

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA
INFORMÁTICA
GRADO EN INGENIERÍA INFORMÁTICA (TECNOLOGÍA DE
LA INFORMACIÓN)

**DIAGNOSTICO AUTOMÁTICO DE PATOLOGÍAS
CARDÍACAS DE BLOQUEO**
**AUTOMATIC DIAGNOSIS OF HEART DISEASES BRANCH
BLOCK**

Realizado por
Emilio Tenorio Serrano
Tutorizado por
José Ignacio Peláez Sánchez
Departamento
Lenguajes y Ciencias de la Computación

UNIVERSIDAD DE MÁLAGA
MÁLAGA, Febrero 2016

Fecha defensa:
El Secretario del Tribunal

Resumen: Los electrocardiogramas (ECG) registran la actividad eléctrica del corazón a través de doce señales principales denominadas derivaciones. Estas derivaciones son analizadas por expertos médicos observando aquellos segmentos de la señal eléctrica que determinan cada una de las patologías que pueden afectar al corazón. Este hecho en general, es un condicionante muy importante para el diseño de sistemas expertos de diagnóstico médico, ya que es preciso conocer, delimitar y extraer de la señal eléctrica aquellos segmentos que determinan la patología. Dar solución a estos problemas, sería fundamental para facilitar el diseño de sistemas expertos para el diagnóstico de enfermedades cardiacas. El objetivo de este trabajo es demostrar que es posible identificar patologías cardiacas analizando la señal completa de las diferentes derivaciones de los ECGs, y determinar puntos concretos que determinan la patología en lugar de segmentos de la señal. Para ello se ha utilizado una BBDD de electrocardiogramas y se ha determinado mediante un algoritmo, los puntos de la señal que determinan la patología. Se ha aplicado a la patología de bloqueos de rama y los puntos obtenidos con el algoritmo se han utilizado para el diseño de un clasificador automático basado en redes neuronales artificiales, obteniendo un coeficiente de sensibilidad del 100% y de especificidad del 99.24%, demostrando su validez para el diseño de sistemas expertos de clasificación.

Palabras claves: Bloqueos de Rama, ECG, Wavelet, FWT, Fourier, DFT, FFT, PCA

Abstract: The electrocardiogram (ECG) records the electrical activity of the heart through twelve major signs referred leads. These derivations are analyzed by medical experts watching those segments of the electrical signal that determine each of the pathologies that can affect the heart. This is generally very important for the design of medical diagnostic expert systems constraint, since it is necessary to know, identify and extract the electrical signal segments that determine the pathology. To solve these problems, it would be essential to facilitate the design of expert systems for diagnosing heart disease. The aim of this paper is to demonstrate that it is possible to identify heart diseases by analyzing the entire signal of the different leads of ECGs, and determine specific points that determine the pathology rather than segments of the signal. For this we have used a DB electrocardiograms and determined by an algorithm, the signal points that determine the pathology. It has been applied to the pathology branch block and the points obtained with the algorithm used for the design of an automatic classifier based on artificial neural networks, obtaining a coefficient of sensitivity of 100% and specificity of 99.24%, demonstrating validity for designing expert systems classification.

Keywords: branch block, ECG, Wavelet, FWT, Fourier, DFT, FFT, PCA

Índice de Contenido

I.	Introducción	9
1.	Anatomía General Del Corazón	10
2.	El Ciclo Cardíaco	12
3.	El Electrocardiograma.....	15
4.	Objetivos y Estructura de la Memoria del Trabajo de Fin de Grado	20
II.	Fundamentos Teóricos de las Transformadas.....	21
1.	Introducción	21
2.	Transformada de Fourier	22
3.	Transformada Wavelet	23
4.	Componentes Principales	25
III.	Análisis Comparativo de Modelos Propuestos.....	27
1.	Introducción	27
2.	Extracción de Características	29
3.	Resultados del Entrenamiento.....	31
4.	Descripción de las magnitudes utilizadas.....	35
4.1.	Matriz de Confusión	38
4.2.	Curvas ROC.....	40
5.	Comparativa de los Resultados Obtenidos con las Diferentes Técnicas.....	41
6.	Comparativa de Complejidad de la Red Utilizada	42
IV.	Conclusiones	45

Referencias	47
Anexos	51
Índice de Figuras	51
Índice de Tablas.....	51

I. Introducción

Las enfermedades cardiovasculares son un conjunto de patologías y dolencias diversas en sus manifestaciones clínicas a través del aparato circulatorio, representando un problema de salud por ser la manifestación más frecuente en los padecimientos crónicos.

En general, para medir y estimar la frecuencia de una enfermedad se utilizan los indicadores de morbilidad, letalidad y mortalidad. La morbilidad se determina en función de las estadísticas de ingreso y egreso o alta en los hospitales de cuadros agudos, mientras que la letalidad surge como la razón de pacientes que fallecen por causa de una enfermedad, y la mortalidad se calcula a partir de los certificados de defunción como una estadística vital para determinar las causas de muerte. Pero la ciencia hoy nos indica que los problemas de salud son tratables si se realizan intervenciones efectivas, tanto para su prevención como para su tratamiento.

Las enfermedades de origen cardiovascular son la primera causa global de mortalidad en el mundo occidental, causando cerca de 4.3 millones de muertes anuales en Europa con un impacto económico que asciende a más de 192 billones de euros anuales (Figura 1).

En la actualidad el electrocardiograma (ECG) es un examen necesario en el diagnóstico de problemas cardiacos, el cual ayuda al doctor tratante a dar un diagnóstico acerca de la dolencia cardiaca del paciente. Este examen se realiza generalmente en centros de Salud y Hospitales, siendo una herramienta de diagnóstico fundamental, para hacer frente y dar seguimiento a las diferentes patologías cardiovasculares.

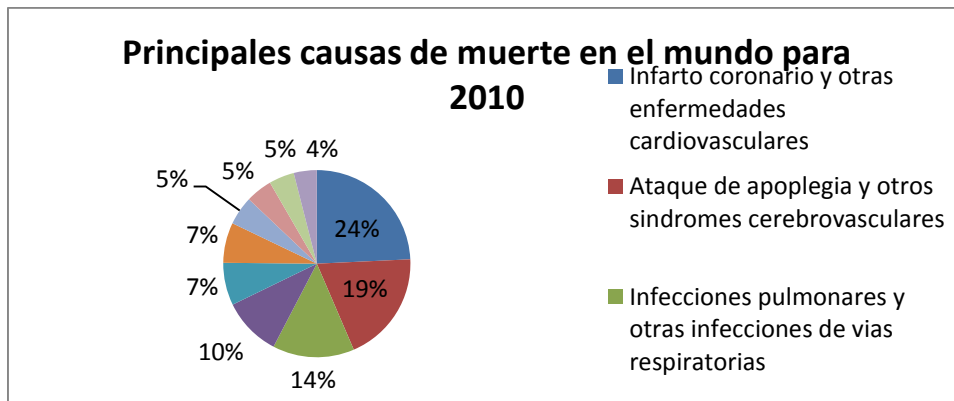


Figura 1. Principales causas de muerte en el mundo. Fuente: Organización Mundial de la Salud (OMS)

El electrocardiograma (ECG), al ser un procedimiento sencillo, rápido y de bajo costo, permite medir el ritmo y la regularidad de los latidos, así como el tamaño y posición de las aurículas y ventrículos para la determinación de cualquier daño al corazón y los efectos que sobre él tienen las drogas. Una gran ventaja se determina por ser una herramienta no invasiva y es utilizada como instrumento de diagnóstico estándar. En un ECG las patologías se manifiestan como secuencias de latidos con distribución anormal o morfología alterada, por lo tanto un paso importante para identificar una patología cardiovascular es la clasificación de las mismas basada en un correcto análisis del trazado electrocardiográfico. Las características del ECG pueden ser tomadas en cuenta como entradas para un clasificador de patologías, tales como el tiempo y la morfología.

La clasificación y diagnóstico de las patologías cardiovasculares es una tarea que requiere mucho tiempo y experiencia, por consiguiente, cualquier procesamiento automatizado del ECG que contribuya a este proceso será muy útil.

A continuación se va a realizar un breve estudio de aquellos aspectos que serán de utilidad para afrontar el resto de capítulos del presente trabajo de fin de grado. Para ello en primer lugar se mostrará la anatomía general de corazón; en segundo lugar el ciclo cardiaco y finalizaremos viendo que es el electrocardiograma.

1. Anatomía General Del Corazón

El corazón es un órgano muscular hueco, del tamaño de un puño cerrado, situado en el centro de la cavidad torácica y encerrada en un saco de tejido conectivo, el pericardio. Dentro de este saco existe una pequeña cantidad de líquido que facilita los movimientos

de deslizamiento de las dos hojas del pericardio, una que recubre la superficie cardíaca y otra en relación con los órganos que rodean al corazón. El corazón es un músculo con una enorme fuerza de contracción, que actúa como una verdadera bomba. Cuando el corazón se contrae, la cavidad interna se reduce, la presión de la sangre en su interior aumenta y la sangre es expulsada. Para que la presión se pueda traducir en un aporte adecuado de sangre requerido por los tejidos se necesita también velocidad y sincronización.

El corazón de los vertebrados está dividido en cámaras, las aurículas y los ventrículos. En el sistema circulatorio de los vertebrados, se puede observar una separación más completa entre la circulación que irriga los pulmones, circulación pulmonar, y la que abastece al resto del organismo, circulación sistémica (Curtis & Schnek, 2008). En los mamíferos, el corazón está dividido por un tabique muscular en dos mitades, una derecha y otra izquierda, y cada una de éstas se compone de dos cavidades, una aurícula, de paredes delgadas, que recibe la sangre que viene de las venas y la envía al ventrículo correspondiente, el cual la expulsa hacia la periferia. Del ventrículo izquierdo, cuyas paredes son de un espesor mayor que las del derecho, parte un grueso vaso arterial, la aorta, que se dirige hacia arriba curvándose luego hacia atrás y hacia abajo, para formar un arco y cruzar el tórax penetrando en el abdomen. En todo su trayecto se desprenden arterias, que se ramifican en arteriolas, más pequeñas, distribuidas en todo el cuerpo. Las últimas ramificaciones terminan en una verdadera red de vasos de muy pequeño calibre y de paredes delgadas, los capilares, nombre que indica que su calibre es comparable al de un cabello. Estos se van uniendo entre sí para formar las venas. Las venas de la mitad inferior del cuerpo desembocan en la vena cava inferior, y las de la cabeza, cuello y miembros superiores, en la vena cava superior. Ambas venas cavas conducen la sangre a la aurícula derecha, de donde pasa luego al ventrículo derecho. Del ventrículo derecho pasa hacia la arteria pulmonar que se divide en dos ramas, izquierda y derecha, destinadas a cada uno de los pulmones. Las arterias también se ramifican y terminan en capilares cuya sangre pasa a las venas que desembocan en la aurícula izquierda que comunica con el ventrículo izquierdo (Figura 2).

Cada aurícula está separada del ventrículo correspondiente por una válvula que permite el paso de sangre de la aurícula hacia el ventrículo, pero no en sentido contrario. La

válvula aurículoventricular derecha se denomina válvula tricúspide, mientras que la izquierda válvula mitral. En el nacimiento de la aorta y de la arteria pulmonar existen válvulas, denominadas semilunares, que impiden el retorno de la sangre de las arterias hacia el corazón.

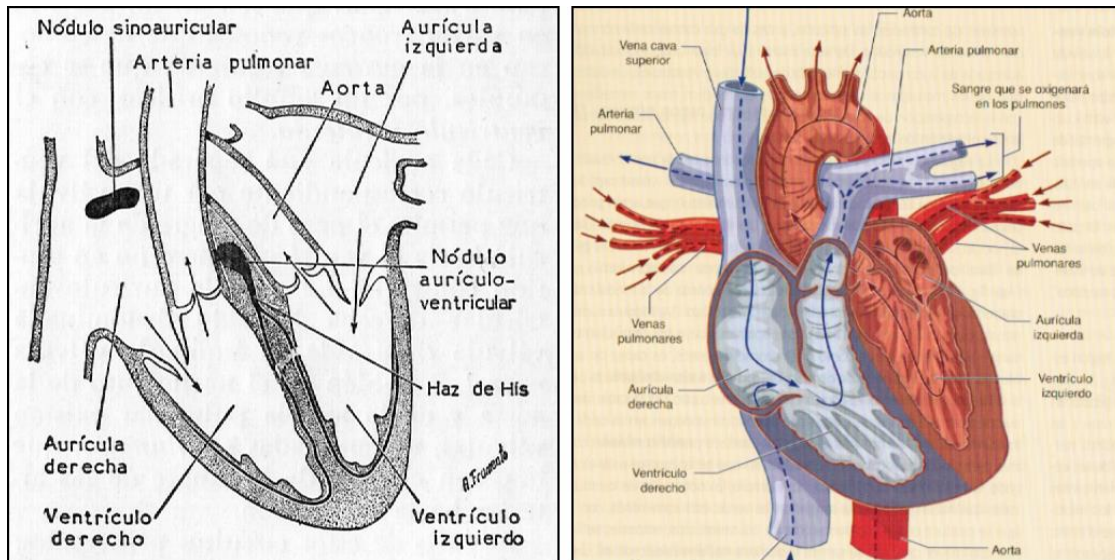


Figura 2. Disposición de las válvulas aurículoventriculares y sigmoideas

El músculo cardíaco responde a un estímulo eléctrico, nervioso o mecánico con una contracción. Los estímulos débiles no provocan respuesta, pero una vez que alcanzan cierta intensidad, al sobrepasar el umbral, se produce una respuesta. La contracción resultante es máxima ya que por más que se aumente la intensidad del estímulo no se conseguirá un aumento de la intensidad de la contracción. Esto es lo que se llama la ley del todo o nada, ya que tanto la fibra muscular estriada como las fibras miocárdicas responden y el corazón se contrae en su totalidad. El músculo cardíaco no responde a estímulos que le llegan cuando está contraído ya que en ese período es refractario a los estímulos.

2. El Ciclo Cardíaco

En condiciones fisiológicas la actividad del corazón comienza al difundirse por las aurículas el estímulo eléctrico originado en el nódulo sinusal. Las aurículas se contraen, haciendo pasar sangre a través de los orificios aurículoventriculares. Cuando a través del haz de His llega el estímulo a los ventrículos, se contraen y comienza la sístole ventricular. La primera consecuencia de la contracción ventricular es el cierre de las

válvulas aurículoventriculares, lo que impide el regreso de la sangre a las aurículas. Las válvulas, que guardan los orificios de las arterias pulmonares y aorta, se abrirán cuando la presión de los ventrículos sobrepase el valor de la presión existente en las arterias, comenzando entonces la expulsión de sangre. Al terminar la sístole ventricular y comenzar la relajación ventricular, diástole ventricular, disminuye la presión dentro de los ventrículos. Cuando ésta es menor que la que existe en la aorta y la arteria pulmonar, las válvulas semilunares se cierran impidiendo el paso de sangre del sistema arterial a los ventrículos. La presión en los ventrículos sigue disminuyendo y, cuando es menor que la presión que reina en las aurículas, se abren las válvulas aurículoventriculares, dejando pasar a los ventrículos la sangre contenida en los grandes troncos venosos y en las aurículas. Al reiniciarse el ciclo con la contracción auricular, los ventrículos están casi llenos de sangre (Figura 3).

La actividad cardíaca produce manifestaciones que pueden ser percibidas por la vista y el tacto, latidos del tórax, y el oído, ruidos cardíacos. En la mayor parte de las personas se percibe al nivel del 4° o 5° espacio intercostal un latido o choque que coincide con la iniciación de la sístole ventricular y que se siente aún mejor estando el sujeto acostado sobre el lado izquierdo. En cada ciclo cardíaco se oyen indistintamente dos ruidos, el primero al comenzar y el segundo al terminar la sístole ventricular. El cierre brusco de las válvulas aurículoventriculares al comenzar la sístole ventricular, junto con vibraciones debidas a la contracción del músculo cardíaco y al paso de sangre a través de los orificios aórtico y pulmonar son los factores principales del primer ruido; mientras que el cierre brusco de las válvulas sigmoideas aórticas y pulmonares, al comenzar la relajación ventricular, es la causa del segundo ruido.

En el corazón, los fenómenos eléctricos se ponen de manifiesto por tratarse de una masa muscular voluminosa que se contrae casi simultáneamente en su totalidad. La corriente eléctrica desarrollada por el corazón se propaga a los tejidos vecinos y puede ser recogida en la superficie del cuerpo. En un momento dado de la sístole, cuando la parte superior del corazón está en actividad, los brazos del sujeto tendrán un potencial más negativo que las piernas. Si se conecta el brazo derecho y la pierna izquierda con un aparato registrador de corrientes eléctricas se captarán las variaciones de potencial correspondiente a las distintas fases de la actividad cardíaca. Este dispositivo se conoce como electrocardiograma y en general cualesquiera que sean los puntos desde los cuales

se obtenga el registro, se observan en el trazado tres ondas positivas y tres ondas negativas, designadas con las letras P, Q, R, S y T. El comienzo de la onda P indica el comienzo de la sístole auricular. El comienzo del grupo de ondas denominadas Q, R y S, indica el comienzo de la actividad ventricular, y el fin de la onda T coincide, aproximadamente, con el fin de la sístole ventricular (Figura 3) (Jackon, 1956).

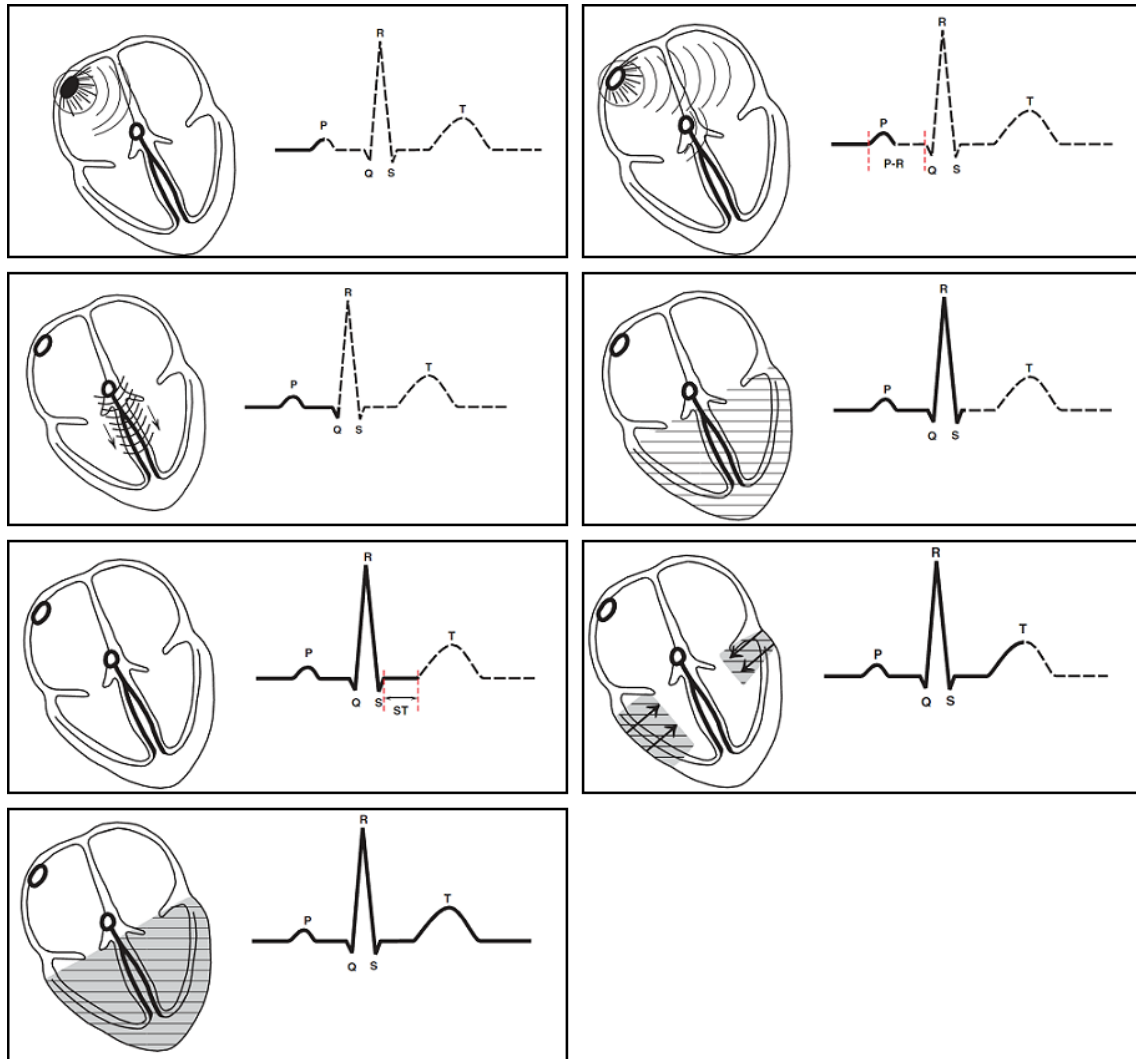


Figura 3. Variaciones eléctricas y de presión en el corazón. (Curtis & Schnek, 2008)

El latido del corazón de mamífero está controlado por una región especializada de la aurícula derecha, el nódulo sinoauricular formado por células musculares cardíacas modificadas que producen potenciales de acción de manera espontánea y rítmica. Los impulsos nerviosos producidos se conducen con rapidez hacia el resto de las células musculares auriculares y de esta manera el nódulo sinoauricular impone el ritmo cardíaco al actuar como un marcapasos. Un segundo conglomerado de células, el nódulo aurículoventricular, controla la conducción hacia los ventrículos de las

corrientes eléctricas auriculares a través del haz de His y sus ramas. La sincronización adecuada de la contracción alternada de aurículas y ventrículos regula el ritmo de la contracción cardíaca. La regulación nerviosa del latido cardíaco es ejercida por el sistema nervioso autónomo, tanto simpático como parasimpático que actúa principalmente sobre los nódulos. Las fibras simpáticas estimulan el nódulo sinoauricular y así la frecuencia cardíaca aumenta, mientras que las fibras parasimpáticas lo inhiben y la frecuencia cardíaca disminuye (Figura 4) (Curtis & Schnek, 2008).

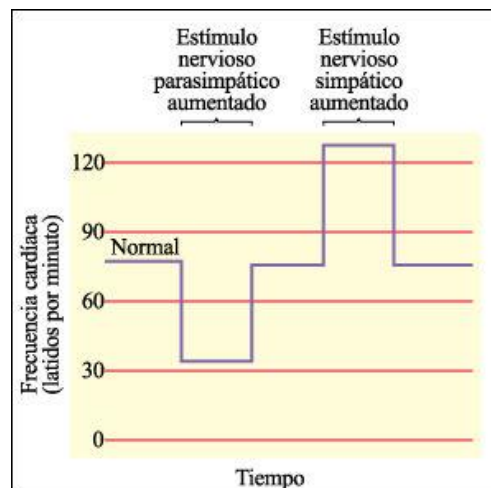


Figura 4. Regulación autónoma de la frecuencia del latido cardíaco. (Curtis & Schnek, 2008)

3. *El Electrocardiograma*

En 1790, una audiencia de científicos fue asombrada con incredulidad cuando Luigi Galvani hizo contraer los músculos de las ancas de una rana muerta por medio de estímulos eléctricos.

Mientras hacían investigación básica alrededor de 1855, Kollicker y Mueller encontraron que cuando un nervio motor de un anca de rana era colocado sobre su corazón aislado y latiendo, el anca pateaba con cada latido cardíaco. Dedujeron que el mismo estímulo eléctrico que causa el patear del anca de la rana debía causar el latido del corazón. Entonces era lógico para ellos asumir que los latidos del corazón deben ser causados por una descarga rítmica de estímulo eléctrico biológico. Y así fue como la asociación entre el bombeo rítmico del corazón y el fenómeno eléctrico fue científicamente establecido.

A mediados de 1880, mientras usaban un electrómetro capilar, Ludwig y Waller descubrieron que el estímulo eléctrico rítmico del corazón puede ser monitoreado desde la piel de una persona. Este aparato consistía de un electrodo sensor que era colocado sobre la piel de un hombre y conectado al electrómetro capilar de Lippman, el cual usaba un tubo capilar en un campo eléctrico para detectar una leve actividad eléctrica. El nivel del fluido en el tubo capilar se movía con el ritmo del latido del corazón del sujeto. Este aparato no fue tan sofisticado para aplicaciones clínicas, pero fue interesante para determinar los principios eléctricos del corazón humano.

En la investigación realizada por el Dr. Willem Einthoven, un científico brillante, que conectó dos sensores (electrodos) a los extremos de un alambre de plata, el cual pasaba entre los dos polos de un magneto, sobre la piel de un hombre. El alambre de plata, en el campo magnético, se movía al ritmo del latido cardíaco del sujeto. Esto fue también muy interesante, pero Einthoven quería un registro medible.

Entonces Einthoven proyectó un pequeño rayo de luz a través de unos agujeros en los polos del magneto, cruzando el alambre de plata en movimiento. Los movimientos rítmicos del alambre fueron registrados como ondas (que él llamó P, QRS y T) en un pergamino de papel fotográfico en movimiento. El movimiento rítmico del alambre, representando el latido cardíaco, creaba una sombra que saltaba y era registrado como una serie rítmica de ondas distintivas en ciclos repetitivos. A partir de ese momento se pudo registrar una actividad eléctrica de un corazón anormal y compararla con uno normal. Y así fue como la gran herramienta para diagnóstico, el electrokardiograma (ElectroKardioGramma), evolucionó alrededor de 1901 (Figura 5).




Figura 5. Elementos básicos iniciales que componen el electrocardiograma.

El electrocardiograma (ECG) registra la actividad eléctrica del corazón, proporcionando un registro de la actividad cardíaca eléctrica, así como también información valiosa acerca de la función y estructura del corazón. El electrocardiograma es conocido por el acrónimo ECG. Desde los tiempos del electrokardiograma de Einthoven, la profesión médica ha usado las letras EKG (derivada por el vocablo utilizado en alemán) para representar el electrocardiograma. A fines de evitar confusión, en este trabajo se usarán las letras ECG para referirnos al electrocardiograma. El ECG se documenta en una cinta de papel graficada que nos da un registro permanente de la actividad cardíaca y del estado de salud del corazón. Los monitores cardíacos y de telemetría cardíaca proporcionan la misma información en tiempo real.

El ECG es el registro gráfico de los potenciales eléctricos generados por el corazón. Las señales se reciben a través de electrodos metálicos que se adhieren a las extremidades y la pared torácica y posteriormente se amplifican y registran con el electrocardiógrafo. Las derivaciones del ECG reciben las diferencias instantáneas de potencial entre estos electrodos. La utilidad clínica del ECG se deriva de su disponibilidad inmediata como técnica incruenta, económica y sumamente versátil. Además de identificar arritmias, alteraciones de la conducción e isquemia miocárdica, la electrocardiografía revela datos relacionados con alteraciones metabólicas que ponen en peligro la vida del enfermo o aumentan la predisposición a la muerte cardíaca súbita. El ECG sólo registra los potenciales de despolarización y repolarización generados por el miocardio auricular y ventricular. La mayoría de estas enfermedades se manifiestan como secuencias de latidos con un fallo temporal o con una diferencia en la morfología de la señal.

El interior de las células de los músculos del corazón, miocitos, son negativas, están polarizadas o en reposo, pero cuando son despolarizadas el interior de las células se vuelven positivas y los miocitos se contraen. Cuando una onda de despolarización viaja a través del corazón, ésta causa contracciones del miocardio. La onda de despolarización y la fase de repolarización que le sigue, son registradas en el ECG como se muestra en la Figura 6 (Dubin, 2007).

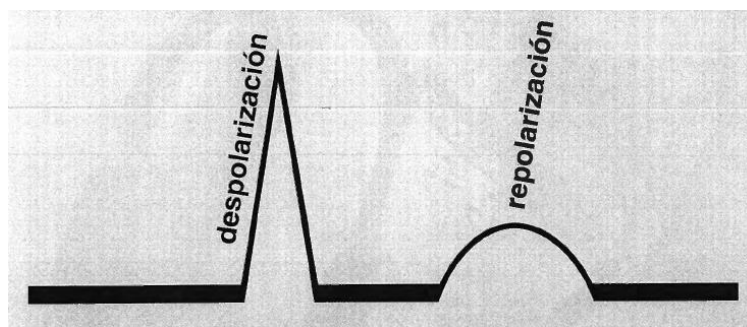


Figura 6. Elementos básicos iniciales que componen el electrocardiograma. (Dubin, 2007)

Los sensores, llamados electrodos, son aplicados sobre la piel para detectar la actividad eléctrica del corazón. La máquina de ECG registra esta actividad sobre un papel en movimiento y produce el electrocardiograma. Las 12 derivaciones convencionales del ECG registran la diferencia de potencial entre los electrodos colocados en la superficie de la piel. Estas derivaciones se dividen en dos grupos, seis derivaciones de las extremidades y seis precordiales o torácicas (Figura 7).

Las derivaciones de las extremidades registran los potenciales que se refieren al plano frontal, mientras que las precordiales recogen los potenciales del plano horizontal. Las seis derivaciones de las extremidades se subdividen a su vez en tres derivaciones bipolares (I, II y III) y tres unipolares (aVR, aVL y aVF). Cada derivación estándar mide la diferencia de potencial entre los electrodos de dos extremidades, derivación I, voltaje de la extremidad superior izquierdo-derecho; derivación II, extremidad inferior izquierda-extremidad superior derecha; derivación III, extremidad inferior izquierda-extremidad superior izquierda. Las derivaciones unipolares miden el voltaje (V) en un determinado lugar con respecto a un electrodo, denominado electrodo central o indiferente, que tiene un potencial de aproximadamente cero. La letra minúscula a indica que estos potenciales unipolares tienen un incremento eléctrico de 50%. VR es la

extremidad superior derecha, VL es la extremidad superior izquierda y VF es la extremidad inferior izquierda. El electrodo del pie derecho actúa como tierra (Figura 7).

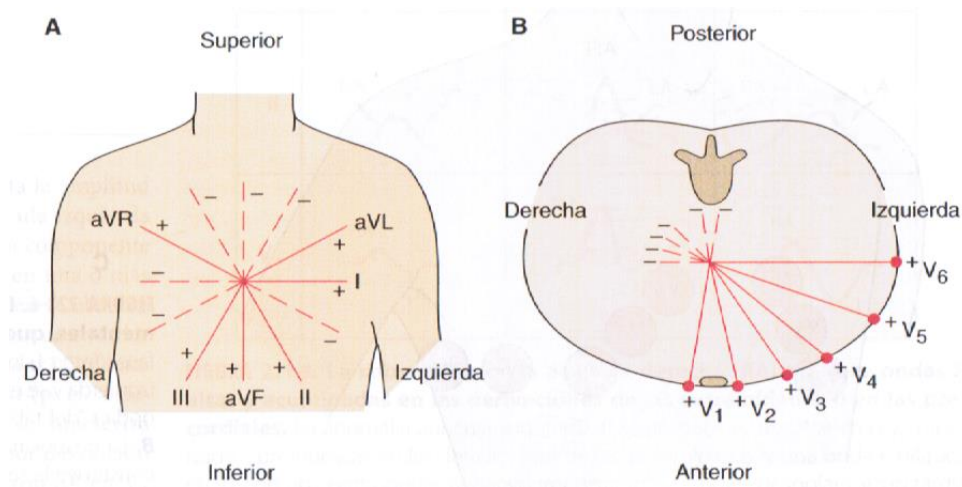


Figura 7. Derivaciones del plano frontal (A) y del plano horizontal (B). (Curtis & Schnek, 2008)

Las ondas del ECG se designan con las letras del alfabeto, comenzando por la letra P, que representa la despolarización auricular. El complejo QRS representa la despolarización ventricular y el complejo ST-T la repolarización ventricular. Un ciclo cardíaco es representado por la onda P, el complejo QRS, la onda T y la línea basal que continúa hasta cuando otra onda P aparece. Este ciclo se repite continuamente (Fauci, Kasper, Longo, Braunwald, Hauser, & Jameson, 2009).

El electrocardiograma suele registrarse en un papel milimétrico especial que se divide en cuadros de 1 mm². Puesto que la velocidad de registro del ECG sobre el papel suele ser de 25 mm/s, la división horizontal más pequeña (1 mm) corresponde a 0.04 s (40 ms), mientras que las líneas más gruesas equivalen a 0.20 s (200 ms). En la vertical, la gráfica del ECG mide la amplitud de determinada onda o deflexión (1 mV = 10 mm con la calibración normalizada). El intervalo PR (normal: 120 a 200 ms) indica el tiempo transcurrido entre las despolarizaciones auricular y ventricular, lo que incluye el retraso fisiológico derivado del estímulo de las células de la unión aurículoventricular. El intervalo QRS (normal: 100 a 110 ms o menos) refleja la duración de la despolarización ventricular. El intervalo QT comprende tanto a la despolarización como a la repolarización ventriculares y varía de manera inversamente proporcional a la frecuencia cardíaca.

4. Objetivos y Estructura de la Memoria del Trabajo de Fin de Grado

La detección de anomalías en el corazón es una tarea compleja. El uso del electrocardiograma permite la captura de la información eléctrica que produce el corazón y mediante la experiencia médica basada en métodos clásicos se puede aproximar al estudio de patologías cardíacas. Pero la interpretación del ECG por parte de una persona sin o con poca experiencia en la interpretación de los electrocardiogramas resulta una tarea sumamente complicada (Korürek & Nizam, 2008). Estudios realizados muestran que un profesional cualificado tiene una tasa de acierto alrededor del 95%, mientras que esa tasa disminuye al 55% en profesionales médicos no especializados. Es por ello, que el objetivo principal de este trabajo de fin de grado, es el diseño y análisis de la extracción de los puntos característicos de ECG, y la implementación de un clasificador basado en redes neuronales artificiales para la clasificación de ECG, concretamente, para la patología de bloqueos de rama. Para ello la memoria ha sido organizada en tres capítulos, como sigue:

En el capítulo II se realiza un estudio exhaustivo de las transformadas que son utilizadas para la extracción de las características de la señal eléctrica para la patología de bloqueos. Para ello, se han seleccionado la transformada discreta de Fourier, la transformada Wavelet, esta última con distintas funciones de escalado ϕ y wavelets ψ , y la transformación en Componentes Principales.

En el capítulo III se propone un clasificador basado en redes neuronales artificiales para la patología de bloqueos. Para llevar a cabo el entrenamiento del sistema neuronal se han utilizado 789 ECGs, de los cuales 127 corresponden a la patología a detectar, bloqueo de rama. En este caso, se determina una secuencia de 870 puntos por cada derivación de cada ECG, aplicando el algoritmo de extracción de características para obtener los puntos representativos en función de la patología y que luego se utilizan como entrada para el entrenamiento de diversas topologías de redes neuronales artificiales (RNA).

Finalmente en el capítulo IV se exponen las conclusiones que se derivan de esta memoria.

II. Fundamentos Teóricos de las Transformadas

1. Introducción

En el presente capítulo se van a analizar en profundidad las diferentes transformadas que serán utilizadas para la extracción de características de la señal de los ECG para la clasificación de los Bloqueos. Para ello el capítulo ha sido organizado como sigue: en primer lugar se realiza una introducción a la transformada de Fourier; en segundo lugar se presenta la transformada wavelet y el análisis de multiresolución; y en tercer lugar se presentará el Análisis de Componentes Principales.

Diferentes métodos han sido propuestos en la literatura para la extracción de características para sistemas automáticos de clasificación de ECGs. Estos métodos pueden ser clasificados en: (1) métodos basado en la morfología de la señal (Benali, Bereksi Reguig, & Hadj Slimane, 2012; de Chazal, O'Dwyer, & Reilly, 2004; He, Hou, Zhen, & Peng, 2006; Hosseini, Luo, & Reynolds, 2006; Jekova, Bortolan, & Christov, 2008a; Korürek & Doğan, 2010), que consisten en obtener distintas medidas tanto de tiempo como de tensión; (2) métodos estadísticos (Ceylan & Özbay, 2007; Ge, Srinivasan, & Krishnan, 2002; S.-N. Yu & Chou, 2009) aplicando distintas técnicas como Análisis Autoregresivo, que es uno de los análisis más exitoso, flexibles, y fácil de usar para el análisis de series de tiempo multivariante, por medio de la identificación de correlaciones o el Análisis de Componentes Independientes, que es una técnica estadística y computacional que revela factores ocultos que están debajo de conjuntos de variables aleatorias, medidas o señales; métodos basado en el procesamiento de la señal (Dokur & Ölmez, 2001; Khorrami & Moavenian, 2010; Martis et al., 2012; Ocak, 2009; Özbay, Ceylan, & Karlik, 2011), que es un área de la ingeniería que aplica métodos matemáticos que se ocupan de hacer un análisis de la señal, tanto de forma discreta como continua en el tiempo. El dominio en el cual se procesa la señal es elegido de manera que mejor represente las características esenciales de la señal; métodos basados en autovectores (Übeyli, 2009), que son usados para estimar frecuencias y potencias de señales desde medidas noise-corrupted; y finalmente, métodos basados en expansiones

polinómicas de hermite (Lagerholm, Peterson, Braccini, Edenbrandt, & Sörnmo, 2000; Osowski & Stodolski, 2003), que son secuencias polinómicas ortogonales que surgen en probabilidad, en combinatoria, en análisis numérico y en física.

2. *Transformada de Fourier*

El análisis de Fourier se desarrolló durante un largo período de tiempo y en él intervinieron una gran cantidad de científicos mediante investigaciones sobre fenómenos físicos muy variados. Jean Baptiste Joseph Fourier encontró que cualquier señal periódica se podía representar mediante series de senoides relacionadas armónicamente; además obtuvo una representación de señales no periódicas como integrales ponderadas de senoides que no están armónicamente relacionadas, extendiendo las series de Fourier a la integral o transformada de Fourier.

La transformada de Fourier es una transformación matemática empleada para transformar señales entre el dominio del tiempo (o espacial) y el dominio de la frecuencia. Es una función reversible, que permite transformaciones de cualquiera de los dominios al otro.

Para determinar el espectro de una secuencia finita se utiliza en la práctica una técnica conocida como transformada discreta de Fourier (DFT, Discrete Fourier Transform). Si se tiene una secuencia causal y finita $x[n] = (x_1, x_2, \dots, x_M)$ que contiene M elementos, la DFT se expresa como

$$y_k = \sum_{p=0}^{N-1} x[p]e^{-j2\pi kp/N} \quad k = 0, \dots, N - 1 \quad (2.1)$$

donde $N \geq M$ se conoce como tamaño de la DFT y $\omega_0 = 2\pi/N$ como resolución de frecuencia. Estos N puntos están igualmente espaciados en el rango $[0, 2\pi)$. La secuencia $y[n]$ es periódica de período 2π , y si es real, su magnitud es una función par y su argumento es una función impar.

La ecuación de síntesis se expresa como

$$x[n] = \frac{1}{N} \sum_{k=0}^{N-1} y_k e^{j2\pi kn/N} \quad n = 0, \dots, N-1 \quad (2.2)$$

que constituye una secuencia periódica en n con período N , dado que se considera como un período de su extensión periódica.

El algoritmo usado para el cálculo de la DFT se conoce como transformada rápida de Fourier (FFT, Fast Fourier Transform), y consiste básicamente en dividir la DFT de N puntos en dos DFT de $N/2$ puntos, una para la subsecuencia de índices pares y otra para la de índices impares; a continuación, cada DFT de $N/2$ puntos se vuelve a dividir en otras dos DFT de $N/4$ puntos, continuando el proceso hasta obtener DFTs de 2 puntos. Este proceso se simplifica notablemente si la secuencia consta de $N = 2^s$ elementos. El esfuerzo computacional se reduce a N productos complejos y N sumas complejas, frente a los N^2 productos y $N(N-1)$ sumas de la resolución directa.

3. Transformada Wavelet

Desde 1982, cuando Jean Morlet propuso la idea de la transformada wavelet, han sido muchas las personas que han aplicado esta técnica en diversos campos, tal como la supresión de ruido, compresión de imágenes o dinámica molecular. Las Wavelet son una familia de funciones generadas a partir de translaciones y dilataciones de una función fija denominada “wavelet madre”. Esta transformada puede considerarse como una extensión de la clásica transformada de Fourier, la cual, además de tener en cuenta el dominio de la frecuencia, trabaja también con el tiempo.

El análisis wavelet se ha introducido como una técnica de ventana con regiones de tamaño variable. Las transformadas Wavelet pueden considerarse como representaciones de formas tiempo-frecuencia de señales continuas, e introduce la noción de la escala como una alternativa a la frecuencia, mapeando la señal en un plano tiempo-escala. Cada escala en este plano corresponde a un cierto rango de frecuencias en el plano tiempo-frecuencia. Este análisis se basa en la descomposición de una señal en una versión desplazada y escalada de la wavelet original mientras que en el análisis mediante Fourier la señal es descompuesta en senos y cosenos de diferentes frecuencias.

La transformada wavelet se obtiene a partir de la expresión

$$W_f(a, b) = \frac{1}{\sqrt{a}} + \int_{-\infty}^{\infty} f(t)\Psi\left(\frac{t-b}{a}\right) dt \quad (2.3)$$

La transformada discreta de Wavelet captura la información de la frecuencia y del tiempo como la transformada continua, con la diferencia de usar wavelets discretamente muestreadas. En este trabajo se va a utilizar la Fast Wavelet Transform (FWT) que es una alternativa a la transformada rápida de Fourier (FFT) por dos motivos: el cómputo de una FWT de N puntos tiene una complejidad lineal $O(n)$ y captura ambos componentes de información de la señal tanto en el dominio de la frecuencia como componentes del dominio temporal.

Tal y como se muestra en la Figura 8, la transformada discreta wavelet puede ser implementada como una serie de filtros. En primer lugar las muestras ($x[n]$) pasan a través de un filtro paso bajo con un impulso de respuesta $g[n]$, lo que resulta en una convolución de las dos señales, y simultáneamente, las muestras pasan a través de un filtro paso alto con un impulso de respuesta $h[n]$

$$Y_{low}[n] = (s * g)[n] = \sum_{k=-\infty}^{\infty} s[k]g[n - k] \quad (2.4)$$

$$Y_{high}[n] = (s * h)[n] = \sum_{k=-\infty}^{\infty} s[k]h[n - k] \quad (2.5)$$

Tal y como muestra el teorema de Nyquist's, la mitad de las frecuencias de la señal han sido eliminadas, por lo que la mitad de las muestras pueden ser descartadas, disminuyendo entre dos la salida de los filtros.

El cálculo de los coeficientes wavelets en cada uno de estos pasos requiere de un gran tiempo computacional, y generaría un gran volumen de datos. Sin embargo, solo se necesita un subconjunto de las escalas y posiciones, las basadas en potencias de dos. Estos coeficientes c_{jk} vienen dados por:

$$c_{jk} = W_f(2^{-j}, k2^{-j}) \quad (2.6)$$




Figura 8. Filtrado en el cálculo de los diferentes niveles wavelet

donde $a = 2^{-j}$, denominado dyadic dilation, y $b = k2^{-j}$, que es la dyadic position. DWT funciona como un filtro paso banda y pueden calcularse varios niveles de la misma. Cada nivel descompone la señal de entrada en aproximaciones (las bajas frecuencias de la señal inicial) y los detalles (altas frecuencias de la señal inicial).

4. Componentes Principales

El análisis de componentes principales (PCA) es un procedimiento matemático que utiliza una transformación ortogonal para convertir una serie de observaciones correspondientes a variables posiblemente correlacionadas, en un conjunto de valores de variables no correlacionadas, denominadas componentes principales. El número de componentes principales siempre es menor o igual al número de variables originales. Esta transformación se define de tal manera que la primera componente principal tenga la mayor varianza posible, ya que de esta forma se obtiene la máxima variabilidad de la información, repitiéndose esta exigencia para cada componente sucesiva, con la restricción de que sea ortogonal (no correlacionada) con las precedentes.

Esta popular técnica se utiliza para la extracción de características y reducción de dimensiones. En un conjunto X de datos de dimensión p , se determinan los m ejes principales T_1, \dots, T_m ($1 \leq m \leq p$), los cuales son ortonormales. Al proyectar los datos sobre estos ejes, se obtiene que la varianza es máxima.

Los nuevos ejes T_1, \dots, T_m se obtienen a partir de los m autovectores principales de la matriz de covarianzas $S = 1/N \sum_{i=1}^N (x_i - \mu)^T (x_i - \mu)$, donde $x_i \in X, \mu$ representa la muestra media y N es el número de muestras, mediante las ecuaciones

$$ST_i = \lambda_i T_i, \quad i \in 1, \dots, m \quad (2.7)$$

siendo los λ_i los mayores autovalores de S . Las m componentes principales de un vector de observación dado $x \in X$ vienen dadas por

$$y = [y_1, \dots, y_m] = [T_1^T x, \dots, T_m^T x] = T^T x \quad (2.8)$$

En este nuevo sistema de referencia, las m componentes principales de x no están correlacionadas. En problemas multiclase, las variaciones en los datos se determinan sobre una base global, ya que los ejes principales son derivados de una matriz de covarianza global

$$\hat{S} = \frac{1}{N} \sum_{j=1}^K \sum_{i=1}^{N_j} (x_i - \hat{\mu})(x_i - \hat{\mu})^T \quad (2.9)$$

donde $\hat{\mu}$ es la media global de todas las muestras, K es el número de clases, N_j es el número de muestras en la clase c ; $N = \sum_{j=1}^K N_j$ representa la observación i^{th} de la clase c . Los ejes principales T_1, \dots, T_m son entonces los autovectores principales de \hat{S}

$$\hat{S}T_i = \hat{\lambda}_i T_i, \quad i \in 1, \dots, m \quad (2.10)$$

donde los $\hat{\lambda}_i$ son los mayores autovalores de \hat{S} . Una hipótesis para la extracción y reducción de dimensiones por PCA es que la máxima información contenida en los vectores de observación se concentra en el subespacio abarcado por los m ejes principales, siendo $m < p$. Así, cada vector de datos original puede ser representado mediante su vector de componentes principales de dimensión m .

III. Análisis Comparativo de Modelos

Propuestos

1. Introducción

Para llevar a cabo el estudio comparativo se dispone de una base de datos con un total de 789 ECGs, de los cuales 127 corresponden a la patología a detectar (bloqueo de rama), y el resto pertenecen a personas sanas o con otra patología. La señal contenida en dichos ECGs está formada por un conjunto de ocho secuencias de puntos (una por derivación) que representan diferencias de potencial, y que se miden en milivoltios (mV). Estas secuencias comprenden varios pulsos cardíacos, por lo que en primer lugar hemos aplicado el pulso medio utilizando, en este caso, la media aritmética para todos ellos. A diferencia de la patología de arritmia, que debe detectarse en diferentes ciclos cardíacos, la ocurrencia de la patología de bloqueos se repite en cada ciclo del pulso cardíaco y la diferencia de la señal en cada pulso es despreciable. Asimismo, el uso de la media aritmética, que representa el más simple de los estadísticos, permite obtener un valor aproximado adecuado y disminuir en forma considerable el volumen de datos a procesar. De esta forma se obtiene un nuevo conjunto de ocho secuencias con 870 puntos cada una, que constituyen los datos que se usarán en nuestro estudio. En la Figura 9 se muestran los pulsos medios de todas las derivaciones correspondientes a un ECG de una persona con bloqueo de rama, escogido aleatoriamente de la base de datos.




Figura 9. Representación gráfica de los pulsos medios de las ocho derivaciones de un ECG patológico.

2. Extracción de Características

Para determinar los puntos concretos que determinan la patología, y que posteriormente, serán utilizados para el entrenamiento de la red neuronal artificial, se ha utilizado el algoritmo que se muestra en la Figura 10. El algoritmo consta de 4 fases: (1) Determinación del latido medio; (2) Agrupación de ECGs; (3) Convergencia de los grupos; (4) y finalmente, determinación de los puntos característicos.



Figura 10. Algoritmo para la Determinación de Puntos Característicos de Patologías.

Fase 1. Determinación del latido medio. El objetivo de determinar el latido medio de cada derivación del electrocardiograma, es eliminar el ruido de distorsión que se genera cuando se realiza el electrocardiograma. Esta fase se compone de 5 pasos como muestra la Figura 11. Los pasos son: (1) Determinación de la ventana de pulsos. Para cada derivación se considera una ventana de pulsos, centrados en el pico R de la señal (Figura 3). El tamaño de la ventana considerado es de 11 pulsos centrados en el pico R. Este tamaño de ventana contiene la información necesaria para llevar a cabo el análisis evitando que los pulsos erróneos influyan en el cálculo del latido medio. Este valor ha sido considerado después de números análisis llevados a cabo de manera empírica. (2) Extracción de pulsos individuales. Una vez determinada la ventana de pulsos, se procede a la extracción de los pulsos individuales. El comienzo y final de un pulso no está delimitado en la señal, por lo tanto es necesario realizar un proceso para su determinación. Este proceso consiste en reconocer el pico R de cada latido el cual se encuentra en el complejo QRS, que es la onda más destacada de un ECG. Para cada uno de estos picos R, se marca y se centra una ventana de 950 puntos: 475 a la izquierda de R y 475 a la derecha de R. Según el estudio que hemos llevado a cabo, el ciclo completo del corazón encaja perfectamente en esta ventana, y todos los puntos significativos están dentro de la ventana. Mediante la localización del pico R como el centro de la ventana

de escaneo, variaciones en el ritmo cardiaco o una disminución en el número de muestras de la línea isoeleétrica se mantienen en los bordes, es decir son eliminados. (3) Filtrado de los pulsos para eliminar el ruido de distorsión. Una vez extraídos los pulsos individuales, se procede a la eliminación de aquellos que son considerados artefactos. (4) Calculo del pulso medio. El pulso se calcula como la media de los pulsos. (5) Aplicación de las Transformadas. A cada pulso medio calculado en el paso anterior se le aplican las transformadas que se van a utilizar para el estudio.




Figura 11. Algoritmo para la Determinación del Latido Medio.

Fase 2. Agrupación de los ECGs en Patológicos y no Patológicos. En esta fase, se agrupan los pulsos medios del paso 1, en dos conjuntos: el primer conjunto contiene aquellos pulsos que presentan la patología objeto de estudios; y el segundo conjunto con el resto de pulsos.

Fase 3. Convergencia de los Grupos de ECGs. En esta fase se calcula un representante para cada pulso medio obtenido en la fase 2. Para ello, cada punto i que conforma el pulso representante, es calculado como una función a los puntos i de los diferentes latidos medios de cada grupo.

Las funciones que pueden aplicar para obtener los puntos son: media aritmética, mediana, moda, componentes principales.

Fase 4. Determinación de los puntos característicos de patología. Los puntos característicos de obtienen como una diferencia absoluta, entre los representantes de los grupos calculados en la fase 3. Esta diferencia está sujeta a un umbral de diferenciación, para determinar los puntos que definen la patología en cuestión. La figura X muestra la diferencia absoluta de las 8 derivaciones de un ECG y el umbral de activación de la diferencia. El ejemplo de la Figura 12 muestra que existen diferencias leves en las

derivaciones V1, V4, V5 y V6; diferencias fuertes en V2 y V3; y ninguna diferencia en las derivaciones I y II.




Figura 12. Aplicación de un umbral de diferenciación del 50%

3. Resultados del Entrenamiento

Diferentes métodos de clasificación automática para ECGs han sido propuestos. Así por ejemplo tenemos clasificadores basados en: (1) métodos estadísticos (de Chazal et al., 2004; Ge et al., 2002; Jekova, Bortolan, & Christov, 2008b; Martis et al., 2012); (2) K-Vecinos más cercanos (Jekova et al., 2008a), que clasifica muestras sin etiquetar basándose en la similitud con las muestras del conjunto de entrenamiento; (3) Árboles de Decisión, que clasifica objetos a través de una secuencia de preguntas; (4) Lógica Difusa (Chiu, 1994; Jang, 1993; Osowski & Stodolski, 2003; Pedrycz, Bortolan, & Degani, 1991; Sugeno, 1985); y finalmente, (5) los métodos basados en Redes Neuronales (Benali et al., 2012; Bishop, 1995; Čeppek, Šnorek, & Chudáček, 2008; de Chazal et al., 2004; Dokur & Ölmez, 2001; Haykin, 1998; Jambukia, Dabhi, & Prajapati, 2015; Jekova et al., 2008a; Martis et al., 2012; Melgani & Bazi, 2008; Özbay & Tezel, 2010; J.I. Peláez, Doña, Fornari, & Serra, 2014; Jose Ignacio Peláez & Fornari, 2014; Übeyli, 2009; Wasserman, 1993; Xu & Zhang, n.d.; C.-C. Yu, Tang, & Liu, n.d.; S.-N. Yu & Chou, 2009), que es uno de los métodos más utilizados en los sistemas automáticos por su capacidad de clasificación.

En este trabajo se va a implementar una red neuronal artificial, en concreto un Perceptron Multicapa, para verificar que los puntos característicos obtenidos producen buenos resultados en los sistemas de clasificación automática.

Datos de Entrenamiento. Para este entrenamiento hemos seleccionado la patología de bloqueos de rama de la BBDD, separando los ECGs de la base de datos en tres conjuntos:

- De entrenamiento, utilizado para optimizar los parámetros de la red con objeto de minimizar el error. Consiste en un 60% del total, lo que equivale a 475 elementos (77 patológicos y 398 no patológicos).
- De validación, con el que se detecta el sobreentrenamiento (overfitting). Consiste en un 20% del total, lo que equivale a 157 elementos (25 patológicos y 132 no patológicos).
- De testeo, que se utiliza para comprobar el rendimiento de la red. Estos datos, al no utilizarse en el entrenamiento de la red, permiten determinar el nivel de generalización que tiene nuestro modelo. Consiste en un 20% del total, lo que equivale a 157 elementos (25 patológicos y 132 no patológicos).

Topología de la Red Neuronal y Umbral de Diferenciación. Se ha realizado una búsqueda empírica del número de neuronas óptimo en la capa oculta del perceptrón multicapa y para el valor umbral utilizado para la extracción de los puntos característicos. Para ello, se han realizado cien entrenamientos para cada número de neuronas en la capa oculta, comenzando estas en dos e incrementando el número de dos en dos, hasta un total de 100.

Este proceso se ha repetido para cada umbral de diferenciación, comenzando en un 99% del valor máximo de la señal de salida de la fase 4 y disminuyendo en 5% en cada iteración hasta terminar en el 10% del valor máximo de la señal.

Para valorar los resultados obtenidos, se utilizará el coeficiente de correlación de Matthews (MCC):

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP) \cdot (TP + FN) \cdot (TN + FP) \cdot (TN + FN)}} \quad (3.1)$$

donde

TP: Verdaderos Positivos (True Positives)

TN: Verdaderos Negativos (True Negatives)

FP: Falsos Positivos (False Positives)

FN: Falsos Negativos (False Negatives)

Una vez realizado este proceso para los diferentes valores, se ha obtenido un conjunto de redes neuronales ordenadas de mayor a menor en función del coeficiente de Matthews, seleccionado aquella que presenta mejor valor de coeficiente (Tabla 1).

Tabla 1. Sensibilidad (S), Especificidad (E), Número de Neuronas en la Capa Oculta (N) y Umbral (U)

	<i>Media</i>				<i>Mediana</i>				<i>Moda</i>				<i>PCA</i>			
	S	E	N	U	S	E	N	U	S	E	N	U	S	E	N	U
<i>Original</i>	96%	99.2%	44	50%	96%	99.2%	8	50%	100%	99.2%	30	30%	92%	100%	32	95%
<i>Muestreado</i>	92%	99.2%	90	50%	100%	98.5%	58	40%	96%	98.5%	2	50%	96%	100%	34	75%
<i>Fourier</i>	88%	97.7%	80	20%	72%	100%	38	30%	88%	99.2%	52	10%	84%	97.7%	90	99%
<i>Haar</i>	84%	97.7%	10	30%	60%	100%	52	40%	64%	100%	58	30%	92%	97.7%	48	85%
<i>db2</i>	56%	98.5%	12	30%	52%	98.5%	94	30%	36%	98.5%	86	30%	40%	100%	98	75%
<i>db4</i>	84%	99.2%	40	30%	60%	100%	60	40%	12%	98.5%	46	70%	20%	99.2%	22	85%
<i>coif1</i>	60%	98.5%	70	30%	56%	94.7%	76	30%	28%	100%	56	30%	40%	98.5%	68	70%
<i>coif2</i>	92%	98.5%	30	30%	80%	97%	48	40%	8%	99.2%	74	40%	12%	100%	12	90%
<i>sym2</i>	60%	98.5%	22	30%	56%	97.7%	54	30%	40%	97%	76	30%	56%	97%	58	75%
<i>sym4</i>	80%	99.2%	2	30%	68%	98.5%	74	30%	4%	100%	54	90%	12%	100%	76	75%

Finalmente, se representan la matriz de clasificación o matriz de confusión y la curva ROC de la mejor red neuronal calculada. Estas gráficas determinan el rendimiento de la red neuronal cuando se aplica a nuevos datos. En la Figura 13 se muestra el coeficiente de Matthews (en tanto por uno) para el umbral con el mejor resultado y el número de neuronas correspondiente a los datos de entrenamiento obtenidos mediante la aplicación de la moda a los puntos originales.

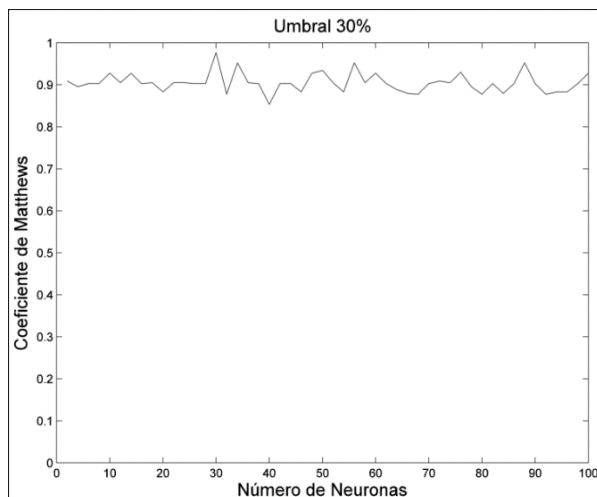


Figura 13. Coeficientes de Matthews para el umbral con el mejor resultado y número de neuronas

En la Tabla 2 se muestran tabulados los coeficientes de Matthews (en %) para cada umbral y número de neuronas correspondientes a los datos de entrenamiento obtenidos mediante la aplicación de la moda a los puntos originales.

Tabla 2. Coeficientes de Matthews. Se destaca el umbral con el mejor resultado y el número de neuronas

Nº Neuronas	Umbral	Coeficiente Matthews (%)
6	90%	77,35
78	80%	74,68
70	70%	80,07
72	60%	90,88
36	50%	95,24
36	40%	93,00
30	30%	97,69

En la Figura 14 se representan, para la red neuronal y el umbral que ofrecen el mejor resultado, la matriz de clasificación o matriz de confusión a la izquierda y la curva ROC a la derecha.

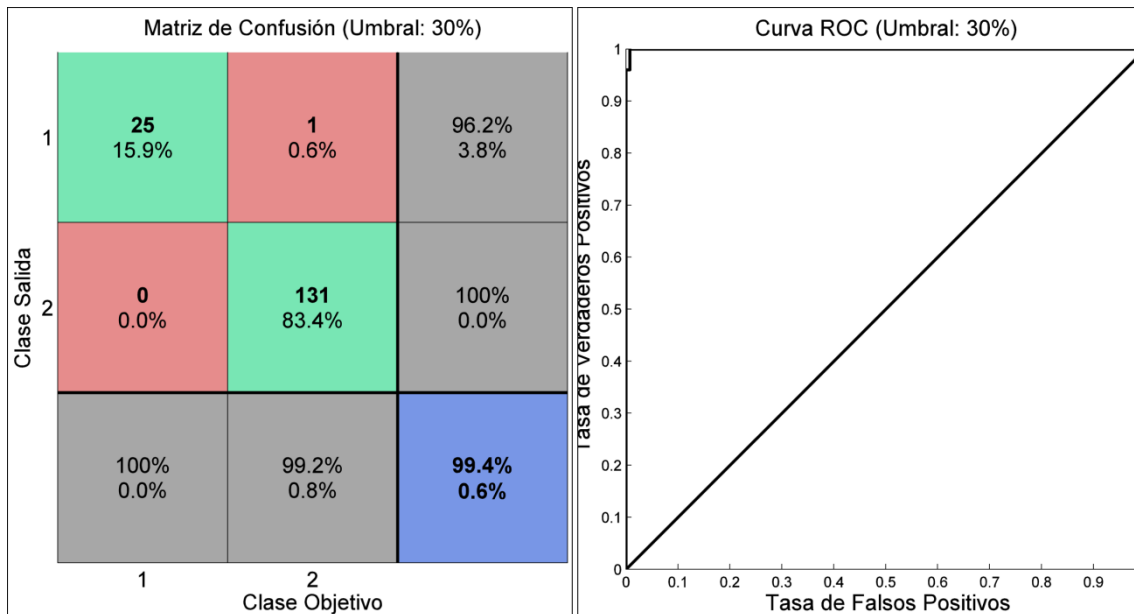


Figura 14. Matriz de Confusion (Izquierda) y curva Roc (Derecha) para el umbral con el mejor resultado.

4. Descripción de las magnitudes utilizadas

La evaluación de las pruebas diagnósticas se ha tratado, en general, sin un criterio universalmente aceptado. En diferentes estudios aparecen términos como sensibilidad, especificidad, eficiencia, exactitud, utilidad, valor, eficacia y efectividad, pero a menudo el significado de los mismos es ambiguo. La ausencia de acuerdo, tanto en el concepto, como en la medida de la calidad de una prueba diagnóstica, crea una situación de confusión a la hora de resolver cuestiones concretas.

La calidad de una prueba diagnóstica utilizada para el cuidado de los pacientes no se juzga sólo por sus características analíticas sino, fundamentalmente, por su capacidad para distinguir entre estados alternativos de salud. El médico solicita una prueba para decidir, junto con otros datos disponibles, si el paciente tiene o no una condición clínica. Por lo tanto, para que una prueba se incluya en la práctica médica rutinaria es necesario que sea capaz de reducir la incertidumbre asociada con una determinada situación clínica.

La principal cualidad clínica de una prueba diagnóstica es su exactitud, definida como la capacidad para clasificar de manera correcta a los individuos en subgrupos clínicamente relevantes. En su forma más simple es la capacidad para distinguir entre dos estados de salud. Una vez establecida esta capacidad de discriminar adecuadamente, es necesario

conocer también el valor práctico de la prueba para el cuidado del paciente. Existen diversas causas que invalidan una prueba diagnóstico para su uso práctico, entre ellas:

- Pueden existir métodos menos invasivos o más económicos para obtener una información semejante.
- La prueba puede ser tan cara o poseer tal requerimiento técnico que sea limitada su disponibilidad.
- Puede ser tan incómoda o invasiva que los pacientes no se sometan con facilidad a ella.
- El coste o indeseabilidad de los resultados falsos puede ser tan alto que no exista un punto de corte aceptable.

Al comparar los resultados de una prueba a evaluar y el diagnóstico de referencia, existen cuatro posibilidades que pueden resumirse en la siguiente tabla de contingencia de 2 x 2:

Tabla 3. Distintas posibilidades de evaluación de una prueba

	Diagnóstico Verdadero	
	Patológicos	No Patológicos
Resultado Positivo	Verdadero Positivo (VP)	Falso Positivo (FP)
Resultado Negativo	Verdadero Negativo (VN)	Falso Negativo (VN)

cuyo significado de los términos utilizados en la Tabla 3 es:

- Verdaderos Positivos (VP): Indica el número de ECGs clasificados como patológicos que realmente lo son.
- Verdaderos Negativos (VN): Indica el número de ECGs clasificados como no patológicos que realmente no lo son .
- Falsos Positivos (FP): Indica el número de ECGs clasificados como patológicos que realmente no lo son.
- Falsos Negativos (FN): Indica el número de ECGs clasificados como no patológicos que realmente lo son.

Siempre que una cuestión clínica y el resultado de la prueba diagnóstica encaminada a resolverla puedan plantearse en términos de dicotomía (presencia o ausencia de enfermedad; positivo o negativo), la exactitud de la prueba puede definirse en función de su sensibilidad y especificidad diagnósticas. Sin embargo, con mucha frecuencia los resultados de las pruebas diagnósticas están distribuidos en una escala continua, por lo que es necesario seleccionar un punto de corte o valor límite adecuado que permita resumir estos resultados en dos categorías: positivo y negativo.

Sensibilidad (Se): La sensibilidad de una prueba diagnóstica es la probabilidad de obtener un resultado positivo cuando el individuo tiene la enfermedad. Mide su capacidad para detectar la enfermedad cuando está presente. Se calcula como

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (3.2)$$

Especificidad (Sp): La especificidad de una prueba indica la probabilidad de obtener un resultado negativo cuando el individuo no tiene la enfermedad. Mide su capacidad para descartar la enfermedad cuando ésta no está presente. Se calcula como

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad (3.3)$$

La prueba diagnóstica ideal debería tener una sensibilidad y una especificidad tan próximas al 100 % como fuera posible. Esto constituye una excepción, pero en principio se debe dudar de pruebas cuya sensibilidad y especificidad sean inferiores al 80 %. A partir de la Tabla 4 se pueden definir los siguientes valores:

- **Valor Predictivo Positivo (VPP):** Es la probabilidad de tener la patología si el resultado de la clasificación es positivo. Se calcula como

$$VPP = \frac{VP}{VP + FP} \quad (3.4)$$

- **Valor Predictivo Negativo (VPN):** Es la probabilidad de no tener la patología si el resultado de la clasificación es negativo. Se calcula como

$$VPN = \frac{VN}{VN + FN} \quad (3.5)$$

- Precisión (Acc): Es la probabilidad de obtener un resultado correcto

$$Precision = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad (3.6)$$

Finalmente, y para poder comparar los resultados obtenidos por el clasificador empleado, se utilizará otro parámetro:

- Coeficiente de Matthews (MCC): Es una medida que nos muestra la calidad de una clasificación binaria. Este valor es en esencia una correlación entre los valores observados y predichos de una clasificación binaria; devuelve un valor entre -1 y 1. Un coeficiente con valor 1 representa una predicción perfecta, un valor de 0 representa una clasificación aleatoria y un coeficiente de -1 indica total desacuerdo entre la predicción y la observación. Este coeficiente se calcula como sigue

$$MCC = \frac{VP \times VN - FP \times FN}{\sqrt{(VP + FP) \times (VP + FN) \times (VN + FP) \times (VN + FN)}} \quad (3.7)$$

Como puede observarse, para la evaluación de las pruebas diagnósticas se utiliza una gran cantidad de datos que dificultan la comprensión exacta del problema. Por ello, se representan los resultados de forma gráfica mediante la utilización de dos elementos distintos, la matriz de confusión y las curvas ROC, y que se describen en los siguientes apartados.

4.1. Matriz de Confusión

En análisis predictivo, una matriz de confusión consiste en una tabla de dos filas y dos columnas que representa el número de verdaderos positivos, falsos positivos, falsos negativos y verdaderos negativos (Tabla 4). Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real.

Tabla 4. Matriz de confusión básica

Verdaderos Positivos	Falsos Negativos
Falsos Positivos	Verdaderos Negativos

En el presenta estudio se ha utilizado una matriz de confusión ampliada, incluida en el software MatLab®, que incluye, además de los valores anteriores, la sensibilidad, la especificidad, la precisión, el valor predictivo positivo y el valor predictivo negativo, que se muestra en la Tabla 5 y en la Figura 15.

Tabla 5. Matriz de confusión ampliada

Realidad	VP (Cantidad) VP (en % del total)	FN (Cantidad) FN (en % del total)	Sensibilidad 1-Sensibilidad
	FP (Cantidad) FP (en % del total)	VN (Cantidad) VN (en % del total)	Especificidad 1-Especificidad
	Valor Predictivo Positivo 1-Valor Predictivo Positivo	Valor Predictivo Negativo 1-Valor Predictivo Negativo	Precisión 1-Precisión
Predicción			

Cada columna de la matriz de la Figura 15 representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real.

Matriz de Confusión (Umbral: 30%)

Clase Salida	1	23 14.6%	2 1.3%	92.0% 8.0%
	2	2 1.3%	130 82.8%	98.5% 1.5%
		1	92.0% 8.0%	2
			Clase Objetivo	97.5% 2.5%

Figura 15. Ejemplo de matriz de confusión utilizada.

4.2. Curvas ROC

Clásicamente, la exactitud de una prueba diagnóstica se ha evaluado en función de dos características: la sensibilidad y la especificidad. Sin embargo, éstas varían en función del criterio elegido como punto de corte entre la población sana y la enferma. Una forma más global de conocer la calidad de la prueba en el espectro completo de puntos de corte es mediante el uso de curvas ROC (Receiver Operating Characteristics) que constituyen una herramienta muy útil y unificadora en el proceso de evaluación y uso de las pruebas diagnósticas.

La curva ROC es un gráfico en el que se observan todos los pares sensibilidad/especificidad resultantes de la variación continua de los puntos de corte en todo el rango de resultados observados. En el eje y de coordenadas se sitúa la sensibilidad o fracción de verdaderos positivos. En el eje x se sitúa la fracción de falsos positivos ' $1 - especificidad$ '.

Cada punto de la curva representa un par ' $\frac{Sensibilidad}{(1-Especificidad)}$ ' correspondiente a un nivel de decisión determinado. Una prueba con discriminación perfecta, sin solapamiento de resultados en las dos poblaciones, tiene una curva ROC que pasa por la esquina superior izquierda, donde Sensibilidad y Especificidad toman valores máximos (Sensibilidad y Especificidad igual a 1). Una prueba sin discriminación, con igual distribución de

resultados en los dos subgrupos, da lugar a una línea diagonal de 45°, desde la esquina inferior izquierda hasta la superior derecha. La mayoría de las curvas ROC caen entre estos dos extremos. Si cae por debajo de la diagonal de 45° se corrige cambiando el criterio de positividad de “mayor que” a “menor que” o viceversa.

Cualitativamente, cuanto más próxima es una curva ROC a la esquina superior izquierda, más alta es la exactitud global de la prueba. De la misma forma, si se dibujan en un mismo gráfico las curvas obtenidas con distintas pruebas diagnósticas, aquella que esté situada más hacia arriba y hacia la izquierda tiene mayor exactitud: por simple observación se obtiene una comparación cualitativa. En la Figura 16 se muestra un ejemplo obtenido con el software MatLab®

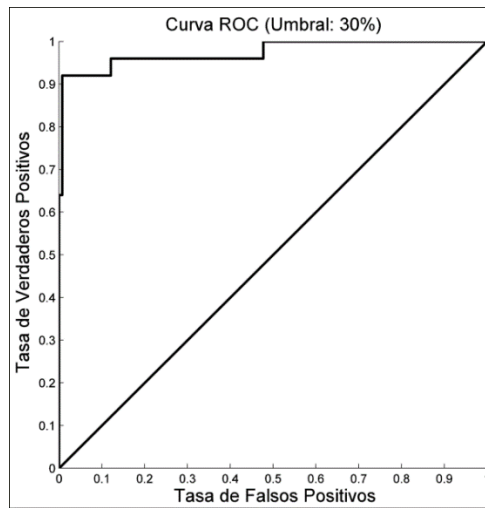


Figura 16. Ejemplo de curva ROC utilizada.

5. Comparativa de los Resultados Obtenidos con las Diferentes Técnicas

En la siguiente sección se presenta la comparación de los diez modelos utilizados con redes neuronales artificiales para la detección de patologías cardíacas de bloqueos. En la Tabla 6 se muestran en cada fila el modelo esgrimido y su resultado y en cada columna los métodos estadísticos (media, mediana y moda) y de dispersión (PCA) utilizados. Los resultados se representan como

Tabla 6. Comparativa de resultados con diferentes técnicas. (MCC / n° neuronas capa oculta / umbral)

	Media	Mediana	Moda	PCA
ECG Completo	95,24/44/50	95,24/8/50	97,69/30/30	95,20/32/95
ECG Muestreado	92,77/90/50	95,49/58/40	95,49/2/50	97,61/34/75
Fourier	85,73/80/20	82,69/38/30	90,28/52/10	83,10/90/99
Waveler Haar	83,10/10/30	74,68/52/40	77,40/58/30	88,32/48/85
Wavelet db2	65,90/12/30	62,84/94/30	49,43/86/30	59,93/98/75
Wavelet db4	87,75/40/30	74,68/60/40	21,85/46/70	32,07/76/70
Wavelet coif1	68,87/70/30	54,50/76/30	49,64/56/30	53,00/68/70
Wavelet coif2	90,48/30/30	78,26/48/40	19,36/74/40	32,07/12/90
Wavelet sym2	68,87/22/30	63,26/54/30	47,46/76/30	60,83/58/75
Wavelet sym4	85,18/2/30	74,59/74/30	18,40/54/90	32,07/76/75

Los mejores resultados obtenidos con cada estadístico son destacados. En este caso, el mejor resultado ocurre cuando se usan de todos los puntos, como es el caso del ECG completo que utilizando la moda muestra el mejor resultado final. El coeficiente de Matthews obtenido es de 97,69 con 30 neuronas en la capa oculta y utilizando el umbral 30.

Así mismo, el ECG muestreado representado a través del uso de los estadísticos de la media, mediana y PCA presenta los mejores resultados pero solamente comparados con el uso de las transformadas. Los resultados obtenidos correspondientes al coeficiente de Matthews son del 92,77; 95,49 y 97,61 respectivamente a los estadísticos mencionados.

6. Comparativa de Complejidad de la Red Utilizada

En esta sección se presenta, no sólo la comparación de los diez modelos utilizados con redes neuronales artificiales, sino también la complejidad de la red neuronal artificial utilizada a través del uso de la cantidad de entradas a la red, el número de neuronas en la capa oculta y la cantidad de pesos sinápticos utilizada. En la Tabla 7 se muestra el modelo utilizado y el resultado obtenido por cada uno de los métodos estadísticos (media, mediana y moda) y de dispersión (PCA) empleados. Los parámetros utilizados en cada celda representan a:

- E = número de entradas a la red neuronal artificial.

- O = número de neuronas utilizadas en la capa oculta.
- N = número de pesos sinápticos de la red neuronal artificial, representa la complejidad de la RNA.
- M = es el coeficiente de Matthews.

En los casos en que los coeficientes de Matthews son iguales, se tiene en cuenta el número de neuronas utilizadas en la capa oculta, siendo la elegida aquella con menor cantidad de neuronas. Y en la situación, en que coincida el coeficiente de Matthews y la cantidad de neuronas de la capa oculta, el mejor resultado se determina en función de la complejidad de la RNA utilizada.

Tabla 7. Comparación de las diversas complejidades de las redes neuronales utilizadas.

	Media	Mediana	Moda	PCA
ECG Completo	E=186 O=44 N=8828 M=95,24	E=201 O=8 N=1616 M=95,24	E=294 O=30 N=8850 M=97,69	E=58 O=32 N=1888 M=95,20
ECG Diezmado	E=19 O=90 N=1800 M=92,77	E=32 O=58 N=1914 M=95,49	E=17 O=2 N=36 M=95,49	E=15 O=34 N=544 M=97,61
Fourier	E=25 O=80 N=2080 M=85,73	E=18 O=38 N=722 M=82,69	E=73 O=52 N=3848 M=90,28	E=77 O=90 N=7020 M=83,10
Waveler Haar	E=207 O=10 N=2080 M=83,10	E=82 O=52 N=4316 M=74,68	E=45 O=58 N=2668 M=77,40	E=35 O=48 N=1728 M=88,32
Wavelet db2	E=142 O=12 N=1716 M=65,90	E=105 O=94 N=9964 M=62,84	E=48 O=86 N=4214 M=49,43	E=305 O=98 N=29988 M=59,93
Wavelet db4	E=426 O=40 N=17080 M=87,75	E=436 O=60 N=26220 M=74,68	E=1 O=46 N=92 M=21,85	E=1142 O=76 N=86868 M=32,07
Wavelet coif1	E=144 O=70 N=10150 M=68,87	E=102 O=76 N=7828 M=54,50	E=109 O=56 N=6160 M=49,64	E=240 O=68 N=16388 M=53,00

Wavelet coif2	E=544 O=30 N=16350 M=90,48	E=456 O=48 N=21936 M=78,26	E=9 O=74 N=740 M=19,36	E=2093 O=12 N=25128 M=32,07
Wavelet sym2	E=142 O=22 N=3146 M=68,87	E=105 O=54 N=5724 M=63,26	E=48 O=76 N=3724 M=47,46	E=305 O=58 N=17748 M=60,83
Wavelet sym4	E=451 O=2 N=904 M=85,18	E=853 O=74 N=63196 M=74,59	E=2 O=54 N=162 M=18,40	E=1302 O=76 N=99028 M=32,07

El mayor coeficiente de Matthews se obtiene a partir de la moda del ECG completo. Sin embargo, utilizando PCA del ECG muestreado se consigue un resultado casi idéntico con una complejidad de la red mucho menor. Así mismo, el uso de las transformadas (tanto Fourier como wavelet) no presentan resultados promisorios y los tiempos de cálculo final fueron mayores en comparación con el uso de los métodos de ECG completo y ECG diezmado.

IV. Conclusiones

A modo de resumen, se exponen a continuación las principales conclusiones, que han sido derivadas de la labor realizada a lo largo de esta memoria.

El objetivo de este trabajo es el desarrollo y comparación de diversos modelos utilizando redes neuronales artificiales para la detección de patologías cardíacas, específicamente bloqueos. En este trabajo se presentan y cotejan diez modelos diferentes partiendo de la información específica obtenida de diversos ECG y comparándolos para determinar el mejor método de análisis de bloqueos cardíacos.

En el capítulo I, y a modo de introducción a la biología básica del aparato cardiovascular, se ha tratado, en primer lugar, la anatomía general del corazón y el ciclo cardíaco. A continuación, se ha descrito la forma de representación gráfica de la actividad eléctrica del corazón a través del uso del electrocardiograma. Finalmente, se presentan las principales anomalías que pueden ser detectadas mediante el ECG.

En el capítulo II se han detallado las principales transformadas que pueden ser aplicadas para la extracción de características de los ECG y se han propuesto las transformadas que son válidas para el estudio de los ECG con patología de bloqueos.

En el capítulo III se ha propuesto un clasificador basado en redes neuronales artificiales para la clasificación de la patología de bloqueos. Para llevar a cabo el entrenamiento del sistema neuronal se han utilizado 789 ECGs, de los cuales 127 corresponden a la patología a detectar, bloqueo de rama. En este caso, se determina una secuencia de 870 puntos por cada derivación de cada ECG y se aplica el algoritmo de extracción de características para obtener los puntos representativos en función de la patología y que luego se utilizan como entrada para el entrenamiento de diversas topologías de redes neuronales artificiales (RNA). Como resultado del comparativo realizado entre el ECG completo, el ECG muestreado, la transformada discreta de Fourier y las transformadas discretas wavelet de nivel 4 (Haar, db2, db4, coif1, coif2, sym2, sym4) se ha obtenido para el mejor clasificador propuesto un resultado del coeficiente de Matthews de 97,69 con una cantidad de 30 neuronas para la capa oculta de la red neuronal artificial propuesta utilizando, en este caso, el ECG completo con el método estadístico moda.

Los resultados obtenidos confirman que no es necesario el empleo de transformaciones a la señal original de ECG para obtener los mejores resultados en cuanto a sensibilidad y especificidad en el entrenamiento de la RNA. Las conclusiones se obtienen a partir de realizar un análisis exhaustivo.

Referencias

- Benali, R., Bereksi Reguig, F., & Hadj Slimane, Z. (2012). Automatic classification of heartbeats using wavelet neural network. *Journal of Medical Systems*, 36(2), 883–92. <http://doi.org/10.1007/s10916-010-9551-7>
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Retrieved from <http://dl.acm.org/citation.cfm?id=525960>
- Čepek, M., Šnorek, M., & Chudáček, V. (2008). *Artificial Neural Networks - ICANN 2008*. (V. Kůrková, R. Neruda, & J. Koutník, Eds.) (Vol. 5163). Berlin, Heidelberg: Springer Berlin Heidelberg. <http://doi.org/10.1007/978-3-540-87536-9>
- Ceylan, R., & Özbay, Y. (2007). Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network. *Expert Systems with Applications*, 33(2), 286–295. <http://doi.org/10.1016/j.eswa.2006.05.014>
- Chiu, S. L. (1994). Fuzzy Model Identification Based on Cluster Estimation. *Journal of Intelligent and Fuzzy Systems*, 2(3), 267–278. <http://doi.org/10.3233/IFS-1994-2306>
- Curtis, H., & Schnek, A. (2008). *Curtis. Biología*. Retrieved from https://books.google.es/books/about/Curtis_Biolog%C3%ADa.html?hl=es&id=mGadUVpdTLsC&pgis=1
- de Chazal, P., O'Dwyer, M., & Reilly, R. B. (2004). Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Transactions on Bio-Medical Engineering*, 51(7), 1196–206. <http://doi.org/10.1109/TBME.2004.827359>
- Dokur, Z., & Ölmez, T. (2001). ECG beat classification by a novel hybrid neural network. *Computer Methods and Programs in Biomedicine*, 66(2-3), 167–181. [http://doi.org/10.1016/S0169-2607\(00\)00133-4](http://doi.org/10.1016/S0169-2607(00)00133-4)
- Dubin, D. (2007). *Interpretación de ECG*.
- Ge, D., Srinivasan, N., & Krishnan, S. M. (2002). Cardiac arrhythmia classification using autoregressive modeling. *Biomedical Engineering Online*, 1(1), 5. <http://doi.org/10.1186/1475-925X-1-5>
- Haykin, S. (1998). *Neural Networks: A Comprehensive Foundation*. Retrieved from <http://dl.acm.org/citation.cfm?id=521706>
- He, L., Hou, W., Zhen, X., & Peng, C. (2006). Recognition of ECG Patterns Using Artificial Neural Network. In *Sixth International Conference on Intelligent Systems Design and Applications* (Vol. 2, pp. 477–481). IEEE. <http://doi.org/10.1109/ISDA.2006.253883>

- Hosseini, H. G., Luo, D., & Reynolds, K. J. (2006). The comparison of different feed forward neural network architectures for ECG signal diagnosis. *Medical Engineering & Physics*, 28(4), 372–8. <http://doi.org/10.1016/j.medengphy.2005.06.006>
- Jackon, W. M. (1956). *Enciclopedia Jackon*.
- Jambukia, S. H., Dabhi, V. K., & Prajapati, H. B. (2015). Classification of ECG signals using machine learning techniques: A survey. In *2015 International Conference on Advances in Computer Engineering and Applications* (pp. 714–721). IEEE. <http://doi.org/10.1109/ICACEA.2015.7164783>
- Jang, J.-S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685. <http://doi.org/10.1109/21.256541>
- Jekova, I., Bortolan, G., & Christov, I. (2008a). Assessment and comparison of different methods for heartbeat classification. *Medical Engineering & Physics*, 30(2), 248–57. <http://doi.org/10.1016/j.medengphy.2007.02.003>
- Jekova, I., Bortolan, G., & Christov, I. (2008b). Assessment and comparison of different methods for heartbeat classification. *Medical Engineering & Physics*, 30(2), 248–57. <http://doi.org/10.1016/j.medengphy.2007.02.003>
- Khorrami, H., & Moavenian, M. (2010). A comparative study of DWT, CWT and DCT transformations in ECG arrhythmias classification. *Expert Systems with Applications*, 37(8), 5751–5757. <http://doi.org/10.1016/j.eswa.2010.02.033>
- Korürek, M., & Doğan, B. (2010). ECG beat classification using particle swarm optimization and radial basis function neural network. *Expert Systems with Applications*, 37(12), 7563–7569. <http://doi.org/10.1016/j.eswa.2010.04.087>
- Korürek, M., & Nizam, A. (2008). A new arrhythmia clustering technique based on Ant Colony Optimization. *Journal of Biomedical Informatics*, 41(6), 874–81. <http://doi.org/10.1016/j.jbi.2008.01.014>
- Lagerholm, M., Peterson, C., Braccini, G., Edenbrandt, L., & Sörnmo, L. (2000). Clustering ECG complexes using hermite functions and self-organizing maps. *IEEE Transactions on Bio-Medical Engineering*, 47(7), 838–48. <http://doi.org/10.1109/10.846677>
- Martis, R. J., Krishnan, M. M. R., Chakraborty, C., Pal, S., Sarkar, D., Mandana, K. M., & Ray, A. K. (2012). Automated screening of arrhythmia using wavelet based machine learning techniques. *Journal of Medical Systems*, 36(2), 677–88. <http://doi.org/10.1007/s10916-010-9535-7>
- Melgani, F., & Bazi, Y. (2008). Classification of electrocardiogram signals with support vector machines and particle swarm optimization. *IEEE Transactions on*

Information Technology in Biomedicine : A Publication of the IEEE Engineering in Medicine and Biology Society, 12(5), 667–77.

<http://doi.org/10.1109/TITB.2008.923147>

- Ocak, H. (2009). Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, 36(2), 2027–2036. <http://doi.org/10.1016/j.eswa.2007.12.065>
- Oowski, S., & Stodolski, M. (2003). On-line heart beat recognition using hermite polynomials and neuro-fuzzy network. *IEEE Transactions on Instrumentation and Measurement*, 52(4), 1224–1231. <http://doi.org/10.1109/TIM.2003.816841>
- Özbay, Y., Ceylan, R., & Karlik, B. (2011). Integration of type-2 fuzzy clustering and wavelet transform in a neural network based ECG classifier. *Expert Systems with Applications*, 38(1), 1004–1010. <http://doi.org/10.1016/j.eswa.2010.07.118>
- Özbay, Y., & Tezel, G. (2010). A new method for classification of ECG arrhythmias using neural network with adaptive activation function. *Digital Signal Processing*, 20(4), 1040–1049. <http://doi.org/10.1016/j.dsp.2009.10.016>
- Pedrycz, W., Bortolan, G., & Degani, R. (1991). Classification of electrocardiographic signals: a fuzzy pattern matching approach. *Artificial Intelligence in Medicine*, 3(4), 211–226. [http://doi.org/10.1016/0933-3657\(91\)90013-2](http://doi.org/10.1016/0933-3657(91)90013-2)
- Peláez, J. I., Doña, J. M., Fornari, J. F., & Serra, G. (2014). Ischemia classification via ECG using MLP neural networks. *International Journal of Computational Intelligence Systems*, 7(2), 344–352. <http://doi.org/10.1080/18756891.2014.889498>
- Peláez, J. I., & Fornari, J. F. (2014). *Foundations and Applications of Intelligent Systems*. (F. Sun, T. Li, & H. Li, Eds.) (Vol. 213). Berlin, Heidelberg: Springer Berlin Heidelberg. <http://doi.org/10.1007/978-3-642-37829-4>
- Sugeno, M. (1985). Industrial Applications of Fuzzy Control. Retrieved from <http://dl.acm.org/citation.cfm?id=537323>
- Übeyli, E. D. (2009). Combining recurrent neural networks with eigenvector methods for classification of ECG beats. *Digital Signal Processing*, 19(2), 320–329. <http://doi.org/10.1016/j.dsp.2008.09.002>
- Wasserman, P. D. (1993). *Advanced Methods in Neural Computing*. Van Nostrand Reinhold. Retrieved from <https://books.google.com/books?id=9rdQAAAAMAAJ&pgis=1>
- Xu, S., & Zhang, M. (n.d.). Data Mining — An Adaptive Neural Network Model for Financial Analysis. In *Third International Conference on Information Technology and Applications (ICITA '05)* (Vol. 1, pp. 336–340). IEEE. <http://doi.org/10.1109/ICITA.2005.109>
- Yu, C.-C., Tang, Y., & Liu, B.-D. (n.d.). An adaptive activation function for multilayer

feedforward neural networks. In *2002 IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering. TENCOM '02. Proceedings.* (Vol. 1, pp. 645–650). IEEE. <http://doi.org/10.1109/TENCON.2002.1181357>

Yu, S.-N., & Chou, K.-T. (2009). Selection of significant independent components for ECG beat classification. *Expert Systems with Applications*, *36*(2), 2088–2096. <http://doi.org/10.1016/j.eswa.2007.12.016>

Anexos

Índice de Figuras

FIGURA 1. PRINCIPALES CAUSAS DE MUERTE EN EL MUNDO. FUENTE: ORGANIZACIÓN MUNDIAL DE LA SALUD (OMS).....	10
FIGURA 2. DISPOSICIÓN DE LAS VÁLVULAS AURICOVENTRICULARES Y SIGMOIDEAS	12
FIGURA 3. VARIACIONES ELÉCTRICAS Y DE PRESIÓN EN EL CORAZÓN. (CURTIS & SCHNEK, 2008)	14
FIGURA 4. REGULACIÓN AUTÓNOMA DE LA FRECUENCIA DEL LATIDO CARDÍACO. (CURTIS & SCHNEK, 2008).....	15
FIGURA 5. ELEMENTOS BÁSICOS INICIALES QUE COMPONEN EL ELECTROCARDIOGRAMA.....	17
FIGURA 6. ELEMENTOS BÁSICOS INICIALES QUE COMPONEN EL ELECTROCARDIOGRAMA. (DUBIN, 2007)	18
FIGURA 7. DERIVACIONES DEL PLANO FRONTAL (A) Y DEL PLANO HORIZONTAL (B). (CURTIS & SCHNEK, 2008)	19
FIGURA 8. FILTRADO EN EL CÁLCULO DE LOS DIFERENTES NIVELES WAVELET.....	25
FIGURA 9. REPRESENTACIÓN GRÁFICA DE LOS PULSOS MEDIOS DE LAS OCHO DERIVACIONES DE UN ECG PATOLÓGICO.	28
FIGURA 10. ALGORITMO PARA LA DETERMINACIÓN DE PUNTOS CARACTERÍSTICOS DE PATOLOGÍAS.	29
FIGURA 11. ALGORITMO PARA LA DETERMINACIÓN DEL LATIDO MEDIO.....	30
FIGURA 12. APLICACIÓN DE UN UMBRAL DEL 50%.....	31
FIGURA 13. COEFICIENTES DE MATTHEWS PARA EL UMBRAL CON EL MEJOR RESULTADO Y NÚMERO DE NEURONAS.....	34
FIGURA 14. MATRIZ DE CONFUSION (IZQUIERDA) Y CURVA ROC (DERECHA) PARA EL UMBRAL CON EL MEJOR RESULTADO. ...	35
FIGURA 15. EJEMPLO DE MATRIZ DE CONFUSIÓN UTILIZADA.....	40
FIGURA 16. EJEMPLO DE CURVA ROC UTILIZADA.....	41

Índice de Tablas

TABLA 1. SENSIBILIDAD (S), ESPECIFICIDAD (E), NÚMERO DE NEURONAS EN LA CAPA OCULTA (N) Y UMBRAL (U)	33
TABLA 2. COEFICIENTES DE MATTHEWS. SE DESTACA EL UMBRAL CON EL MEJOR RESULTADO Y EL NÚMERO DE NEURONAS...	34
TABLA 3. DISTINTAS POSIBILIDADES DE EVALUACIÓN DE UNA PRUEBA	36
TABLA 4. MATRIZ DE CONFUSIÓN BÁSICA	39
TABLA 5. MATRIZ DE CONFUSIÓN AMPLIADA.....	39
TABLA 6. COMPARATIVA DE RESULTADOS CON DIFERENTES TÉCNICAS. (MCC / Nº NEURONAS CAPA OCULTA / UMBRAL).....	42
TABLA 7. COMPARACIÓN DE LAS DIVERSAS COMPLEJIDADES DE LAS REDES NEURONALES UTILIZADAS.	43