

Sistema de detección de insuficiencia cardíaca congestiva en señales de ECG a través de aprendizaje máquina

Detection system of congestive heart failure in ECG signals through machine learning

Aldair **Ascencio Salazar**¹, Ángel Humberto **Corral Domínguez**²
Fortunato **Ramírez Arzate**³, José Ricardo **Cárdenas Valdez**⁴

Tecnológico Nacional de México, Instituto Tecnológico de Tijuana, Tijuana, MÉXICO

¹ ORCID: 0009-0003-2082-8518 | aldair.ascencio193@tectijuana.edu.mx

² ORCID: 0000-0003-2009-6161 | angel.corral@tectijuana.edu.mx

³ ORCID: 0009-0009-6107-1826 | fortunato.ramirez@tectijuana.edu.mx

⁴ ORCID: 0000-0002-5437-8215 | jose.cardenas@tectijuana.edu.mx

Recibido 09-09-2024, aceptado 29-10-2024.

Resumen

Las enfermedades cardiovasculares, como la insuficiencia cardíaca congestiva, son una de las principales causas de mortalidad global y deterioran la calidad de vida. El electrocardiograma, eficiente y no invasivo, es esencial para detectar la insuficiencia cardíaca congestiva mediante el análisis de la actividad eléctrica del corazón. Este trabajo integra el aprendizaje automático supervisado en el análisis del electrocardiograma, utilizando modelos de clasificación para distinguir entre señales normales y aquellas afectadas por la insuficiencia cardíaca congestiva. Se desarrolla una plataforma web para apoyar la investigación y el desarrollo de sistemas de telemedicina, facilitando la clasificación de señales de electrocardiograma de manera automática y contribuyendo al diagnóstico médico a distancia, el registro de datos, y las consultas médicas. El presente trabajo demuestra que los modelos utilizados alcanzan una precisión de hasta el 99%, con solo cinco errores en 720 muestras de prueba. No obstante, la generalización del sistema puede verse limitada por la variabilidad en las señales y las condiciones de adquisición. La principal contribución de este trabajo es la investigación de rasgos específicos del electrocardiograma para entrenar modelos de clasificación, ofreciendo técnicas de utilidad para futuras investigaciones en entornos clínicos.

Palabras clave: Análisis de señales, aprendizaje máquina, clasificación, electrocardiograma, plataforma web.

Abstract

Cardiovascular diseases, such as congestive heart failure, are leading causes of global mortality and deteriorate quality of life. The electrocardiogram, efficient and non-invasive, is essential for detecting congestive heart failure by analyzing the heart's electrical activity. This work integrates supervised machine learning into electrocardiogram analysis, using classification models to distinguish between normal signals and those affected by congestive heart failure. A web platform is developed to support research and the development of Telemedicine systems, facilitating the automated classification of electrocardiogram signals and contributing to remote medical diagnosis, data recording, and medical consultations. The present study demonstrates that the models used achieve up to 99% accuracy, with only five errors in 720 test samples. However, the system's generalization may be limited by signal variability and acquisition conditions. The main contribution of this work is the investigation of specific electrocardiogram features to train classification models, offering useful techniques for future research in clinical settings.

Index terms: Classification, electrocardiogram, signal analysis, machine learning, web platform.

GLOSARIO

- CSV: Valores Separados por Comas (*Comma-Separated Values*).
- ECG: Electrocardiograma.
- HTTP: Protocolo de Transferencia de Hipertexto (*Hypertext Transfer Protocol*).
- ICC: Insuficiencia Cardíaca Congestiva.
- K-NN: K-Vecinos más cercanos (*K-Nearest Neighbors*).
- PDF: Función de Densidad de Probabilidad (*Probability Density Function*).
- ResNet: Redes Neuronales Residuales.
- RN: Redes Neuronales.
- SFTP: Protocolo Seguro de Transferencia de Archivos (*Secure File Transfer Protocol*).
- SVM: Máquinas de Vectores de Soporte (*Support Vector Machines*).
- VM: Máquina Virtual.
- VPP: Valor Predictivo Positivo.
- WFDB: *Python Waveform-Database*.

I. INTRODUCCIÓN

Las enfermedades cardiovasculares, incluida la ICC, son una de las principales causas de mortalidad y afectan significativamente la calidad de vida. El ECG, eficiente y no invasivo, es esencial para detectar la ICC mediante el análisis de la actividad eléctrica del corazón [1]. Ante las limitaciones del diagnóstico empírico, el cual depende de la interpretación subjetiva del médico, la incorporación del aprendizaje automático en el diagnóstico de la ICC mediante señales de ECG surge como una solución innovadora. El presente trabajo aplica técnicas de aprendizaje automático supervisado para analizar patrones en señales de ECG, ofreciendo un sistema de detección que puede asistir tanto en el diagnóstico como en la formación de especialistas y médicos en entrenamiento.

Es importante señalar que este trabajo representa una prueba de concepto y no ha sido evaluado en un entorno clínico real, por lo que no se puede afirmar que optimice el proceso de diagnóstico. Los resultados obtenidos muestran el potencial del sistema, pero se requieren evaluaciones adicionales para validar su efectividad en entornos clínicos.

La problemática central que aborda este trabajo es la falta de procesos automáticos y métodos tecnológicos para interpretar señales de ECG en el diagnóstico de ICC. Desde una perspectiva de ingeniería, es crucial aplicar métodos estadísticos y de análisis de datos para descubrir patrones y características significativas en las señales de ECG, adaptándose a la variabilidad individual de los pacientes y a las condiciones de adquisición de las señales. La solución propuesta es un sistema que identifica características de la ICC mediante aprendizaje automático, con el objetivo de ofrecer mediciones y análisis más objetivos para la detección de la enfermedad y proporcionar soporte tecnológico en la toma de decisiones de estudiantes y médicos generales.

En este artículo, el contenido se estructura de la siguiente manera: en la sección II, "Estado del Arte y Comparación con Otros Métodos", se discuten investigaciones previas y las metodologías empleadas para el análisis de señales de ECG, destacando las diferencias y similitudes con el presente trabajo. La sección III, "Teoría de Respaldo", ofrece una explicación detallada de las señales de ECG, la ICC y las técnicas de aprendizaje automático utilizadas en este trabajo, incluyendo SVM, K-NN y RN. En la sección IV, "Desarrollo", se describe el proceso técnico de extracción de características de las señales de ECG y la creación de la plataforma web para la interacción con el sistema de clasificación. La sección V, "Resultados", presenta las

métricas de desempeño de los modelos propuestos y la evaluación de los rasgos extraídos. Finalmente, en la sección VI, "Conclusiones", se resumen los hallazgos principales, se discuten las limitaciones del trabajo y se sugieren direcciones futuras para la investigación.

II. ESTADO DEL ARTE Y COMPARACIÓN CON OTROS MÉTODOS

La aplicación de modelos de aprendizaje automático se ha extendido a diversos campos de la investigación científica debido a sus eficientes funciones, como la predicción de casos y el análisis de datos. Estas técnicas se han utilizado para la detección de enfermedades a través del análisis de bioseñales del cuerpo humano. Un área donde esta aplicación ha sido particularmente relevante es en el análisis de señales de ECG para la identificación de la ICC.

Dentro de esta área, el trabajo [2] destaca por la aplicación de RN recurrentes en señales de ECG con ICC. Esta investigación se enfoca en el preprocesamiento y normalización de las señales de ECG, utilizando segmentos de 1 a 4 segundos para entrenar el modelo. Los resultados muestran una notable capacidad de las RN para detectar características relevantes de la ICC en segmentos cortos, demostrando su eficiencia con muestras de tamaño limitado. A diferencia de este enfoque, el presente trabajo emplea técnicas adicionales de análisis, como la extracción de características relacionadas con la entropía, diferencias morfológicas en la señal y análisis de la energía en diferentes bandas de frecuencia. Además, se exploran y comparan múltiples modelos de aprendizaje automático, como SVM y K-NN, ampliando las estrategias para analizar segmentos de señales de ECG y evaluando su desempeño en diferentes condiciones.

Por otro lado, la investigación [3] utiliza ResNet con una arquitectura multi-escala para analizar las señales de ECG a diferentes niveles de detalle. Este enfoque permite la identificación precisa de los indicadores de ICC, resaltando la importancia de capturar una amplia variedad de características. Aunque este método resulta efectivo en la detección de ICC, el enfoque aquí presentado se diferencia al ampliar las técnicas de extracción y análisis de rasgos. Además, este trabajo propone métodos para validar la efectividad de los rasgos extraídos, no solo mediante modelos neuronales, sino también a través de otras técnicas de clasificación. Adicionalmente, se desarrolla una plataforma web que incluye un sistema de interacción con el usuario para facilitar la clasificación de señales.

En la misma línea, los trabajos [4] y [5] presentan metodologías relevantes para el desarrollo de sistemas de detección de ICC mediante el análisis de señales de ECG. Ambos estudios obtienen resultados óptimos al implementar modelos de clasificación, incluyendo SVM y K-NN, con un análisis de rasgos tanto en el dominio del tiempo como en el de la frecuencia, usando técnicas como *wavelets* para obtener características como la entropía de la señal. Estos métodos sientan las bases para la identificación de rasgos distintivos en las señales de ECG, tanto en casos de ICC como en casos normales. El presente trabajo se basa en estos estudios para identificar rasgos importantes y propone nuevas formas de extracción de rasgos, como la combinación de análisis morfológico y energético. Además, se evalúa la utilidad de estos rasgos mediante pruebas controladas, demostrando su efectividad o limitaciones en la clasificación de señales de ECG con ICC.

Este proyecto se distingue de las investigaciones anteriores principalmente por la investigación de más rasgos característicos que se pueden extraer de las señales de ECG de pacientes con ICC. Esto permite clasificar, a través de modelos de aprendizaje automático, las señales como indicativas de la enfermedad o sanas, contribuyendo al campo de la medicina con nuevas perspectivas de análisis. Además, se enfoca en la implementación de una plataforma web funcional, lo que no se aborda en los trabajos citados. Mientras que las investigaciones previas se centran en el análisis técnico y procesamiento de señales de ECG, el desarrollo de la plataforma web en este trabajo permite la interacción directa de los usuarios con el sistema. Esto puede facilitar la clasificación de señales de manera práctica y abre la posibilidad de integrar la tecnología en aplicaciones clínicas y educativas, incrementando su potencial de impacto en la práctica médica real.

III. TEORÍA DE RESPALDO

Entender el comportamiento de las señales de ECG es crucial para identificar los indicadores de ICC presentes en estas señales. Las señales de ECG constituyen la base de datos principal utilizada en este trabajo para el análisis y procesamiento necesarios para desarrollar el sistema capaz de detectar esta enfermedad.

El análisis comienza estableciendo las características normales del ECG y del ritmo sinusal, lo cual permite distinguir entre un funcionamiento cardíaco saludable y posibles anomalías. El ECG es un registro de los potenciales eléctricos originados por la actividad cardíaca. La ICC provoca cambios significativos en las señales de ECG, como alteraciones en la morfología del complejo QRS, variaciones en la onda T, y la presencia de ondas Q patológicas. Estos cambios indican condiciones como el agrandamiento ventricular y la hipertrofia, comúnmente asociadas con estados avanzados de la enfermedad [6].

Además, la presencia de arritmias, evidenciada por irregularidades en el ritmo sinusal, puede ser indicativa de ICC. La frecuencia cardíaca puede aumentar como un mecanismo compensatorio o presentar ritmos anormales que sugieren un compromiso en la capacidad del corazón para mantener una circulación adecuada [7][8].

Este trabajo utiliza registros de pacientes con ICC en clases III-IV, obtenidos del repositorio de *PhysioNet* [9][10]. Estas señales de ECG provienen de pacientes de tercera edad con severas limitaciones en su capacidad para realizar actividades físicas, experimentando síntomas como fatiga, palpitaciones y disnea incluso en reposo. También se emplean señales de ritmo sinusal normal del repositorio *PhysioNet* [11] para la distinción entre las dos clases (señales de ECG normales y afectadas por la enfermedad).

A. Aprendizaje máquina

El aprendizaje máquina juega un papel crucial en la identificación y clasificación de señales de ECG asociadas con la ICC, permitiendo el desarrollo de sistemas de diagnóstico avanzados. Para la integración de esta tecnología, una etapa importante es la adquisición y el preprocesamiento de las señales de ECG para eliminar ruido y estandarizarlas, preparándolas para el análisis [12]. Se realiza la extracción de características, identificando rasgos significativos que diferencian condiciones saludables como las explicadas en [6] de las patológicas, resaltando los aspectos más relevantes relacionados con la ICC.

Al aplicar los modelos predictivos de aprendizaje máquina y ser entrenados con datos históricos extraídos de las señales, estos aprenden a identificar patrones y hacer predicciones o clasificaciones sobre nuevos datos [13]. En este trabajo, los modelos se entrenan para distinguir entre señales de ECG normales y aquellas alteradas por la ICC. Los modelos seleccionados para la clasificación de la enfermedad en este trabajo son SVM, K-NN y RN.

B. Máquinas de Vectores de Soporte

SVM es un algoritmo de aprendizaje supervisado utilizado en problemas de clasificación y regresión, que incluye aplicaciones en medicina, procesamiento del lenguaje natural y reconocimiento de imágenes y voz. Su objetivo es encontrar un hiperplano que separe dos clases de datos con el mayor margen posible. En problemas prácticos, SVM maximiza el margen permitiendo algunas clasificaciones erróneas, lo que ha demostrado ser eficaz en la detección de insuficiencia cardíaca a partir de señales de ECG [14].

Los vectores de soporte son un subconjunto de las observaciones de entrenamiento que determinan la ubicación del hiperplano. Aunque SVM está formulado para clasificación binaria, los problemas multiclase se abordan mediante una serie de problemas binarios, como se ha aplicado en la clasificación de arritmias mediante señales de ECG [15]. Para la detección de la ICC en este trabajo, SVM aprovecha las alteraciones características en la

señal de ECG, como la amplitud de la onda T y la longitud del complejo QRS, proporcionando parámetros necesarios para diferenciar y clasificar las señales.

C. *K-Vecinos más cercanos*

El algoritmo KNN es un método de clasificación supervisado que no depende de parámetros específicos y se basa en la proximidad de los datos para realizar predicciones o clasificaciones. Parte de la premisa de que las observaciones con características similares tienden a estar ubicadas cerca unas de otras [16].

↳ En los problemas de clasificación, KNN asigna una etiqueta de clase a un nuevo punto de datos basándose en el voto mayoritario de sus k vecinos más cercanos en el conjunto de entrenamiento. La selección del valor de k , que representa el número de vecinos considerados, es crucial para la precisión del modelo. Un valor de k bajo puede hacer que el modelo sea sensible al ruido en los datos, mientras que un valor de k alto puede diluir las influencias locales importantes [17][18]. En el contexto de la detección de ICC utilizando KNN, la proximidad entre las muestras de ECG permite que el modelo distinga con precisión entre señales de ECG normales y aquellas que indican ICC [19].

D. *Redes neuronales*

Las RN son modelos inspirados en el cerebro humano, utilizados para tareas de clasificación y regresión en el aprendizaje automático. Están compuestas por capas de neuronas interconectadas que procesan información a través de funciones de activación. Este diseño permite a las RN aprender representaciones complejas y manejar problemas no lineales eficientemente [20].

En el contexto de señales de ECG, las RN se utilizan para detectar y clasificar anomalías cardíacas, como la ICC. Al entrenar las RN con grandes volúmenes de datos de ECG, pueden identificar patrones y características relevantes que indican enfermedades cardíacas. Esta capacidad de aprender y generalizar a partir de datos complejos las hace herramientas valiosas en la mejora de diagnósticos clínicos [21].

La selección y aplicación de los tres modelos (SVM, K-NN y RN) proporcionan robustez al sistema, permitiendo interpretar y clasificar eficazmente las señales de ECG. El usuario puede elegir el modelo con el que desea clasificar la señal de entrada, asegurando un respaldo más sólido en los resultados mediante comparaciones entre los diferentes métodos de clasificación.

E. *Tecnologías web*

En el desarrollo de este trabajo, se aprovechan las tecnologías web y los servicios en la nube de *Google Cloud* para crear una plataforma en línea accesible. Se utiliza una VM con *Ubuntu*, alojada en *Google Cloud*, que sirve como núcleo del servidor web. Esta VM gestiona la base de datos, credenciales y recursos necesarios para el sistema de clasificación, proporcionando flexibilidad en la configuración y aislamiento de procesos. Además, los servicios en la nube permiten el acceso a recursos computacionales bajo demanda, ofreciendo una solución escalable y eficiente para la gestión y actualización remota del contenido web desde cualquier ubicación.

F. *Tecnologías de vanguardia*

Las tecnologías y modelos de aprendizaje automático utilizados en este trabajo, como SVM, K-NN, y RN, se consideran métodos avanzados y ampliamente aplicados en el análisis de señales biomédicas, incluyendo las señales de ECG. Esto se respalda con los diversos estudios realizados en este campo, como los que se mencionan en la sección II “Estado del Arte”. La implementación de una plataforma web basada en servicios en la nube de *Google Cloud* también refleja la vanguardia en la gestión y procesamiento de datos a gran escala, permitiendo un acceso remoto y eficiente a los recursos computacionales. Al combinar estas tecnologías de última generación, este proyecto ofrece un enfoque integral y moderno para la detección de la ICC, alineándose con las tendencias actuales en el campo de la bioingeniería y la medicina digital.

IV. DESARROLLO

En esta sección se redacta el desarrollo para la creación del sistema de detección de la ICC. Se explica el procedimiento técnico del proceso en la extracción de características de las señales de ECG de señales normales y aquellas afectadas por la enfermedad, además del desarrollo de la plataforma web para la interacción con el sistema. En la Figura 1 se ilustra el diagrama del marco de trabajo de aprendizaje automático seguido en este trabajo. A lo largo del documento se explica cada uno de los elementos que lo conforma.

6

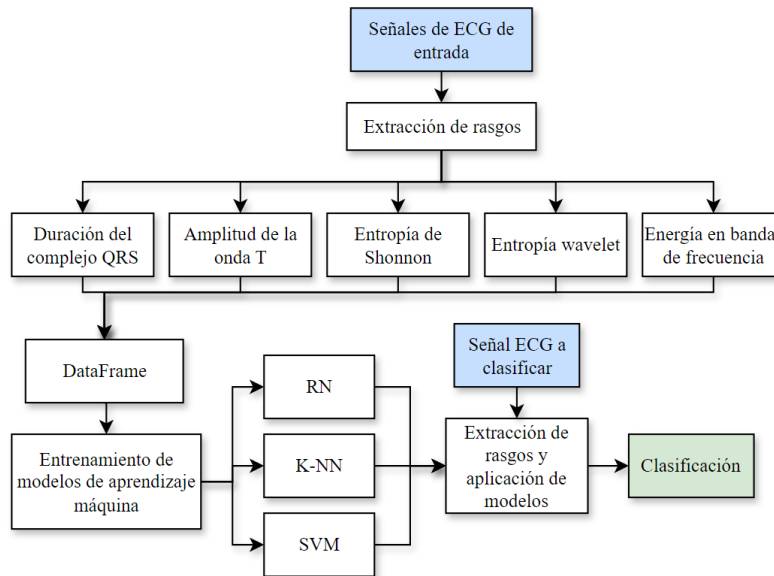


Fig. 1. Diagrama del marco de trabajo de aprendizaje automático.

A. Extracción de rasgos

En el desarrollo del sistema de detección, la extracción de rasgos de las señales de ECG y la implementación del aprendizaje máquina, incluyendo el entrenamiento de los modelos, se llevan a cabo utilizando el lenguaje de programación *Python*. El primer paso en el desarrollo del sistema implica la extracción de rasgos característicos de las señales de ECG. Este proceso se realiza tanto para señales de individuos sanos con ritmo sinusal normal, como para señales de pacientes diagnosticados con ICC de grado III-IV. Inicialmente, es necesario descargar estas señales desde los bancos de datos. Las señales seleccionadas, tanto patológicas como normales, se almacenan en una carpeta para facilitar el análisis posterior.

Las señales de ECG obtenidas de *PhysioNet* están codificadas en un formato binario para optimizar el almacenamiento. Para procesar y analizar estas señales, se utiliza la librería *WFDB*. Esta herramienta es esencial para la manipulación de los datos de ECG, ya que permite leer, escribir y procesar eficientemente las señales junto con sus anotaciones médicas. Tras importar la biblioteca *WFDB*, es posible obtener información de las señales contenidas en los archivos tipo *.dat*, como el número de señales disponibles, la frecuencia de muestreo, el nombre de las señales y su longitud.

Para mejorar la calidad de las señales de ECG, se aplican diversos filtros diseñados para eliminar el ruido y conservar las frecuencias relevantes para el análisis. El filtro *Notch* se utiliza específicamente para eliminar el ruido de la línea eléctrica, generalmente a 50 o 60 Hz. Los filtros pasa alta y pasa baja se configuran para mantener un rango de frecuencias útil, típicamente entre 0.5 Hz y 50 Hz, que es donde se encuentran la mayoría

de los componentes significativos de la señal de ECG. Este proceso requiere de las librerías de *scipy.signal* para aplicar los filtros *Notch*, pasa alta y pasa baja. La función *filtfilt* se utiliza específicamente para asegurar que la fase de la señal no se altere durante el filtrado. En la Figura 2, se ilustra parte de la señal de ECG de un paciente con ICC antes de aplicar los filtros seleccionados, mientras que en la Figura 3 se muestra un ejemplo del suavizado del ruido, donde las mínimas distorsiones presentes en la serie se han reducido.




Fig. 2. Señal ECG original sin filtros.




Fig. 3. Aplicación de filtros a señal ECG.

Una vez filtrada la señal de ECG, el siguiente paso consiste en procesar las anotaciones médicas asociadas a los datos. Se seleccionan las anotaciones marcadas con el símbolo *N*, que indican cada latido y están centradas en el pico R del ECG. Este enfoque permite focalizar el análisis en cada latido y en el complejo completo PQRST. Se aplica una ventana de análisis alrededor de cada anotación *N* para garantizar que se capturen todos los rasgos relevantes del latido. En la Figura 4, se ilustra un ejemplo de la aplicación de la ventana de análisis en el ECG para la extracción de rasgos, así como la ubicación de las anotaciones médicas.




Fig. 4. ECG con ventana de análisis y anotaciones.

Con los picos R de la señal identificados gracias a las anotaciones y la aplicación de la ventana de análisis centrada en cada uno de ellos, se utilizan ciclos para iterar a través de estos puntos en la señal. Para cada pico R, se establece la ventana de análisis que define el segmento específico del latido a examinar. Este enfoque segmentado permite que el análisis se centre solo en la sección abarcada, evitando el procesamiento innecesario de toda la serie fuera de la ventana y acelerando la extracción de rasgos. Dentro de cada segmento definido, se busca confirmar la presencia del pico R, que valida el segmento. Si se detecta un pico R, se procede a extraer los rasgos característicos del latido en cuestión.

B. Duración del complejo QRS

∞

El primer rasgo es la duración del complejo QRS. Se selecciona esta característica debido a que las señales de pacientes con ICC presentan una mayor duración y amplitud del complejo QRS en comparación con las señales normales. La diferencia en la duración del complejo QRS, medida en segundos, es un rasgo significativo para la clasificación.

Para calcular la duración del complejo QRS, se identifica la amplitud del pico R en el segmento de la señal y se define un umbral basado en el 10% de esta amplitud. Se procede a buscar hacia atrás desde el pico R para encontrar el inicio del complejo QRS y hacia adelante para encontrar el final del complejo. Por lo tanto, la duración del complejo QRS se calcula en muestras y luego se convierte a segundos. En la Figura 5 y Figura 6 se ilustra la diferencia de duración entre señales con ICC y normales.




Fig. 5. Duración del complejo QRS, segmento ECG con ICC.




Fig. 6. Duración del complejo QRS, segmento ECG normal.

C. Amplitud de la onda T

El siguiente rasgo es la amplitud de la onda T, que se diferencia entre señales normales y aquellas afectadas por ICC. Este rasgo se selecciona debido a que, en los registros de pacientes con ICC, la onda T presenta una amplitud negativa, mientras que en las señales normales la amplitud es positiva. La diferencia de signo entre las amplitudes permite que este rasgo sea un discriminador eficaz, especialmente en el modelo SVM, que aprovecha estas diferencias para mejorar la clasificación.

9

Para calcular la amplitud de la onda T, se define un rango de búsqueda específico después del final del complejo QRS. En el código, se establece el rango de búsqueda entre 0.2 y 0.4 segundos después del complejo QRS. Para las señales con ICC, el proceso implica invertir la señal en la ventana para detectar los valles como picos. Luego, se buscan picos en la señal invertida, que corresponden a los valles en la señal original. Se selecciona el valle más profundo, identificado como un pico en la señal invertida, para determinar la amplitud de la onda T. Para las señales normales se busca directamente el pico positivo de la onda T sin invertir la señal. Esto se hace buscando picos en la señal original dentro del mismo rango de búsqueda. Se selecciona el más prominente para determinar la amplitud de la onda T. En la Figura 7 y Figura 8 se ilustra esta diferencia entre amplitudes en cada caso.




Fig. 7. Amplitud onda T, segmento ECG con ICC.




Fig. 8. Amplitud onda T, segmento ECG normal.

D. Entropía de Shannon

Al buscar rasgos distintivos que representen características únicas de cada tipo de señal, se exploraron diversas técnicas y métodos. Uno de los rasgos que muestra resultados significativos y una clara separación entre clases es la entropía de *Shannon*.

Para calcular la entropía de *Shannon* de la señal de ECG, primero se ajusta la señal para que todos los valores sean positivos. Después, la señal se normaliza dividiendo cada valor por la suma total de la señal, de esta manera se asegura que los valores formen una distribución de probabilidad. Finalmente, se aplica la función de entropía de *Shannon* de la biblioteca *scipy.stats*, que mide la cantidad de incertidumbre presente en la señal. La entropía de *Shannon* se define matemáticamente como la ecuación (1):

$$H(P) = - \sum_i p_i \log(p_i) \quad (1)$$

donde p_i son las probabilidades de los diferentes eventos en la distribución P [22]. Este rasgo es útil porque las señales de ECG de pacientes con ICC suelen mostrar patrones más complejos y variables, lo que se refleja en una entropía más alta en comparación con las señales de individuos sanos.

10

E. Entropía wavelet

La entropía *wavelet* es otro de los rasgos seleccionados debido a las diferencias de resultados entre las dos clases. Para calcular la entropía *wavelet* de la señal de ECG, se descompone el segmento de la señal al utilizar la función *wavedec* de la biblioteca *PyWavelets*, que aplica la transformada *wavelet* discreta a la señal. Los coeficientes resultantes se utilizan para calcular la energía en cada nivel de detalle. Esta energía se normaliza respecto al total de energía, y se aplica la fórmula de entropía de *Shannon* a la distribución de energía para obtener la entropía *wavelet*.

La entropía resultante proporciona una medida de la complejidad de la señal de ECG, permitiendo diferenciar entre señales normales y patológicas, como se ha demostrado en trabajos previos [23]. Este rasgo es útil porque las señales de ECG de pacientes con ICC tienden a tener una distribución de energía más dispersa en los coeficientes *wavelet*, reflejando una mayor complejidad y variabilidad en comparación con las señales de individuos sanos.

F. Cálculo de la energía en bandas de frecuencia

El quinto rasgo extraído para el sistema de clasificación es la suma de la energía en las bandas de frecuencia. Este rasgo se basa en la distribución de energía dentro de ciertas bandas de frecuencia de la señal de ECG, ya que proporciona información sobre las características de la señal y permite diferenciar entre señales sanas y aquellas con ICC. Para calcular la energía de banda, se utiliza la transformada *wavelet* continua, que permite analizar la señal en diferentes escalas y frecuencias. Esta técnica de análisis, que utiliza *wavelets* y energía, ha sido empleada en trabajos para la clasificación de señales ECG, como se demuestra en el trabajo [24].

Se define un rango de escalas de 1 a 128 y se aplica la transformada *wavelet* continua a la señal de ECG segmentada utilizando la *wavelet cmor*. Esto produce un conjunto de coeficientes y frecuencias que representan la señal en diferentes niveles de detalle. Luego, se calcula la energía de banda sumando los cuadrados de los coeficientes absolutos dentro del rango de 1 a 127. Esta suma representa la energía contenida en esas bandas de frecuencia específicas y proporciona el valor utilizado para distinguir entre señales de ECG sanas y señales con ICC.

En la Figura 9 y Figura 10 se ilustra la diferencia en la distribución de energía entre los dos tipos de señales. El segmento afectado por la enfermedad presenta una mayor distribución de energía en los rangos de frecuencia, indicado en color rojo su magnitud. En contraste, el escalograma de las señales normales muestra una distribución de energía más concentrada y de menor magnitud en los mismos rangos de frecuencia. La escala de colores representa la magnitud de la energía, donde los colores más cálidos (rojo y amarillo) indican una mayor magnitud, mientras que los colores más fríos (verde y azul) representan una menor magnitud.




Fig. 9. Energía en bandas de frecuencia, segmento ECG con ICC.




Fig. 10. Energía en bandas de frecuencia, segmento ECG normal.

G. Preparación y etiquetado de datos

La preparación y etiquetado de datos es una fase crucial en el desarrollo de sistemas de clasificación basados en aprendizaje automático, ya que garantiza la calidad y relevancia de la información utilizada para el entrenamiento. En este trabajo, se obtuvieron un total de 2400 muestras de señales de ECG, que se dividieron equitativamente en dos categorías: el 50% corresponde a segmentos de ICC, etiquetados con el número 1, mientras que el otro 50% corresponde a señales de ECG normales, etiquetadas como 0. Este balance en las clases es fundamental para evitar sesgos en el entrenamiento de los modelos, asegurando que ambos tipos de señales sean considerados de manera justa.

Después de etiquetar los datos, estos se almacenaron en un *DataFrame* y se guardaron en un archivo CSV, un formato adecuado para el manejo y procesamiento eficiente de grandes volúmenes de datos. Este conjunto de datos etiquetados es esencial para el entrenamiento y validación de los modelos de aprendizaje automático utilizados en este trabajo, proporcionando la base necesaria para que los algoritmos puedan aprender a diferenciar entre señales normales y patológicas con precisión.

H. Red neuronal

Para el desarrollo del modelo de red neuronal, se utiliza una arquitectura secuencial en la que se incorporaron varias capas densas. La entrada del modelo consiste en los rasgos extraídos de las señales de ECG. La red neuronal está compuesta por la capa de entrada que recibe estos rasgos, seguida de tres capas densas con activaciones *leaky_relu* y tamaños de 1024, 1024 y 512 neuronas, respectivamente. La capa de salida consta de una neurona con activación *sigmoid* para realizar la clasificación binaria. La Figura 11 ilustra esta arquitectura de la red neuronal.

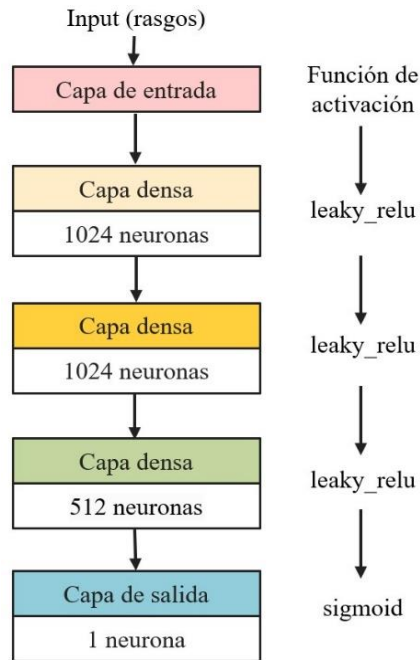


Fig. 11. Arquitectura de red neuronal.

Para el entrenamiento del modelo, se utilizó el optimizador *Adamax* con una tasa de aprendizaje inicial de 0.005 y la función de pérdida de entropía cruzada binaria. Los datos se dividieron en conjuntos de entrenamiento y prueba en una relación del 70/30. El modelo se entrenó durante 50 épocas, con un tamaño de lote de 32, utilizando *callbacks* como *EarlyStopping* y *ReduceLRonPlateau* para prevenir el sobreajuste y ajustar la tasa de aprendizaje en función del rendimiento del modelo.

1. Plataforma web

El desarrollo de la plataforma web facilita el acceso al sistema de detección de ICC en señales de ECG mediante una interfaz en línea. Los usuarios pueden cargar las señales a analizar y recibir los resultados sin necesidad de instalar software adicional o ejecutar códigos localmente. Para esta plataforma, se utilizan los servicios de nube y VM. El esquema general de la plataforma web se ilustra en la Figura 12, incluye la integración de servicios en la nube para la gestión de recursos esenciales como la base de datos y el servidor. Se emplea SFTP para la carga y actualización de archivos, y HTTP para la comunicación eficaz entre el servidor y el navegador, asegurando el funcionamiento adecuado de la plataforma. Los modelos entrenados y los recursos necesarios para la ejecución del sistema de clasificación se alojan en la VM, permitiendo el funcionamiento de la plataforma.




Fig. 12. Esquema general para el desarrollo de la plataforma web.

V. RESULTADOS

Para evaluar la utilidad de los rasgos extraídos en la clasificación binaria, se utilizaron las PDF. Las gráficas de las PDF muestran la distribución de cada rasgo para las dos clases, lo que permite visualizar la separación entre ellas. De la Figura 13 a la Figura 15 se observa que los cinco rasgos presentan distribuciones distintas para cada clase. Las señales normales (clase 0) y las señales con ICC (clase 1) tienen picos de densidad en diferentes rangos, indicando diferencias significativas en las características de las señales.

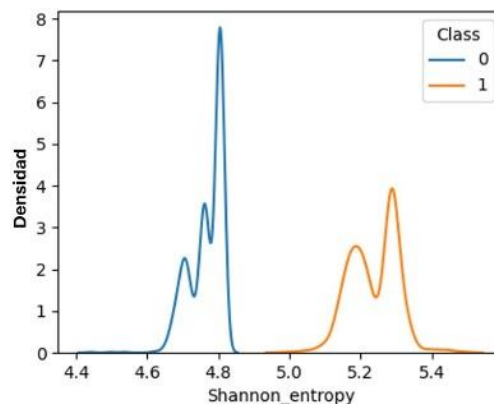


Fig. 13. Entropía de Shannon, PDF.




Fig. 14. Duración complejo QRS y amplitud onda T, PDFs.




Fig. 15. Entropía wavelet y energía, PDF.

La longitud del complejo QRS muestra que las señales normales tienden a tener una distribución más concentrada en valores más bajos, mientras que las señales con ICC se distribuyen en un rango más amplio. La amplitud de la onda T presenta una clara separación, con las señales normales mostrando amplitudes positivas y las señales con ICC amplitudes negativas. La entropía de *Shannon* y la entropía *wavelet* también muestran diferencias en la complejidad y distribución de energía de las señales, con picos en diferentes rangos para cada clase. La suma de la energía en las bandas de frecuencia revela que las señales normales tienden a concentrarse en un rango específico de energía, mientras que las señales con ICC tienen una distribución más dispersa.

Estas diferencias en las distribuciones de los rasgos entre las dos clases demuestran que los rasgos extraídos son efectivos para separar las señales normales de las afectadas por ICC. La separación observada en las gráficas de PDF proporciona una base sólida para la clasificación binaria en los modelos de aprendizaje máquina, contribuyendo a la precisión en la detección de la ICC.

A. Métricas de rendimiento de SMV

El entrenamiento del modelo SVM se realiza utilizando los datos extraídos de las señales de ECG, divididos en conjuntos de entrenamiento y prueba en una relación de 70/30. Este modelo muestra un elevado rendimiento en la clasificación de las señales de ECG, logrando una precisión del 100% tanto en el conjunto de prueba como en las predicciones. La matriz de confusión de la Figura 16, indica que las 720 muestras de prueba fueron clasificadas correctamente, con 367 muestras normales y 353 muestras de ICC sin errores de clasificación. El VPP que es la proporción de verdaderos positivos entre todas las muestras que el modelo clasifica como positivas da como resultado el 100%. Los índices de evaluación en la Tabla 1 revelan una sensibilidad y especificidad de 1.0 en ambas clases. Estos resultados confirman la eficacia del modelo SVM para la clasificación de señales de ECG, proporcionando un soporte para la detección de ICC.

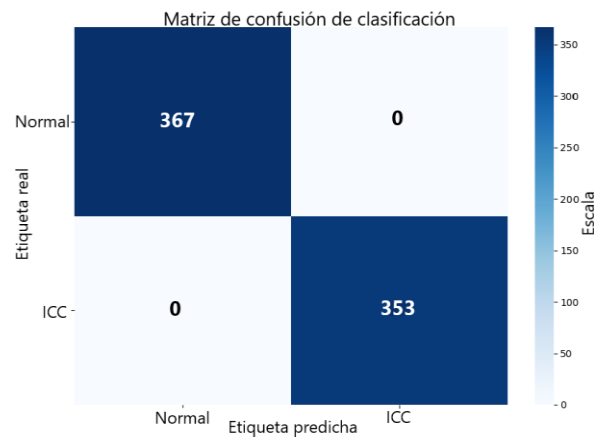


Fig. 16. Matriz de confusión SVM.

TABLA 1
ÍNDICES DE EVALUACIÓN SVM

	Índices de clase 0 (normal)	Índices de clase 1 (ICC)
Sensibilidad	--	1.0
Especificidad	1.0	--
Prevalencia	0.51	0.49

B. Métricas de rendimiento de K-NN

El modelo K-NN también demuestra una alta precisión en la clasificación, con una exactitud del 99% tanto en la prueba del modelo como en la predicción. La matriz de confusión en la Figura 17 indica que, de las 720 muestras de prueba, solo se cometieron cuatro errores de clasificación. El VPP es del 100%. Los índices de evaluación se muestran en la Tabla 2 reflejando una alta sensibilidad y especificidad en ambas clases.




Fig. 17. Matriz de confusión K-NN.

TABLA 2
ÍNDICES DE EVALUACIÓN SVM

	Índices de clase 0 (normal)	Índices de clase 1 (ICC)
Sensibilidad	--	0.98
Especificidad	1.0	--
Prevalencia	0.50	0.49

C. Métricas de rendimiento de RN

El modelo de RN muestra una precisión del 99% durante la prueba, siendo efectivo para la clasificación de las señales. La matriz de confusión de la Figura 18 revela que la red neuronal clasifica correctamente la mayoría de las muestras, registrando solo cinco errores en un total de 720 muestras. Esto también genera un VPP de 100%. Los índices de evaluación, incluyendo sensibilidad y especificidad, muestran valores cercanos a 1.0 para ambas clases. Los resultados detallados se encuentran en la Tabla 3.




Fig. 18. Matriz de confusión RN.

TABLA 3
ÍNDICES DE EVALUACIÓN RN

	Índices de clase 0 (normal)	Índices de clase 1 (ICC)
Sensibilidad	--	0.98
Especificidad	1.0	--
Prevalencia	0.52	0.47

17

Para el modelo de RN, la Figura 19 ilustra la gráfica de exactitud durante las épocas de entrenamiento y validación. Se observa una tendencia estable en la precisión hasta la época 30, tanto para los datos de entrenamiento como de validación. Sin embargo, se destaca un pico notable que experimenta una caída brusca alrededor de la época 30. Esta disminución podría señalar un problema temporal durante el entrenamiento, como variabilidad en los datos de entrada o un ajuste del modelo. A pesar de esta caída, el modelo recupera rápidamente su precisión en las siguientes épocas, lo que sugiere una buena capacidad para ajustar y mejorar su rendimiento después de un breve desajuste. Este comportamiento resalta la robustez del modelo RN para mantener una alta exactitud en la clasificación de señales de ECG a lo largo del tiempo.

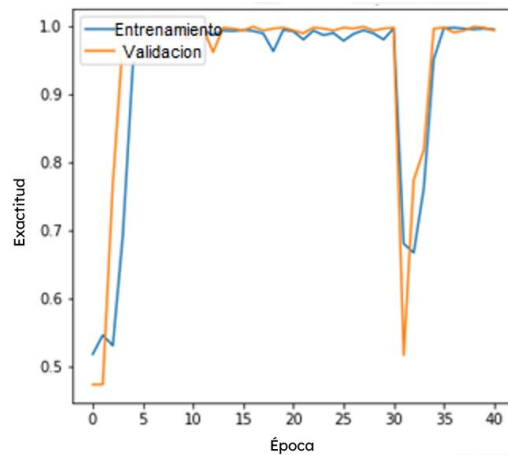


Fig. 19. Exactitud del modelo durante el entrenamiento.

D. Plataforma web resultante

La página principal del sitio web es donde se encuentra la interfaz para la clasificación de las señales de ECG. En la Figura 20 se ilustra el diseño de esta página. Esta interfaz contiene los elementos principales para la interacción del usuario con el sistema. A continuación, se describen los elementos y el flujo de uso:

1. Campos para seleccionar los archivos de las señales de ECG a analizar. El usuario puede hacer clic para abrir el navegador de archivos, o simplemente arrastrar los elementos dentro del área designada.
2. Botón para subir los archivos seleccionados a la nube, preparándolos para el análisis.
3. Botones para seleccionar el modelo de aprendizaje máquina con el que se desea clasificar el ECG (SVM, KNN o RN).
4. Botón para iniciar el análisis de la señal una vez que se ha seleccionado el modelo deseado.
5. Gráfica desplazable que muestra el ECG de los datos subidos por el usuario, permitiendo una visualización clara de la señal.
6. Indicadores del resultado de la clasificación, que muestran si la señal analizada es normal o indicativa de ICC.
7. Información de la señal de ECG analizada.

17

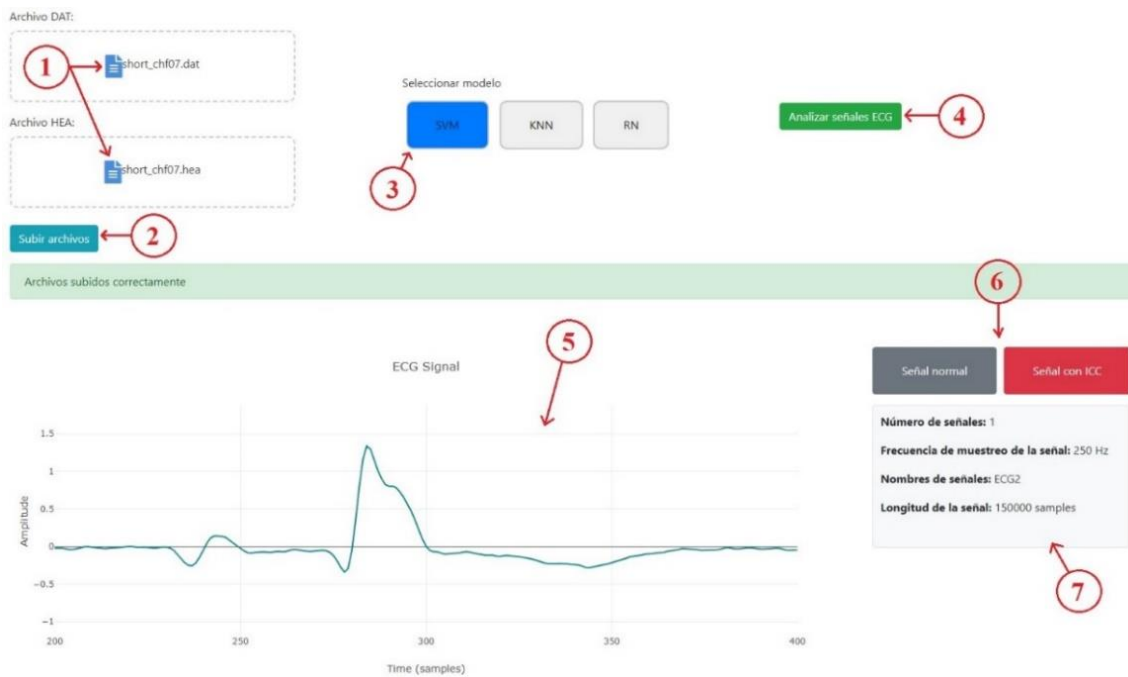


Fig. 20. Plataforma web para la clasificación de la señal de ECG.

VI. CONCLUSIONES

Este trabajo ha demostrado la viabilidad de integrar técnicas de aprendizaje automático en el análisis de señales de ECG para el apoyo en el diagnóstico de la ICC. La plataforma web desarrollada facilita la clasificación de señales, automatizando el proceso de análisis, lo que podría beneficiar tanto a médicos como a pacientes en entornos de telemedicina. Aunque los resultados son prometedores, se reconoce que este sistema aún está en fase de investigación y futuras evaluaciones en entornos clínicos serán necesarias para validar su efectividad y potencial optimización en el diagnóstico de ICC.

Los modelos de aprendizaje automático SVM, K-NN y RN mostraron una alta eficacia en la clasificación de señales de ECG en el conjunto de datos utilizado. En particular, la RN alcanzó una precisión del 99% en la detección de ICC, con solo cinco errores en 720 muestras de prueba. Los índices de evaluación para SVM y K-NN también fueron altos, con sensibilidades y especificidades cercanas al 100%.

Los rasgos extraídos, como la duración del complejo QRS, la amplitud de la onda T, la entropía de *Shannon*, la entropía *wavelet* y la energía en bandas de frecuencia, demostraron ser altamente relevantes para el entrenamiento de los modelos. Estos rasgos permitieron una clara diferenciación entre las señales normales y las afectadas por ICC, contribuyendo significativamente a la precisión del sistema de clasificación.

Finalmente, este trabajo representa una propuesta tecnológica en la clasificación de señales de ECG afectadas por ICC y propone más ejemplos de rasgos característicos indicativos de ICC que puede servir para futuras investigaciones y sistemas más completos. Aunque las pruebas controladas han mostrado resultados alentadores, será necesario realizar evaluaciones más amplias en entornos clínicos para garantizar su aplicabilidad real en el diagnóstico de la ICC.

REFERENCIAS

- 19
- [1] L. Azcona, "El electrocardiograma," in *Libro de la salud cardiovascular*, A. López Farré, C. Mayaca Miguel, 1ª ed. Bilbao, España: Narea, 2009, pp. 49-56.
 - [2] A. Darmawahyuni, S. Nurmaini, M. Yuwandini, M. N. Rachmatullah, F. Firdaus, B. Tutuko, "Congestive heart failure waveform classification based on short time-step analysis with recurrent network," *Informatics in Medicine Unlocked*, vol. 21, p. 100441, 2020, doi: <https://doi.org/10.1016/j.imu.2020.100441>.
 - [3] D. Li, Y. Tao, J. Zhao, H. Wu, "Classification of Congestive Heart Failure from ECG Segments with a Multi-Scale Residual Network," *Symmetry*, vol. 12, no. 12, p. 2019, Dec. 2020, doi: 10.3390/sym12122019. Disponible en: <https://doi.org/10.3390/sym12122019>.
 - [4] V. Jahmunah, S. L. Oh, J. K. E. Wei, E. J. Ciaccio, K. Chua, T. R. San, U. R. Acharya, "Computer-aided diagnosis of congestive heart failure using ECG signals – A review," *Physica Medica*, vol. 62, pp. 95-104, jun. 2019, ISSN 1120-1797. DOI: 10.1016/j.ejmp.2019.05.004. [En línea]. Available: <https://www.sciencedirect.com/science/article/pii/S1120179719301115>.
 - [5] L. Hussain, I. A. Awan, W. Aziz, S. Saeed, A. Ali, F. Zeeshan, K. S. Kwak, "Detecting Congestive Heart Failure by Extracting Multimodal Features and Employing Machine Learning Techniques," *BioMed Research International*, vol. 2020, ID 4281243, Feb. 2020. DOI: 10.1155/2020/4281243. [En línea]. Disponible en: <https://www.hindawi.com/journals/bmri/2020/4281243/>.
 - [6] A. C. Guyton, J. E. Hall, "Electrocardiograma normal," in *Tratado de fisiología médica*, 12ª ed., vol. 1, Unidad 3, Elsevier, 2011, pp. 121-130.
 - [7] R. Bover, "El electrocardiograma (ECG) en la insuficiencia cardíaca: bloqueo de rama izquierda," *Insuficiencia cardíaca para pacientes*, Aug. 13, 2018. Available: <https://insuficiencia-cardiaca.com/insuficiencia-cardiaca/diagnostico-insuficiencia-cardiaca/41-diagnostico-electrocardiograma-insuficiencia-cardiaca.html>.
 - [8] D. Zipes, P. Libby, R. Bonow, D. Mann, and G. Tomaselli, *Braunwald's Heart Disease: A Textbook of Cardiovascular Medicine*, 11ª ed. Philadelphia, PA, USA: Elsevier, 2019.
 - [9] D. S. Baim, W. S. Colucci, E. S. Monrad, H. S. Smith, R. F. Wright, A. Lanoue, D. F. Gauthier, B. J. Ransil, W. Grossman, E. Braunwald, "Survival of patients with severe congestive heart failure treated with oral milrinone," *Journal of the American College of Cardiology*, vol. 7, no. 3, pp. 661-670, Mar. 1986, doi: [https://doi.org/10.1016/s0735-1097\(86\)80478-8](https://doi.org/10.1016/s0735-1097(86)80478-8).
 - [10] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215-e220, Jun. 2000, doi: <https://doi.org/10.13026/C29G60>.
 - [11] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, and H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215-e220, Jun. 2000. Available: <https://physionet.org/content/nsrdb/1.0.0/>.
 - [12] O. Manolkar, N. Gawande, "ECG Analysis for Chronic Heart Failure Detection using Deep Learning," *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, vol. 11, no. 6, 2023, doi: <https://doi.org/10.22214/ijraset.2023.53733>.
 - [13] V. Morales Oñate, "Machine Learning: Teoría y Práctica," [En línea]. Disponible: https://bookdown.org/victor_morales/TecnicasML/. (accessed Apr. 11, 2023).
 - [14] J. Botros, F. Mourad-Chehade, D. Laplanche, "CNN and SVM-Based Models for the Detection of Heart Failure Using Electrocardiogram Signals," *Sensors (Basel)*, vol. 22, no. 23, p. 9190, Nov. 2022, doi: <https://doi.org/10.3390/s22239190>.
 - [15] A. Turnip *et al.*, "Classification of ECG signal with Support Vector Machine Method for Arrhythmia Detection," *J. Phys.: Conf. Ser.*, vol. 970, p. 012012, Jul. 2018, doi: <https://doi.org/10.1088/1742-6596/970/1/012012>.
 - [16] I. Logunova, "K-Nearest Neighbors Algorithm for ML," *Serokell*. Available: <https://serokell.io/blog/knn-algorithm-in-ml>. (accessed Sep. 7, 2024).
 - [17] Y. Shi, Z. Yang, K. Yang, Y. Zhou, "k-Nearest Neighbors Method," in *Mobile Edge Artificial Intelligence*, Academic Press, 2022. Available: <https://doi.org/10.1016/C2020-0-00624-9>.
 - [18] ScienceDirect, "k-Nearest Neighbors Algorithm," *ScienceDirect*. Available: <https://www.sciencedirect.com/topics/computer-science/k-nearest-neighbors-algorithm>. (accessed Sep. 7, 2024).
 - [19] S. Jayalalitha, D. Susan, S. Kumari, B. Archana, "K-nearest Neighbour Method of Analysing the ECG Signal (To Find out the Different Disorders Related to Heart)," *Journal of Applied Sciences*, vol. 14, no. 14, pp. 1628-1632, 2014, doi: <https://doi.org/10.3923/jas.2014.1628.1632>.
 - [20] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, 1st ed. Cambridge, MA, USA: MIT Press, 2016.

- [21] U. R. Acharya, H. Fujita, O. S. Lih, M. Adam, J. H. Tan, C. K. Chua, "Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network," *Knowledge-Based Systems*, vol. 132, pp. 62-71, Jun. 2017, doi: <https://doi.org/10.1016/j.knosys.2017.06.003>.
- [22] Y. Karaca, M. Moonis, "Shannon entropy-based complexity quantification of nonlinear stochastic process," in *Multi-Chaos, Fractal and Multi-Fractional Artificial Intelligence of Different Complex Systems*, Elsevier, 2022. Available: <https://www.sciencedirect.com/topics/engineering/shannon-entropy>.
- [23] T. Li, M. Zhou, "ECG classification using wavelet packet entropy and random forests," *Entropy*, vol. 18, no. 8, p. 285, Aug. 2016. <https://doi.org/10.3390/e18080285>.
- [24] H. Yanık, E. Değirmenci, B. Büyükakıllı, D. Karpuz, O. Kılınc, S. Gürgül, "Electrocardiography (ECG) analysis and a new feature extraction method using wavelet transform with scalogram analysis," *Biomedical Engineering / Biomedizinische Technik*, vol. 65, no. 5, pp. 543-556, May 2020. <https://doi.org/10.1515/bmt-2019-0147>.