



UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO

---

FACULTAD DE INGENIERÍA ELÉCTRICA  
DIVISIÓN DE POSGRADO

DIAGNÓSTICO AUTOMÁTICO  
DE ENFERMEDADES  
CARDÍACAS UTILIZANDO  
REDES NEURONALES  
CONVOLUCIONALES

TESIS

PARA OBTENER EL TÍTULO DE:

**Maestra en Ciencias en  
Ingeniería Eléctrica**

**Sistemas Computacionales**

PRESENTA:

**Brenda Isabel Zavala García**



ASESOR DEL TRABAJO:

Dr. José Antonio Camarena Ibarrola

Morelia Michoacán, mayo de 2025



## DIAGNÓSTICO AUTOMÁTICO DE ENFERMEDADES CARDÍACAS UTILIZANDO REDES NEURONALES CONVOLUCIONALES

Los Miembros del Jurado de Examen de Grado aprueban la Tesis de Maestría en  
Ciencias en Ingeniería Eléctrica de Brenda Isabel Zavala García.

Dr. Luis Eduardo Gamboa Guzmán  
*Presidente del Jurado*

Dr. José Antonio Camarena Ibarrola  
*Director de Tesis*

Dr. Jaime Cerda Jacobo  
*Vocal*

25.02.2025

Dr. José Ortiz Béjar  
*Vocal*

Dr. Luis Valero Elizondo.  
*Revisor Externo (FISMAT UMSNH)*

Dr. J. Aurelio Medina Rios  
*Jefe de la División de Estudios de Posgrado  
de la Facultad de Ingeniería Eléctrica. UMSNH  
(Por reconocimiento de firmas)*

UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO  
Febrero 2025

# Resumen

En este documento se presenta el desarrollo de un clasificador de seis condiciones cardíacas: normal, contracción ventricular prematura, latido acompasado, golpe de bloqueo de rama derecha, golpe de bloqueo de rama izquierda y contracción auricular prematura; haciendo uso de redes neuronales convolucionales 2D en lenguaje Python y con apoyo de la base de datos MIT-BIH Arrhythmia de Physionet, la cual posee registros de electrocardiogramas.

Para llevar a cabo el objetivo mencionado anteriormente se desarrollan dos clasificadores basados en redes neuronales convolucionales 2D, para esto se toma la señal segmentada en 10 segundos. En el primer clasificador las señales se convierten en una imagen en escala de grises pasando los valores de un arreglo de una dimensión a una matriz cuadrada; mientras que para el segundo clasificador se obtienen los escalogramas de los mismos segmentos de señal mediante la función de Morlet.

Debido al desbalance de las clases que se presenta en la base de datos utilizada se realizan traslapes durante la segmentación de las señales, para de esta forma obtener la misma cantidad de señales por clase. De esta manera se obtuvieron como resultado una exactitud de 0.8863 para las imágenes en escala de grises y 0.9465 para la clasificación de escalogramas.

***Palabras clave***— Electrocardiograma, CNN, clasificación, diagnóstico, escalograma



# Abstract

This document presents the development of a classifier for six cardiac conditions: normal, premature ventricular contraction, paced beat, right bundle branch block beat, left bundle branch block beat and atrial premature contraction; using 2D convolutional neural networks in Python and with the support of the MIT-BIH Arrhythmia database from Physionet, which has electrocardiogram records.

To carry out the objective two classifiers are developed based on 2D convolutional neural networks; for this, the signal is divided into 10 seconds segments. In the first classifier, the signals are converted into a grayscale image by passing the values of a one-dimensional array to a square matrix; while for the second classifier, the scalograms of the same signal segments are obtained using the Morlet function.

Due to the imbalance of classes in the database used, overlaps are made during the segmentation of the signals, to obtain the same number of signals per class. This resulted in an accuracy of 0.8863 for gray scale images and 0.9465 for the classification of scalograms.

***Keywords***— Electrocardiogram, CNN, classification, diagnosis, scalogram



# Contenido

|                                                 |      |
|-------------------------------------------------|------|
| Resumen . . . . .                               | III  |
| Abstract . . . . .                              | V    |
| Contenido . . . . .                             | VII  |
| Lista de Figuras . . . . .                      | IX   |
| Lista de Tablas . . . . .                       | XII  |
| Lista de Símbolos . . . . .                     | XIII |
| Glosario . . . . .                              | XVI  |
| <br>                                            |      |
| 1. Introducción . . . . .                       | 1    |
| 1.1. Planteamiento del Problema . . . . .       | 1    |
| 1.2. Objetivos de la Tesis . . . . .            | 3    |
| 1.2.1. Objetivo general . . . . .               | 3    |
| 1.2.2. Objetivos particulares . . . . .         | 3    |
| 1.3. Descripción de Capítulos . . . . .         | 3    |
| <br>                                            |      |
| 2. Marco Teórico . . . . .                      | 5    |
| 2.1. Electrocardiograma . . . . .               | 5    |
| 2.1.1. Onda P . . . . .                         | 8    |
| 2.1.2. Complejo QRS . . . . .                   | 9    |
| 2.1.3. Intervalo QT . . . . .                   | 11   |
| 2.1.4. Derivaciones . . . . .                   | 11   |
| 2.2. Arritmias . . . . .                        | 14   |
| 2.2.1. Ritmos Irregulares . . . . .             | 14   |
| 2.2.2. Escape . . . . .                         | 16   |
| 2.2.3. Latidos Prematuros . . . . .             | 19   |
| 2.2.4. Taquiarritmias . . . . .                 | 25   |
| 2.3. Bloqueos . . . . .                         | 31   |
| 2.4. Técnicas de Aprendizaje Profundo . . . . . | 36   |
| 2.4.1. Red Neuronal Convolutiva (CNN) . . . . . | 37   |
| 2.5. Conclusiones . . . . .                     | 38   |

---

|                                                                   |    |
|-------------------------------------------------------------------|----|
| 3. Antecedentes                                                   | 40 |
| 3.1. Conclusiones . . . . .                                       | 56 |
| 4. Implementación del Diagnosticador                              | 58 |
| 4.1. Imagen en Escala de Grises . . . . .                         | 60 |
| 4.1.1. Preprocesamiento . . . . .                                 | 60 |
| 4.1.2. CNN . . . . .                                              | 61 |
| 4.2. Escalograma . . . . .                                        | 63 |
| 4.2.1. Preprocesamiento . . . . .                                 | 65 |
| 4.2.2. CNN . . . . .                                              | 66 |
| 4.3. Conclusiones . . . . .                                       | 68 |
| 5. Pruebas y Resultados                                           | 69 |
| 5.1. Base de Datos . . . . .                                      | 69 |
| 5.2. Clases . . . . .                                             | 71 |
| 5.3. Conjuntos de Entrenamiento y Prueba . . . . .                | 73 |
| 5.3.1. Balanceo de clases . . . . .                               | 75 |
| 5.4. Clasificador Mediante Imágenes en Escala de Grises . . . . . | 76 |
| 5.5. Clasificador Mediante Escalograma . . . . .                  | 80 |
| 5.6. Conclusiones . . . . .                                       | 84 |
| 6. Conclusiones                                                   | 85 |
| 6.1. Conclusiones Generales . . . . .                             | 85 |
| 6.2. Trabajos Futuros . . . . .                                   | 86 |
| A. Información de Registros                                       | 88 |
| B. Cantidad de Latidos por Registro                               | 91 |
| Referencias                                                       | 93 |

# Lista de Figuras

|                                                             |    |
|-------------------------------------------------------------|----|
| 2.1. Electrómetro capilar de Gabriel Lippmann. . . . .      | 6  |
| 2.2. Máquina de ECG inventada por Einthoven . . . . .       | 6  |
| 2.3. Contracción del miocardio. . . . .                     | 7  |
| 2.4. Ondas de despolarización y repolarización . . . . .    | 7  |
| 2.5. Inicio de la despolarización . . . . .                 | 8  |
| 2.6. Onda P . . . . .                                       | 9  |
| 2.7. Pausa en el ECG . . . . .                              | 9  |
| 2.8. Complejo QRS . . . . .                                 | 10 |
| 2.9. Segmento ST y curva T . . . . .                        | 11 |
| 2.10. ECG con las distintas derivaciones . . . . .          | 12 |
| 2.11. Electrodo para derivaciones de extremidades . . . . . | 13 |
| 2.12. Electrodo para derivaciones torácicas . . . . .       | 13 |
| 2.13. ECG de marcapasos errante . . . . .                   | 15 |
| 2.14. ECG de Taquicardia Auricular Multifocal . . . . .     | 15 |
| 2.15. ECG de Fibrilación Auricular . . . . .                | 16 |
| 2.16. ECG de Ritmo con Escape Auricular . . . . .           | 17 |
| 2.17. ECG de Ritmo con Escape de Unión . . . . .            | 17 |
| 2.18. ECG de Ritmo con Escape Ventricular . . . . .         | 18 |
| 2.19. ECG de Latido con Escape Auricular . . . . .          | 18 |
| 2.20. ECG de Latido con Escape de Unión (AV) . . . . .      | 19 |
| 2.21. ECG de Latido con Escape Ventricular . . . . .        | 19 |
| 2.22. ECG de Latido Auricular Prematuro . . . . .           | 20 |
| 2.23. ECG de Bigeminismo Auricular . . . . .                | 21 |
| 2.24. ECG de Trigeminismo Auricular . . . . .               | 21 |
| 2.25. ECG de Latido Prematuro de la Unión AV . . . . .      | 22 |
| 2.26. ECG de Contracción Ventricular Prematura . . . . .    | 23 |
| 2.27. ECG con PVC's Múltiples Unifocales . . . . .          | 24 |
| 2.28. ECG de Taquicardia Ventricular . . . . .              | 24 |
| 2.29. ECG de Fenómeno R en T . . . . .                      | 25 |
| 2.30. ECG de Taquicardia Auricular Paroxística. . . . .     | 26 |
| 2.31. ECG de Taquicardia de la Unión Paroxística . . . . .  | 26 |

|                                                                                                                   |    |
|-------------------------------------------------------------------------------------------------------------------|----|
| 2.32. ECG de Taquicardia Supraventricular Paroxística . . . . .                                                   | 27 |
| 2.33. ECG de Taquicardia Ventricular Paroxística . . . . .                                                        | 27 |
| 2.34. ECG de Aleteo Auricular . . . . .                                                                           | 28 |
| 2.35. ECG de Aleteo Ventricular . . . . .                                                                         | 29 |
| 2.36. ECG de Fibrilación Auricular . . . . .                                                                      | 30 |
| 2.37. ECG de Fibrilación Ventricular . . . . .                                                                    | 30 |
| 2.38. ECG de Bloqueo Sinusal . . . . .                                                                            | 31 |
| 2.39. ECG de Síndrome de Disfunción Sinusal . . . . .                                                             | 32 |
| 2.40. ECG de Bloqueo AV de Primer Grado . . . . .                                                                 | 32 |
| 2.41. ECG de Bloqueo AV de Segundo Grado Tipo I . . . . .                                                         | 33 |
| 2.42. ECG de Bloqueo AV de Segundo Grado Tipo II . . . . .                                                        | 33 |
| 2.43. ECG de Bloqueo AV de Tercer Grado del Foco Juncional . . . . .                                              | 34 |
| 2.44. ECG de Bloqueo AV de Tercer Grado del Foco Ventricular . . . . .                                            | 34 |
| 2.45. ECG de Bloqueo de la Rama Derecha . . . . .                                                                 | 35 |
| 2.46. ECG de Bloqueo de la Rama Izquierda . . . . .                                                               | 36 |
| 2.47. Arquitectura de una Red Neuronal Convolucional . . . . .                                                    | 37 |
| 3.1. Triángulo de Einthoven . . . . .                                                                             | 41 |
| 3.2. Señal del registro 101 preprocesada . . . . .                                                                | 42 |
| 3.3. Algoritmo utilizado para la clasificación de 6 clases con sus 12 variaciones                                 | 45 |
| 3.4. Arquitectura de CNN utilizada 17 clases. . . . .                                                             | 46 |
| 3.5. Arquitectura de CNN utilizada para la clasificación de 5 clases. . . .                                       | 47 |
| 3.6. Proceso realizado por Wang . . . . .                                                                         | 48 |
| 3.7. Arquitectura de la CNN utilizada por Wang . . . . .                                                          | 48 |
| 3.8. Ejemplo de CNN para la clase V utilizando escalogramas . . . . .                                             | 49 |
| 3.9. Ejemplo de segmentos de ECG de cada clase . . . . .                                                          | 50 |
| 3.10. Cortes realizados a una señal para nivelación de clases . . . . .                                           | 51 |
| 3.11. Arquitectura de la CNN utilizada para clasificar imágenes $128 \times 128$<br>en escala de grises . . . . . | 51 |
| 3.12. Proceso de clasificación de 6 clases de arritmias en dos etapas . . . .                                     | 52 |
| 3.13. Arquitectura de ResNet-18 y ResNet-50 . . . . .                                                             | 53 |
| 3.14. Arquitectura de descomposición y clasificación mediante onformación<br>espectral . . . . .                  | 54 |
| 3.15. Proceso de itentificación de arritmias ventriculares . . . . .                                              | 56 |
| 4.1. Gráfica de 30 segundos de ECG con condición normal . . . . .                                                 | 59 |
| 4.2. Gráfica de 10 segundos de ECG con condición normal. . . . .                                                  | 59 |
| 4.3. Proceso de conversión de una señal a imagen en escala de grises. . . .                                       | 62 |
| 4.4. Distintas funciones madre para Transformada Wavelet . . . . .                                                | 64 |
| 4.5. Función madre wavelet B-Spline. . . . .                                                                      | 65 |
| 4.6. Creación de escalograma a partir de una señal. . . . .                                                       | 66 |
| 5.1. Gráfica de 10 segundos la señal 100 . . . . .                                                                | 70 |

---

|                                                                              |    |
|------------------------------------------------------------------------------|----|
| 5.2. Lectura de 10 segundos de las distintas clases de la base de datos. . . | 73 |
| 5.3. Lectura de 10 segundos del primer canal de los registros. . . . .       | 74 |
| 5.4. Ejemplos de imágenes en escala de grises por clase. . . . .             | 77 |
| 5.5. Gráficas de métricas para imágenes en escala de grises. . . . .         | 78 |
| 5.6. Matriz de confusión para imágenes en escala de grises. . . . .          | 79 |
| 5.7. Ejemplos de escalogramas por clase . . . . .                            | 81 |
| 5.8. Gráficas de métricas de escalogramas. . . . .                           | 82 |
| 5.9. Matriz de confusión para escalogramas . . . . .                         | 82 |

# Lista de Tablas

|                                                                              |    |
|------------------------------------------------------------------------------|----|
| 3.1. Arquitecturas y resultados utilizados [Padrón98]. . . . .               | 41 |
| 3.2. Arquitecturas y resultados obtenidos [Andreotti17]. . . . .             | 44 |
| 4.1. Hiperparámetros de la red neuronal para imágenes en escala de grises.   | 63 |
| 4.2. Hiperparámetros de la red neuronal para escalogramas. . . . .           | 67 |
| 5.1. Símbolos de los distintos tipos de latidos [Goldberger00] . . . . .     | 71 |
| 5.2. Clasificación de registros por enfermedad [Jun18]. . . . .              | 72 |
| 5.3. Traslapes para equilibrar las clases. . . . .                           | 76 |
| 5.4. Métricas de clasificador mediante imágenes en escala de grises. . . . . | 80 |
| 5.5. Métricas de clasificador mediante escalogramas. . . . .                 | 83 |
| 5.6. Comparación de resultados. . . . .                                      | 83 |
| A.1. Información sobre los registros de la base de datos [Moddy01]. . . . .  | 90 |
| B.1. Tipo y cantidad de latidos por registro [Goldberger00]. . . . .         | 92 |

# Lista de Símbolos

|          |                              |
|----------|------------------------------|
| $x$      | variable independiente       |
| $y$      | variable dependiente         |
| $\theta$ | parámetro de aproximación    |
| $In$     | números de entrada           |
| $Out$    | números de salida            |
| Hz       | Hertz                        |
| $G[i]$   | elemento $i$ del arreglo $G$ |
| mín      | elemento mínimo              |
| máx      | elemento máximo              |
| $\psi$   | función wavelet              |
| $B$      | ancho de banda               |
| $C$      | centro de frecuencia         |

# Glosario

**AF:** Atrial Fibrillation - Fibrilación Auricular

**APC:** Atrial Premature Contraction - Contracción Auricular Prematura

**AV:** Atrio-Ventricular

**BBB:** Bundle Branch Block - Bloqueo de Rama

**BIH:** Beth Israel Hospital

**BRNN:** Bidirectional Recurrent Neural Network - Red Neuronal Recurrente Bidireccional

**CNN:** Convolutional Neural Network - Red Neuronal Convolutacional

**CWT:** Continuous Wavelet Transform - Transformada Wavelet Continua

**DBN:** Deep Belief Network - Red de Creencias Profundas

**DL:** Deep Learning - Aprendizaje Profundo

**DNN:** Deep Neural Network - Redes Neuronales Profundas

**DWT:** Discrete Wavelet Transform - Transformada Discreta Wavelet

**ECG:** Electrocardiograma

**ECV:** Enfermedades Cardiovasculares

**ELU:** Exponential Linear Unit - Unidad Lineal Exponencial

**EPOC:** Enfermedad Pulmonar Obstructiva Crónica

**FN:** False Negative - Falsos Negativos

**FP:** False Positive - Falsos Positivos

**GRU:** Gated Recurrent Unit - Unidad Recurrente Controlada

**INEGI:** Instituto Nacional de Estadística, Geografía e Informática

**LBBB:** Left Budle Branch Block - Bloqueo de Rama Derecho

**LSTM:** Long Short-Term Memory - Memoria a Corto Plazo y Larga Duración

**MAT:** Multifocal Atrial Tachycardia - Taquicardia Auricular Multifocal

**MBCKP:** Momentum Backpropagation - Retropropagación con Momentum

**MLP:** Multilayer Perceptron - Perceptrones Multicapa

**MVP:** Mitral Valve Prolapse - Prolapso de la Válvula Mitral

**NOR:** Normal

**OMS:** Organización Mundial de la Salud

**PAB:** Premature Atrial Beat - Latido Auricular Prematuro

**PAT:** Paroxysmal Atrial Tachycardia - Taquicardia Auricular Paroxística

**PJB:** Premature Junctional Beat - Latido Prematuro de la Unión AV

**PJT:** Paroxysmal Junctional Tachycardia - Taquicardia Paroxística de la Unión AV

**PVC:** Premature Ventricular Contraction - Contracción Ventricular Prematura

**RBBB:** Right Budle Branch Block - Bloqueo de Rama Izquierda

**RBM:** Restricted Boltzmann Machine - Máquina de Boltzmann Restrictiva

**RNA:** Red Neuronal Artificial

**RNN:** Recurrent Neural Network - Red Neuronal Recurrente

**SA:** Sinusal

**SSS:** Sick Sinus Syndrome - Síndrome de Disfunción Sinusal

**SVM:** Support Vector Machine - Máquina de Soporte Vectorial

**SVT:** Supraventricular Tachycardia - Taquicardia Supraventricular

**TP:** True Positive - Verdaderos Positivos

**VEB:** Ventricular Escape Beat - Latido de Escape Ventricular

**VF:** Ventricular Fibrillation - Fibrilación Ventricular

**VFW:** Ventricular Flutter Wave - Onda de Aleteo Ventricular

**VT:** Ventricular Tachycardia - Taquicardia Ventricular

**WAP:** Wondering Atrial Pacemaker - Marcapasos errante

# Capítulo 1

## Introducción

### 1.1. Planteamiento del Problema

Según la OMS [OMS21], las enfermedades cardiovasculares (ECV) son la principal causa de defunción en el mundo, ya que las cifras arrojan que 17.9 millones de personas fallecieron debido a esta causa durante el año 2019, lo cual representa el 32 % de todas las muertes a nivel mundial, de este porcentaje el 85 % se debe a infartos al miocardio y accidentes cerebrovasculares, por lo que un diagnóstico oportuno es importante para un buen acompañamiento médico.

En México, según el Instituto Nacional de Estadística, Geografía e Informática [INEGI24], en 2023 se registraron 794,739 defunciones de las cuales 189,289 corresponden a enfermedades del corazón correspondiente al 23.82 % del total. De la misma manera en Michoacán las enfermedades cardíacas fueron la principal causa de muerte en 2023 con 7,178 de 18,418 defunciones registradas, lo que corresponde al 38.97 %. Este mismo estudio muestra que las enfermedades cardíacas se encuentran dentro de las primeras tres causas de muerte en hombres y mujeres a partir de los 35 años, volviéndose la principal a partir de los 65 años en mujeres y de los 45 años en hombres. El Gobierno de México menciona [Secretaría de Salud18], que las arritmias se volvieron un padecimiento cada vez más frecuente en la población, causando muerte súbita en

personas de todas las edades. Una arritmia suele presentarse como condición o como consecuencia de alguna enfermedad en personas adultas, como la isquemia miocárdica [May19], considerada la de mayor presencia en el país [INEGI24].

Algunas de las arritmias más peligrosas son: ***fibrilación auricular***, taquicardia que provoca el trabajo errático del corazón con un ritmo entre 350 y 450 latidos por minuto; ***escape ventricular (VEB)***, bradicardia que se presenta cuando el nodo sinusal se detiene y un foco ventricular toma el papel principal provocando un ritmo entre 20 y 40 latidos por minuto; ***taquicardia ventricular***, conocida como corrida de contracciones ventriculares prematuras (PVC), se da con la presencia de una serie de latidos antes de tiempo; ***aleteo ventricular (VFW)***, taquicardia que produce un ritmo entre 2500 y 350 latidos por minuto, evitando que los ventrículos se llenen; ***fibrilación ventricular***, taquicardia con un ritmo errático entre 350 y 450 latidos por minuto evitando la despolarización completa de los ventrículos; ***bloqueo de rama izquierda (LBBB) o derecha (RBBB)***, se trata de una bradicardia que evita la despolarización de uno de los ventrículos. Todas ellas tienen como consecuencia mayor un paro cardíaco [Dubin00].

La mejor manera de detectar una arritmia es mediante un electrocardiograma (ECG) [Dubin00], ya que en ellos se logra observar los distintos tipos de patrones en cada arritmia, además de ser una forma de diagnóstico no invasiva. Sin embargo, la evaluación manual de un ECG puede volverse demasiado tediosa y demandar mucha precisión y tiempo, por lo que un mal diagnóstico oportuno puede hacer que el problema avance gradualmente dañando el músculo del corazón [Naz21]. Es por esto que el diagnóstico mediante aprendizaje profundo ha cobrado interés dentro de la ingeniería biomédica mostrando buenos resultados.

En el presente trabajo se desarrolla la clasificación de seis arritmias, anteriormente explicadas, que se encuentran en la base de datos MIT-BIH Arrhythmia. Para esto se hace uso de la derivación superior de las dos presentadas en los registros de la base de datos, y se desarrolla una Red Neuronal Convolutiva 2D, transformando las señales

en imágenes. Además se busca vencer obstáculos como el desbalance de clases dentro de las bases de datos para lograr automatizar su diagnóstico.

## **1.2. Objetivos de la Tesis**

### **1.2.1. Objetivo general**

Implementar un clasificador, mediante redes neuronales convolucionales, de cinco tipos de arritmia para la detección automática de enfermedades cardíacas utilizando señales de electrocardiogramas.

### **1.2.2. Objetivos particulares**

- Revisar el estado del arte sobre trabajos de clasificación de electrocardiogramas.
- Estudiar y comprender la base de datos pública MIT-BIH.
- Analizar los distintos tipos de preprocesamiento para elegir el óptimo para la clasificación.
- Implementar una red neuronal convolucional 2D para la clasificación de electrocardiogramas.
- Realizar pruebas de sensibilidad a los diagnosticadores desarrollados.

## **1.3. Descripción de Capítulos**

En el capítulo dos se presentan las bases teóricas de la investigación, entre las que podemos encontrar las bases de la creación del electrocardiograma, las partes que lo conforman y qué significa cada una, la colocación de los electrodos y las distintas derivaciones que se pueden obtener con ellos. Además se encuentra la explicación de

las arritmias y cómo reconocerlas en un electrocardiograma, algunas de estas arritmias son: ritmos irregulares como marcapasos errante, taquicardia auricular multifuncional y fibrilación auricular; escapes, entre los que se encuentran: ritmo de escape auricular, de unión y ventricular, latido de escape auricular, de unión y ventricular; latidos prematuros como el auricular prematuro, con conducción ventricular, no conducido, bigeminismo y trigeminismo y contracción ventricular; taquicardias, entre las cuales se encuentran: paroxística, aleteos y fibrilaciones; y bloqueos como el sinusal, AV y de rama. Y para finalizar con las bases teóricas se encuentra también una investigación sobre las técnicas de aprendizaje profundo y cuál es el uso que se le da a cada una.

Dentro del capítulo tres se encuentran antecedentes sobre trabajos relacionados con el presente, los cuales tratan la clasificación de enfermedades cardíacas mediante redes neuronales. Algunos de ellos tratan temas como la elección de los conjuntos de entrenamiento y prueba, los preprocesamientos a seguir, manejo de muestras de una y dos dimensiones, extracción de características, redes neuronales convolucionales y segmentación. El capítulo cuatro presenta la implementación de los dos clasificadores desarrollados, el procesamiento de las señales para obtener las imágenes en escala de grises y los escalogramas, así como la arquitectura de las redes neuronales detallando cada uno de los parámetros.

Mientras que en el capítulo cinco se encuentra la base de datos explicada con los siguientes detalles: número de registros, derivaciones, latido y ritmo, cantidad de latidos; así como la explicación de las clases que se toman en cuenta, conjuntos de entrenamiento y prueba. También se encuentran los resultados obtenidos con la matriz de confusión y métricas como accuracy, precision, recall y F1 de cada uno de los clasificadores. Finalmente, el capítulo seis presenta las conclusiones y trabajos futuros para mejorar los resultados obtenidos.

## Capítulo 2

# Marco Teórico

### 2.1. Electrocardiograma

En 1790 Luigi Galvani descubrió que el músculo del corazón (miocardio) funciona gracias a impulsos eléctricos, este descubrimiento se logró haciendo que las piernas de una rana muerta se movieran mediante una simulación eléctrica. Dicho suceso fue científicamente establecido en 1855, por Kollicker y Mueller al colocar un nervio motor de la pata de la rana a su corazón palpitante y observar que la pata se movía con cada latido [Dubin00].

A mediados de 1880 Ludwig y Waller [Dubin00], descubrieron que los estímulos eléctricos del ritmo cardíaco humano pueden ser monitoreados haciendo uso de electrodos colocados en la piel y conectados a un electrómetro capilar. Este instrumento consta de un tubo de vidrio vertical cuyo extremo queda en un tubo capilar afilado, este tubo contiene mercurio y se encuentra sumergido en un recipiente con agua acidulada y mercurio [Pagnini10], como se muestra en la Figura 2.1, de esta manera el nivel del mercurio en el tubo capilar se mueve con el ritmo de los latidos del corazón.




Figura 2.1: Electrómetro capilar de Gabriel Lippmann [Micheli11].

En 1901, el doctor Willem Einthoven inventó la máquina de electrocardiogramas colocando dos electrodos a la piel de la persona, los cuales estaban conectados a los extremos de un alambre de plata suspendido entre los polos de un imán, logrando así que se mueva al ritmo de los latidos de la persona. Para registrar estos movimientos se proyectó un pequeño rayo de luz a través de los polos como se muestra en la Figura 2.2 [Dubin00].




Figura 2.2: Máquina de ECG inventada por Einthoven en 1901 [Dubin00].

Según Dale [Dubin00], un electrocardiograma (ECG) es la grabación de la actividad eléctrica cardíaca, la cual brinda información importante sobre el funcionamiento y estructura del corazón. La mayoría de esta información es sobre la contracción del

miocardio ya que esta se da cuando es eléctricamente estimulado.

Explicado por Dubin [Dubin00] las células del miocardio (miocitos), son cargadas negativamente cuando se encuentra en reposo, la despolarización de dichas células causan la contracción del miocardio. El cambio de carga es causado por el movimiento rápido de iones de sodio que se ponen en contacto con los miocitos como se muestra en la Figura 2.3. La onda provocada por la despolarización y la repolarización inmediata de las células son grabadas en el ECG mostrado en la Figura 2.4.




Figura 2.3: Corte transversal del miocardio, los signos + muestran el cambio de carga de los miocitos, mientras que las flechas muestran la contracción causada. [Dubin00].




Figura 2.4: Grabación de ondas de despolarización y repolarización [Dubin00].

### 2.1.1. Onda P

El nódulo sinusal, también conocido como nodo sinusal (SA), es considerado el marcapasos natural del corazón siendo el encargado de comenzar con la onda de despolarización, se localiza en la parte superior-posterior derecha, como se observa en la Figura 2.5. El ritmo de su actividad es llamado “ritmo sinusal” [Dubin00].





Figura 2.5: Nodo sinusal del corazón, encargado de comenzar la despolarización con un ritmo de 60 a 100 latidos por minuto [Dubin00].

Cada onda de despolarización emitida por el nodo SA se extiende a ambas aurículas produciendo la onda P del ECG, mostrado en la Figura 2.6. Dale [Dubin00] menciona que a pesar de que la contracción de las aurículas tiene mayor duración, la onda P es considerada su representación.

La contracción obtenida hace que la sangre pase de las aurículas a los ventrículos a través de la válvula atrio-ventricular (AV), logrando una despolarización eficiente de los ventrículos. La corriente eléctrica es conducida de las aurículas a los ventrículos mediante el nodo AV de manera lenta, lo que provoca una breve pausa en el flujo de la sangre, esta pausa se observa en el ECG como un segmento pequeño en la línea base después de la onda P, como se muestra en la Figura 2.7.



(a) Cuatro cavidades [Estrada19].

(b) Onda P [Dubin00].

Figura 2.6: Onda P causada por la despolarización de las aurículas, emitida por el nodo SA.




Figura 2.7: Pausa en el ECG provocada por la despolarización del nodo AV [Dubin00].

### 2.1.2. Complejo QRS

Una vez que la despolarización pasa por el nodo AV se conduce rápidamente al fascículo de His (haz de fibras musculares) y sus ramas, izquierda y derecha, así como a sus subdivisiones, logrando una distribución rápida a los miocitos de los ventrículos.

La despolarización completa de los ventrículos e inicio de contracción generan el complejo QRS en el ECG [Dubin00], como se observa en la Figura 2.8.




Figura 2.8: Complejo QRS causado por la despolarización de los ventrículos. [Dubin00].

El complejo QRS está compuesto por una onda negativa llamada onda Q, la cual representa la primera parte de despolarización cuya corriente fluye alejándose del electrodo positivo; seguida de una onda positiva R, que representa la segunda fase de despolarización, la cual es positiva porque fluye hacia el electrodo positivo; y finalmente una onda negativa S [UNAM21]. Sin embargo, a menudo la onda Q se encuentra ausente en el ECG.

Seguido del complejo QRS se ubica un segmento sobre la línea base conocido como segmento ST, el cual representa la fase inicial de la repolarización. Cuando este segmento tiene alguna inclinación positiva o negativa puede significar una patología seria [Dubin00].

### 2.1.3. Intervalo QT

La onda T representa la fase final de repolarización ventricular, durante esta fase la repolarización se realiza de manera rápida y efectiva; esta curva es de joroba baja y ancha como se muestra en la Figura 2.9.




Figura 2.9: Segmento ST y curva T provocado por la repolarización de los ventrículos [Dubin00].

La sístole ventricular (ciclo cardíaco en que se contrae y expulsa la sangre) se ve reflejada en el ECG desde el inicio del complejo QRS hasta el final de la curva T, llamado intervalo QT. Cuando este intervalo es demasiado largo o corto se pueden detectar anomalías peligrosas [Dubin00].

### 2.1.4. Derivaciones

Mencionado por Dale [Dubin00], un ECG estándar se encuentra compuesto por doce derivaciones distintas, ver Figura 2.10, seis correspondientes a los electrodos de las extremidades (brazos y piernas) y seis ubicadas en el pecho.




Figura 2.10: Ejemplo de un ECG estándar tomado desde las distintas derivaciones [Dubin00].

Para las derivaciones de las extremidades los electrodos son colocados en el brazo izquierdo, derecho y pierna izquierda, de esta manera la combinación de electrodos forman una derivación; el electrodo negativo del brazo derecho con el positivo del brazo izquierdo forman la derivación I, negativo del brazo derecho con positivo de la pierna la II y positivo del brazo izquierdo con positivo de la pierna izquierda la III, como se muestra en la Figura 2.11. Esta configuración es conocida como “Triángulo de Einthoven” [Dubin00].


Otras derivaciones de extremidades son las llamadas Augment Voltage (AV) [Dubin00], conformadas por:

- **AVF**: el electrodo positivo de la pierna izquierda y el electrodo negativo de ambos brazos.
- **AVR**: el electrodo positivo del brazo derecho y negativos en las otras extremidades.
- **AVL**: el electrodo positivo del brazo izquierdo y negativo de las otras extremidades.




Figura 2.11: Combinaciones de electrodos para obtener las derivaciones de extremidades [Dubin00].

Por otro lado, las derivaciones del pecho corresponden a los electrodos que se muestra en la Figura 2.12a, enumeradas de  $V_1$  a  $V_6$ , los cuales son todos positivos. Estas derivaciones muestran cambios en las curvas según sea su posición, la derivación  $V_1$  es mayormente negativa mientras que la  $V_6$  mayormente positiva, como se observa en la Figura 2.12b, esto se debe a que la despolarización ventricular se da en dirección al electrodo  $V_6$  [Dubin00].



(a) Electrodos [UNAM22].



(b) ECG [Dubin00].

Figura 2.12: Ubicación de los electrodos en el pecho para la obtención de derivaciones torácicas y ejemplos de complejos QRS de dichas derivaciones.

## 2.2. Arritmias

Mencionado por Dale [Dubin00], un corazón es considerado sano o normal cuando posee un ritmo de 60 a 100 latidos por minuto de manera regular (realizados por el nodo sinusal), esto significa que los picos R guardan la misma distancia entre ellos, por lo que el ECG es considerado el medio más preciso de detección de arritmias. Cuando la cantidad de latidos se encuentra fuera del rango normal se considera una arritmia (fuera de ritmo), si es menor a 60 se tiene un paciente con **bradicardia** pero cuando los latidos están por encima de 100 se considera una **taquicardia**.

Las arritmias pueden ser clasificadas de manera general como:

- **Ritmos irregulares**
- **Ritmo de escape**
- **Latidos prematuros**
- **Taquiarritmias**

### 2.2.1. Ritmos Irregulares

Son aquellos que carecen de una duración constante entre ciclos, lo que significa que los ciclos no pueden describirse con un patrón determinado. Dentro de los ritmos irregulares se encuentran:

- ***Marcapasos Errante (WAP, por sus siglas en inglés Wondering Atrial Pacemaker)***: Es producido por una mala actividad desde el Nodo SA hasta el nodo AV y sus ramificaciones, lo que produce variación en la longitud de los ciclos y en la forma de las ondas P, es decir, la morfología de cada curva P es diferente sin guardar semejanza entre ellas, con un ritmo menor a 100, como se muestra en la Figura 2.13. Un marcapasos errante provoca, que en ocasiones, las células del nodo AV hagan el trabajo de marcapasos. Esta arritmia no se considera un padecimiento [Dubin00].




Figura 2.13: ECG de marcapasos errante en donde se observa que las curvas P no guardan semejanza y ritmo menor a 100 latidos por minuto [AlfaMD23].

- ***Taquicardia Auricular Multifocal (MAT, por sus siglas en inglés Multifocal Atrial Tachycardia)***: Es el ritmo cardíaco que presentan las personas con enfermedad pulmonar obstructiva crónica (EPOC) y otras enfermedades que disminuyen la cantidad de oxígeno en la sangre. Su ritmo mayor a 100 latidos por minuto, con tres o más formas distintas en las ondas P, como se muestra en la Figura 2.14. En esta arritmia los impulsos eléctricos son enviados de distintas partes de la aurícula al mismo tiempo [Dubin00].




Figura 2.14: ECG de Taquicardia Auricular Multifocal, su ritmo es mayor a 100 latidos por minuto y posee tres o más formas de de onda P [AlfaMD23].

- ***Fibrilación Auricular (AF, por sus siglas en inglés Atrial Fibrillation)***: Es causada por el disparo rápido y continuo de impulsos eléctricos desde distintas partes de las aurículas, esto provoca que ningún impulso, de manera individual, logre la despolarización completa de las aurículas por lo

que una despolarización auricular aleatoria es la encargada de pasar la señal a los ventrículos. Esta actividad irregular se muestra en el ECG con la ausencia de ondas P, en su lugar se presenta una serie de pequeños y erráticos picos [Dubin00], como se observa en la Figura 2.15. La falta de diagnóstico puede tener consecuencias graves.



Figura 2.15: ECG de Fibrilación Auricular, presentando ausencia de ondas P y presencia de series de pequeños picos erráticos [AlfaMD23].

### 2.2.2. Escape

Se presenta tras una pausa en la actividad del nodo SA. Cuando la constancia y patrón del ritmo se ve afectado se considera un ritmo de escape, pero si es un sólo ciclo el que falta antes de retomar el ritmo normal se considera un latido de escape, en ambos casos es importante identificar si la causa es auricular, ventricular o de unión [Dubin00].

A pesar de que el nodo SA se puede detener por completo, presentando un paro sinusal, la actividad no cesa gracias a la automaticidad del corazón, haciendo que algún foco tome el papel de marcapasos temporal [Dubin00]. A esto se le conoce como ritmo de escape, dentro de los ritmos de escape se tienen:

- **Ritmo de Escape Auricular:** Se presenta cuando un foco de la aurícula (mayor nivel de automaticidad) toma el papel de marcapasos, provocando un ritmo entre 60 y 80 latidos por minuto, esto presenta ondas P más pequeñas y

lentas que provocadas por el nodo SA [Dubin00], como se muestra en la Figura 2.16.




Figura 2.16: ECG de Ritmo con Escape Auricular, presenta un ritmo entre 60 y 80 latidos por minuto con ondas P pequeñas y lentas [AlfaMD23].

- ***Ritmo de Escape de Unión:*** Cuando ningún foco de la aurícula toma el papel de marcapasos o si existe un bloqueo en el extremo próximo del nodo AV, este nodo (nodo AV) comienza a enviar los estímulos eléctricos provocando un ritmo entre 40 y 60 latidos por minuto. Debido a la conducción de la señal del nodo AV a los ventrículos la onda P deja de aparecer en el ECG, como se observa en la Figura 2.17, o en algunos casos puede provocar una despolarización auricular regresiva, haciendo que la onda P se vuelva negativa [Dubin00].



Figura 2.17: ECG de Ritmo con Escape de Unión , con un ritmo entre 40 y 60 latidos por minuto y provocando la ausencia o negatividad de la onda P [AlfaMD23].

- ***Ritmo de Escape Ventricular:*** Se presenta cuando un foco de automaticidad ventricular no es regularmente estimulado por la señal del nodo SA, lo que provoca que el foco ventricular tome el papel de marcapasos dando un ritmo entre 20 y 40 latidos por minuto. En el ECG se presenta con complejos QRS enormes y ondas P antes y después del complejo, como se muestra en la Figura

2.18. Esta condición es peligrosa ya que disminuye significativamente el flujo de sangre al cerebro [Dubin00].



Figura 2.18: ECG de Ritmo con Escape Ventricular, sus características son un ritmo entre 20 y 40 latidos por minuto, complejos QRS enormes y ondas P antes y después de cada complejo [AlfaMD23].

Por otro lado, los latidos de escape se presentan tras el bloqueo del nodo sinusal por un tiempo no tan prolongado, pero sí lo suficiente para perder un ciclo, activar un foco como marcapasos y después volver al ritmo normal [Dubin00], entre ellos se encuentran:

- **Latido de Escape Auricular:** Se presenta cuando un foco auricular lleva a cabo un sólo estímulo eléctrico. Su ECG se muestra en la Figura 2.19.




Figura 2.19: ECG de Latido con Escape Auricular, un sólo latido se presenta de manera retardada y con onda P pequeña [AlfaMD23].

- **Latido de Escape de Unión (AV, Atrio-Ventricular):** Se da cuando la pausa induce al nodo AV a emitir un impulso eléctrico. Este ritmo se muestra en la Figura 2.20.




Figura 2.20: ECG de Latido con Escape de Unión (AV), presenta una pausa con un latido sin onda P [AlfaMD23].

- **Latido de Escape Ventricular:** Se presenta tras la activación de un foco ventricular. Cualquier impulso realizado en el ventrículo provoca un complejo QRS enorme y generalmente invertido, como se muestra en la Figura 2.21.



Figura 2.21: ECG de Latido con Escape Ventricular, su pausa provoca que el latido presente un complejo QRS grande con onda P antes y después [AlfaMD23].

### 2.2.3. Latidos Prematuros

Se tiene un latido prematuro cuando un foco irritable lanza de manera espontánea un único estímulo produciendo un latido antes de que el ritmo lo marque. Al igual que los latidos de escape, es importante identificar si el foco causante es un foco auricular, de unión o ventricular [Dubin00].

Los focos ventriculares son muy sensibles a la presencia de moléculas de oxígeno, por lo que se vuelve irritable y reacciona con su baja presencia. En cambio, los focos auriculares y de unión se vuelven irritables con la presencia de adrenalina, la estimulación del sistema nervioso simpático, presencia de cafeína, anfetaminas, cocaína, exceso de toxinas como el etanol, hipertiroidismo y en algunos casos la baja presencia de oxígeno. Los tipos de latidos prematuros, mencionados por Dubin [Dubin00], son:

- **Latido Auricular Prematuro (PAB, por sus siglas en inglés *Premature Atrial Beat*):** Se origina de manera espontánea en un foco de automatidad auricular irritable, produciendo una onda P antes de lo normal y distinta a las demás, en algunas ocasiones la onda P es difícil de identificar ya que se encuentra oculta en la onda T, como se muestra en la Figura 2.22. Cuando el nodo SA es despolarizado por un foco auricular la señal se reinicia.




Figura 2.22: ECG de Latido Auricular Prematuro, presenta una onda P antes de lo normal y distinta a las demás [AlfaMD23].

Dentro de esta arritmia se subclasifican los siguientes casos [Dubin00]:

- **PAB con Conducción Ventricular Aberrante:** Se presenta cuando el latido prematuro pasa a los ventrículos provocando que estos se despolaricen antes de lo usual, sin embargo, uno de los ventrículos se despolariza de manera inmediata, mientras que la despolarización del otro se ve demorada y su respectiva ramificación no es repolarizada completamente.
- **PAB no Conducido:** En ocasiones el nodo AV es insensible al estímulo del foco auricular, por lo que no es despolarizado manteniendo su estado de reinicio, a esto se le conoce como latido auricular prematuro sin conducción. Dentro del ECG se presenta con la ausencia de complejo QRS y onda T (por la falta de despolarización de ventrículos) y la presencia de una onda P inusual y antes de tiempo.

- ***Bigeminismo y Trigeminismo Auricular:*** El **Bigeminismo Auricular** se presenta cuando ocasionalmente un foco irritable lanza un estímulo acoplando un PAB al final de un ciclo normal, repitiendo esto en cada ciclo, a un ciclo normal unido a un PAB se le conoce como “doblete”. En otras ocasiones un foco auricular irritable lanza un impulso después de dos ciclos normales, repitiéndolo de manera continua, a esto se le conoce como **Trigeminismo Auricular**. En ambos casos el estímulo prematuro provoca que el nodo SA se reinicie mostrando un segmento de línea recta sobre la línea base, como se muestra en las Figuras 2.23 y 2.24.




Figura 2.23: ECG de Bigeminismo Auricular, presenta un ciclo normal y un PAB, es decir un latido normal y una onda P antes y distinta a lo normal [AlfaMD23].




Figura 2.24: ECG de Trigeminismo Auricular, presenta dos ciclos normales y un PAB, es decir dos latidos normales y una onda P antes y distinta a lo normal [AlfaMD23].

- ***Latido Prematuro de la Unión AV (Juncional) (PJB, por sus siglas en inglés *Premature Junctional Beat*):*** Se presenta cuando un foco irritable de la unión AV (nodo AV) lanza un estímulo y despolariza los ventrículos, como se observa en la Figura 2.25, y en ocasiones logra la despolarización de las aurículas de manera regresiva provocando una onda P invertida [Dubin00].




Figura 2.25: ECG de Latido Prematuro de la Unión AV, en él se observa la onda P invertida [AlfaMD23].

- ***Bigeminismo y Trigeminismo Juncional (de unión AV):*** Ocurre cuando el foco del nodo AV lanza un estímulo eléctrico después de uno (bigeminismo) o dos (trigeminismo) ciclos normales de manera repetitiva, provocando el reinicio del nodo AV en con cada estímulo prematuro, lo que significa un segmento de línea base en el ECG [Dubin00].
- ***Contracción Ventricular Prematura (PVC, por sus siglas en inglés Premature Ventricular Contraction):*** Se presenta con el estímulo repentino de un foco ventricular, este foco se puede volver irritable con un nivel bajo de  $O_2$ , nivel bajo de  $K$  o alguna patología como prolapso de la válvula mitral o miocarditis [Dubin00]. Una PVC se presenta con un latido ventricular antes del momento en que se presentaría un ciclo normal, provocando un enorme complejo QRS dentro del ECG, además de que el complejo QRS tiene una polaridad opuesta a un complejo normal. El estímulo de un foco ventricular no reinicia al nodo SA pero sí provoca una pausa compensatoria entre la repolarización de los ventrículos y la generación de un nuevo ciclo, como se observa en la Figura 2.26.




Figura 2.26: ECG de Contracción Ventricular Prematura, presentando un complejo QRS enorme y de polaridad opuesta [AlfaMD23].


- **PVC's Múltiples:** Un foco ventricular muy irritable puede producir múltiples latidos prematuros esto es, generalmente, a causa de un estado pobre de oxigenación, por lo que seis o más PVC's por minuto significan la existencia de una patología. Cuando los PVC's de un ECG son idénticos se concluye que fueron provocados por el mismo foco irritable (PVC's unifocales) [Dubin00].

Este foco puede producir estímulos formando dobletes, provocando de esta manera un **bigeminismo ventricular** cuando hay un PVC después de cada ciclo, Figura 2.27a; **trigeminismo ventricular** con un PVC cada dos ciclos normales, Figura 2.27b; **cuatrigeminismo ventricular** con un PVC cada tres ciclos, Figura 2.27c; etc.


- **Parasistolia Ventricular:** Se presenta cuando un foco ventricular sufre un bloqueo de entrada (pero no es irritable), por lo que no se puede sobre estimular, pero sí puede generar estímulos a su frecuencia produciendo un ritmo dual provocado por el nodo SA y el foco ventricular. En el ECG se muestra como un complejo QRS dominante (más largo) respecto al ritmo normal, generando dobletes.
- **Taquicardia Ventricular (VT, por sus siglas en inglés Ventricular Tachycardia):** Un foco ventricular muy irritable puede provocar más de un estímulo eléctrico, es decir, una rápida serie de impulsos que



(a) Bigeminismo Ventricular.



(b) Trigeminismo Ventricular.



(c) Cuadrigeminismo Ventricular.

Figura 2.27: ECG con PVC's Múltiples Unifocales, mostrando un complejo QRS enorme e invertido cada uno, dos o tres ciclos [AlfaMD23].

provocan una corrida de PVC's, esto debido a un muy bajo nivel de oxigenación. Cuando la corrida tiene tres o más PVC's en sucesión, como se muestra en la Figura 2.28, se produce una **taquicardia ventricular**.




Figura 2.28: ECG de Taquicardia Ventricular, presenta una corrida de PVC's [AlfaMD23].

- ***Prolapso de la Válvula Mitral (MVP, por sus siglas en inglés Mitral Valve Prolapse)***: Es causado por la presencia de PVC's multifocales y corridas de VT, es considerada una condición benigna, causando que la válvula mitral se vuelva flexible y genere ondas en la aurícula izquierda durante la sístole ventricular [Dubin00].

- **Fenómeno R en T:** Es considerada una condición de alto riesgo, se produce cuando un PVC se hace presente durante un periodo “vulnerable”, es decir, justo antes de la onda T, como se muestra en la Figura 2.29. El fenómeno R en T puede provocar arritmias ventriculares y muerte súbita por paro cardíaco [Dubin00].




Figura 2.29: ECG de Fenómeno R en T, presenta al menos un PVC justo antes de la onda T [AlfaMD23].

#### 2.2.4. Taquiarritmias

Mencionado por Dubin [Dubin00], una taquiarritmia se origina a partir de un foco muy irritable que manda estímulos de manera rápida. Una taquiarritmia es fácil de reconocer conociendo el ritmo, pero es importante reconocer cuál es el lugar de origen (auricular, de unión o ventricular). Dentro de los tipos de taquiarritmias se encuentran:

- **Taquicardia Paroxística:** Con un ritmo entre 150 y 250 latidos por minuto, se puede comprender como ritmo cardíaco rápido repentino. Dentro de las taquicardias paroxísticas se pueden encontrar:
  - **Taquicardia Auricular Paroxística (PAT, por sus siglas en inglés Paroxysmal Atrial Tachycardia):** Se origina repentinamente a partir de un foco muy irritable de alguna aurícula que suprime el ritmo del nodo SA y cualquier otro foco irritable. Dentro del ECG se observan ondas P con

apariciencia distinta a las normales y complejos QRS de apariencia normal, pero más cortos, como se muestra en la Figura 2.30.



Figura 2.30: ECG de Taquicardia Auricular Paroxística, muestra ondas P distintas a las normales y complejos QRS más cortos [AlfaMD23].

- \* ***PAT con Bloqueo AV:*** Cuando se tiene un exceso en el consumo de digitálicos o una intoxicación, en algunas ocasiones por bajo nivel de potasio en el cuerpo, se puede presentar una PAT con inhibición del nodo AV. En el ECG se muestra como señales con dos ondas P por ciclo.
- ***Taquicardia de la Unión AV Paroxística (PJT, por sus siglas en inglés Paroxysmal Junctional Tachycardia):*** Se presenta tras la estimulación repentina de un foco irritable de la unión AV, provocando en el ECG ondas P invertidas y en ocasiones imperceptibles, como se muestra en la Figura 2.31.




Figura 2.31: ECG de Taquicardia de la Unión Paroxística, se observan ondas P invertidas o imperceptibles [AlfaMD23].

- ***Taquicardia Supraventricular (SVT, por sus siglas en inglés Supraventricular Tachycardia)***: Se trata de la presencia de PAT y PJT, también es conocida como Taquicardia Supraventricular Paroxística. Muestran un ECG en el cual la onda P se encuentra unida a la onda T, de tal manera que se vuelve indistinguible, como se observa en la Figura 2.32.




Figura 2.32: ECG de Taquicardia Supraventricular Paroxística, la onda P se encuentra unida a la onda T [AlfaMD23].

- ***Taquicardia Ventricular Paroxística (PVT o VT, por sus siglas en inglés Ventricular Tachycardia)***: Es generada por los estímulos repentinos de un foco irritable ventricular, su ECG se muestra como enormes complejos PVC, como se muestra en la Figura 2.33. Es muy común en pacientes con enfermedad coronaria o infarto.




Figura 2.33: ECG de Taquicardia Ventricular Paroxística, muestra complejos PVC enormes [AlfaMD23].

- **Aleteo:** Con un rango de 250 y 350 latidos por minuto. Al igual que los casos anteriores el tipo de aleteo depende del lugar en que se origine, de este modo existen los siguientes tipos:
  - **Aleteo Auricular:** Es causado por un foco auricular extremadamente irritable, provocando una serie rápida de despolarizaciones auriculares. Dentro del ECG se ve caracterizado por una serie consecutivas de curvas en forma de olas idénticas entre las cuales se desvanece la línea base, como se observa en la Figura 2.34. Otra manera de identificarlo es por su parecido a los dientes de una sierra.




Figura 2.34: ECG de Aleteo Auricular, en él se observa una serie consecutiva de curvas en forma de olas idénticas [AlfaMD23].

- **Aleteo Ventricular:** Producido por un sólo foco ventricular, los estímulos son tan rápidos que no da el tiempo suficiente para que los ventrículos se llenen, lo cual podría desencadenar en una arritmia mortal. En su ECG se logra observar una serie de suaves curvas senoidales de amplitud similar, como se muestra en la Figura 2.35.




Figura 2.35: ECG de Aleteo Ventricular, presenta una serie de suaves curvas senoidales de amplitud similar [AlfaMD23].

- **Fibrilación:** Con un rango de 350 y 450 latidos por minuto. Es generada por numerosas descargas eléctricas producidas por distintos focos irritables, ya sean auriculares o ventriculares, causando un ritmo totalmente errático ya que un estímulo no puede suprimir a los demás pasan todos a la vez lo que vuelve imposible conocer con exactitud el ritmo del corazón. Las fibrilaciones son consideradas siempre condiciones patológicas ya que pueden provocar bloqueos [Dubin00]. Los tipos de fibrilación son:

- **Fibrilación Auricular (AF, por sus siglas en inglés Atrial Fibrillation):** Es causada por múltiples focos parasistólicos auriculares irritables lanzando estímulos eléctricos rápidos, esto provoca que las aurículas no logren despolarizarse por completo, mientras que los ventrículos se ven estimulados sólo por aquellos focos cercanos al nodo AV. Se observa en el ECG como una serie de picos R delgados y erráticos, ausencia de ondas P y oscilaciones rápidas y erráticas [Dubin00], como se muestra en la Figura 2.36.



Figura 2.36: ECG de Fibrilación Auricular, se observa una serie de picos R delgados y erráticos, ausencia de ondas P y oscilaciones rápidas y erráticas [AlfaMD23].

- **Fibrilación Ventricular (VF, por sus siglas en inglés Ventricular Fibrillation):** Generada por descargas rápidas de numerosos focos ventriculares, lo que produce contracciones erráticas en los ventrículos sin una despolarización total, es decir, un mal mecanismo de bombeo (provocando una emergencia para el paciente ya que lleva a la muerte del corazón). En el ECG se observan curvas conocidas como “bolsas de gusanos”, refiriéndose a trazos totalmente erráticos, curvas indefinibles, como se muestra en la Figura 2.37. Una VF es considerada una emergencia médica terrible, uno de los peores tipos de paro cardíaco, ya que necesita reanimación inmediata.




Figura 2.37: ECG de Fibrilación Ventricular, muestra trazos totalmente erráticos, curvas indefinibles [AlfaMD23].

## 2.3. Bloqueos

Un bloqueo retarda o evita la conducción eléctrica necesaria para la despolarización, puede ocurrir en el nodo SA, nodo AV o alguna de sus divisiones que conducen a los ventrículos. Mencionado por Dubin [Dubin00], los tipos de bloqueos son:

- **Bloqueo Sinusal:** Se presenta a partir de un nodo SA no sano que falla temporalmente, deteniendo el pase del estímulo eléctrico, provocando la falta de un ciclo, este ciclo faltante tampoco posee onda P. Una vez que el nodo vuelve a trabajar recupera el ritmo que tenía inicialmente, lo que significa que la onda P antes y después de la pausa son idénticas, como se muestra en la figura 2.38.




Figura 2.38: ECG de Bloqueo Sinusal, presenta la ausencia de un ciclo completo [AlfaMD23].

- **Síndrome de Disfunción Sinusal (SSS, por sus siglas en inglés Sick Sinus Syndrome):** Se trata de la combinación de distintas arritmias causadas por el nodo SA y la falta de respuesta supraventricular. Los pacientes con SSS suelen estar caracterizados por tener Bradicardia Sinusal, es decir, una combinación de ambas.



Figura 2.39: ECG de Síndrome de Disfunción Sinusal, presenta una combinación de distintas arritmias del nodo SA [AlfaMD23].

- **Bloqueo AV:** El bloqueo Aurículo-Ventricular retarda o elimina la conducción de las aurículas a los ventrículos [Dubin00]. Este tipo de bloqueos se clasifica de la siguiente manera:
  - **Bloqueo de primer grado:** Prolonga la conducción de las aurículas a los ventrículos para su despolarización. Dentro del ECG se observa un intervalo PR prolongado, es decir, dura más de 0.2 segundo (tiempo normal), como se muestra en la Figura 2.40, esta prolongación permanece en cada ciclo, mientras que el intervalo P-QRS-T mantiene una forma normal [Dubin00].



Figura 2.40: ECG de Bloqueo AV de Primer Grado, se observa un intervalo PR prolongado e intervalo P-QRS-T normal [AlfaMD23].

- **Bloqueo de segundo grado:** Permite el paso de algunos estímulos eléctricos de despolarización de la aurícula a los ventrículos, mientras que otros estímulos son bloqueados provocando ondas P que no están asociadas a

complejos QRS [Dubin00]. Existen dos tipos de bloqueo AV de segundo grado:

- \* **Wenckebach:** También llamado tipo I, se produce en el nodo AV, provoca una serie de ciclos con bloqueo de la conducción hasta el final de la onda P, eliminando la respuesta del complejo QRS, por ejemplo, se pueden mostrar en razón P:QRS como 3:2, 4:3, 5:4, etc., un complejo QRS que ondas P, como se muestra en la Figura 2.41.



Figura 2.41: ECG de Bloqueo AV de Segundo Grado Tipo I, también llamado Wenckebach, mantiene una razón P:QRS de 3:2 [AlfaMD23].

- \* **Mobitz:** Conocido como tipo II, se produce en las ramificaciones del nodo AV provocando series con un intervalo P-QRS-T normales seguidos de curvas P con la ausencia de complejos QRS. La razón P:QRS consiste en 3:1, 4:1, 5:1, etc., como se muestra en la Figura 2.42. La severidad del problema aumenta conforme aumenta la ausencia de complejos QRS.



Figura 2.42: ECG de Bloqueo AV de Segundo Grado Tipo II, también llamado bloqueo de Mobitz, mantiene una razón P:QRS de 3:1 [AlfaMD23].

- **Bloqueo de tercer grado:** Conocido como bloqueo AV completo, se da por el bloqueo total de la conducción eléctrica de las aurículas a los ventrículos evitando su despolarización [Dubin00]. Los pacientes con bloqueo de tercer grado suelen ocupar un marcapasos artificial. Sus tipos son:
  - \* **De Foco Juncional:** Se produce en el nodo AV, en este tipo de bloque la señal se escapa a los ventrículos mostrando ondas P y complejos QRS independientes generalmente normales, como se muestra en la Figura 2.43.




Figura 2.43: ECG de Bloqueo AV de Tercer Grado del Foco Juncional, se observan ondas P y complejos QRS independientes [AlfaMD23].

- \* **De Foco Ventricular:** Se produce debajo del nodo AV provocando que la conducción a los ventrículos sea lenta con ritmos de onda P y complejos QRS distintos, los complejos QRS son de morfología similar a los de PVC pero largos y anchos, como se muestra en la Figura 2.44.



Figura 2.44: ECG de Bloqueo AV de Tercer Grado del Foco Ventricular, presenta ondas P y complejos QRS distintos, además de complejos QRS similares a un PVC pero largos y anchos [AlfaMD23].

- **Bloqueo de Rama (BBB, por sus siglas en inglés Bundle Branch Block):** Es causado por el bloqueo de la rama derecha o izquierda retrasando la despolarización del ventrículo que suministra, una vez pasado el bloqueo la despolarización se retoma rápidamente. Como los ventrículos no se despolarizan de manera simultánea el ECG muestra un complejo QRS ancho con dos picos R (uno por ventrículo) [Dubin00].

- **BBB Derecho (RBBB, por sus siglas en inglés Right Bundle Branch Block):** Se presenta con el retraso en la despolarización del ventrículo. En el ECG se presenta un pico R representando la despolarización del ventrículo izquierdo unido a un pico R para el ventrículo derecho, como de observa en la Figura 2.45. Las mejores derivaciones para su diagnóstico con  $V_1$  y  $V_2$  [Dubin00].



Figura 2.45: ECG de Bloqueo de la Rama Derecha, muestra dos picos R unidos, el primero correspondiente al ventrículo izquierdo y el segundo al derecho [AlfaMD23].

- **BBB Izquierdo (LBBB, por sus siglas en inglés Left Bundle Branch Block):** Presenta el retraso en la despolarización del ventrículo izquierdo, en este caso el primer pico R que se presenta corresponde al ventrículo derecho y el segundo al izquierdo, como se muestra en la Figura 2.46. Las mejores derivaciones para su diagnóstico con  $V_5$  y  $V_6$  [Dubin00].



Figura 2.46: ECG de Bloqueo de la Rama Izquierda, muestra dos picos R unidos, el primero correspondiente al ventrículo derecho y el segundo al izquierdo [AlfaMD23].

- **Hemibloqueo:** Se trata del bloqueo de una de las subdivisiones de las ramas causando, comúnmente, infarto, ya que al no ser una obstrucción completa causa un bloqueo intermitente con pérdida de sangre [Dubin00].

## 2.4. Técnicas de Aprendizaje Profundo

El aprendizaje profundo, mejor conocido como Deep Learning (DL), se refiere al estudio de la extracción de conocimiento para realizar predicciones o tomar decisiones inteligentes, en otras palabras, el reconocimiento y aprendizaje de patrones en conjuntos de datos llamados conjuntos de entrenamiento. A diferencia de los métodos tradicionales de aprendizaje, las Redes Neuronales Profundas (DNN), suelen alcanzar mayor precisión en los problemas actuales aumentando solamente el tamaño de la red o del conjunto de entrenamiento [Goodfellow16].

Dentro de las prácticas modernas para mejorar la precisión en los resultados de problemas complejos sin una intervención humana mayor son: perceptrones multicapa (MLP), redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN), red de memoria a corto plazo y larga duración (LSTM), red de creencias profundas (DBN) [Ebrahimi20].

### 2.4.1. Red Neuronal Convolucional (CNN)

Se trata de una de las redes profundas más populares, usualmente entrenada con la optimización de gradiente. Consiste en diversas capas conectadas de manera progresiva. Los tipos de capas son, principalmente: convolucionales, agrupamiento y completamente conectada. Los primeros tres tipos de capas son las responsables de la extracción de características y la última la encargada de la clasificación [Ebrahimi20], su arquitectura general se muestra en la Figura 2.47.




Figura 2.47: Arquitectura de una Red Neuronal Convolucional [Ebrahimi20].

Las CNN son redes neuronales que utilizan la operación convolución, en al menos una de sus capas, en lugar de la multiplicación de matrices general. Se especializan en el procesamiento de datos con una topología de red o cuadrícula, como puede ser una serie de tiempo regular para una dimensión o los píxeles de una imagen para dos dimensiones. Se consideran exitosas en aplicaciones prácticas [Goodfellow16].

La motivación de la CNN se basa en tres ideas importantes para ayudar a mejorar el aprendizaje automático, estas ideas son:

- **Interacciones dispersas:** Las capas de redes tradicionales utilizan la multiplicación de matrices entre cada unidad de entrada y cada unidad de salida, mientras que las redes convolucionales tienen interacciones dispersas, lo cual se logra haciendo que el núcleo sea más pequeño que la entrada, y ayudando a la detección de características más detalladas [Goodfellow16].

- **Parámetros compartidos:** En una red tradicional cada elemento de la matriz de pesos es utilizado exactamente una vez al calcular la capa de salida. En una CNN cada miembro del núcleo es utilizado en cada posición de la entrada, lo que reduce los requisitos de memoria y eficiencia estadística [Goodfellow16].
- **Representaciones equivariantes:** esto significa que si se mueve un objeto en la entrada, su representación se moverá la misma cantidad en la salida, lo cual es útil, por ejemplo al momento de procesar imágenes recortadas o mal centradas [Goodfellow16].

Cuando se utilizan para la identificación de imágenes la red se vuelve más compleja y precisa conforme aumenta la cantidad de capas, ya que las primeras capas convolucionales se centran únicamente en la identificación de características sencillas como bordes y colores; conforme los datos van avanzando en las capas se encuentran características más grandes hasta lograr identificar el objeto, aplicando la operación convolución entre la imagen y un filtro. Con las capas de agrupación se busca la reducción de las dimensiones, esto se hace eligiendo ya sea el valor mayor o la media de los valores dentro de una ventana de la imagen. Finalmente con la capa totalmente conectada cada valor de salida está conectado con un nodo de la capa anterior, y se encarga de la clasificación de la imagen haciendo uso de las características obtenidas por las capas anteriores y regresando una probabilidad entre 0 y 1 [Goodfellow16].

## 2.5. Conclusiones

La lectura de ECG's es una herramienta eficiente para el diagnóstico de arritmias, ya que cada uno de los padecimientos presentan curvas notoriamente diferentes, sin embargo, debido a la cantidad de padecimientos y señales que pueden abarcar demasiado tiempo, agregando a esto también las distintas derivaciones que pueden analizarse, este trabajo se torna tedioso.

Ya que el método de diagnóstico humano se basa en la comparación de curvas, utilizar un método de clasificación basado en imágenes podría ser el más similar; la CNN es el clasificador que mejores resultados ha mostrado en esta tarea.

## Capítulo 3

# Antecedentes

La clasificación de los latidos cardíacos mediante el análisis de Electrocardiogramas (ECG), es un tema estudiado en los últimos años utilizando distintos tipos de preprocesamiento de la señal y clasificadores.

Padrón, et al. utilizaron la base de datos proporcionada por el Grupo Cardiólogo de México, con las derivaciones del triángulo Einthoven (pierna izquierda, brazo izquierdo y brazo derecho) en cada uno de los ciclos (3 o 4) como se muestra en la Figura 3.1. Los patrones de los ECG fueron adquiridos en papel especial para ECGs con varios ciclos para después digitalizarlos, de tal manera que cada ciclo del ECG fuera un vector de entrada a la red neuronal artificial (RNA) con 101 elementos, estos vectores fueron separados en 6 clases de entrenamiento correspondientes a cada clase (individuo sano o alguna de las 5 anomalías cardíacas) [Padrón98]. Las anomalías a diagnosticar fueron: problemas de frecuencia cardíaca, arritmias, eje cardíaco, hipertrofias e infarto al miocardio. Utilizando la configuración bipolar I, como se muestra en la Figura 3.1, cada clase contó con 16 o 20 elementos para el conjunto de entrenamiento. La clasificación fue realizada mediante una red neuronal artificial con un algoritmo de ajuste de gradiente conocido como retropropagación con momentum (MBCKP) [Raschka17], para evitar el estancamiento en mínimos locales, las arquitecturas utilizadas y resultados obtenidos para cada clase se pueden observar en

la Tabla 3.1, esta tabla contiene las siguientes columnas: tipo de anomalía, número de entradas, nodos y salida de la RNA, pesos utilizados, número de bias, número de épocas o iteraciones, número de ECG's evaluados, la suma cuadrática del valor de error, porcentaje del diagnóstico obtenido para el conjunto de entrenamiento y prueba, así como las anomalías mal clasificadas en cada grupo. Las anomalías clasificadas fueron: ritmo normal (NOR), arritmias (ARR), ritmo sinusal (RHY), acha cardíaca (CAX), hipertrofia (HYP) e infarto al miocardio (IMY); obteniendo como resultados porcentajes entre el 75 y 90 % de evaluaciones correctas en las distintas clases.




Figura 3.1: Triángulo de Einthoven (LL-pierna izquierda, LA-brazo izquierdo y RA-brazo derecho), utilizado para analizar las derivaciones de un ECG [Padrón98].


| Anomalía | RNA     | Pesos<br>W1-W2 | Número<br>Bias | Épocas<br>o Iter | ECG<br>evals | Sum Q<br>Error | Diag. Produ<br>TS-ES( %) | Malclasificados |   |   |   |   |
|----------|---------|----------------|----------------|------------------|--------------|----------------|--------------------------|-----------------|---|---|---|---|
|          |         |                |                |                  |              |                |                          | N               | A | R | C | H |
| NOR      | 10-15-6 | 1515-150       | 107            | 137              | 86           | 0.098          | 100-90                   | -               | x | x | x | x |
| ARR      | 10-15-6 | 1515-150       | 107            | 89               | 75           | 0.093          | 100-80                   | -               | x | x | x | x |
| RHY      | 10-15-6 | 1515-150       | 107            | 152              | 68           | 0.098          | 100-80                   | x               | - | x | x |   |
| CAX      | 10-15-6 | 1515-150       | 107            | 195              | 64           | 0.099          | 100-75                   | x               | x | - | x |   |
| HYP      | 10-15-6 | 1515-150       | 107            | 75               | 55           | 0.095          | 100-80                   | x               | x | x | - |   |
| IMY      | 10-15-6 | 1515-150       | 107            | 106              | 52           | 0.095          | 100-90                   |                 | x | x | - |   |

Tabla 3.1: Arquitecturas y resultados utilizados [Padrón98].

Villagrán y Pradenas en su trabajo de tesis [Villagrán17] realizaron una clasificación de latidos a partir de ECG, utilizando la base de datos MIT-BIH, implementaron cuatro arquitecturas de redes neuronales convolucionales, logrando exactitudes del 93.2 %, 93.7 %, 94.4 % y 94.0 %. El proceso consistió en cuatro etapas:


- **Preprocesamiento**, se atenuaron dos tipos de ruido: **desplazamiento de**

**línea base**, para que los valores de amplitud se centren en cero, utilizando un filtro de media móvil simple, con ventana móvil de tamaño correspondiente al doble de la frecuencia de muestreo, en la Figura 3.2b se puede observar el desplazamiento del registro 101; y **ruido electromagnético de la red eléctrica**, eliminando la presencia de ruido de 60 Hz mediante un filtro FIR rechaza banda orden 180 con una ventana de tipo Kaiser [Villagrán17] con rango de atenuación de frecuencias entre 59 y 61 Hz, la Figura 3.2c muestra la señal procesada.



(a) Señal original.

(b) Filtrada en línea base.



(c) Filtrada en línea base y ruido.

Figura 3.2: Señal del registro 101 durante el preprocesamiento para su filtración [Villagrán17].

- **Segmentación de latidos**, se segmentó la señal en trozos de 360 muestras (1s) con el complejo QRS en el centro, para obtener latidos individuales.
- **Estructura de datos**. La estructura de los datos fue establecida como un arreglo de tres dimensiones, la primera dimensión corresponde al número de latidos, la segunda a las muestras de cada latido y la tercera al número de canales (2 canales), además de incluir un arreglo unidimensional con las etiquetas de cada latido con valores numéricos.
- **Clasificación**, se diseñaron cuatro estructuras de redes neuronales convolucionales mediante la librería de Tensorflow, con función de activación ReLU. El remuestreo (reshape) en todos los casos se realizó con los parámetros: -1, frecuencia de muestreo, 1, número de canales. Las redes utilizadas fueron:
  - *Estructura 1 (CNN1F)*: Con 2 capas convolucionales (25 filtros tamaño 3x3 y 15 filtros tamaño 6x6 y normalización de datos en cada una) y dos capas densas (con 75 y 5 neuronas), con 3 épocas de entrenamiento.
  - *Estructura 2 (CNN2F)*: Con 3 capas convolucionales (20, 15 y 10 filtros, normalización y pooling en cada una) y 2 capas densas (con 75 neuronas cada una ), con 4 épocas de entrenamiento.
  - *Estructura 3 (CNN3F)*: Con 5 capas convolucionales (con 20 filtros tamaño 10, 10 tamaño 3, 15 tamaño 6, 15 tamaño 3 y 10 filtros tamaño 3), 3 capas densas ( con 80, 40 y 5 neuronas), normalización, con 9 épocas de entrenamiento.
  - *Estructura 4 (CNN4F)*: Con 6 capas convolucionales (con 20 filtros tamaño 10, 10 filtros tamaño 5, 15 tamaño 4, 10 tamaño 5, 8 tamaño 3, 5 tamaño 3, con pooling cada 2 capas, 3 capas densas (con 64, 48 y 32 neuronas), con 9 épocas de entrenamiento.

Basándose en las Redes Neuronales Convolucionales, Andreotti y Carr [Andreotti17] clasificaron segmentos de ECG en cuatro clases (fibrilación atrial, latido normal, otras arritmias y ruido) con una CNN 1D. Su base de datos consistió de 8,528 segmentos

de ECG obtenidos de distintas bases de AF Physionet, el proceso consistió en:

- **Preprocesamiento**, filtrando las señales con un filtro pasabanda Butterworth de orden 10 para después utilizar cuatro detectores de QRS (gqrs, Pan-Tompkins, detección de máximos y coincidencias de filtración).
- **Extracción de características**, de cada QRS se extrajeron características de actividad atrial y ventricular, de QRS y algunas morfológicas como la onda P y la QT.
- **Clasificación**, los modelos propuestos fueron desarrollados en base a la arquitectura ResNet [He16], entre los experimentos se utilizaron las señales sin segmentar, segmentación de 10 segundos con un traslape del 50 %, segmentación de 30 y 60 segundos y filtración de ruido, obteniendo como mejor resultado la segmentación de 60s y 16 filtros convolucionales con un 83 % de exactitud, como se puede observar en la Tabla 3.2, esta tabla muestra en la primer columna la descripción de la red neuronal a utilizar, junto con algunas características como el segmentado y filtrado; la segunda columna menciona la base de datos que se utilizan, seguido de los porcentajes de validación del entrenamiento para cada clase y para el conjunto total; por último se muestran los porcentajes obtenidos como resultado de la prueba para cada clase y el conjunto total.

| Descripción                              | Validación en el Entrenamiento (%) |      |      |      |      |       | Resultados de TEST-DB (%) |           |           |           |
|------------------------------------------|------------------------------------|------|------|------|------|-------|---------------------------|-----------|-----------|-----------|
|                                          | Set                                | N    | A    | O    | ~    | Total | N                         | A         | O         | Total     |
| Características (no segmentado)          | TRAIN-DB                           | 90.6 | 72.1 | 74.8 | 50.5 | 72.0  | 89                        | 80        | 69        | 79        |
| Características (segmentos de 10s)       | TRAIN-BD                           | 89.9 | 76.8 | 73.7 | 66.0 | 76.6  | 90                        | 77        | 68        | 79        |
| REsNet (original 34L, 30s SEG)           | AUG-BD                             | 90.2 | 65.7 | 69.8 | 64.0 | 72.4  | n.a.                      | n.a.      | n.a.      | n.a.      |
| ResNet (16 CF, 60s SEG)                  | TRAIN-DB                           | 82.6 | 46.6 | 60.0 | 60.2 | 62.4  | 92                        | 70        | 75        | 79        |
| ResNet (16 CF, 60s SEG)                  | AUG-BD                             | 88.5 | 67.7 | 66.6 | 65.6 | 72.1  | <u>93</u>                 | <u>78</u> | <u>78</u> | <u>83</u> |
| ResNet (16 CF, 34 L, 30s SEG, sin ruido) | AUG-BD                             | 89.6 | 65.3 | 69.1 | 0.0  | 56.0  | 71                        | 41        | 43        | 52        |

Tabla 3.2: Arquitecturas y resultados obtenidos [Andreotti17].

Por otra parte, Liu en su trabajo [Liu18] busca la detección de infartos al miocardio; considerando complicado mantener la generalización al momento de elegir características de manera “manual” hace uso del aprendizaje profundo mediante una

método de múltiple rama de característica (MFB-CNN) [Liu18] para la clasificación de 6 clases utilizando las 12 variaciones de un ECG. Todas las señales fueron segmentadas mediante la detección de curva QRS (usando el algoritmo Pan-Tompkins), cada segmento contiene 600 muestras incluyendo 199 antes y 400 después del pico QRS y centrando la línea base; una vez realizado el preprocesamiento, la extracción de características se utiliza tres capas convolucionales 1D con función de activación ReLU, tres capas pooling con media obteniendo un vector de 12 vectores de características (uno por variación, Figura 3.3), obteniendo un porcentaje de exactitud promedio del 98.79 %.




Figura 3.3: Algoritmo utilizado para la clasificación de 6 clases con sus 12 variaciones, pasando por la segmentación, filtración de línea base y extracción de características con 3 capas convolucionales 1D [Liu18].

Özal Yildirim, et al [Yildirim18] presentan una CNN 1D para detectar 17 clases de arritmias de la base de datos MIT-BIH Arrhythmia, tomando segmentos de 10 segundos sin traslape (no necesariamente un complejo QRS) que es el tiempo típico para obtener el ritmo cardiaco. Los pasos fueron:

- **Preprocesamiento:** las señales son reescaladas a un rango de  $[-1, 1]$  y estandarizándolas para utilizar fragmentos de 128 muestras.
- **Conjuntos:** Se realizaron 3 conjuntos distintos: el primero de ellos consta de 17 clases correspondientes a los 15 tipos de arritmia, ritmo normal y ritmo con marcapasos; para el segundo conjunto fueron removidas las clases de fusión entre latido normal y ventricular y la taquicardia supraventricular; mientras que para el tercer conjunto se removieron las dos clases anteriores y las clases de taquicardi ventricular y contracción ventricular prematura. Las clases que se fueron eliminando en los conjuntos son los que presentan menor porcentaje en los resultados, esto con el fin de obtener mejores rendimientos.
- **Clasificación** se utiliza una CNN de 16 capas como se muestra en la Figura 3.4, con 50 épocas de entrenamiento. Los resultados obtenidos para la clasificación de 13 clases fueron del 95.2%, para 15 clases del 92.51% y para 17 clases del 91.33% de exactitud.




Figura 3.4: Arquitectura de CNN utilizada para clasificar 17 clases, consta de 16 capas y 50 épocas de entrenamiento [Yildirim18].

Ali Sellami y Heasoo Hwang [Sellami18] presentan una CNN, para clasificar 5 clases distintas de latidos para detección de arritmias utilizando la base de datos MIT-BIH bajo un esquema interpaciente con los conjuntos utilizados [Villagrán17]. Se utilizaron segmentos de 170 muestras, 70 antes del pico R y 100 después (el pico R se determina mediante el algoritmo Pan-Tompkins), para balancear las clases de

agregaron datos extra, mientras que la arquitectura de la CNN se muestra en la Figura 3.5, obteniendo un porcentaje de exactitud del 99.79%.




Figura 3.5: Arquitectura de CNN 1D utilizada para la clasificación de 5 clases con señales segmentadas por latidos [Sellami18].

Pasando a las CNN 2D Wang [Wang21] presentan en su trabajo haciendo uso de una CNN 2D, la Transformada Wavelet Continua (CWT), la base de datos MIT-BIH y el paradigma interpaciente. Su proceso, se observa en la Figura 3.6, el cual consiste en:

- **Preprocesamiento:** se realiza la eliminación de ruido con dos filtros de mediana, una vez filtrada se segmenta en latidos con 90 muestras antes del pico

R y 110 después, el siguiente paso es pasar la señal al dominio de la frecuencia utilizando la CWT obteniendo un escalograma por señal.

- **Clasificación:** se desarrolla una CNN a la que se le dan los escalogramas obtenidos e información sobre los intervalos RR de los segmentos, la estructura de la CNN se muestra en la Figura 3.7 con función de activación ReLU
- **Resultados:** muestran porcentajes de exactitud entre el 98.74 y el 99.27 %, resultados obtenidos con la wavelet madre Gaussiana (gaus4) [Wang21].




Figura 3.6: Proceso realizado por Wang utilizando una CNN 2D y CWT para señales segmentadas en latidos [Wang21].




Figura 3.7: Arquitectura de la CNN utilizada para la clasificación de escalogramas de latidos previamente preprocesados [Wang21].

Por otra parte, Al Rahhal [Al Rahhal18] propone la detección de arritmias utilizando una CNN con imágenes RGB utilizando las bases de datos MIT-BIH arrhythmia, INCART y SVDB. El proceso constó de:

- **Preprocesamiento** para reducción de ruido, corrección de línea base y un submuestreo de segmentos con 50 muestras, una vez realizado esto se convierten las señales en imágenes utilizando la Transformada Continua Wavelet (CWT) Db4, Brior3.5 y Coif 3.
- **Extracción de características**, utilizando las imágenes RGB de la CWT para una mejor localización de de las componentes de frecuencia, estas imágenes son dadas a una CNN modelo VGGNet de 8 capas, 5 convolucionales ( $96 \times 7 \times 7$ ,  $256 \times 5 \times 5$ ,  $512 \times 3 \times 3$ ,  $512 \times 3 \times 3$  y  $512 \times 3 \times 3$ ) con función de activación ReLU, normalización y pooling (Figura 3.8).
- **Clasificación**, agregando una capa oculta y una función sigmoid. El estudio obtuvo resultados mayores del 98 % de exactitud, según menciona el autor en [Al Rahhal18].




Figura 3.8: Ejemplo de CNN para la clase V, haciendo uso de escalogramas con 3 funciones madre distintas de segmentos de 50 muestras [Al Rahhal18].

Tae Joon Jun junto con sus compañeros [Jun18], desarrollaron una CNN 2D, transformando cada latido del ECG en una imagen en escala de grises con la base de

datos MIT-BIH arrhythmia y clasificando ocho clases distintas. Su trabajo consta de transformar cada señal en imágenes de  $128 \times 128$  en escala de grises, sin necesidad de segmentar en exactamente un latido, pero con el pico de la curva Q centrado y sin un procesamiento previo como se muestra en la Figura 3.9; para balancear las clases con la de latidos normales se hicieron nueve cortes distintos de un mismo segmento 3.10, obteniendo 100,000 imágenes de la base de datos. La razón por la que se utilizó este preprocesamiento y una CNN 2D, como la mostrada en la figura 3.11, es porque se acerca más al proceso de diagnóstico físico, dicha CNN utiliza el kernel de activación Xavier en donde los pesos se inicializan aleatoriamente en el rango:

$$x = \frac{\sqrt{6}}{In + Out}; [-x, x] \quad (3.1)$$

donde  $In$  y  $Out$  son el número de entradas y salidas en los pesos del kernel. Además de utilizar la función de activación Unidad Lineal Exponencial (ELU), cuidando la normalización y optimizada con la función Adam logrando como resultado el 99.05 % de exactitud [Jun18].




Figura 3.9: Ejemplo de imágenes en escala de gris obtenidas tras la segmentación de ECG de las 8 clases distintas con la curva Q centrada pero sin ser exactamente un latido y sin procesamiento previo [Jun18].




Figura 3.10: Distintos cortes realizados a una señal PVC para nivelación de clases obteniendo imágenes de  $128 \times 128$ [Jun18].




Figura 3.11: Arquitectura de la CNN utilizada para clasificar imágenes  $128 \times 128$  en escala de grises [Jun18].

Mathunjwa, et al [Mathunjwa22] proponen en su trabajo una clasificación de 6 clases de arritmias (bases de datos de PhysioNet) en dos etapas (Figura 3.12), la primera etapa detecta fibrilación ventricular y ruido (arquitectura ResNet18), mientras que la segunda etapa se encarga de la detección de latidos normales, fibrilación auricular, contracción prematura ventricular y auricular (arquitectura ResNet), evaluadas usando 5-fold cross-validation. Los pasos a seguir fueron:

- **Preprocesamiento:** las señales son segmentadas cada 2s y convertidas en imágenes mostrando su RP (herramienta que permite observar la recurrencia de las trayectorias espaciales en sólo dos dimensiones), cuando una señal pasa a la segunda etapa se realiza una detección del pico R y una nueva segmentación como segundo preprocesamiento; para la clasificación.
- **Clasificación** se utilizaron las redes neuronales residuales mencionadas anteriormente (ResNet-18 para la primera etapa y ResNet-50 para la segunda, las cuales se muestran en la Figura 3.13); obteniendo como resultado porcentajes entre 94.85 y 98.36 % de exactitud, respectivamente, según se menciona en [Mathunjwa22].





Figura 3.12: Proceso de clasificación de 6 clases de arritmias en dos etapas, la primera detecta fibrilación ventricular y ruido, y la segunda latidos normales, fibrilación auricular, contracción prematura ventricular y auricular [Mathunjwa22].



En el trabajo presentado por Hiren Mewada [Mewada22], se propone la clasificación mediante una CNN-2D haciendo uso de la información espectral de las señales, cuatro clases finales y la base de datos MIT-BIH. Su proceso constó de:

- **Preprocesamiento:** consta de una segmentación de 300 muestras, filtración de las señales para eliminación de ruido y conversión a una imagen 2D utilizando la Transformada Discreta Wavelet (DWT) Haar con tres niveles de descomposición.
- **Clasificación** y conversión se utiliza la arquitectura mostrada en la Figura 3.14; esta propuesta dió resultados de 99.52 % de exactitud, según se menciona en [Mewada22].




Figura 3.14: Arquitectura de descomposición y clasificación haciendo uso de la información espectral de las señales para obtener 4 clases finales[Mewada22].

Naz et al. [Naz21] realizaron un programa para la detección de arritmias ventriculares a partir de imágenes obtenidas de ECG de la base de datos MIT-BIH. El proceso constó de:

- **Preprocesamiento:** cada paciente cuenta con 127,356 valores en su ECG de los cuales se eliminan los últimos 380 valores ya que no presentan ningún rol en la señal. Los 126,976 valores restantes se dividen en series de 124 segmentos, con 1024 valores cada uno, para después convertirlos en matrices de 32x32 y finalmente en imágenes binarias.
- **Extracción de Características** por medio de tres modelos de CNN pre-entrenados (VGG19, AlexNet e Inception-v3), para lo cual se redimensionan las imágenes a 3D según sea cada CNN, fusionan las características obtenidas en cada red.
- **Clasificación** mediante la reducción de características basada en entropía, el proceso completo se muestra en la Figura 3.15, haciendo uso de distintos clasificadores.
- **Resultados:** el resultado obtenido con la base de datos MIT-BIH es de 97.6 % de exactitud utilizando una Máquina de Soporte Vectorial Cúbica como clasificador final, mencionado por Naz [Naz21].




Figura 3.15: Proceso de identificación de arritmias ventriculares mediante imágenes binarias de dimensiones  $32 \times 32$  utilizando los modelos VGG19, AlexNet e Inception-V3 [Naz21].

### 3.1. Conclusiones

Existen numerosas investigaciones alrededor del mundo sobre el desarrollo de clasificadores de enfermedades cardíacas mediante ECG, algunas de ellas se basan en la segmentación latido por latido de la señal, otros en segmentaciones por tiempo de la señal; por un lado, se encuentran los que buscan la mejor serie de características para una extracción previa y los que convierten el problema en una clasificación de imágenes. Todos estos mostrando buenos resultados.

El uso de CNN se ha convertido en un método novedoso en el cual la extracción

de características deja de ser el principal problema al momento de la clasificación. Sin embargo, para el uso de CNN en segunda dimensión, la búsqueda de la imagen que mejor represente a la clase se convierte en el principal trabajo, teniendo como propuestas de algunos autores imágenes directas del ECG, recurrencia de trayectoria, escalogramas e imágenes binarias.

## Capítulo 4

# Implementación del Diagnosticador

Buscando diagnosticar enfermedades cardíacas mediante señales de ECG en forma de imágenes, se desarrollan dos clasificadores basados en redes neuronales convolucionales 2D. Conforme a lo mencionado en el Capítulo 2.4.1, la CNN 2D se trata de la red más popular y con mejores resultados para datos con topología de matriz. Para esto se hace uso de 10 segundos de distintos ECG, este rango de tiempo es considerado debido a que en él podemos observar el patrón de comportamiento que posee el ritmo cardíaco teniendo una cantidad considerable de muestras.

La lectura de la base de datos se presenta como se muestra en la Figura 4.1, con una grabación de 30 segundos de un paciente con condición normal y la Figura 4.2 con 10 segundos de la misma grabación. Estas gráficas muestran dos curvas, la color azul correspondiente a la derivación MLII y en color naranja la derivación V5, los puntos rojos en la gráfica señala la posición de cada pico R del ECG, mientras que entre la curva y los puntos rojos se encuentran las etiquetas de cada uno de los latidos de la grabación estas etiquetas se detallan más adelante en la Tabla 5.1. En la Figura 4.1 se muestra que en 30 segundos posee alrededor de 37 picos R correspondiente a 37 latidos, mientras que en la Figura 4.2 se observa que con mayor claridad 13 picos R.

En el presente trabajo se realizan dos conversiones distintas de señal 1D a 2D.




Figura 4.1: Gráfica de 30 segundos de ECG con condición normal, en color naranja se observa la derivación V5, mientras que en azul la MLII, los puntos rojos representan la presencia de un pico R con la etiqueta correspondiente al tipo de latido.




Figura 4.2: Gráfica de 10 segundos de ECG con condición normal, se observa la señal de manera más detallada.

La primera de ellas se trata de un arreglo de los valores de la señal en una matriz cuadrada, en la que cada valor corresponde a un pixel de la imagen, obteniendo así una imagen en escala de grises; mientras que la segunda red clasifica los escalogramas que se obtienen de los mismos segmentos de las señales, reduciendo la resolución para reducir el costo del clasificador. Estos dos procesos se explican a continuación de manera detallada.

## 4.1. Imagen en Escala de Grises

Como se menciona anteriormente, las señales utilizadas son segmentos de 10 segundos de distintos ECG's, considerando una frecuencia de muestreo de 360Hz se manejan 3600 muestras por segmento, que son sometidos a un procesamiento para su conversión a una imagen y posteriormente su clasificación.

### 4.1.1. Preprocesamiento

Para obtener una imagen en escala de grises que represente a la señal se realizan los siguientes pasos:

1. Las 3600 muestras son sometidas a un cambio de rango a  $[0, 255]$ , para esto se busca el valor mínimo y el máximo, y se les asigna el valor de 0 y 255 respectivamente, haciendo uso de la ecuación:

$$G[i] = \left[ \frac{g_{max} - g_{min}}{f_{max} - f_{min}} (F[i] - f_{min}) \right] + g_{min} \quad (4.1)$$

en donde:

$$F \equiv \text{arreglo de la señal}$$

$$f_{min} \equiv \text{valor mínimo del arreglo}$$

$$f_{max} \equiv \text{valor máximo del arreglo}$$

$$g_{min} = 0$$

$$g_{max} = 255$$

2. Una vez que el rango fue cambiado se construye una matriz cuadrada  $60 \times 60$ , en donde la señal se parte en 60 renglones de 60 muestras cada uno y cada valor corresponde a un pixel de la imagen, tal como se muestra en la continuación:

$$[g_0, g_1, g_2, \dots, g_{3599}] = \begin{pmatrix} g_0 & g_1 & g_2 & \dots & g_{59} \\ g_{60} & g_{61} & g_{62} & \dots & g_{119} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ g_{3540} & g_{3541} & g_{3542} & \dots & g_{3599} \end{pmatrix}$$

Las dimensiones se tomaron con referencia a Naz [Naz21] y Mewada [Mewada22], quienes recomiendan el uso de matrices cuadradas. Un ejemplo de esta construcción se muestra en la Figura 4.3 comenzando con la gráfica de la señal, en la siguiente el arreglo de los valores de dicha señal, mientras que la tercera muestra el valor mínimo y máximo de dicho arreglo y su cambio de rango para finalmente obtener la matriz y la imagen final, esta señal corresponde al registro 209 de la base de datos MIT-BIH Arrhythmia.

#### 4.1.2. CNN

La CNN desarrollada consta de distintas etapas apiladas secuencialmente, esta implementación se realiza con apoyo de la librería *Keras* [TensorFlowCore22] en lenguaje Python. La estructura de la red consta de once capas entre las que se encuentran: capas Convolucionales 2D, encargadas de la extracción de características; MaxPooling, cuyo trabajo es la reducción de tamaño para evitar problemas durante la extracción; Dropout, para deshechar los pesos no significativos de la matriz; Flatten, encargadas del aplanamiento de las matrices; y capas Densas para llegar a la clasificación.

En la Tabla 4.1 se pueden observar cada una de las capas de la CNN con los hiperparámetros utilizados, estos hiperparámetros fueron determinado de manera experimental, a prueba y error, realizando variaciones hasta encontrar el mejor resultado en la evaluación de la red.




Figura 4.3: Proceso de conversión de una señal a imagen en escala de grises, pasando la señal a una imagen de dimensiones  $60 \times 60$ .

La primera capa se trata de una capa **Convolutional 2D** con 32 filtros y tamaño  $5 \times 5$  para comenzar con la extracción de características, seguida de una capa **MaxPooling** de tamaño  $2 \times 2$  para reducir el tamaño; las siguientes dos capas se dan repitiendo las anteriores para continuar la extracción de características; en la capa 5, correspondiente a una convolutional, se reduce el tamaño para obtener más detalles en la extracción, seguida nuevamente de una capa Maxpooling; continúa con una capa **Dropout** para deshechar los pesos no significativos de la matriz extraída hasta el momento; le sigue una capa **Flatten** encargada de aplanar la entrada para poder seguir con las capas densas; la primera capa **Densa** tiene 8,192 neuronas completamente conectadas y con función de activación ReLu, encargada del aprendizaje de las características anteriormente encontradas; continúa otra capa Dropout y finalmente una

capa densa con función **SoftMax** con 6 filtros encargada de la clasificación.


El entrenamiento se da con nueve épocas y un tamaño de lote de 200, estos dos parámetros también fueron encontrados de manera experimental.

| Capa           | Hiperparámetros      |                                 |                     |
|----------------|----------------------|---------------------------------|---------------------|
| Conv2D         | Filtros: 32          | Tamaño de filtros: $5 \times 5$ | Activación: ReLu    |
| MaxPooling2D   | Tamaño: $2 \times 2$ |                                 |                     |
| Conv2D         | Filtros: 32          | Tamaño de filtros: $5 \times 5$ | Activación: ReLu    |
| MaxPooling2D   | Tamaño: $2 \times 2$ |                                 |                     |
| Conv2D         | Filtros: 32          | Tamaño de filtros: $3 \times 3$ | Activación: ReLu    |
| MaxPooling2D   | Tamaño: $2 \times 2$ |                                 |                     |
| Dropout        | 0.5                  |                                 |                     |
| Flatten        | -                    |                                 |                     |
| Dense          | Neuronas: 8,192      |                                 | Activación: ReLu    |
| Dropout        | 0.5                  |                                 |                     |
| Dense          | Neuronas: 6          |                                 | Activación: SoftMax |
| Épocas         | 9                    |                                 |                     |
| Tamaño de lote | 200                  |                                 |                     |


Tabla 4.1: Hiperparámetros de la red neuronal para imágenes en escala de grises.

## 4.2. Escalograma


Al igual que en el clasificador anterior se utilizan segmentos de 10 segundos de señales de ECG, sin embargo, durante el preprocesamiento se obtienen escalogramas para utilizar durante la clasificación. La Transformada Wavelet se lleva a cabo utilizando la librería **PyWavelets** [Lee19], dentro de esta librería se tienen distintas funciones como Sombrero Mexicano, Morlet, Morlet Compleja, Gaussiana, Gaussiana Compleja, Shannon y B-Spline. Las Figuras 4.4 y ?? muestran los escalogramas, de un mismo segmento de ECG, aplicando las funciones mencionadas. La imagen visualmente más nítida, es decir, en la que se diferencian las características de manera más clara, es la obtenida con la función Morlet Compleja, observada en la Figura 4.4c, es por esto que se hace uso de ella en el clasificador.




(a) Sombrero Mexicano.




(b) Morlet.




(c) Morlet compleja.



(d) Gaussiana.



(e) Gaussiana compleja.



(f) Shannon.

Figura 4.4: Escalogramas de una señal con condición normal con distintas funciones para Transformada Wavelet.




Figura 4.5: Escalograma de una señal con condición normal con función B-Spline.

#### 4.2.1. Preprocesamiento

Para obtener la imagen se llevan a cabo los siguientes pasos:

1. Se aplica la Transformada Wavelet con la función Compleja Morlet, también conocida como CMOR:

$$\psi(t) = \frac{1}{\sqrt{\pi B}} \exp\left(-\frac{t^2}{B}\right) \exp(j2\pi Ct)$$

en donde:  $B = 1.5$  representa el ancho de banda y  $C = 1.0$  el centro de frecuencia. Obteniendo una matriz de  $99 \times 3599$ .

2. Se baja la resolución del escalograma a un noveno del total de columnas, esto para evitar problemas de memoria durante el entrenamiento del clasificador.

La Figura 4.6 muestra un ejemplo de la creación y reducción de un escalograma utilizado, en ella se puede observar la gráfica del segmento de ECG a utilizar, seguido de su escalograma utilizando una escala logarítmica, el escalograma con sus valores originales y finalmente el escalograma obtenido a partir de la reducción del conjunto original, se trata de una matriz de  $99 \times 400$  pixeles.




Figura 4.6: Creación y reducción a un noveno de datos de escalograma a partir de una señal de 10 segundos.

#### 4.2.2. CNN

Para este clasificador se desarrolla una CNN 2D compuesta de 13 capas, entre las que se encuentran capas convolucionales, MaxPooling y capas densas detalladas en la Tabla 4.2, estos parámetros fueron determinados de manera experimental.

Se trata de dos capas **Convolucionales 2D** con 32 filtros de tamaño  $5 \times 5$  encargadas de comenzar a obtener las características, cada una de ellas con función de activación ReLu y seguida de una capa **MaxPooling** de tamaño  $2 \times 2$  para reducir el tamaño; para obtener características más detalladas se colocan dos capas convolucionales de 32 filtros pero en esta ocasión de tamaño  $3 \times 3$ , de igual manera,

cada una de ellas con su respectiva capa MaxPooling; a continuación se tiene una capa **Dropout** para eliminar los pesos no significativos; la capa 10 se trata de una capa **Flatten** que reduce la dimensión de las características; para el aprendizaje de las características se cuenta con una capa **densa** con 8,192 neuronas y función de activación ReLu acompañada de una capa Dropout para finalmente pasar por la asignación de clase mediante una capa densa de seis neuronas y función de activación **SoftMax**.

El entrenamiento del clasificador se realiza mediante 10 épocas y un tamaño de lote de 200, ambos parámetros obtenidos de igual manera mediante experimentación.

| Capa         | Hiperparámetros      |                                 |                     |
|--------------|----------------------|---------------------------------|---------------------|
| Conv2D       | Filtros: 32          | Tamaño de filtros: $5 \times 5$ | Activación: ReLu    |
| MaxPooling2D | Tamaño: $2 \times 2$ |                                 |                     |
| Conv2D       | Filtros: 32          | Tamaño de filtros: $5 \times 5$ | Activación: ReLu    |
| MaxPooling2D | Tamaño: $2 \times 2$ |                                 |                     |
| Conv2D       | Filtros: 32          | Tamaño de filtros: $3 \times 3$ | Activación: ReLu    |
| MaxPooling2D | Tamaño: $2 \times 2$ |                                 |                     |
| Conv2D       | Filtros: 32          | Tamaño de filtros: $3 \times 3$ | Activación: ReLu    |
| MaxPooling2D | Tamaño: $2 \times 2$ |                                 |                     |
| Dropout      | 0.5                  |                                 |                     |
| Flatten      | -                    |                                 |                     |
| Dense        | Neuronas: 8,192      |                                 | Activación: ReLu    |
| Dropout      | 0.5                  |                                 |                     |
| Dense        | Neuronas: 6          |                                 | Activación: SoftMax |
| Épocas       | 10                   |                                 |                     |
| Tamaño lote  | 200                  |                                 |                     |

Tabla 4.2: Hiperparámetros de la red neuronal para escalogramas.

### 4.3. Conclusiones

Como conclusión, los modelos propuestos no necesitan de una extracción previa de características, ayudando así a disminuir el trabajo de preprocesamiento. Además es posible trabajar con cualquier segmento del ECG, lo que evita también el trabajo de segmentar específicamente con latido. En este caso se usa un segmento de 1o segundos, equivalente a 3,600 muestras y aproximadamente 13 picos Q.

La creación de las imágenes de basa, en el caso número uno, en pasar una señal 1D de 3,600 muestras a una matriz cuadrada  $60 \times 60$ , mientras que en el caso dos el cálculo de la Transformada Wavelet con función Morlet Compleja y para el uso de su escalograma. La base de datos a utilizar y los resultados se muestran en el siguiente capítulo.

## Capítulo 5

# Pruebas y Resultados

### 5.1. Base de Datos

Una de las bases de datos más utilizadas para la clasificación de arritmias es la MIT-BIH Arrhythmia [Moddy01], obtenida la página Physionet [Goldberger00]. Los registros fueron obtenidos por el Laboratorio de Arritmia del Hospital Beth Israel entre 1975 y 1979. La base de datos cuenta con 48 registros, con una duración de poco más de 30 minutos, de los cuales aproximadamente el 60% se obtuvo de pacientes hospitalizados. Las señales fueron tomadas de 25 hombres entre 32 y 89 años y 22 mujeres entre 23 y 89 años, La tabla se puede observar en el Apéndice A. Dicha tabla presenta el número de registro del paciente, su sexo, edad, las derivaciones utilizadas en el ECG y el tipo de ritmo y latido que posee.

La mayoría de los registros tienen como señal superior, aquella que proviene de una derivación de extremidad, a la derivación MLII, y como inferior, la que proviene de una derivación de pecho, alguna derivación modificada V (V1, V2, V5 y en un caso V4). En la Figura 5.1 se observa en color azul la gráfica de la señal superior, derivación MLII; mientras que en color naranja se encuentra la señal inferior, derivación V5.

Esta configuración (derivaciones MLII y V) es la que se utiliza usualmente en los laboratorios de arritmias BIH debido a que en la señal superior los complejos QRS

normales son más prominentes, mientras que en la señal inferior los latidos normales son difíciles de distinguir pero los latidos no normales suelen ser más prominentes. La misma base de datos oficial [Goldberger00] muestra una clasificación por latidos de cada registro, como se muestra en la Tabla B.1, en esta tabla se puede observar el número de registro en la primera columna, mientras que en las posteriores se encuentra el tipo de ritmo con una subdivisión de los tipos de latido; los símbolos de cada tipo, con su respectivo significado, de encuentran en la Tabla 5.1. De esta manera el registro 100 posee 2,239 latidos normales y 33 latidos auriculares prematuros, que entran dentro de un ritmo normal, así como un latido con contracción ventricular prematura, siendo el único que no es considerado normal.




Figura 5.1: Gráfica de 10 segundos la señal 100 de la base de datos MIH-BIH con condición normal, la curva azul corresponde a la derivación MLII y la naranja a V5.

| Símbolo   | Descripción                                           |
|-----------|-------------------------------------------------------|
| ' , . o N | Ritmo normal                                          |
| L         | Latido de bloqueo de rama izquierda                   |
| R         | Latido de bloqueo de rama derecha                     |
| A         | Latido auricular prematuro                            |
| a         | Latido prematuro auricular aberrado                   |
| j         | Latido prematuro nodal (de la unión)                  |
| S         | Latido prematuro supraventricular                     |
| V         | Contracción ventricular prematura                     |
| F         | Fusión de latido ventricular y normal                 |
| e         | Latido de escape auricular                            |
| j         | Latido de escape nodal (de la unión)                  |
| n         | Latido de escape supraventricular (auricular o nodal) |
| E         | Latido de escape ventricular                          |
| /         | Ritmo acelerado                                       |
| f         | Fusión de ritmo acelerado y normal                    |
| Q         | Latido inclasificable                                 |
| ?         | Latido no clasificado durante el aprendizaje          |

Tabla 5.1: Símbolos de los distintos tipos de latidos [Goldberger00]

### Observaciones:

Sólo 2 registros no tienen derivación MLII (102 y 104) debido a que los pacientes tenían apósitos quirúrgicos y la 114 la tiene como segunda derivación debido a que es el único caso en que la V es superior, pero no hay relación entre ellas. En cuanto a la segunda derivación varía entre V1, V2, V4, V5.

Las señales fueron digitalizadas a 360 Hz, esta frecuencia fue elegida para facilitar la implementación de filtros de muesca de 60 Hz, ya que la mayoría del ruido de 60 Hz surgió durante la digitalización.

## 5.2. Clases

Jun [Jun18] realizó una clasificación de registros por enfermedades, según sea el tipo de latidos que posee el paciente, como se muestra en la Tabla 5.2, en ella se

pueden observar como primer columna el tipo de enfermedad, como segunda columna los registros que se identificaron con dicha enfermedad y finalmente el número total de latidos en cada conjunto; las clases son:

- NOR: Normal
- PVC: Premature Ventricular Contraction (contracción ventricular prematura)
- PAB: Paced Beat (latido acompasado)
- RBB: Right Bundle Branch Block Beat (golpe de bloqueo de la rama derecha)
- LBB: Left Bundle Branch Block Beat (golpe de bloqueo de la rama izquierda)
- APC: Atrial Premature Contraction (contracción auricular prematura)
- VFW: Ventricular Flutter Wave (onda de aleteo ventricular)
- VEB: Ventricular Escape Beat (latido de escape ventricular)


dejando fuera las arritmias: latido de aleteo ventricular, fusión de latido acompasado y normal y el no clasificable, debido a que son generalmente ignoradas en los ECG al momento de clasificar arritmias.

| Tipo         | Registros                                                                                | #Latidos      |
|--------------|------------------------------------------------------------------------------------------|---------------|
| NOR          | 100, 101, 103, 105, 108, 112, 113, 114, 115, 117, 121, 122, 123, 202, 205, 219, 230, 234 | 75052         |
| PVC          | 106, 116, 119, 200, 201, 203, 208, 210, 213, 215, 221, 228, 233                          | 7130          |
| PAB          | 102, 104, 107, 217                                                                       | 7028          |
| RBB          | 118, 124, 212, 231                                                                       | 7259          |
| LBB          | 109, 111, 207, 213                                                                       | 8075          |
| APC          | 209, 220, 222, 223, 232                                                                  | 2546          |
| VFW          | 207                                                                                      | 472           |
| VEB          | 207                                                                                      | 106           |
| <b>Total</b> |                                                                                          | <b>106501</b> |


Tabla 5.2: Clasificación de registros por enfermedad [Jun18].

Utilizando la base de datos MIT-BIH Arrhythmia y considerando la clasificación Tabla 5.2 se toman en cuenta seis clases: NOR, PVC, PAB, RBB, LBB y APC, dejando fuera VFW y VEB debido a que sólo poseen un registro. En la Figura 5.2


se observa un ejemplo de registro de cada clase con ambas derivaciones, el color azul representa la señal superior y la naranja la inferior.




(a) Registro 100, clase 1 (NOR).




(b) Registro 116, clase 2 (PVC).




(c) Registro 102, clase 3 (PAB).



(d) Registro 118, clase 4 (RBB).



(e) Registro 109, clase 5 (LBB).




(f) Registro 209, clase 6 (APC).

Figura 5.2: Lectura de 10 segundos de registros de las distintas clases de la base de datos MIT-BIH con sus dos derivaciones.


### 5.3. Conjuntos de Entrenamiento y Prueba

Para formar los conjuntos de entrenamiento y prueba se toma el primer canal de cada registro y se obtienen segmentos de 10 segundos en cada uno de ellos. En la


Figura 5.3 se muestran segmentos de 10 segundos de ECG de las seis clases distintas que se utilizan en el presente trabajo, tomando en cuenta solamente el primer canal, correspondiente a la señal superior.




(a) Registro 100, clase 1 (NOR).




(b) Registro 116, clase 2 (PVC).




(c) Registro 102, clase 3 (PAB).



(d) Registro 118, clase 4 (RBB).



(e) Registro 109, clase 5 (LBB).



(f) Registro 209, clase 6 (APC).

Figura 5.3: Lectura de 10 segundos del primer canal, es decir, la derivación mayor de la base de datos MIT-BIH.

### 5.3.1. Balanceo de clases

Para solucionar el desbalance de las clases, y evitar de esta manera malas predicciones, se busca obtener aproximadamente 2,500 segmentos por cada una, sin embargo, la gran diferencia entre la cantidad de registros evita que se tomen los segmentos de manera continua.

La obtención de dichos segmentos se realiza mediante traslapes en las señales. Buscando la menor pérdida de información se toma como base la clase normal, ya que es la que posee una mayor cantidad de registros, se considera que cada registro posee alrededor de 30 minutos de señal se toman 139 segmentos de manera continua por cada registro, obteniendo un total de 2,502 segmentos.

La clase PVC posee sólo 13 registros de 30 minutos cada uno, lo que significa un total de 234,000 segundos, esto representa 2,340 segmentos obtenidos de manera continua. Para obtener la cantidad deseada se opta por realizar un traslape del 7 % , de esta manera se obtiene un total de 193 segmentos por registro, lo que equivale a 2,509 segmentos para la clase.

Las clases PAB, RBB y LBB tiene sólo 4 registros cada una de ellas, lo que corresponde a 120 minutos y 7,200 segundos, esta cantidad tan pequeña de registros hace que el traslape entre segmentos aumente a un 75 %, obteniendo así 625 segmentos por registro y 2,500 por clase. Finalmente, para la clase APC cuenta con 5 registros, es decir, 9,000 segundos, con un traslape del 70 % se logran obtener 500 segmentos por registro, lo que equivale a 2,500 segmentos totales para la clase.

En la Tabla 5.3, se muestran las distintas clases, cantidad de registros, cantidad de segmentos por registro y los traslapes anteriormente mencionados, en ella se observa que la clase mayoritaria, condición normal, no necesita traslapes, mientras que las clases con menor cantidad de registros, PAB, RBB y LBB, se manejan con un traslape del 75 % en cada segmento.

| Clase | No. de Registros | Muestras por registro | Traslape |
|-------|------------------|-----------------------|----------|
| NOR   | 18               | 139                   | 0 %      |
| PVC   | 13               | 193                   | 7 %      |
| PAB   | 4                | 625                   | 75 %     |
| RBB   | 4                | 625                   | 75 %     |
| LBB   | 4                | 625                   | 75 %     |
| APC   | 5                | 500                   | 70 %     |


Tabla 5.3: Traslapes para equilibrar las clases.

Una vez obtenidos los segmentos necesarios en cada clase se separan en el 80 % para formar el conjunto de entrenamiento, es decir, 2,000 segmentos por clase, mientras que el 20 % forma el conjunto de prueba, sin repetir señales en los conjuntos. Del conjunto de entrenamiento se selecciona el 20 % de datos, 400 segmentos por clase sin repetir ninguno, para conformar el conjunto de validación.


## 5.4. Clasificador Mediante Imágenes en Escala de Grises

La primera prueba se realiza con la CNN explicada en la Sección 4.1, para la cual se utilizan imágenes en escala de grises, la Figura 5.4 muestra un ejemplo de imagen por cada una de las clases consideradas.


La Figura 5.5 muestra el accuracy (exactitud en inglés) y la pérdida obtenidas durante las 9 épocas de entrenamiento y la validación del diagnosticador, obteniendo de esta forma el 0.8863 de accuracy y 0.3756 de pérdida durante el entrenamiento, mientras que para el conjunto de validación el accuracy corresponde a 0.9228 y la pérdida a 0.2353.



(a) Registro 100, clase 1 (NOR). (b) Registro 116, clase 2 (PVC).




(c) Registro 102, clase 3 (PAB). (d) Registro 118, clase 4 (RBB).



(e) Registro 109, clase 5 (LBB). (f) Registro 209, clase 6 (APC).

Figura 5.4: Ejemplos de imágenes en escala de grises de registros de las distintas clases de la base de datos MIT-BIH.



(a) Exactitud.

(b) Pérdida.

Figura 5.5: Gráficas de métricas durante la fase de entrenamiento y validación para imágenes en escala de grises.

Al realizar la evaluación con el conjunto de prueba se obtiene la matriz de confusión mostrada en la Figura 5.6, en la cual las clases se encuentran con etiquetas de números siguiendo el orden mostrado a continuación:

- 0: NOR
- 1: PVC
- 2: PAB
- 3: RBB
- 4: LBB
- 5: APC

La matriz de confusión de la clasificación realizada se muestra en la figura 5.6.

Para continuar con el análisis de dicho clasificador se realiza el cálculo, de las métricas: accuracy (exactitud), definida mediante la Ecuación 5.1; precision (precisión en inglés), definida por la Ecuación 5.5; recall (recuperación en inglés) definida en la Ecuación 5.6; así como F1 cuya definición corresponde a la Ecuación 5.4.




Figura 5.6: Matriz de confusión para la clasificación de imágenes en escala de grises.

$$\begin{aligned}
 \text{Exactitud} &= \frac{\text{Predicciones correctas}}{\text{Total de predicciones}} \\
 &= \frac{(TP + TN)}{(TP + TN + FP + FN)}
 \end{aligned} \tag{5.1}$$

$$\text{Precisión} = \frac{TP}{(TP + FP)} \tag{5.2}$$

$$\text{Recall} = \frac{TP}{(TP + FN)} \tag{5.3}$$

$$F1 = 2 * \frac{(\text{recall} * \text{precision})}{(\text{recall} + \text{precision})} \tag{5.4}$$

Sin embargo, al tratarse de una clasificación de etiquetas múltiples y buscando un análisis general, las métricas precision y recall se realizan con un promedio Micro.

El micro-promedio se trata de una alternativa, para calcular el promedio, en la cual primero se calcula el total de Verdaderos Positivos (TP), Falsos Positivos (FP)

y Falsos Negativos (FN) de todas las clases juntas [EvidentlyAI24], obteniendo las siguientes fórmulas:

$$Precisión_{Micro-promedio} = \frac{TP_0 + TP_1 + \dots + TP_5}{TP_0 + FP_0 + TP_1 + FP_1 + \dots + TP_5 + FP_5} \quad (5.5)$$

$$Recall_{Micro-promedio} = \frac{TP_0 + TP_1 + \dots + TP_5}{TP_0 + FN_0 + TP_1 + FN_1 + \dots + TP_5 + FN_5} \quad (5.6)$$

Este tipo de promedio otorga el mismo peso a cada instancia sin importar la etiqueta y cantidad de casos de la clase, por lo que la vuelve apropiada para clases equilibradas [EvidentlyAI24]. Es importante mencionar que el uso del micro-promedio provoca que el resultado de accuracy, precision y recall sea el mismo.


De esta manera las métricas obtenidas para el primer clasificador es de 0.8863, como se muestra en la Tabla 5.4.

| Métrica   | Valor  |
|-----------|--------|
| Exactitud | 0.8863 |
| Precisión | 0.8863 |
| Recall    | 0.8863 |
| F1        | 0.8863 |


Tabla 5.4: Métricas de clasificador mediante imágenes en escala de grises.

## 5.5. Clasificador Mediante Escalograma


En este caso se hace uso de la CNN mostrada en la Sección 4.2, la cual se encarga de la clasificación de escalogramas. Debido al peso de las imágenes los conjuntos de entrenamiento y prueba se redujeron a la mitad, la Figura 5.7 muestra un ejemplo de escalograma para cada clase utilizadas para la clasificación.




(a) Registro 100, clase 1 (NOR).




(b) Registro 116, clase 2 (PVC).




(c) Registro 102, clase 3 (PAB).



(d) Registro 118, clase 4 (RBB).



(e) Registro 109, clase 5 (LBB).



(f) Registro 209, clase 6 (APC).

Figura 5.7: Ejemplos de escalogramas de registros de las distintas clases de la base de datos MIT-BIH.

La Figura 5.8 muestra las gráficas de accuracy y pérdida durante el proceso de entrenamiento y validación, en las cuales el valor final de accuracy en el entrenamiento es 0.9691, mientras que el de pérdida es 0.0922. De la misma manera el valor de accuracy en la validación corresponde a 0.9758, y el de pérdida 0.0716.




Figura 5.8: Gráficas de métricas durante la fase de entrenamiento y validación para la clasificación de escalogramas.

Una vez realizada la evaluación del clasificador se obtiene la matriz de confusión mostrada en la Figura 5.9, la cual muestra resultados favorables en todas las clases.




Figura 5.9: Matriz de confusión para la clasificación mediante escalogramas.

Siguiendo las Ecuaciones 5.1, 5.5, 5.6 y 5.4, las métricas obtenidas son las mostradas en la Tabla 5.5

| Métrica   | Valor  |
|-----------|--------|
| Exactitud | 0.9465 |
| Precisión | 0.9465 |
| Recall    | 0.9465 |
| F1        | 0.9465 |

Tabla 5.5: Métricas de clasificador mediante escalogramas.

La siguiente tabla 5.6, muestra una comparativa entre los resultados obtenidos en el presente trabajo y los obtenidos por algunos autores. En la primera columna se observa el nombre del autor y cita del artículo consultado, la segunda muestra el tipo de segmentación utilizada, la tercera columna corresponde al método de obtención de las imágenes y por último la cuarta columna hace referencia al accuracy obtenido en porcentaje.

| Autor                      | Segmentación   | Método                       | Accuracy |
|----------------------------|----------------|------------------------------|----------|
| Al Rahal<br>[Al Rahhal18]  | 50 muestras    | CTW Daubechies y Biortogonal | 98 %     |
| Wang [Wang21]              | por latido     | CWT Gaussiana                | 98.74 %  |
| Mathunjwa<br>[Mathunjwa22] | 720 muestras   | Trayectoria espacial         | 98.36 %  |
| Hiren Mewada<br>[Mewada22] | 300 muestras   | DWT Haar                     | 99.53 %  |
| Naz [Naz21]                | 1,024 muestras | imagen binaria               | 97.6 %   |
| Trabajo Propio             | 3,600 muestras | imagen en escala de grises   | 88.63 %  |
| Trabajo Propio             | 3,600 muestras | CTW Morlet Compleja          | 94.65 %  |

Tabla 5.6: Comparación de resultados.

La cantidad de muestras se consideró con el criterio de que a mayor cantidad mejor entrenamiento y menor sobreajuste durante el entrenamiento.

## 5.6. Conclusiones

Las imágenes obtenidas a partir de escalogramas presentan dimensiones notoriamente mayores que las imágenes en escala de grises, teniendo para las primeras un tamaño de  $99 \times 400$ , mientras que en las imágenes en escala de grises de sólo  $60 \times 60$ , por lo que fue necesario reducir el tamaño de los conjuntos de entrenamiento y prueba a sólo la mitad de los elementos y evitar así problemas con la memoria del equipo durante el entrenamiento.

Al momento de evaluar los diagnosticadores la clasificación mediante imágenes en escala de grises presentó una exactitud de 0.8863, mientras que el clasificador de escalogramas una de 0.9465, esto a pesar de la reducción de muestras por imagen y de los conjuntos de entrenamiento y prueba. Otra observación importante es que la clase con mayor dificultad es la misma en ambos casos, la clase PVC, mientras que la mejor clasificada varía en cada uno.

## Capítulo 6

# Conclusiones

Este trabajo tuvo como objetivo la implementación de un diagnosticador de cinco arritmias distintas, haciendo uso de electrocardiogramas, esto mediante el desarrollo de dos clasificadores basados en redes neuronales convolucionales.

### 6.1. Conclusiones Generales

Tomando en cuenta los estudios anteriores se optó por el desarrollo de dos clasificadores de imágenes, para uno de ellos fueron utilizadas imágenes en escala de grises obtenidas de segmentos de señal, mientras que para el segundo se crearon escalogramas de los mismos segmentos.

Através de la creación de imágenes se evitó una extracción de características detallada de manera previa. Además el desbalance de clases fue resuelto aplicando traslapes durante la segmentación, dichos traslapes fueron elegidos tomando en cuenta la cantidad de registros en cada clase, esto para utilizar la mayor cantidad de información.

Al tratarse de clases balanceadas se obtiene que los resultados para las métricas Accuracy, Precision, Recall y F1 es el mismo. Por un lado, para el clasificador a base de imágenes en tono de grises da como resultado un accuracy de 0.8863, presentando

mayor dificultad con clase PVC y mientras que las mejores reconocidas fueron LBB y PAB.

Por otro lado, el clasificador mediante escalogramas tuvo un accuracy de 0.9465. En este caso las clases mejores reconocidas corresponden a RBB y APC, sin la presencia de errores, tal como se muestra en la Figura 5.9, mientras que la que presentó mayor dificultad de reconocimiento fue PVC, al igual que en el clasificador número uno. Es importante mencionar que debido al peso de las imágenes de escalogramas fue necesaria una reducción, dejando sólo la novena parte de las columnas de las imágenes, además de realizó también una reducción en los conjuntos de entrenamiento y prueba, trabajando sólo con la mitad de los datos. A pesar de estas reducciones en la información los resultados fueron mejores en el trabajo con Transformada Wavelet (escalogramas), que con la señal normal (imágenes en escala de grises).

Los resultados muestran que el clasificador por escalogramas da un resultado lo suficientemente confiable para tomarlo como un apoyo al momento de diagnosticar alguna de las cinco enfermedades con las que se trabajaron.

## 6.2. Trabajos Futuros

1. Utilizar matrices en las que cada renglón esté conformado por un latido para la creación de imágenes en escala de grises.
2. Realizar la reducción de escalogramas retirando la parte superior que no presenta demasiada información.
3. Agregar otras bases de datos para aumentar la cantidad de enfermedades y de muestras.
4. Considerar una primera clasificación con el primer canal (señal superior) de los datos para la identificación de personas sanas y enfermas, para posteriormente

realizar una segunda clasificación con las personas enfermas y el segundo canal de los registros (señal inferior) identificando el tipo de padecimiento.

## Apéndice A

# Información de Registros

Las señales fueron tomadas de 25 hombres entre 32 y 89 años y 22 mujeres entre 23 y 89 años, como se muestra en la Tabla A.1. Dicha tabla presenta el número de registro del paciente, su sexo, edad, las derivaciones utilizadas en el ECG y el tipo de ritmo y latido que posee. Para más detalles consultar The Impact of the MIT-BIH Arrhythmia Database [Moddy01].

| <i>Número de Registro</i> | <i>Sexo</i> | <i>Edad</i> | <i>Derivación 1</i> | <i>Derivación 2</i> | <i>Latidos y ritmo</i>                                                              |
|---------------------------|-------------|-------------|---------------------|---------------------|-------------------------------------------------------------------------------------|
| 100                       | masculino   | 69          | MLII                | V5                  | Normal y APC                                                                        |
| 101                       | femenino    | 75          | MLII                | V1                  | Normal y APC                                                                        |
| 102                       | femenino    | 84          | V5                  | V2                  | Ritmo acompasado, función de marcapasos y PVC                                       |
| 103                       | masculino   | -           | MLII                | V2                  | Normal                                                                              |
| 104                       | femenino    | 66          | V5                  | V2                  | Normal, ritmo acompasado, función de marcapasos y PVC                               |
| 105                       | femenino    | 73          | MLII                | V1                  | Normal y PVC                                                                        |
| 106                       | femenino    | 24          | MLII                | V1                  | Normal, PVC, bigenismo ventricular, trigenismo ventricular, taquicardia ventricular |
| 107                       | masculino   | 63          | MLII                | V1                  | Ritmo acompasado, marcapasos y PVC                                                  |
| 108                       | femenino    | 87          | MLII                | V1                  | Normal, APC, PVC, bloqueo AV, arritmia sinusoidal                                   |
| 109                       | masculino   | 64          | MLII                | V1                  | Bloqueo de rama izquierda y PVC                                                     |
| 111                       | femenino    | 47          | MLII                | V1                  | Bloqueo de rama izquierda y PVC                                                     |
| 112                       | masculino   | 54          | MLII                | V1                  | Normal y APC                                                                        |

|     |           |    |      |      |                                                                                                                                                                                        |
|-----|-----------|----|------|------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 113 | femenino  | 24 | MLII | V1   | Normal, APC aberrado y arritmia sinusoidal                                                                                                                                             |
| 114 | femenino  | 72 | V5   | MLII | Normal, APC, PVC, SVTA                                                                                                                                                                 |
| 115 | femenino  | 39 | MLII | V1   | Normal                                                                                                                                                                                 |
| 116 | masculino | 68 | MLII | V1   | Normal, PVC y APC                                                                                                                                                                      |
| 117 | masculino | 69 | MLII | V2   | Normal y APC                                                                                                                                                                           |
| 118 | masculino | 69 | MLII | V1   | Bloqueo de la rama derecha, APC, PVC, bloqueo APC                                                                                                                                      |
| 119 | femenino  | 51 | MLII | V1   | Normal, PVC, bigenismo ventricular, trigenismo ventricular                                                                                                                             |
| 121 | femenino  | 83 | MLII | V1   | Normal, APC, PVC                                                                                                                                                                       |
| 122 | masculino | 51 | MLII | V1   | Normal                                                                                                                                                                                 |
| 123 | femenino  | 63 | MLII | V5   | Normal, PVC                                                                                                                                                                            |
| 124 | masculino | 77 | MLII | V4   | Bloqueo de la rama derecha, PVC, APC, unión prematura, unión de escape, trigenismo ventricular, ritmo idioventricular                                                                  |
| 200 | masculino | 64 | MLII | V1   | Normal, APC, PVC, bigenismo ventricular, taquicardia ventricular                                                                                                                       |
| 201 | masculino | 68 | MLII | V1   | Normal, APC, APC aberrado, PVC, unión de escape, bloqueo APC, SVTA, fibrilación auricular, trigenismo ventricular                                                                      |
| 202 | masculino | 68 | MLII | V1   | Normal, bradicardia, APC, APC aberrado, aleteo auricular, fibrilación atrial                                                                                                           |
| 203 | masculino | 43 | MLII | V1   | Normal, APC aberrado, PVC, aleteo auricular, fibrilación auricular, trigenismo ventricular, taquicardia ventricular                                                                    |
| 205 | masculino | 59 | MLII | V1   | Normal, APC, PVC, taquicardia ventricular                                                                                                                                              |
| 207 | femenino  | 89 | MLII | V1   | Bloqueo de la rama izquierda, bloque de la rama derecha, APC, PVC, aleteo ventricular, escape ventricular, SVTA, bigenismo ventricular, ritmo idioventricular, taquicardia ventricular |
| 208 | femenino  | 23 | MLII | V1   | Normal, SVPC, PVC, trigenismo ventricular                                                                                                                                              |
| 209 | masculino | 62 | MLII | V1   | Normal, APC, PVC, SVTA                                                                                                                                                                 |
| 210 | masculino | 89 | MLII | V1   | Normal, APC aberrado, PVC, escape ventricular, fibrilación atrial, bigenismo ventricular, trigenismo ventricular, taquicardia, ventricular                                             |
| 212 | femenino  | 32 | MLII | V1   | Normal, bloqueo de la rama derecha                                                                                                                                                     |

|     |           |    |      |    |                                                                                                                          |
|-----|-----------|----|------|----|--------------------------------------------------------------------------------------------------------------------------|
| 213 | masculino | 61 | MLII | V1 | Normal, APC, APC aberrado, PVC, bigenismo ventricular, taquicardia ventricular                                           |
| 214 | masculino | 53 | MLII | V1 | Bloqueo de la rama izquierda, PVC, trigenismo ventricular, taquicardia ventricular                                       |
| 215 | masculino | 81 | MLII | V1 | Normal, APC, PVC, taquicardia ventricular                                                                                |
| 217 | masculino | 65 | MLII | V1 | Normal, PVC, acompasado, marcapasos, fibrilación atrial, bigenismo ventricular, taquicardia ventricular                  |
| 219 | masculino | -  | MLII | V1 | Normal, APC, PVC, bloqueo APC, fibrilación auricular, bigenismo ventricular, trigenismo ventricular                      |
| 220 | femenino  | 87 | MLII | V1 | Normal, APC, SVTA                                                                                                        |
| 221 | masculino | 83 | MLII | V1 | Normal, PVC, fibrilación auricular, bigenismo ventricular, trigenismo ventricular, taquicardia ventricular               |
| 222 | femenino  | 84 | MLII | V1 | Normal, APC, unión prematura, unión de escape, bigenismo auricular, SVTA, aleteo auricular, fibrilación auricular        |
| 223 | masculino | 73 | MLII | V1 | Normal, APC, APC aberrado, PVC, escape auricular, bigenismo ventricular, trigenismo ventricular, taquicardia ventricular |
| 228 | femenino  | 80 | MLII | V1 | Normal, APC, PVC, bigenismo ventricular                                                                                  |
| 230 | masculino | 32 | MLII | V1 | Normal, PVC, pre-exitación (WPW)                                                                                         |
| 231 | femenino  | 72 | MLII | V1 | Normal, bloqueo de rama derecha, APC, PVC, bloqueo APC, bloqueo del corazón                                              |
| 232 | femenino  | 76 | MLII | V1 | bloqueo de la rama derecha, APC, unión de escape, bradicardia sinoidal, SVTA, pausas                                     |
| 233 | masculino | 57 | MLII | V1 | Normal, APC, PVC, bigenismo ventricular, trigenismo ventricular, taquicardia ventricular                                 |
| 234 | femenino  | 56 | MLII | V1 | Normal, unión prematura, PVC, SVTA                                                                                       |

Tabla A.1: Información sobre los registros de la base de datos [Moddy01].

## Apéndice B

# Cantidad de Latidos por Registro

La presente tabla muestra la cantidad de latidos de cada tipo que posee cada uno de los registros de la base de datos MIT-BIH. La primera columna presenta el número de registro analizado mientras que las columnas siguientes el tipo de latido, esta información fue obtenida de la página Physionet [Goldberger00].

| Registro | N    |      |      |    |   |    |   | V   | F | O | N |   | E | P    | F   | O  | Q  |
|----------|------|------|------|----|---|----|---|-----|---|---|---|---|---|------|-----|----|----|
|          | .    | L    | R    | A  | a | J  | S | V   | F | ! | e | j | E | P    | f   | p  | Q  |
| 100      | 2239 | -    | -    | 33 | - | -  | - | 1   | - | - | - | - | - | -    | -   | -  | -  |
| 101      | 1860 | -    | -    | 3  | - | -  | - | -   | - | - | - | - | - | -    | -   | -  | 2  |
| 102      | 99   | -    | -    | -  | - | -  | - | 4   | - | - | - | - | - | 2028 | 56  | -  | -  |
| 103      | 2082 | -    | -    | 2  | - | -  | - | -   | - | - | - | - | - | -    | -   | -  | -  |
| 104      | 163  | -    | -    | -  | - | -  | - | 2   | - | - | - | - | - | 1380 | 666 | -  | 18 |
| 105      | 2526 | -    | -    | -  | - | -  | - | 41  | - | - | - | - | - | -    | -   | -  | 5  |
| 106      | 1507 | -    | -    | -  | - | -  | - | 520 | - | - | - | - | - | -    | -   | -  | -  |
| 107      | -    | -    | -    | -  | - | -  | - | 59  | - | - | - | - | - | 2078 | -   | -  | -  |
| 108      | 1739 | -    | -    | 4  | - | -  | - | 17  | 2 | - | - | 1 | - | -    | -   | 11 | -  |
| 109      | -    | 2492 | -    | -  | - | -  | - | 38  | 2 | - | - | - | - | -    | -   | -  | -  |
| 111      | -    | 2123 | -    | -  | - | -  | - | 1   | - | - | - | - | - | -    | -   | -  | -  |
| 112      | 2537 | -    | -    | 2  | - | -  | - | -   | - | - | - | - | - | -    | -   | -  | -  |
| 113      | 1789 | -    | -    | -  | 6 | -  | - | -   | - | - | - | - | - | -    | -   | -  | -  |
| 114      | 1820 | -    | -    | 10 | - | 2  | - | 43  | 4 | - | - | - | - | -    | -   | -  | -  |
| 115      | 1953 | -    | -    | -  | - | -  | - | -   | - | - | - | - | - | -    | -   | -  | -  |
| 116      | 1953 | -    | -    | 1  | - | -  | - | 109 | - | - | - | - | - | -    | -   | -  | -  |
| 117      | 1534 | -    | -    | 1  | - | -  | - | -   | - | - | - | - | - | -    | -   | -  | -  |
| 118      | -    | -    | 2166 | 96 | - | -  | - | 16  | - | - | - | - | - | -    | -   | 10 | -  |
| 119      | 1543 | -    | -    | -  | - | -  | - | 444 | - | - | - | - | - | -    | -   | -  | -  |
| 121      | 1861 | -    | -    | 1  | - | -  | - | 1   | - | - | - | - | - | -    | -   | -  | -  |
| 122      | 2476 | -    | -    | -  | - | -  | - | -   | - | - | - | - | - | -    | -   | -  | -  |
| 123      | 1515 | -    | -    | -  | - | -  | - | 3   | - | - | - | - | - | -    | -   | -  | -  |
| 124      | -    | -    | 1531 | 2  | - | 29 | - | 47  | 5 | - | - | 5 | - | -    | -   | -  | -  |
| 200      | 1743 | -    | -    | 30 | - | -  | - | 826 | 2 | - | - | - | - | -    | -   | -  | -  |

|     |      |      |      |      |    |    |   |     |     |     |    |     |     |      |     |     |   |
|-----|------|------|------|------|----|----|---|-----|-----|-----|----|-----|-----|------|-----|-----|---|
| 201 | 1625 | -    | -    | 30   | 97 | 1  | - | 198 | 2   | -   | -  | 10  | -   | -    | -   | 37  | - |
| 202 | 2061 | -    | -    | 36   | 19 | -  | - | 19  | 1   | -   | -  | -   | -   | -    | -   | -   | - |
| 203 | 2529 | -    | -    | -    | 2  | -  | - | 444 | 1   | -   | -  | -   | -   | -    | -   | -   | 4 |
| 205 | 2571 | -    | -    | 3    | -  | -  | - | 71  | 11  | -   | -  | -   | -   | -    | -   | -   | - |
| 207 | -    | 1457 | 86   | 107  | -  | -  | - | 105 | -   | 472 | -  | -   | 105 | -    | -   | -   | - |
| 208 | 1586 | -    | -    | -    | -  | -  | 2 | 992 | 373 | -   | -  | -   | 105 | -    | -   | -   | 2 |
| 209 | 2621 | -    | -    | 383  | -  | -  | - | 1   | -   | -   | -  | -   | -   | -    | -   | -   | - |
| 210 | 2423 | -    | -    | -    | 22 | -  | - | 194 | 10  | -   | -  | -   | 1   | -    | -   | -   | - |
| 212 | 923  | -    | 1825 | -    | -  | -  | - | -   | -   | -   | -  | -   | -   | -    | -   | -   | - |
| 213 | 2641 | -    | -    | 25   | 3  | -  | - | 220 | 362 | -   | -  | -   | -   | -    | -   | -   | - |
| 214 | -    | 2003 | -    | -    | -  | -  | - | 256 | 1   | -   | -  | -   | -   | -    | -   | -   | 2 |
| 215 | 3195 | -    | -    | 3    | -  | -  | - | 164 | 1   | -   | -  | -   | -   | -    | -   | -   | - |
| 217 | 244  | -    | -    | -    | -  | -  | - | 162 | -   | -   | -  | -   | -   | 1542 | 260 | -   | - |
| 219 | 2082 | -    | -    | 7    | -  | -  | - | 64  | 1   | -   | -  | -   | -   | -    | -   | 133 | - |
| 220 | 1954 | -    | -    | 94   | -  | -  | - | -   | -   | -   | -  | -   | -   | -    | -   | -   | - |
| 221 | 2031 | -    | -    | -    | -  | -  | - | 396 | -   | -   | -  | -   | -   | -    | -   | -   | - |
| 222 | 2062 | -    | -    | 208  | -  | 1  | - | -   | -   | -   | -  | 212 | -   | -    | -   | -   | - |
| 223 | 2029 | -    | -    | 72   | 1  | -  | - | 473 | 14  | -   | 16 | -   | -   | -    | -   | -   | - |
| 228 | 1688 | -    | -    | 3    | -  | -  | - | 362 | -   | -   | -  | -   | -   | -    | -   | -   | - |
| 230 | 2255 | -    | -    | -    | -  | -  | - | 1   | -   | -   | -  | -   | -   | -    | -   | -   | - |
| 231 | 314  | -    | 1254 | 1    | -  | -  | - | 2   | -   | -   | -  | -   | -   | -    | -   | 2   | - |
| 232 | -    | -    | 397  | 1382 | -  | -  | - | -   | -   | -   | -  | 1   | -   | -    | -   | -   | - |
| 233 | 2230 | -    | -    | 7    | -  | -  | - | 831 | 11  | -   | -  | -   | -   | -    | -   | -   | - |
| 234 | 2700 | -    | -    | -    | -  | 50 | - | 3   | -   | -   | -  | -   | -   | -    | -   | -   | - |

Tabla B.1: Tipo y cantidad de latidos por registro [Goldberger00].

# Referencias

- [Al Rahhal18] Al Rahhal, M. M., Bazi, Y., Al Zuari, M., Othman, E., y BenJ-dira, B. Convolutional Neural Networks for Elecgtrocardio-gram Classification. *Journal of Medical and Biological Engi-neering*, Febrero 2018.
- [AlfaMD23] AlfaMD, 2023. Consultado el: 02 de agosto del 2024, de Al-fa Medical Doctor, en <https://www.istockphoto.com/es/portfolio/alfamd?mediatype=illustration>.
- [Andreotti17] Andreotti, F., Carr, O., Pimentel, M. A. F., Mahdi, A., y De Vos, M. Comparing FeatureBased Classifiers and Con-volutional Neural Networks to Detect Arrhythmia from Short Segments of ECG. 2017.
- [Dubin00] Dubin, D. *Rapid Interpretation of EKG's*. COVER Inc., 6<sup>a</sup> ed<sup>ón</sup>., 2000. ISBN 0-912912-06-5.
- [Ebrahimi20] Ebrahimi, Z., Loni, M., Daneshtalab, M., y Gharehbaghi, A. A Review on Deep Learning Methods for ECG Arrhythmia Clas-sification. *Expert Systems with Applications: X*, Junio 2020.
- [Estrada19] Estrada, K. Músculo Cardíaco: el corazón co-mo bomba y la función de las válvulas cadiacas. 2019. Consultado el: 23 de Julio del 2024, en

<https://anromfisiologiablog.home.blog/2019/02/24/musculo-cardiaco-el-corazon-como-bomba-y-la-funcion-de-las-valvulas->

- [EvidentlyAI24] EvidentlyAI. Accuracy, precision and recall in multi-class classification. *Evidently AI*, Octubre 2024. <https://www.evidentlyai.com/classification-metrics/multi-class-metrics>.
- [Goldberger00] Goldberger, A., Amaral, L., Glass, J., L. and Hausdorff, Ivanov, P. C., Mark, R. G., y Stanley, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research for complex physiologic signals. *Circulation [Online]*, 101(23):e215–e220, 2000.
- [Goodfellow16] Goodfellow, I., Bengio, Y., y Courville, A. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [He16] He, Z., Zhang, X., Ren, S., y Sun, J. Deep Residual Learning for Image Recognition. *arXiv*, 7(3):171–180, 2016.
- [INEGI24] INEGI. Estadísticas de Defunciones Registradas (EDR) 2023. *Comunicado de prensa número 478/24*, Agosto 2024.
- [Jun18] Jun, T. J., Nguyen, H. M., Kang, D., Kim, D., Kim, D., y Kim, Y. ECG Arrhythmia Classification Using a 2-D Convolutional Neural Network. *Korea*, Abril 2018.
- [Lee19] Lee, G. R., Gommers, R., Wasilewski, F., Wohlfahrt, K., y O’Leary, A. PyWavelets: A Python package for wavelet analysis. *Journal of Open source Software*, 4(36):1237, 2019. <https://doi.org/10.21105/joss.01237>.

- [Liu18] Liu, W., Huang, Q., Chang, S., Wang, H., y He, J. Multiple-Feature-Branch Convolutional Neural Network for Myocardial Infarction Diagnosis Using Electrocardiogram. *ELSEVIER*, Mayo 2018.
- [Mathunjwa22] Mathunjwa, B. M., Lin, Y. T., Lin, C. H., Abbod, M. F., Sadra-wi, M., y Shieh, J. S. ECG Recurrence Plot-Based Arrhythmia Classification Using Two-Dimensional Deep Residual CNN Features. *Sensors*, 22, Febrero 2022.
- [May19] Isquemia Miocárdica, 2019. Consultado el 22 de agosto de 2024, en <https://www.mayoclinic.org/es/diseases-conditions/myocardial-ischemia/symptoms-causes/syc-20375417>.
- [Mewada22] Mewada, H. 2D-Wavelet Encoded Deep CNN for Image-based ECG Classification. *Springer*, 2022.
- [Micheli11] Micheli, A. Entorno a los Primeros Estudios de Electrofisiología. *Archivos de Cardiología de México*, 81:337–342, Diciembre 2011.
- [Moddy01] Moddy, G. B. y Mark, R. G. The Impact of the MIT-BIH Arrhythmia Database. *IEEE Eeng in Med and Biol*, 20(3):45–50, Mayo-Junio 2001.
- [Naz21] Naz, M., Shah, J. H., Khan, M. A., Sharif, M., y Raza, M. D. From ECG Signals to Images: a Transformation Based Approach for Deep Learning. *PeerJ Computer Science*, pág. 15, 2021.
- [OMS21] OMS. Enfermedades Cardiovasculares. *who.int*, Junio 2021.

- [Padrón98] Padrón, A., Pérez, J. L., Fuentes, R., y Garduño, V. G. Diagnóstico de Anomalías en Electrocardiogramas por Medio de Redes Neuronales Artificiales. Octubre 1998.
- [Pagnini10] Pagnini, P. Electrómetro Capilar de Lippmann, 2010. Consultado el: 06 de Julio del 2024, en <https://www.criticadelibros.com/sin-clasificar/electrometro-capilar-de-lippmann/>.
- [Raschka17] Raschka, S. y Mirjalili, V. *Python Machine Learning*. Expert Insight. Packt, 2ª ed<sup>ón</sup>., 2017. ISBN 978-1-78712-593-3. Pag. 412-416.
- [Secretaría de Salud18] Secretaría de Salud. La arritmia, padecimiento frecuente entre la población, Diciembre 2018. Consultado el: 22 de agosto de 2024, en <https://www.gob.mx/salud/articulos/la-arritmia-padecimiento-frecuente-entre-la-poblacion>.
- [Sellami18] Sellami, A. y Hwuang, H. A Robust Deep Convolutional Neural Network with Batch-Weighted Loss for Heartbeat Classification. *Expert Systems with Applications*, Diciembre 2018.
- [TensorFlowCore22] TensorFlow Core. Keras. *Instructivos*, 2022. <https://www.tensorflow.org/guide/keras?hl=es-419>.
- [UNAM21] UNAM, F. d. M. *Fundamentos Electrofisiológicos del Electrocardiograma*, Enero 2021.
- [UNAM22] UNAM, F. d. M. *Taller de interpretación del electrocardiograma*, Septiembre 2022.
- [Villagrán17] Villagrán, C. A. y Pradenas, L. *Clasificación Automática de Latidos de un Electrocardiograma Utilizando Aprendizaje Pro-*

*fundo*. Maestría, Universidad de Concepción, Facultad de Ingeniería, Departamento de Ingeniería Industrial, Chile, Abril 2017.

- [Wang21] Wang, T., Lu, C., Sun, Y., M., Y., y Liu, C., C. Ou. Automatic ECG Classification Using Continuous Wavelet Transform and Convolutional Neural Network. *Entropy*, 23(119), Enero 2021.
- [Yildirim18] Yildirim, O., Plawiak, P., Tan, R. S., y Acharya, U. R. Arrhythmia Detection Using Deep Convolutional Neural Network with Long Duration ECG Signal. *Computers in Biology and Medicine*, Septiembre 2018.

# Brenda Isabel Zavala García

## DIAGNÓSTICO AUTOMÁTICO DE ENFERMEDADES CARDÍACAS UTILIZANDO REDES NEURONALES CONVOLUCIONALES.pdf

 Universidad Michoacana de San Nicolás de Hidalgo

### Detalles del documento

Identificador de la entrega

trn:oid::3117:460569771

Fecha de entrega

19 may 2025, 8:37 a.m. GMT-6

Fecha de descarga

19 may 2025, 8:48 a.m. GMT-6

Nombre de archivo

DIAGNÓSTICO AUTOMÁTICO DE ENFERMEDADES CARDÍACAS UTILIZANDO REDES NEURONALES C....pdf

Tamaño de archivo

11.6 MB

113 Páginas

20.226 Palabras

104.335 Caracteres

# 14% Genel Benzerlik

Her veri tabanı için çıkarılan kaynaklar da dâhil tüm eşleşmelerin kombine toplamı.

## Ön Sıradaki Kaynaklar

- 12%  İnternet kaynakları
- 7%  Yayınlar
- 0%  Gönderilen çalışmalar (Öğrenci Makaleleri)

## Bütünlük Bayrakları

### İnceleme için 0 Bütünlük Bayrağı

Herhangi bir şüpheli metin manipölasyonu belirlenmedi.

Sistemimizin algoritmaları bir belgede, onu normal bir gönderiden ayırabilecek her türlü tutarsızlığı derinlemesine inceler. Tuhaf bir şey fark edersek incelemeniz için bayrak ekleriz.

Bir Bayrak mutlaka bir sorun olduğunu göstermez. Ancak daha fazla inceleme için dikkatinizi vermenizi öneririz.

# Formato de Declaración de Originalidad y Uso de Inteligencia Artificial

Coordinación General de Estudios de Posgrado  
Universidad Michoacana de San Nicolás de Hidalgo



A quien corresponda,

Por este medio, quien abajo firma, bajo protesta de decir verdad, declara lo siguiente:

- Que presenta para revisión de originalidad el manuscrito cuyos detalles se especifican abajo.
- Que todas las fuentes consultadas para la elaboración del manuscrito están debidamente identificadas dentro del cuerpo del texto, e incluidas en la lista de referencias.
- Que, en caso de haber usado un sistema de inteligencia artificial, en cualquier etapa del desarrollo de su trabajo, lo ha especificado en la tabla que se encuentra en este documento.
- Que conoce la normativa de la Universidad Michoacana de San Nicolás de Hidalgo, en particular los Incisos IX y XII del artículo 85, y los artículos 88 y 101 del Estatuto Universitario de la UMSNH, además del transitorio tercero del Reglamento General para los Estudios de Posgrado de la UMSNH.

| Datos del manuscrito que se presenta a revisión |                                                                                              |                               |
|-------------------------------------------------|----------------------------------------------------------------------------------------------|-------------------------------|
| <b>Programa educativo</b>                       | Maestría en Ciencias en Ingeniería Eléctrica                                                 |                               |
| <b>Título del trabajo</b>                       | Diagnóstico Automático de Enfermedades Cardíacas Utilizando Redes Neuronales Convolucionales |                               |
|                                                 | <b>Nombre</b>                                                                                | <b>Correo electrónico</b>     |
| <b>Autor/es</b>                                 | LCFM Brenda Isabel Zavala García                                                             | brenda.isabel.zavala@umich.mx |
| <b>Director</b>                                 | Dr. José Antonio Camarena Ibarrola                                                           | antonio.camarena@umich.mx     |
| <b>Codirector</b>                               |                                                                                              |                               |
| <b>Coordinador del programa</b>                 | Dr. Norberto García Barriga                                                                  | norberto.garcia@umich.mx      |

| Uso de Inteligencia Artificial |             |             |
|--------------------------------|-------------|-------------|
| Rubro                          | Uso (sí/no) | Descripción |
| Asistencia en la redacción     | no          |             |

# Formato de Declaración de Originalidad y Uso de Inteligencia Artificial

Coordinación General de Estudios de Posgrado  
Universidad Michoacana de San Nicolás de Hidalgo



| Uso de Inteligencia Artificial             |             |             |
|--------------------------------------------|-------------|-------------|
| Rubro                                      | Uso (sí/no) | Descripción |
| Traducción al español                      | no          |             |
| Traducción a otra lengua                   | no          |             |
| Revisión y corrección de estilo            | no          |             |
| Análisis de datos                          | no          |             |
| Búsqueda y organización de información     | no          |             |
| Formateo de las referencias bibliográficas | no          |             |
| Generación de contenido multimedia         | no          |             |
| Otro                                       | no          |             |

| Datos del solicitante |                                                                                                                  |
|-----------------------|------------------------------------------------------------------------------------------------------------------|
| Nombre y firma        | Brenda Isabel Zavala García  |
| Lugar y fecha         | Morelia, Mich., 16 de mayo del 2025                                                                              |