Clasificación de anomalías cardiacas mediante el uso de señales ECG y algoritmos de aprendizaje automático en una Raspberry PI

Manuel de Jesús Hernandez Llamas[1], Jorge Ulises Muñoz Minjares[2], Eduardo Cabal Yepez[1], Luis Manuel Ledezma Carrillo[1], Misael López Ramírez[1], Jorge Armando Carrillo-Zavala[1]

[1]Universidad de Guanajuato, campus Irapuato-Salamanca, Guanajuato, México. mdj.hernandezllamas@ugto.mx, educabal@ugto.mx, lopez.misael@ugto.mx, lm.ledesma@ugto.mx

[2]Universidad Autónoma de Zacatecas, Campus Jalpa, Zacatecas, México. ju.muñoz@uaz.edu.mx

Resumen

Las enfermedades cardíacas son una de las principales causas de muerte en el mundo, por esto es importante el contar con herramientas que ayuden a la detección temprana de estas enfermedades. Por ello, en este trabajo se plantea en el trabajo se plantea el uso de una tarjeta Raspberry PI para el procesamiento de señales electrocardiográficas (ECG) por medio de un filtrado con el Filtro de Respuesta Finita al Impulso no Sesgado Iterativo (I-UFIR) y posteriormente el entrenamiento de algoritmos de aprendizaje automático, como lo es las máquinas de soporte vectorial (SVM) y los Boosted Trees. En este trabajo la tarjeta Raspberry Pi demostró ser una herramienta eficaz para realizar la implementación en hardware del filtro, así como para entrenar los algoritmos para la detección de señales ECG de pacientes sin problemas cardiacos y de pacientes con arritmia e insuficiencia cardiaca congestiva.

Palabras clave: Raspberry Pi, Señal ECG, Filtro I-UFIR, Machine learning.

Introducción

En la actualidad, millones de personas en el mundo padecen enfermedades cardiovasculares, muchas de las cuales no se detectan a tiempo debido a la falta de acceso a diagnósticos tempranos, especialmente en regiones con recursos limitados. La identificación temprana de estas condiciones es fundamental para prevenir complicaciones graves a futuro e incluso la muerte de las personas. Es crucial atender este problema porque las enfermedades cardíacas siguen siendo una de las principales causas de mortalidad a nivel mundial y en Estados Unidos, esto de acuerdo a la OMS y la CDC respectivamente. Al integrar algoritmos de aprendizaje automático con dispositivos portátiles, potentes y versátiles como lo es la Raspberry Pi, se abre la posibilidad de desarrollar soluciones accesibles, portátiles y eficientes para el monitoreo continuo del corazón. Esto con el fin de mejorar la calidad de vida de los pacientes, y aliviar un poco la carga sobre los servicios de salud pública. Ignorar este problema puede tener consecuencias graves. La falta de detección temprana desencadena en diagnósticos tardíos, tratamientos más costosos, menor esperanza de vida, menor calidad de vida y, por último, una mayor presión sobre los servicios hospitalarios. Por ello, es fundamental contar con herramientas tecnológicas innovadoras que faciliten y ayuden a prevenir y vigilar enfermedades cardíacas de forma automatizada.

Las señales electrocardiográficas (ECG) son un método confiable y poco intrusivo para analizar el estado de un órgano tan importante como el corazón, estas señales han sido analizadas por medio de algoritmos de machine learning para encontrar patrones o arritmias que ayuden a los médicos a emitir un diagnóstico. Por ejemplo, El autor (Madan *et al*., 2022) implementó una red neuronal convolucional (CNN) para la detección de arritmias, insuficiencia cardiaca congestiva y señales sanas. También (Ahmad *et al*., 2021) propuso el análisis de estas señales desde la perspectiva de una imagen, extrayendo características de ellas mediante el uso de una CNN para posteriormente entrar una Máquina de Soporte Vectorial (SVM), este proceso demostró tener una buena efectividad y ser una opción viable, aunque el costo computacional puede ser algo elevado por las diferentes técnicas empleadas. Por otro lado (Cheng *et al*., 2021) propuso el uso de una red neuronal convolucional profunda (DCNN), que consta de 24 capas, y la memoria bidireccional de corto-largo plazo para la extracción de características de las señales ECG, esperando lograr una mejor clasificación de las señales, aunque el costo computacional de este método es alto. Por su parte (Attallah, 2022) hizo uso de la técnica ECG-BiCoNet para la detección de COVID-19, así como anormalidades en las señales ECG, el método consiste en 5 modelos de aprendizaje profundo que extraen características de las señales ECG. A

su vez se probaron 3 diferentes clasificadores: el Análisis Discriminante Lineal (LDA), máquina de soporte vectorial (SVM) y bosques aleatorios (RF). El autor (Al-Zaiti *et al*., 2023) en su trabajo realizó la detección de personas susceptibles a un infarto al miocardio por obstrucción, mediante el uso de un algoritmo de RF en conjunto con un algoritmo especial Shapley Additive exPlanations (SHAP), este algoritmo es utilizado para calcular la importancia de las características de una señal ECG y qué tanto impacto tiene en el algoritmo implementado. Por su parte (Aziz *et al*., 2021) planteó el uso de los algoritmos two-event related moving-averages (TERMA) y Fractional-Fourier-Transformer (FFT). El primero se encarga de especificar el área de interés donde la señal varía, mientras que el segundo transforma la señal ECG al plano tiempo-frecuencia para indicar la posición de las variaciones de la señal. Como clasificador se usó una SVM; y un perceptrón multicapa (MLP), realizando una clasificación de 4 tipos de arritmias cardíacas.

Por otro lado, la Raspberry Pi es un dispositivo portátil, versátil y potente que permite la implementación de algoritmos de machine learning. Por ejemplo, el autor (Sanjaya *et al*., 2024) hace uso de una red de sensores para detectar gases en las albóndigas, la información obtenida por estos sensores es utilizada para entrenar una SVM, con el fin de detectar y clasificar los gases.

La principal limitación de los algoritmos anteriormente mencionados es que requieren de equipos de alto costo, con gran capacidad de cómputo para su ejecución; lo cual dificulta su implementación en plataformas portátiles de bajo costo. La presente investigación propone la implementación de un sistema embebido basado en una plataforma Raspberry Pi para el procesamiento y análisis de señales electrocardiográficas (ECG), integrando técnicas de filtrado IUFIR, extracción de características y clasificación automática de anomalías cardíacas mediante el entrenamiento de 2 algoritmos de aprendizaje automático, SVM y Boosted Trees. A diferencia de trabajos previos desarrollados exclusivamente en entornos de simulación y procesamiento offline mediante MATLAB sobre computadoras personales, esta propuesta traslada la metodología a una arquitectura física de bajo costo y bajo consumo energético, orientada a aplicaciones biomédicas portátiles.

La principal aportación de este trabajo radica en la validación funcional de los algoritmos de procesamiento digital de señales en una plataforma embebida, considerando restricciones reales de memoria, capacidad de cómputo y tiempos de ejecución. Asimismo, se busca demostrar la viabilidad de integrar en un único sistema las etapas de adquisición futura de señales ECG, preprocesamiento mediante filtros IUFIR, extracción de parámetros relevantes y clasificación automática de eventos anómalos, permitiendo la detección local de alteraciones cardíacas sin depender de estaciones de procesamiento externas. De manera adicional, el trabajo contribuye al desarrollo de soluciones biomédicas accesibles y escalables, orientadas a sistemas portátiles de monitoreo cardiovascular, telemedicina y diagnóstico asistido por inteligencia artificial. La implementación embebida constituye un paso intermedio entre la validación teórica del algoritmo y su futura aplicación en dispositivos autónomos para supervisión continua de pacientes.

Filtrado I-UFIR

Para poder identificar y separar de manera eficiente las características que componen las distintas regiones de la señal ECG, es necesario realizar un preprocesamiento de filtrado a fin de aminorar los efectos de distintos tipos de ruidos. Por ejemplo, el Ruido muscular (EMG), interferencia de la línea base, ruido de red eléctrica (50/60 Hz) y por movimiento o la mala colocación de electrodos

Estos elementos afectan la calidad de la señal y pueden dificultar la correcta detección de las ondas, especialmente del complejo QRS, que es clave para el análisis de ritmo cardíaco.

Las técnicas de filtrado y procesamiento digital buscan atenuar el ruido sin distorsionar las características morfológicas de la señal, lo cual es crucial para preservar la información diagnóstica.

El filtrado I-UFIR es una técnica de procesamiento basada en filtros de Respuesta Finita al Impulso (FIR) con la propiedad de producir estimaciones de la señal original. A diferencia de los filtros convencionales FIR y Filtro de Respuesta Infinita al Impulso (IIR), el I-UFIR no depende de un modelo estadístico del ruido ni de condiciones iniciales, lo que lo hace particularmente robusto en situaciones donde la dinámica de la señal puede cambiar o donde la información previa es limitada. Debido a las bondades del filtrado, Los autores (Navarrete-Sanchez *et al*., 2025) lo utilizaron para realizar una predicción para los datos que se pierden durante el proceso de medición de la temperatura de un salón de clases.

En cuanto a las señales ECG, el filtro I-UFIR ha demostrado ser eficaz para:

Eliminar ruido de alta frecuencia sin afectar las formas de onda clave, Preservar la morfología del complejo QRS, mejorar la detección de eventos cardiacos incluso en condiciones adversas de adquisición. Considerando lo anterior, se aplica un filtro UFIR a la señal ECG con el objetivo de obtener tres estados derivados de su procesamiento. El estado 1 corresponde al suavizado de la señal ECG original. El estado 2 representa la estimación de la primera derivada del estado 1, mientras que el estado 3 corresponde a la estimación de la segunda derivada del mismo. Cada uno de estos estados proporciona información adicional sobre la dinámica de la señal, lo que permite extraer un mayor número de características relevantes para su análisis. La representación de una señal ECG en un modelo discreto en espacio de estados se expresa de la siguiente forma:

$$x_k = \boldsymbol{A}x_k k - 1 + \boldsymbol{B}w_k \quad (1)$$

$$y_k = \boldsymbol{C}x_k + v_k \quad (2)$$

Donde $x_k \in \mathbb{R}^K$ es el vector de estado, $y_k \in \mathbb{R}^M$ es el vector de observación, y $\boldsymbol{A} \in \mathbb{R}^{K\,x\,K}$ es la matriz de estado, $\boldsymbol{B} \in \mathbb{R}^{K\,x\,P}$, y $\boldsymbol{C} \in \mathbb{R}^{M\,x\,K}$.

El vector de ruido blanco gaussiano $w_k \sim N(0, Q_k) \in \mathbb{R}^P$ y $v_k \sim N(0, R_k) \in \mathbb{R}^M$ son considerados media cero, $E\{w_k\} = 0$ y $E\{v_k\} = 0$, con covarianzas $E\{w_k w_n^T\} = Q_k \mathrm{d}_{k-n}$ y $E\{v_k v_n^T\} = R_k \mathrm{d}_{k-n}$ y con la propiedad $E\{w_k v_n^T\} = 0$ para todo n y k.

Máquina de soporte vectorial

Las máquinas de soporte vectorial son algoritmos de aprendizaje supervisado desarrollados en la década de 1990. El objetivo principal de este algoritmo es encontrar un hiperplano optimo que divida los datos en distintas clases maximizando el margen entre los puntos más cercanos a dicho hiperplano, conocidos como vectores de soporte.

Cuando los datos no son linealmente separables, las SVM hacen uso de funciones kernel, para transformar el espacio original en uno de mayor dimensionalidad donde la separación sea posible. El kernel función de base radial (RBF), es uno de los kernels más utilizados, debido a que permite modelar relaciones altamente no lineales

Boosted Trees

Uno de los algoritmos más influyentes en esta categoría es Gradient Boosting, del cual derivan implementaciones modernas como XGBoost y LightGBM. Gradient Boosting entrena arboles de forma secuencial, donde cada nuevo árbol ajusta a los errores residuales del modelo anterior, en lugar de optimizar directamente los errores.

Mientras que XGBoost es una implementación optimizada del Gradient Boosting, está diseñada para mejorar el rendimiento predictivo y la eficiencia computacional. LightGBM es otra implementación del Gradient Boosting que fue desarrollada por Microsoft, esta se enfoca principalmente en la eficiencia y escalabilidad para volúmenes de datos muy grandes.

Metodología Propuesta

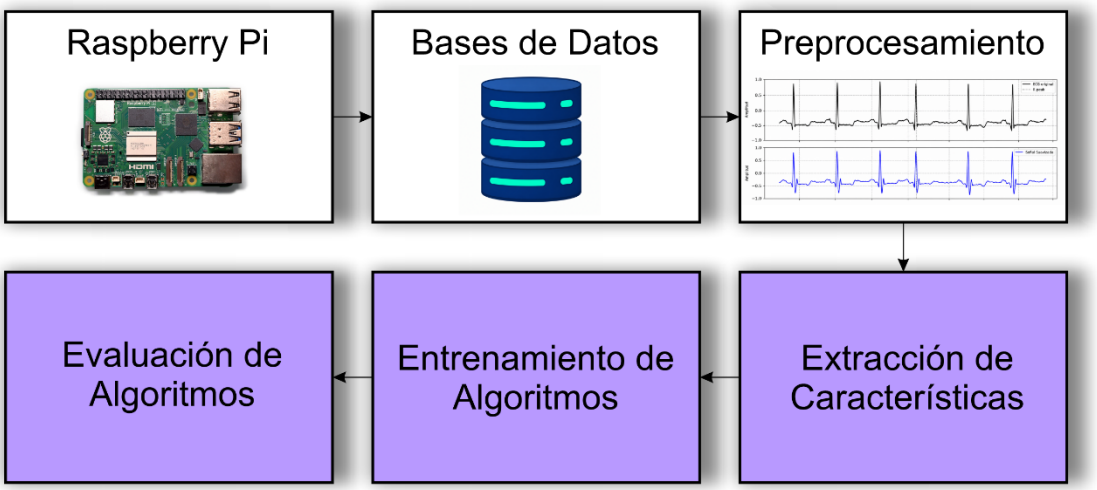


Figura 1. Metodología propuesta para el trabajo.
Fuente: Autoría propia.

En la Fig. 1 se puede observar la metodología que se utilizó en el desarrollo de este trabajo, primero se eligieron las bases de datos del sitio de Physionet, las bases de datos elegidas fueron: MIT-BIH Arrhythmia (Moody y Mark, 1992), la cual cuenta con 48 señales con duración de 30 minutos cada una, la MIT-BIH Normal Sinus Rhythm (The Beth Israel Deaconess Medical Center, 1990) que cuenta con 18 señales de 24 horas de duración cada una y por último, la BIDMC Congestive Heart Failure (Baim *et al*., 2000) que cuenta con 15 señales de 20 horas cada una, de igual forma estas bases de datos contienen señales ECG etiquetadas, posteriormente se hace el procesado de las señales en la Raspberry Pi 5, se utilizó la versión que cuenta con 16 Gb de RAM, todos los procesos de segmentación, filtrado y entrenamiento fueron implementados en la tarjeta, mediante el uso de Python, primero se realiza una segmentación tomando en cuenta las anotaciones incluidas en las bases de datos, obteniendo así fragmentos con una duración de 1500 muestras, obteniendo así, 85320 señales a las que posteriormente se les realizará el filtrado I-UFIR para obtener los 3 estados mencionados anteriormente. Una vez que se realiza esto, se procede a la extracción de las características, estas son: Entropía Espectral, Valor Pico, Factor Cresta, Factor de Impulso, Factor de Claridad, estas variables se someten a los algoritmos Anova y Tukey para determinar qué tan relevantes y útiles son para el entrenamiento de los algoritmos propuestos. Por último, se realiza el entrenamiento de la máquina de soporte vectorial y de los Boosted Trees, en cuanto a la SVM se entrenó con el kernel RBF, y por parte de los Boosted Trees se entrenaron con Gradient Boosting y XGBoost.

Resultados

Filtrado I-UFIR

El filtro I-UFIR fue implementado en la plataforma Raspberry Pi, demostrando que el dispositivo cuenta con la capacidad computacional necesaria para ejecutar el algoritmo y procesar señales ECG de forma eficiente. El filtrado permite obtener tres estados de la señal: el primero corresponde al suavizado de la señal ECG original, el segundo a la estimación de la primera derivada y el tercero a la estimación de la segunda derivada. Estos estados permiten resaltar la dinámica de la señal y facilitan la extracción de características relevantes para el proceso de clasificación. En la Fig. 2 se muestra un ejemplo del resultado del filtrado aplicado a una señal ECG correspondiente a un paciente con arritmia, donde se observa una reducción significativa del ruido preservando las características morfológicas de la señal.

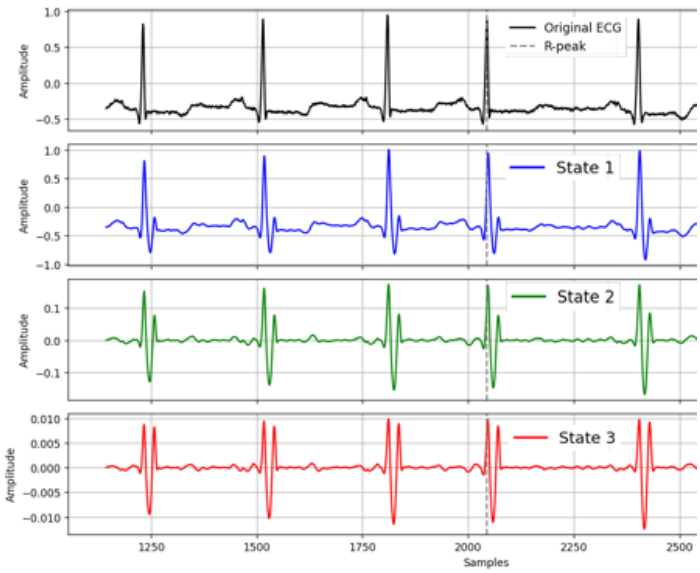


Figura 2. Resultados obtenidos por el filtrado I-UFIR aplicado a la señal ECG.
Fuente: Autoría propia.

Características

A partir de las señales ECG filtradas se extrajeron diversas características en el dominio temporal y espectral, entre las que se incluyen: entropía espectral, valor pico, factor de cresta, factor de impulso y factor de claridad. Con el fin de evaluar la relevancia de estas variables, se aplicaron los métodos estadísticos ANOVA y Tukey, los cuales permitieron identificar diferencias significativas entre los tres tipos de señales analizadas: señales normales, señales con arritmia y señales con insuficiencia cardíaca congestiva. Los resultados indican que las características seleccionadas contienen información suficiente para discriminar entre las diferentes clases de señales ECG.

Algoritmos

Para la clasificación de las señales ECG se evaluaron dos algoritmos de aprendizaje automático: Máquinas de Soporte Vectorial y Boosted Trees. En el caso de la SVM, se empleó el kernel RBF alcanzando una precisión mayor al 92%.

Por otra parte, se evaluaron dos algoritmos basados en Boosted Trees: Gradient Boosting y XGBoost. El algoritmo XGBoost ofrece un desempeño mejor en cuanto a precisión y tiempo de procesamiento, alcanzando una precisión cercana del 91 % con un tiempo de entrenamiento menor respecto al Gradient Boosting. Los resultados obtenidos por los algoritmos se pueden visualizar en la Tabla 1.

En general, los resultados obtenidos demuestran que la combinación del filtrado I-UFIR con algoritmos de aprendizaje automático permite realizar una clasificación efectiva de señales ECG, y que la plataforma Raspberry Pi constituye una alternativa viable para la implementación de este tipo de sistemas en entornos de bajo costo.

La tarjeta demostró poder manejar una gran cantidad de datos, haciendo uso de pocos recursos, como es el caso de la SVM, o en el caso de los boosted trees, es capaz de utilizar todo el procesador para realizar un entrenamiento más rápido, de igual forma, la cantidad de muestras que puede procesar por segundo son bastante altas.

***Tabla 1**. Resultados obtenidos por los algoritmos y recursos empleados durante su entrenamiento.*

Algoritmo	Accuracy (%)	Tiempo (S)	Memoria Utilizada (MB)	Procesador Utilizado (%)
RBF	92.1	287	395	25
Gradient Boosting	88.64	161	255	25
XGBoost	91.13	32	306	94

Referencias

Ahmad, Z., Tabassum, A., Guan, L., y Khan, N. M. (2021). ECG Heartbeat Classification Using Multimodal Fusion. *IEEE Access*, *9*, 100615–100626. https://doi.org/10.1109/ACCESS.2021.3097614

Al-Zaiti, S. S., Martin-Gill, C., Zègre-Hemsey, J. K., Bouzid, Z., Faramand, Z., Alrawashdeh, M. O., Gregg, R. E., Helman, S., Riek, N. T., Kraevsky-Phillips, K., Clermont, G., Akcakaya, M., Sereika, S. M., Van Dam, P., Smith, S. W., Birnbaum, Y., Saba, S., Sejdic, E., y Callaway, C. W. (2023). Machine learning for ECG diagnosis and risk stratification of occlusion myocardial infarction. *Nature Medicine*, *29*(7), 1804–1813. https://doi.org/10.1038/s41591-023-02396-3

Attallah, O. (2022). ECG-BiCoNet: An ECG-based pipeline for COVID-19 diagnosis using Bi-Layers of deep features integration. *Computers in Biology and Medicine*, *142*, 105210. https://doi.org/10.1016/j.compbiomed.2022.105210

Aziz, S., Ahmed, S., y Alouini, M.-S. (2021). ECG-based machine-learning algorithms for heartbeat classification. *Scientific Reports*, *11*(1), 18738. https://doi.org/10.1038/s41598-021-97118-5

Baim, D. S., Colucci, W. S., Monrad, E. S., Smith, H. S., Wright, R. F., Lanoue, A., Gauthier, D. F., Ransil, B. J., Grossman, W., y Braunwald, E. (2000). *The BIDMC Congestive Heart Failure Database* [Dataset]. physionet.org. https://doi.org/10.13026/C29G60

Cheng, J., Zou, Q., y Zhao, Y. (2021). ECG signal classification based on deep CNN and BiLSTM. *BMC Medical Informatics and Decision Making*, *21*(1), 365. https://doi.org/10.1186/s12911-021-01736-y

Madan, P., Singh, V., Singh, D. P., Diwakar, M., Pant, B., y Kishor, A. (2022). A Hybrid Deep Learning Approach for ECG-Based Arrhythmia Classification. *Bioengineering*, *9*(4), 152. https://doi.org/10.3390/bioengineering9040152

Moody, G. B., y Mark, R. G. (1992). *MIT-BIH Arrhythmia Database* [Dataset]. physionet.org. https://doi.org/10.13026/C2F305

Navarrete-Sanchez, M. A., Olivera-Reyna, R., Olivera-Reyna, R., Perez-Chimal, R. J., y Munoz-Minjares, J. U. (2025). *IoT-Based Classroom Temperature Monitoring and Missing Data Prediction Using Raspberry Pi and ESP32 | Journal of Robotics and Control (JRC)*. https://journal.umy.ac.id/index.php/jrc/article/view/24345

Sanjaya, W. S. M., Roziqin, A., Wijaya Temiesela, A., Fauzi Badru Zaman, M., Taqwim, A., Opialisti, I., Sintia, P., Mulyawan, A., Anggraeni, D., y Sa'adah, T. (2024). Developing an electronic nose for formalin detection in meatballs using Support Vector Machine (SVM) method and Raspberry Pi 4. *Physica Scripta*, *99*(9), 096009. https://doi.org/10.1088/1402-4896/ad6a9e

The Beth Israel Deaconess Medical Center, T. A. L. (1990). *The MIT-BIH Normal Sinus Rhythm Database* [Dataset]. physionet.org. https://doi.org/10.13026/C2NK5R