

Detección del pico de la onda R en señales ECG mediante redes neuronales R-wave peak detection in ECG signals using neural networks

F. R. Serrano-Domínguez ^a, L. A. Ramírez-Cruz ^a, M. J. Arzeta-Tellez ^a, J. C. Cruz López ^a

^a Área Académica de Electrónica, Tecnológico de Estudios Superiores de Villa Guerrero, 51767, Villa Guerrero, Estado de México, México.

Resumen

En este trabajo se desarrolla un algoritmo para el procesamiento de señales electrocardiográficas (ECG) para la detección de ondas específicas de estas señales mediante Redes Neuronales. Estas señales que presentan características distintivas como intervalos temporales, amplitudes y morfologías están definidos en las ondas P, Q, R, S. El estudio se enfoca a la detección del pico de la onda R del complejo QRS usualmente empleado para la determinación de la frecuencia cardíaca. La red neuronal se entrena con una señal ideal que ha sido generada por un sistema electrónico conformado por un dispositivo DAC (digital to analog converter), aplicando en el proceso capas intermedias para ajustar los pesos sinápticos mediante el método de retropropagación (backpropagation), corrigiendo así los errores de aprendizaje, posteriormente, se prueba la red para verificar su capacidad de reconocer la presencia del pico de la onda R en señales alteradas morfológicamente, este tipo de investigaciones permiten identificar características relacionadas con las arritmias cardíacas y otras afecciones en señales del corazón.

Palabras Clave: Señales, ECG, Ondas, Complejos, Redes.

Abstract

In this work an algorithm for the processing of electrocardiographic (ECG) signals is developed for the detection of specific waves using Neural Networks. These signals present distinctive characteristics such as time intervals, amplitudes and morphologies which are defined as the P, Q, R, S waves. The study is focused on the detection of the R wave peak of the QRS complex usually used for heart rate determination. The neural network is trained with an ideal signal generated by an electronic system conformed by a DAC (digital to analog converter) device, applying in the process intermediate layers to adjust the synaptic weights by means of the backpropagation method, thus correcting the learning errors, later the network is tested to verify its capacity to recognize the presence of the R wave peak in morphologically altered signals, this type of research allows identifying characteristics related to cardiac arrhythmias and other heart conditions.

Keywords: Signals, ECG, Waves, Complexes, Networks.

1. Introducción

Las señales ECG (electrocardiograma) han sido estudiadas constantemente como recurso para la medición del ritmo cardíaco y el diagnóstico de enfermedades, la estructura de estas señales está determinada por una nomenclatura propuesta por Einthoven (Lama, 2003) como PQRS y T.

Las investigaciones aplicando esta nomenclatura han permitido caracterizar e identificar distintas enfermedades relacionadas con el corazón, para 1985 ya se había desarrollado un algoritmo que permitía la detección del complejo QRS en tiempo real creado por Jiapu Pan y Willis J. Tompkins este algoritmo propone un análisis de amplitud, pendiente y fase de los complejos QRS, permitiendo identificar sus intervalos por

medio de filtros integradores y derivadores que perciben los cambios bruscos de pendiente que caracterizan el inicio de las ondas R (Tomkins, 1985).

Entre algunos de los algoritmos implementados en la detección de los complejos se encuentran el uso de la transformada Wavelet para la detección del complejo QRS en electrocardiogramas (N. Garcia, 2014), La transformada rápida de Fourier en aplicación del análisis tiempo-frecuencia en electrocardiografía (Tomkins, 1985). (Willys, 2014). Dichas técnicas son las más utilizadas en el análisis de los intervalos R-R o del complejo QRS realizando un estudio más completo de la señal ECG. También se han empleado otras técnicas u algoritmos desarrollados de forma analítica basándose en las características principales que presentan las señales eléctricas del corazón, otra propuesta (Olivera, 2014),

*Autor para la correspondencia: felipeserranod@gmail.com

Correo electrónico: felipeserranod@gmail.com (Felipe Raymundo Serrano Domínguez), skjuance@gmail.com (Juan Carlos Cruz López), luisangel.ramirez.ie.tesvg@gmail.com (Luis Ángel Ramírez Cruz), Jahaziel02@gmail.com (Mijamin Jahaziel Arzeta Tellez)

Historial del manuscrito: recibido el 17/03/2025, última versión-revisada recibida el 30/06/2025, aceptado el 30/07/2025, publicado el 15/09/2025. **DOI:** <https://doi.org/10.29057/icbi.v13iEspecial2.14711>



propone un método para la detección de arritmias a través del intervalo R-R, denominado método de detección de arritmias para un dispositivo móvil con sistema de alerta.

La principal característica es que la detección del intervalo se realiza mediante un circuito analógico diseñado con amplificadores operacionales, basándose en la obtención de amplitud máxima de la señal ECG que son procesados por un microcontrolador Arduino y conforme a este método se pueden detectar enfermedades cardíacas clasificándolas en taquiarritmias y bradiarritmias.

De acuerdo con A. Mariel, se pueden crear algoritmos sencillos para la detección del complejo QRS. En su trabajo estudia el ECG pero a bajo nivel, analiza cada pulso del corazón extrayendo las características del mismo, permitiéndolo desarrollar un proceso de detección de ondas. Se emplean algoritmos específicos creados por el autor, hace uso de una placa Arduino para la ejecución de instrucciones y realiza una interfaz con un dispositivo Android para su visualización. (Mariel, 2014).

Entre los métodos donde se implementan redes neuronales artificiales se encuentran la implementación de RNA y extracción de características para clasificar señales de ECG basadas en clasificar segmentos o intervalos, presentes en una señal ECG, para ello se suelen utilizar algoritmos como el de Jiapu Pan y Willis J. Tompkins que permiten detectar el complejo QRS. El diseño de esta red proporciona un resultado óptimo para la clasificación de distintas arritmias.

Por su parte S. Jiménez, argumenta que las RNA aplicadas en ECG se pueden utilizar para la detección automática de latidos cardíacos irregulares (Mariel, 2014). En este trabajo se realiza un programa donde diseña una RNA que entrena con una señal cardíaca ideal con intervalos periódicamente repetidos, los resultados los adquiere con un porcentaje de error comparando diversas señales con ritmos irregulares con respecto de la señal ideal. (Serrano, 2018)

En redes neuronales artificiales para el procesado versátil de señales electrocardiográfica (Jiménez, 2012), se establece un sistema de arquitecturas de redes que facilitan tanto el filtrado como la identificación del complejo QRS, así como la extracción automática de características de la actividad ventricular en las señales de ECG. Para comprobar la validez de sus resultados, se creó una base de datos que incluye registros de ECG con distintos tipos de señales: sintetizadas, pseudo-reales y reales. Sin embargo N. Bettancourt en su trabajo menciona que una desventaja al implementar redes neuronales es requerir de una base de datos para cualquier tipo de estudio o proceso, además del alto costo computacional al usar muchos datos y complejo de comprender debido a su naturaleza (Gélvez, Díaz, Montenegro, & Gaona, 2022).

Entre los dispositivos comerciales para la detección de señales cardíacas actualmente se cuenta con dispositivos comerciales que son capaces de monitorear en tiempo real un electrocardiograma, se hace mención en el artículo de (Estragó, 2024) como es el caso de Kardia Mobile que está diseñado por KardiaTM para registrar, almacenar y transferir ritmos en un electrocardiograma de un solo canal ECG, se

representan los ritmos cardíacos y se identifica la presencia de fibrilación auricular, así como un ritmo sinusal normal, siempre que se prescriba o utilice bajo la supervisión de un médico.

La propuesta que se realiza a diferencia de los trabajos relacionados es el aprovechamiento de datos generados mediante un modelo matemático y no por señales reales de pacientes en específico, esto en consideración de distintos aspectos entre los que se encuentran:

- La dificultad para poder adquirir señales en entornos reales o adquirir información de bases de datos de centros de atención los cuales suelen ser muy extensos y con características técnicas muy específicas para cada equipo ECG, donde destacan aquellos que trabajan con 12 derivaciones para los procesos de diagnóstico, esto resulta poco práctico para los objetivos de la investigación con enfoque en la onda R.
- Asimismo, en muchos de los casos las señales de estas bases de datos tienen registros indiferentes entre, personas con alguna patología o sanas por lo que sin la supervisión especializada el proceso de aprendizaje sería poco útil.
- Por otra parte, para los fines de la investigación se tienen delimitado enfocarse en el complejo R, donde una señal ideal se considera lo suficiente precisa, considerando que el monitoreo normalmente se realiza con 3 derivaciones con especial interés en el complejo de mayor amplitud o complejo R (Gonzalez, Velandia, & Nieto, 2016), con esto se hace evidente el interés de enfocar los esfuerzos en esta onda para determinar una frecuencia cardíaca, en ese sentido una señal ideal se ha considerado como una opción viable para las pruebas.

2. Redes neuronales

Según J. Montaña, las Redes Neuronales Artificiales (RNA), también conocidas como sistemas conexionistas son: estructuras creadas para manejar información, tomando como modelo la organización y operación de las redes neuronales en los seres vivos. Estas redes consisten en componentes de procesamiento básico, denominados nodos o neuronas, que están conectados mediante enlaces que poseen valores numéricos modificables, a los que se les llama pesos. (Montaña, 2002).

En 1943, McCulloch y Pitts describieron la estructura y el funcionamiento de la unidad básica de procesamiento en una red conexionista conocida hoy como la neurona de McCulloch-Pitts, esta unidad suma los valores de las entradas que recibe de otras neuronas conectadas y luego compara este total con un valor umbral si alcanza o supera este umbral, envía una señal de activación a las neuronas conectadas. Tanto las entradas como las salidas dependen de la fuerza de las conexiones, es decir, de los pesos asignados a cada una de

ellas. (Melendez, 2000), se muestra en la Figura 1 una representación de dicho proceso.

Un modelo típico de RNA está compuesto por varias capas de unidades de procesamiento que imitan el comportamiento de las neuronas. Cada unidad toma información de las neuronas de la capa anterior realiza una operación simple, como determinar si su valor supera un umbral y luego pasa el resultado a la siguiente unidad, facilitando así la obtención del resultado deseado en la última neurona. (Tejada, 2002).




Figura 1: Modelo de una neurona artificial

En la Figura 1 se observa que la suma de las n entradas x_j con $j = 1, \dots, n$ de la neurona i , ponderadas con los pesos que enlazan a la neurona i con la entrada j , que miden la intensidad de la interacción entre las dos neuronas que están conectadas por el enlace. Para la neurona i , la entrada se expresa en la Ecuación 1.

$$h_i(t) = \sum_{j=1}^n w_{ij} x_j \quad (1)$$

2.1 Arquitectura de redes neuronales

Hagan y Demut (1996) definen que la arquitectura se refiere a la topología, estructura o patrón de conexiones de una red neuronal. En los sistemas neuronales artificiales (ANS), los nodos están vinculados a través de sinapsis, y el funcionamiento de la red depende de la configuración de estas conexiones. Estas son unidireccionales, lo que implica que la información se desplaza en una sola dirección, desde la neurona presináptica hacia la neurona postsináptica. Generalmente, las neuronas se agrupan en unidades estructurales denominadas capas y dentro de cada capa, pueden organizarse en conjuntos neuronales que suelen ser del mismo tipo (Demuth, 1996). El enlace entre una o más capas constituye una red neuronal, como se ilustra en la Figura 2. Se pueden identificar tres tipos de capas:

Capa de entrada: Formada por neuronas que reciben datos o señales iniciales del entorno.

Capa oculta: Esta capa no tiene conexión directa con el entorno. Proporciona a la red neuronal grados de libertad que le permiten representar características específicas del entorno que está modelando.

Capa de salida: Compuesta por neuronas cuyo resultado final representa la respuesta final de la red neuronal.




Figura 2: Modelo de red neuronal

2.2 Redes neuronales aplicadas a señales ECG

3. Diseño de la red para la detección del pico de la onda R

Estructura del MLP (multilayer perceptron) se presenta en la Figura 1, y sus componentes se muestran en la Tabla 1.

Tabla 1: Variables de la red neuronal

componente	descripción
L	Número total de capas de toda la red neuronal
X_i	Número de neurona en la capa de entrada
Z	Neuronas en las capas ocultas y capa de salida de la red
q, j	Representan el número de neuronas en las capas ocultas
k	Número de neuronas en la capa de salida
w_{qi}	Los pesos que conectan a la capa entrada i con la capa q
w_{jq}	Los pesos que conectan a la capa q con la capa j
w_{kj}	Los pesos que conectan a la capa j con la capa de salida k
θ	Umbral de la red




Figura 3: Red neuronal multicapa con dos capas ocultas.

Se dispone de un conjunto de entradas-salidas con p pares de entrenamiento que se denotan como: $[x_1, c_1], [x_2, c_2], \dots, [x_p, c_p]$. Donde x es la entrada y c la salida objetivo. Se puede definir a la señal de error e_{pk} del valor de la capa de salida z_{pk}^L y el par de entrenamiento p con la Ecuación (2).

$$\xi_p = \frac{1}{2} \sum_{k=1}^S (e_{pk})^2 \quad (2)$$

El error cuadrático medio se calcula sumando ξ_p para todos los pares de entrenamiento y normalizando el resultado dividiendo por S tal como se indica en la Ecuación (3).

$$E = \frac{1}{S} \sum_{k=1}^S (\xi_p) \quad (3)$$

La Ecuación (3) describe la función de coste, que actúa como una medida del proceso de aprendizaje. El objetivo principal de este proceso es ajustar los parámetros de la red para reducir al máximo el error. Los cambios en los pesos se basan en los errores calculados para cada par de entrenamiento que se introduce en la red. Al promediar esos ajustes individuales a lo largo de todos los pares de entrenamiento, se obtiene una estimación de cómo deberían modificarse los pesos para minimizar la función de coste E en todo el conjunto de datos. (Tanco, 2021). La corrección de los pesos sinápticos se realiza mediante la Ecuación (4).

$$w(t+1) = w(t) - \alpha \nabla E \quad (4)$$

Teniendo en cuenta que $w(t+1)$ es el valor del nuevo peso, $w(t)$ valor del peso actual, α la tasa de aprendizaje y $-\nabla E$ se describe como la derivada parcial del error respecto al vector de parámetros de la red, en dirección al decremento más rápido del error.

$-\nabla E$ Es proporcional al gradiente $-\frac{\partial \xi_p}{\partial w_{kj}^L}$ y $-\frac{\partial \xi_p}{\partial \theta_k^L}$ que de acuerdo a la regla de la cadena se puede expresar de la Ecuación (5).

$$-\frac{\partial \xi_p}{\partial w_{kj}^L} = \frac{\partial \xi_p}{\partial z_{pk}^L} \frac{\partial z_{pk}^L}{\partial w_{kj}^L} \frac{\partial h_{pk}^L}{\partial w_{kj}^L} \quad (5)$$

$$-\frac{\partial \xi_p}{\partial \theta_k^L} = \frac{\partial \xi_p}{\partial z_{pk}^L} \frac{\partial z_{pk}^L}{\partial h_{pk}^L} \frac{\partial h_{pk}^L}{\partial \theta_k^L} \quad (6)$$

Recordando que la entrada de la última capa es $h_{pk}^L = (\sum_{j=1}^o w_{kj}^L z_{pj}^{L-1} + \theta_k^L)$ y la salida de la red $z_{pk}^L = f_k^L(\sum_{j=1}^o w_{kj}^L z_{pj}^{L-1} + \theta_k^L)$. Tenemos que la derivada de la función de ξ_p con respecto a z_{pk}^L es igual a la Ecuación (6).

$$\frac{\partial \xi_p}{\partial z_{pk}^L} = (c_{pk} - z_{pk}^L) \quad (7)$$

La derivada de la respuesta de la neurona en relación a su excitación es, sin duda, la derivada de la función de activación empleada en la unidad pertinente. Por consiguiente:

$$\frac{\partial z_{pk}^L}{\partial h_{pk}^L} = f_k'^L(h_{pk}^L) \quad (8)$$

La función de activación se mantiene expresada de esa manera ya que depende de la función implementada en esa capa, por ejemplo:

Si la función de activación f usada es sigmoidea, entonces se vería expresada como:

$$z_{pk}^L = \left(\frac{1}{1 + e^{-h_{pk}^L}} \right) \Rightarrow f_k'^L(h_{pk}^L) = z_{pk}^L (1 - z_{pk}^L) \quad (9)$$

Mientras que una función lineal sería igual a:

$$z_{pk}^L = h_{pk}^L \Rightarrow f_k'^L(h_{pk}^L) = 1 \quad (10)$$

Finalmente derivando h_{pk}^L con respecto de los parámetros de la red se tiene:

$$\frac{\partial h_{pk}^L}{\partial w_{kj}^L} = z_{pj}^{L-1} \quad (11)$$

$$\frac{\partial h_{pk}^L}{\partial \theta_k^L} = 1 \quad (12)$$

Sustituyendo las Ecuaciones (7), (8) y (11) en Ecuación (5), resulta:

$$-\frac{\partial \xi_p}{\partial w_{kj}^L} = (c_{pk} - z_{pk}^L) f_k'^L(h_{pk}^L) z_{pj}^{L-1} \quad (13)$$

Si sustituimos las Ecuaciones (7), (8) y (25) en 14 tenemos:

$$-\frac{\partial \xi_p}{\partial \theta_k^L} = (c_{pk} - z_{pk}^L) f_k'^L(h_{pk}^L) \quad (14)$$

De la Ecuación (21), se obtiene la sensibilidad de la última capa (δ), que se define como la fuerza que tiene el error propagado en esa capa y se expresa como:

$$\delta_{pk}^L = (c_{pk} - z_{pk}^L) f_k'^L(h_{pk}^L) \quad (15)$$

De manera que los pesos en la última capa se modificarán con la Ecuación (16).

$$w_{kj}^L(t+1) = w_{kj}^L(t) + \alpha \delta_{pk}^L z_{pj}^{L-1} \quad (16)$$

Mientras que la Ecuación (17), actualiza el sesgo.

$$\theta_k^L(t+1) = \theta_k^L(t) + \alpha \delta_{pk}^L \quad (17)$$

5.4.1 Capas ocultas

En cuanto a los parámetros de la capa oculta, se muestran en la Ecuación (18) y (19).

$$-\frac{\partial \xi_p}{\partial w_{jq}^{L-1}} = \sum_{k=1}^S (c_{pk} - z_{pk}^L) \frac{\partial z_{pk}^L}{\partial h_{pk}^L} \frac{\partial h_{pk}^L}{\partial z_{pj}^{L-1}} \frac{\partial z_{pj}^{L-1}}{\partial h_{pj}^{L-1}} \frac{\partial h_{pj}^{L-1}}{\partial w_{jq}^{L-1}} \quad (18)$$

$$-\frac{\partial \xi_p}{\partial \theta_j^{L-1}} = \sum_{k=1}^S (c_{pk} - z_{pk}^L) \frac{\partial z_{pk}^L}{\partial h_{pk}^L} \frac{\partial h_{pk}^L}{\partial z_{pj}^{L-1}} \frac{\partial z_{pj}^{L-1}}{\partial \theta_j^{L-1}} \quad (19)$$

Donde $h_{pj}^{L-1} = (\sum_{q=1}^m w_{jq}^{L-1} z_{pq}^{L-2} + \theta_j^{L-1})$ mientras que $z_{pj}^{L-1} = f_j^{L-1}(\sum_{q=1}^m w_{jq}^{L-1} z_{pq}^{L-2} + \theta_j^{L-1})$. Sabemos que la Ecuación 21, representa la sensibilidad de la última capa por lo tanto podemos reescribir la Ecuación (20) y (21) tal que:

$$-\frac{\partial \xi_p}{\partial w_{jq}^{L-1}} = \sum_{k=1}^S (\delta_{pk}^L) \frac{\partial h_{pk}^L}{\partial z_{pj}^{L-1}} \frac{\partial z_{pj}^{L-1}}{\partial h_{pj}^{L-1}} \frac{\partial h_{pj}^{L-1}}{\partial w_{jq}^{L-1}} \quad (20)$$

$$-\frac{\partial \xi_p}{\partial \theta_j^{L-1}} = \sum_{k=1}^S (\delta_{pk}^L) \frac{\partial h_{pk}^L}{\partial z_{pj}^{L-1}} \frac{\partial z_{pj}^{L-1}}{\partial h_{pj}^{L-1}} \frac{\partial h_{pj}^{L-1}}{\partial \theta_j^{L-1}} \quad (21)$$

La Ecuación (22), muestra la derivada h_{pk}^L con respecto de la salida de la capa z_{pj}^{L-1} :

$$\frac{\partial h_{pk}^L}{\partial z_{pj}^{L-1}} = w_{kj}^L \quad (22)$$

Al derivar la salida de la capa z_{pj}^{L-1} en relación a h_{pj}^{L-1} resulta la derivada de la función de activación utilizada en dicha capa.

$$\frac{\partial z_{pj}^{L-1}}{\partial h_{pj}^{L-1}} = f_j^{L-1}(h_{pj}^{L-1}) \quad (23)$$

Por otra parte, la Ecuación (24) y (25) muestran que se tiene h_{pj}^{L-1} respecto a los elementos peso y sesgo de la capa oculta correspondiente.

$$\frac{\partial h_{pj}^{L-1}}{\partial w_{jq}^{L-1}} = z_{pq}^{L-2} \quad (24)$$

$$\frac{\partial h_{pk}^L}{\partial \theta_k^L} = 1 \quad (25)$$

Por lo que la sensibilidad de la capa anterior L-1, se vería expresada como en la Ecuación (26).

$$\delta_{pj}^{L-1} = f_j^{L-1}(h_{pj}^{L-1}) \sum_{k=1}^S (\delta_{pk}^L) w_{kj}^L \quad (26)$$

Finalmente, la actualización de pesos y sesgo en las capas ocultas quedan en Ecuación (27) y (28).

$$w_{jq}^{L-1}(t+1) = w_{jq}^{L-1}(t) + \alpha \delta_{pj}^{L-1} z_{pq}^{L-2} \quad (27)$$

$$\theta_j^{L-1}(t+1) = \theta_j^{L-1}(t) + \alpha \delta_{pj}^{L-1} \quad (28)$$

3.2 Origen de datos

Los datos ECG para realizar pruebas fueron generados mediante el modelo triplemente acoplado de Van Der Pol, una de las características importantes de este modelo es que genera a partir de un sistema ecuaciones valores ideales de un ECG con ritmo normal, es decir valores que carecen de interferencias y además cuenta con intervalos periódicamente repetidos. (M. J. López, 2010). En referencia a los alcances de este modelo ideal se consideró esencial incorporarle las limitantes de un entorno físico generadas por un sistema electrónico, con ello se limita la cantidad de datos, la amplitud de estos y se incorpora parte del ruido que puede presentarse en un sistema real.

Para ello se emplea un microcontrolador ATMEGA328P y un Convertidor Digital Analógico serie DAC0800. El programa consiste en un vector que contiene todas las cifras numéricas que conforman el registro ECG del modelo y que son enviados a través de uno de sus puertos de 8 bits del microcontrolador, que posteriormente son adquiridos por el DAC convirtiendo estos valores digitales en salidas analógicas en una escala numérica de 0 a 5v o su equivalente decimal de 0 a 255 unidades, Con ello el resultado final de los datos en la Figura 4.




Figura 4: Señal de entrenamiento con datos ideales generados por ADC.

Las características de esta señal se describen en la Tabla 2. Aquí se observa como para el caso de la onda R se tiene la mayor amplitud de voltaje equivalente a 3.6v o en su caso 184 en el sistema decimal.

Tabla 2: Valores de la señal cardiaca.

Onda	Amplitud	Escala decimal ADC 8 bits
P	1.23 Volts	63
Q	0.3 Volts	15
R	3.6 Volts	184
S	0.5 Volts	26
T	1.75 Volts	89

3.3 Modelo de la red neuronal implementada

Mediante un proceso empírico donde se considera la estructura de los datos y la precisión de los resultados para identificar la onda R. La capa de entrada se estableció por lo tanto en el mismo número de datos totales de los registros de la señal ECG (402 datos). El número de capas ocultas y neuronas se determinaron, de forma experimental hasta reducir considerablemente el error para una señal ideal de prueba obteniendo un total de 9 capas ocultas, la primera capa z^1 está constituida por 190 neuronas (z_{190}^1) sucesivamente hasta la capa z_{110}^9 y con funciones de activación tipo sigmoidea.

Para la capa de salida se cuenta con una única neurona que se encargará de informarsi la señal corresponde a la posición de la red neuronal. Este diseño se puede ver en la Figura 5, el mismo nos permite analizar otro tipo de señales que tengan otra morfología o que presenten variaciones en los datos siempre y cuando cuenten con el mismo número de datos, este modelo resultante está estrechamente relacionado a la estructura de datos que se menciona en la siguiente sección.




Figura 5: Modelo de Red implementada

3.4 Entrenamiento de la red

El entrenamiento se basa en el aprendizaje supervisado. Se estableció una base de datos que nos permita realizar una fase de entrenamiento y una fase de prueba. Los datos de entrenamiento se componen de 402 valores que conforman a la señal. Como se menciona en secciones anteriores el entrenamiento con aprendizaje supervisado se debe realizar conociendo la respuesta de salida esperada por la red, por lo que, se tomaron los valores máximos como referencia que identificará la posición donde se encuentra el complejo R.

Lo que se pretende con la red neuronal es que logre identificar la posición exacta del pico de la onda R del complejo QRS, identificado en la señal como el valor máximo, para lograr esto debemos conocer la posición exacta donde se encuentra dicho complejo asignándole ese valor a la salida esperada en el proceso de aprendizaje. En términos generales mediante un diagrama de flujo que se muestra en la Figura 6.




Figura 6: Diagrama de flujo del algoritmo para detectar Picos de la onda R y su aplicación para detectar la frecuencia.

Con una base de datos de entrenamiento conformada por 402 datos con una longitud de 402 bytes se ha realizado el proceso de entrenamiento obteniendo el error cuadrático medio del proceso de entrenamiento. A medida que avanza el proceso el error disminuye hasta alcanzar valores lo más cercanos a cero tal y como se muestra en Figura 7. Para el proceso de prueba e identificación se aplica una base de datos de 402 datos donde se distinguen al menos dos ondas R sobre el eje del tiempo hasta que la red sea capaz de identificar con un error menor al 0.5%.




Figura 7: Gráfica de error cuadrático medio.

En la verificación del proceso de aprendizaje se ha delimitado la cantidad de datos seleccionados, si bien podrían incrementarse para mejorar su precisión, en el enfoque actual solo se pretende explorar a nivel local para facilitar su implementación en una computadora o microcontrolador con

recursos limitados por lo que la cantidad de datos se considera adecuada.

4. Resultados

Para la verificación de la funcionalidad de la red se realiza la comprobación mediante tres tipos de señales de prueba.

Tipo 1, con datos obtenidos de los mismos empleados para el entrenamiento de la red, ver Figuras 8 y 9.




Figura 8: Resultado con señal de entrenamiento prueba 1.




Figura 9: Resultados con señal de entrenamiento prueba 2.

Tipo 2, con una señal de entrenamiento contaminada con una señal tipo sinusoidal a 60hz con una amplitud del 10% sobre la amplitud máxima, ver Figura 10.




Figura 10: Resultados con Señal contaminada 1 prueba 1

Tipo 3, con una señal contaminada con una señal tipo sinusoidal a 60hz con una amplitud del 20% sobre la amplitud máxima, ver Figura 11.




Figura 11: Resultados con señal contaminada 3

Los asteriscos en color rojo nos indican la respuesta de la red neuronal. Los tres resultados de la primera prueba se muestran en la Figura 8 y 9 con una señal ideal, la Figura 10 con señal contaminada y la Figura 11 con una señal más contaminada, las respuestas de la red se muestran en la Tabla 3.

Tabla 3: Resultados obtenidos con el diseño de red neuronal.

Prueba	Respuesta esperada por la red	Respuesta de la red con señal de entrenamiento	Respuesta de red con señal contaminada 1	Respuesta de red con señal contaminada 2
1	132, 332	132.5, 332.5	137.2, 337.2	144.3, 344.3
2	184, 384	184.5, 384.5	190.4, 390.4	197.6, 397.6
3	36, 236	36.5, 236.5	41.8, 241.8	47.2, 247.2
4	83, 283	83.5, 283.5	89.1, 288.1	95.5, 295.5

El porcentaje de error de cada prueba se muestra en Tabla 4, en esta se puede observar como el error se incrementa conforme se incrementa el nivel de contaminación en la señal de prueba tanto para la posición en x como en la posición en y.

Tabla 4: Porcentaje de error obtenido por cada prueba realizada

Prueba	Respuesta esperada por la red	Porcentaje de error con señal de entrenamiento	Porcentaje de error con señal contaminada 1 (10% ruido).	Porcentaje de error con señal contaminada 2 (20% ruido)
1	132, 332	0.37%, 0.15%	3.93%, 1.56%	9.31%, 3.70%
2	184, 384	0.27%, 0.13%	3.47%, 1.66%	7.39%, 3.54%
3	36, 236	1.38%, 0.21%	16.11%, 2.45%	31.11%, 4.74%
4	83, 283	0.60%, 0.17%	7.34%, 1.80%	15.06%, 4.41%

5. Conclusiones

La implementación de redes neuronales destaca por su capacidad adaptativa ante cambios en la señal, lo que permite buscar la respuesta más cercana a la esperada incluso cuando la señal está contaminada o desplazada. Además, añadir más

capas neuronales podría potencialmente reducir el error. a pesar de estas ventajas, las redes neuronales tienen limitaciones, como la restricción a evaluar una cantidad específica de datos, en este caso 402, la demanda computacional durante el entrenamiento que limita la respuesta en tiempo real comparada con sistemas analógicos o detectores de picos digitales incluyendo la necesidad de recursos dedicados para el procesamiento, sin embargo los alcances para detectar otras ondas o complejos de las señales creo una amplia oportunidad para futuros desarrollo que en conjunto con registros de señales de distintas afecciones al corazón puede resultar en desarrollar beneficios altamente satisfactorios para futuros trabajos en la predicción de enfermedades cardíacas.

Agradecimientos

Agradecemos al Tecnológico de Estudios Superiores de Villa Guerrero por su apoyo institucional, y a la división de ingeniería electrónica por ser motivador en el desarrollo de investigación. Finalmente, a quienes, con juicio, determinación y reconocimiento, (JDR), ofrecieron palabras de aliento y motivación en los momentos en que más se necesitaban.

Referencias

- Demuth, M. H. (1996). *Neural network design*. eBook, Universidad de Kansas
- Estragó, V. e. (2024). *Revista Uruguaya de Cardiología*. Sociedad Uruguaya de Cardiología, 60.
- Gélvez, N., Díaz, K., Montenegro, C., & Gaona, P. (2022). Estructuración bibliográfica acerca de multiview learning para clasificación. *Vínculos ciencia tecnología y sociedad*, 46.
- Gonzalez, J., Velandia, C., & Nieto, J. (2016, Enero 01). Algoritmos para realce de la onda R del electrocardiograma, capítulo 7, 148-171. DOI:10.15332/dt.inv.2016.00466
- Jiménez, M. (2012, 10 23). Aplicación de redes neuronales artificiales en el procesado versátil. (Tesis) Universitat Politecnica de Valencia.
- Lama, A. (2003, 11 17). *Eindhoven: el hombre y su invento*. Scielo, v.132, n.2.260-264. DOI: 10.4067/S0034-98872004000200018
- M. J. López, A. C. (2010). Computer simulation and method for hearth rhythm control based on ECG signal reference tracking. *WSEAS transactions on systems*, 272.
- Mariel, A. (2014). *Un electrocardiograma de bajo coste* (Tesis). Vasco: Universidad del país vasco.
- Melendez, R. P. (2000). El modelo neuronal de Mcculloch y Pitts interpretación comparativa. XV congreso nacional de instrumentación, Guadalajara.
- Montaño, J. (2002, 9 13). *Redes neuronales artificiales aplicadas al analisis de datos* (Tesis). Universitat de les illes balears
- N. Garcia, A. (2014). Uso de la transformada Wavelet para detección de complejo QRS. *Universidad Nacional del Sur*, 84.
- Olivera. (2014). Desarrollo de un método de detección de arritmias para un dispositivo móvil con sistema de alerta. UNAM.
- Serrano, S. J. (2018, 7). Clasificación automática de registros ECG para la detección de fibrilacion auricular y otros ritmos cardiacos (Tesis). Universidad politecnica de Valencia.
- Tanco, F. (2021, 02). *Redes Neuronales Artificiales*. Universidad tecnológica nacional. Extraído de <https://www.frba.utn.edu.ar/wp-content/uploads/2021/02/RNA.pdf>
- Tejada, J. (2002). Los modelos conexionistas y sus potencialidades en el análisis de datos. *Revista academica avances en medición*. Vol.2. 11-20.
- Tomkins, J. P. (1985). A real time QRS detection algorithm. *IEEE*, 7, 230-236. DOI: 110.1109/TBME.1985.325532
- Willys, J. (2014). *Análisis de señales electroencefalográficas por medio de la transformada* (Tesis). Universidad Autónoma de Baja California. URI:20.500.12930/5097