



Revista EIA
ISSN 1794-1237
e-ISSN 2463-0950
Año XVIII/ Volumen 19/ Edición N.38
Junio-Diciembre de 2022
Reia3823 pp. 1-14

Publicación científica semestral
Universidad EIA, Envigado, Colombia

**PARA CITAR ESTE ARTÍCULO /
TO REFERENCE THIS ARTICLE /**

Maya Gonzalez, J. C. (2022). Detección en tiempo real de fibrilación auricular en computador de placa reducida. Revista EIA, 19(38), Reia3823. pp. 1-14. <https://doi.org/10.24050/reia.v19i38.1565>

✉ *Autor de correspondencia:*

MSc, Ingeniería Electrónica con Enfoque en Ingeniería Biomédica
Esp. Bioingeniería
Ing. Electronico.
Correo electrónico:
juan.maya@mail.escuelaing.edu.co

Recibido: 08-01-2022
Aceptado: 18-04-2022
Disponible online: 01-06-2022

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

✉ JUAN CARLOS MAYA GONZALEZ¹

1. Escuela Colombiana de Ingeniería Julio Garavito

Resumen

El desarrollo de dispositivos portables, que permita la detección en tiempo real de fibrilación auricular, requiere la implementación de algoritmos de reconocimiento automático de patrones con la metodología adecuada para su ejecución en sistemas embebidos. En el presente artículo se expone la implementación de una red neuronal artificial (ANN), una máquina de soporte vectorial (SVM) y un algoritmo de K vecinos más cercanos (KNN) en un computador de placa reducida para así comparar su desempeño en cuanto a la capacidad de detección de esta arritmia y el tiempo de respuesta asociado en 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 parámetros asociados a la transformada wavelet estacionaria. Se encontraron resultados entre el 92% y 97% para la sensibilidad y especificidad de los algoritmos mencionados y tiempos de respuesta variados entre 6 s y 7,1 s.

Palabras clave: Computador de placa reducida, fibrilación auricular, K vecinos más cercanos (KNN), red neuronal artificial (ANN), máquina de soporte vectorial (SVM), Transformada Wavelet Estacionaria.

Real-time detection of atrial fibrillation on single board computer

Abstract

Development of portable devices, that allows real-time detection of atrial fibrillation, requires the implementation of automatic pattern recognition algorithms and an appropriate methodology for their execution in embedded systems. In the present article, the performances of an artificial neural network, a machine vector support, a k-nearest neighbors algorithm and a hybrid classifier implemented on a single-board computer, were compared in terms of detection capacity of arrhythmia and time response associated with real-time execution. The MIT-BIH AFIB database was used to train and validate the algorithms. In advance, the extraction of parameters associated with the stationary wavelet transform was developed. Results between 92 % and 97 % for sensitivity and specificity, and time responses between 6 s and 7.1 s were found in this research.

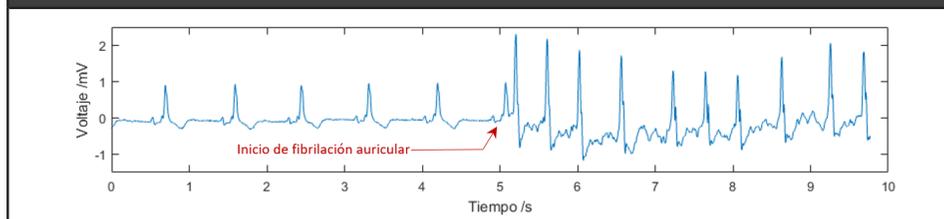
Key Words: Atrial fibrillation, artificial neural network (ANN), hybrid classifier, k-nearest neighbors algorithm (KNN), single-board computer, support vector machine (SVM), static wavelet transform.

1. Introducción

La fibrilación auricular es una arritmia cardíaca que resulta ser la más frecuente en el ser humano. El 1% de la población general y hasta 10% de mayores de 80 años la padece [1]. De hecho, con el aumento de la expectativa de vida, esta arritmia se está convirtiendo en una de las enfermedades de mayor prevalencia [2] [3] y con muy elevados gastos para los sistemas de salud (en países desarrollados se le atribuye un gasto del 2.5% de los gastos generales) [1].

En la fibrilación auricular, las aurículas son excitadas aleatoriamente y eventualmente se anula el impulso generado por el nodo sinoatrial (en la fig. 1 se presenta su trazado electrocardiográfico). Como consecuencia, el corazón presenta un progresivo déficit de bombeo de sangre, incrementando el riesgo de un infarto hasta cuatro veces [4], de hecho “se calcula que el 15% de los eventos cerebro-vasculares se atribuyen a esta arritmia, los cuales son más graves o discapacitantes que los no relacionados con ella” [5] lo que aumenta la probabilidad de muerte o invalidez de la población afectada [6]. 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) [6].

Fig. 1. Comparativo electrocardiográfico entre un ritmo sinusal y uno con fibrilación auricular, según la lectura del archivo 4048 de la base de datos MIT-BIH AFIB encontrada en [7].



De ahí que sus altos niveles de incidencia a nivel mundial generen un interés particular en el desarrollo de tecnologías para su diagnóstico [1]. Sin embargo, su difícil detección en algunos casos, y la ocurrencia asintomática en otros, son algunas de las problemáticas que enfrenta el desarrollo de tecnologías para su diagnóstico oportuno.

Actualmente, en cuanto a las herramientas tecnológicas para el diagnóstico de esta arritmia 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 [1]. Por otra 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 que 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 ofrece una mayor sensibilidad de diagnóstico, del 15 al 28% frente a la casi nula con el uso de electrocardiograma convencional [2]. Sin embargo, hay un gran número de pacientes con periodicidad de ocurrencia de la afección mayor a 24 o 72 horas [5].

Como alternativa a la monitorización Holter, los monitores externos de eventos pueden usarse por un tiempo mucho más prolongado de hasta cuatro semanas [2]. Adicionalmente, con la inclusión de un marcador de eventos que reconoce y graba automáticamente las arritmias presentadas, hay mayor probabilidad de que el especialista pueda detectarlas y analizarlas, pues hay periodos cortos de tiempo que analizar prioritariamente [9]. Comparando el equipo Holter con el monitor externo de eventos, [2] establece 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.

Pese a la mayor capacidad de diagnóstico de los monitores externos de eventos, su uso no resulta tan común como las demás tecnologías [5], en gran parte por los altos costos de estos equipos [10] [11] que requieren gran capacidad para la detección automática de la arritmia con tiempos de respuesta cortos [6] y disponibilidad de gran cantidad de memoria para el almacenamiento de datos [4]. Al respecto del tiempo de respuesta, sobre todo en pacientes con posible toxicidad de fármacos antiarrítmicos se requiere el acceso inmediato a los datos [10]. Adicionalmente, en [8] y [12] se recalca que entre algunos parámetros importantes a obtener de la monitorización, está la duración precisa de la fibrilación y la densidad de las arritmias en un periodo de tiempo.

En [13] se resalta que diferentes herramientas computacionales o algoritmos 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 sistemas embebidos. 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. 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.

Un computador de placa reducida, por su bajo tamaño y gran capacidad de procesamiento, 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 los diferentes algoritmos mencionados 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 [14].

Entre los algoritmos más utilizados en el reconocimiento automático de fibrilación auricular se encuentran: k vecinos más cercanos (KNN), redes neuronales artificiales (ANN), y máquinas de soporte vectorial (SVM) [6]. En la presente investigación se implementan estos algoritmos en un computador de placa reducida para realizar su evaluación en cuanto a capacidad de detección de fibrilación auricular y tiempo de respuesta.

Las secciones que a continuación se presentan se encuentran organizadas de la siguiente manera: en la sección 2 se realiza una descripción de la base de datos de electrocardiografía usada para la implementación y validación del sistema propuesto, se presenta adicionalmente el hardware utilizado como sistema embebido; en la sección 3 se presenta la descripción de las diferentes herramientas matemáticas para el reconocimiento automático de fibrilación auricular y su implementación en el computador de placa reducida; en la sección 4 se presenta la evaluación realizada a los diferentes algoritmos de reconocimiento automático en cuanto a capacidad de detección de fibrilación auricular y tiempo de respuesta; para por último, en la sección 5 presentar las conclusiones más relevantes del estudio realizado.

2. Materiales

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 [7]). 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 250 Hz, a una resolución de 12 bits y un rango de +/-10 mV. 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 [3]. Estos episodios se encuentran marcados, con anotaciones en tiempos específicos según revisiones previas de especialistas creadores de la base de datos; en la fig. 1 se representa un ejemplo 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.

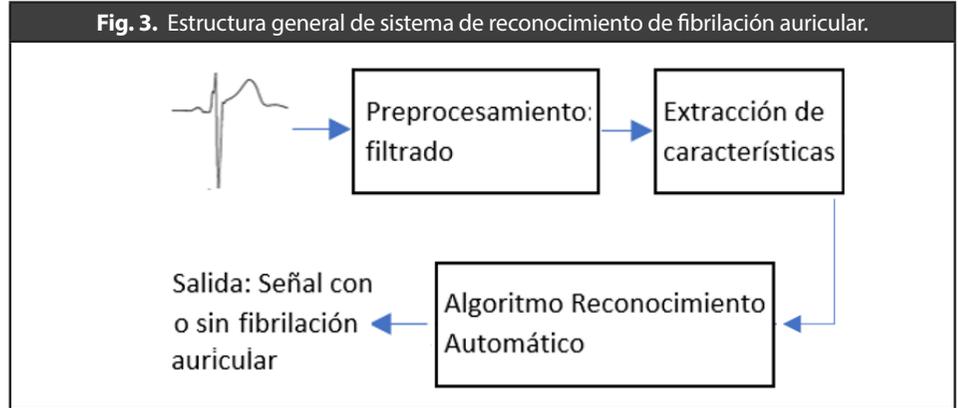
El sistema a utilizar consta de un computador de placa reducida Raspberry Pi 2 (que cuenta con un procesador quad-core ARM Cortex-A7, 1 GB de memoria RAM y puertos digitales para comunicación con diferentes periféricos [15]). En él se realiza el preprocesamiento, la extracción de características y el reconocimiento automático de fibrilación auricular de señales tanto guardadas en memoria como provenientes del módulo análogo digital externo ADS1115 (convertor con resolución de 16 bits y frecuencia de muestreo de 860 Hz) 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 presentada en una pantalla TouchScreen referencia ADAFR-2097 para visualizar tanto la señal analizada como el resultado de su análisis. En la figura fig. 2 se representa el hardware implementado.



3. Metodos

Una vez la señal de electrocardiografía es adquirida, se puede procesar computacionalmente para detectar automáticamente si presenta o no algún tipo de arritmia, en nuestro caso de estudio, fibrilación auricular (según recomendación de [3] y propuesta de [13], la señal es procesada en ventanas de 10 segundos). 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 fig. 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.

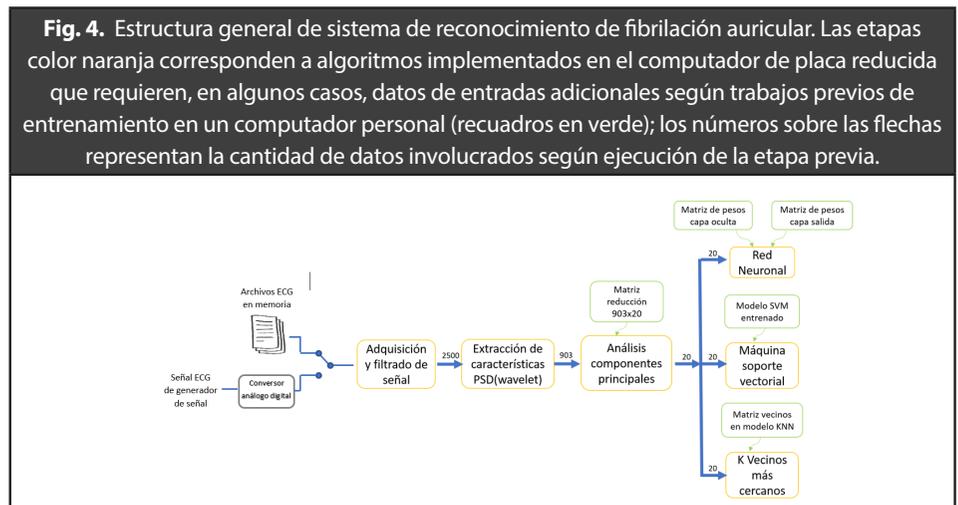
A partir de los requerimientos de diseño en cuanto a detección de velocidad de rotación de la cabeza, ángulo total de recorrido, detección de movimiento de la cabeza por flexión e inclinación; el prototipo planteado despliega el test de agudeza visual dinámica garantizando el test en un solo plano o eje de rotación con la velocidad y ángulo establecido previamente en la aplicación.



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. 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 fig. 4 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.



3.1. Preprocesamiento

Como primera etapa, realizando la lectura de la fig. 4 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 28580 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 preprocesamiento, con el fin de eliminar ruidos en la señal electrocardiográfica, entre los que se encuentran: ruidos de contacto de electrodos, artefactos musculares, interferencia de línea, variaciones en línea de base, ruidos asociados al dispositivo de captura, entre otros [16], el sistema filtra señales que presentan frecuencias inferiores a los 0,05 Hz y superiores a los 40 Hz. Lo anterior como se plantea en [13], teniendo en cuenta que de hecho la actividad atrial usualmente ocurre entre las frecuencias de 4 a 9 Hz [3].

3.2. Extracción de características

En cuanto a los métodos lineales de extracción de características, las estrategias más utilizadas tratan de analizar los intervalos RR de la señal ECG (picos más altos en el trazado según la fig. 1) [17], información útil por ejemplo resulta ser el promedio de la duración de estos intervalos y su desviación estándar [17]. 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 [18]. De hecho, es común encontrar dispositivos comerciales que realizan este tipo de extracción de característica [4] [19].

El 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 [6]. 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 [3].

Por otro lado, la caracterización en frecuencia de la señal ECG también es 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 [16].

Por último, 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 [17]. Esta transformada 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(s)). 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 [20].

$$[W_{\psi} f](s,\tau)=A\sum\sum\Psi_{s,\tau}(s,\tau)f(t) \quad (1)$$

3.3. Implementación extracción de características

Con base en las investigaciones de [3], 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. Esta información, que incluye 903 datos por cada señal analizada (como lo representa la fig. 4) 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 determinó 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.

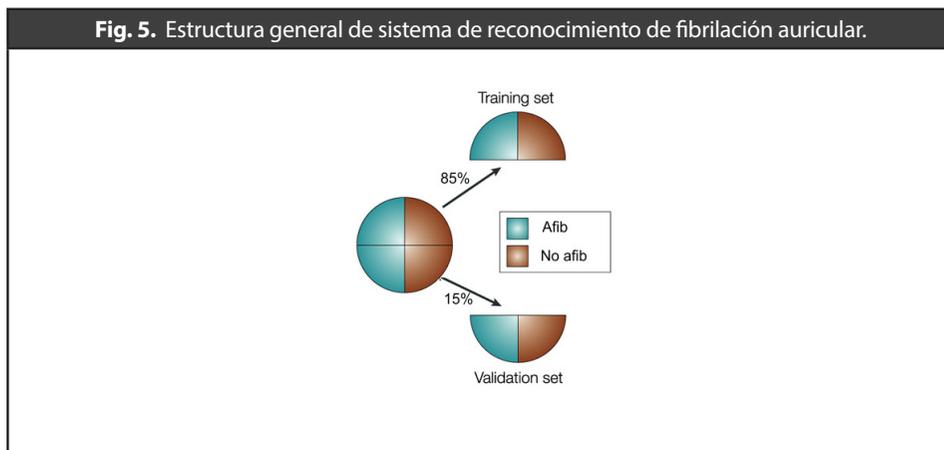
Hasta aquí, en el computador de placa reducida se implementan las funciones que permiten el filtrado adecuado de la señal y la extracción de características (densidad espectral de potencia de las 7 sub bandas según descomposición wavelet); para por último, mediante el uso de la matriz de reducción de características previamente guardada en la memoria, disminuir el número de características que ingresan a los diferentes algoritmos de reconocimiento automático de patrones que van a ser evaluados según su previo entrenamiento. Las funciones de filtrado, extracción de características y reducción de dimensión se logran haciendo uso de las librerías *numpy* y *scipy* de Python.

3.4. 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. 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 extrajeron 33625 señales, cada una relacionado con la lectura de 10 segundos de información (2500 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 señales sin fibrilación auricular y 9263 señales con fibrilación auricular; mientras que para el caso del conjunto de validación se cuenta con 3410 señales con fibrilación auricular y 1635 muestras catalogadas como sin fibrilación auricular. En la fig. 5 se ilustra la partición de la base de datos.

Fig. 5. Estructura general de sistema de reconocimiento de fibrilación auricular.


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 incluye P muestras con fibrilación auricular (muestras positivas) y N muestras sin ella (muestras negativas).

Entre los parámetros más usados para caracterizar el desempeño se encuentran la sensibilidad, y especificidad. 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.

$$TPR = TP / (TP + FN) \quad (2)$$

$$TNR = TN / (FP + TN) \quad (3)$$

En cuanto a la velocidad o tiempo de respuesta del sistema en la detección de fibrilación auricular, es usual medir el tiempo de predicción del algoritmo [20], estimado como el tiempo de transición (tiempo de espera para detección de cambios de señal con o sin fibrilación atrial)[3].

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 tiempo de respuesta hace referencia al tiempo que tarda un algoritmo determinado en detectar una transición a fibrilación auricular.

3.4.1. |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 a fibrilación auricular).

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 es 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 la red neuronal artificial a implementar en el computador de placa reducida, dadas las recomendaciones de [17] y [22] en el entrenamiento con coeficientes wavelet como características para el reconocimiento de fibrilación auricular, se escoge como topología una red neuronal feed-forward perceptrón con tres capas con función de activación sigmoideal; su función de transferencia se presenta en la ecuación 4 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.

Sobre esta topología según los mismos autores, se procede a variar el número de neuronas en la capa oculta para estimar la configuración que maximice 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. Como resultado de la mejor configuración, se implementó finalmente una red con 10 neuronas en la capa oculta y una neuronal en la capa de salida.

$$f(x)=\text{sigmod}(LW*\text{sigmod}((IW*x)+b1)+b2) \quad (4)$$

Las matrices que contienen los pesos de las diferentes neuronas LW , IW , $b1$ 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 4 kbytes en memoria.

3.4.2. Máquinas de soporte vectorial

Partiendo de un conjunto de muestras (en el espacio de características) con o sin fibrilación auricular, éste 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 establecer si corresponde al subespacio con fibrilación auricular o sin ella. Adicionalmente, SVM procura establecer el mayor nivel de margen entre las dos categorías a clasificar, la inclusión adicional de kérneles permite implementar hiperplanos de separación de mayor complejidad.

En la ecuación 5 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.

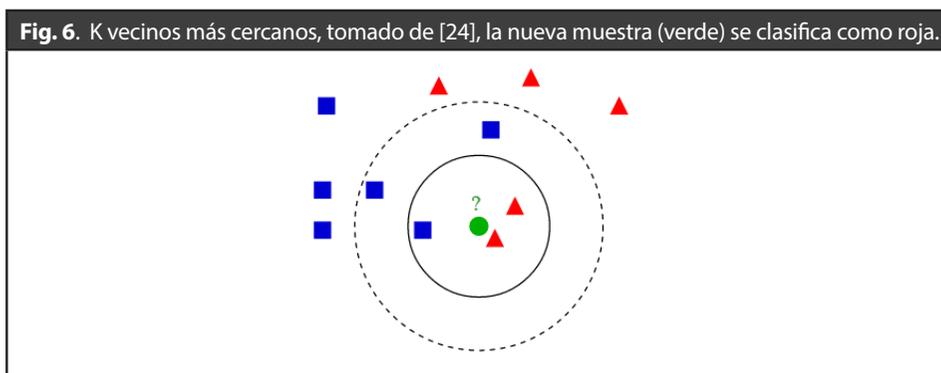
$$f(x)=\sum_{i=1}^n \alpha_i (k(x,x_i)+b) \quad (5)$$

Para la implementación de la máquina de soporte vectorial, según la revisión de [3], 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 [17]). Los modelos son entrenados en el lenguaje de programación de *Python* con ayuda de la librería *Scikit-learn*. Como resultado, se escogieron los parámetros $\gamma = 10$ y $C = 1$ en la configuración de la máquina de soporte vectorial con kernel gaussiano, dado que presentó mejores resultados. 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, el tipo de kernel utilizado y los parámetros correspondientes.

3.4.3. K vecinos más cercanos

Este clasificador, a diferencia de los anteriores, no requiere etapa de entrenamiento [23], 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 fig. 6, 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.

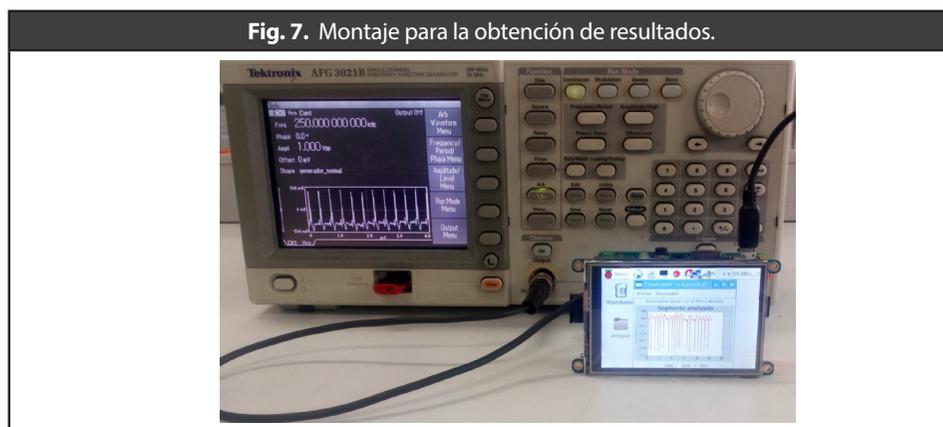


Por último, haciendo nuevamente uso de la librería *Scikit-learn* de *python*, el clasificador de K vecinos más cercanos propuesto utiliza la distancia Euclidiana como medida de similitud [17]. Como se plantea en [17] se procede a variar el número de vecinos en el modelo y comparar su precisión mediante validación cruzada. Como resultado, se escogió el valor $k = 10$ como parámetro, y una vez entrenado el modelo se procede a serializar el objeto, generando un archivo de 9,6 Mb, valor superior al del tamaño de la máquina de soporte vectorial y la red neuronal en la medida dado que aquí el archivo relaciona todos los vecinos, es decir muestras en el espacio de características, teniéndose en este caso un vector por cada muestra del conjunto de entrenamiento de la base de datos.

El computador de placa reducida lee los archivos .csv con las matrices y los objetos serializados en formato .pkl para configurar los modelos de clasificación de fibrilación auricular previa extracción de características, como se ilustra en la fig. 4. 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.

4. Resultados y discusión

En la fig. 7 se presenta el montaje final para la evaluación de desempeño de los diferentes algoritmos de reconocimiento automático de fibrilación auricular. 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 análoga proveniente del generador de señales para la estimación de tiempo de respuesta en la detección de fibrilación auricular.



En cuanto a la capacidad para detectar las señales con o sin fibrilación auricular, se utilizan las ecuaciones de sensibilidad y 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. 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 la tabla 1 se presentan los valores de sensibilidad y especificidad para cada uno de los algoritmos planteados.

Tabla. 1. Resultados Sensibilidad y Especificidad algoritmos implementados.

Algoritmo	Sn	Sp
Red Neuronal	91,9%	96,8%
<i>Máquina de soporte vectorial</i>	94,5%	97,5%
<i>K vecinos más cercanos</i>	95,8%	96,6%

En general el algoritmo que presentó mejor desempeño en la detección de fibrilación auricular fue el de k vecinos más cercanos, seguido por el de máquina de soporte vectorial y por último la red neuronal. Lo anterior en cuanto a la detección tanto de señal con fibrilación auricular como de señales sin fibrilación auricular.

Los resultados encontrados son superiores a diversas investigaciones que utilizan también una ventana de trabajo corta como la utilizada en la presente investigación [25] [26]. Aunque existen investigaciones que documentan resultados aún superiores a los presentados en el presente trabajo [3], en ellas no se documentan específicamente el tratamiento, selección u omisión de señales que se realiza con la base de datos.

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. Y de este tiempo de cómputo se encontró que el 95% corresponde a las líneas de código destinadas a la extracción de características y el restante a la evaluación de los modelos sea ANN, SVM o KNN. Por lo que, pese a que algunos modelos pueden resultar más complejos en su uso computacional (por ejemplo KNN), su uso no representa una contribución representativa en el tiempo de cómputo final.

Tabla. 2. Tiempos de cómputo de algoritmos implementados.

Algoritmo	Tiempo de cómputo
Extracción de características	0,667 s
Red Neuronal	0,027 s
<i>Máquina de soporte vectorial</i>	0,037 s
<i>K vecinos más cercanos</i>	0.067 s

Por otra parte, para la evaluación del tiempo de respuesta de los algoritmos en computador de placa reducida para la detección en tiempo real de fibrilación auricular, se realiza la lectura de señal análoga por medio del módulo 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. De modo que ante cada cambio de señal se calcula su tiempo de respuesta, previa sincronización de las medidas realizadas. En la tabla 3 se presentan los resultados obtenidos para los diferentes algoritmos. En general los algoritmos detectan fibrilación auricular después de un tiempo cercano a la longitud de la ventana escogida para el entrenamiento y ejecución de la aplicación (10 s), y la varianza presenta valores elevados en la medida que los algoritmos no solo fueron entrenados con los cambios de señal sin fibrilación auricular a señales con ella, si no que por la naturaleza de la base de datos utilizada se presentó un mayor entrenamiento con intervalos no relacionados con dicha transición (hay muchas más muestras con fibrilación sostenida que paroxismal).

Tabla. 3. Resultados Sensibilidad y Especificidad 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

5. CONCLUSIONES

La extracción de características en el dominio tiempo frecuencia utilizada presenta buenos resultados para el desempeño de algoritmos de reconocimiento automático de fibrilación auricular. Los valores de sensibilidad, especificidad obtenidos para los algoritmos ANN, SMV y KNN son equiparables a los de diversas investigaciones a fines en aplicaciones no embebidas con variadas metodologías para la extracción de características, como se relacionan en [6].

La metodología utilizada en cuanto al uso de coeficientes wavelet sobre ventanas de 10 segundos, el entrenamiento y la importación de modelos entrenados de KNN, SVM y ANN es adecuada en cuanto a la detección en tiempo real de fibrilación auricular con el sistema embebido propuesto dados los tiempos de cómputo y de respuesta encontrados.

En cuanto al tiempo de cómputo, si bien existen diferencias sustanciales en cuanto al tamaño de información que representan a los modelos ANN, SVM, y KNN entrenados, se requiere mucho más tiempo para la extracción de características que para la ejecución de estos modelos. Por ello, trabajar con ventanas aún más cortas que la utilizada en la presente investigación requeriría una revisión previa de la metodología utilizada para garantizar su operación en tiempo real.

6. Referencias

- A. A. Basaif, S. Aljunid, N. Sabri, M. I. Omer, and M. Salim, "Design and implementation of an embedded system to analysis an ecg signal for heart diagnosis system," *Journal of Theoretical and Applied Information Technology*, vol. 91, no. 2, p. 289, 2016.
- A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, "Physiobank, physiotookit, and physionet," *Circulation*, vol. 101, no. 23, pp. e215–e220, 2000. DOI: 10.1161/01.CIR.101.23.e215
- C. Rodriguez, J. Gallego, I. D. Mora, A. Orozco-Duque, and J. Bustamante, "Clasificación de latidos de contracción ventricular prematura basados en métodos de aprendizaje no supervisado" *Revista Ingeniería Biomédica*, vol. 8, no. 15, p. 51, 2014. DOI: 0.24050/19099762.n15.2014.608
- D. Batista and A. Fred, "Spectral and time domain parameters for the classification of atrial fibrillation," in *Proceedings of the International Conference on Bio-inspired Systems and Signal Processing - Volume 1: BIOSIGNALS, (BIOSTEC 2015)*, 2015, pp. 329–337.
- D. F. Ransohoff, "Rules of evidence for cancer molecular-marker discovery and validation," *Nature Reviews Cancer*, vol. 4, no. 4, p. 309, 2004. DOI: 10.1038/nrc1322
- D. J. Gladstone, R. Spring et al., "Atrial fibrillation in patients with cryptogenic stroke," *New England Journal of Medicine*, vol. 370, no. 26, pp. 2467–2477, 2014. DOI: 10.1056/NEJMoa1311376
- D. I. Vanegas-Cadavid, "Uso del monitor cardiaco implantable en fibrilación auricular," *Revista Colombiana de Cardiología*, vol. 23, pp. 34–39, 2016. DOI: 10.1016/j.rccar.2016.10.031
- G. Mora-Pabón, "Utilidad del monitor externo de eventos en el tratamiento del paciente con fibrilación auricular," *Revista Colombiana de Cardiología*, vol. 23, pp. 40–43, 2016. DOI:10.1016/j.rccar.2016.11.005
- H. W. Lim, Y. W. Hau, C. W. Lim, and M. A. Othman, "Artificial intelligence classification methods of atrial fibrillation with implementation technology," *Computer Assisted Surgery*, vol. 21, no. sup1, pp. 154–161, 2016. DOI: 10.1080/24699322.2016.1240303
- J. J. Carvajal, C. Clavijo, L. J. Bautista, and G. Mora, "Características clínicas de pacientes llevados a monitoría externa de eventos," *Revista Colombiana de Cardiología*, vol. 21, no. 5, pp. 278–283, 2014. DOI: 10.1016/j.rccar.2013.11.001
- J. Pérez-Rodon, J. Francisco-Pascual, N. Rivas-G'andara, I. Roca-Luque, N. Bellera, and A` . Moya-Mitjans, "Cryptogenic stroke and role of loop recorder," *Journal of Atrial Fibrillation*, vol. 7, no. 4, 2014. DOI: 10.4022/jafib.1178.
- J. Vogler, G. Breithardt, and L. Eckardt, "Bradiarritmias y bloqueos de la conducción," *Revista Española de Cardiología*, vol. 65, no. 7, pp. 656–667, 2012. DOI: 10.1016/j.recesp.2012.01.025
- L. Villa-Rodríguez, J. D. Lemos-Duque et al., "Desarrollo de un holter digital con grabación de eventos y software de visualización," *Revista ingeniería biomédica*, 2014. DOI: 10.24050/19099762.n7.2010.84
- M. A. Rockx, J. S. Hoch, and Klein, "Is ambulatory monitoring for "community-acquired" syncope economically attractive? A cost-effectiveness analysis of a randomized trial of external loop recorders versus Holter monitoring," *American heart journal*, vol. 150, no. 5, pp. 1065–e1, 2005. DOI: 10.1016/j.ahj.2005.08.003

- M. R. Homaeinezhad, S. Atyabi, E. Tavakkoli, H. N. Toosi, A. Ghaffari, and R. Ebrahimipour, "Ecg arrhythmia recognition via a neuro-svm-knn hybrid classifier with virtual qrs image-based geometrical features," *Expert Systems with Applications*, vol. 39, no. 2, pp. 2047–2058, 2012. DOI:10.1016/j.eswa.2011.08.025
- N. Larburu, T. Lopetegi, and I. Romero, "Comparative study of algorithms for atrial fibrillation detection," in *Computing in Cardiology*, 2011. IEEE, 2011, pp. 265–268.
- P. Zimetbaum and A. Goldman, "Ambulatory arrhythmia monitoring," *Circulation*, vol. 122, no. 16, pp. 1629 – 1636, 2010. DOI: 10.1161/CIRCULATIONAHA.109.925610
- Q. He, B. Segee, and V. Weaver, "Raspberry pi 2 b gpu power, performance, and energy implications," in *Computational Science and Computational Intelligence (CSCI)*, 2016 International Conference on. IEEE, 2016, pp. 163–167. DOI: 10.1109/CSCI.2016.0038
- R. Colloca, A. E. Johnson, L. Mainardi, and G. D. Clifford, "A support vector machine approach for reliable detection of atrial fibrillation events," in *Computing in Cardiology Conference (CinC)*, 2013. IEEE, 2013, pp.1047–1050.
- R. J. Martis, U. R. Acharya, and H. Adeli, "Current methods in electrocardiogram characterization," *Computers in biology and medicine*, vol. 48, pp. 133–149, 2014. DOI: 10.1016/j.combiomed.2014.02.012
- S. Asgari, A. Mehrnia, and M. Moussavi, "Automatic detection of atrial fibrillation using stationary wavelet transform and support vector machine," *Computers in biology and medicine*, vol. 60, pp. 132–142, 2015. DOI: 10.1016/j.combiomed.2015.03.005
- S. Mittal, C. Movsowitz, and J. S. Steinberg, "Ambulatory external electrocardiographic monitoring: focus on atrial fibrillation," *Journal of the American College of Cardiology*, vol. 58, no. 17, pp. 1741–1749, 2011. DOI: 10.1016/j.jacc.2011.07.026.
- S. Sovilj, G. Rajsman, and R. Magjarević, "Ecg based prediction of atrial fibrillation using support vector classifier," *AUTOMATIKA: Journal of Automation, Measurement, Electronics, Computing and Communications*, vol. 52, no. 1, pp. 58–67, 2011. DOI: 10.1080/00051144.2011.11828404
- S. Raj, S. Luthra, and K. C. Ray, "Development of handheld cardiac event monitoring system," *IFAC PapersOnLine*, vol. 48, no. 4, pp. 71–76, 2015. DOI: 10.1016/j.ifacol.2015.07.010
- T. Jeon, B. Kim, M. Jeon, and B.-G. Lee, "Implementation of a portable device for real-time ecg signal analysis," *Biomedical engineering online*, vol. 13, no. 1, p. 160, 2014. DOI:10.1186/1475-925X-13-160.
- W. contributors, "K-nearest neighbors algorithm wikipedia the free encyclopedia," 2018, [Online; accessed 9-October-2021]. [Online]. Available: https://en.wikipedia.org/w/index.php?title=K-nearest_neighbors_algorithm&oldid=827389390