

Maestría en Ingeniería Electrónica

Detección en tiempo real de fibrilación auricular en
computador de placa reducida

Juan Carlos Maya Gonzalez

Bogotá 16 de agosto de 2018



**Detección en tiempo real de fibrilación auricular en
computador de placa reducida**

**Tesis para optar al título de magíster en Ingeniería Electrónica
con énfasis en Ingeniería Biomédica.**

**Juan Manuel Lopez Lopez PhD
Director de Tesis**

Bogotá 16 de agosto de 2018

1. Resumen

El desarrollo de dispositivos portables, que permitan la detección en tiempo real de fibrilación auricular, requiere el uso de algoritmos de reconocimiento automático de patrones con la metodología adecuada para su ejecución en sistemas embebidos. En el presente trabajo, se expone la implementación de una red neuronal artificial (ANN), una máquina de soporte vectorial (SVM), un algoritmo K vecinos más cercanos (KNN) y un modelo Híbrido, en un computador de placa reducida para obtener dicha detección automática usando ventanas de análisis de 10 segundos. Como resultado, se comparan los desempeños de los algoritmos implementados en cuanto a la capacidad de detección de esta arritmia y el tiempo de respuesta asociado a su ejecución en tiempo real. La base de datos MIT-BIH AFIB es usada para el entrenamiento y validación de los algoritmos previa extracción de características relacionadas con el uso de coeficientes wavelet. Se encontraron resultados superiores al 95 % y 96 % en la precisión de los algoritmos mencionados y variados tiempos de respuesta entre 5,7 s y 7,1 s.

Índice

1. Resumen	2
2. Introducción	7
3. Objetivos	10
3.1. Objetivo general	10
3.2. Objetivos específicos	10
4. Marco Referencial	11
4.1. Fibrilación Auricular	11
4.2. Tecnologías actuales	12
4.2.1. Monitor Externo de Eventos	13
4.3. Sistema de reconocimiento automático de fibrilación auricular	15
4.3.1. Preprocesamiento y extracción de características	16
4.3.2. Algoritmos de reconocimiento automático de patrones	18
4.3.2.1. Redes neuronales	20
4.3.2.2. Máquinas de soporte vectorial	22
4.3.2.3. K vecinos más cercanos	23
4.3.2.4. Clasificador híbrido	23
4.4. Sistemas embebidos y computador de placa reducida	24
5. Metodología	27
5.1. Materiales	27
5.2. Métodos	29
5.2.1. Preprocesamiento	30
5.2.2. Extracción de características	30
5.2.2.1. Determinación de características	31
5.2.2.2. Características extraídas	33
5.2.3. Algoritmos de reconocimiento automático de patrones	34
5.2.3.1. Implementación red neuronal artificial	35

	4
5.2.3.2. Implementación máquina de soporte vectorial	36
5.2.3.3. Implementación k vecinos más cercanos	37
5.2.3.4. Implementación modelo híbrido	38
6. Resultados y discusión	39
7. Conclusiones	45
8. Referencias	47

Índice de tablas

1.	Listado de características para la detección de fibrilación auricular	18
2.	Comparación computadores de placa reducida	28
3.	Validación cruzada modelos red neuronal	36
4.	Validación cruzada modelos máquina de soporte vectorial	37
5.	Validación cruzada modelos K vecinos más cercanos	38
6.	Sensibilidad, especificidad y precisión de algoritmos implementados . . .	40
7.	Tiempo de cómputo de algoritmos implementados	42
8.	Tiempo de respuesta de algoritmos implementados	43

Índice de figuras

1.	Ritmo electrocardiográfico normal y con fibrilación auricular	13
2.	Monitor Externo de Eventos	14
3.	Estructura general de sistema de reconocimiento de fibrilación auricular .	15
4.	Densidad espectral de potencia de señal de electrocardiografía normal . .	16
5.	Red neuronal artificial	21
6.	Máquina de soporte vectorial	22
7.	K vecinos más cercanos	23
8.	Hardware utilizado en sistema propuesto	28
9.	Lectura ejemplo de señal de base de datos MIT-BIH AFIB	29
10.	Estructura general del sistema de reconocimiento de fibrilación auricular	31
11.	División de base de datos en conjuntos de entrenamiento y validación . .	35
12.	Red neuronal implementada	36
13.	Montaje para la obtención de resultados	39

2. Introducción

Fibrilación auricular es la arritmia cardíaca más frecuente en el ser humano, el 1% de la población general, tanto en hombres como en mujeres, y hasta 10% de mayores de 80 años la padece (Vogler, Breithardt, y Eckardt, 2012). De hecho, con el aumento de la expectativa de vida e intensificación de factores de riesgo (especialmente hipertensión arterial), se está convirtiendo en una de las enfermedades de mayor prevalencia (Carvajal, Clavijo, Bautista, y Mora, 2014) (Asgari, Mehrnia, y Moussavi, 2015) (Pérez-Rodon y cols., 2014) y con muy elevados gastos para los sistemas de salud (Vogler y cols., 2012) (Vanegas-Cadavid, 2016). De manera similar, en Colombia, en los registros poblacionales se observa un crecimiento en la incidencia de fibrilación auricular en la última década, alrededor de 2.000 casos por 100.000 habitantes (Pava-Molano y Perafán-Bautista, 2016); y en un estudio realizado con electrocardiogramas en un hospital universitario colombiano, se encontró una prevalencia de 4,6% en pacientes mayores de 60 años (Rosselli, Rodríguez, García, y Rueda, 2013)

En cuanto al impacto asociado a fibrilación auricular, "se calcula que el 15% de los eventos cerebro-vasculares se atribuyen a esta arritmia" (Mora-Pabón, 2016) lo que aumenta la probabilidad de muerte o invalidez de la población afectada (Lim, Hau, Lim, y Othman, 2016). Está relacionada con el aumento de riesgo de desarrollar falla cardíaca de 3,4 veces mayor y riesgo para morir de dos veces más respecto a los pacientes que tienen ritmo sinusal. De hecho, la presencia de fibrilación auricular eleva por cinco el costo de salud de un paciente frente a aquel que no la sufre (Pava-Molano y Perafán-Bautista, 2016). De ahí que sus altos niveles de incidencia a nivel mundial generen un interés particular en el desarrollo de tecnologías para su diagnóstico (Vogler y cols., 2012).

Actualmente, en cuanto a las herramientas tecnológicas para el diagnóstico de fibrilación auricular se cuenta con equipos de electrocardiografía que, si bien resultan ser la herramienta más asequible para el paciente, son insuficientes en el manejo clínico de pacientes con fibrilación auricular, dado el carácter asintomático y paroxístico de esta arritmia (Mittal, Movsowitz, y Steinberg, 2011) (Vogler y cols., 2012). Por su parte, el equipo Holter permite monitorizar al paciente por medio de 3 a 5 electrodos, durante un periodo

de uno a dos días; terminado este tiempo, en el cual el paciente sigue su rutina diaria normal, se transfieren los datos a un computador de escritorio y el especialista realiza el análisis manual de la información recogida. Esta monitorización, si bien ofrece una mayor sensibilidad de diagnóstico del 15 al 28 % frente a la casi nula con el uso de electrocardiograma convencional (Carvajal y cols., 2014), hay un gran número de pacientes con periodicidad de ocurrencia de la afección mayor a 24 o 72 horas (Mora-Pabón, 2016) y el estudio manual de los registros incrementa la posibilidad de error en el diagnóstico.

Como alternativa a la monitorización Holter, los Monitores Externos de Eventos pueden usarse por un tiempo mucho más prolongado de hasta cuatro semanas (Carvajal y cols., 2014). Adicionalmente, con la inclusión de herramientas que reconocen y graban automáticamente las arritmias presentadas, hay mayor probabilidad de que el especialista pueda detectarlas y analizarlas, pues hay periodos cortos de tiempo que analizar prioritariamente (Villa-Rodríguez, Lemos-Duque, y cols., 2014), teniendo en cuenta además que esta arritmia es asintomática entre el 10-30 % de la población afectada (Vanegas-Cadavid, 2016). Comparando el equipo Holter con el Monitor Externo de Eventos, Carvajal y cols. (2014) establecen una mejora de la sensibilidad de este último en la detección general de arritmias con valores de hasta el 63 %.

Pese a la muy superior capacidad de diagnóstico de los Monitores Externos de Eventos, resaltada por recientes publicaciones de la revista colombiana de cardiología, estos equipos aún no se encuentran disponibles en Colombia (Mora-Pabón, 2016) (Carvajal y cols., 2014). En gran parte por los altos costos de esta tecnología (Zimetbaum y Goldman, 2010) (Rockx, Hoch, y Klein, 2005) que requiere gran capacidad para la detección automática de la arritmia con tiempos de respuesta cortos (Lim y cols., 2016) y disponibilidad de gran cantidad de memoria para el almacenamiento de datos (Pérez-Rodon y cols., 2014).

Jeon, Kim, Jeon, y Lee Jeon y cols. (2014) resaltan que diferentes herramientas computacionales para la detección de fibrilación auricular pueden estar limitadas en su ejecución en computadores de escritorio, en la medida que su implementación en plataformas portátiles o móviles pueden no presentar resultados satisfactorios en el tiempo de ejecución, de ahí que no se cuente con numerosas investigaciones dedicadas al estudio de posibles

soluciones para la detección de fibrilación auricular en tiempo real en sistemas embebidos. Por un lado, se requiere un alto grado de certeza en la detección de la fibrilación auricular, y por otro, se requiere una velocidad de procesamiento adecuada.

Como alternativa, un computador de placa reducida, por tratarse de computador en una sola placa y de tamaño reducido, puede utilizarse para la implementación de sistemas embebidos portables como en el caso de un Monitor Externo de Eventos Automático, y los recursos con los que actualmente se fabrican, hacen suponer un adecuado desempeño de diferentes algoritmos para la detección automática de la arritmia tanto en su capacidad de reconocimiento como en su tiempo de respuesta, variables esenciales en la propuesta de un equipo biomédico práctico (Basaif, Aljunid, Sabri, Omer, y Salim, 2016).

En cuanto a las herramientas computacionales necesarias, entre los algoritmos de reconocimiento automático de patrones más utilizados para la detección de fibrilación auricular se encuentran: k vecinos más cercanos (KNN), redes neuronales artificiales (ANN), y máquinas de soporte vectorial (SVM) (Lim y cols., 2016). Algoritmos que en la presente investigación se implementan en un computador de placa reducida para realizar su evaluación de desempeño en cuanto a capacidad de detección de fibrilación auricular y tiempo de respuesta. Conocimiento no encontrado actualmente en investigaciones relacionadas y útil a nivel nacional en futuras propuestas para la realización de Monitores Externos de Eventos Automáticos actualmente no disponibles y altamente demandados en el país.

3. Objetivos

3.1. Objetivo general

Caracterizar el desempeño, en cuanto a sensibilidad, especificidad y tiempo de respuesta, de los algoritmos de reconocimiento automático de patrones ANN, KNN, SVM y modelos híbridos, en la detección en tiempo real de fibrilación auricular en computador de placa reducida Raspberry Pi, usando la base de datos MIT-BIH AFIB para su entrenamiento y validación.

3.2. Objetivos específicos

- Recopilar señales de electrocardiografía con y sin fibrilación auricular de la base de datos MIT-BIH AFIB y determinar las características a extraer para su posterior uso en el entrenamiento e implementación de diferentes algoritmos de reconocimiento de patrones.
- Implementar en computador personal, las herramientas para la extracción de características y los algoritmos de reconocimiento automático de fibrilación auricular, y determinar su sensibilidad y especificidad usando las señales de base de datos.
- Implementar y evaluar algoritmos en computador de placa reducida en términos de sensibilidad y especificidad con base en señales de bases de datos previamente guardadas en memoria.
- Implementar y evaluar la ejecución en tiempo real del reconocimiento automático de fibrilación auricular en términos de tiempo de respuesta.

4. Marco Referencial

4.1. Fibrilación Auricular

El sistema cardiovascular tiene como función principal transportar sangre desde y hacia el corazón en una vasta red de vasos sanguíneos. Con el fin de garantizar, entre muchas funciones, el metabolismo celular para la generación de energía vital de cada uno de los tejidos y por ende la operación de cada uno de los sistemas del cuerpo humano.

Como órgano principal del sistema circulatorio, el corazón funciona como una cavidad muscular que permite a través de sus relajaciones y contracciones el bombeo de sangre hacia todos los tejidos del cuerpo. Esta contracción y relajación rítmica se encuentra regulada por el sistema nervioso autónomo, y parte de un impulso eléctrico en el nódulo sinusal (marcapasos natural del corazón ubicado en la parte superior de la aurícula derecha) que se esparce por las aurículas produciendo así su contracción, consecuentemente, el potencial eléctrico llega al nódulo auriculoventricular para viajar a través del haz de His y las fibras de Purkinje hacia las células musculares de los ventrículos que permitirán su contracción siguiente.

Una vez propagados los impulsos cardíacos, gracias a la contracción de las aurículas y ventrículos, se garantiza el bombeo de sangre pobre en oxígeno desde el ventrículo derecho hacia los pulmones para su oxigenación, y el bombeo de sangre rica en oxígeno desde el ventrículo izquierdo hacia todos los tejidos. De ahí que la caracterización de los ciclos cardíacos permita diferenciar entre un ritmo sinusal (latido normal del corazón) y algún tipo de arritmia, arritmias de variadas causas como: anormalidad en la frecuencia del marcapasos, desplazamiento del nódulo sinusal, bloqueos de puntos de propagación o vías anormales de propagación y generación espontánea de pulso anormales (Guyton, Hall, Arthur, y John, 2002).

En la fibrilación auricular, las aurículas son excitadas aleatoriamente y eventualmente se anula el impulso generado por el marcapasos natural, que es el nodo sinoatrial. Como consecuencia, el corazón presenta un progresivo déficit de bombeo de sangre, aumentando la probabilidad de muerte o invalidez de la población afectada (Lim y cols., 2016). Para algunas personas la arritmia se presenta continuamente, y para otras, el ritmo normal

puede suceder después de cierto tiempo (tiempos tan variados como arritmias de apenas un segundo a días) (Lim y cols., 2016). Esta baja predictibilidad de algunos casos, y la ocurrencia asintomática en otros, son algunas de las problemáticas que enfrenta el desarrollo de tecnologías para su diagnóstico oportuno. En el caso de diagnóstico por registro electrocardiográfico, se presentan mayores dificultades en la detección de ausencia de la onda P (ver figura 1) y en acertada medición de la duración de la arritmia en intervalos cortos de duración en aplicaciones en tiempo real.

4.2. Tecnologías actuales

Para el diagnóstico de fibrilación auricular, el análisis de la señal electrocardiográfica (ECG) es ampliamente usado, tratándose de la captura de la actividad eléctrica del corazón, propagada hacia la piel del paciente luego de que grupos de células que se despolarizan simultáneamente (representándose eléctricamente como un dipolo) generan vectores que sumados a los demás grupos representan el vector resultante del impulso eléctrico (Sornmo, 2011), en la figura 1 se presenta la señal resultante común de un ritmo normal y con fibrilación auricular.

El electrocardiograma de 12 derivaciones, que resulta ser la herramienta más asequible para el paciente, es insuficiente en el manejo clínico de pacientes con fibrilación auricular, dado el carácter asintomático y paroxístico de esta arritmia Mittal y cols. (2011) Vogler y cols. (2012).

Por otra parte, la monitorización Holter permite monitorizar al paciente por medio de 3 a 5 electrodos durante un periodo de uno a dos días. Terminado este tiempo, en el que el paciente sigue su rutina diaria normal, se transfieren los datos a un computador de escritorio y el especialista realiza el análisis de la información recogida. Esta monitorización ofrece una mayor sensibilidad de diagnóstico; del 15 al 28 % frente a la casi nula con el uso de electrocardiograma convencional (Carvajal y cols., 2014). Sin embargo, hay un gran número de pacientes con periodicidad de ocurrencia de la afección mayor a 24 o 72 horas (Mora-Pabón, 2016). Adicionalmente, Zimetbaum y Goldman (2010) presentan entre las principales desventajas de este dispositivo: la limitación de procesar información

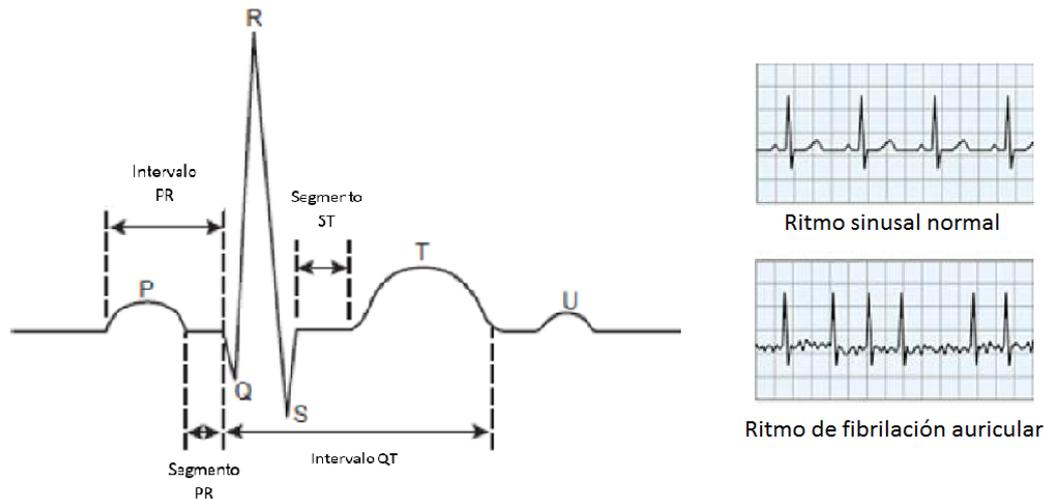


Figura 1. Señal de electrocardiografía con ritmo normal con sus ondas, segmentos e intervalos (izquierda), editada de (Batista y Fred, 2015). A la derecha se presenta el comparativo entre un ritmo sinusal y uno con fibrilación auricular, editado de (Lim y cols., 2016)

en tiempo real, el requerimiento de que el paciente debe estar despierto y el frecuente incumplimiento de su parte en cuanto la realización de anotaciones correspondientes (en una libreta) de los momentos en que tiene alguna molestia relacionada .

4.2.1. Monitor Externo de Eventos. Como alternativa a la monitorización Holter, los Monitores Externos de Eventos pueden usarse por un tiempo mucho más prolongado de hasta cuatro semanas (Carvajal y cols., 2014). Su uso se representa en la figura 2. Adicionalmente, con la inclusión de un marcador de eventos, hay mayor probabilidad de que las arritmias queden claramente grabadas en la memoria del dispositivo, y el especialista pueda detectarlas y analizarlas, pues ahora hay periodos cortos de tiempo que analizar prioritariamente (Villa-Rodríguez y cols., 2014).

Comparando el método Holter con el Monitor Externo de Eventos, Carvajal y cols. (2014) establecen una mejora de la sensibilidad de este último en la detección general de arritmias con valores de hasta el 63%, comparado con el 28% del examen Holter. Por otra parte, entre estos monitores se encuentran tanto los que graban eventos por accionamiento manual del paciente y los que detectan automáticamente arritmias para realizar la



Figura 2. Uso de Monitor Externo de Eventos, tomado de Zimetbaum y Goldman (2010)

grabación, observándose una mayor detección de estos últimos del 72 a 80 % versus un 17 a 72 % en los manuales (Carvajal y cols., 2014). Al respecto, Zimetbaum y Goldman (2010) mencionan entre las limitaciones de los monitores manuales, el requerimiento de que el paciente debe estar despierto, además de tener una coherencia y disposición suficiente para la activación del dispositivo, no olvidando que las arritmias ocurridas pueden ser asintomáticas, como en algunos casos de fibrilación auricular.

El Monitor Externo de Eventos Automático está indicado en el estudio de pacientes con eventos cerebro-vasculares o ataque isquémico transitorio criptogénico, y pacientes sometidos a ablación de fibrilación auricular (acompañados en lo posible con telemetría ambulatoria) (Mora-Pabón, 2016). La Sociedad Colombiana de Cardiología advierte que, pese a la mayor utilidad de estos equipos, lamentablemente no se encuentran disponibles en Colombia (Mora-Pabón, 2016), (Carvajal y cols., 2014). Fuera de Colombia, el precio de estos equipos resulta ser del doble de los equipos de monitorización estándar (Zimetbaum y Goldman, 2010) (Rockx y cols., 2005).

Con respecto al tiempo de respuesta, sobre todo en pacientes con posible toxicidad de fármacos antiarrítmicos se requiere el acceso inmediato a los datos (Zimetbaum y Goldman, 2010) . Adicionalmente, se recalca que entre los parámetros más importantes a obtener de la monitorización está la duración precisa de la fibrilación (Mittal y cols., 2011) y la densidad de las arritmias en un periodo de tiempo (Vanegas-Cadavid, 2016).

La dificultad en la implementación de Monitores Externos de Eventos Automáticos está determinada por la inclusión de complejos algoritmos para la detección automática de la arritmia, y su desempeño es inversamente proporcional al tiempo de respuesta (Lim y cols., 2016). Por un lado, se requiere un alto grado de certeza en la detección de la fibrilación auricular, y por otro, se requiere una velocidad de procesamiento adecuada.

Por ello, el proponer una herramienta tecnológica para tal fin involucra revisar los algoritmos de reconocimiento de patrones pertinentes para su aplicación en una tarjeta electrónica, como sistema embebido portable para la detección automática de fibrilación auricular. Las siguientes dos secciones estudian tanto los algoritmos de reconocimiento automático (incluida la extracción de características), como los sistemas embebidos utilizados en diferentes investigaciones consultadas.

4.3. Sistema de reconocimiento automático de fibrilación auricular

La señal de electrocardiografía adquirida de un paciente se puede procesar computacionalmente para detectar automáticamente si presenta o no algún tipo de arritmia, en nuestro caso de estudio, fibrilación auricular. Para ello, deben extraerse de la señal ciertas características que permitan distinguir fácilmente y con el mayor nivel de generalización posible, la presencia o no de la arritmia. Una vez establecidas las características, el paso siguiente es aplicar un algoritmo de reconocimiento automático de patrones que las categorice como pertenecientes a una señal con o sin fibrilación auricular, ver figura 3. Así, los algoritmos se dividen en dos etapas fundamentales, por un lado el preprocesamiento y la extracción de características, y por otro, los algoritmos de reconocimiento automático de patrones.

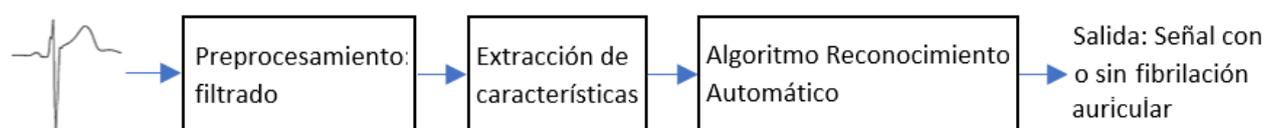


Figura 3. Estructura general de sistema de reconocimiento de fibrilación auricular

4.3.1. Preprocesamiento y extracción de características. En cuanto al preprocesamiento, la señal electrocardiográfica con o sin fibrilación auricular adquirida incluye ruido inherente a la influencia natural de demás señales biológicas y al proceso de medida asociado. Entre las principales fuentes de ruido eléctrico se encuentran: ruido de contacto de electrodos, artefactos musculares, interferencia de línea, variaciones en línea de base, ruido asociados al dispositivo de captura, entre otros (Martis, Acharya, y Adeli, 2014). De ahí que en aras de una posterior clasificación adecuada de la señal, es fundamental como primera medida el filtrado de la señal. Es común, por ejemplo, realizar un filtrado pasa bandas entre 0.5 y 50 Hz (Asgari y cols., 2015) (ver figura 4), teniendo en cuenta que de hecho, la actividad atrial usualmente ocurre entre las frecuencias de 4 a 9 Hz (Asgari y cols., 2015).

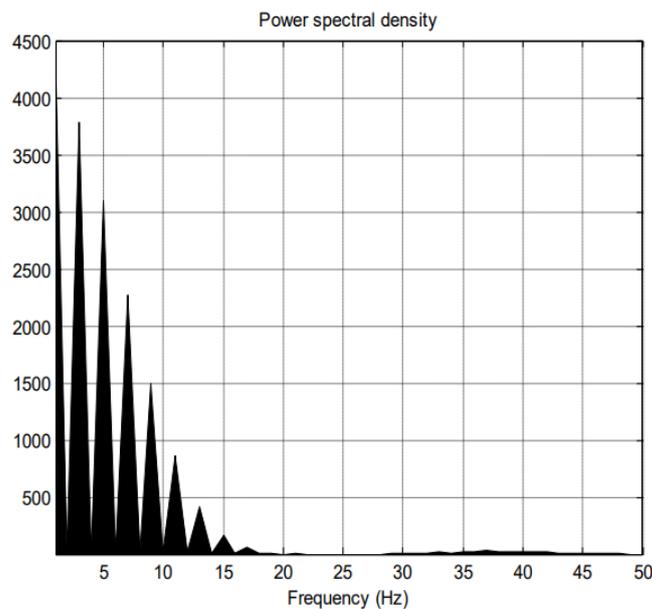


Figura 4. Densidad espectral de potencia de señal de electrocardiografía normal, tomado de Das y Chakraborty (2011).

Si bien el filtrado de la señal puede realizarse por medios analógicos o digitales mediante la implementación de filtros específicos, también es usual utilizar la transformada Wavelet discreta hasta un nivel específico según el propósito (Rodríguez, Gallego, Mora, Orozco-Duque, y Bustamante, 2014). En esta transformada se trata de estimar la correlación de la señal a analizar con versiones escaladas (cambios en frecuencias) y trasladadas de una

onda madre principal. La manera más práctica de calcularla es usando filtros consecutivos para el cálculo de aproximaciones y detalles (Misiti, Misiti, Oppenheim, y Poggi, 1996). La transformada Wavelet representa una señal en una secuencia de coeficientes basados en bases ortogonales ψ de ondas finitas (wavelet madre, trasladada (τ) y escalada en el tiempo(n)). Como en la ecuación 1, se define la transformada wavelet para señales discretas como la correlación entre la señal y la función ψ escalada y trasladada en el tiempo (Rodriguez y cols., 2014).

$$[W_{\psi}f](s, \tau) = \sum_{-\infty}^{\infty} \psi_{s,\tau}(n) f(n) \quad (1)$$

Una vez realizado el preprocesamiento de la señal, la extracción de características permite al siguiente paso procesar la señal como una selecta colección de rasgos que facilitan el reconocimiento de la arritmia, entre las herramientas para extracción de características de señales de electrocardiografía se encuentran las basadas en el dominio del tiempo, frecuencia y tiempo-frecuencia (Martis y cols., 2014). Por último, con las características iniciales ya extraídas, métodos adicionales como Análisis de Componentes Principales (PCA) y Análisis de Componentes Independientes (ICA) permiten reducir el número de características a procesar, propiciando así su análisis más rápido. El cuadro 1 lista las características más utilizadas en aplicaciones de reconocimiento automático de fibrilación auricular.

Tabla 1

Listado de características extraídas para la detección de fibrilación auricular usadas o referenciadas en las citas presentadas

Dominio	Característica
Tiempo	Variabilidad de frecuencia cardíaca: valor medio intervalos RR, desviación estándar de intervalos RR... (Lim y cols., 2016), (Basaif y cols., 2016)
	Morfología onda P, R o complejo QRS (Lim y cols., 2016) (Leutheuser y cols., 2014)
	Momentos estadísticos (Leutheuser y cols., 2014)
Frecuencia	Parámetros de densidad espectral de potencia. (Martis y cols., 2014)
	Parámetros de densidad espectral de potencia en sub- bandas frecuenciales HF, LF y VLF (Chen, Cheng, Liao, y Kuo, 2014)
Tiempo - frecuencia	Valor medio e integral de PSD de descomposiciones hasta el sexto nivel Wavelet (Batista y Fred, 2015)
	Relaciones energía pico sobre promedio de descomposiciones hasta el sexto nivel Wavelet (Asgari y cols., 2015)
	Entropía de descomposiciones hasta el sexto nivel Wavelet (Asgari y cols., 2015)
	Análisis de componentes principales de la descomposición wavelet (Martis y cols., 2014)
	Coefficientes de la descomposición Wavelet hasta el séptimo nivel con análisis de componentes principales (Martis y cols., 2014) o analisis de componentes independientes (Martis, Acharya, Prasad, Chua, y Lim, 2013)

4.3.2. Algoritmos de reconocimiento automático de patrones. Una vez extraídas las características, es posible aplicar un algoritmo de reconocimiento automático de patrones que previamente entrenado sepa distinguir entre características procedentes de una señal con o sin fibrilación auricular.

En general, los algoritmos de reconocimiento automático de patrones utilizan en primera instancia un conjunto de datos para su entrenamiento y otro para su validación, ambos provenientes generalmente de bases de datos con alto grado de aceptación científica. Entre

las bases de datos más usadas se encuentran la de la Asociación Americana del Corazón (base de datos AHA), la del Instituto de Tecnología de Massachusetts (base de datos MIT-BIH) y la del grupo Pisa con apoyo de la Sociedad Europea de Cardiología (base de datos europea ST-T) (Moody, 2001).

Con el conjunto de datos de entrenamiento, es posible caracterizar el algoritmo de reconocimiento de patrones que maximice la discriminación entre las categorías a clasificar. Y una vez entrenado, conviene especificar las medidas de su desempeño estadístico en cuanto a su respuesta para la clasificación de nuevas señales (datos del conjunto de validación). Aquí es importante recalcar que este conjunto de datos no ha sido usado en ninguna medida en el proceso de entrenamiento, e incluye su categorización clara según criterio científico, en nuestro caso el concepto médico. Este conjunto de validación incluye P muestras con fibrilación auricular (muestras positivos) y N muestras sin ella (muestras negativas).

Entre los parámetros más usados para caracterizar el desempeño se encuentran la sensibilidad, la especificidad y la precisión. Si el algoritmo clasificador clasifica adecuadamente TP fibrilaciones auriculares (Verdaderos positivos), la sensibilidad puede expresarse como en la ecuación 2, siendo FN el número de falsos negativos. Por otro lado, si se clasifican adecuadamente TN señales sin fibrilación auricular (verdaderos negativos), la especificidad puede expresarse como en la ecuación 3, siendo TN el número de verdaderos negativos; la precisión, por su parte, se representa en la ecuación 4.

$$S_n = \frac{TP}{TP + FN} \quad (2)$$

$$S_p = \frac{TN}{FP + TN} \quad (3)$$

$$Precisión = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

En resumen, sensibilidad hace relación a la medición de la proporción de positivos (en nuestro caso, señales con fibrilación auricular) correctamente identificados; especificidad mide la proporción de negativos (señales sin fibrilación auricular) que son correctamente

identificados como tal; y precisión informa sobre el número general de aciertos en la clasificación sobre el número total de casos examinados.

En cuanto a los diferentes algoritmos de reconocimiento automático de patrones, si para cada uno de los datos de entrenamiento se conoce previamente a qué categoría pertenece, se trata de algoritmos de aprendizaje supervisado; mientras que, en caso de no conocerse a priori su categoría, y se pretende que el algoritmo organice y discrimine los datos de manera autónoma, se trata de aprendizaje no supervisado.

Los modelos supervisados son los más utilizados en el reconocimiento automático de fibrilación auricular, entre ellos se encuentran: clasificadores bayesianos, análisis de discriminación lineal, k vecinos más cercanos (KNN), redes neuronales artificiales (ANN), máquinas de soporte vectorial (SVM) y clasificación basada en el conocimiento (KBC) (Lim y cols., 2016). Mientras que, en cuanto a aprendizaje no supervisado, clustering resulta ser la estrategia más común para su entrenamiento; k-means presenta por ejemplo algunos buenos resultados en la clasificación de arritmias según lo presentan Rodriguez y cols. (2014), aunque no precisamente para fibrilación auricular.

En razón a que el presente trabajo se basó en la base de datos MIT-BIH AFIB que incluye la categorización clara de las señales según el análisis previo de un especialista, los modelos aplicados fueron los supervisados. A continuación, se expone la base teórica de los diferentes algoritmos utilizados y su aplicación en el reconocimiento automático de fibrilación auricular, no se estudia los clasificadores bayesianos en cuanto a que ofrecen menor sensibilidad y especificidad que SVM y ANN, según la revisión de métodos de reconocimiento de fibrilación atrial realizada por (Lim y cols., 2016) (Asgari y cols., 2015); aunque un trabajo exhaustivo y más detallado en la extracción de características para garantizar que todas sean independientes entre ellas, puede generar mejores resultados de los clasificadores bayesianos para el reconocimiento de arritmias, según se estudia en (Martis y cols., 2013).

4.3.2.1. Redes neuronales. Su uso computacional pretende modelar el comportamiento del cerebro biológico mediante la interconexión de muchas neuronas para procesar información de entrada (características) y generar una salida (decisión si las características

corresponden o no fibrilación auricular).

Como se representa en la figura 5, cada una de las neuronas corresponden a los puntos de unión donde se realizan las sumas de la multiplicación de cada entrada por un peso previamente establecido, el esquema se repite con nuevas capas aumentando la complejidad del algoritmo clasificador. En este caso, previamente la red neuronal tuvo que ser entrenada para establecer el valor de cada uno de los pesos, el entrenamiento se hace ajustando iterativamente los pesos según la lectura de bases de datos en los que se conoce a priori la presencia o no de la arritmia. Para el caso de una topología feed-forward perceptrón con tres capas con función de activación sigmoïdal (como se recomienda en (Raj, Luthra, y Ray, 2015)) su función de transferencia se presenta en la ecuación 5; con x el vector de características a analizar, IW y $b1$ los pesos de la capa oculta, y LW con $b2$ los pesos de la capa de salida.

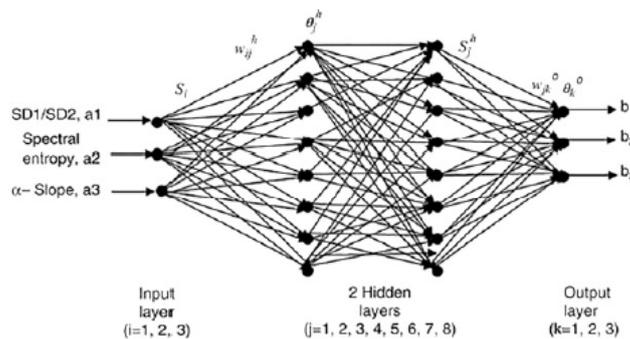


Figura 5. Red neuronal artificial, tomado de Lim y cols. (2016)

$$f(x) = \text{sigmod}(LW * \text{sigmod}((IW * x) + b1) + b2) \quad (5)$$

En cuanto a su aplicación en la detección de fibrilación auricular Lim y cols. (2016) listan seis investigaciones basadas en redes neuronales con diversos métodos de extracción de características. En los estudios, que datan del año 1994 hasta el 2013, se encuentran sensibilidades superiores al 88 %, mientras que las especificidades superan el 85 %. Por su parte, Batista y Fred (2015) presenta un error medio de 9.2 %, utilizando características según la descomposición wavelet.

4.3.2.2. Máquinas de soporte vectorial. Partiendo de un conjunto de muestras (en el espacio de características) con o sin fibrilación auricular, este modelo busca un hiperplano que separe todas las muestras en dos subespacios, de tal modo que al tener un nuevo dato (vector características), es posible determinar de qué lado de la separación se encuentra, y así determinar si corresponde al subespacio de características con fibrilación auricular o sin ella. Adicionalmente, SVM procura establecer el mayor nivel de margen entre las dos categorías a clasificar como se muestra en la figura 6 Anwar (2014).

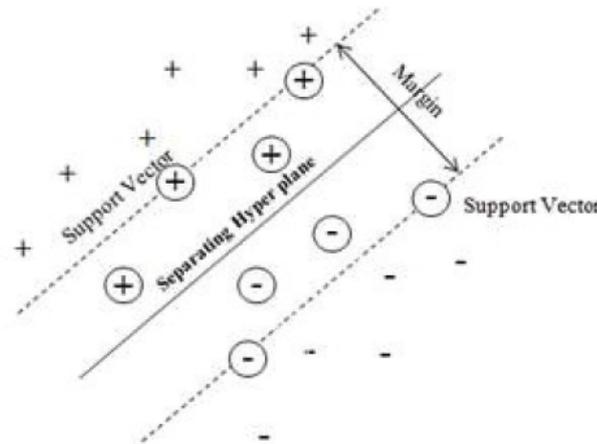


Figura 6. Máquina de soporte vectorial, tomado de Deepthi, Ravikumar, y Nair (2016a)

En la figura 6, se trata del caso simple bidimensional, donde se han analizado todas las muestras para determinar el hiperplano de separación óptimo. El algoritmo se puede aplicar también para el caso n dimensional, con la posible inclusión adicional de kérneles para subespacios separables a un nivel de complejidad mayor.

En la ecuación 6 se presenta su función de clasificación, siendo x el vector de características a clasificar; k la función kernel, b el margen de separación, α_i los coeficientes de lagrange y x_i el i ésimo vector de soporte, estos parámetros resultantes del proceso de entrenamiento.

$$f(x) = \sum_{i=1}^n \alpha_i (k(x, x_i) + b) \quad (6)$$

Lim y cols. (2016) analiza para este caso seis investigaciones desde el año 2009 al 2015 que utilizan este método, las sensibilidades y especificidades encontradas superan el 91% y el 92% respectivamente. El error medio encontrado por Batista y Fred (2015) utilizando

la descomposición wavelet y SVM es inferior al de ANN y KNN, 4,53%. Anwar (2014) presenta también mejores resultados utilizando este método que con ANN.

4.3.2.3. *K vecinos más cercanos.* Este clasificador, a diferencia de los anteriores, no requiere etapa de entrenamiento (Homaeinezhad y cols., 2012), y está basado en el análisis de la distancia geométrica entre una nueva muestra y las demás del conjunto de entrenamiento. Para ilustrar con un ejemplo, como se presenta en la figura 7, un nuevo vector de características es clasificado en una de las categorías, si al revisar geoméricamente un número determinado de vecinos, este se encuentra en una vecindad mayoritaria de determinada categoría. Así, el algoritmo incluye el cálculo de las distancias y el conteo de vecinos más cercanos de cada categoría.

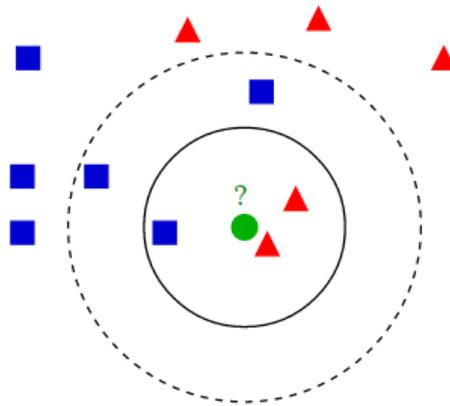


Figura 7. K vecinos más cercanos, tomado de Contributors (2018), la nueva muestra (verde) se clasifica como roja.

En cuanto a su aplicación en la detección de fibrilación auricular, Lim y cols. (2016) lista seis investigaciones basadas en este algoritmo con diversos métodos de extracción de características. En los estudios, que datan del 2004 hasta el 2015, se encuentran sensibilidades en todo caso superiores al 84%, mientras que las especificidades superan el 76%, con algunos resultado incluso superiores a los presentados en SVM.

4.3.2.4. *Clasificador híbrido.* Como se ha presentado anteriormente, diferentes algoritmos presentan desempeños diferentes en la detección de arritmias, y es este mismo hecho el que posibilita la creación de clasificadores adicionales con base en la integración de clasificadores individuales. Esta integración se conoce como clasificadores Híbridos.

Para obtener mejores resultados con la implementación de clasificadores híbridos, se requiere que los diferentes clasificadores tengan errores de clasificación diferentes, situación fácilmente predecible en razón a que ANN, KNN Y SVM son teórica y estructuralmente diferentes (Homaeinezhad y cols., 2012). Homaeinezhad y cols. (2012) y Chen y cols. (2014) obtuvieron una mejora en la clasificación de arritmias cardíacas utilizando clasificadores híbridos en comparación con el desempeño de clasificadores individuales.

Entre las técnicas para la implementación de clasificadores híbridos se encuentran: voto mayoritario, bagging , dagging y DECCORATE. Deepthi, Ravikumar, y Nair (2016b) encontraron que, en detección de arritmias, el ensamble que mejores resultados presenta es el de voto mayoritario. Tratándose este de un arreglo de clasificadores independientes en el cual se examina la respuesta de cada uno de ellos como si se tratase de un conteo de votos, y dependiendo la salida que haya obtenido mayor número de votos, esta se reflejará en la salida.

4.4. Sistemas embebidos y computador de placa reducida

Un sistema embebido es un sistema electrónico con microcontrolador o microprocesador, equipado con periféricos de entrada y salida, portable y que permite ejecutar una tarea específica. (Lim y cols., 2016). Entre las limitaciones de los sistema embebidos se encuentran la menor velocidad de ejecución y la menor disponibilidad de energía para su uso (Lim y cols., 2016). Es común, por ejemplo, encontrar que algoritmos complejos con alto desempeño consuman muchos recursos, lo que significa tiempos de procesamiento elevados.

En general, en la caracterización del desempeño de algoritmos para el reconocimiento de arritmias cardíacas, adicional a la sensibilidad y especificidad presentados previamente, se requiere estimar su costo computacional. Para ello, es usual medir el tiempo de predicción del algoritmo (Rodriguez y cols., 2014), en algunos casos se especifica el uso de la CPU en porcentaje (Jeon y cols., 2014), en otros se discrimina el tiempo de transición (tiempo de espera para detección de cambios de señal con o sin fibrilación atrial) y el tiempo de cómputo(Asgari y cols., 2015).

En cuanto a las diferentes investigaciones relacionadas con la implementación de algoritmos en sistemas embebidos para el reconocimiento automático de arritmias cardíacas, Orozco-Duque y cols. (2013) presentan buenos resultados en la implementación de una red neuronal y una máquina de soporte vectorial en microcontrolador ARM de 32 bits Cortex M4 y una red neuronal en una FPGA Spartan 6, aunque no precisamente para detección de fibrilación atrial, si no en taquicardia ventricular y fibrilación ventricular, Raj, Maurya, y Ray (2015) presentan también la implementación satisfactoria de reglas de decisión en el reconocimiento de fibrilación ventricular, contracciones ventriculares prematuras (pvc) y señal normal en una FPGA artix 4.

Raj, Luthra, y Ray (2015), por su parte, también presentan un sistema basado en microcontrolador ARM para la detección de diversas arritmias utilizando redes neuronales y la extracción de características temporales con aplicación de PCA, su sensibilidad y especificidad supera el 92%. Por otra parte, Leutheuser y cols. (2014) realizan la implementación y análisis de los diferentes algoritmos para el reconocimiento de arritmia cardíaca en dispositivo móvil basado en Android (incluidos los previamente expuestos en el presente trabajo), presentan resultados de desempeño en algunos casos inferiores al 80% de sensibilidad, y su costo computacional y uso de memoria deja en evidencia que algoritmos como K vecinos más cercanos no tienen una aplicación práctica en este dispositivo en relación al elevado tiempo de respuesta requerido.

Al respecto Jeon y cols. (2014) resalta que varios algoritmos de reconocimiento de patrones y extracción de características están limitados a su ejecución en computadores de escritorio o portátiles, en la medida que su implementación en plataformas portátiles o móviles pueden no presentar resultados satisfactorios en el tiempo de ejecución. Lim y cols. (2016) recalcan por ejemplo que métodos como SVM y ANN pueden involucrar mayor complejidad en la implementación eficiente en sistemas embebidos, con lo que para el reconocimiento automático de fibrilación atrial en sistemas embebidos, se requieren mayores prestaciones en hardware en la medida de la demanda de alta exactitud y tiempos de ejecución cortos.

Hay que prever que un monitor de eventos cardíacos, aparte de requerir de los recursos

comunes encontrados en sistemas embebidos con microcontroladores y FPGA, debe tener la facultad de grabar todos los episodios que se presentan en el transcurso del examen (hasta cuatro semanas), de modo que se debe al menos disponer de una capacidad de memoria suficiente que permita almacenar esta información, situación que es precisamente una limitación en hardware del equipo Holter.

Como herramienta tecnológica propuesta que últimamente integra mayores prestaciones en hardware, un computador de placa reducida se define como un circuito impreso que contiene todos los recursos para crear un microcomputador funcional, entre ellos se encuentran: microprocesador, memoria RAM, controladores periféricos y diversos tipos de chips adicionales (Braun, Moss, y Stigall, 1986). Sus características, como la buena relación costo efectivo, pequeño tamaño, capacidad de procesamiento, suficiente memoria, disponibilidad de puertos y conexión a periféricos, son las que incentivan su uso en sistemas embebidos para el diagnóstico de afecciones cardíacas. (Basaif y cols., 2016).

Aunque Lim y cols. (2016) presentan la revisión de diferentes algoritmos de detección de fibrilación atrial, no se incluyen ahí trabajos que se relacionen con computadores de placa reducida. Y así como se ha podido establecer, en computadores personales y en algunos dispositivos de propósito específico, la caracterización del desempeño de diferentes algoritmos de reconocimiento de fibrilación atrial; se requiere realizar también la caracterización comparativa suficiente de los algoritmos en computador de placa reducida, y establecer la estrategia para crear dichos algoritmos, conocimiento base en futuras implementaciones de Monitores Externos de Eventos Automáticos.

5. Metodología

5.1. Materiales

El computador de placa reducida es el elemento central, en hardware, del sistema propuesto para la detección de fibrilación auricular en tiempo real. Y en cuanto su selección, en la tabla 2 se presenta la comparación de las especificaciones técnicas de 5 diferentes dispositivos ampliamente usados en la actualidad. En síntesis, se destaca el computador Raspberry Pi 2 dado a su bajo costo, su mayor número de núcleos, memoria RAM elevada y tamaño inferior al resto; características que favorecen el desarrollo de sistemas embebidos portables con gran capacidad de procesamiento, como se requiere en la presente investigación.

Con relación a la lectura de señal análoga (en este caso, de electrocardiografía), si bien otros computadores de placa reducida pueden incluir en la misma tarjeta el conversor análogo digital, su capacidad de cómputo (característica crítica para la ejecución de algoritmos de alto consumo computacional) puede ser inferior. Razón por la cual se prefirió utilizar un dispositivo con mayor capacidad de cómputo y apoyarse de un módulo conversor análogo digital externo para realizar la lectura de la señal de electrocardiografía. Adicionalmente, el dispositivo Raspberry Pi 2 cuenta con mayor documentación y soporte que los demás dispositivos, como consecuencia de ser uno de los actuales dispositivos más vendidos y respaldado por una amplia comunidad para compartir recursos tanto de software como de hardware (Upton y Halfacree, 2014).

El sistema a utilizar consta entonces de un computador de placa reducida Raspberry Pi 2 que incluye un procesador quad-core ARM Cortex-A7, las características o recursos mencionados, y puertos digitales para comunicación con diferentes periféricos (He, Segee, y Weaver, 2016). En él se realiza el preprocesamiento, la extracción de características y el reconocimiento automático de fibrilación auricular de señales tanto guardadas en memoria como provenientes de un módulo análogo digital externo ADS1115 (conversor con resolución de 16 bits y frecuencia de muestreo de 860Hz) conectado vía I2C y que permite adquirir la señal a analizar proveniente de un generador de señales.

Una vez los algoritmos son ejecutados, la información es almacenada en memoria y es

Tabla 2

Comparación computadores de placa reducida

Computador de placa reducida	CPU	Num. de Núcleos	RAM	Tamaño	Costo	ADC
Raspberry Pi 2	900 MHz	4	1 GB	85.6x54 mm	\$35	No
BeagleBone Black	1 GHz	1	512 MB	86.4x53.3 mm	\$48	Si
pcDuino3	1 GHz	2	1 GB	121x65 mm	\$40	Si
Intel Galileo Gen 2	400 MHz	1	256 GB	123.8x72 mm	\$68	Si
Acadia V3	1.2 GHZ	4	1 GB	145x76 mm	\$119	Si

presentada en una pantalla TouchScreen referencia ADAFR-2097 para visualizar tanto la señal analizada como el resultado de su análisis. En la figura 8 se representa el hardware implementado.

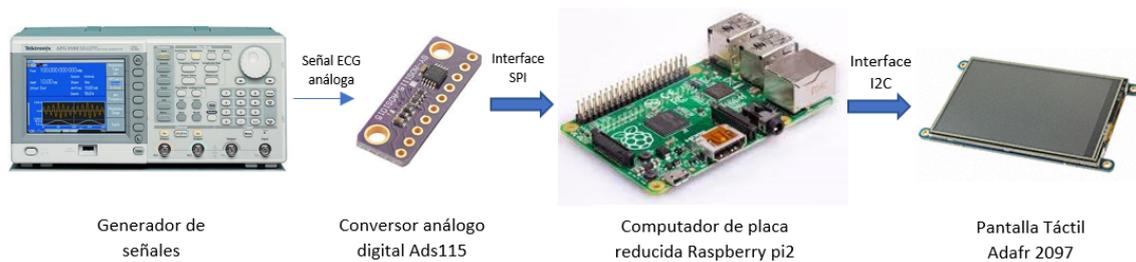


Figura 8. Computador de placa reducida con pantalla táctil y módulo análogo digital para la lectura y clasificación de señales electrocardiográficas

Para la evaluación de desempeño de los algoritmos de reconocimiento automático de patrones en la detección de fibrilación auricular en computador de placa reducida se propone el uso de la base de datos MIT-BIH AFIB (encontrada en (Goldberger y cols., 2000)). Base de datos de uso generalizado en investigaciones afines y que contiene 23 registros de electrocardiografía de pacientes que presentan fibrilación auricular, con una frecuencia de muestreo de 250Hz, a una resolución de 12 bits y un rango de $+/- 10mv$. Cada registro tiene una duración de 10 horas, en total se incluyen 291 episodios de fibrilación auricular con un tiempo promedio de 115 segundos, y 344 episodios de otros

ritmos cardíacos (Asgari y cols., 2015). Estos episodios se encuentran marcados, con anotaciones en tiempos específicos según revisiones previas de especialistas creadores de la base de datos; en la figura 9 se representa, como ejemplo, un recorte de un archivo de la base de datos con la anotación respectiva en la medida que la señal cardíaca cambia llegando el segundo 5 de ritmo normal a ritmo con fibrilación auricular.

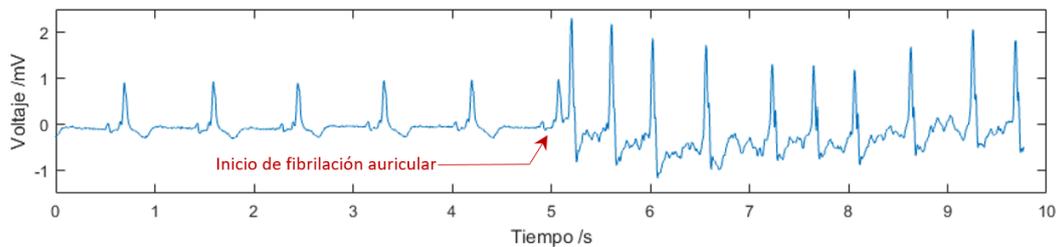


Figura 9. Ejemplo de lectura de señal filtrada en archivo 4048 de base de datos MIT-BIH AFIB encontrada en (Goldberger y cols., 2000)

5.2. Métodos

La metodología para la implementación del sistema final para el reconocimiento automático de fibrilación auricular consistió en el trabajo previo en computador personal para realizar la lectura de la base de datos MIT-BIH AFIB anteriormente presentada, determinar las características a extraer de las señales y entrenar los algoritmos con ayuda de los paquetes de procesamiento de señales y aprendizaje automático de Matlab y Python. El sistema analiza segmentos de 10 segundos de señal electrocardiográfica siguiendo las recomendaciones de Asgari y cols. (2015), quienes encontraron que usando coeficientes wavelet es factible disminuir la longitud de la ventana de análisis hasta 10 segundos sin afectar la capacidad de detección de los clasificadores (ventanas más cortas de trabajo pueden significar una velocidad de cómputo mayor a costa de una disminución considerable de la precisión en la detección de fibrilación auricular); usar por otro lado segmentos de análisis más largos implicaría la no detección de fibrilaciones paroxísticas de corta duración, detecciones de gran relevancia como se sustenta en (Vanegas-Cadavid, 2016). Como resultado, se establecen concretamente las funciones matemáticas para la extracción de características y las matrices o modelos entrenados que configuran los diferentes

algoritmos de reconocimiento automático a implementar en el computador de placa reducida.

Tanto las funciones para extraer las características de la señal de ECG a leer en el sistema propuesto, como la lectura de las matrices o modelos entrenados de los algoritmos son implementadas en el computador de placa reducida para así evaluar su desempeño en cuanto a capacidad de detección de fibrilación auricular y tiempo de respuestas asociado. En la figura 10 se presentan las diferentes etapas que componen el sistema de reconocimiento automático de fibrilación auricular propuesto, éstas se describen con mayor detalle en las siguientes subsecciones.

5.2.1. Preprocesamiento. Como primera etapa, realizando la lectura de la figura 10 de izquierda a derecha, la señal de electrocardiografía es adquirida por dos posibles canales, uno según la lectura de señales en archivos guardados en memoria y otro según la adquisición de la señal entregada por un generador de señales. La lectura de los ficheros guardados en memoria permite analizar las señales de validación para realizar la estimación estadística de la capacidad de detección del sistema propuesto (sensibilidad y especificidad), mientras que la adquisición de la señal entregada por el generador de señales permite la estimación de tiempo de respuesta

En cuanto al procesamiento o filtrado de la señal adquirida; el sistema elimina ruidos de deriva de línea base (a causa de señal de respiración, cambio de impedancia y movimiento de electrodos), atenuando señales con frecuencias inferiores a los 0.05Hz; se elimina el ruido de línea AC y se atenúan ruidos provenientes de posible actividad muscular que se encuentran por encima de los 40Hz. Lo anterior como se plantea en (Jeon y cols., 2014).

5.2.2. Extracción de características. Posterior al preprocesamiento realizado, se hizo una revisión de las diferentes estrategias usadas en investigaciones afines para encontrar las características que representan un mejor desempeño de los algoritmos de reconocimiento automático de fibrilación auricular según el propósito de la presente investigación. La siguiente subsección describe ésa investigación, para que en la subsección que sigue se describa concretamente la metodología utilizada de extracción de características del sistema propuesto.

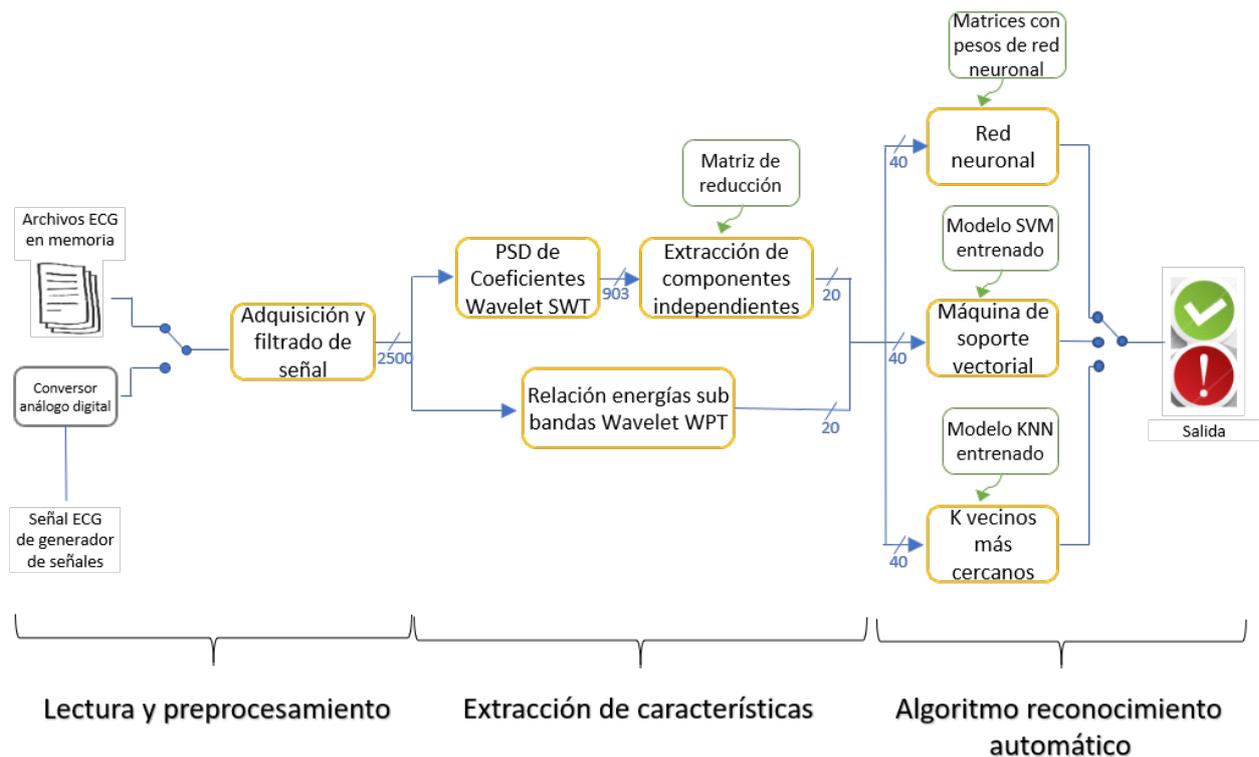


Figura 10. Estructura general de sistema de reconocimiento de fibrilación auricular. Las etapas color naranja corresponden a algoritmos implementados en el computador de placa reducida que requieren, en algunos casos, datos de entradas adicionales según trabajos previos de entrenamiento en un computador personal (recuadros en verde); los números sobre las flechas representan la cantidad de datos involucrados según ejecución de la etapa previa.

5.2.2.1. Determinación de características. Se encontró que en cuanto a los métodos lineales, las estrategias más utilizadas tratan de analizar los intervalos RR de la señal ECG (picos más altos en el trazado según la figura 1), información útil por ejemplo resulta ser el promedio de la duración de estos intervalos y su desviación estándar (Batista y Fred, 2015). Adicionalmente, dado que la fibrilación auricular se presenta con variaciones en la onda P, también existen algoritmos que incluyen la detección y análisis esta onda (Sovilj, Rajsman, y Magjarević, 2011). De hecho, es común encontrar dispositivos comerciales que realizan este tipo de extracción de características (Gladstone, Spring, y

cols., 2014) (Pérez-Rodon y cols., 2014)

Este análisis temporal de la señal de electrocardiografía presenta sin embargo un mayor reto para la adecuada detección de fibrilación auricular por la obligada detección eficaz de las ondas R y P, dado que por ejemplo las ondas P son muy propensas a contaminación con señales de movimientos y artefactos, y de hecho, su no detección degrada por completo la detección de la arritmia Lim y cols. (2016). Aquí hay un esfuerzo mayor por depurar el algoritmo de detección de picos que a su vez son propensos a ruido y errores de procesamiento Asgari y cols. (2015).

Si bien son más las investigaciones que usan el análisis temporal en aplicaciones para ventanas superiores a los 30 segundos que para la detección más temprana como en la presente propuesta, en el presente trabajo se estudió la posibilidad de incluir, como estrategia de extracción de características el cálculo de valores estadísticos asociados a la variabilidad de frecuencia cardíaca a partir del algoritmo de Pan Tompkins y la estimación de la entropía, como lo siguieron (Colloca, Johnson, Mainardi, y Clifford, 2013) y (Mamaghani, Sterling, Gruendike, Hamer, y Ghoraani, 2014). Como resultado, en pruebas previas en computador personal, se obtuvo una exactitud del 83,4 % en su uso con un clasificador de máquina de soporte vectorial, resultado atribuible a que pequeños errores en la detección de la onda R de la señal de ECG significaron una determinación errónea de la variabilidad de la frecuencia cardíaca, ocasionando un mayor número de falsos positivos o negativos. Adicionalmente, se encontró que el tiempo de cómputo en un computador personal es de 490 ms para el análisis de 10 segundos, tiempo muy elevado que puede perjudicar la detección en tiempo real en el sistema embebido a implementar. Por otro lado, la caracterización en frecuencia de la señal ECG también se documenta como una alternativa útil, aquí se incluye el análisis de Fourier y el cálculo de la densidad espectral de potencia. Si bien este método cuenta con una buena resolución frecuencial, la incertidumbre en la localización temporal de la energía resulta ser su principal desventaja (Martis y cols., 2014).

Por ello, para suplir la falta de ubicación temporal de las energías discriminadas frecuencialmente, se plantean las representaciones tiempo-frecuencia, permitiendo, según

una resolución deseada, mediar entre la incertidumbre de frecuencia y la de la ubicación exacta. Al respecto, la transformada wavelet discreta ha tomado mayor popularidad en cuanto a que permite la descomposición en niveles de escala diferentes (el inverso de la frecuencia) de la señal, a lo largo del tiempo (Batista y Fred, 2015).

Entre las ventajas del uso de wavelet, como representación tiempo frecuencia, en la detección automática de fibrilación auricular se encuentra el no requerimiento de detección y análisis de la onda P (Asgari y cols., 2015). De hecho, Asgari y cols. (2015) encontraron resultados incluso superiores a los encontrados en métodos sólo temporales.

Dadas las investigaciones mencionadas y las pruebas realizadas, en la presente investigación, con base en el trabajo de Asgari y cols. (2015), se estudió como estrategia de extracción de características, la implementación de los algoritmos de Transformada Wavelet Estacionaria hasta el nivel 7 y sobre cada una de las sub-bandas, el cálculo de la densidad espectral de potencia y la relación entre el máximo y mínimo en cada una de las densidades. En pruebas preliminares en computador personal, las relaciones entre máximos y mínimos de las densidades representaron una exactitud del 85 % en la detección de fibrilación auricular, mientras que utilizando toda la información de las densidades espectrales de potencia de las 7 sub-bandas se obtuvo una exactitud superior al 95 %.

5.2.2.2. Características extraídas. Como resultado de la escogencia de la metodología para extracción de características, y como representa en la figura 10, parte del algoritmo de extracción de características escogido se basa en este cálculo de la transformada wavelet estacionaria hasta el nivel 7 y de la densidad espectral de potencia para cada una de las bandas. Esta información, que incluye 903 datos por cada muestra debe ingresarse a un algoritmo de análisis de componentes principales que permita disminuir la cantidad de datos y por ende el fácil entrenamiento y uso de los algoritmos siguientes de reconocimiento automático de patrones. Como lo representa la misma figura, en trabajos preliminares en computador personal, se determina la matriz de reducción de características que es leída como un archivo .csv por el computador de placa reducida para así disminuir el número de variables a 20.

Complementando estas características extraídas se incluyeron 20 características adicio-

nales dado el cálculo de la transformada wavelet por paquetes WPT hasta el 5 nivel de descomposición, y sobre cada una de las bandas se calculó la energía relativa con respecto a la energía total de la señal analizada (Asgari y cols., 2015). Bandas con los detalles de mayor frecuencia dada la descomposición no se tuvieron en cuenta según se recomienda en (Martis y cols., 2013).

En resumen, en el computador de placa reducida se implementó las funciones que permiten el filtrado adecuado de la señal y la extracción de características. Características que incluyen el cálculo de la densidad espectral de potencia sobre las sub-bandas de la descomposición wavelet SWT, y la extracción de componentes independientes; más la estimación de las relaciones de energía de las sub-bandas de la descomposición wavelet WPT. En total por segmento analizado se obtienen 40 características con ayuda de las librerías *numpy* y *scipy* de Python encontrándose un tiempo de cómputo para su cálculo en computador de escritorio de 300ms. Estas características son ingresadas a los diferentes algoritmos de reconocimiento automático de patrones para así evaluarlos en cuanto a su desempeño en la detección de fibrilación auricular.

5.2.3. Algoritmos de reconocimiento automático de patrones. De la lectura de los 23 archivos de 10 horas cada uno de la base de datos MIT-BIH AFIB, y considerando las observaciones adicionales que acompañan la colección de los archivos en relación con la ausencia de algunos paquetes de datos, se extrajo un conjunto de 33625 muestras con 10 segundos cada una para el entrenamiento y validación del sistema (estimación de sensibilidad y especificidad) y 140 muestras de 40 segundos que incluyen cambios de señal sin fibrilación auricular a señal con fibrilación auricular para la estimación del tiempo de respuesta.

En cuanto a las 33625 muestras, este conjunto de datos se dividió aleatoriamente en dos subconjuntos; uno representando al 85 % de la base de datos para el entrenamiento de los algoritmos, y el otro al 15 % restante para la validación y caracterización de desempeño de los algoritmos. El conjunto de entrenamiento resultante está compuesto por 19317 muestras de señales sin fibrilación auricular y 9263 de con señales con fibrilación auricular; mientras que para el caso del conjunto de validación se cuenta con 3410 muestras de se-

ñales con fibrilación auricular y 1635 muestras catalogadas como sin fibrilación auricular. Ver figura 11.

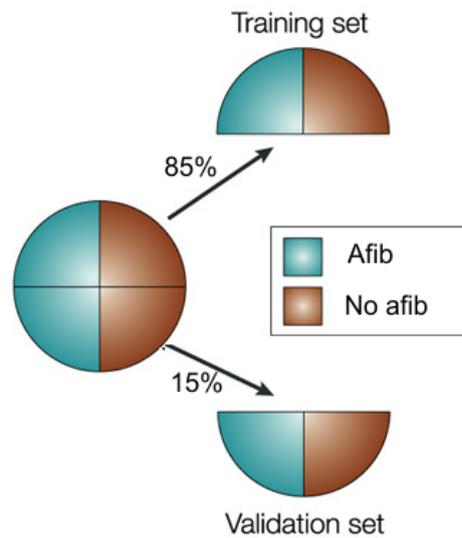


Figura 11. División de base de datos en conjuntos de entrenamiento y validación, editado de (Ransohoff, 2004)

5.2.3.1. Implementación red neuronal artificial. Para el caso de la red neuronal artificial a implementar en el computador de placa reducida, dadas las recomendaciones de Batista y Fred (2015) y Raj, Luthra, y Ray (2015) en el entrenamiento con coeficientes wavelet como características para el reconocimiento de fibrilación auricular, se escoge como topología una red neuronal feed-forward perceptron con tres capas con función de activación sigmoideal. Y sobre esta topología, según los mismos autores, se procede a variar el número de neuronas en la capa oculta para estimar la capacidad de respuesta del modelo. Para cada una de las configuraciones se realiza la validación cruzada del modelo según la lectura de las muestras en el conjunto de entrenamiento. Los resultados se presentan en el cuadro 3.

Como resultado, en la figura 12 se establece la topología y dimensión final de la red implementada. Se trata de una red con 10 neuronas en la capa oculta y una neuronal en la capa de salida.

Con la lectura iterativa de la base de datos, la red neuronal es entrenada con ayuda del paquete Neural Network Toolbox de Matlab según la minimización del error de cla-

Tabla 3

Validación cruzada modelos red neuronal

N° de neuronas en la capa oculta	Precisión
4	88 %
6	95 %
8	95 %
10	96 %
12	96 %
14	96 %
16	96 %
18	96 %
20	96 %

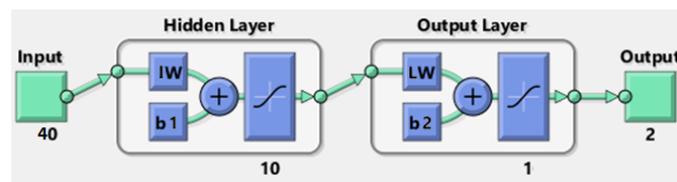


Figura 12. Red neuronal implementada

sificación. Como resultado, las matrices $IW_{10 \times 40}$, $LW_{1 \times 10}$, $b1_{1 \times 10}$ y $b2_{1 \times 1}$ y la topología representan la configuración completa de la red.

Las matrices IW , LW , $b1$ y $b2$ son guardadas en archivos .csv con una precisión de 9 cifras decimales para su almacenamiento en la memoria del computador de placa reducida y su lectura al momento de ejecutar la red neuronal. Los archivos generados ocupan 4kbytes en memoria.

5.2.3.2. Implementación máquina de soporte vectorial. Para la implementación de la máquina de soporte vectorial, según la revisión de Asgari y cols. (2015), quien utiliza como características la densidad espectral de potencia de los coeficientes wavelet, se parte de un kernel gaussiano con valores $\gamma = 0,01$ y $C = 100$. Y sobre estos valores iniciales, se procede a realizar pruebas con distintos valores de γ y C (como lo sugieren Batista y Fred (2015)). En el cuadro 4 se presenta la validación cruzada con el conjunto de

muestras de entrenamiento. Los modelos son entrenados en el lenguaje de programación de Python con ayuda de la librería Scikit-learn.

Tabla 4

Validación cruzada modelos máquina de soporte vectorial

Parámetros	Precisión
$\gamma = 10^{-2}$ y $C = 10^3$	96 %
$\gamma = 0,05$ y $C = 10^{-1}$	95 %
$\gamma = 10$ y $C = 1$	94 %
$\gamma = 10^{-1}$ y $C = 10^2$	96 %
$\gamma = 10^{-2}$ y $C = 100$	97 %

Como resultado, se escogieron los parámetros $\gamma = 10^{-2}$ y $C = 100$ en la configuración de la máquina de soporte vectorial con kernel gaussiano. Como se trata aquí de exportar el modelo al computador de placa reducida, conviene serializar el objeto y así poder leerlo con el mismo paquete de librerías con el que se entrenó. Al serializar el objeto, con la ayuda del paquete pickle, éste se convierte en una cadena de bytes de bajo tamaño y rápida lectura. El fichero resultante del modelo entrenado de la máquina de soporte vectorial corresponde a un archivo con extensión .pkl de 0.9 Mbytes, el fichero incluye los vectores soporte, los coeficientes de lagrange, el tipo de kernel utilizado y los parámetros correspondientes.

5.2.3.3. Implementación *k* vecinos más cercanos. Haciendo nuevamente uso de la librería *Scikit-learn* de *python*, el clasificador de *K* vecinos más cercanos propuesto utiliza la distancia Euclidiana como medida de similaridad, según se establece en (Batista y Fred, 2015). En este mismo artículo se propone variar el número de vecinos en el modelo y comparar su precisión mediante validación cruzada. En el cuadro 5 se presenta la validación cruzada con el conjunto de muestras de entrenamiento.

Como resultado, se escogió el valor $k = 4$ como parámetro y una vez entrenado el modelo se procede a serializar el objeto, obteniéndose un archivo con 24 Mb, valor superior al del tamaño de la máquina de soporte vectorial y la red neuronal en la medida que aquí el archivo relaciona todos los vecinos, es decir muestras en el espacio de características,

Tabla 5

Validación cruzada modelos K vecinos más cercanos

Número de vecinos	Precisión
$k = 2$	93 %
$k = 3$	94 %
$k = 4$	97 %
$k = 5$	96 %
$k = 6$	96 %
$k = 7$	95 %

teniéndose en este caso un vector por cada muestra del conjunto de entrenamiento de la base de datos.

5.2.3.4. Implementación modelo híbrido. En la medida que los algoritmos ANN, SVM y KNN presentaron en su entrenamiento valores favorables en la validación cruzada, y teniendo en cuenta que son estructuralmente diferentes entre ellos, según lo planteado en la respectiva subsección del marco referencial, la implementación de un algoritmo híbrido entre ellos puede representar mejores resultados en la detección de fibrilación auricular.

Entre las distintas topologías para la implementación del sistema híbrido, a partir de los trabajos realizados por (Homaeinezhad y cols., 2012), (Chen y cols., 2014), y (Deepthi y cols., 2016b), el modelo a utilizar es el de voto mayoritario. Y una vez implementada la ponderación relacionada, nuevamente se realizó la validación cruzada del sistema implementado, encontrándose una precisión del 97%.

En resumen para la implementación de los algoritmos ANN, SVM, KNN e Híbrido, el computador de placa reducida lee los archivos serializados en formato .pkl para configurar los objetos de clasificación de fibrilación auricular previa extracción de características. Y una vez implementado el sistema, es posible realizar la lectura de las señales del conjunto de datos de validación para así caracterizar el desempeño de cada algoritmo.

6. Resultados y discusión

El desempeño de los algoritmos es caracterizado en cuanto a su capacidad para detectar acertadamente las señales con y sin fibrilación auricular, y adicionalmente por el tiempo de respuesta requerido en la detección en tiempo real. En la figura 13 se presenta el montaje final para la evaluación de desempeño de los diferentes algoritmos de reconocimiento automático de patrones. El computador de placa reducida permite la lectura tanto de ficheros guardados en memoria para la determinación de sensibilidad y especificidad, como de la señal analógica proveniente del generador de señales para la estimación de tiempo de respuesta en la detección de fibrilación auricular.

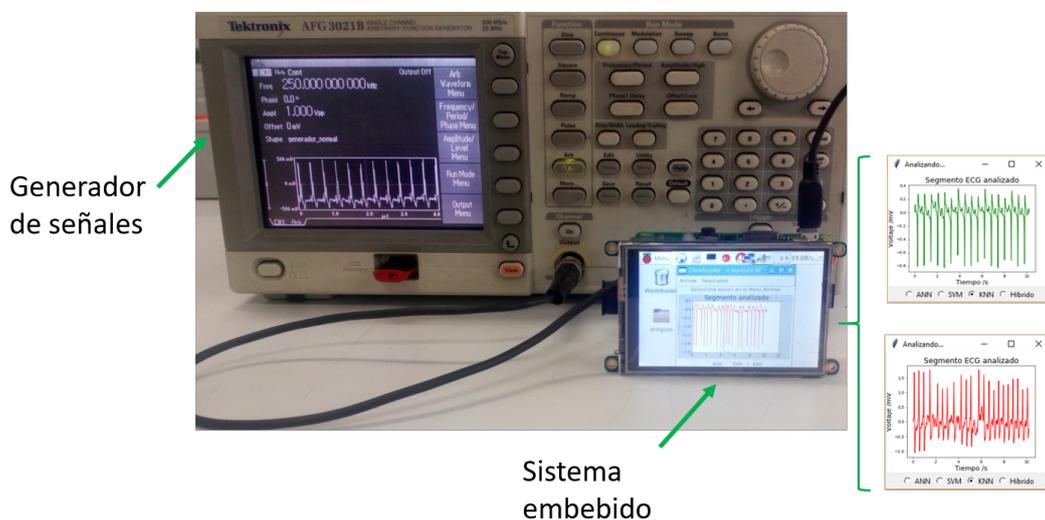


Figura 13. Montaje para la obtención de resultados. Las imágenes de la derecha ejemplifican la clasificación de señal de electrocardiografía sin fibrilación auricular (señal en verde) y con fibrilación auricular (señal en rojo), una vez escogido el algoritmo de clasificación.

En cuanto a la capacidad para detectar las señales con o sin fibrilación auricular, se utilizan las ecuaciones de sensibilidad, especificidad 2 y 3. Estimativos según la respuesta del sistema propuesto dado el análisis de cada una de las 5045 señales de validación, esta vez guardadas en memoria (el 67% de ellas corresponde a señales con fibrilación atrial y el porcentaje restante a señales sin ella). Una vez realizada la lectura de todas las señales de validación, se contabilizaron para cada uno de los algoritmos (ANN, KNN y SVM) el

número de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. En el cuadro 6 se presentan los valores de sensibilidad, especificidad y precisión para cada uno de los algoritmos planteados en el sistema propuesto; se incluye adicionalmente algunos resultados de otros autores que no necesariamente utilizaron la misma longitud de ventana o las características extraídas en esta investigación.

Tabla 6

Sensibilidad, especificidad y precisión de algoritmos implementados

Algoritmo	Sn	Sp	Precisión	Otros Autores
Red Neuronal	91.9 %	96.8 %	95.2 %	Sn=92 %, Sp=98 %, Kiki-llus y Bolz (2009)
Máquina de soporte vectorial	94.5 %	97.5 %	96.5 %	Sn=96.6 %, Sp=96.3 %, Asgari y cols. (2015)
K vecinos más cercanos	95.8 %	96.6 %	96.5 %	Sn=92 %, Sp=93 %, Leutheuser y cols. (2014)
Híbrido	95.8 %	97.6 %	96.8 %	Precisión=98 %, Homaeinezhad y cols. (2012)

En general el algoritmo que presentó mejor desempeño en la detección de fibrilación auricular fue el modelo Híbrido, seguido de K vecinos más cercanos, Máquina de soporte vectorial y por último la Red neuronal. Investigaciones previas con implementaciones en plataformas no embebidas y con variadas metodologías de extracción de características corroboran la mejoría en sensibilidad y especificidad del modelo híbrido de voto mayoritario en la detección de fibrilación auricular, entre ellas se encuentran (Homaeinezhad y cols., 2012) y (Deepthi y cols., 2016b).

El modelo red neuronal presentó resultados inferiores a los demás algoritmos implementados. En (Batista y Fred, 2015) se realizó una comparación similar con ventanas de muestreo mucho más grandes (60 s) con uso de coeficientes wavelet, encontrando también esta inferioridad. Por su parte, Lim y cols. (2016) presentan una revisión de los diferentes algoritmos utilizados para el reconocimiento automático de fibrilación auricular (se excluye el modelo Híbrido) con variados métodos de extracción de características

y longitud de ventana analizada, en general se presenta que el algoritmo K vecinos más cercanos puede presentar resultados superiores a los de máquina de soporte vectorial y red neuronal, situación que también se corrobora en la presente investigación en la aplicación embebida propuesta.

En general, los resultados encontrados son superiores a diversas investigaciones que utilizan también una ventana de trabajo corta como la utilizada en la presente investigación, entre ellas se encuentran las realizadas por Larburu, Lopetegui, y Romero (2011) y Colloca y cols. (2013). La investigación de Asgari y cols. (2015) que sirvió en gran parte como referencia para la implementación del algoritmo de extracción de características presentó resultados muy similares con su máquina de soporte vectorial implementada, ellos obtuvieron un 96.4% de precisión respecto al 96.5% obtenido en la presente investigación aunque ellos presentaron una ligera mejoría en la sensibilidad (96.6% versus la aquí encontrada de 94.5%). Sin embargo, en Asgari y cols. (2015) no se establece concretamente el uso de base de datos; la presente investigación utilizó la base de datos en su totalidad con la optimización del algoritmo de extracción de características y de los modelos implementados, como se planteó en el capítulo Metodología con apoyo de varias investigaciones adicionales.

En cuanto a la revisión del tiempo de cómputo requerido para la ejecución de los diferentes algoritmos, se encontró que todos los algoritmos tardaron en el computador de placa reducida 0,7 s antes de procesar los nuevos datos que esperan a su procesamiento en tiempo real; valor muy superior al encontrado con aplicaciones en plataformas no embebidas como la utilizada por Asgari y cols. (2015) quienes plantean tiempos tan cortos como de 35 ms dada la ejecución en computador de escritorio. El elevado tiempo de cómputo aquí encontrado resulta de los recursos en hardware reducidos de un computador de placa reducida con respecto a un computador de escritorio actual.

Como consecuencia de estos tiempos de cómputo obtenidos, si bien la metodología desarrollada permite suponer un buen desempeño computacional con ventanas tan cortas como un segundo, resulta imperativo recordar que como se planteó en el capítulo Metodología, en referencia al trabajo de Asgari y cols. (2015), usar ventanas más cortas

de 10 segundos repercute en una pérdida sustancial de sensibilidad y especificidad en la detección de fibrilación auricular. Por otra parte, plantear aplicaciones con ventanas más largas a los 10 segundos usados, implica necesariamente que diferentes fibrilaciones auriculares de corta duración (inferiores a los 30 segundos) no son detectadas (Pérez-Rodon y cols., 2014), falsos negativos que perjudican un diagnóstico completo del paciente por la estimación inexacta de la densidad y carga asociada a arritmias de corta duración (Vanegas-Cadavid, 2016) .

Del total del tiempo de cómputo, se encontró que el 95 % corresponde a la ejecución de las líneas de código destinadas a la extracción de características y el restante a la evaluación de los modelos sea ANN, SVM, KNN o Híbrido, información que se resume en el cuadro 7. En general, se encontró una ligera demora adicional en la ejecución del algoritmo K vecinos más cercanos (y por ende del modelo Híbrido) como resultado directo de la cantidad de memoria RAM involucrada, como se plantea en (Leutheuser y cols., 2014). En todo caso, dado que el tiempo de cómputo de los algoritmos de reconocimiento automático de patrones resulta irrelevante comparado con el destinado a la extracción de características, plantear aplicaciones futuras con ventanas de trabajo aún más cortas implicaría realizar una revisión de las funciones o métodos involucrados en la extracción de características.

Tabla 7

Tiempo de cómputo de algoritmos implementados

Algoritmo	Tiempo de Cómputo
Extracción de características	0.667 s
Red Neuronal	0.027 s
Máquina de soporte vectorial	0.037 s
K vecinos más cercanos	0.067 s

Por otra parte, para la evaluación del tiempo de respuesta de los algoritmos en computador de placa reducida se realiza la lectura de señal análoga por medio del modulo conversor análogo digital conectado vía serial al computador de placa reducida, la señal que ingresa al sistema es la suministrada por un generador de señales que tiene almacenados los segmentos de fibrilación auricular precedidos por señales sin esta arritmia. Como

se mencionó en el marco referencial, uno de los estimativos más claros del tiempo de respuesta es el tiempo que tarda el sistema en responder ante un cambio de señal normal a fibrilación auricular. De modo que ante cada cambio de señal se calcula su tiempo de respuesta, previa sincronización de las medidas realizadas.

La señal que ingresa al sistema es la suministrada por un generador de señales que tiene almacenados los segmentos de fibrilación auricular precedidos por señales sin esta arritmia. De modo que ante cada cambio de señal se calcula su tiempo de respuesta previa sincronización de las medidas realizadas, en el cuadro 8 se presentan los resultados obtenidos para los diferentes algoritmos. En general, los algoritmos detectan fibrilación auricular después de un tiempo cercano al 60% de la longitud de la ventana utilizada para el entrenamiento y ejecución de la aplicación (10 s); y los tiempos de respuesta encontrados con su varianza asociada son aceptables para futuras implementaciones de monitores de eventos cardíacos en la medida que estas consideraciones no están asociadas con el incremento de riesgo clínico según se demuestra en (Swiryn y cols., 2016).

Tabla 8

Tiempo de respuesta de algoritmos implementados

Algoritmo	Media	Varianza
Red Neuronal	7.12 s	12.08 s
Máquina de soporte vectorial	6.17 s	10.08 s
K vecinos más cercanos	6.05 s	8.36 s
Híbrido	5.71 s	7.18 s

Del análisis el cuadro 8 se aprecia una menor varianza en los algoritmos K vecinos más cercanos y modelo Híbrido como resultado de la mayor precisión de estos modelos relacionada en el cuadro 6, de hecho fue con estos algoritmos que en la obtención de tiempos de respuesta se encontró un menor número de falsos negativos o falsos positivos. En Asgari y cols. (2015) con la implementación de una máquina de soporte vectorial con ventana de trabajo de 10 segundos se encontró un tiempo de respuesta de 9,8 s, diferencia probablemente atribuible a la definición concreta de fibrilación paroxismal en cuanto a su tiempo mínimo de ocurrencia para el cual no existe un consenso bien definido (Pérez-Rodon

y cols., 2014); en la presente investigación se consideró a 3 s como el tiempo mínimo (Vanegas-Cadavid, 2016).

7. Conclusiones

Durante la etapa de preprocesamiento y clasificación se probó la extracción de múltiples características y se concluyó que el uso de coeficientes wavelet es la mejor herramienta para el reconocimiento automático de fibrilación auricular en ventanas de 10 segundos. Lo anterior en concordancia con propuestas de investigaciones relacionadas, como las de Asgari y cols. (2015) y Martis y cols. (2014).

Los algoritmos de reconocimiento automático de patrones ANN, SVM, KNN y modelo Híbrido presentan buenos resultados en cuanto a la capacidad de detección de fibrilación auricular, dadas las sensibilidades y especificidades cercanas al 95 % y 96 % encontradas en cada uno de ellos. Resultados equiparables a los de diversas investigaciones a fines en aplicaciones no embebidas con variadas metodologías para la extracción de características, como las relacionadas en (Lim y cols., 2016).

Si bien existen diferencias sustanciales en cuanto al tamaño en disco que ocupan los modelos ANN, SVM, KNN e Híbrido entrenados, los recursos en hardware del computador de placa reducida escogido permiten obtener tiempos de cómputo similares e inferiores a 0,7 s (con la extracción de características) para la ejecución de cada uno de ellos. Como consecuencia, posibles implementaciones con ventanas de trabajo diferentes a la utilizada en esta investigación no se encuentran limitadas por los recursos de actuales computadores de placa reducida; sin embargo, dadas las características de la arritmia, usar otra longitud de ventana implica la contraproducente desmejora en la capacidad de detección de diferentes tipos de fibrilación atrial (Asgari y cols., 2015) (Vanegas-Cadavid, 2016).

La metodología utilizada, en cuanto al uso de las herramientas en software y hardware presentadas, es adecuada para a la detección en tiempo real de fibrilación auricular dados los tiempos de cómputo y de respuesta encontrados. Esta metodología resulta apropiada para el desarrollo de Monitores Externos de Eventos Automáticos, innovaciones que repercutirían directamente en el diagnóstico oportuno y a bajo costo de la creciente y elevada población afectada por esta patología en el país. Son varias las investigaciones que reportan esta necesidad tecnológica en el país con base en la epidemiología actual y

estudios clínicos (Vanegas-Cadauid, 2016) (Mora-Pabón, 2016) (Carvajal y cols., 2014).

8. Referencias

- Anwar, A. (2014). Machine learning evaluation in paf prediction. *Journal of Global Research in Computer Science*, 3(2), 5–10.
- Asgari, S., Mehrnia, A., y Moussavi, M. (2015). Automatic detection of atrial fibrillation using stationary wavelet transform and support vector machine. *Computers in biology and medicine*, 60, 132–142.
- Basaif, A. A., Aljunid, S., Sabri, N., Omer, M. I., y Salim, M. (2016). Design and implementation of an embedded system to analysis an ecg signal for heart diagnosis system. *Journal of Theoretical and Applied Information Technology*, 91(2), 289.
- Batista, D., y Fred, A. (2015). Spectral and time domain parameters for the classification of atrial fibrillation. En *Proceedings of the international conference on bio-inspired systems and signal processing - volume 1: Biosignals, (biostec 2015)* (p. 329-337). doi: 10.5220/0005283403290337
- Braun, P. A., Moss, R. H., y Stigall, P. D. (1986). The single board computer: A practical alternative to a custom designed microsystem. *Computers & electrical engineering*, 12(3-4), 109–118.
- Carvajal, J. J., Clavijo, C., Bautista, L. J., y Mora, G. (2014). Características clínicas de pacientes llevados a monitoría externa de eventos. *Revista Colombiana de Cardiología*, 21(5), 278–283.
- Chen, H., Cheng, B.-C., Liao, G.-T., y Kuo, T.-C. (2014). Hybrid classification engine for cardiac arrhythmia cloud service in elderly healthcare management. *Journal of Visual Languages & Computing*, 25(6), 745–753.
- Colloca, R., Johnson, A. E., Mainardi, L., y Clifford, G. D. (2013). A support vector machine approach for reliable detection of atrial fibrillation events. En *Computing in cardiology conference (cinc), 2013* (pp. 1047–1050).
- Contributors, W. (2018). *K-nearest neighbors algorithm wikipedia the free encyclopedia*. Descargado de https://en.wikipedia.org/w/index.php?title=K-nearest_neighbors_algorithm&oldid=827389390 ([Online; accessed 16-March-2018])
- Das, S., y Chakraborty, M. (2011). Comparison of power spectral density (psd) of normal

- and abnormal ecgs. En *Ijca, special issue on 2nd national conference-computing, communication and sensor network,(2): pp-10-14*.
- Deepthi, S., Ravikumar, A., y Nair, R. V. (2016a). Evaluation of classification techniques for arrhythmia screening of astronauts. *Procedia Technology*, *24*, 1232–1239.
- Deepthi, S., Ravikumar, A., y Nair, R. V. (2016b). Evaluation of classification techniques for arrhythmia screening of astronauts. *Procedia Technology*, *24*, 1232–1239.
- Gladstone, D. J., Spring, R., y cols. (2014). Atrial fibrillation in patients with cryptogenic stroke. *New England Journal of Medicine*, *370*(26), 2467–2477.
- Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... Stanley, H. E. (2000). Physiobank, physiotoolkit, and physionet. *Circulation*, *101*(23), e215–e220.
- Guyton, A. C., Hall, J. E., Arthur, C. G., y John, E. (2002). *Manual de fisiología médica*. McGraw-Hill Interamericana,.
- He, Q., Segee, B., y Weaver, V. (2016). Raspberry pi 2 b+ gpu power, performance, and energy implications. En *Computational science and computational intelligence (csci), 2016 international conference on* (pp. 163–167).
- Homaeinezhad, M. R., Atyabi, S., Tavakkoli, E., Toosi, H. N., Ghaffari, A., y Ebrahimipour, R. (2012). Ecg arrhythmia recognition via a neuro-svm–knn hybrid classifier with virtual qrs image-based geometrical features. *Expert Systems with Applications*, *39*(2), 2047–2058.
- Jeon, T., Kim, B., Jeon, M., y Lee, B.-G. (2014). Implementation of a portable device for real-time ecg signal analysis. *Biomedical engineering online*, *13*(1), 160.
- Kikillus, M., Nicole, y Bolz, A. (2009). Identifying patients suffering from atrial fibrillation during atrial fibrillation and non-atrial fibrillation episodes. En *4th european conference of the international federation for medical and biological engineering* (pp. 1349–1352).
- Larburu, N., Lopetegi, T., y Romero, I. (2011). Comparative study of algorithms for atrial fibrillation detection. En *Computing in cardiology, 2011* (pp. 265–268).
- Leutheuser, H., Gradl, S., Kugler, P., Anneken, L., Arnold, M., Achenbach, S., y Esko-

- fier, B. M. (2014). Comparison of real-time classification systems for arrhythmia detection on android-based mobile devices. En *Engineering in medicine and biology society (embc), 2014 36th annual international conference of the ieee* (pp. 2690–2693).
- Lim, H. W., Hau, Y. W., Lim, C. W., y Othman, M. A. (2016). Artificial intelligence classification methods of atrial fibrillation with implementation technology. *Computer Assisted Surgery*, 21(sup1), 154–161.
- Mamaghani, B., Sterling, M., Gruendike, D., Hamer, M., y Ghoraani, B. (2014). Entropy & frequency analysis of new electrocardiogram lead placement for atrial fibrillation detection.
- Martis, R. J., Acharya, U. R., y Adeli, H. (2014). Current methods in electrocardiogram characterization. *Computers in biology and medicine*, 48, 133–149.
- Martis, R. J., Acharya, U. R., Prasad, H., Chua, C. K., y Lim, C. M. (2013). Automated detection of atrial fibrillation using bayesian paradigm. *Knowledge-Based Systems*, 54, 269–275.
- Misiti, M., Misiti, Y., Oppenheim, G., y Poggi, J. M. (1996). Wavelet toolbox computation visualization programming user’s guide version 1, 626 páginas, mathworks.
- Mittal, S., Movsowitz, C., y Steinberg, J. S. (2011). Ambulatory external electrocardiographic monitoring: focus on atrial fibrillation. *Journal of the American College of Cardiology*, 58(17), 1741–1749.
- Moody, R., G.B.; Mark. (2001). The impact of the mit-bih arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20. Descargado de <http://gen.lib.rus.ec/scimag/index.php?s=10.1109/51.932724> doi: 10.1109/51.932724
- Mora-Pabón, G. (2016). Utilidad del monitor externo de eventos en el tratamiento del paciente con fibrilación auricular. *Revista Colombiana de Cardiología*, 23, 40–43.
- Orozco-Duque, A., RÃ³a, S., Zuluaga, S., Redondo, A., Restrepo, J. V., y Bustamante, J. (2013). Support vector machine and artificial neural network implementation in embedded systems for real time arrhythmias detection. En *Proceedings of the international conference on bio-inspired systems and signal processing - volume 1:*

- Biosignals, (biostec 2013)* (p. 310-313). doi: 10.5220/0004232003100313
- Pava-Molano, L. F., y Perafán-Bautista, P. E. (2016). Generalidades de la fibrilación auricular. *Rev Colomb Cardiol*, 23(Supl 5), 5–8.
- Pérez-Rodon, J., Francisco-Pascual, J., Rivas-Gándara, N., Roca-Luque, I., Bellera, N., y Moya-Mitjans, À. (2014). Cryptogenic stroke and role of loop recorder. *Journal of Atrial Fibrillation*, 7(4).
- Raj, S., Luthra, S., y Ray, K. C. (2015). Development of handheld cardiac event monitoring system. *IFAC-PapersOnLine*, 48(4), 71–76.
- Raj, S., Maurya, K., y Ray, K. C. (2015). A knowledge-based real time embedded platform for arrhythmia beat classification. *Biomedical Engineering Letters*, 5(4), 271–280.
- Ransohoff, D. F. (2004). Rules of evidence for cancer molecular-marker discovery and validation. *Nature Reviews Cancer*, 4(4), 309.
- Rockx, M. A., Hoch, J. S., y Klein. (2005). Is ambulatory monitoring f. *American heart journal*, 150(5), 1065–e1.
- Rodriguez, C., Gallego, J., Mora, I. D., Orozco-Duque, A., y Bustamante, J. (2014). Clasificación de latidos de contracción ventricular prematura basados en métodos de aprendizaje no supervisado. *Revista Ingeniería Biomédica*, 8(15), 51.
- Rosselli, D., Rodríguez, A. J., García, Á. A., y Rueda, J. D. (2013). Prevalencia de fibrilación auricular en un hospital universitario colombiano. *Revista Colombiana de Cardiología*, 20(6), 383–385.
- Sornmo, L. P., L. (2011). *Bioelectrical signal processing in caridac and neurological applications* (Vol. 1) (n.º sup1). Elsevier Academic Press.
- Sovilj, S., Rajsman, G., y Magjarević, R. (2011). Ecg based prediction of atrial fibrillation using support vector classifier. *AUTOMATIKA: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije*, 52(1), 58–67.
- Swiryn, S., Orlov, M. V., Benditt, D. G., DiMarco, J. P., Lloyd-Jones, D. M., Karst, E., ... Waldo, A. L. (2016). Clinical implications of brief device-detected atrial tachyarrhythmias in a cardiac rhythm management device populationclinical perspec-

- tive: Results from the registry of atrial tachycardia and atrial fibrillation episodes. *Circulation*, *134*(16), 1130–1140.
- Upton, E., y Halfacree, G. (2014). *Raspberry pi user guide*. John Wiley & Sons.
- Vanegas-Cadavid, D. I. (2016). Uso del monitor cardiaco implantable en fibrilación auricular. *Revista Colombiana de Cardiología*, *23*, 34–39.
- Villa-Rodríguez, L., Lemos-Duque, J. D., y cols. (2014). Desarrollo de un holter digital con grabación de eventos y software de visualización. *Revista ingeniería biomedica*.
- Vogler, J., Breithardt, G., y Eckardt, L. (2012). Bradiarritmias y bloqueos de la conducción. *Revista Española de Cardiología*, *65*(7), 656–667.
- Zimetbaum, P., y Goldman, A. (2010). Ambulatory arrhythmia monitoring. *Circulation*, *122*(16), 1629–1636.