7.5 muestra que, para la clase Normal o de control, los resultados se mantienen prácticamente sin variaciones, oscilando su tasa de éxito entre el 95% y 97% de aciertos en el clasificador.

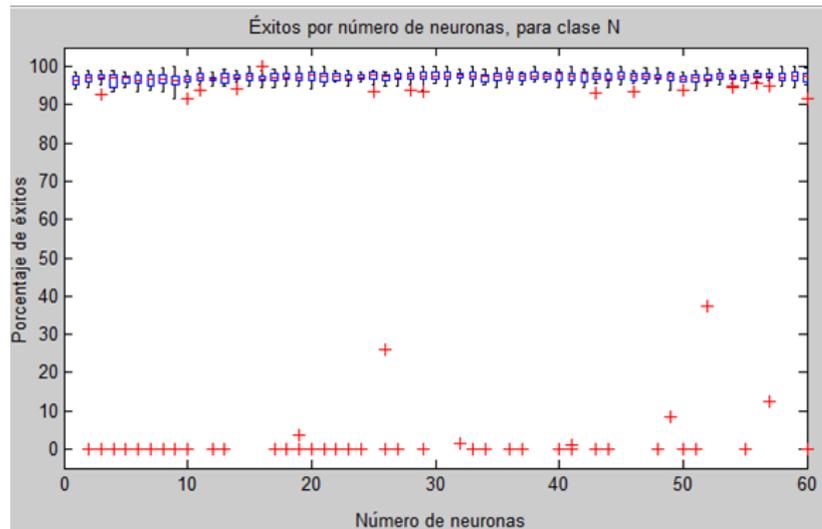


Figura 7. 5 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta

#### ▪ Clase A

Para la clase Latido Atrial Prematuro (A) los resultados también se mantienen prácticamente sin variaciones, pero esta vez con una tasa de éxito más baja que para clase N, oscilando entre el 80 y 90% durante todo el barrido. Además, la presencia de atípicos para esta clase y la varianza es mayor que con respecto a la que se obtuvo para la clase N.

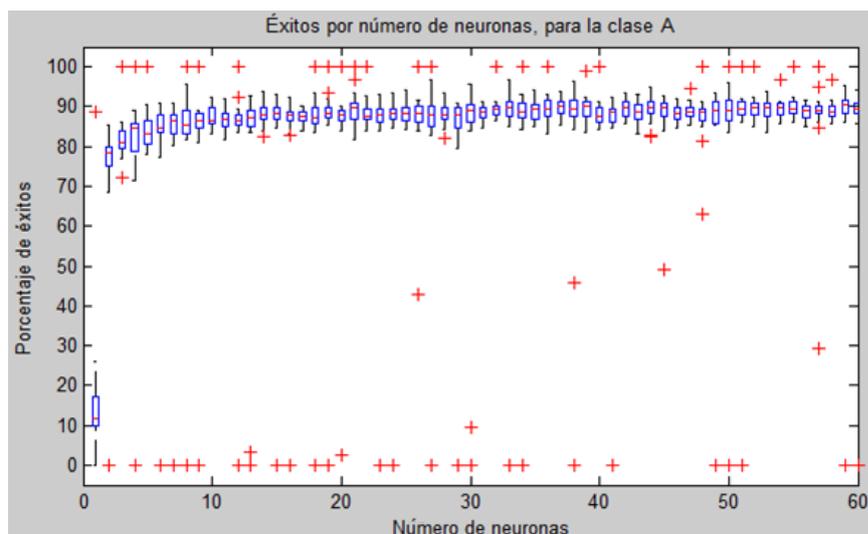


Figura 7. 6 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta

▪ **Clase V**

En la Figura 7.7 se muestran los resultados que se consiguieron para la clase patológica Contracción Ventricular Prematura (V). Con estos resultados las variaciones no son muy significativas, y su tasa de éxito es similar a la tasa de éxito de la clase A, entre el 80 y 90% durante todo el barrido.

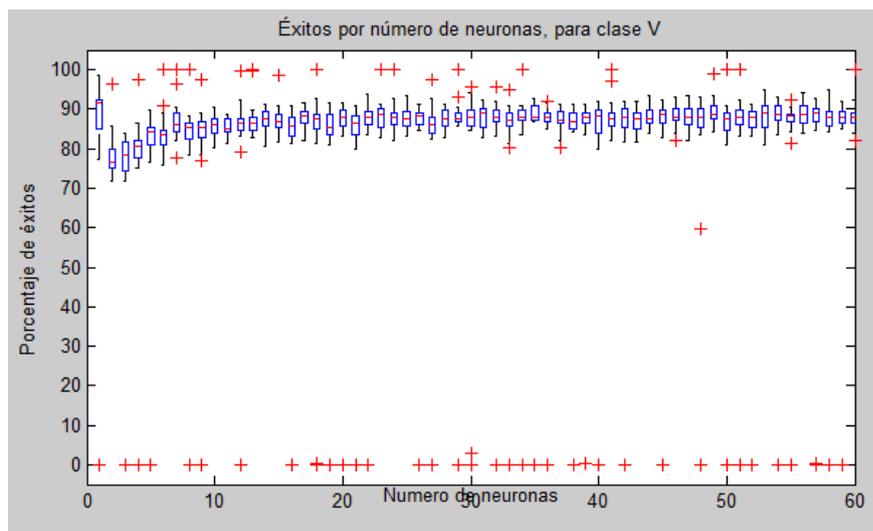


Figura 7.7 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta

**7.3.1.2. Clasificación sano- patológico**

Los resultados obtenidos son bastante aceptables, siendo la variación entre las distintas configuraciones apenas significativas. Es por tanto que puede considerarse adecuada cualquiera de ellas para efectuar las pruebas.

A diferencia de los resultados que se obtuvieron en la clasificación de las clases N, A, y V, el número de neuronas requerido en esta ocasión es más elevado, superando las 50 neuronas en la mayoría de los casos, lo que acarrea un mayor tiempo de cómputo.

Los resultados de las diferentes configuraciones se muestran en la tabla:

TABLA 7. 3 : NÚMERO DE NEURONAS ÓPTIMO OBTENIDO PARA LA DISCRIMINACIÓN DE LAS CLASES SANO Y PATOLÓGICO CON UN NÚMERO DE MUESTRAS BALANCEADO

Entrenamiento (%)	Test (%)	Validación (%)	Éxitos (%)		Nº de neuronas
			Sano	Patológico	
70	10	20	95,4006	94,1447	52
60	20	20	95,2897	93,9942	51
60	10	30	95,2701	94,0720	53
60	30	10	95,0123	94,0142	42

#### ▪ Clase Sano

En la Figura 7.8 se muestran los resultados que se consiguieron para la clase Sano. La tasa de éxito se mantiene constante, alrededor del 95%, para la mayoría de las neuronas ensayadas, lo que posibilita escoger un número de neuronas más bajo que aquel que alcanza mayores éxitos y, aun así, conseguir resultados aceptables.

Por otra parte, la varianza de resultados estimados por número de neuronas es muy baja.

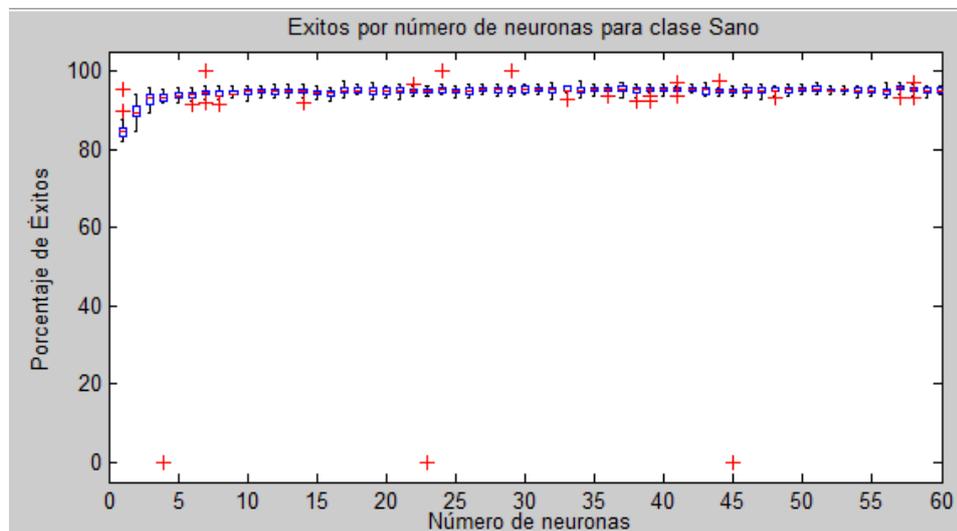


Figura 7. 8 : Éxitos en la clasificación para clase Sano en función del número de neuronas de la capa oculta

▪ **Clase Patológico**

Para la clase Patológico la tasa de éxito también se mantiene constante, entre el 90% y el 94%, para la mayoría de las neuronas ensayadas y la varianza de resultados estimados por número de neuronas es muy baja.

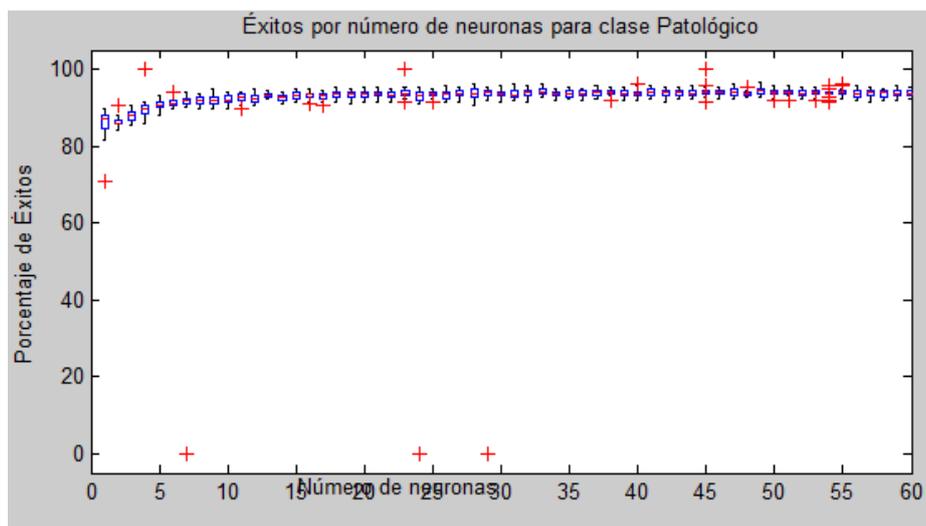


Figura 7. 9 : Éxitos en la clasificación para clase Patológico en función del número de neuronas de la capa oculta

**7.3.1.3. Comparativa de resultados teóricos con los prácticos para balanceado**

En la Tabla 7.4 se muestra la comparativa de resultados que se obtendrían utilizando, por un lado, el número de neuronas óptimo hallado teóricamente, y por otra parte, los resultados que se obtuvieron tras el barrido de 1 a 60 neuronas.

En el capítulo anterior se estimó el intervalo de neuronas donde se encontraba el número óptimo de ellas. Por ello, se simuló el sistema efectuando un barrido de 1 a 10 neuronas, de una en una.

Los resultados indican que, aunque se consigue una mayor tasa de éxitos cuando se utiliza el número de neuronas obtenido de manera práctica (el más alto), la diferencia entre los resultados teóricos y prácticos no es demasiado significativa.

TABLA 7. 4 : COMPARATIVA DE NÚMERO ÓPTIMO DE NEURONAS TEÓRICO Y PRÁCTICO PARA BALANCEADO

Estudio entre clases	Entrenamiento (%)	Test (%)	Validación (%)	Éxitos (%)			Nº de neuronas
				N	A	V	
Teórico	70	10	20	81,5	75,8	80,9	9
Práctico				97,2	88,3	88,5	53
Estudio Sano-Patológico	Entrenamiento (%)	Test (%)	Validación (%)	Sano	Patológico	-	Nº de neuronas
Teórico	70	10	20	86,9	82,9	-	10
Práctico				95,4	94,1	-	52

### 7.3.2. Estudio desbalanceado

#### 7.3.2.1. Clasificación de las clases N, A y V

En la tabla se muestran los resultados tras las simulaciones de las distintas configuraciones y el número de neuronas con los que se ha alcanzado.

TABLA 7. 5 : NÚMERO DE NEURONAS ÓPTIMO OBTENIDO PARA EL ESTUDIO ENTRE CLASES CON UN NÚMERO DE MUESTRAS DESBALANCEADO

Entrenamiento (%)	Test (%)	Validación (%)	Éxitos (%)			Nº de neuronas
			N	A	V	
70	10	20	99,3956	44,1324	89,9157	51
60	20	20	99,3642	42,9140	83,7130	27
60	10	30	99,4121	38,6413	87,7699	42
60	30	10	99,2158	38,7984	87,0744	7

Los resultados muestran que la clase con menor número de muestras, A, se encuentra desfavorecida frente a las otras dos. Además, el número de neuronas óptimo que se consigue con las configuraciones propuestas es bastante dispar, desde 7 neuronas para la cuarta hasta 51 neuronas para la primera.

### 7.3.2.2. Clasificación de las clases Sano-Patológico

TABLA 7. 6 : NÚMERO DE NEURONAS ÓPTIMO OBTENIDO PARA EL ESTUDIO SANO-PATOLÓGICO CON UN NÚMERO DE MUESTRAS DESBALANCEADO

Entrenamiento (%)	Test (%)	Validación (%)	Éxitos (%)		Nº de neuronas
			Sano	Patológico	
70	10	20	99,2195	82,2294	44
60	20	20	99,2304	82,6057	57
60	10	30	99,1014	83,5253	11
60	30	10	99,1441	83,3873	24

Los resultados obtenidos se consideran aceptables, además que el número de neuronas requerido es bajo. En este caso, el número de neuronas óptimo es de 11 neuronas.

### 7.3.2.3. Comparativa de resultados teóricos con los prácticos para balanceado

La diferencia entre los resultados teóricos y prácticos es más significativa en este caso en comparación a utilizar un número de muestras balanceado. Para las clases A y Patológico, los resultados obtenidos utilizando el número de neuronas teórico se consideran insuficientes.

TABLA 7. 7 : COMPARATIVA DE NÚMERO ÓPTIMO DE NEURONAS TEÓRICA Y PRÁCTICA

Estudio entre clases	Entrenamiento (%)	Test (%)	Validación (%)	Éxitos (%)			Nº de neuronas
				N	A	V	
Teórico	70	10	20	98,7	21,3	58,1	9
Práctico				99,4	44,1	89,9	51
Estudio Sano-Patológico	Entrenamiento (%)	Test (%)	Validación (%)	Sano	Patológico	-	Nº de neuronas
Teórico	60	10	30	93,4	55,6	-	10
Práctico				99,1	83,5	-	11

## 7.4. RESULTADOS DEL ESTUDIO DEL NÚMERO DE NEURONAS ÓPTIMO DE LA RED PARÁMETRO A PARÁMETROS

En este apartado se representan los resultados de los parámetros que han obtenido las mejores tasas de éxito: Complejidad Lempel-Ziv, Hurst (R/S, Varianza Agregada y Momento Absoluto) y Lyapunov (Rosenstein). En el Anexo II se muestran los resultados para el resto de los parámetros bajo estudio.

### 7.4.1. Complejidad Lempel-Ziv

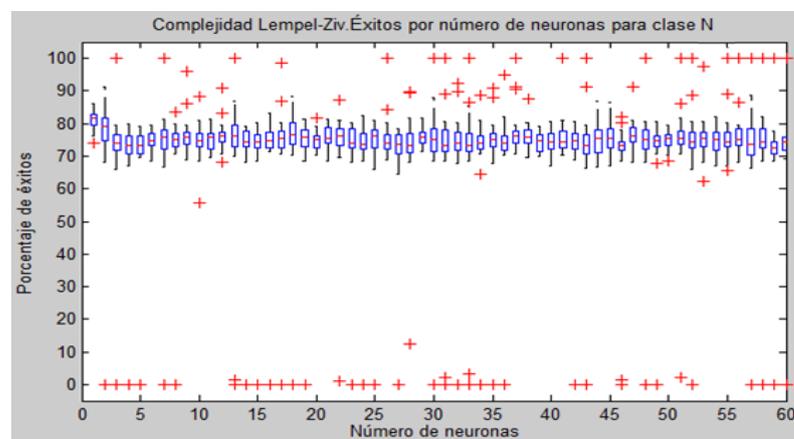


Figura 7. 10 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Complejidad Lempel-Ziv

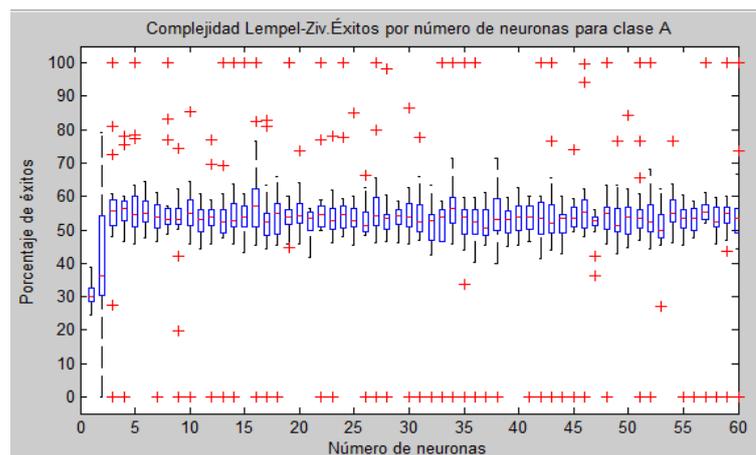


Figura 7. 11 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Complejidad Lempel-Ziv

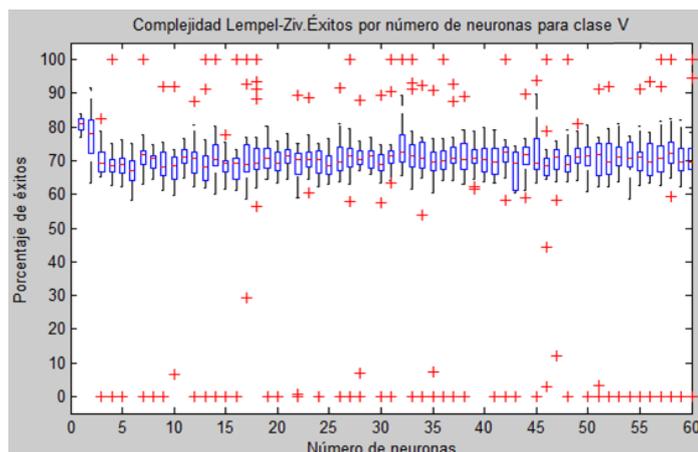


Figura 7. 12: Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Complejidad Lempel-Ziv

### 7.4.2. Exponente de Hurst, algoritmo RS

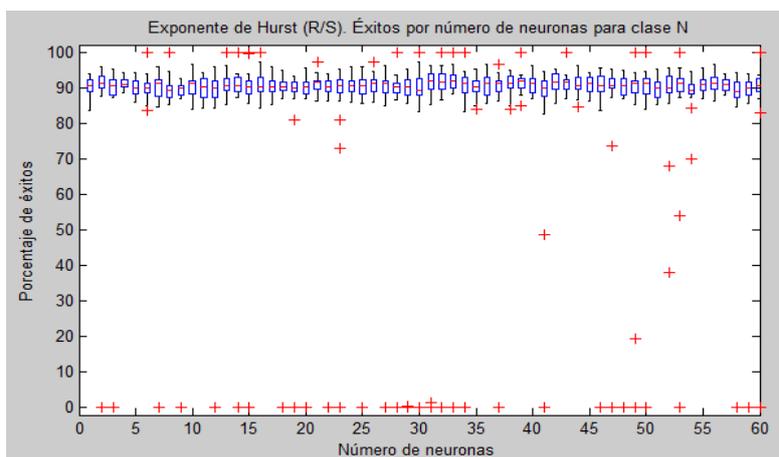


Figura 7. 13 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para para Exponente de Hurst (R/S)

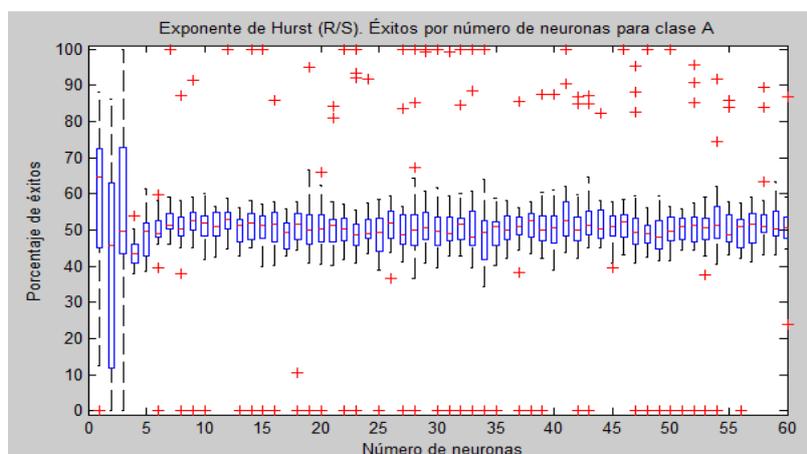


Figura 7. 14 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para para Exponente de Hurst (R/S)

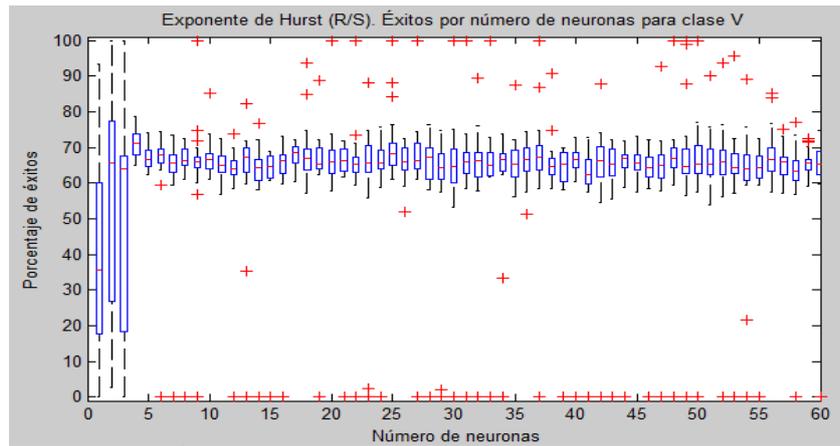


Figura 7. 15 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para para Exponente de Hurst (R/S)

### 7.4.3. Exponente de Hurst, algoritmo de Varianza Agregada

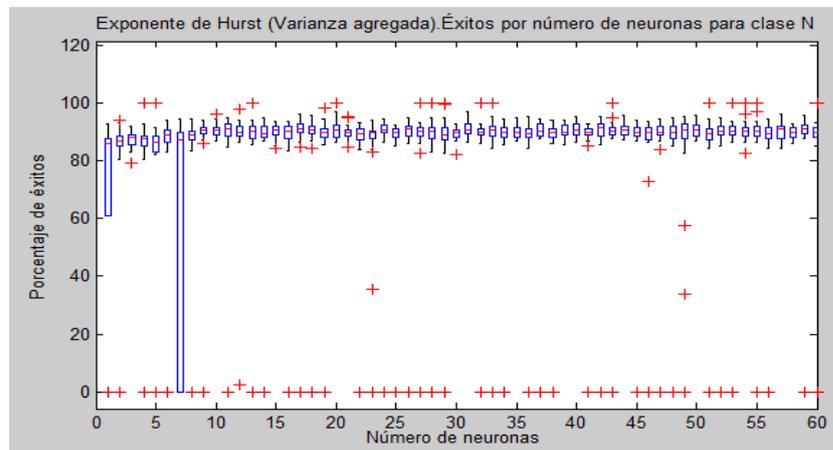


Figura 7. 16 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Exponente de Hurst (Varianza Agregada)

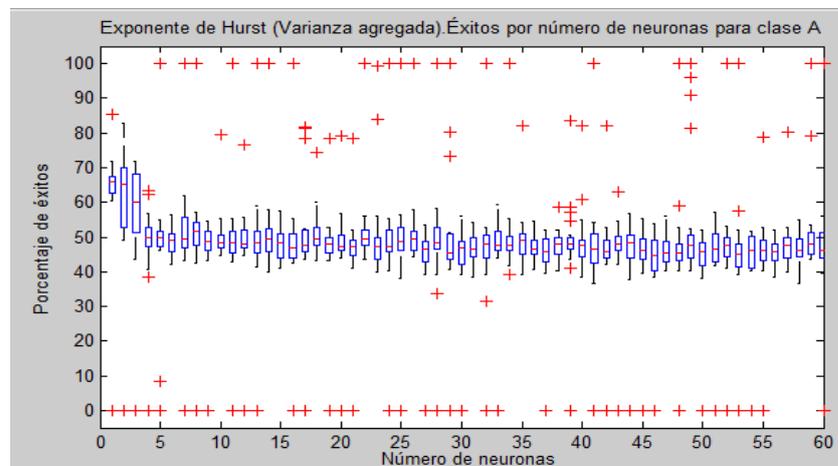


Figura 7. 17 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Exponente de Hurst (Varianza Agregada)

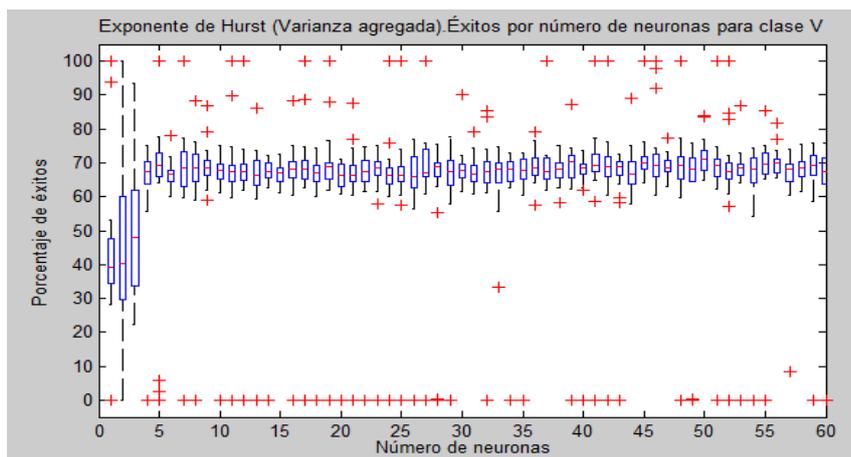


Figura 7. 18: Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Exponente de Hurst (Varianza Agregada)

#### 7.4.4. Exponente de Hurst, algoritmo de Momento Absoluto

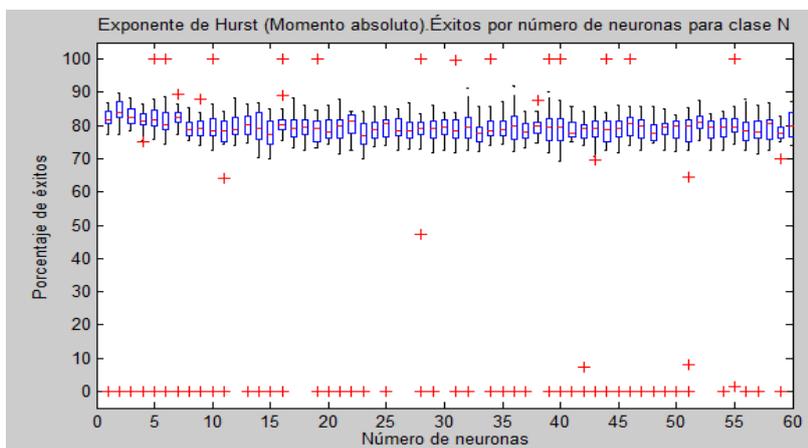


Figura 7. 19 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Exponente de Hurst (Momento Absoluto)

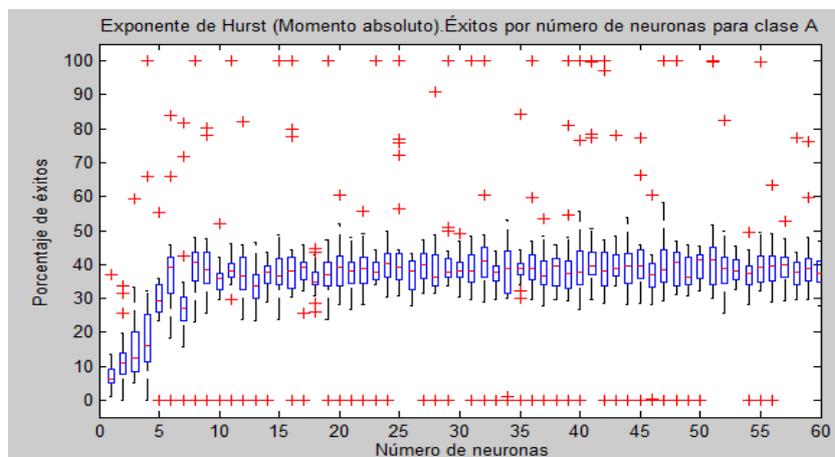


Figura 7. 20 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Exponente de Hurst (Momento Absoluto)

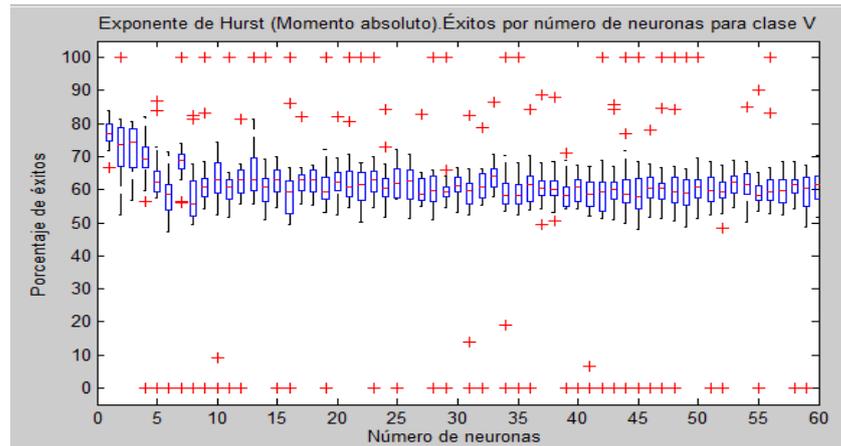


Figura 7. 21 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Exponente de Hurst (Momento Absoluto)

#### 7.4.5. Máximo Exponente de Lyapunov, algoritmo de Rosenstein

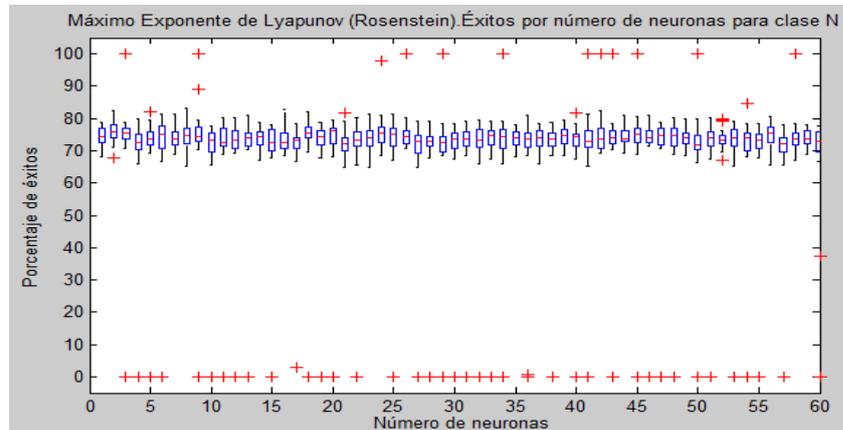


Figura 7. 22 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov (Rosenstein)

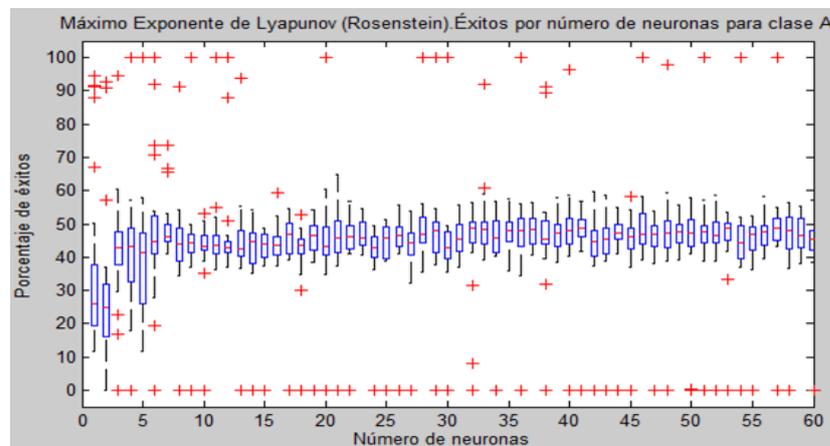


Figura 7. 23 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov (Rosenstein)

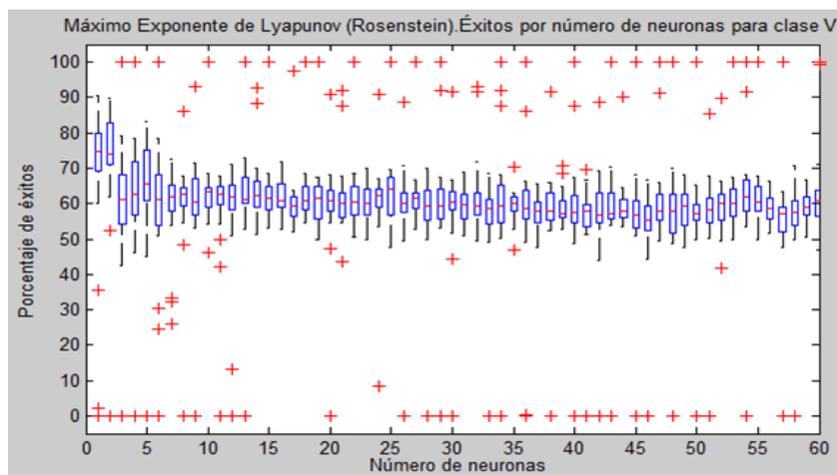


Figura 7. 24 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov (Rosenstein)

## 7.5. RESULTADOS DEL SISTEMA DE DETECCIÓN

Tras los resultados obtenidos en la clasificación, utilizando por un lado el conjunto de parámetros y, por otro, cada parámetro de manera independiente, se ha tomado como sistema de detección aquel que mejores resultados ha logrado. Por lo tanto, se utilizará como sistema de detección de cardiopatías el sistema formado por el conjunto de parámetros utilizando una clasificación balanceada. Es este sistema el que se analizará a continuación su comportamiento.

### 7.5.1. Resultados de las curvas ROC

Se presentan a continuación las curvas ROC obtenidas para cada clase. Además, en la Tabla 7.8 se muestra el área bajo la curva (AUC) de cada gráfica, obtenida para cada una de las clases

En las curvas ROC se ha remarcado con un círculo el punto dónde se encuentran las coordenadas de valores óptimos de sensibilidad y especificidad. Estos puntos óptimos de operación han sido estimados mediante la función *perfcurve* de Matlab, al igual que los valores de AUC de cada clase.

Se obtienen, en general, excelentes resultados para el sistema de clasificación.

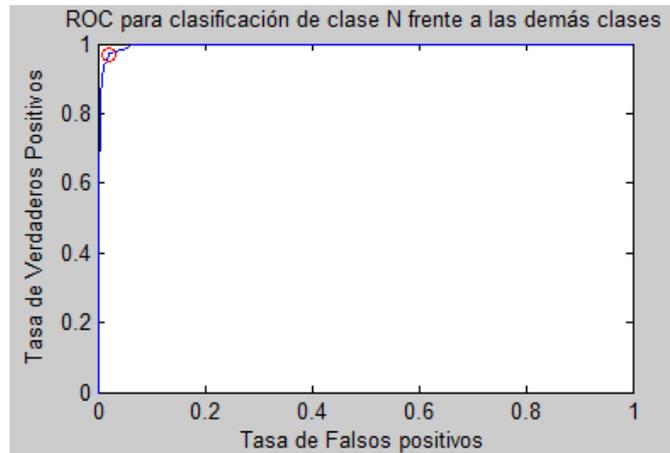


Figura 7. 25 : Representación ROC del sistema para clase N

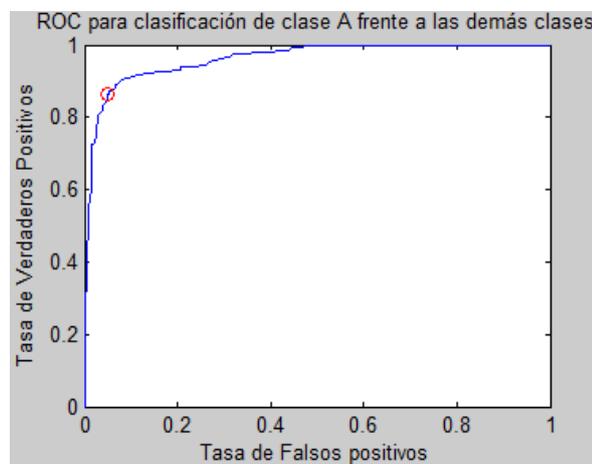


Figura 7. 26 : Representación ROC del sistema para clase A

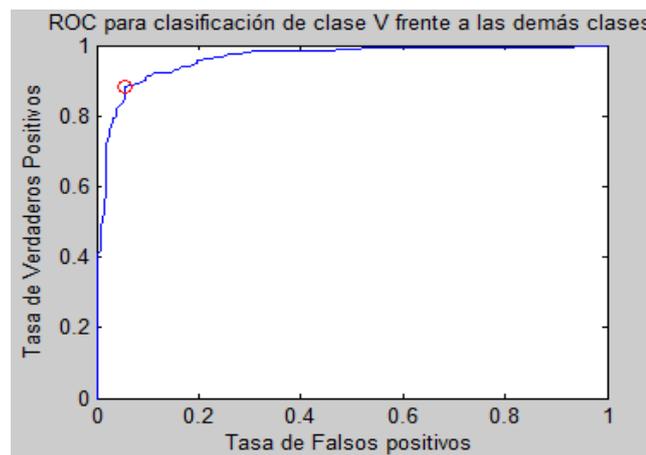


Figura 7. 27 : Representación ROC del sistema para clase V

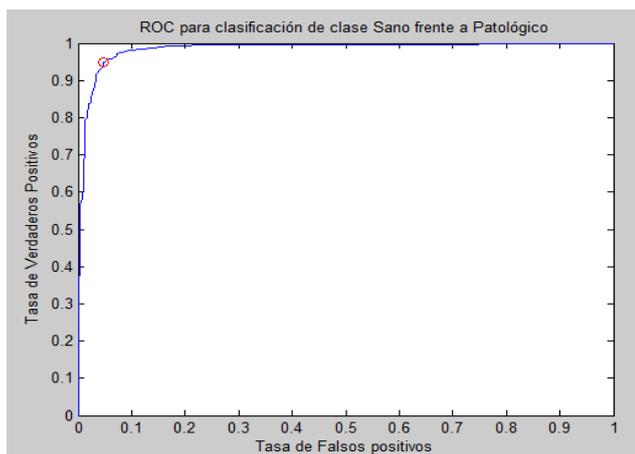


Figura 7. 28 : Representación ROC del sistema para clase Sano

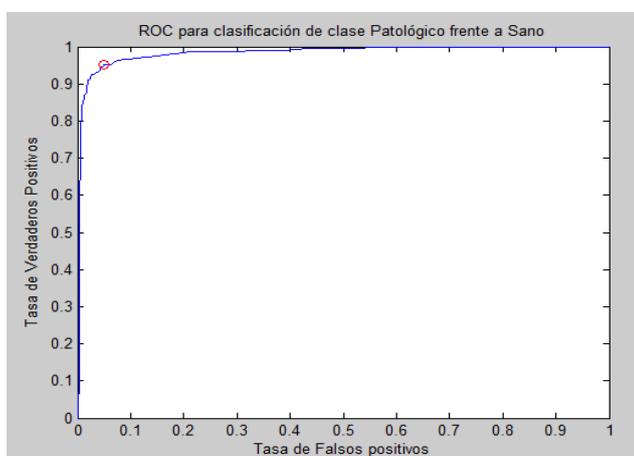


Figura 7. 29 : Representación ROC del sistema para clase Patológico

TABLA 7. 8: AUC DEL SISTEMA DE CLASIFICACIÓN, PARA CADA CLASE

Clase	N	A	V	Sano	Patológico
<b>AUC</b>	0,996	0,9621	0,9626	0,9835	0,9836
<b>Sensibilidad óptima</b>	0,9671	0,8660	0,8829	0,9498	0,9531
<b>Especificidad óptima</b>	0,9807	0,9431	0,9522	0,9517	0,9498
<b>Valoración del test</b>	Excelente	Excelente	Excelente	Excelente	Excelente

### 7.5.2. Resultados del sistema de detección a modo de verificación

En la Tabla 7.9 se muestran las medidas con las que se ha evaluado el clasificador por cada parámetro, siendo:

PPV: valor predictivo positivo

NPV: valor predictivo negativo

FPR: tasa de falsos positivos

FDR: tasa de falsos descubrimientos

TABLA 7. 9: RESULTADOS DEL SISTEMA DE DETECCIÓN A MODO DE VERIFICACIÓN

Clase	Exactitud	Especificidad	Sensibilidad
N	0,9807 $\pm$ 1,8592e-08	0,9734 $\pm$ 2,8789e-08	0,9624 $\pm$ 5,4782e-08
A	0,8829 $\pm$ 1,5906e-07	0,9408 $\pm$ 1,5796e-06	0,8634 $\pm$ 9,5869e-07
V	0,9522 $\pm$ 1,1385e-08	0,9402 $\pm$ 1,1706e-06	0,8804 $\pm$ 4,1087e-08
Sano	0,9517 $\pm$ 7,2916e-06	0,9462 $\pm$ 1,1140e-06	0,9498 $\pm$ 3,2666e-05
Pat.	0,9531 $\pm$ 7,2916e-06	0,9539 $\pm$ 3,2666e-05	0,9448 $\pm$ 1,1140e-06

Clase	PPV	NPV	FPR	FDR
N	0,9671 $\pm$ 3,6312e-07	0,9805 $\pm$ 1,2406e-06	0,0266 $\pm$ 2,8789e-08	0,0509 $\pm$ 3,6312e-07
A	0,8660 $\pm$ 1,0814e-06	0,9341 $\pm$ 4,5516e-06	0,0592 $\pm$ 1,5796e-06	0,1238 $\pm$ 1,1154e-06
V	0,9431 $\pm$ 1,1154e-06	0,9402 $\pm$ 4,4770e-06	0,0598 $\pm$ 1,1709e-06	0,1196 $\pm$ 1,0814e-06
Sano	0,9539 $\pm$ 1,7161e-05	0,9527 $\pm$ 4,0170e-05	0,0552 $\pm$ 1,1140e-06	0,0538 $\pm$ 1,7161e-06
Pat.	0,9498 $\pm$ 4,017e-05	0,9462 $\pm$ 1,7161e-05	0,0461 $\pm$ 3,2666e-05	0,0473 $\pm$ 4,0170e-05

En cuanto el estudio entre clases, es la clase N la que mejores resultados obtiene, clasificándose correctamente un 96,2% de las veces y excluyéndose correctamente un 97,34%. Además, la clase A obtiene en este sentido unos porcentajes de 86,3% y 94% respectivamente y, la clase V, de un 88% y 94%.

Por otra parte, los resultados indican que la probabilidad de que sea clase N tras haberse obtenido clase N en la clasificación es de un 96,7%. Esto es, que existe un 96,7% de los casos en el que el paciente, si es sano y ha sido diagnosticado por el test como sano, lo haya diagnosticado correctamente. Para pacientes con patologías de clase A y V se obtuvieron tasas de 86,6% y 94,3% respectivamente.



## Capítulo 8

# 8. CONCLUSIONES Y LÍNEAS FUTURAS

### 8.1. CONCLUSIONES

En el presente proyecto se ha conseguido la elaboración de un sistema capaz de detectar patologías cardíacas realizando dos tipos de clasificación. En primer lugar mediante un clasificador que discrimina entre diferentes patologías y latido normal y, en segundo lugar, a través de otro capaz de distinguir entre pacientes sanos y patológicos.

Para este sistema de clasificación, tras efectuarse un estudio previo de la duración óptima de trama y número de neuronas óptimo de la red neuronal, los resultados han sido satisfactorios para ambas clasificaciones. En el primer tipo de clasificación, se consigue detectar un 94,4% de pacientes con enfermedad tipo A y un 86,6% con enfermedad tipo V que realmente lo padecen (PPV). Asimismo, si el paciente sometido bajo test es realmente sano, el sistema lo detectará en un 96,7% de los casos. En el segundo tipo de clasificación, los porcentajes de éxito han sido mejores: si un paciente se somete bajo test al sistema, éste detectará en un 95,4% de los casos que realmente es un paciente sano y en un 95 % que tiene alguna patología.

Para conseguir estas tasas de éxito han sido necesarios diferentes estudios previos, como determinar el tamaño óptimo de las tramas extraídas de la señal ECG, la utilidad de los parámetros caóticos seleccionados para la clasificación de cardiopatías y el número de neuronas óptimo para configurar la red neuronal.

En el estudio del tamaño óptimo de trama se puede concluir que, a la hora de clasificar con parámetros no lineales señales de tipo ECG, se requiere de tamaños de trama elevados, puesto que con ellos se obtuvieron los mayores porcentajes de éxito en las simulaciones. Se utilizó un tamaño de trama de 20 segundos, siendo el máximo admitido en la base de datos creada.

En cuanto al estudio de la utilidad de los parámetros caóticos para la clasificación de cardiopatías se concluye que se obtienen mejores resultados en su utilización conjunta que

separadamente. Los mejores resultados de clasificación individual se logran con los parámetros Exponente de Hurst, Máximo Exponente de Lyapunov (con algoritmo Rosenstein) y con la Complejidad Lempel-Ziv. Sin embargo, las tasas de éxito obtenidas individualmente se han desestimado a la hora de realizar el sistema clasificador al no alcanzar resultados realmente aceptables para todas sus clases. En cambio, las tasas de éxito alcanzadas utilizando los 9 parámetros en su conjunto consiguen resultados de test valorados como muy buenos y excelentes.

En el estudio del número de neuronas óptimo se puede concluir que, en general, el número de neuronas que requiere el sistema para conseguir los resultados alcanzados en este estudio es más elevado que el que proponen los resultados hallados teóricamente. En el caso del estudio entre clases, la diferencia es más notoria y se encuentra en torno a las 50 neuronas. Para el caso de discriminación entre pacientes sanos y patológicos, pueden conseguirse resultados muy similares con tan sólo 11 neuronas. Aunque si bien es cierto que (para ambos casos) a partir de 10 neuronas no existe una diferencia muy significativa entre los porcentajes de éxito obtenidos, se ha escogido como número de neuronas óptimo aquel que mayores resultados de éxito arrojó en la práctica. Se decidió de tal manera puesto que la diferencia de cómputo entre 10 y 50 neuronas no resultó excesiva y se priorizó la obtención de resultados lo más fiable posible para la detección de las patologías.

Por último, se considera que se han cumplido los objetivos marcados para este proyecto puesto que, además de la implementación del sistema detector, en su elaboración se han adquirido los conocimientos necesarios acerca de los modelos no lineales, sus técnicas de procesado para las señales de ECG y del uso de los algoritmos de parametrización basados en la teoría del caos.

En definitiva, se aporta al campo de la Biomedicina un sistema de clasificación de patologías cardíacas usando modelos basados en dinámica no lineal. Se ha desarrollado un software que permitiría ayudar a resolver los problemas de subjetividad en el diagnóstico de cardiopatías y facilitar la labor del médico especialista, pudiéndose emplear en hospitales, bien para ayuda al diagnóstico de cardiopatías como sistema de clasificación automático o bien en la detección de otras patologías que dependen del ritmo cardíaco, como la apnea del sueño.

Además del sistema de detección aportado, se ha creado una base de datos de señales ECG compuesta por nueve clases, de las cuales ocho son patológicas y una de tipo normal

o de control, que puede utilizarse para continuar realizando estudios de este tipo. Esta base de datos se encuentra ya filtrada de las interferencias típicas de este tipo de señales y las señales están correspondientemente etiquetadas.

## 8.2. APORTACIONES

Durante el desarrollo de este proyecto se han conseguido las siguientes aportaciones:

- Sistema de clasificación de cardiopatías usando técnicas no lineales
  - Dos tipos de sistemas de clasificación: discriminador entre clases y discriminador entre pacientes sanos de patológicos
  - Análisis de viabilidad de nueve parámetros caóticos para clasificación de patologías cardíacas. Análisis individualizado y en su conjunto, mediante simulaciones
  - Estudio teórico y práctico del número óptimo de neuronas de la red neuronal, tanto para el conjunto de parámetros como para cada uno de ellos
  - Análisis de la configuración óptima del clasificador para parámetros no lineales extraídos de señales ECG
  - Estudio del tamaño óptimo de trama de entrada al clasificador mediante simulaciones
- Base de datos con ocho patologías cardíacas y una clase normal o de control, correctamente filtradas y etiquetadas
  - Algoritmos de conformación de la base de datos
  - Algoritmos de filtrado para señales ECG
- Medidas de complejidad extraídas de las señales ECG
  - Algoritmos de extracción de medidas de complejidad a partir de una serie, parametrizable a diferentes tamaños de trama y solapamiento

- Sistema de extracción de las medidas de complejidad mediante el acceso automatizado a una base de datos
- Análisis de no linealidad para series de ECG en función del tipo de patología (incertidumbre, complejidad, desorden, divergencia de trayectorias, ...)

### **8.3. LÍNEAS FUTURAS**

En la elaboración del sistema detector de cardiopatías se ha utilizado como sistema clasificador redes neuronales. Aunque por su componente no lineal son adecuadas para abordar series no lineales, se propone el uso de otros clasificadores con el objeto de evitar la etapa de entrenamiento del clasificador, que en ocasiones puede ser largo y consumir varias horas de CPU. Otro tipo de clasificador también evitaría definir una cantidad numerosa de parámetros como los presentados en el capítulo 6 (número de neuronas y de capas de la red, las funciones de transferencia, de entrenamiento, de aprendizaje,...) y evitaría además la realización de pruebas para obtener la mejor configuración posible. Se proponen las máquinas de vectores de soporte puesto que el entrenamiento es relativamente fácil y ya han sido utilizadas en el tratamiento de señales ECG con buenos resultados [60] o con sistemas de inferencia difusos o neuro difusos, ya que son más robustos y tienen mejores resultados frente a un mal etiquetado o ruido [44].

En base a los resultados conseguidos, los parámetros caóticos precisaron de tamaños de trama elevados. Se propone la ampliación de la base de datos de manera que pueda conseguirse tamaño de trama mayores y evaluar si con un tamaño de trama superior al utilizado se consigue mejoras en la clasificación. Además, esto aportaría más robustez y versatilidad al sistema.

A la hora de estudiar el tamaño de trama óptima en el simulador, los tamaños de tramas evaluados fueron estudiados con un tamaño de solape fijado previamente. Se propone el ensayo de diferentes tamaños de solape con el objetivo de poder hallar un tamaño óptimo de trama más baja que aporte resultados similares o superiores.

Como se había comentado, se había limitado el número de clases de la base de datos creada (nueve clases) a tan solo tres clases, puesto que de esta manera se conseguiría el número de elementos por clase suficiente para obtener los mejores resultados en el

clasificador. Una de las limitaciones se debió a la necesidad de un tamaño de trama grande. Es por ello que se propone conseguir un tamaño de trama de entrada al clasificador menor que el óptimo estimado y que aporte resultados similares o superiores a estos, tal que permita la utilización del resto de clases de la base de datos.

En cuanto a los parámetros no lineales seleccionados, se ha realizado su estudio de viabilidad como clasificador de dos formas, separadamente (simulándolos uno a uno) y simulando los 9 en su conjunto. Tras los resultados obtenidos, se propone el estudio de la viabilidad en la clasificación al conjunto de parámetros que obtuvo mejores resultados por separado (Exponente de Hurst, Máximo Exponente de Lyapunov y Complejidad Lempel-Ziv) o bien el estudio de nuevas medidas de complejidad.

Se han conseguido muy buenos resultados en la clasificación balanceada, no tanto así para la desbalanceada, en la que la clase A (Latido Atrial Prematuro) no alcanza resultados aceptables para la clasificación. Por ello, se propone ensayar un tipo de clasificación ramificada (en árbol) con el objeto de mejorar la tasa de acierto para esta clase. El procedimiento consistiría en que el clasificador discriminara, en primer lugar, entre señal de paciente sano y patológico y, en el caso de detectar patológico, realizase de nuevo la clasificación evaluando solamente las clases patológicas (A y V).



## Anexo I

### A1. GRÁFICAS Y TABLAS DEL ESTUDIO ESTADÍSTICO

Se muestran los resultados obtenidos de los estadísticos para los casos de paciente sano (N) y los casos patológicos ‘Latido Atrial Prematuro’ (A) y ‘Contracción Ventricular Prematura’ (V). Con ello se pretende valorar la no linealidad de los parámetros en función del tamaño de trama.

La estimación se ha realizado para los diferentes tamaños de trama en los que se ha estudiado la señal. Asimismo quedan representados en la gráfica sus valores de mediana y sus percentiles 25 y 75 del conjunto de datos.

#### A1.1 ENTROPÍA DE SHANNON

La clase V es la que presenta mayores valores de  $H$  para todas sus tramas y por tanto una mayor incertidumbre en las series de clase V, seguidas de las clases N y A.

La varianza es decreciente con el tamaño de trama para las tres clases. Por otra parte, la asimetría estadística es positiva para las clases N y A y negativa para la clase V.

Para las tres clases, la curtosis decrece, en general, a medida que aumenta el tamaño de trama. Para las clases patológicas A y V, los valores de curtosis no sobrepasan el valor umbral 3 para las tramas de mayor tamaño (concretamente para tramas mayores a 8 segundos). En cambio, la clase N se mantiene en todos los casos por encima el umbral. Tan sólo para tramas de 4 segundos, las tres clases superan conjuntamente este valor. Se observa además que existe una mayor dispersión y presencia de atípicos en los resultados obtenidos para clase N que para los que se obtuvieron para las clases A y V. Para estas dos clases, sus elementos se encuentran más concentrados y la presencia de atípicos es muy baja.

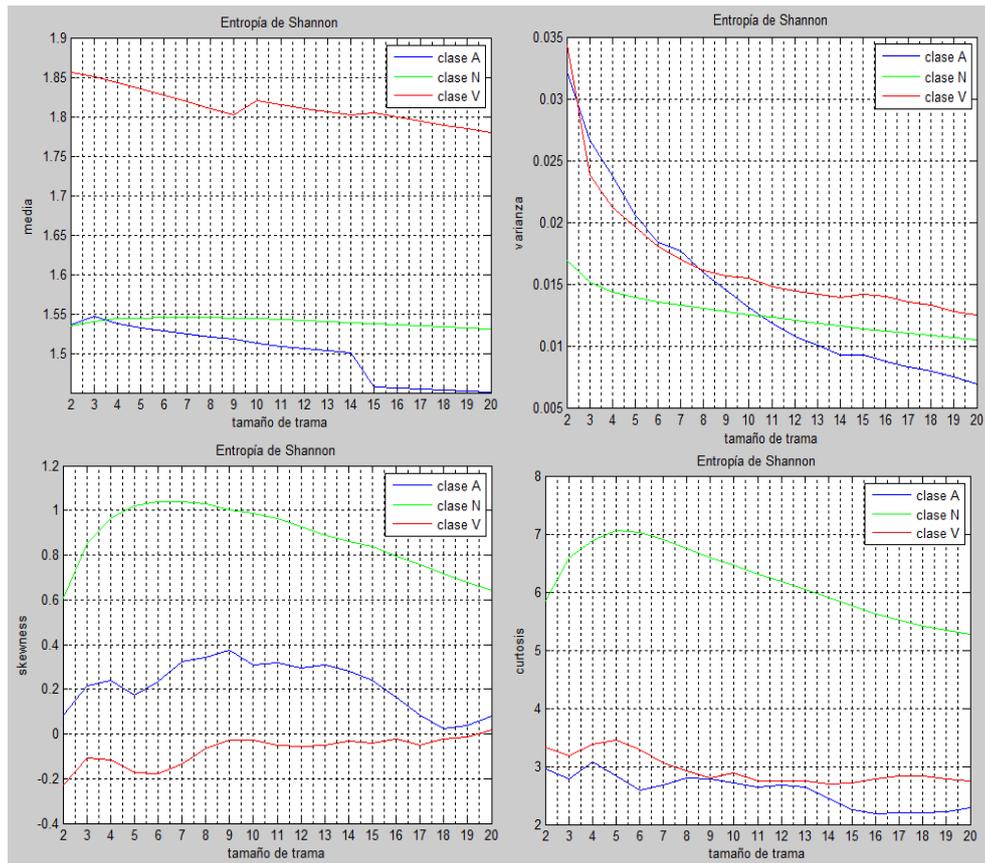


Figura AI. 1 Estadísticos obtenidos para Entropía de Shannon, para tramas de 2 a 20 s

TABLA AI. 1 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA ENTROPÍA DE SHANNON

Clase	Media [max - min]	Varianza [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[1,55 - 1,52]	[0,017 - 0,010]	[1,1 - 0,6]	[7,1 - 5,2]
Clase A	[1,52 - 1,45]	[0,033 - 0,007]	[0,4 - 0,1]	[ 3,1 - 2,1]
Clase V	[1,85 - 1,78]	[0,034 - 0,013]	[0,1 - (-0,2)]	[3,2 - 2,9]

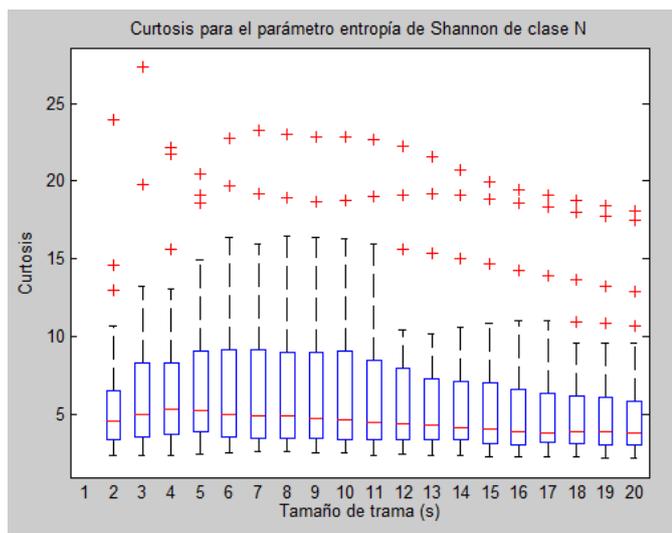


Figura AI. 2 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Entropía de Shannon de clase normal (N)

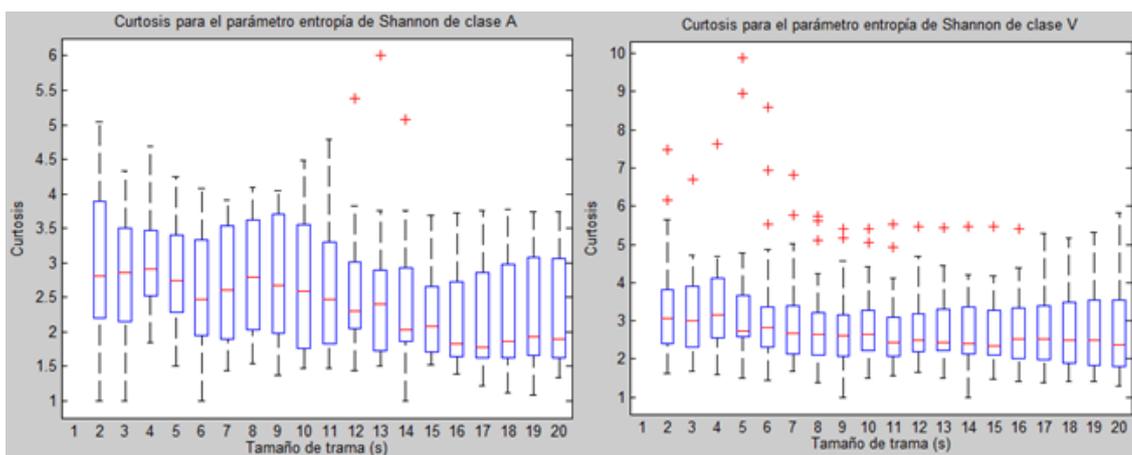


Figura AI. 3 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Entropía de Shannon en pacientes patológicos, clases A y V

### A1.2 MÁXIMO EXPONENTE DE LYAPUNOV CON ALGORITMO DE ROSESTEIN

Las tres clases presentan valores de  $\lambda$  positivos, lo que indica divergencia de trayectorias en el espacio de fase y, por tanto, dinámica caótica. Las clases N y A obtienen resultados muy similares y mayores a la clase V.

La varianza es decreciente para las tres clases con el tamaño de trama y la asimetría estadística es positiva siempre.

Para este parámetro se obtienen valores de curtosis mayores al umbral en todos de los tamaños de tramas y para las tres clases, aunque decreciente con el tamaño de trama. Los valores más altos se obtienen para clase N. Existe un alto grado de dispersión en las tres clases y la presencia de atípicos es frecuente, sobre todo en las clases N y V.

TABLA AI. 2 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA MÁXIMO EXPONENTE DE LYAPUNOV CON ALGORITMO DE ROSESTEIN

Clase	Media [max - min]	Varianza [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[0,26 - 0,20]	[0,011 - 0,001]	[2,1 - 0,8]	[12,2 - 5,8]
Clase A	[0,21 - 0,20]	[0,004 - 0,001]	[1,2 - 0,2]	[6 - 3,2]
Clase V	[0,16 - 0,11]	[0,009 - 0,001]	[1,8 - 1,1]	[8,8 - 5,4]

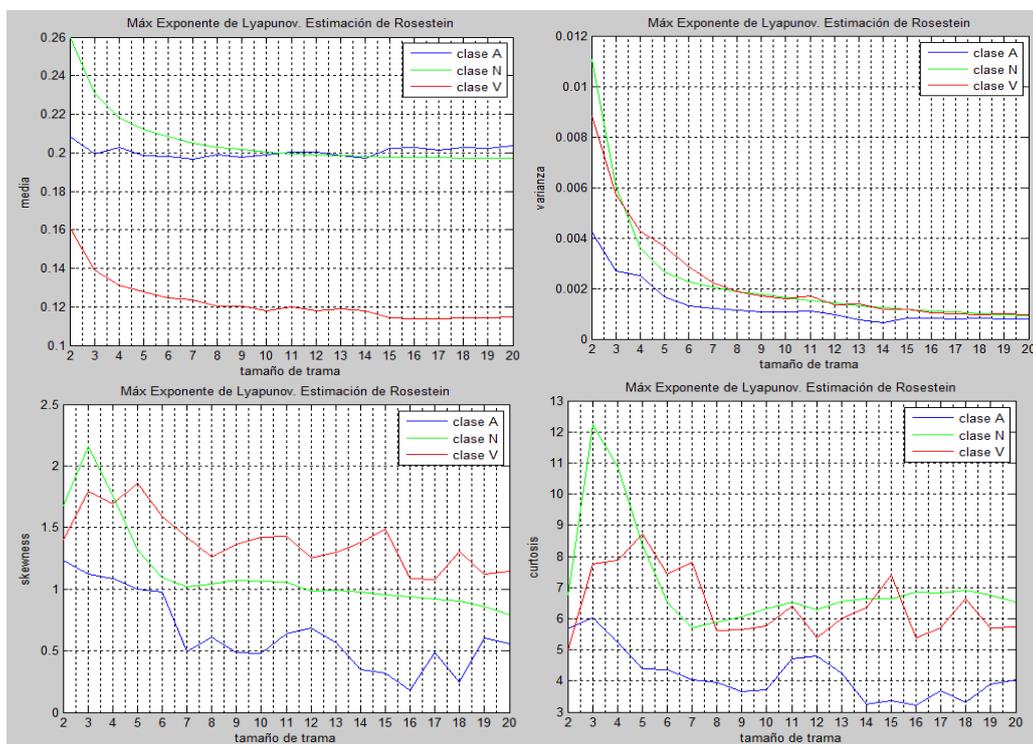


Figura AI. 4 : Estadísticos obtenidos para Máximo Exponente de Lyapunov (estimado con algoritmo de Rosenstein), para tramas de 2 a 20 s

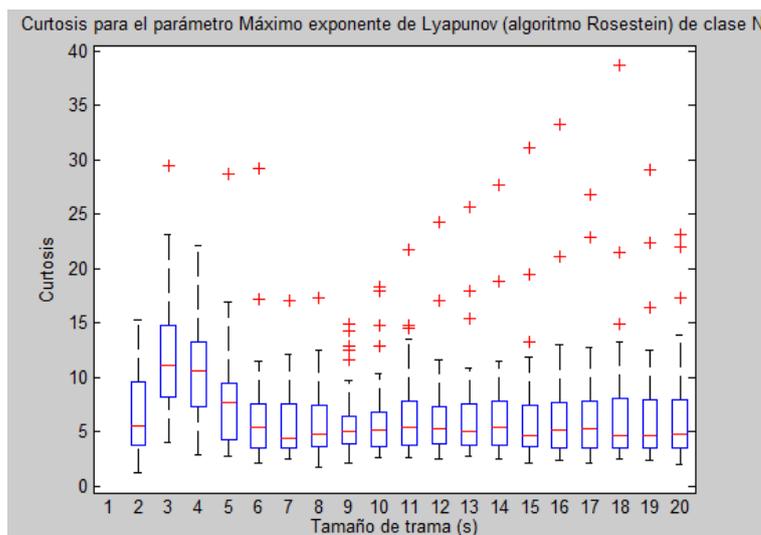


Figura AI. 5 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con Rosenstein, de clase normal (N).

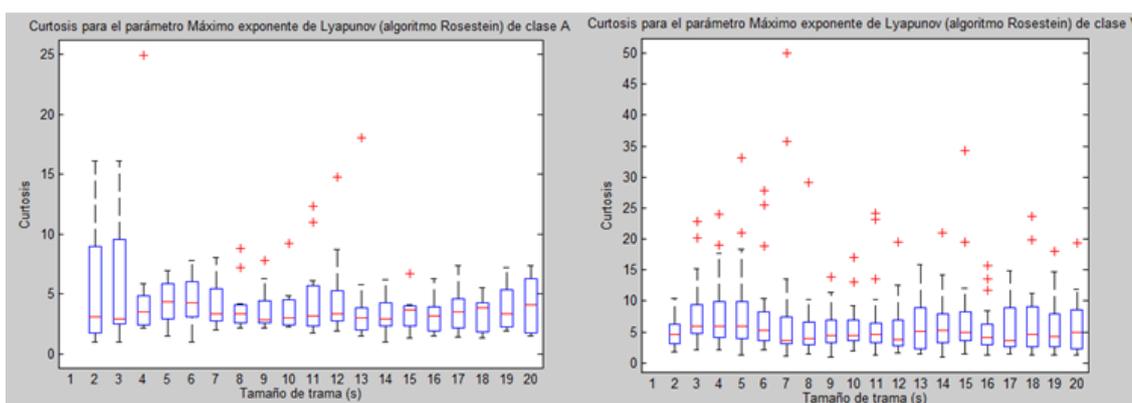


Figura AI. 6 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con algoritmo Rosenstein, en pacientes patológicos (clases A y V)

### A1.3 MÁXIMO EXPONENTE DE LYAPUNOV, CON ALGORITMO DE KANTZ

Al igual que para el algoritmo de Rosenstein, las tres clases presentan  $\lambda$  positivos, pero los resultados de éste son ligeramente mayores. La varianza es decreciente, para las tres clases, con el tamaño de trama y también la asimetría estadística es positiva siempre.

Existe un crecimiento de la curtosis a medida que aumenta el tamaño de trama. Sólo la clase A se mantiene por debajo del umbral para tamaños de trama inferiores a 8 segundos, siendo esta clase también la que representa una variación entre los valores de curtosis más

irregular. Los resultados usando el algoritmo de Kantz son mucho más concentrados, con una presencia de atípicos baja para los casos patológicos (y algo mayor para paciente sano), en comparación a los resultados extraídos con el algoritmo Rosenstein. Sin embargo, los valores de curtosis para el algoritmo Rosenstein son mayores en general.

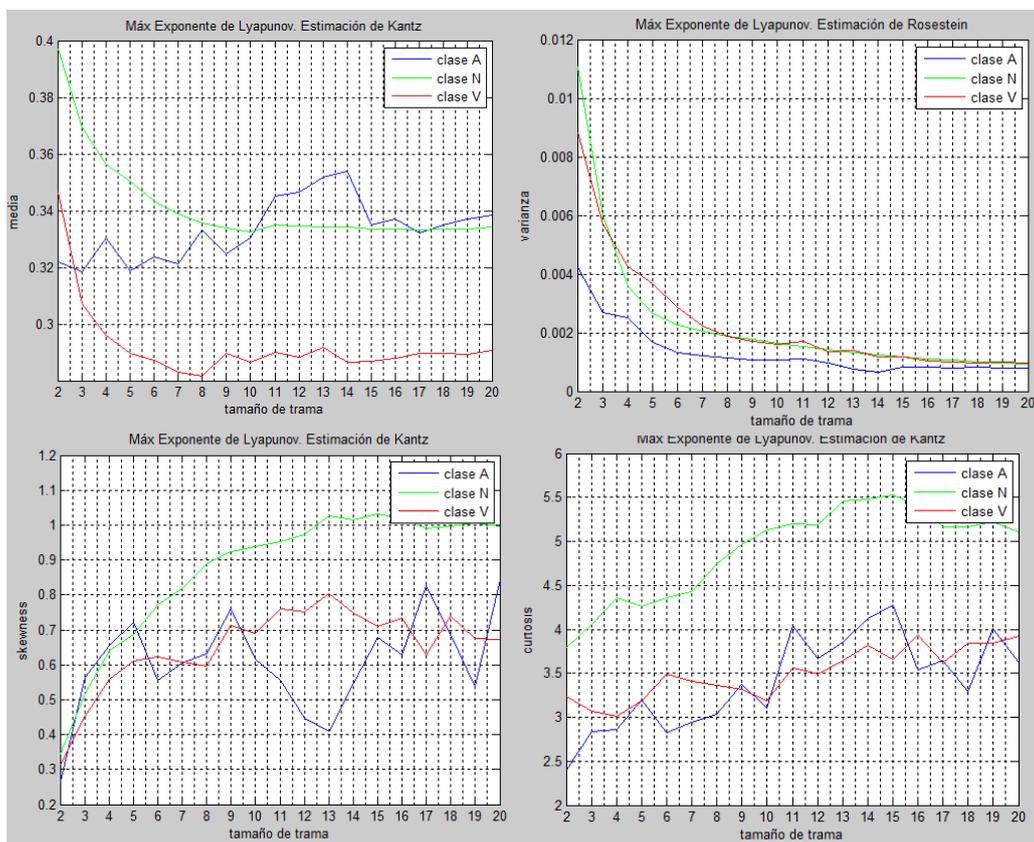


Figura AI. 7 : Estadísticos obtenidos para Máximo Exponente de Lyapunov (estimado con algoritmo de Kantz), para tramas de 2 a 20 s

TABLA AI. 3 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA MÁXIMO EXPONENTE DE LYAPUNOV CON ALGORITMO DE KANTZ

Clase	Media [max - min]	Varianza [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[0,40 - 0,33]	[0,011 - 0,001]	[1,00- 0,35]	[5,2 - 3,7]
Clase A	[0,35 - 0,32]	[0,004 - 0,001]	[0,8 - 0,29]	[4,3 - 2,5]
Clase V	[0,34 - 0,28]	[0,009 - 0,001]	[0,82 - 0,31]	[3,9 - 3,2]

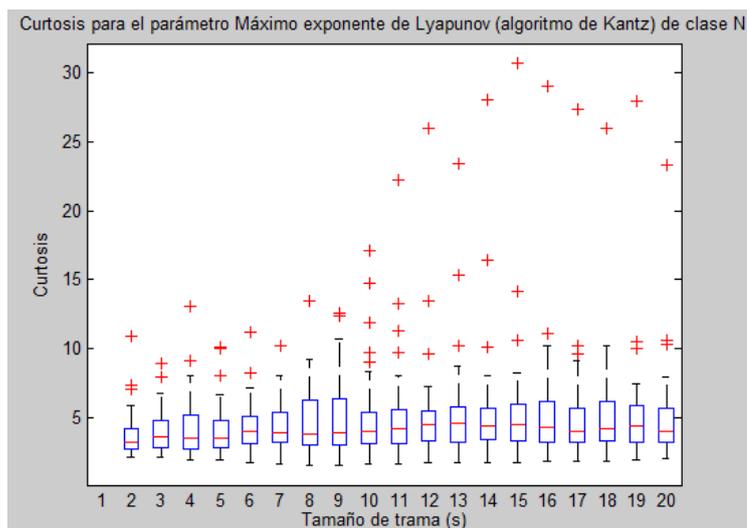


Figura AI. 8 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con Kantz, de clase normal (N)

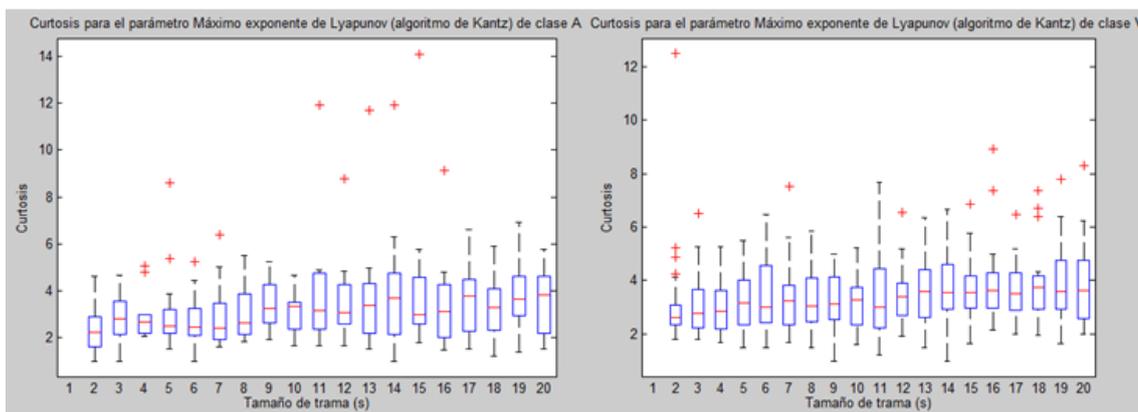


Figura AI. 9 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para máximo exponente de Lyapunov, estimado con algoritmo Kantz, en pacientes patológicos (clases A y V)

#### A1.4 DIMENSIÓN DE CORRELACIÓN

Las clases N y A obtienen mayor valor  $D_3$  con respecto a la clase V y por tanto presentan mayor complejidad.

La varianza es decreciente, para las tres clases, con el tamaño de trama. La asimetría estadística es positiva y decreciente para las tres clases, llegando a ser negativa en la clase A para valores de trama mayores a 12 segundos.

Los valores de curtosis disminuyen con el aumento del tamaño de trama aunque las tres clases superan el umbral 3 en la mayor parte de los casos. La clase V obtiene valores inferiores al umbral, aunque muy próximos, para tamaños de trama mayores a 14 segundos. Los valores de curtosis se encuentran muy concentrados, sobre todo para tamaños de trama grandes. Por otra parte, la presencia de atípicos es muy baja.

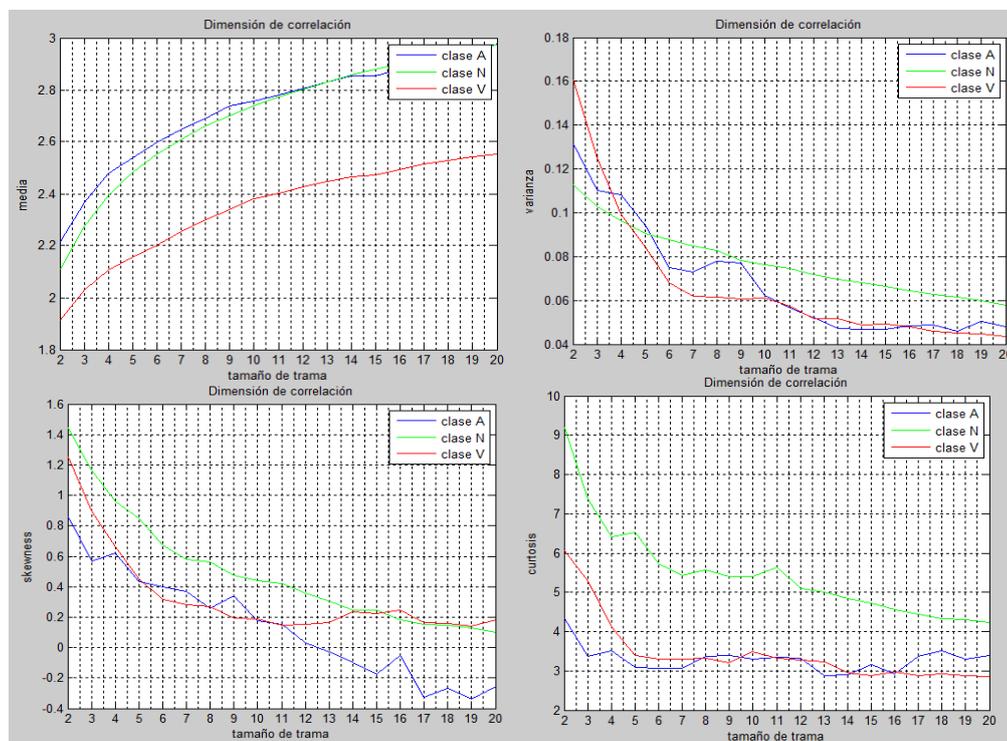


Figura AI. 10 : Estadísticos obtenidos para Dimensión de Correlación, para tramas de 2 a 20 s

TABLA AI. 4 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA DIMENSIÓN DE CORRELACIÓN

Clase	Media [max - min]	Varianza [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[2,99 - 2,10]	[0,11 - 0,06]	[1,4 - 0,1]	[9,1 - 4,2]
Clase A	[2,99 - 2,21]	[0,13 - 0,05]	[0,8 - (-0,3)]	[4,2 - 2,9]
Clase V	[2,55 - 1,90]	[0,16 - 0,05]	[1,2 - 0,2]	[6 - 2,9]

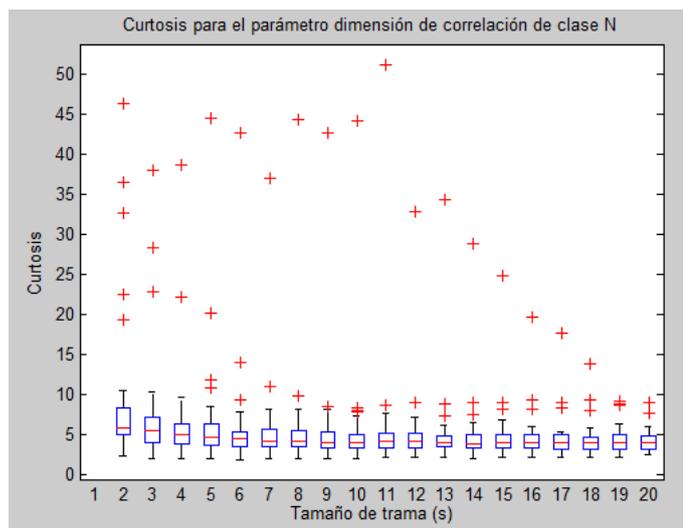


Figura AI. 11 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Dimensión de correlación, de clase normal (N).

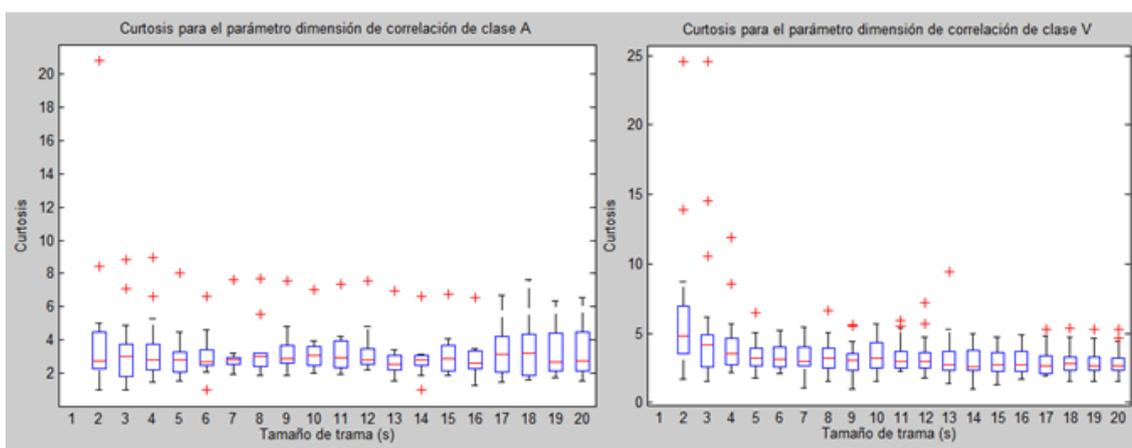


Figura AI. 12 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro Dimensión de correlación, en pacientes patológicos (clases A y V)

### A1.5 ENTROPÍA DE CORRELACIÓN

Los mayores valores de entropía de correlación, y por tanto de desorden, se tienen para clase V, seguidos de las clases N y A.

La varianza es decreciente, para las tres clases y, la asimetría estadística, positiva. Para la mayoría de los tamaños de trama, las tres clases consiguen una curtosis mayor que 3. La clase N se mantiene mayor que 3 y regular en todos los casos. La clases patológicas A y V obtienen valores muy irregulares, pero superiores al umbral en general. La excepción está

en las tramas de tamaños 14 y 17 segundos para clase A, y para la clase V, para tamaños de trama menores a 9 segundos.

Por otra parte, de entre todos los parámetros estudiados, éste es el que obtiene los valores de curtosis más concentrados para cualquier tamaño de trama, pero también es el que ofrece mayor diferencia entre valores de curtosis cercano.

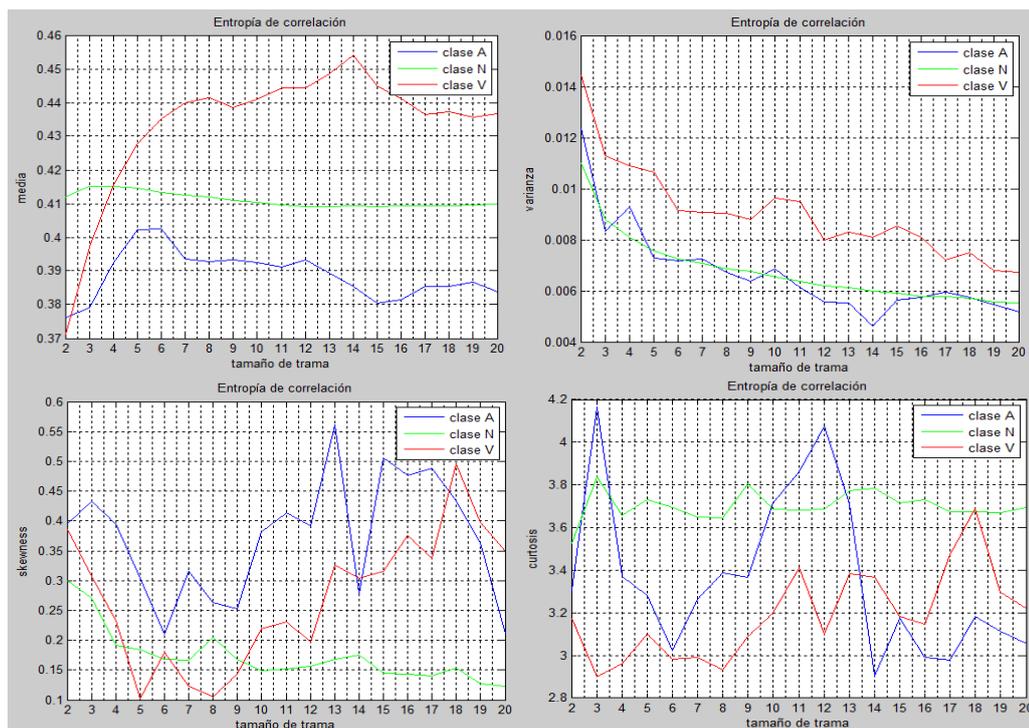


Figura AI. 13 : Estadísticos obtenidos para Entropía de correlación para tramas de 2 a 20 s

TABLA AI. 5 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA ENTROPÍA DE CORRELACIÓN

Clase	Media [max - min]	Varianza [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[0,411-0,410]	[0,011 – 0,006]	[0,30 – 0,12]	[3,8 - 3,5]
Clase A	[0,385 - 0,375]	[0,012 – 0,005]	[0,40 – 0,21]	[4,2 – 2,9]
Clase V	[0,455 - 0,371]	[0,014 – 0,007]	[0,39 – 0,10]	[3,7 - 2,9]

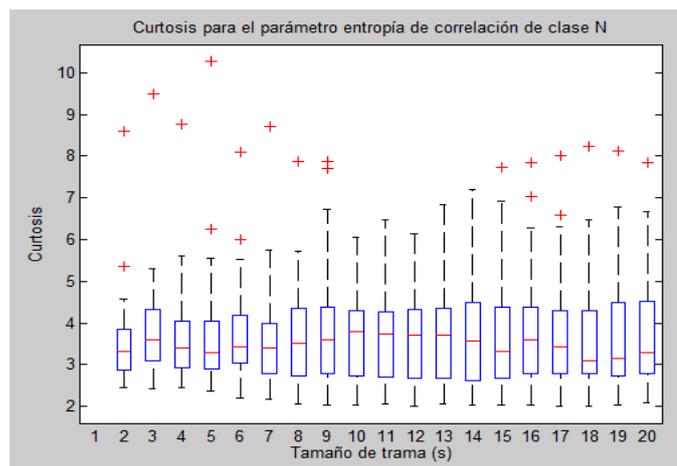


Figura AI. 14 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos

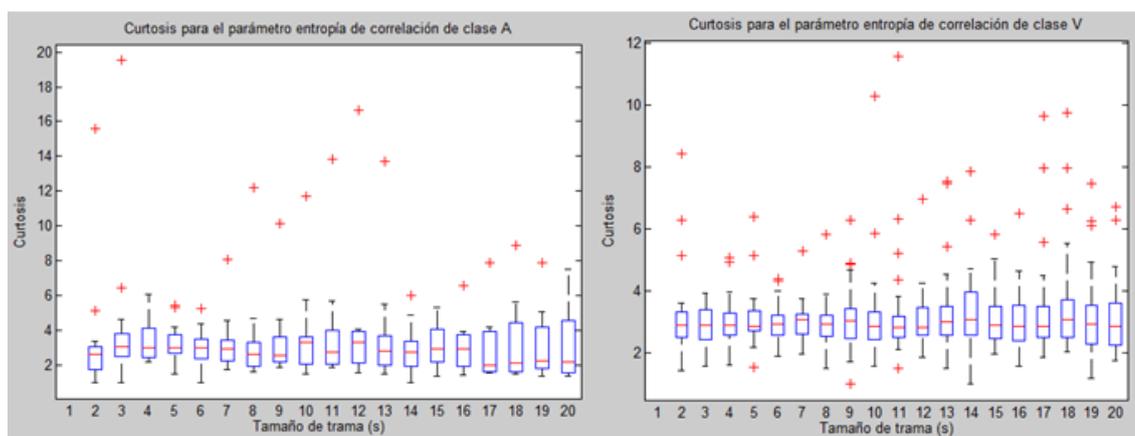


Figura AI. 15 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro entropía de correlación, en pacientes patológicos (clases A y V)

### A1.6 COMPLEJIDAD LEMPEL-ZIV

Los valores LZC se muestran decrecientes con el tamaño de trama, así pues son las tramas de menor tamaño las que poseen mayor complejidad. Los valores más altos se obtienen para la clase A, seguido de la N, y por último la clase V, pero muy próximos entre ellos.

La varianza es decreciente para las tres clases. La asimetría estadística siempre es positiva, a excepción de la clase A para tramas mayores a 4 segundos.

Se observa que, en general, para tamaños de trama crecientes, los valores de curtosis van en decremento. Así, las clases A y V llegan a valores de curtosis inferiores al umbral cuando los tamaños de trama superan los 8 segundos. Los resultados indican que para clase N la serie tiene una alta dispersión, incluso para los tamaños de trama mayores. Además,

en esta clase, se encuentra presencia de atípicos en todos los tamaños de tramas. En los casos de señal patológica, los valores de curtosis se encuentran más concentrados y la presencia de atípicos es mucho menor.

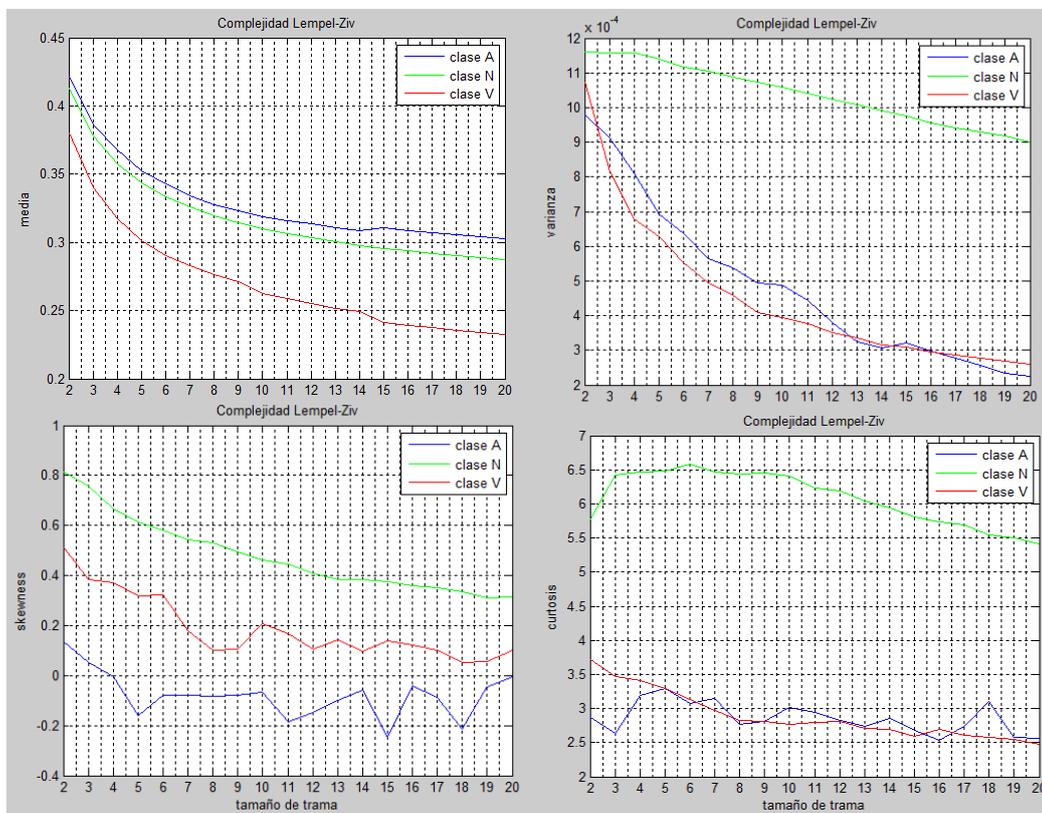


Figura AI. 16 : Estadísticos obtenidos para Complejidad Lempel-Ziv, para tramas de 2 a 20 s

TABLA AI. 6 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA COMPLEJIDAD LEMPEL-ZIV

Clase	Media [max - min]	Varianza ( $10^{-4}$ ) [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[0,41 - 0,29]	[11,5 - 9,0]	[0,8 - 0,3]	[6,6 - 5,7]
Clase A	[0,42 - 0,30]	[9,8 - 2,2]	[0,5 - 0,1]	[3,4 - 2,5]
Clase V	[0,38 - 0,24]	[10,5 - 2,5]	[0,1 - (-0,3)]	[3,7 - 2,5]

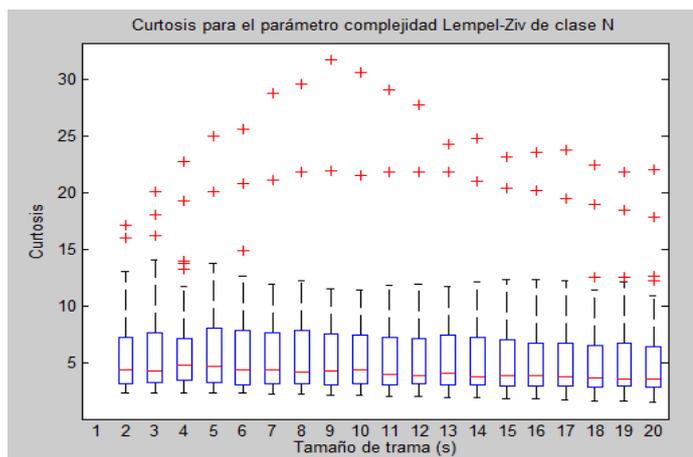


Figura AI. 17 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro complejidad Lempel-Ziv, de clase normal (N).

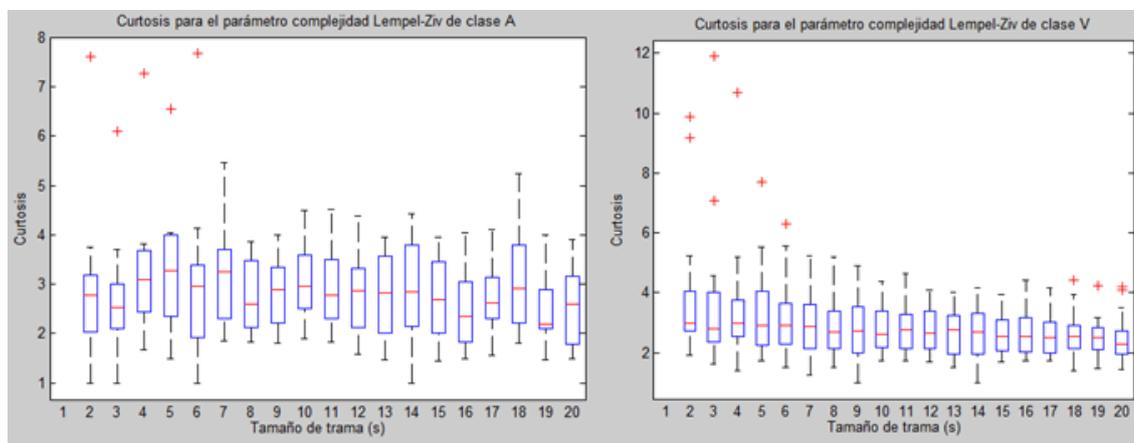


Figura AI. 18 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro complejidad Lempel-Ziv, en pacientes patológicos (clases A y V)

### A1.7 EXPONENTE DE HURST CON ALGORITMO DE VARIANZA AGREGADA

Los valores obtenidos para las tres clases son mayores a 0,5 y decrecientes con el tamaño de trama, por lo que presentan un comportamiento persistente. Los valores más altos se obtienen para la clase V, seguidas de las clases N y A de valores muy aproximados.

A diferencia del resto de parámetros, la varianza aumenta con el tamaño de trama, pero los valores que alcanza son muy bajos. La asimetría estadística es positiva para las clases N y A pero negativa para la clase V.

Para las clases patológicas A y V, los valores de curtosis se mantienen casi constantes (decrecen ligeramente) para todos los tamaño de trama evaluados. En cambio, para la clase N, empieza a decrecer a partir de tamaños de trama de 9 segundos, aunque se mantiene por encima del umbral para todos los tamaños de trama. La clase V también supera el umbral en todos los casos. La clase A, en cambio, no alcanza el umbral para valores mayores a 11 segundos. Para clase N la serie tiene una alta dispersión, sobre todo para los tamaños de trama mayores. Además, en esta clase, se encuentra presencia de atípicos en todos los tamaños de tramas. En los casos de señal patológica, los valores de curtosis se encuentran más concentrados y la presencia de atípicos es mucho menor.

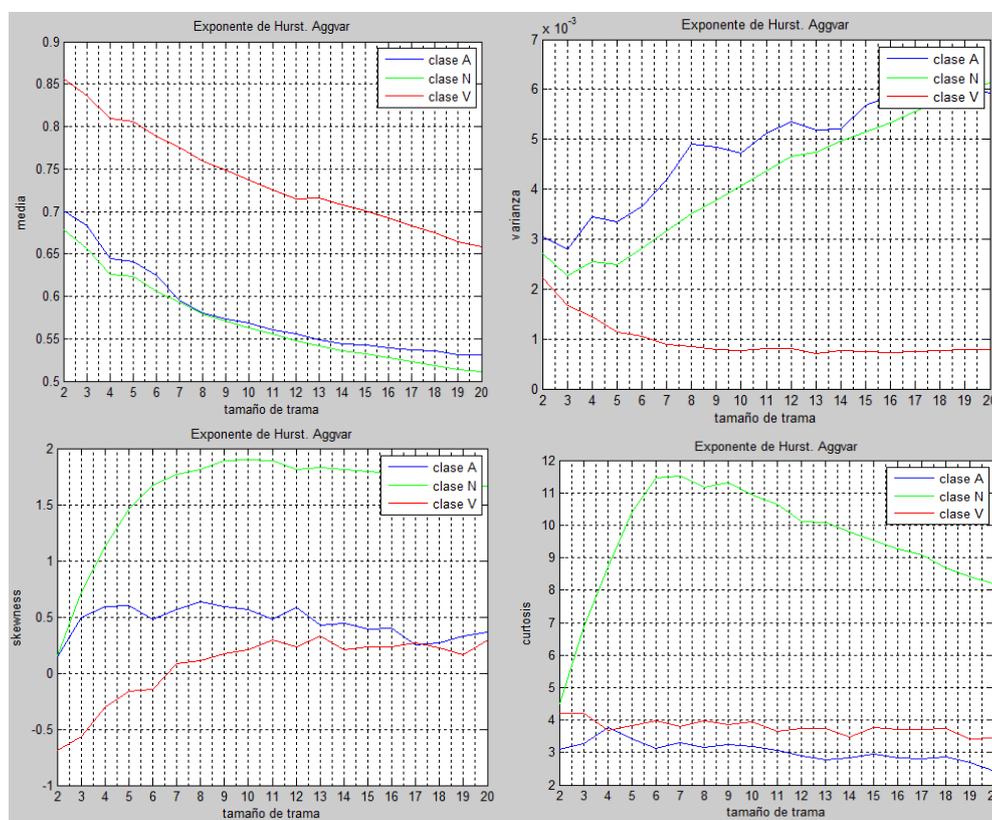


Figura AI. 19 : Estadísticos obtenidos para Exponente de Hurst, con algoritmo de Varianza Agregada, para tramas de 2 a 20 s

TABLA AI. 7 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA EXPONENTE DE HURST, CON ALGORITMO DE VARIANZA AGREGADA

Clase	Media [max - min]	Varianza ( $10^{-3}$ ) [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[0,67 - 0,51]	[6,0 - 2,2]	[1,6 - 0,2]	[11,5 - 4,5]
Clase A	[0,70 - 0,54]	[6,1 - 2,9]	[0,6 - 0,2]	[3,8 - 2,5]
Clase V	[0,85 - 0,66]	[6,1 - 2,1]	[0,4 - (-0,8)]	[4,2 - 3,5]

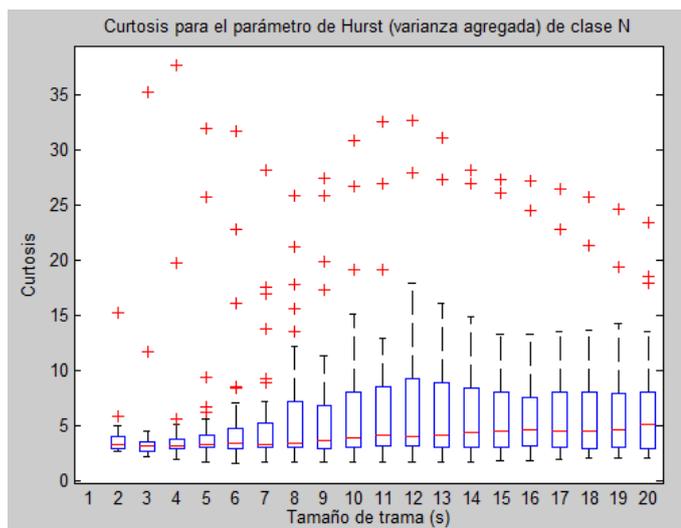


Figura AI. 20 : Valores de curtosis obtenidos en tramas de 2 a 20 segundos, para el parámetro de Hurst con algoritmo de varianza agregada, de clase normal (N)

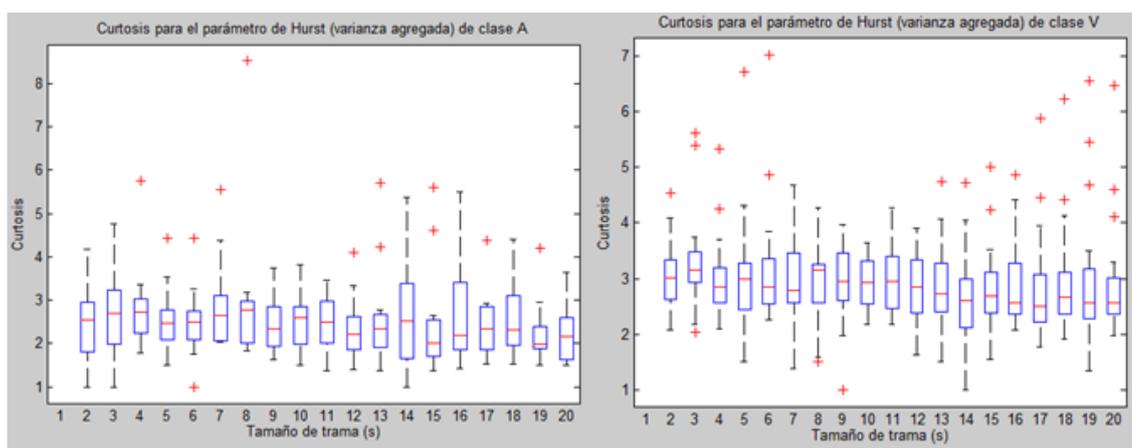


Figura AI. 21 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo de varianza agregada, en pacientes patológicos (clases A y V)

### A1.8 EXPONENTE HURST CON ALGORITMO DE MOMENTO ABSOLUTO

Al igual que para el algoritmo anterior, los valores obtenidos para las tres clases son mayores a 0,5 y decrecientes con el tamaño de trama, por lo que presentan una comportamiento persistente. También, los valores más altos se obtienen para la clase V, seguidas de las clases N y A de valores muy aproximados.

La varianza tiene en este caso un comportamiento creciente para las clases N y A y decreciente para V, con el tamaño de trama. La asimetría estadística es negativa para clase V, y positiva para las clases N y A.

Los valores de curtosis para patologías decrecen con el aumento del tamaño de trama. Las clases N y V se mantienen por encima del umbral para casi todos los tamaños de trama. La clase A, en cambio, no alcanza el umbral para valores mayores a 9 segundos. Por otra parte, para clase N la serie tiene una alta dispersión, sobre todo para los tamaños de trama mayores. Además, en esta clase, se encuentra presencia de atípicos en todos los tamaños de tramas. En los casos de señal patológica, los valores de curtosis se encuentran mucho más concentrados y la presencia de atípicos es mucho menor.

*TABLA AI. 8 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA EXPONENTE DE HURST, CON ALGORITMO DE MOMENTO ABSOLUTO*

<b>Clase</b>	<b>Media [max - min]</b>	<b>Varianza (<math>10^{-3}</math>) [max - min]</b>	<b>Skewness [max - min]</b>	<b>Curtosis [max - min]</b>
Clase N	[0,84 - 0,65]	[3,3 - 1,4]	[1,1 - (-0,3)]	[6,5 - 3,5]
Clase A	[0,85 - 0,67]	[2,6 - 1,4]	[0,4 - (-0,2)]	[3,5 - 2,4]
Clase V	[0,90 - 0,75]	[1,2 - 0,5]	[0,01 - (-0,7)]	[3,8 - 2,9]

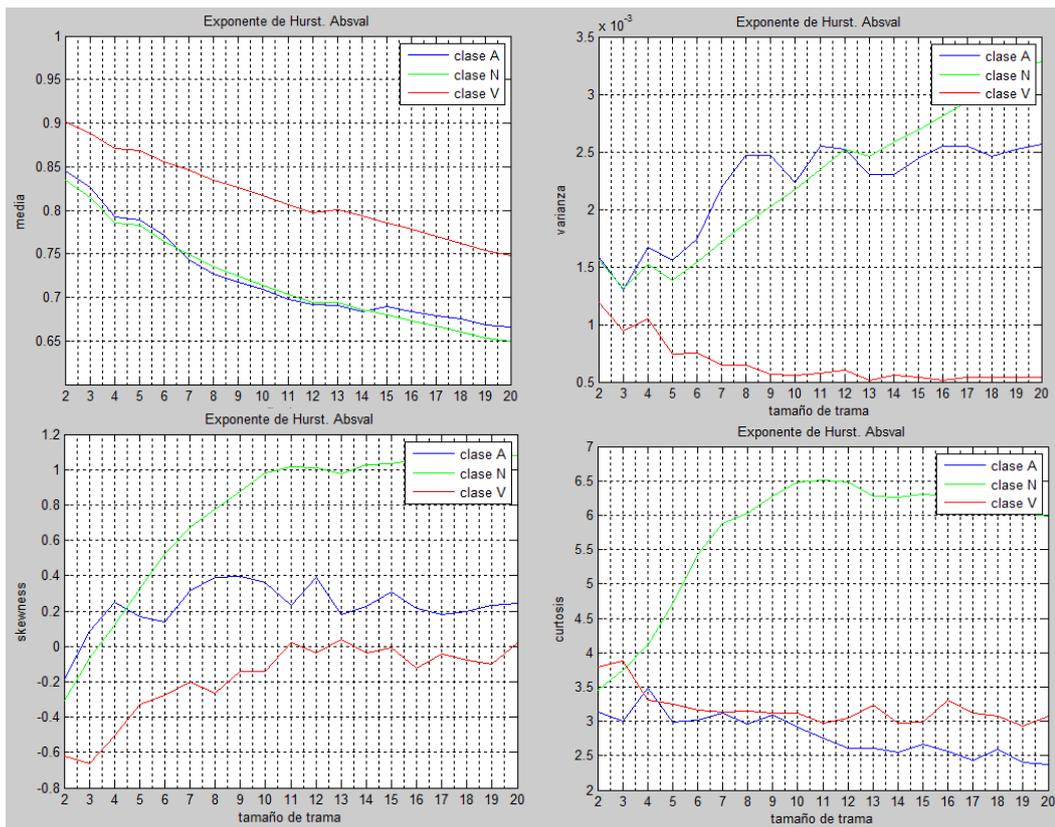


Figura AI. 22 : Estadísticos obtenidos para Exponente de Hurst, con algoritmo de Momento Absoluto, para tramas de 2 a 20 s

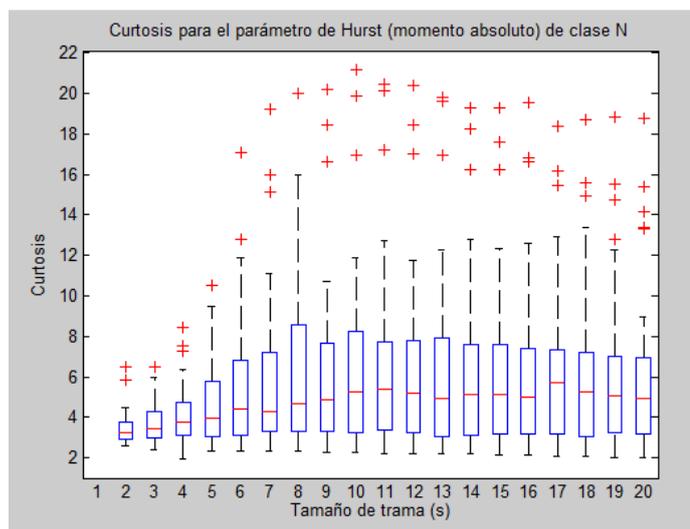


Figura AI. 23 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo de momento absoluto, de clase normal (N).

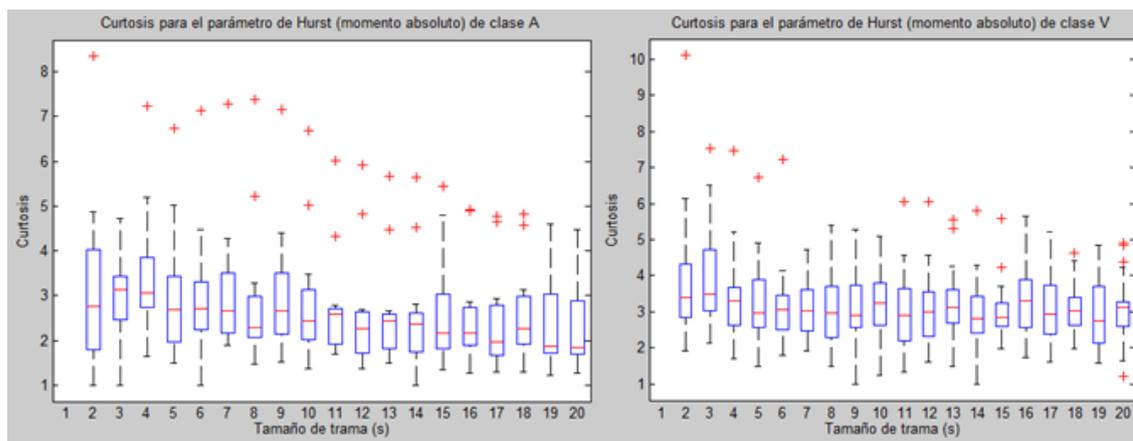


Figura A1. 24 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo de momento absoluto, en pacientes patológicos (clases A y V)

### A1.9 EXPONENTE HURST CON ALGORITMO DE R/S

Las clases N y A alcanzan, con este algoritmo, valores de H menores a 0,5 para los tamaños de trama mayores y, por tanto, son regidos por procesos antipersistentes.

La varianza es creciente, pero de valores muy pequeños. La asimetría estadística es positiva para las clases N y A a partir de tramas de 4 segundos y la clase V a partir de 12 segundos.

Las clases patológicas A y V no superan el umbral para la mayoría de los tamaños de trama, sobre todo para los tamaños de trama mayores. A partir de 7 segundos, para el caso de señal patológica, la curtosis no supera el umbral.

De los tres algoritmos presentados para la estimación del parámetro de Hurst, es éste el que presenta una mayor dispersión, muy alta para clase N, manteniéndose incluso para los tamaños de trama mayores. También, en esta clase se encuentra presencia de atípicos en todos los tamaños de tramas. En los casos de señal patológica, los valores de curtosis se encuentran mucho más concentrados y la presencia de atípicos es mucho menor para clase A, no así para clase V.

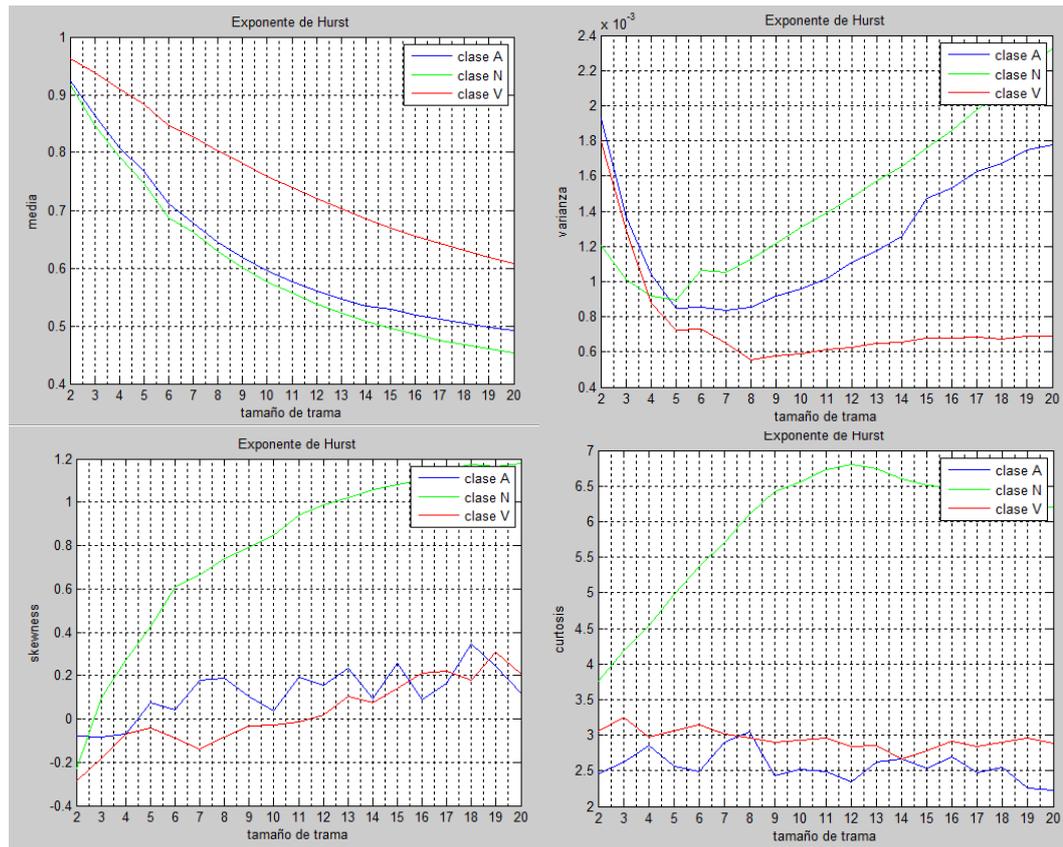


Figura A1. 25 : Estadísticos obtenidos para Exponente de Hurst, con algoritmo de R/S, para tramas de 2 a 20 s

TABLA A1. 9 : VALORES MÁXIMO Y MÍNIMO DE CADA ESTADÍSTICO POR CLASE, PARA EXPONENTE DE HURST, CON ALGORITMO DE R/S

Clase	Media [max - min]	Varianza ( $10^{-3}$ ) [max - min]	Skewness [max - min]	Curtosis [max - min]
Clase N	[0,91 - 0,46]	[2,3 - 0,9]	[1,2 - (-0,2)]	[6,8 - 3,7]
Clase A	[0,92 - 0,49]	[1,9 - 0,9]	[0,3 - (-0,1)]	[3,3 - 2,6]
Clase V	[0,95 - 0,61]	[1,8 - 0,5]	[0,3 - (-0,3)]	[3,1 - 2,3]

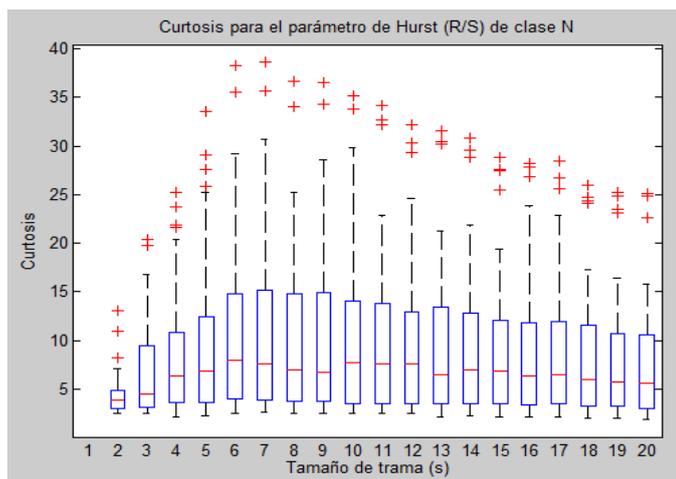


Figura AI. 26 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo R/S, de clase normal (N).

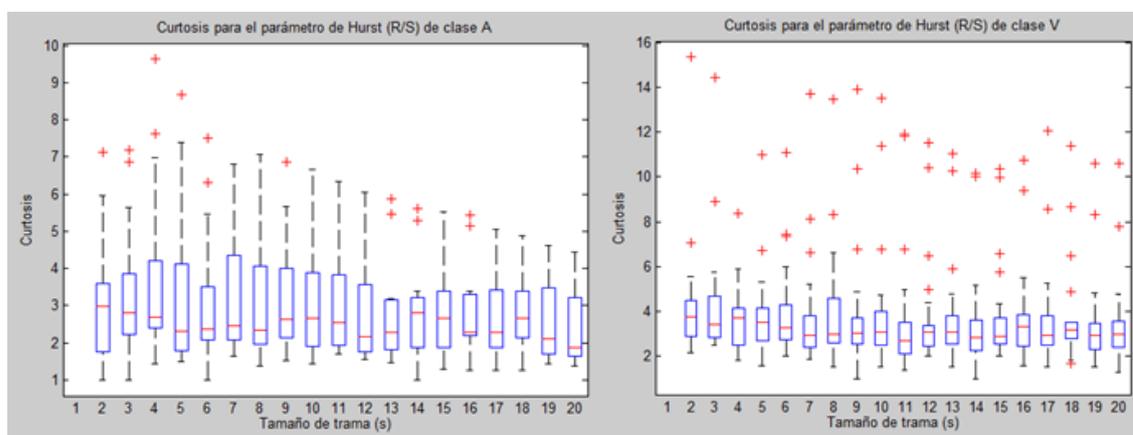


Figura AI. 27 : Valores de curtosis obtenidos en tramas de 2 hasta 20 segundos, para el parámetro de Hurst con algoritmo R/S, en pacientes patológicos (clases A y V)

## Anexo II

### A2. GRÁFICAS Y TABLAS COMPLEMENTARIAS DE LAS SIMULACIONES

#### A2.1 ESTUDIO DEL TAMAÑO DE TRAMA ÓPTIMO Y DE NÚMERO DE NEURONAS ÓPTIMO

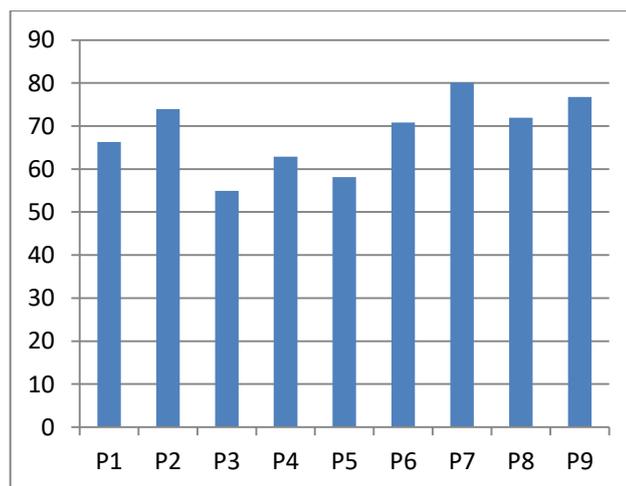
TABLA AII. 1: ÉXITOS OBTENIDOS Y NÚMERO DE NEURONAS EN EL ESTUDIO ENTRE CLASES

Tamaños de trama (s)	Nº de neuronas	Porcentaje de éxitos		
		Clase 1 (N)	Clase 2 (A)	Clase 3 (V)
2	21	98,9968	27,0724	79,4013
3	38	99,0535	48,0701	90,4438
4	20	99,2113	47,1522	91,8780
5	24	99,3347	39,2875	88,8188
6	9	99,3480	35,2498	80,7275
7	7	99,2745	42,8470	80,0104
8	12	99,3827	37,3030	80,9499
9	9	99,3345	45,3796	81,1566
10	26	99,5276	37,2760	90,6516
11	14	99,4159	41,7545	85,9040
12	11	99,4412	37,9241	84,5206
13	25	99,5061	38,3550	86,2109
14	22	99,5790	29,5711	82,6816
15	12	99,4403	39,0967	85,0771
16	18	99,5202	24,9249	93,3965
17	20	99,5005	40,9350	89,8710
18	12	99,3998	40,5539	89,2218
19	35	99,5409	43,8348	93,0192
20	45	99,5095	53,5001	89,6292

**TABLA AII. 2: ÉXITOS OBTENIDOS Y NÚMERO DE NEURONAS EN EL ESTUDIO SANO-PATOLÓGICO**

Tamaños de trama (s)	Nº de neuronas	Porcentaje éxitos	
		Sano	Patológico
2	45	98,8768	69,5589
3	26	98,8417	79,9953
4	43	99,1080	83,0523
5	24	99,2038	82,7549
6	26	99,2197	82,3688
7	19	99,2612	86,2292
8	39	99,3277	86,2833
9	15	99,2111	85,3094
10	21	99,3285	83,4360
11	50	99,3196	86,5992
12	45	99,3253	85,6096
13	44	99,3457	86,1113
14	37	99,2941	87,4499
15	42	99,3639	86,1647
16	19	99,2964	85,8430
17	20	99,3186	87,5584
18	33	99,3518	84,6376
19	37	99,3349	87,2345
20	29	99,3641	87,4257

## A2.2 RESULTADOS COMPLEMENTARIOS DEL ESTUDIO PARAMÉTRICO CON TAMAÑO ÓPTIMO DE TRAMA



*Figura AII. 1 : Tasa de acierto media (en %), parámetro a parámetro, con tamaño óptimo de trama*

TABLA AII. 3: TASA DE ACIERTO, POR CLASE Y PARÁMETRO, CON TAMAÑO ÓPTIMO DE TRAMA

Parámetros no lineales	Tasa de éxito entre clases (%)			Tasa de éxito Sano-Patológico(%)	
	Clase N	Clase A	Clase V	Sano	Patológico
Entropía de Shannon	76,4379	34,006	61,5814	74,012	58,6012
Máximo Exponente de Lyapunov (Rosenstein)	66,829	45,5415	63,0924	85,5249	62,2796
Máximo Exponente de Lyapunov (Kantz)	58,0759	23,7288	48,545	57,252	52,5507
Dimensión de correlación	70,7619	38,3302	53,2267	87,9075	37,8166
Entropía de correlación	62,0872	38,2414	49,0209	66,7302	49,4464
Complejidad Lempel-Ziv	80,7003	49,9062	79,6969	73,9898	67,6557
Hurst (varianza agregada)	74,7448	51,7207	62,9186	89,0402	71,1252
Hurst (momento absoluto)	69,0175	46,3216	63,4561	87,5717	56,3423
Hurst (R/S)	76,4379	34,006	61,5814	74,012	58,6012

### A2.3 RESULTADOS COMPLEMENTARIOS DEL ESTUDIO PARAMÉTRICO CON NÚMERO ÓPTIMO DE NEURONAS

- Entropía de Shannon

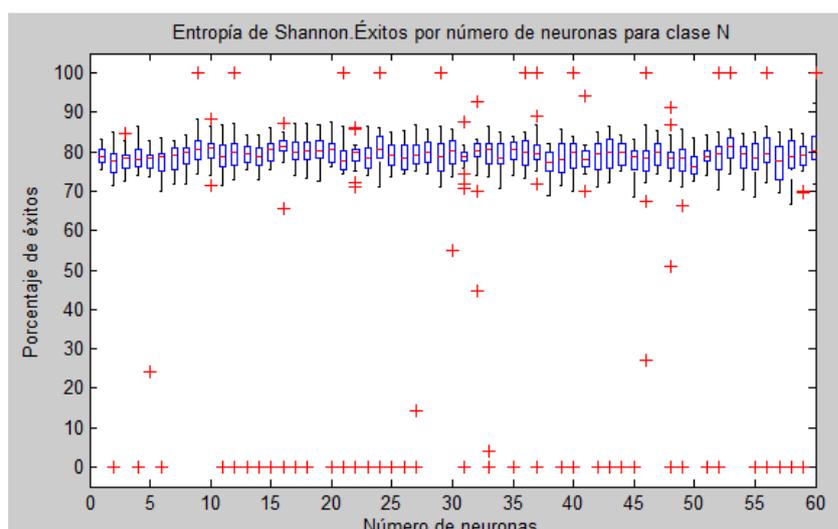


Figura AII. 2 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Entropía de Shannon

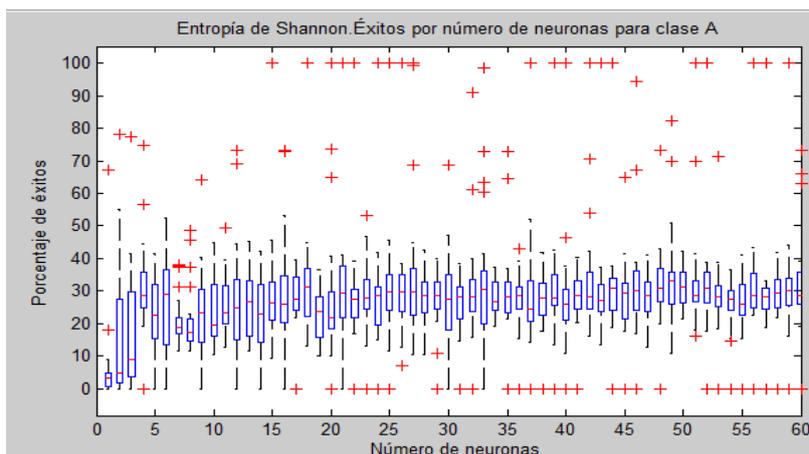


Figura AII. 3 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Entropía de Shannon

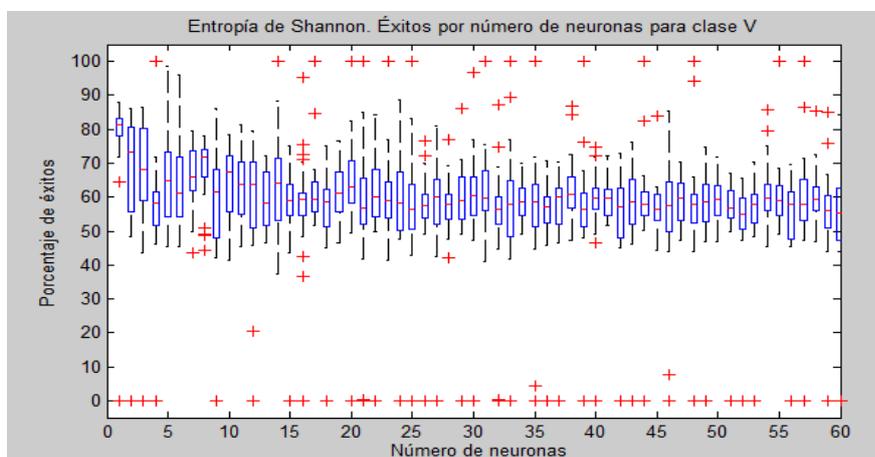


Figura AII. 4 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Entropía de Shannon

▪ Entropía de correlación

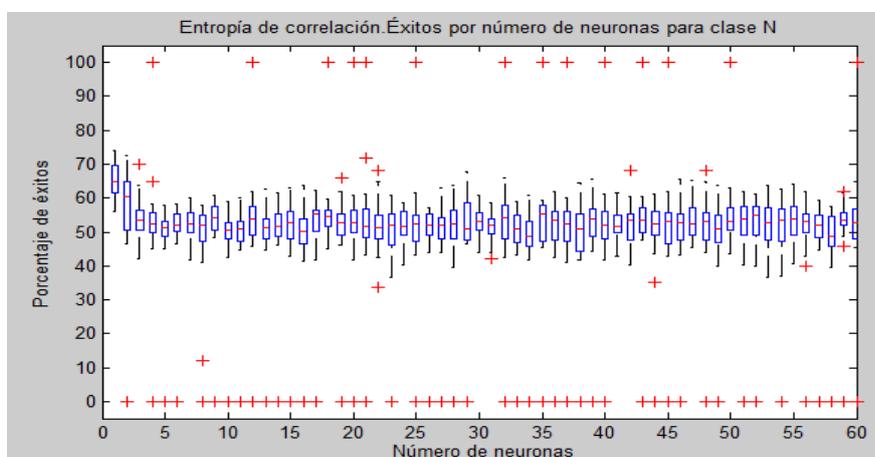


Figura AII. 5 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Entropía de Correlación

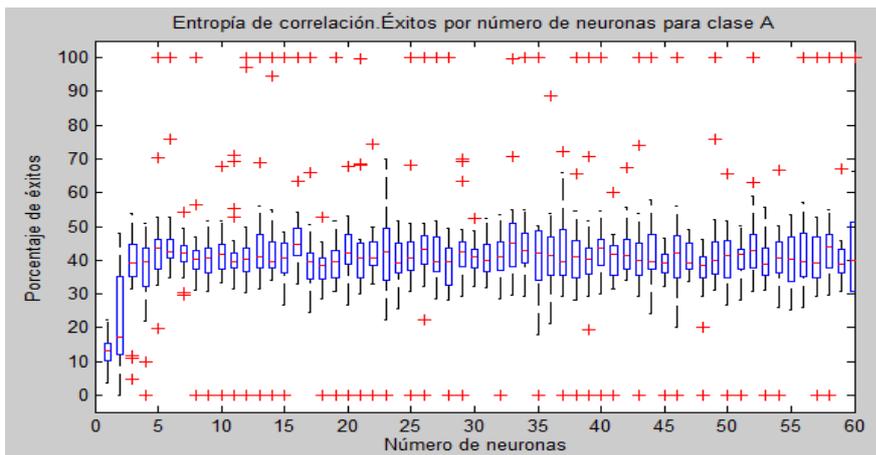


Figura AII. 6 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Entropía de Correlación

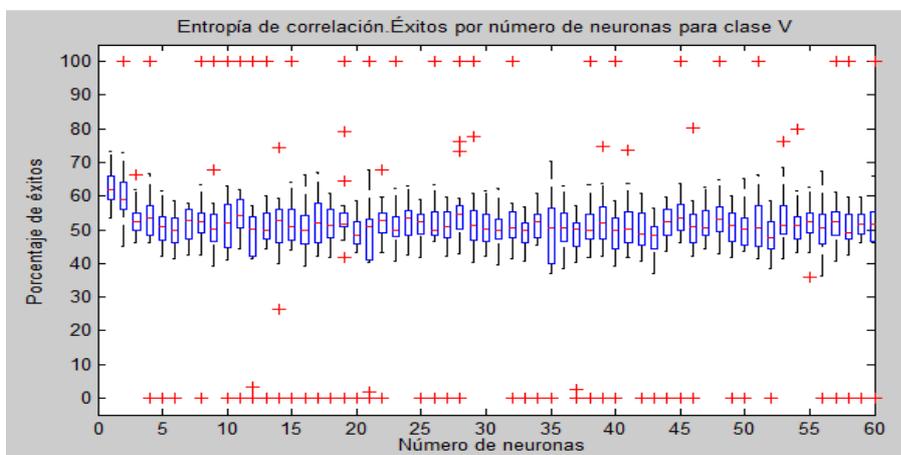


Figura AII. 7 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Entropía de Correlación

▪ **Dimensión de correlación**

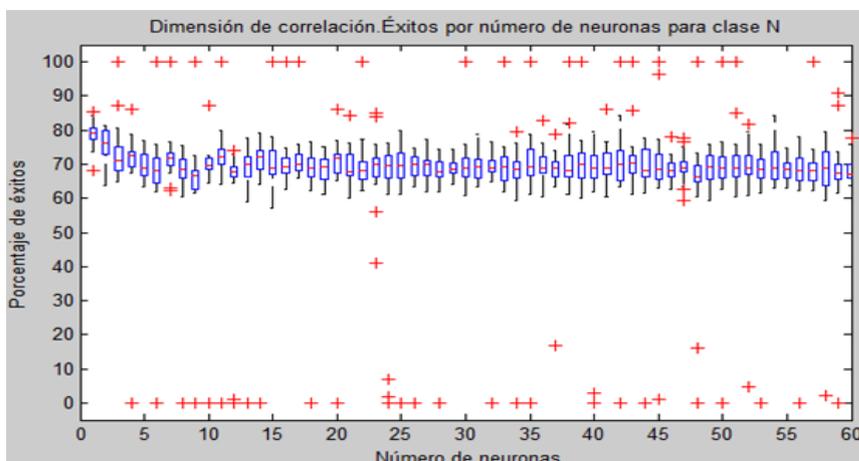


Figura AII. 8 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Dimensión de Correlación

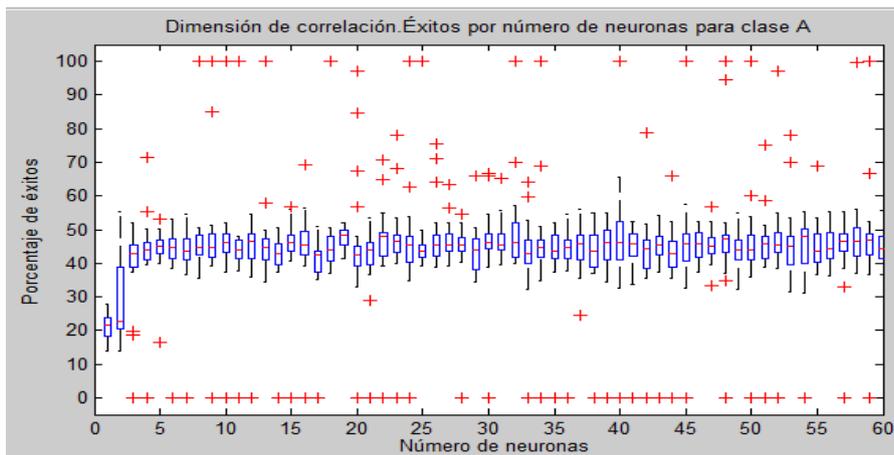


Figura AII. 9 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Dimensión de Correlación

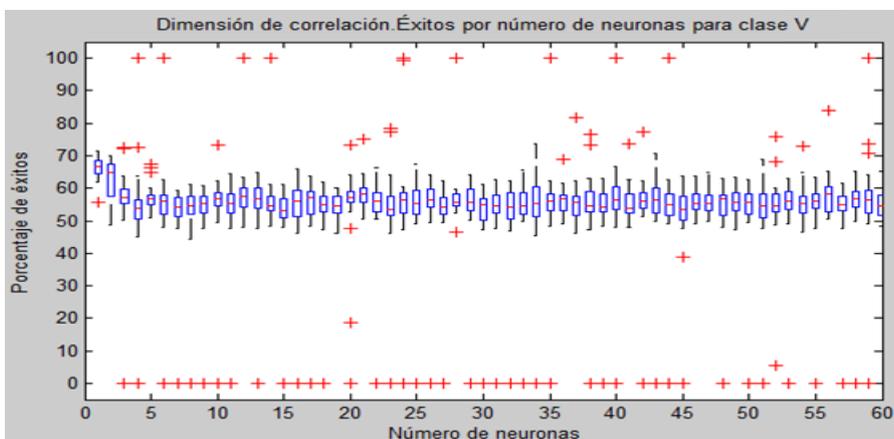


Figura AII. 10 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Dimensión de Correlación

▪ **Máximo Exponente de Lyapunov, con algoritmo de Kantz**

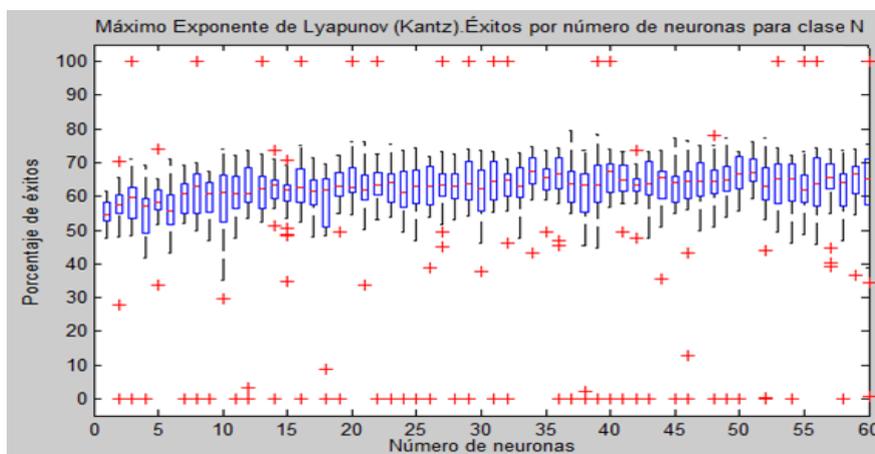


Figura AII. 11 : Éxitos en la clasificación para clase N en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov, con algoritmo de Kantz

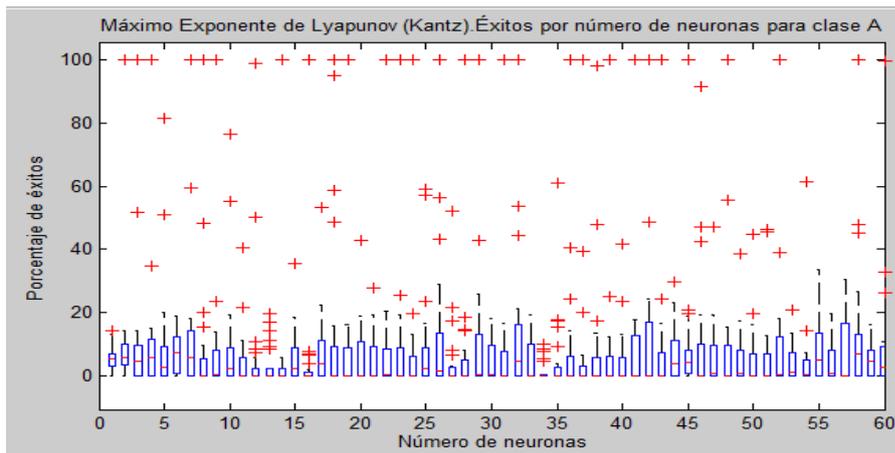


Figura AII. 12 : Éxitos en la clasificación para clase A en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov, con algoritmo de Kantz

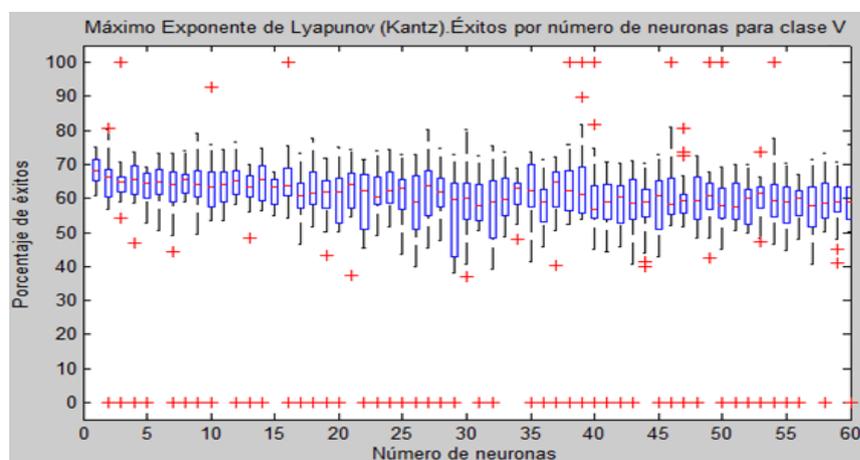


Figura AII. 13 : Éxitos en la clasificación para clase V en función del número de neuronas de la capa oculta, para Máximo Exponente de Lyapunov, con algoritmo de Kantz



# BIBLIOGRAFÍA

- [1] Organización Mundial de la Salud (OMS)  
<http://www.who.int/mediacentre/factsheets/fs317/es/>, última visita en julio de 2016
- [2] Informe sobre la situación mundial de las enfermedades no transmisibles  
 2014 [http://apps.who.int/iris/bitstream/10665/149296/1/WHO\\_NMH\\_NVI\\_15.1\\_spa.pdf?ua=1&ua=1](http://apps.who.int/iris/bitstream/10665/149296/1/WHO_NMH_NVI_15.1_spa.pdf?ua=1&ua=1), última visita 22/07/2016
- [3] Notas de prensa del Instituto Nacional de Estadística (INE)  
<http://www.ine.es/prensa/np896.pdf>, última visita en julio de 2016
- [4] Orozco Alzate, Mauricio “*Clasificación de Arritmias Cardíacas usando Transformada Wavelet y Técnicas de Reconocimiento de Patrones*”. Trabajo de Grado, Universidad Nacional de Colombia de Manizales, 2003.
- [5] Acharya, R., Krishnan, S. M., Spaan, J. A., & Suri, J. S. (Eds.). (2007). *Advances in cardiac signal processing* (pp. 1-50). Berlin: Springer.
- [6] Falcón Alonso, Antonio J. “*Aplicación de la Transformadas Wavelets a la detección automática de Apnea mediante ECG*”. Proyecto fin de carrera, ULPGC, 2010.
- [7] SUN, Y. CHAN, K. Arrhythmia detection and recognition in ECG signals using nonlinear techniques. *Ann. Biomed. Eng.*, 28.
- [8] Khadra, L., Al-Fahoum, A. S., & Al-Nashash, H. (1997). Detection of life-threatening cardiac arrhythmias using the wavelet transformation. *Medical and Biological Engineering and Computing*, 35(6), 626-632.
- [9] Ge, D., Srinivasan, N., & Krishnan, S. M. (2002). Cardiac arrhythmia classification using autoregressive modeling. *Biomedical engineering online*, 1(1), 5.
- [10] Acharya, R., Kumar, A., Bhat, P. S., Lim, C. M., Lyengar, S. S., Kannathal, N., & Krishnan, S. M. (2004). Classification of cardiac abnormalities using heart rate signals. *Medical and Biological Engineering and Computing*, 42(3), 288-293.
- [11] Anuradha, B., & Reddy, V. V. (2008). ANN for classification of cardiac arrhythmias. *ARPN Journal of Engineering and Applied Sciences*, 3(3), 1-6.
- [12] Gómez, A. A., & Suárez, E. G. (2006). CLASIFICACIÓN DE ARRITMIAS UTILIZANDO ANFIS, REDES NEURONALES Y AGRUPAMIENTO SUBSTRACTIVO. *Scientia et technica*, 2(31), 19-22.
- [13] Ballesteros Ruiz Benítez de Lugo, Jorge “*Detección automática de patologías cardiológicas mediante el análisis del electrocardiograma*”. Proyecto fin de carrera,

ULPGC, 2006

[14] Corsino Espino, Jorge “*Reconocimiento automático de diferentes tipos de arritmias basado en señales ECG*” Proyecto fin de carrera, ULPGC, 2007

[15] Travieso, C. M., Alonso, J. B., Ferrer, M. A., & Corsino, J. (2010). Automatic Arrhythmia Detection. In *Soft Computing Methods for Practical Environment Solutions: Techniques and Studies* (pp. 204-218). IGI Global.

[16] Corsino, J., Travieso, C. M., Alonso, J. B., & Ferrer, M. A. (2008). Improving an Automatic Arrhythmias Recogniser Based in ECG Signals. In *BIOSIGNALS (2)* (pp. 453-457).

[17] Chandnani Chandnani, Bhavish V. “*Análisis de reducción de características en la detección de arritmias cardíacas*” Proyecto fin de carrera, ULPGC, 2011

[18] Vázquez Sedano, Ariadna. “*Diseño de un detector automático de cardiopatías a partir de señales electrocardiográficas en tiempo real usando dispositivos digitales programables*”. Proyecto fin de carrera ETSIT-ULPGC, 2011

[19] Alonso Hernández, Jesús B. “*Sistema de detección automático de disfonías*”, Proyecto Fin de Carrera, ULPGC, 2001.

[20] Henríquez Rodríguez, Patricia “*Aplicación de la teoría del caos en la detección de patologías laríngeas*”. Proyecto fin de carrera, ULPGC, 2006

[21] Alonso Hernández, Jesús B. “*Metodología del Análisis Acústico para la Evaluación Clínica de la Voz*”. Tesis Doctoral, Julio 2006

[22] Henríquez Rodríguez, Patricia “*Advances in preventive monitoring of machinery through audio and vibration signals*”. Tesis Doctoral, 2016

[23] Hegger, R., Kantz, H., & Schreiber, T. (1999). Practical implementation of nonlinear time series methods: The TISEAN package. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 9(2), 413-435.

[24] Biblioteca Nacional de Medicina de EEUU - Medline Plus

<https://medlineplus.gov/spanish/ency/article/001100.htm>, última visita en agosto de 2016

[25] [https://es.wikipedia.org/wiki/N%C3%B3dulo\\_sinoauricular](https://es.wikipedia.org/wiki/N%C3%B3dulo_sinoauricular), última visita en agosto de 2016

[26] Lorenzo Romero, José “*Análisis de señales electrocardiográficas usando técnicas de procesamiento digital*”. Trabajo fin de carrera, Universidad Abierta de Cataluña, 2015

[27] Enciclopedia Médica

<http://sintomastratamiento.com/dolor-enfermedad-trastorno/complejos-auriculares-prematurados-o-latidos-auriculares-prematurados-tratamiento-causas-sintomas-diagnostico-y-prevencion/>, última visita en septiembre de 2016

[28] Instituto del corazón de Texas

[http://www.texasheart.org/HIC/Topics\\_Esp/Cond/arcats\\_sp.cfm](http://www.texasheart.org/HIC/Topics_Esp/Cond/arcats_sp.cfm), última visita en agosto de 2016

[29] Sociedad Española de Enfermería de Urgencias y Emergencias.

[http://www.enfermeriadeurgencias.com/ciber/PRIMERA\\_EPOCA/2006/octubre/contraccionesventriculares.htm](http://www.enfermeriadeurgencias.com/ciber/PRIMERA_EPOCA/2006/octubre/contraccionesventriculares.htm)

[30] Piorno Campo, Juan. *“Diseño de un nuevo clasificador supervisado para minería de datos”*. Proyecto de fin de máster, Universidad Complutense de Madrid, 2009

[31] Mateo Sotos, Jorge *“Aplicación de redes neuronales artificiales en el procesado versátil de señales electrocardiográficas”* Tesis Doctoral, Universidad Politécnica de Valencia, 2012

[32] Base de datos del MIT-BIH

<https://www.physionet.org/physiobank/database/mitdb/>, última visita en julio de 2016

[33] Herramienta ATM (Automated Teller Machine)

<http://physionet.org/cgi-bin/atm/ATM> última visita en julio de 2016

[34] Tabla de latidos de PhysioNet

<https://physionet.org/physiobank/database/html/mitdbdir/tables.htm#allbeats>, última visita en julio de 2016

[35] Álvarez Escobar, L. L., Henao, R., & Duque Cardona, E. (2007). Análisis de esquemas de filtrado análogo para señales ECG.

[36] Garza, G. P. El electrocardiograma y su tecnología.

[37] Hernández Ramírez, Celia. *“Extracción de características electrocardiográficas y su aplicación al diseño de un sistema de diagnóstico temprano de patologías cardíacas”* Proyecto fin de carrera, ULPGC, 2007

[38] Gell-Mann, M. (2002). What is complexity?. In *Complexity and industrial clusters* (pp. 13-24). Physica-Verlag HD.

- [39] San Martín, V. M., & Ferri, G. L. (2014, October). LA COMPLEJIDAD ESTADÍSTICA Y LA MEDIDA DE FISHER COMO INDICADORES DE TRANSICIÓN AL CAOS EN SISTEMAS DE TIEMPO CONTINUO. In *ANALES AFA* (Vol. 24, No. 2).
- [40] Fernández Rodríguez, Fernando. “*El problema de la predicción en series temporales: aplicaciones del caos determinista*“. Tesis doctoral, ULPGC, 1992
- [41] Servicio de divulgación científica DivulgaUNED  
<http://divulgauned.es/?p=721>, última visita noviembre de 2016
- [42] Ruelas, E., & Ruelas, E. (2005). *Las ciencias de la complejidad y la innovación médica* (No. Sirsi) i9789707224377).
- [43] Van Zyl, J. (2001). *Modelling chaotic systems with neural networks: application to seismic event predicting in gold mines* (Doctoral dissertation, Stellenbosch: University of Stellenbosch).
- [44] Alzate, A., & Giraldo, E. (2006). Clasificación de Arritmias utilizando ANFIS. *Redes Neuronales y Agrupamiento Substractivo*.
- [45] Kuznetsov, N. V., & Leonov, G. (2003). Stability by the first approximation for discrete systems. *VESTNIK-ST PETERSBURG UNIVERSITY MATHEMATICS C/C OF VESTNIK-SANKT-PETERBURGSKII UNIVERSITET MATEMATIKA.*, 36, 21-27.
- [46] Lempel, A., & Ziv, J. (1976). On the complexity of finite sequences. *IEEE Transactions on information theory*, 22(1), 75-81.
- [47] Picó, A. M., Roldan, E. C., & Frau, D. C. Complejidad Lempel-Ziv: robustez frente a spikes y pérdida de muestras en registros EEG.
- [48] Hornero, R., Ortiz, T., & López-Ibor, J. J. (2010). Análisis de complejidad de la actividad cerebral y trastornos mentales. *Actas Esp Psiquiatr*, 38(4), 229-238.
- [49] Delgado, O. Y. Q., & Delgado, J. R. (2011). Estimación del Exponente de Hurst y la dimensión Fractal de una superficie topográfica a través de la extracción de perfiles. *UD y la GEOMÁTICA*, (5), 84-91.
- [50] Rodríguez, A., Sanmartín, J. P., Giraldo, E., Orozco, Á., & Fetecua, J. G. (2008). Interpretación dinámica de bioseñales usando técnicas de análisis no lineal. *Memorias*, 2, 89-94.
- [51] Falcón Alonso, Antonio J. “*Aplicación de transformadas Wavelet a la detección automática de Apnea mediante ECG*“. Proyecto fin de carrera, ULPGC, 2010
- [52] Crispim-Junior, C. F., & Marino-Neto, J. (2013). Artificial Neural Networks and Image Features for Automatic Detection of Behavioral Events in Laboratory Animals. In *V*

*Latin American Congress on Biomedical Engineering CLAIB 2011 May 16-21, 2011, Habana, Cuba* (pp. 862-865). Springer Berlin Heidelberg.

[53] Van Zyl, J. (2001). *Modelling chaotic systems with neural networks: application to seismic event predicting in gold mines* (Doctoral dissertation, Stellenbosch: University of Stellenbosch).

[54] Plataforma inteligente de aprendizaje virtual

<http://disi.unal.edu.co/~lctorress/RedNeu/LiRna008.pdf>, última visita en noviembre de 2016

[55] Izaurieta, F., & Saavedra, C. (2000). Redes neuronales artificiales. *Departamento de Física, Universidad de Concepción Chile*.

[56] Slide Share

<http://es.slideshare.net/mentelibre/diseo-de-redes-neuronales-multicapa-y-entrenamiento>, última visita en noviembre de 2016

[57] Buscador Heaton

<http://www.heatonresearch.com>, última visita en noviembre de 2016

[58] Florez-Lopez, R., & Fernández, J. M. F. (2008). Las redes neuronales artificiales: Fundamentos teóricos y aplicaciones prácticas.

[59] University of Nebraska Medical Center

<http://gim.unmc.edu/dxtests/roc3.htm> última visita en marzo de 2017

[60] Giraldo Giraldo, B., Rodriguez Benitez, J., Arcentales Viteri, A. R., Voss, A., Caminal Magrans, P., & Bayés Genis, A. (2015). Caracterización de pacientes isquémicos y dilatados a partir de las señales ECG y de presión sanguínea. In *Libro de Actas del XXXIII Congreso Anual de la Sociedad Española de Ingeniería Biomédica* (pp. 31-34).



## II. PROGRAMAS



En este bloque se muestra la interfaz de las funciones implementadas en este proyecto con sus respectivos comentarios. Para realizar las simulaciones se ha utilizado el entorno matemático Matlab, en el cual se han programado todas las funciones. Este bloque se ha dividido en 4 secciones, en las que se han explicado las funciones implementadas para la creación de la base de datos, las funciones de preprocesado de las señales de ECG, las del procesamiento de las mismas y finalmente las simulaciones.

## P.1 BASE DE DATOS

### P.4.1 Cambio de formato

#### ➤ **convertirPtoMat.m.**

Permite cambiar el formato a .mat, y unificar en una sola variable los ficheros .atr .dat y .hea descargados de Physionet. Dicha variable contiene la señal electrocardiográfica y su etiquetado, además de otros parámetros de interés como frecuencia de muestreo, ganancia, etc.

```
[ ] = convertirPtoMat(directorio_archivo, nombre_archivo)
```

La función *convertirPtoMat.m* utiliza las funciones

- **función\_leer\_achivo\_dat\_mcs\_impar.mat**
- **función\_leer\_achivo\_he.mat**

Estas funciones se encargan de leer por separado los datos y la cabecera y realizar el cambio de formato.

## P.4.2 Separación de señales

### ➤ **clasificaTipos.mat**

Separa las distintas clases que pueda contener el registro ECG de cualquier paciente de la base de datos del MIT-BIH a partir de la información cardiológica. De todas las posibles, extrae las 9 clases más frecuentes en la base de datos (N, L, R, P, A, V, F, f), clasificando como artefactos las minoritarias. La información cardiológica es una matriz formada por dos vectores. El primero contiene la localización de las muestras donde se encuentran los puntos del complejo RR. El segundo, el tipo de patología que contiene dicho complejo.

```
[sigN, sigL, sigR, sigP, sigA, sigV, sigF, sigf, artefactos]=  
clasificaTipos(sigIn, RRIn)
```

Esta función *ClasificaTipos.mat* utiliza las siguientes rutinas:

#### ▪ **txt2mat.m**

Permite importar desde Physionet los archivos de anotaciones cardiológicas en texto (.txt) y hacerlos legibles por Matlab (.mat).

```
[anotaciones]= txt2mat (nombFichero)
```

#### ▪ **extraeRRyTipo.m**

Extrae de entre todas las anotaciones cardiológicas solamente la localización del complejo RR y tipo de latido al que se corresponde (cardiopatía).

```
[RRyTipo]= extraeRRyTipo (anotaciones)
```

## P.2 PREPROCESADO

### ➤ **filtraSenal.mat**

El programa *filtraSenal.mat* realiza filtrados paso alto, paso bajo y paso banda a cada señal ECG. Accede de manera automática a la carpeta donde está la base de datos de los pacientes y guarda la señal filtrada en el fichero actual (*sFiltrada*).

```
carpeta = './senales pacientes\'; % define carpeta origen
d = dir([carpeta, '*.mat']); % número de elementos de la carpeta

for i = 1:length(d) % proceso iterativo para todos los elementos

    load([carpeta, d(i).name]) % carga de un paciente a Workspace

    sStruct=load([carpeta, d(i).name]); % extracción de la info

    names=fieldnames(sStruct); % extracción del nombre de
        % la señal (por ejemplo sig100N)

    s=getfield(sStruct, names{3}); % extracción del contenido del
        % campo: la señal

    %[llamadas a subrutinas de filtrado]
```

Esta función *filtraSenal.mat* utiliza las siguientes rutinas:

- **filtroPA.m**

Filtro paso alto que elimina las variaciones en la línea basal de una señal electrocardiográfica. Requiere de la especificación del orden del filtro (N) y de la limitación de frecuencia  $W_n$ , entre 0 y 1, donde 1 se corresponde con la frecuencia de Nyquist.

$$[sFiltradaPA] = \text{filtroPA}(\text{senal}, N, W_n)$$

- **filtroPB.m**

Filtro paso bajo que elimina el ruido de alta frecuencia. Requiere las mismas especificaciones que el filtro paso alto.

```
[sFiltradaPB] = filtroPB(senal,N,Wn)
```

- **filtroNotch.m**

Filtro paso banda que elimina la interferencia en la red eléctrica. Requiere especificar el factor de calidad (Q), la frecuencia de muestreo de la señal a filtrar (fs) y la frecuencia a eliminar (freqElim), que para la red eléctrica de EEUU son 60 Hz.

```
[sFiltrada]=filtroNotch(senal,Q,fs,freqElim)
```

### P.3 SEGMENTACIÓN Y OBTENCIÓN DE CARACTERÍSTICAS

- **fMatrices.m**

Realiza de forma automatizada la segmentación en tramas de la señal de ECG de la base de datos, de la extracción de características de las tramas y del cálculo de los estimadores estadísticos (media, varianza, *skewness* y *curtosis*) de cada vector de características.

Usa las funciones:

- **creaMatrizTramas.m**

A partir de una señal ECG de cualquier clase de la base de datos (N, R, L, P, A, V, F, f) conforma una matriz de tramas, cuyo tamaño y solape entre tramas serán los que se especifiquen por parámetro.

```
[matrizTramas,Ntramas]=creaMatrizTramas (fs, senal, durTrama,
                                         durDesplaz);
```

#### ▪ **creaMatricesCar.m**

Extrae las características caóticas de una matriz de tramas y forma una matriz con dichos resultados. La matriz característica está formada por 12 características caóticas, de las que las 8 últimas son los parámetros del caos, y los 3 primeros son el retardo, la dimensión del embedding y la dimensión del embedding estimada por falsos vecinos.

```
[matrizCar]=creaMatricesCar(matrizTramas, Ntramas);
```

La función *creaMatricesCar.m* usa la herramienta *Caos.m*, (propiedad del GPDS de la ULPGC), que permite extraer características caóticas a partir de una secuencia.

#### ▪ **creaMatrizCurt.m**

Obtiene los valores de curtosis de los parámetros caóticos, para cada una de las matrices características de la misma clase (N, A, V...). Es decir, por cada matriz característica habrá un vector de curtosis, y el conjunto de vectores de curtosis de las matrices características de la misma clase formarán la matriz de curtosis.

```
[matrizCurt]=creaMatrizCurt(matrizCar,matrizCurt);
```

#### ▪ **creaMatrizMedia.m**

Obtiene los valores de media de los parámetros caóticos, para cada una de las matrices características de la misma clase (N, A, V...). Es decir, por cada matriz característica habrá un vector de media, y el conjunto de vectores de media de las matrices características de la misma clase formarán la matriz de media.

```
[matrizMedia]=creaMatrizMedia(matrizCar,matrizMedia);
```

▪ **creaMatrizVarianza.m**

Obtiene los valores de varianza de los parámetros caóticos, para cada una de las matrices características de la misma clase (N, A, V...). Es decir, por cada matriz característica habrá un vector de varianza, y el conjunto de vectores de varianza de las matrices características de la misma clase formarán la matriz de varianza.

```
[matrizVar]=creaMatrizvarianza(matrizCar,matrizVar);
```

▪ **creaMatrizSkewness.m**

Obtiene los valores de *skewness* de los parámetros caóticos, para cada una de las matrices características de la misma clase (N, A, V...). Es decir, por cada matriz característica habrá un vector de *skewness*, y el conjunto de vectores de *skewness* de las matrices características de la misma clase formarán la matriz de *skewness*

```
[matrizSkew]=creaMatrizSkewness(matrizCar,matrizSkew);
```

## P.4 SIMULACIONES

### P.4.1 Formación de las entradas al clasificador

➤ **creaEntradaClasif.m**

Programa que crea la entrada y la etiqueta que se introducirá en el clasificador para simular el parámetro caótico deseado. La entrada estará formada por las clases N, A y V de dicho parámetro. Cada uno de los nueve parámetros caóticos a elegir (Pi) se ha codificado mediante numeración por simplicidad, según el siguiente orden:

- 1 Entropía de Shannon
- 2 Máximo Exponente de Lyapunov, Rosenstein
- 3 Máximo Exponente de Lyapunov, Kantz
- 4 Dimensión de Correlación
- 5 Entropía de Correlación
- 6 Complejidad Lempel-Ziv
- 7 Exponente de Hurst, Varianza Agregada
- 8 Exponente de Hurst, Momento Absoluto
- 9 Exponente de Hurst, R/S

```
[entradaClasifPi, etiquetaPi]=creaEntradaClasif(parametro)
```

Requiere acceder a las carpetas ‘Clase N’, ‘Clase A’ y ‘Clase V’ con las matrices características calculadas previamente.

Esta función hace uso de las siguientes subrutinas:

- **creaParametroEntrada.m**

Función que accede de forma automatizada a las matrices características y crea un vector de parámetro caótico según la clase especificada (N, A, V). Esta entrada será por tanto de tipo N, tipo A o tipo V. Los nueve parámetros caóticos se han codificado numéricamente por simplicidad, según el siguiente orden:

```
1 Entropía de Shannon
2 Máximo Exponente de Lyapunov, Rosenstein
3 Máximo Exponente de Lyapunov, Kantz
4 Dimensión de Correlación
5 Entropía de Correlación
6 Complejidad Lempel-Ziv
7 Exponente de Hurst, Varianza Agregada
8 Exponente de Hurst, Momento Absoluto
9 Exponente de Hurst, R/S
```

```
[entrada]=creaParametroEntrada(clase, parametro)
```

- **aleatorizaEntradas.m**

Función que escoge de manera aleatoria las muestras de cada clase.

```
[entradaAleatN, entradaAleatA, entradaAleatV]=aleatorizaEntradasClasif(entradaN, entradaA, entradaV)
```

- **GuardaEntradasyEtiquetas.m**

Función que forma simultáneamente las entradas y las etiquetas de los nueve parámetros para un mismo tamaño de trama (si nParametros = 9). Devuelve nueve

variables llamadas Parami, con i de 1 a 9 (Param1, Param2,..., Param9), que contiene a su vez entradaClasifPi y etiquetaPi, y las guarda directamente en memoria.

```
[]=GuardaEntradasyEtiquetas(nParametros)
```

Requiere acceder a las carpetas 'Clase N', 'Clase A' y 'Clase V' con las matrices características calculadas previamente.

## **P.4.2 Estimación del tamaño óptimo de trama**

### **➤ barridoTamanoTramaOptimo.m**

Programa que calcula el porcentaje de éxitos para los tamaños de trama desde 2 segundos hasta tamanoEntradaMax especificado por usuario (hasta 20 segundos).

```
[porcentajeExitosMedia,vectorExitosporNeurona]=barridoTamanoTramaOptimo(tamanoEntradaMax,entrada,etiqueta,iteracionesEntrenam,porcentEntrenam,porcentTest,porcentValidac,iteracionesMedia,nClases)
```

Requiere acceder a las carpetas '2s', '3s',..., '20s' que contienen las entradas y las etiquetas para cada uno de esos tamaños de trama.

Utiliza las siguientes subrutinas:

#### **▪ tramaOptima.m**

Calcula, para tramas de t segundos (tamaño fij), una tabla con los porcentajes de éxito del clasificador con un barrido de 2 a 50 neuronas

```
[porcentajeExitos]=tramaOptima(entrada,etiquetas,iteracionesEntrenam,porcentEntrenam,porcentTest,porcentValidac,iteracionesMedia,nClases,tamanoClase1,tamanoClase2,tamanoClase3)
```

- **calculaMediaExitos.m**

Calcula la media de los éxitos para las clases N, A y V (o Sano y Patológico en su caso) tras el número de simulaciones realizadas iterativamente. El número de simulaciones son especificadas por usuario con el parámetro iteracionesMedia (con el objeto de aportar mayor fiabilidad a los resultados).

```
[porcentajeExitosMedia]=calculaMediaExitos(entrada,etiquetas,iteracionesEntrenam,porcentEntrenam,porcentTest,porcentValidac,iteracionesMedia,i,nClases,tamanoClase1,tamanoClase2,tamanoClase3);
```

- **mayorExito.m**

Rutina que extrae de la tabla con los porcentajes de éxito para cada uno de los tamaños de trama, cual es el mayor porcentaje de la tabla y el número de neuronas con el que se alcanzaron dichos resultados

```
[mayorPorcentaje,nNeuronasOpt]=mayorExito(porcentajeExitos)
```

### P.4.3 Estimación el número óptimo de neuronas

- **estimaNumNeuronas.m**

Programa que estima el número de neuronas óptimo de la capa oculta de una red neuronal en función de la entrada, las etiquetas y la configuración elegida. La parametrización de las variables tamanoClasei (con i=1,2,3) permite el estudio balanceado y desbalanceado. Realiza un barrido desde 1 al número de neuronas especificado por parámetro, aportando además una tabla con los éxitos obtenidos para cada número de neuronas y la matriz de éxitos que se consigue con el número de neuronas óptimo.

```
[nNeuronasOpt,porcentajeExitosMedia,matrizExitos]=estimaNumNeuronas2(entrada,etiquetas,iteracionesEntrenam,porcentEntrenam,porcentTest,porcentValidac,iteracionesMedia,nClases,tamanoClase1,tamanoClase2,tamanoClase3,nNeuronasBarrido)
```

Esta función hace uso de las siguientes subrutinas:

- **calculaExitosporNeurona.m**

Programa que realiza un barrido de neuronas en función del número de neuronas especificado por parámetro y calcula, para cada una de esas configuraciones de la red, la tasa de éxitos que se obtendría.

```
[porcentajeExitosMedia, vectorExitosporNeurona]=calculaExitosporNeurona(entrada, etiquetas, iteracionesEntrenam, percentEntrenam, percentTest, percentValidac, iteracionesMedia, nNeuronas, nClases, tamanoClase1, tamanoClase2, tamanoClase3)
```

- **simulaParametros.m**

Programa que realiza la simulación de los parámetros a la entrada del clasificador. Para ello se introducen los parámetros como entrada, junto con sus etiquetas, y la configuración de la red neuronal (porcentajes de entrenamiento, validación y test, número de épocas,...). Devuelve como resultado la salida de la clasificación (niveles entre 0 y 1), las etiquetas (valores 0 o 1 tomados según el umbral de decisión fijado), la matriz de confusión en porcentajes y el porcentaje de éxito logrado

```
[porcentajeExitos, matrizConfusionPorcentajes, resultados, etiquetasConfusion]=simulaParametros(entrada, etiquetas, iteraciones, percentEntrenam, percentTest, percentValidac, nNeuronas)
```

- **calculaMediaExitos.m**

Rutina que calcula la tasa media de éxitos de los parámetros de entrada, en función de la configuración de la red.

```
[porcentajeExitosMedia, resultadosSimulacion, etiquetasConfusion]=calculaMediaExitos(entrada, etiquetas, iteracionesEntrenam, percentEntrenam, percentTest, percentValidac, iteracionesMedia, nNeuronas, nClases, tamanoClase1, tamanoClase2, tamanoClase3)
```

➤ **representaROC.m**

Programa que calcula los valores de especificidad y sensibilidad a partir de la salida del clasificador. Representa gráficamente la ROC y su punto óptimo y calcula además el área bajo la curva (AUC) de la ROC

```
[especificidad, sensibilidad, ptoOptimo, AUC]=representaROC(salidaClasif, etiquetasClasif, clase)
```

➤ **calcularMatrizConfusion.m**

Calcula la matriz de confusión, en muestras, de la simulación a partir de las salidas y las etiquetas.

```
[y]=calcularMatrizConfusion(x, etiquetas)
```

➤ **calculaMatrizConfusionPorcentajes.m**

Convierte una matriz de confusión en muestras a una matriz de confusión en porcentajes

```
[matrizConfPorcentajes]=calculaMatrizConfusionPorcentajes(matrizConfMuestras)
```

➤ **variablesBoxplot.m**

Función que durante las simulaciones crea vectores de las clases N, A, V con los diferentes resultados para poder ser representados en diagrama de cajas.

```
[C1, C2, C3]=variablesBoxplot(entrada, etiquetas, iteracionesEntrenam, percentEntrenam, percentTest, percentValidac, iteracionesMedia, nNeuronas, nClases, tamañoClase1, tamañoClase2, tamañoClase3)
```



# III. PLIEGO DE CONDICIONES



Este bloque se divide en dos partes, el Pliego de Condiciones Técnicas y el Pliego de Condiciones Legales. En el Pliego de Condiciones Técnicas se presentan las herramientas que fueron necesarias para llevar a cabo el desarrollo y ejecución de este proyecto. En él se especifica por separado los componentes *hardware* y las aplicaciones (*software*) que han sido utilizados. En el Pliego de Condiciones Legales, se aportan los acuerdos de licencia de los programas.

## **P.1 PLIEGO DE CONDICIONES TÉCNICAS**

- **Hardware:**

- Ordenador de sobremesa Intel Pentium Dual Core
- Impresora

- **Software:**

- Microsoft Windows 7 Home Edition.
- Entorno MathWorks:
  - MATLAB R2010a
  - Librería Matlab Neural Network Toolbox, Versión 4.0.1
- Toolbox TISEAN Versión 2.1
- Toolbox Chaos, 2012
- Microsoft Office Professional 2013 para Windows

## **P.2 PLIEGO DE CONDICIONES LEGALES**

### **2.1 Concesión de licencia**

Este trabajo es propiedad de la Universidad de Las Palmas de Gran Canaria y todos los usuarios deben estar de acuerdo en obligarse por los términos y condiciones establecidas en esta licencia, aceptando todas sus cláusulas. El uso de este material o de una copia será bajo la autorización expresa del autor, tutores del proyecto y de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria.

### **2.2 Derechos de autor**

Estos programas y la documentación adjunta están protegidos por las leyes de la propiedad intelectual que les sean aplicables, así como las disposiciones de los tratados internacionales. En consecuencia, el material debe ser utilizado como cualquier producto protegido por derechos de autor. Sin embargo, el usuario podrá usar una copia y utilizar los códigos fuente de la programación y la documentación siempre bajo la autorización del autor, los tutores y de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria.

### **2.3 Restricciones**

El usuario no podrá realizar ingeniería inversa, de compilación o desensamblado del programa. El usuario podrá transferir los programas a un tercero, siempre que no tenga copias de los mismos, incluyendo posibles actualizaciones o retener material escrito adicional que acompañe dichos programas.

### **2.4 Garantía**

La autora garantiza que la aplicación funcionará correctamente siempre que la instalación se realice de acuerdo con lo especificado en los requisitos informáticos. Asimismo, se garantiza que el soporte en el cual está grabado el programa no contendrá defectos en el momento de la adquisición del mismo.

La única excepción de lo expuesto en el párrafo anterior es que la aplicación está creada sin garantías de ninguna clase. La autora no asegura, garantiza, o realiza ninguna

declaración respecto al uso o los resultados derivados de la utilización del programa o de la documentación.

## **2.5 Limitación de responsabilidad**

En ningún caso serán el autor ni los tutores, ni la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de las Palmas de Gran Canaria responsables de los perjuicios directos, indirectos incidentales o consiguientes, gastos, lucro cesante, pérdida de ahorros, interrupción de negocios, pérdida de información comercial o de negocio, o cualquier otra pérdida que resulte del uso o de la incapacidad de usar los programas o la documentación. El usuario conoce y acepta que los derechos de licencia reflejan esta asignación de riesgo como el resto de cláusulas y restricciones. El autor rechaza cualquier otra garantía que no haya sido indicada anteriormente.

## **2.6 Actividades de alto riesgo**

El material no está exento de errores y no ha sido diseñado ni proyectado para ser utilizado en entornos peligrosos que requieran un funcionamiento con protección ante errores, en las cuales el fallo de cualquier aplicación podría ser causa directa de muerte, lesiones o daños físicos o daños a la propiedad graves (en general, “Actividades de Alto Riesgo”). La autora del software rechaza expresamente cualquier garantía explícita o implícita de adecuación para Actividades de Alto Riesgo.

## **2.7 Varios**

En el supuesto de que cualquier disposición de esta licencia sea declarada total o parcialmente inválida, la cláusula afectada será modificada convenientemente de manera que sea ejecutable una vez modificada, plenamente eficaz, permaneciendo el resto de este contrato en vigencia.

Este Contrato se rige por las leyes de España. El usuario acepta la jurisdicción exclusiva de los tribunales de este país en relación con cualquier disputa que pudiera derivarse de la presente licencia.



# IV. PRESUPUESTO



En este bloque se presentan los gastos estimados generados por este proyecto. El presupuesto del presente proyecto se ha obtenido teniendo en cuenta los gastos que se han ocasionado debido a la realización del mismo. Dichos gastos son los derivados por el uso del material, los gastos debidos al trabajo realizado (honorarios), redacción del proyecto y derechos de visado. Se desglosa, por tanto, en los siguientes aspectos:

- Trabajo tarifado por tiempo empleado.
- Amortización del *hardware*
- Amortización del *software*
- Redacción del proyecto.
- Derechos de visado del COITT.
- Gastos de tramitación y envío.

### **P.1 TRABAJO TARIFADO POR TIEMPO EMPLEADO**

Siguiendo las recomendaciones del COIT, se obtiene una aproximación el importe de las horas empleadas en la realización del proyecto. Los honorarios totales se calculan en base a la siguiente expresión:

$$H = P_N \cdot H_n \cdot C_T + P_E \cdot H_e \cdot C_T \text{ €}$$

Donde:

- $H$  son los honorarios por tiempo.
- $P_N$  es el precio de horas normales, 74,88 €
- $H_n$  son las horas trabajadas dentro de la jornada laboral
- $C_T$  es un factor de corrección en función del número de horas trabajadas
- $H_e$  son las horas especiales trabajadas
- $P_E$  es el precio de horas extraordinarias, 96,72 €

Para la realización del presente Proyecto Fin de Carrera, se estima que se ha trabajado 1280 horas laborales (8 horas x 5 días x 32 semanas). El COIT establece el valor del coeficiente según las horas trabajadas de acuerdo con la siguiente tabla.

TABLA P. 1: RELACIÓN ENTRE HORAS TRABAJADAS Y FACTOR DE CORRELACIÓN

Horas trabajadas	Factor de correlación $C_T$
Hasta 36 horas	1,0
De 36 a 72 horas	0,90
De 72 a 108 horas	0,80
De 108 a 144 horas	0,70
De 144 a 180 horas	0,65
De 180 a 360 horas	0,60
De 360 a 540 horas	0,55
De 540 a 720 horas	0,50
De 720 a 1080 horas	0,45
Más de 1080 horas	0,40

Como el número de horas trabajadas es superior a 1080 horas, se aplica un factor de corrección  $C_T$  de 0,40. Mediante la fórmula anterior se obtienen los honorarios totales por las horas dedicadas al proyecto.

$$H = 74,88 \cdot 1280 \cdot 0,40 = 38.338,56 \text{ €}$$

La tarifa por tiempo de ejecución es de treinta y ocho mil trescientos treinta y ocho euros con cincuenta y seis céntimos.

## P.2 AMORTIZACIÓN DEL HARDWARE

En este apartado se consideran los gastos del material empleado para el desarrollo. Se estipula el coste de amortización para un período de 3 años, utilizando un sistema de amortización lineal o constante. En este sistema, se supone que el inmovilizado material se deprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula haciendo uso de la siguiente fórmula

$$\text{Cuota de amortización anual} = \frac{\text{Valor de adquisición} - \text{Valor residual}}{\text{Nº de años de vida útil}}$$

Siendo el valor residual el valor teórico que se supone tendrá el elemento en cuestión después de su vida útil, teniendo en cuenta los índices de depreciación actual.

Para calcular el gasto derivado del uso del equipo se ha usado la siguiente fórmula:

$$A = \left( \frac{V_o - V_R}{T_A} \right) \cdot T_E$$

Donde

$A$  es la amortización

$V_o$  es el valor inicial

$V_R$  es el valor residual

$T_A$  es el tiempo de amortización (se considerará un valor fijo de años)

$T_E$  es el tiempo empleado

Puesto que la elaboración del proyecto ha supuesto ocho meses de trabajo y el cálculo del coste de amortización se estipula en un período de 3 años, los costes serán calculados como los derivados del primer año. En la tabla 2 se muestra el material necesario para la realización del proyecto, indicando en cada elemento su valor de adquisición, valor residual y coste de amortización.

TABLA P. 2: GASTOS DE AMORTIZACIÓN DEL HARDWARE

Concepto	Valor de adquisición	Valor residual a los 3 años	Coste de amortización anual
Ordenador de sobremesa	600 €	240 €	120 €
Impresora láser	180 €	126 €	18 €
Disco duro externo	90 €	36 €	18 €
Total en costes <i>hardware</i>			156 €

Por lo tanto, el coste total del material *hardware* es ciento cincuenta y seis euros.

### P.3 AMORTIZACIÓN DEL SOFTWARE

Para estimar la amortización del software empleado se procede de la misma manera que en la amortización *hardware*. Los costes se detallan en la siguiente tabla

TABLA P. 3: GASTOS DE AMORTIZACIÓN DEL SOFTWARE

Concepto	Valor de adquisición	Valor residual a los 3 años	Coste de amortización anual
Matlab R2010a	3900 €	0 €	1.300 €
Microsoft Office Profesional 2013	539 €	0 €	169,67 €
Microsoft Windows 7	135 €	0 €	45 €
Total en costes de software			1.514,67 €

El coste total del material *software* es mil quinientos catorce euros con sesenta y siete céntimos.

### P.4 REDACCIÓN DEL PROYECTO

El importe de la redacción del proyecto se calcula haciendo uso de la siguiente fórmula:

$$R = 0,007 \cdot P \cdot C_h$$

Donde

$R$  son los costes de redacción

$P$  es el presupuesto

$C_h$  es un coeficiente de ponderación

El presupuesto  $P$  se calcula sumando los subtotales calculados en los apartados anteriores.

*TABLA P. 4: COSTES DE REDACCIÓN*

Concepto	Coste
Trabajo tarifado por tiempo empleado	38.338,56 €
Amortización hardware	156 €
Amortización software	1.514,67 €
Presupuesto	40.009,23 €

El coeficiente de ponderación  $C_h$  es variable en función del presupuesto. Así, para proyectos cuyo presupuesto es menor a 42.070,70 euros, su valor es de 0,5. Por tanto, los costes de redacción resultan:

$$R = 0,007 \cdot P \cdot C_h = 0,07 \cdot 40009,23 \cdot 0,5 = 1.400,32 \text{ €}$$

Los costes del proyecto son mil cuatrocientos euros con treinta y dos céntimos.

## **P.5 DERECHOS DE VISADO**

Los derechos de visado del COIT se calculan con la siguiente expresión:

$$V = 0,006 \cdot P \cdot C_v$$

Donde

$P$  es el presupuesto del proyecto

$C_v$  es el coeficiente reductor en función del presupuesto del proyecto

El presupuesto  $P$  calculado hasta el momento asciende a

$$P = 40.009,23 \text{ €} + 1.400,32 \text{ €} = 41.409,55 \text{ €}$$

Como el coeficiente  $C_v$  para presupuestos de más de 30.050 € y menos de 60.101 € viene definido por el COIT con un valor de 0,9, el coste de los derechos de visado del proyecto asciende a

$$V = 0,006 \cdot P \cdot C_v = 0,006 \cdot 41.409,55 \cdot 0,9 = 223,60 \text{ €}$$

Los derechos de visado son doscientos veintitrés euros con sesenta céntimos

## **P.6 GASTOS DE TRAMITACIÓN Y ENVÍO**

Los gastos de tramitación y envío son fijos y se estipulan en 6,01 € (seis euros con un céntimo).

## **P.7 APLICACIÓN DE IMPUESTOS**

El importe del presupuesto lleva implícito el importe del IGIC. Para esta actividad económica, el IGIC grava con un 7 %. El presupuesto calculado hasta el momento asciende a:

$$P = 41.409,55 \text{ €} + 223,60 \text{ €} + 6,01 \text{ €} = 41.639,16 \text{ €}$$

Por lo tanto, el impuesto es de  $41.639,16 \text{ €} \cdot 0,07 = 2.914,74 \text{ €}$

**P.8 IMPORTE FINAL**

El coste final del proyecto se calcula sumando los subtotales calculados en los apartados anteriores

*TABLA P. 5 : IMPORTE FINAL*

<b>Concepto</b>	<b>Coste</b>
Trabajo tarifado por tiempo empleado	38.338,56 €
Amortización <i>hardware</i>	156,00 €
Amortización <i>software</i>	1.514,67 €
Redacción del proyecto	1.400,32 €
Derechos de visado del COITT	223,60 €
Gastos de tramitación y envío	6,01 €
Total sin IGIC	41.639,16 €
IGIC	2.914,74 €
<b>TOTAL</b>	<b>44.553,90 €</b>

Por tanto, el coste final de este proyecto final de carrera asciende a CUARENTA Y CUATRO MIL QUINIENTOS CINCUENTA Y TRES EUROS CON NOVENTA CÉNTIMOS.

Fdo.: Raquel Plata Pérez

En las Palmas de Gran Canaria, marzo de 2017