

**UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA**  
**FACULTAD DE INGENIERÍA**  
**MAESTRÍA Y DOCTORADO EN CIENCIAS E INGENIERÍA**



**PÉEK: UNA APLICACIÓN WEB PARA DETECTAR ARRITMIAS  
CARDIACAS MEDIANTE REDES NEURONALES CONVOLUCIONALES Y  
TRAZOS ELECTROCARDIOGRÁFICOS**

TESIS PARA OBTENER EL GRADO DE MAESTRO EN CIENCIAS  
QUE PRESENTA

NESTOR ALEXANDER ZERMEÑO CAMPOS

**DIRECTOR**

DR. JUAN PABLO GARCÍA VÁZQUEZ

**CO-DIRECTOR**

ROBERTO LÓPEZ AVITIA

Mexicali, Baja California

11 de septiembre de 2021

TESIS DEFENDIDA POR

**Nestor Alexander Zermeño Campos**

Y APROBADA POR EL SIGUIENTE COMITÉ

---

**Dr. Juan Pablo García Vázquez**  
Director de Tesis

---

**Dr. Roberto López Avitia**  
Co-Director

---

**Dr. Marco Antonio Reyna  
Carranza**  
Miembro del Comité

---

**Dr. Arnoldo Díaz Ramírez**  
Miembro del Comité

---

**Dra. Wendy Flores Fuentes**  
Coordinador de Posgrado de la FIM

**RESUMEN** de la tesis de Nestor Alexander Zermeño Campos, presentada como requisito parcial para obtener el grado de **MAESTRO EN CIENCIAS**, en el campo de conocimiento **COMPUTACIÓN**, Mexicali B.C., 11 de septiembre de 2021.

**PÉEK: UNA APLICACIÓN WEB PARA DETECTAR ARRITMIAS CARDIACAS MEDIANTE REDES NEURONALES CONVOLUCIONALES Y TRAZOS ELECTROCARDIOGRÁFICOS**

Resumen aprobado por:

---

**Dr. Juan Pablo García Vázquez**  
Director de la Tesis

---

**Dr. Roberto López Avitia**  
Co-Director de la Tesis

**Palabras clave:** Arritmias, Trazo Electrocardiográfico, Aprendizaje Profundo, Redes Neuronales, Aplicación Web, Python, PVC.

RESUMEN.-

La presente tesis se orienta al desarrollo de una aplicación web aplicando un modelo de aprendizaje profundo para identificar arritmias cardíacas a partir de un trazo de electrocardiograma (ECG).

La aplicación web tiene por nombre PÉEK cuyo significado proviene del maya “latido” y fue desarrollada con la arquitectura Cliente-Servidor, donde el usuario interactúa con una página web (Cliente) y se conecta con Python (Servidor) en donde se procesa el trazo de ECG para localizar cada ciclo cardíaco en él e identificar la presencia de una arritmia cardíaca según la forma de onda que presente cada ciclo.

El modelo utilizado es una Red Neuronal Convolutiva (del inglés Convolutional Neural Networks, CNN) de 20 capas, de las cuales 4 capas son de convolución, seguidas cada una con una capa de la función de activación ReLu, 4 de MaxPooling, 3 de Dropout, 1 capa Flatten, 2 capas Densas y, finalmente, una de Softmax como función de activación de salida. El modelo fue entrenado a partir de imágenes de ciclos cardíacos normales (sin arritmia cardíaca) y ciclos con contracción ventricular prematura (del inglés Premature Ventricular Contraction, PVC).

Los resultados obtenidos del modelo para la identificación de la arritmia cardíaca PVC fue de 98.92% de precisión y la aplicación web genera una imagen de todo el trazo de ECG, mostrando trazos de 29 segundos por renglón, con cada ciclo cardíaco clasificado, marcando con las letras NSR a los ciclos normales, y a las arritmias con un recuadro rojo y la etiqueta de la arritmia identificada, para facilitar su visualización en la imagen.

**SUMMARY** of the thesis of Nestor Alexander Zermeño Campos, presented as a partial requirement to obtain the degree of **MASTER IN SCIENCE**, in the field of knowledge **COMPUTER**, Mexicali B.C., september 11 2021.

**PEÉK: A WEB APPLICATION FOR DETECTING CARDIAC ARRHYTHMIAS USING CONVOLUTIONAL NEURAL NETWORKS AND ELECTROCARDIOGRAPHIC SIGNALS**

Summary approved by:

---

**PhD. Juan Pablo García Vázquez**  
**Thesis Advisor**

---

**PhD. Roberto López Avitia**  
**Co-Thesis Advisor**

**Keywords:** Arrhythmias, Electrocardiographic trace, Deep Learning, Neural Networks, Web Application, Python. PVC.

**ABSTRACT.-**

This thesis is oriented to the development of a web application applying a deep learning model to identify cardiac arrhythmias from an electrocardiogram (ECG) trace.

The web application is called PÉEK whose meaning comes from the Mayan "heartbeat" and was developed with Client-Server architecture, where the user interacts with a web page (Client) and connects to Python (Server) where the ECG trace is processed to locate each cardiac cycle in it and identify the presence of a cardiac arrhythmia according to the waveform that each cycle presents.

The model used is a Convolutional Neural Network (CNN) of 20 layers, of which 4 layers are convolutional, followed each with a layer of the ReLu activation function, 4 of MaxPooling, 3 of Dropout, 1 Flatten layer, 2 Dense layers and, finally, one of Softmax as the output activation function.

The model was trained from images of normal cardiac cycles (without cardiac arrhythmia) and cycles with premature ventricular contraction (PVC).

The results obtained from the model for the identification of PVC cardiac arrhythmia was 98.92% accuracy and the web application generates an image of the entire ECG trace, showing traces of 29 seconds per line, with each cardiac cycle classified, marking normal cycles with the letters NSR, and arrhythmias with a red box and the label of the identified arrhythmia, to facilitate their visualization in the image.

## **Dedicatoria**

Dedico esta tesis a mis padres, María de los Ángeles Campos López y Jorge Nestor Zermeño Espinoza, por haberme impulsado a seguir mis sueños desde mi infancia, pues me permitieron experimentar mis habilidades en distintas áreas y apoyaron cada decisión que tomé a pesar de mis errores. Gracias por demostrarme que, sin importar las limitantes, siempre hay maneras de salir adelante.

Plenamente orgulloso de mis padres y enormemente agradecido por sus esfuerzos.

¡Los amo!

---

**Nestor Alexander Zermeño Campos**

## Agradecimientos

A los miembros de mi comité de tesis: el Dr. Miguel Bravo Zanoguera, Dr. Roberto López Avitia, Dr. Marco Antonio Reyna Carraza y Dr. Arnoldo Díaz Ramírez por su apoyo, comprensión y sugerencias.

A mi asesor, el Dr. Juan Pablo García Vázquez, por sus enseñanzas durante estos años, por su comprensión tras mi ausencia, por su apoyo constante en mi carrera profesional como desarrollador y su apoyo para el término de mi posgrado. De la misma manera, le agradezco haberme forjado como investigador y el haberme heredado su metodología de trabajo para esta primera etapa en el área científica.

A mi co-asesor, el Dr. Roberto López Avitia, por apoyar mi carrera desde mis estudios de licenciatura y encaminarme por el área científica, por creer en mi capacidad para innovar y por apoyar el descubrimiento de mis habilidades profesionales.

Al Dr. Cline por sus recomendaciones y el tiempo que dedicó a la revisión de mis avances de proyecto.

A la M.C. Isabel Lebasi y al M.C. Ricardo López, estudiantes del programa de maestría y doctorado, que fueron mi equipo de trabajo durante los primeros semestres de mis estudios de maestría, pues me brindaron su compañía y experiencia en el área.

A la Dra. Ma Elena Zermeño Espinoza por brindarme la fuerza para salir adelante en mi vida y mis proyectos tras la agotadora lucha contra el COVID, y recordarme todos los sueños que había dejado en pausa, aún después de su partida.

Al M.C. Ricardo Delgadillo Valle por recordarme lo emocionante que es la ciencia y ser un ejemplo de perseverancia al alcanzar uno a uno sus objetivos.

A mis padres por su incondicional apoyo para mis estudios, mi bienestar y el cumplimiento de mis metas, y por moldear el carácter de la persona que soy actualmente y por todos los sacrificios que hicieron por darme la vida que ahora tengo.

A mi esposa, Laura Lizbeth Luna Limón, por su apoyo durante la temporada de regreso a mis estudios de posgrado, por acompañar mis desvelos y comprender mis ausencias durante las últimas semanas de mi tesis.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por brindarme el apoyo económico para estudiar un posgrado (CVU 765061)

A la Universidad Autónoma de Baja California (UABC) y a mis profesores del posgrado por brindarme siempre su apoyo y asesoría.

# Tabla de Contenido

<b>Capítulo 1: Introducción</b>	1
1.1 Antecedentes	1
1.4 Planteamiento del problema	3
1.5 Objetivos específicos	5
1.6 Metodología	5
1.7 Organización de la Tesis	6
<b>Capítulo 2: Marco teórico</b>	7
2.1 Fisiología cardíaca	7
2.1.1 Electrocardiograma	9
2.2 Arritmias	12
2.2.1 Anormalidades en la frecuencia	13
2.2.2 Anormalidades en el ritmo	13
2.3 Redes Convolucionales	15
2.3.1 Estructura de una red neuronal convolucional	15
<b>Capítulo 3: Diseño de PÉEK</b>	18
3.1 Introducción	18
3.2 Interfaz de PÉEK	19
3.3 Conexión Cliente-Servidor	21
3.4 Procesamiento del trazo electrocardiográfico	23
3.4.1 Adquisición del trazo electrográfico	23
3.4.2 Transformación del trazo electrocardiográfico a imagen	24
3.4.3 Identificación de picos R	25
3.4.4 Ventaneo de ciclo cardíaco	28
3.4.5 Detección de la arritmia cardiaca PVC	29
3.4.5.1 Base de datos MIT-BIH	29
3.4.5.2 Conjunto de datos de entrenamiento	30
3.4.5.3 Modelado	35
<b>Capítulo 4: Resultados</b>	38
4.1 Conjunto de datos de prueba	38
4.2 Evaluación del modelo	39
4.3 Interpretación del trazo electrocardiográfico.	41
<b>Capítulo 5: Conclusiones y Trabajo Futuro</b>	43
5.1 Conclusiones	43

<b>5.2 Contribuciones</b>	44
<b>5.3 Trabajo Futuro</b>	45
<b>Referencias</b>	46
<b>Anexos</b>	49

## Índice de Figuras

Figura. 1 Principales causas de mortalidad en México [4].	2
Figura. 2 Trazo de ECG en papel con anotaciones de un especialista.	4
Figura. 3 Etapas de la Metodología.	5
Figura. 4 Ubicación gráfica del corazón en el centro del tórax [18].	7
Figura. 5 Estructura del corazón y flujos sanguíneos a través de él [18].	8
Figura. 6 Cavidades del corazón y principales vasos sanguíneos [18].	8
Figura. 7 Triángulo de Einthoven: derivaciones para realizar registros de ECG [19].	10
Figura. 8 Formas de onda de un latido en un ECG normal [19].	10
Figura. 9 Correlación entre las formas de onda en un ECG y los eventos cardíacos del corazón [18].	11
Figura. 10 Condiciones cardíacas representativas A) ECG normal, B) Bloqueo de tercer grado, C) Fibrilación auricular, D) Fibrilación ventricular y E) Alteración en ritmo cardíaco Fuente: (Silverthorn, 2008).	13
Figura. 11 Diagrama de una red convolucional tradicional.	16
Figura. 12 Elementos de la interfaz PÉEK.	20
Figura. 13 Representación minimalista de una hamburguesa para el ícono de menú principal en páginas web [28].	21
Figura. 14 Ubicación de Anvil Uplink.	21
Figura. 15 Ejemplo de código proporcionado por la función Anvil Uplink.	22
Figura. 16 Ejemplo de Código para establecer conexión con la interfaz web.	22
Figura. 17 Ejemplo código para definir a una función como llamable para Anvil.	22
Figura. 18 Trazo muestra de ECG con PVC en formato “.csv”.	24
Figura. 19 Familia de formas de onda Daubechies [33].	26
Figura. 20 Detección de complejo QRS en un trazo con ruido y una duración de 3 segundos (Muestra 105 de la base de datos MIT-BIH) [kalidas2017].	27
Figura. 21 Ventana obtenida a partir de un trazo de ECG de la base de datos MIT-BIH.	28
Figura. 22 Clasificación de latidos de la base de datos MIT-BIH según la AAMI.	30
Figura. 23 LightWAVE, aplicación web para visualizar trazos de ECG de la base de datos MIT-BIH Arrhythmia Database.	31
Figura. 24 Pantalla de selección de trazo/paciente.	31
Figura. 25 Pantalla de visualización de grafo: A) Controles de desplazamiento, B) botones de búsqueda, C) recuadro de búsqueda de ciclo cardíaco por tipo, D) herramientas del gráfico y E) tamaño de ventana en segundos.	32
Figura. 26 Sección Tables de la aplicación LightWAVE con descripción del paciente/registro “100”.	33

Figura. 27 Localización de un ciclo cardíaco con PVC en el registro 100 con herramientas de gráfico ocultas.....	33
Figura. 28 Carpetas clasificadas por tipo de arritmia.....	34
Figura. 29 Muestra de imágenes numeradas de la carpeta PVC .....	34
Figura. 30 A) Botón para activar Google Drive en CoLab, B) vista con Google Drive activado .....	35
Figura. 31 Arquitectura de la CNN utilizada .....	36
Figura. 32 Parámetros del modelo entrenado .....	37
Figura. 33 Características del servidor proporcionado por Google Colab.....	38
Figura. 34 División del conjunto de datos para entrenamiento y validación del modelo de predicción .....	38
Figura. 35 Evaluación del modelo propuesto utilizando 25 épocas .....	39
Figura. 36 Gráficas de precisión y pérdida presentadas por el modelo propuesto.....	40
Figura. 37 Resultado de la evaluación final del algoritmo con el conjunto de datos de entrenamiento.....	40
Figura. 38 Conteo de ciclos cardiacos encontrados por el modelo propuesto y las anotaciones de la base de datos MIT-BIH.....	40
Figura. 39 Matriz de confusión y evaluación estadística del algoritmo propuesto.....	41
Figura. 40 Resultado mostrado desde la aplicación web PÉEK al finalizar el proceso de identificación de arritmias.....	42

# Capítulo 1: Introducción

## 1.1 Antecedentes

De acuerdo con la *Organización Mundial de la Salud*, las enfermedades cardiovasculares (CVD, por sus siglas en inglés de *Cardiovascular Disease*) son la mayor causa de muerte a nivel mundial, sus estadísticas indican que 17.5 millones de personas murieron a causa de CVD en el 2020, representando al 32% de muertes globales (World Health Organization, 2021).

Las enfermedades cardiovasculares más frecuentes y de mayor influencia en la mortalidad son principalmente las derivadas de la arteriosclerosis, particularmente el *Infarto Agudo al Miocardio* (IAM). Su incidencia se eleva significativamente con la edad, pues son consecuencia de la acción prolongada de diversos factores de riesgo como la hipertensión, el tabaquismo, la obesidad, el sedentarismo, colesterol alto y el envejecimiento (Luis et al., 2013)(Dé et al., 2013).

En México, en 2020 el Instituto Nacional de Estadística, Geografía e Informática reportó que la diabetes mellitus, las enfermedades isquémicas del corazón y diabetes son las principales causas de muerte de la población ya que representan el 36% de las defunciones totales. Representando las enfermedades isquémicas del corazón el 21% de las muertes totales, esto es 156 mil 041 muertes ocurridas por esta causa (INEGI, 2021), como se muestra en la Figura 1.

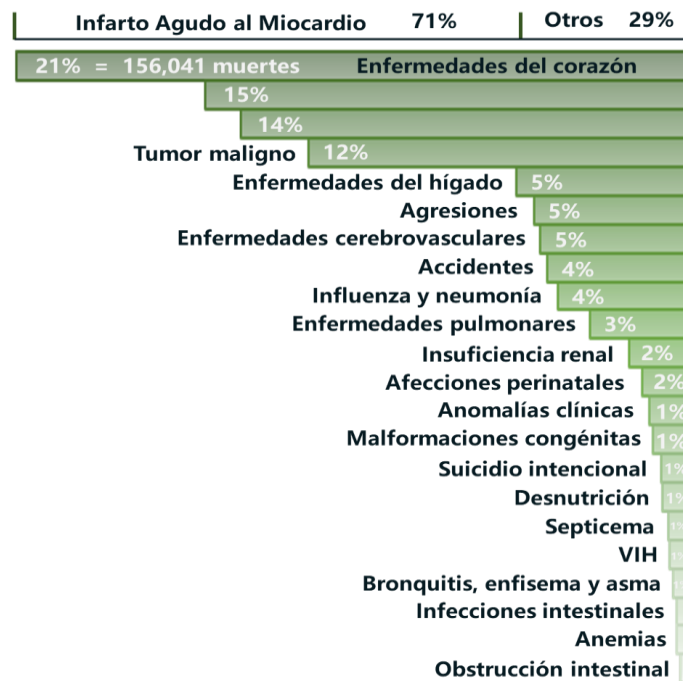


Figura. 1 Principales causas de mortalidad en México (INEGI, 2021).

Algunos métodos para la prevención del padecimiento de enfermedades cardiovasculares han sido la aplicación de políticas integrales de control del tabaco; aumento de impuestos para reducir la ingesta de alimentos con alto contenido de grasas, azúcar y sal; construcción de vías peatonales y carriles para bicicletas con el fin de promover la actividad física; estrategias para reducir el consumo nocivo de alcohol; suministro de comidas saludables en los comedores escolares (Luis et al., 2013). Dichas estrategias aún permanecen lejos de ser óptimas, por lo que el médico familiar juega un papel importante en la prevención de sus pacientes, considerando todos los factores de riesgo que el paciente presente y estimando el riesgo cardiovascular que este presenta para diseñar un tratamiento individualizado acerca de los cambios de estilo de vida que deberá hacer y el tratamiento médico que deberá llevar. Incluso, operaciones quirúrgicas para tratar las CVD, tales como el trasplante de corazón, implantes de corazón artificial, angioplastia con globo (introducción de un globo en la arteria obstruida) y la reparación o sustitución de las válvulas del corazón (Francisco Jiménez-Navarrete et al., 2013).

## Métodos de diagnóstico de arritmias

Existen diversos trabajos que reportan enfoques para proveer herramientas que asistan al médico para buscar anomalías pero no generan un diagnóstico y se basan en el uso del vector de una dimensión para su análisis, no en la imagen del ciclo cardíaco.

<b>Autor</b>	<b>Aplicación</b>	<b>Algoritmo DL</b>	<b>Base de datos</b>	<b>Resultados</b>
(Yildirim, 2018)	Clasificación de arritmia	LSTM	MIT-BIH	Acc.: 99.39%
(Guo et al., 2019)	Clasificación de arritmias	LSTM y extracción de características con CNN	Fantasia; St. Petersburg INCART	Acc.: 99.85%
(Faust et al., 2018)	Clasificación de arritmias	LSTM y extracción de características con CNN	MIT-BIH	Acc.: 98.10%
(Wang et al., 2019)	Clasificación de latidos	LSTM	MIT-BIH, INCART	Acc.: 99.9%
(Andersen et al., 2019)	Fibrilación auricular	LSTM y extracción de características con CNN	MIT-BIH	Acc.: 97.80%
(Saadatnejad et al., 2020)	Clasificación de arritmias	RNN	MIT-BIH	Acc.: 93.53%
(Ping et al., 2020)	Fibrilación auricular	LSTM y extracción de características con CNN	Cardiology Challenge 2017 Dataset	Sped up by 38% F1 score 89.55%

**Tabla 1** Tabla comparativa de estudios que proponen el uso de aprendizaje profundo para la clasificación de arritmias cardíacas

## 1.4 Planteamiento del problema

La examinación manual es esencial, pero un cardiólogo debe analizar el trazo de ECG de 24 a 48 horas para identificar anomalías de aparición prolongada. Es una tarea cansada y complicada que se atiene al error humano aún con expertos entrenados por años (véase Figura 2). El análisis asistido por computadora es más

rápido y preciso sin la diferencia ocasionada por inter-operadores (Liu et al., 2021).

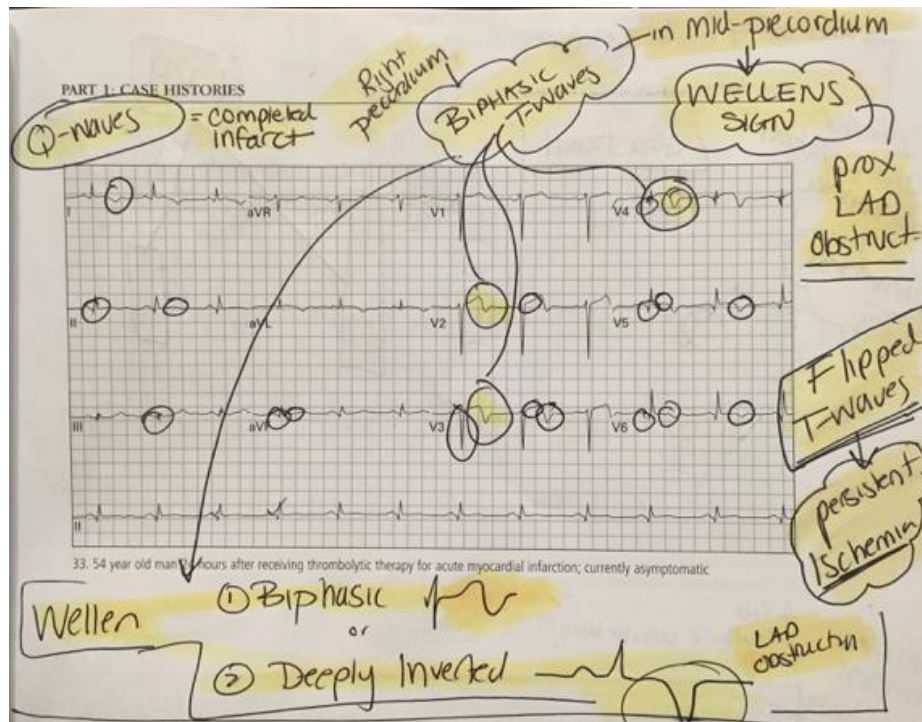


Figura. 2 Trazo de ECG en papel con anotaciones de un especialista

Los métodos actuales para identificación de arritmias basados en Machine Learning implican un alto costo computacional (Liu et al., 2021)(Rath et al., 2021). Esto dificulta su uso en aplicaciones portátiles para atención domiciliaria o telemedicina (Peimankar & Puthusserypady, 2021). La telemedicina juega un papel importante ya que proporciona un diagnóstico oportuno y de bajo costo (Liu et al., 2021).

## 1.4 Objetivos de la Tesis

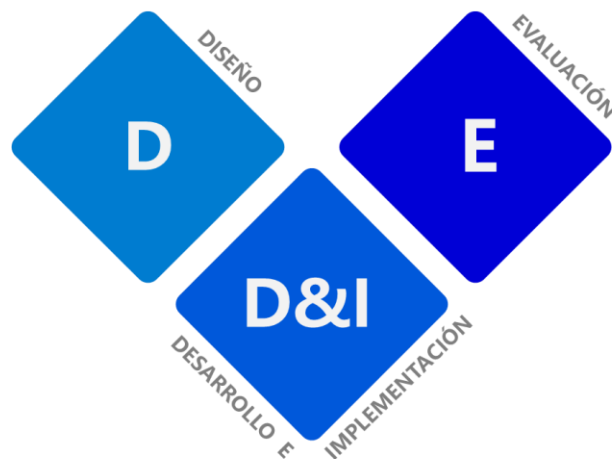
### 1.4.1 Objetivo General

Desarrollar una aplicación web de uso libre que ayude a los especialistas a detectar latidos normales y latidos anormales asociados al infarto agudo al miocardio a partir de imágenes de trazos electrocardiográficos utilizando Redes Neuronales Convolucionales.

## 1.5 Objetivos específicos

- Generar un conjunto de datos relacionados con trazos electrográficos de las bases de datos MIT-BIH para el entrenamiento y prueba de un modelo de clasificación de arritmias.
- Diseñar el modelo arquitectónico del componente de software que se ejecutará en la WEB.
- Implementar los métodos y algoritmos de aprendizaje profundo para la clasificación de un trazo electrocardiográfico
- Evaluar la efectividad del componente de software

## 1.6 Metodología



*Figura. 3 Etapas de la Metodología*

Las etapas de la metodología propuesta están basadas en el trabajo de Jonas Löwgren (Lowgren, 1995), quien aplicó la metodología de diseño en el área de desarrollo de software, y la metodología propuesta por Luis Barría (Barría Rumbaut, 2013) en su tesis de maestría sobre el diseño de software dedicado al aprendizaje.

En la etapa de diseño (D) se busca analizar e identificar los métodos y modelos de aprendizaje profundo utilizados para el análisis de detección de arritmias cardíacas mediante una revisión bibliográfica de los últimos 3 años, además de identificar las herramientas de desarrollo que serán utilizadas.

En la etapa de desarrollo e implementación (D&I) se desarrolla la aplicación web implementando el modelo de aprendizaje profundo seleccionado y sus parámetros, entrenando al modelo y aplicando pruebas por módulos para añadir funcionalidades a la aplicación web de forma iterativa hasta alcanzar los objetivos planteados, desarrollándose mediante el uso de software libre.

En la etapa de evaluación (E), se selecciona una muestra de nuestra población total de datos para validar el cumplimiento de las funciones de la aplicación web mediante métricas de rendimiento.

## **1.7 Organización de la Tesis**

Esta tesis está conformada por seis capítulos y dos apéndices. En este primer capítulo se presentó la motivación para realizar este trabajo de tesis. En el siguiente capítulo, se presenta la fisiología del corazón. En el Capítulo 3 se introduce a las redes neuronales convolucionales sus elementos. El diseño de la aplicación PÉEK que tiene por objetivo detectar arritmias en un electrocardiograma es presentado en el Capítulo 4. La evaluación de la aplicación de PÉEK con respecto a su precisión para detectar arritmias en un electrocardiograma es presentada en el Capítulo 5. Las conclusiones del trabajo realizado y posibles nichos de trabajo futuro se presentan en el capítulo 6.

## Capítulo 2: Marco teórico

En este capítulo se hablará a detalle sobre el proceso eléctrico y mecánico que se lleva a cabo durante un ciclo cardíaco o latido del corazón, cómo pueden medirse estos procesos mediante un electrocardiograma y qué información nos indica cada forma de onda. Así también, se dará a conocer las características y partes que conforman a una red convolucional para reconocimiento de patrones.

### 2.1 Fisiología cardíaca

El corazón es el motor del cuerpo humano, una bomba que suministra sangre a todos los órganos mediante la contracción de los músculos que lo componen, este se contrae continuamente y solo reposa en la pausa de milisegundos entre cada latido. El corazón se ubica en el centro del tórax (Figura 4), entre los pulmones, y tiene cuatro cavidades que mantienen el flujo sanguíneo (ver Figura 5).

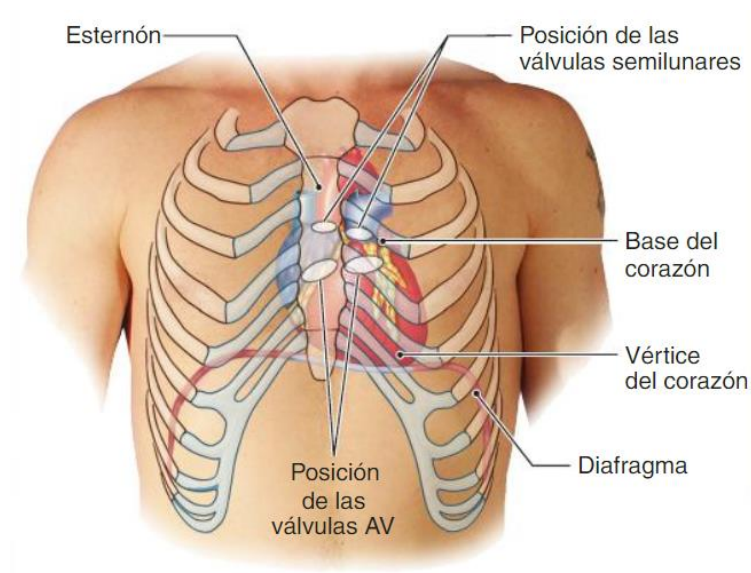


Figura. 4 Ubicación gráfica del corazón en el centro del tórax (Silverthorn, 2019)

El corazón está compuesto mayormente por músculo o miocardio (*myo*, músculo + *kardia*, corazón) y a sangre fluye de las venas a las cavidades superiores

llamadas aurículas y desde ahí a los ventrículos, que son las cavidades inferiores que bombean la sangre al cuerpo, como se observa en la Figura 6.




Figura. 5 Estructura del corazón y flujos sanguíneos a través de él (Silverthorn, 2019)

	Recibe sangre de	Envía sangre a
<b>Corazón</b>		
Aurícula derecha	Venas cavas	Ventrículo derecho
Ventrículo derecho	Aurícula derecha	Pulmones
Aurícula izquierda	Venas pulmonares	Ventrículo izquierdo
Ventrículo izquierdo	Aurícula izquierda	Cuerpo, excepto pulmones
<b>Vasos</b>		
Venas cavas	Venas sistémicas	Aurícula derecha
Tronco (arteria) pulmonar	Ventrículo derecho	Pulmones
Vena pulmonar	Venas del pulmón	Aurícula izquierda
Aorta	Ventrículo izquierdo	Arterias sistémicas

Figura. 6 Cavidades del corazón y principales vasos sanguíneos (Silverthorn, 2019)

La mayor parte del músculo cardíaco es contráctil, pero alrededor del 1% de las células miocárdicas están especializadas en generar potenciales de acción o impulso eléctrico de forma espontánea (Sherwood, 2011)(Silverthorn, 2019), las cuáles son llamadas células *autorrítmicas o marcapasos* y son responsables de una propiedad única del corazón, que es la contracción autónoma. La comunicación eléctrica comienza con un potencial de acción de una célula marcapasos y se propaga con rapidez a las células adyacentes. La propagación del impulso eléctrico o despolarización es seguida de una onda de contracción que atraviesa las aurículas y se desplaza a los ventrículos.

### 2.1.1 Electrocardiograma

Un electrocardiograma (ECG) es un registro extracelular que representa la suma de múltiples potenciales de acción que tienen lugar en numerosas células del músculo cardíaco y es adquirida por medio de electrodos superficiales colocados sobre el cuerpo (Sherwood, 2011). Las corrientes eléctricas generadas por el músculo cardíaco durante la despolarización y repolarización se propagan a los tejidos que rodean al corazón y son conducidas a través de los líquidos corporales hasta alcanzar la superficie corporal (Sherwood, 2011).

La interpretación de la configuración de la onda registrada por cada derivación depende del conocimiento a fondo sobre la secuencia de la propagación de la excitación cardíaca y sobre la posición del corazón en relación a la colocación del electrodo (Figura. 7). Un ECG normal tiene tres formas de onda: La onda P, el complejo QRS, y la onda T (Silverthorn, 2019).

- La **onda P** representa la despolarización auricular.
- El **complejo QRS** representa la despolarización ventricular.
- La **onda T** representa la repolarización ventricular.

Además de contar con intervalos y segmentos entre ondas que también representan un suceso dentro de la actividad eléctrica y mecánica del corazón:

- El **segmento PR** representa el retardo nodal auriculoventricular (AV), que es el tiempo en que tarda en comenzar la despolarización ventricular. Durante este intervalo, las aurículas se encuentran contraídas, vaciando la sangre que contenían hacia los ventrículos.
- El **segmento ST** es el tiempo durante el cual los ventrículos se contraen y vacían la sangre que contenían hacia las arterias.
- El **segmento TP** es el intervalo de tiempo en el cual se relajan y llenan los ventrículos .

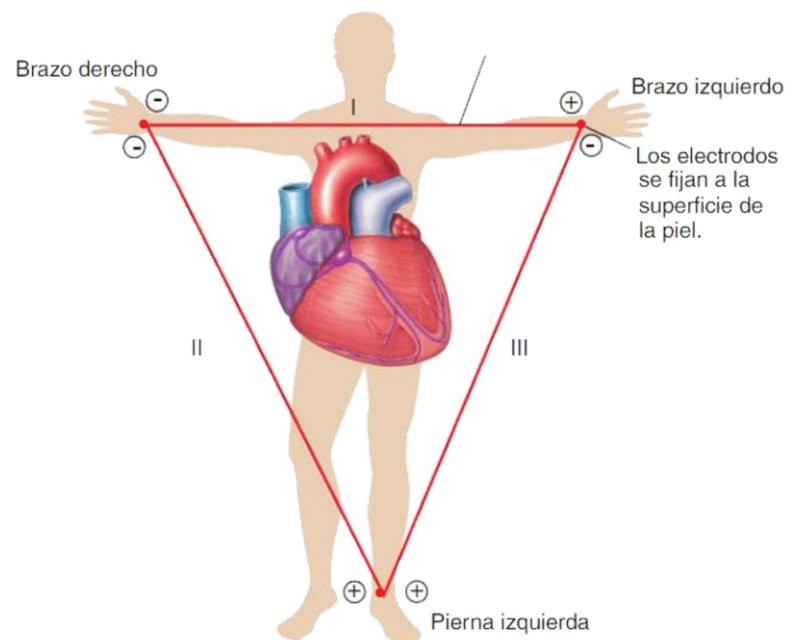


Figura. 7 Triángulo de Einthoven: derivaciones para realizar registros de ECG (Sherwood, 2011)

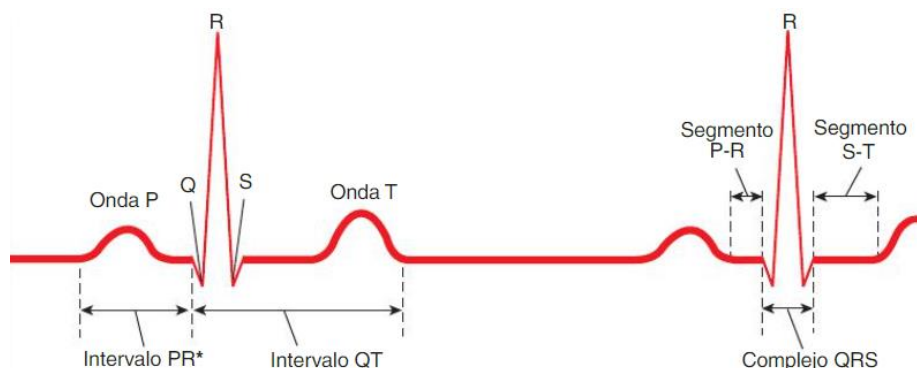


Figura. 8 Formas de onda de un latido en un ECG normal (Sherwood, 2011)

El ritmo sinusal comienza en el nodo sinusal, produciendo la despolarización de la aurícula (onda P del ECG, que es positiva de II, III, y aVF y negativa en aVR).

El impulso alcanza el nodo AV, donde experimenta un retraso en su conducción (intervalo PR). Una vez que alcanza el Haz de His, se distribuye rápidamente a los ventrículos dando lugar al QRS, que es estrecho. Posteriormente aparece la repolarización ventricular, que se representa en el ECG con la onda T, teniendo la misma polaridad que la onda P. La frecuencia normal de descarga del nodo sinusal es de 60-100 latidos por minuto (lpm)

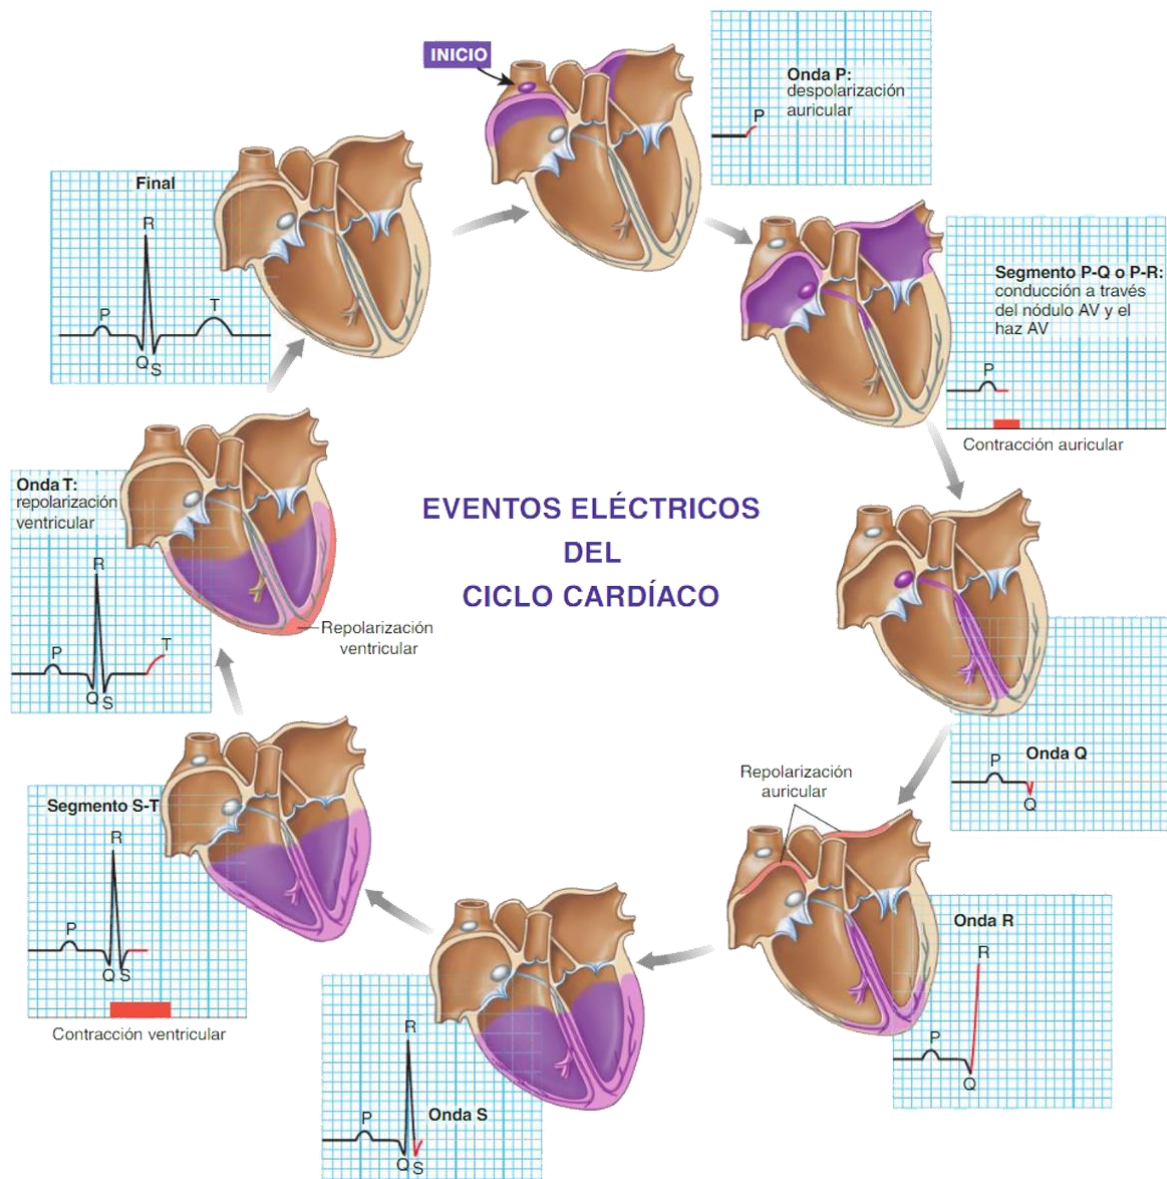


Figura. 9 Correlación entre las formas de onda en un ECG y los eventos cardíacos del corazón (Silverthorn, 2019)

Hay puntos a considerar sobre un registro de un ECG:

- El disparo del **nodo Sinoauricular (SA)** no genera actividad eléctrica como para alcanzar la superficie corporal, por lo que no hay una onda de registro para la despolarización del nodo SA. La primera onda que se registra es la onda P, que ocurre cuando el impulso o despolarización se propaga a través de las aurículas.
- No existe onda que indique la repolarización auricular. Su actividad eléctrica ocurre de manera simultánea con la despolarización ventricular y es enmascarada por el **complejo QRS**.
- La **onda P** es mucho más pequeña que el complejo QRS debido a que las aurículas tienen una masa muscular mucho menor que los ventrículos. En consecuencia, a ello, se genera menos actividad eléctrica.
- En los **segmentos PR, ST y TP** no existe un flujo de corriente neto en la musculatura del corazón, por lo que el ECG permanece en línea basal

Un ECG proporciona información sobre la frecuencia y el ritmo cardíaco, la velocidad de conducción y el estado de los tejidos cardíacos. Para clasificar un ECG como normal o anormal, se realiza un cuidadoso análisis profesional sobre las características de las formas de onda. Debido a que la actividad eléctrica dispara la actividad mecánica, los patrones de actividad eléctrica anormal son generalmente acompañados por actividad contráctil anormal del corazón. Por lo tanto, la evaluación de los patrones ECG puede proveer información útil sobre el estado del corazón.

## 2.2 Arritmias

Se define arritmia como cualquier alteración del ritmo cardiaco anormal (Sherwood, 2011), es decir, cualquier ritmo diferente al ritmo sinusal. Las principales desviaciones de la normalidad que pueden encontrarse a través de la electrocardiografía son: anomalías en la frecuencia, anomalías en el ritmo cardíaco, y cardiomiopatías.



Figura. 10 Condiciones cardiacas representativas A) ECG normal, B) Bloqueo de tercer grado, C) Fibrilación auricular, D) Fibrilación ventricular y E) Alteración en ritmo cardíaco (Silverthorn, 2019)

### 2.2.1 Anormalidades en la frecuencia

La frecuencia cardíaca puede determinarse por la distancia entre dos complejos QRS consecutivos en el ECG. Una frecuencia cardíaca rápida de más de 100 latidos por minuto se llama **taquicardia** (*tachy* significa “rápido”), mientras que una frecuencia cardíaca lenta, menor a 60 latidos por minuto, se denomina **bradicardia** (*brady* significa “lento”). Una frecuencia normal se encuentra entre los 60-100 bpm (latidos por minuto, por sus siglas en inglés “beats per minute”).

### 2.2.2 Anormalidades en el ritmo

El ritmo se refiere a la regularidad o espacio de las ondas del ECG. Cualquier variación del ritmo normal y de la secuencia de la excitación en el corazón se denomina **arritmia**. Puede ser resultado de **focos ectópicos**, alteraciones en la actividad de marcapasos del nodo SA, o interferencia con la conducción. A menudo la frecuencia cardíaca también se altera. Las extrasístoles o contracciones prematuras ventriculares, originadas en un foco ectópico son desviaciones comunes

del ritmo normal. Otras anomalías en ritmo fácilmente detectadas en un ECG incluyen el aleteo auricular, la fibrilación auricular, la fibrilación ventricular y el bloqueo cardíaco.

El **aleteo auricular** se caracteriza por una rápida pero regular secuencia de despolarizaciones auriculares en frecuencias entre los 200 y 380 lpm. Los ventrículos rara vez mantienen el paso con los rápidos latidos de las aurículas. Debido a que el periodo refractario del tejido conductor es mayor que el del músculo auricular, el nodo AV es incapaz de responder a cada impulso que converge en él proveniente de las aurículas. Una frecuencia tan alta no permitiría el tiempo adecuado para el llenado ventricular entre latidos. En este caso, el flujo sanguíneo se reduciría a tal extremo que resultaría en la pérdida de conciencia o aún en la muerte debido a la disminución del flujo de sangre al cerebro.

La **fibrilación auricular** está caracterizada por la despolarización rápida, irregular y descoordinada de las aurículas, sin ondas P definidas. Por lo tanto, las contracciones auriculares son caóticas y asincrónicas. Debido a que los impulsos alcanzan erráticamente el nodo AV, el ritmo ventricular también es bastante irregular. Los complejos QRS son normales en forma, pero ocurren esporádicamente.

La **fibrilación ventricular** es una anomalía rítmica muy seria en donde la musculatura ventricular exhibe contracciones caóticas y descoordinadas. Múltiples impulsos viajan erráticamente en todas las direcciones alrededor de los ventrículos. El registro del ECG en la fibrilación ventricular es muy irregular, sin patrón o ritmo detectable. Los ventrículos se convierten en bombas de flujo ineficaces. Si la circulación no se restablece en menos de cuatro minutos a través de compresión cardíaca externa o desfibrilación eléctrica, ocurren daños irreversibles al cerebro y la muerte es inminente.

El **bloqueo cardíaco** se origina a partir de defectos en el sistema de conducción cardíaco. Las aurículas siguen latiendo con regularidad, pero los ventrículos ocasionalmente fallan al ser estimulados y por lo tanto no se contraen después de la contracción de las aurículas. El bloqueo cardíaco completo se caracteriza por la completa disociación de la actividad auricular y ventricular, donde los impulsos de las aurículas no son conducidos a los ventrículos.

La **contracción prematura de los ventrículos (PVC)** son latidos que tienen origen en los ventrículos y, por lo tanto, no se distingue su forma de onda P ni su complejo QRS (Rodríguez et al., 2014).

Las ondas anormales en el ECG también son importantes para conocer y evaluar cardiomiopatías (daño del músculo cardíaco). La **isquemia miocárdica** es el inadecuado suministro de sangre oxigenada al tejido cardíaco. La muerte, o **necrosis**, de las células del músculo cardíaco ocurre cuando un vaso sanguíneo que irriga a esa área del corazón se bloquea o se rompe. Esta condición es llamada **Infarto Agudo al Miocardio**, comúnmente llamado **ataque cardíaco**. Formas anormales de ondas QRS aparecen cuando parte del músculo cardíaco se hace necrótico. Además de los cambios en el ECG, debido a que las células musculares dañadas liberan enzimas características a la sangre, el nivel de estas enzimas en la sangre nos da un índice más completo del daño al corazón (Sherwood, 2011).

## 2.3 Redes Convolucionales

Una Red Neural Convolutiva (del inglés Convolutional Neural Network, CNN) es un tipo de Red Neural Profunda diseñada específicamente para el reconocimiento de imágenes (Zaccone & Karim, 2018), donde cada imagen utilizada en el proceso de aprendizaje se divide en porciones topológicas compactas, cada una de las cuales será procesada por filtros mientras se buscan patrones particulares. En una CNN, cada imagen de entrada se representa como una matriz tridimensional de píxeles, que consta de anchura, altura y canales de color (profundidad) respectivamente.

### 2.3.1 Estructura de una red neuronal convolutiva

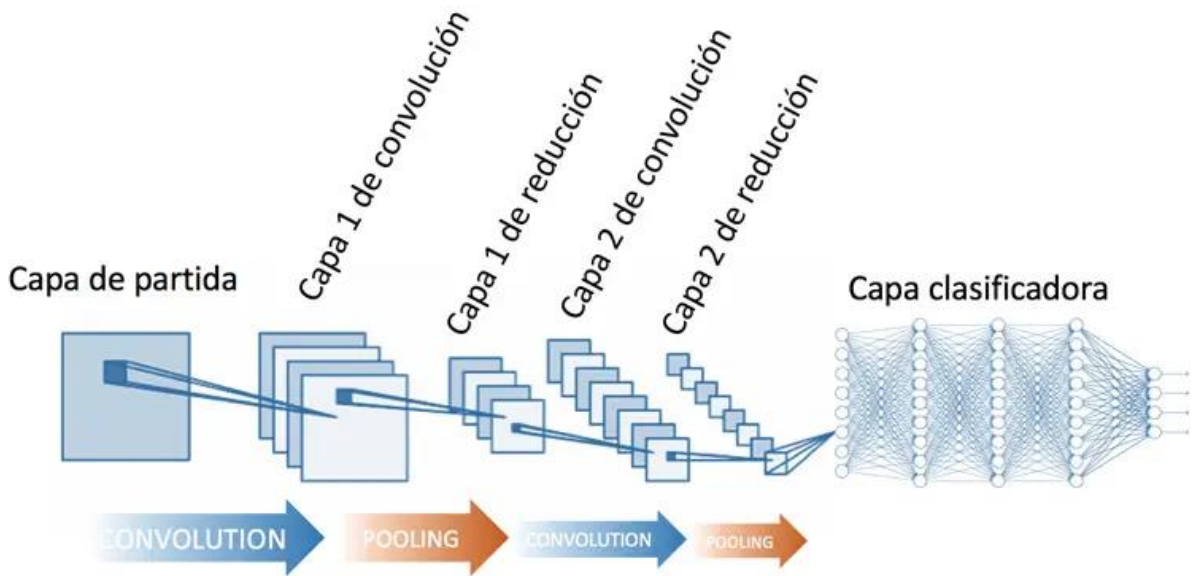


Figura. 11 Diagrama de una red convolucional tradicional

La Fig. 11 muestra la arquitectura básica de una CNN y sus componentes, que se describen a continuación:

- **Capa de convolución:** Es un tipo especial de capa donde cada neurona está conectada a una determinada región del área de entrada llamada campo receptivo (Zaccone & Karim, 2018). Las capas convolucionales utilizan varios filtros kernel de diferentes dimensiones sobre los mismos campos receptivos para reconocer imágenes de una característica diferente. El conjunto de neuronas que identifican la misma característica define un único mapa de características.
- **Capa de Pooling:** Las CNN también utilizan capas de agrupación situadas inmediatamente después de las capas convolucionales. Una capa de pooling divide una región convolucional en subregiones y, a continuación, selecciona un único valor representativo para reducir el tiempo computacional de las capas posteriores y aumentar la robustez de la característica con respecto a su posición espacial (Zaccone & Karim, 2018).
- **ReLU:** Es una función lineal que convierte los valores de la entrada en números positivos (Alzubaidi et al., 2021). Es la función de activación por defecto de muchas redes neuronales, ya que los modelos que la utilizan son más fáciles

de entrenar y a menudo consiguen un mejor rendimiento.

- **Capas totalmente conectadas:** Las Capas Totalmente Conectadas forman las últimas capas de una CNN (Habibi Aghdam & Jahani Heravi, 2017); su entrada es la salida de la última Capa Pooling o Convolutiva, que se aplana y se introduce en ella para realizar las operaciones matemáticas que, una vez pasadas a la Capa Softmax, determinarán la probabilidad de cada clase.
- **Capa Softmax:** La Capa Softmax es una capa de salida para tareas de multclasificación en conjunción con la función de pérdida Cross-Entropy. Normaliza las salidas de la capa anterior, para que sumen uno. De esta manera, la salida podría representar la probabilidad para cada clase (Ketkar, 2017).
- **Función de pérdida:** Es el error de predicción de una Red Neuronal, denotado por la diferencia entre la salida y la verdad básica para una sola entrada (Zhao et al., 2016). La Función de Pérdida a utilizar dependerá de la naturaleza del problema, siendo las más comunes el Error Medio Cuadrático, Binario, Categórico, y la Entropía Cruzada Categórica Esparcida.

# Capítulo 3: Diseño de PÉEK

## 3.1 Introducción

Se desarrolló una aplicación web de uso libre que ayuda a los especialistas a detectar latidos normales y latidos anormales asociados al infarto agudo al miocardio a partir de imágenes de trazos electrocardiográficos utilizando algoritmos de Deep Learning. A esta aplicación la llamamos PÉEK, que significa “Latido” y proviene del vocablo Maya.

La aplicación web fue desarrollada en lenguaje Python versión 3.7.3.6 con las siguientes librerías o marcos de desarrollo listados en la Tabla 1.

Librería	Versión
Tensor Flow	2.6.0
Keras	2.6.0
OpenCV	4.1.2.30
Numpy	1.19.5
Matplotlib	3.2.2
Py-ECG-detectors	1.0.2
PIL	7.1.2
Pandas	1.1.5
Anvil-UpLink	0.3.39

Tabla 2. Librerías utilizadas para PÉEK

PÉEK cuenta con los siguientes componentes:

- Una interfaz de usuario diseñada en el ambiente de programación Anvil Works<sup>1</sup>.
- Cliente en código Python, que se ejecuta en un navegador web (p. ej chrome,

---

<sup>1</sup> [Anvil | Build Web Apps with Nothing but Python](#)

edge).

- Servidor en código Python, que se ejecuta en los servidores gratuitos de Google Colab<sup>2</sup>.
- Una base de datos incorporada (Data Tables) en combinación con Google Drive, que almacena las imágenes y vectores obtenidos con cada interacción desde la aplicación web.

### 3.2 Interfaz de PÉEK

La interfaz de la aplicación PÉEK fue desarrollada utilizando Anvil, un servicio web para diseño de aplicaciones Full Stack, el cual permite su edición en HTML, CSS y JavaScript, o utilizar el modo gráfico para facilitar la ubicación y edición de objetos mediante el arrastre y personalización (Galvão et al., 2021). Para el desarrollo de PÉEK, fueron utilizadas ambas formas de diseño. Anvil tiene soporte incorporado para:

- Alojamiento y despliegue con un solo clic.
- Versionar su aplicación con el control de versiones Git.
- Enviar y recibir correos electrónicos.
- Exponer y utilizar APIs HTTP.
- Integrar con servicios de: Google, Microsoft, Facebook, Stripe y culturizar rostro con un SDK de Python.

La interfaz de la aplicación PÉEK presenta la siguiente información:

1. Nombre de la aplicación web.
2. Menú hamburguesa con funciones que se desarrollarán como trabajo futuro.
3. Botón para subir el trazo de ECG como vector en archivo CSV.
4. Botón para cargar el archivo seleccionado y presentarlo en pantalla.
5. Selectores con sus respectivos cuadros de texto para declarar la frecuencia de muestreo del trazo o la duración del mismo en segundos.
6. Botón para comenzar la identificación de arritmias y plasmarlo en pantalla.
7. Visualizador de trazo electrográfico tras cargarlo desde el archivo CSV.

---

<sup>2</sup> [Google Colab](#)

## 8. Visualizador de trazo electrográfico con marcas de arritmias identificadas.

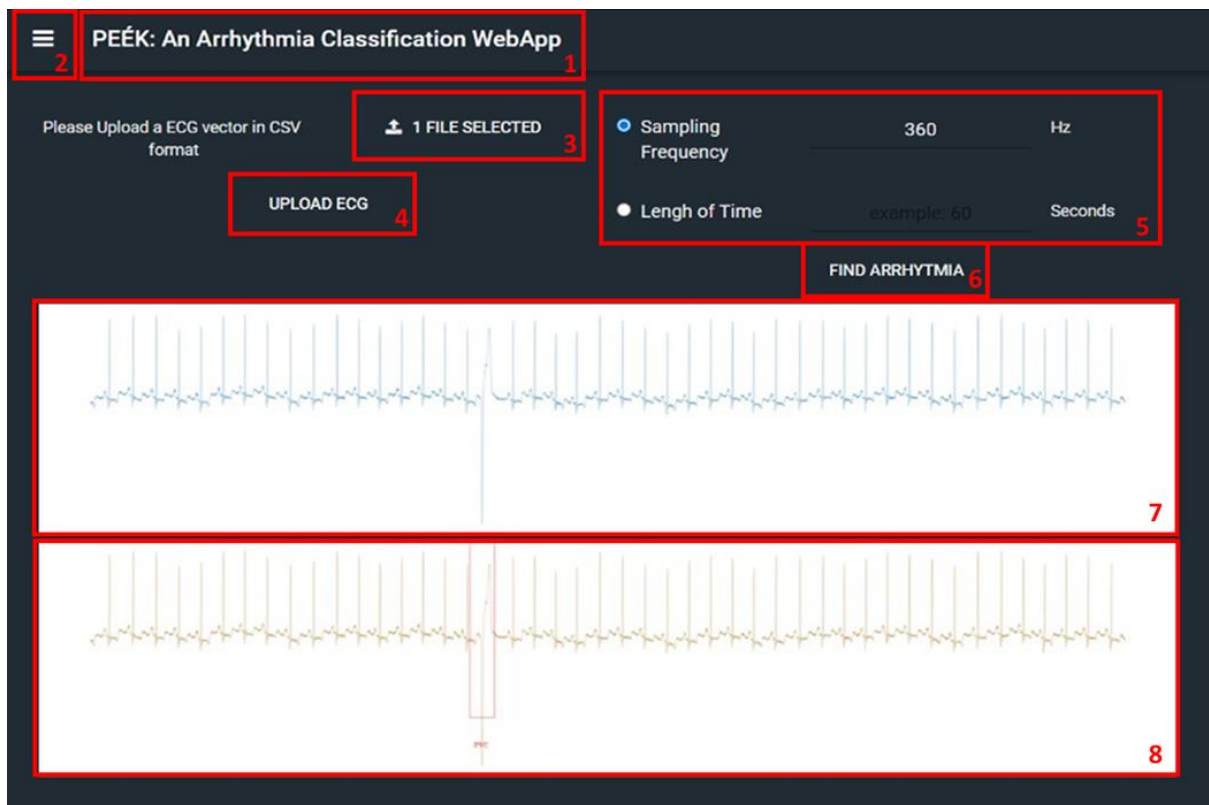


Figura. 12 Elementos de la interfaz PEEK

El diseño de la interfaz web se basa en las tendencias actuales de diseño web minimalista, identificados en un estudio de homólogos (Sánchez Díaz et al., 2019) realizado en páginas web de la industria farmacéutica y médica que se caracteriza por un sistema de navegación global representado por etiquetas y la forma de su menú hamburguesa (véase Figura 13). Dicho menú consiste en un ícono formado por tres líneas horizontales que forman la imagen minimalista de una hamburguesa y, cuando se activa, este se despliega para mostrar sus contenedores de funciones adicionales a los que se presentan en la pantalla principal.

El menú hamburguesa facilita la navegación permitiendo recoger todos los elementos del menú de forma que solamente serán visibles cuando se le seleccione y se ocultará nuevamente al presionarlo por segunda vez. Además, la aplicación web está pensada para su funcionamiento a futuro en dispositivos móviles, por lo que este diseño de menú se adaptará fácilmente al tamaño de la pantalla y su forma de desplegar y ocultar sus elementos.



Figura. 13 Representación minimalista de una hamburguesa para el ícono de menú principal en páginas web (Ortega, 2017)

### 3.3 Conexión Cliente-Servidor

Para establecer conexión entre la interfaz de la aplicación web y el servidor Colab. Anvil proporciona un enlace llamado “Uplink” que deberá llamarse desde el servidor utilizando la librería “Anvil Uplink”. En la sección de opciones, dentro del ambiente de programación de Anvil, se encuentra dicho enlace, tal como se muestra en la Fig. 14.

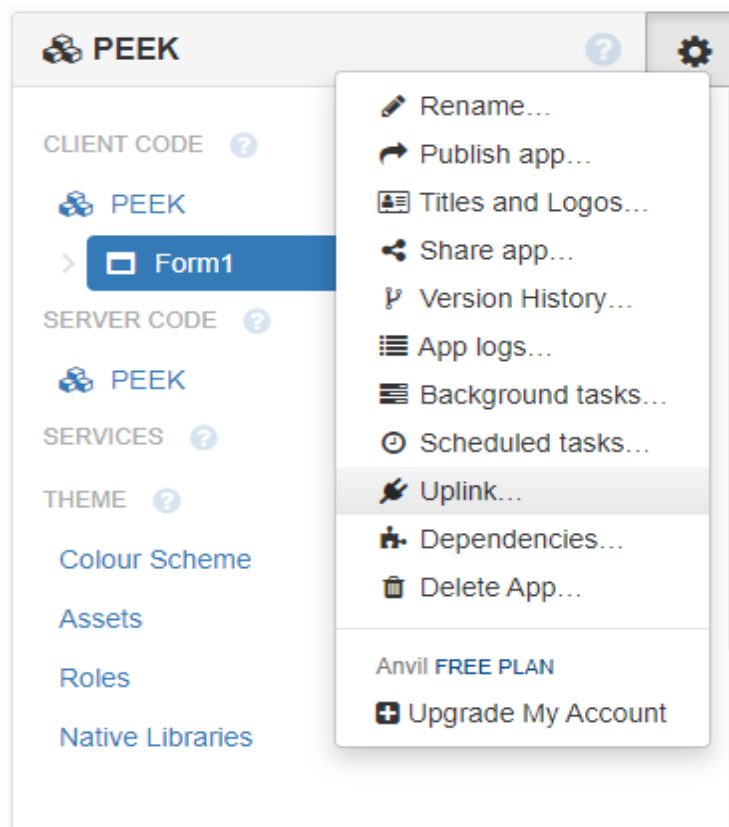


Figura. 14 Ubicación de Anvil Uplink

## Connect your app to existing code

Server code

Client code

To connect privileged code to this app, use the following uplink key:

G4SKKTLX4IJI2P45FWMBJK3J-7I6IYR6U2OJCTQUL

Reset Uplink Key ↻

Figura. 15 Ejemplo de código proporcionado por la función Anvil Uplink

Desde el código del servidor colab, se manda a llamar la llave Uplink utilizando la librería Anvil Uplink y la función `anvil.serv.connect` (Figura 16).

```
import anvil.server
import anvil.media

anvil.server.connect("G4SKKTLX4IJI2P45FWMBJK3J-7I6IYR6U2OJCTQUL")
```

Figura. 16 Ejemplo de Código para establecer conexión con la interfaz web

Una vez establecida la conexión, Anvil puede mandar a llamar las funciones dentro del servidor, mientras estas tengan el llamado `@anvil.server.callable` antes de definición de la función (Fig 17).

```
@anvil.server.callable
def Upload_ECG(orECG, Fs, FST):
    #Frecuencia de muestreo o Duración
    if FST == 1:
        Fs=int(Fs)
    if FST == 2:
        Fs=1/int(Fs)
    #Transformar el archivo CSV de 1 dimen
```

Figura. 17 Ejemplo código para definir a una función como llamable para Anvil

Mediante este llamado, Anvil proporciona una o más variables para ser procesadas en el servidor y recibir, de igual manera, una variable de respuesta.

### **3.4 Procesamiento del trazo electrocardiográfico**

La identificación de arritmias a través de la aplicación PÉEK se lleva a cabo en 5 etapas. Estas etapas son la adquisición trazo de ECG, la transformación del trazo o vector a imagen, la identificación de picos R, el ventaneo para generar la imagen del ciclo cardíaco, la valoración de arritmias ciclo por ciclo. Al final, se entrega una imagen del trazo de electrocardiograma con las marcas de arritmias localizadas.

#### **3.4.1 Adquisición del trazo electrográfico**

En esta etapa, el trazo de electrocardiográfico se proporciona a la aplicación web mediante la sección de carga de archivos dentro de la interfaz de usuario. Para realizar esto se utiliza el botón con la etiqueta CSV (del inglés Comma Separated Values). Este permite seleccionar un archivo desde una fuente (p. ej. computadora). El archivo debe tener formato CSV como un vector de 1 dimensión tal como se muestra en la Fig. 4.8.




Figura. 18 Trazo muestra de ECG con PVC en formato “.csv”

Al ser seleccionado el archivo, el usuario debe presionar el botón “Upload ECG” para proporcionar al servidor de Colab al que está conectado. Dicha conexión fue establecida desde el documento de Python, dentro del ambiente de programación de Colab.

### 3.4.2 Transformación del trazo electrocardiográfico a imagen

Dentro del servidor Colab, se define una función para la adquisición del archivo .csv, que es recibido como un objeto multimedia en un formato de Anvil. Para manipularlo, fue necesario utilizar la función “anvil.media.TempFile”, que interpreta el archivo leído por Anvil y lo almacena en el disco duro como archivo temporal en su formato original (.csv).

Una vez en su formato, se procede a su lectura utilizando la librería Pandas para transformar el archivo .csv a un vector de 1 dimensión, que será dibujado en una figura tipo “plot” mediante la librería “matplotlib”, limitando sus dimensiones a 299 píxeles de altura, mientras que el largo de la imagen se calcula en base al tamaño del vector dividido entre la multiplicación frecuencia de muestreo por 100, con la finalidad de disminuir el tamaño de la imagen sin perder información detallada del ciclo cardíaco.

Al finalizar la creación de la figura, se almacena en el disco duro del servidor en formato .png (del inglés Portable Network Graphics), excluyendo los ejes, y se transforma a un formato compatible para Anvil utilizando la función “Anvil.media.from\_file” y se define como objeto multimedia de retorno de la función, que llega a la aplicación web para su despliegue en pantalla.

Una vez desplegada la imagen de ECG, si el usuario decide aplicar la búsqueda de arritmias en el trazo, se llevará a cabo mediante el botón “Find Arrhythmia”, el cuál manda a llamar a una segunda función que transforma el vector del trazo ECG en una variable tipo arreglo numérico que permitirá manipulación para las siguientes funciones.

### **3.4.3 Identificación de picos R**

Para la identificación de arritmias es definir la ventana de muestreo que pasará por el modelo de reconocimiento. Para esto, es necesario identificar los picos R que permitirán ubicar la posición de cada ciclo cardíaco presente en el trazo electrocardiográfico.

Existen distintos algoritmos que permiten la identificación de picos R o del complejo QRS en un trazo electrocardiográfico (Luis & Porr, 2019). Para términos de este proyecto, se utilizó la Transformada Wavelet Estacionaria (SWT, por sus siglas en inglés “Stationary Wavelet Transform”) propuesto por Kalidas, el cual presenta un porcentaje de precisión entre el 99.73% y el 99.87% (Kalidas & Tamil, 2017); el más

alto porcentaje de detección para el complejo QRS entre los algoritmos más populares.

La señal de entrada es remuestreado a 80 Hz, limitando el componente de frecuencia máxima a 40 Hz según el criterio de Nyquist, asumiendo que esta frecuencia es muestreo es la más útil para la localización de un ciclo cardiaco, ya que su rango de frecuencias es de 0.05 Hz a 40 Hz. Lo que permite atenuar la amplitud de los componentes de ruido de alta frecuencia, disminuyendo la sensibilidad de detección de picos, a su vez, este paso reduce el tiempo computacional al reducir el número de muestras y optimizando su aplicación en tiempo real (Kalidas & Tamil, 2017).

Este método calcula la SWT de 2 niveles de la nueva señal utilizando como forma de onda madre la onda Daubechies 3 (db3, como se muestra en la Figura 19) y extrae los coeficientes de detalle del nivel 2, que corresponden al ancho de banda de frecuencias que se sabe que tiene la máxima energía del QRS y, por tanto, es el más adecuado para la detección del QRS (Sun et al., 2005)(Elgendi et al., 2010). Finalmente, remuestrea estos coeficientes a la frecuencia de muestreo original de la señal de entrada, y se le aplica una función cuadrada. Posterior a ello, se le recorre una ventana promediadora (MWA, del inglés Moving Window Averaging) para realzar los picos alrededor de las localizaciones del complejo QRS y atenuar el resto de los puntos de la muestra. Para el paso MWA, la duración de la ventana es de 0.15s y se normaliza la señal promediada entre 0 y 1.




Figura. 19 Familia de formas de onda Daubechies (Mfcc, 2018)

Para localizar los picos R en la señal ECG, se calcula la ubicación real del pico R correspondiente como el índice del pico máximo en la señal de ECG normalizada dentro de los 0,10s anteriores, utilizando un umbral de  $\pm 0.4$  el valor el pico R anterior. Si no se encuentra un pico R en esa ventana, se define el índice del valor de amplitud máxima dentro de dicha ventana.




Figura. 20 Detección de complejo QRS en un trazo con ruido y una duración de 3 segundos (Muestra 105 de la base de datos MIT-BIH) [kalidas2017]

### 3.4.4 Ventaneo de ciclo cardiaco

Con la finalidad de reducir el tiempo computacional durante la identificación de arritmias, se utiliza la posición de los picos R encontrados para crear una ventana. Para esto, se define al pico R como punto de partida y tomando en cuenta que la duración de un ciclo cardíaco completo, desde el inicio de la onda P hasta el final de la onda T, es de 0.8 segundos (Tortora & Derrickson, 2018). En base a lo anterior, la venta se genera tomando 0.32 segundos (40%) antes del pico R, tiempo suficiente para abarcar la onda P, y 0.48 segundos (60%) después del pico R para abarcar hasta el término común de la onda T (Tortora & Derrickson, 2018).




Figura. 21 Ventana obtenida a partir de un trazo de ECG de la base de datos MIT-BIH

La etapa de ventaneo se repite para cada pico R identificado en la etapa anterior. Al crearse cada ventana del ciclo cardíaco, este repite el proceso presentado en la etapa de adquisición de la señal completa, transformando la ventana en una figura tipo “plot” y almacenando en el disco duro del servidor. Esta imagen pasará por la etapa de detección utilizando un modelo de aprendizaje profundo (Deep Learning) previamente entrenado.

### **3.4.5 Detección de la arritmia cardiaca PVC**

#### **3.4.5.1 Base de datos MIT-BIH**

La base de datos MIT-BIH Arrhythmia Database, es una base de datos estándar con material para evaluación de detectores de arritmias (Moody & Mark, 2001). Junto con la base de datos de la Asociación Americana del Corazón (AHA – American Heart Association) (Goldberger et al., 2000), contribuyen en la estimulación de analizadores de arritmias, desarrollo y evaluación de dispositivos médicos e investigación básica. MIT-BIH consta de 48 registros de media hora adquiridos de 47 sujetos; utilizando 2 canales (MLII y V1). Los sujetos incluyen 25 hombres de 32 a 89 años y 22 mujeres de 23 a 89 años. En la mayoría de los registros, uno de los canales es el MLII, y el segundo canal usualmente es el V1. Sin embargo, dependiendo del sujeto, en algunos casos son V2, V4 o V5. El 60% de los registros fueron tomados por pacientes del Laboratorio de Arritmias de Boston's Beth Israel Hospital (BIH; ahora la Beth Israel Deaconess Medical Center).

Los registros 201 y 202 pertenecen al mismo sujeto. De estos, los primeros 23 (las "series 100") fueron elegidos de manera aleatoria de 4,000 registros Holter, y los otros 25 ("series 200") fueron seleccionados incluyendo ejemplos de arritmias no comunes pero clínicamente importantes que no podrían ser bien representados con una pequeña muestra aleatoria.

La clasificación según la AAMI (Association for the Advancement of the Medical Instrumentation) para los latidos cardíacos es la que se muestra en la Figura 22.

Tipos de latidos MIT-BIH	Tipo de latido AAMI
Latido normal (NOR)	Latido normal
Bloqueo de rama izquierdo (LBBB)	
Bloqueo de rama derecho (RBBB)	
Latidos de escape auriculares (AE)	
Latido de escape de unión (NE)	
Contracción auricular prematura (AP)	Latido supraventricular (S)
Contracción auricular prematura aberrante (aAP)	
Contracción prematura de unión (NP)	
Contracción prematura supraventricular (SP)	
Contracción ventricular prematura (PVC)	Latido ectópico ventricular (V)
Latido de escape ventricular (VE)	
Latido normal o en conjunto con ventricular (fVN)	Latido no reconocido (Q)

Figura. 22 Clasificación de latidos de la base de datos MIT-BIH según la AAMI

### 3.4.5.2 Conjunto de datos de entrenamiento

Para la creación del conjunto de imágenes de entrenamiento, fue necesario recolectar muestras (recortes de pantalla) utilizando la aplicación web LightWAVE de PhysioNet. LightWAVE es un visor y editor ligero de formas de onda y anotaciones (Goldberger et al., 2000). Se utiliza para ver cualquiera de los trazos de señales fisiológicas y series temporales de PhysioBank, junto con sus anotaciones (marcadores de eventos). Se ejecuta dentro de cualquier navegador web moderno y no requiere instalación en el ordenador, tableta o teléfono del usuario. LightWAVE es un software libre con licencia GPL (General Public License).



Figura. 23 LightWAVE, aplicación web para visualizar trazos de ECG de la base de datos MIT-BIH Arrhythmia Database

En la primera pestaña de la aplicación (Choose input), se puede seleccionar el trazo que se desea inspeccionar de la base de datos MIT-BIH (Figura. 24). Al seleccionar uno de ellos, se desplegará en pantalla la vista del gráfico (View/edit) en donde se puede desplazar la ventana de visualización a lo largo del trazo de ECG utilizando los controles de dirección ubicados en la parte superior de la pantalla (Figura. 25 A) o ubicar un tipo de ciclo cardíaco mediante el botón Encontrar o Find (Figura. 25 B).

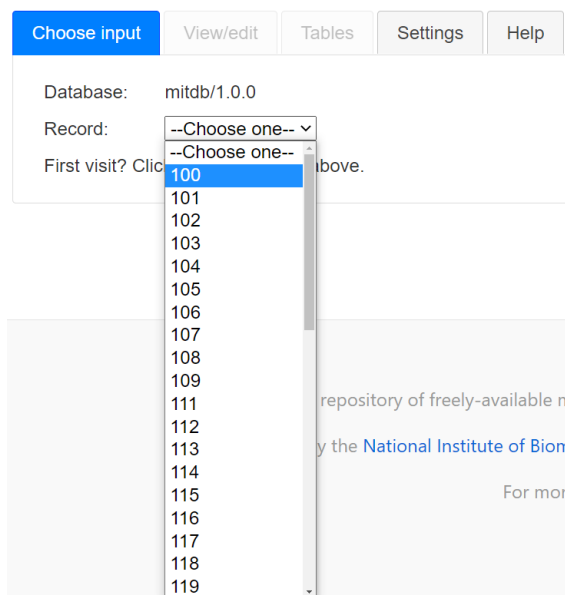


Figura. 24 Pantalla de selección de trazo/paciente

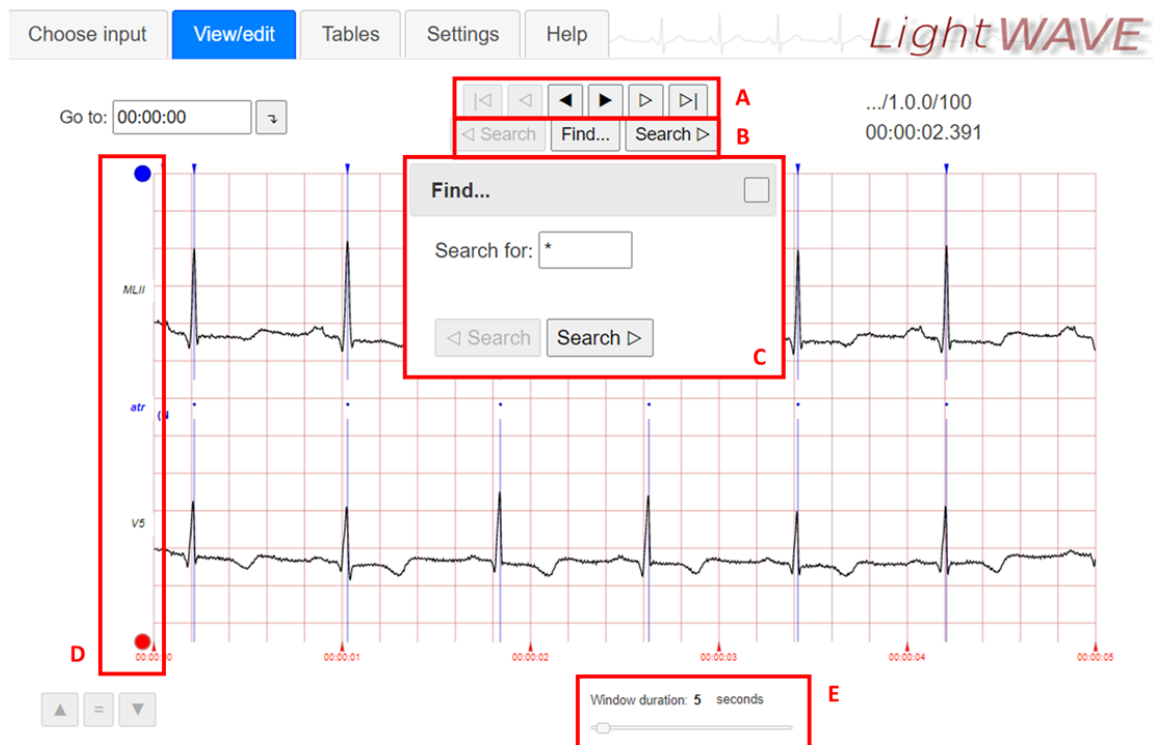


Figura. 25 Pantalla de visualización de grafo: A) Controles de desplazamiento, B) botones de búsqueda, C) recuadro de búsqueda de ciclo cardíaco por tipo, D) herramientas del gráfico y E) tamaño de ventana en segundos

Cada registro o trazo de la base de datos cuenta con anotaciones y descripción de la duración del trazo, frecuencia de muestreo, tipos de ciclo cardíaco/anotaciones de especialistas, derivaciones del electrocardiograma utilizadas en el paciente y notas clínicas (Figura. 26).

Para términos de este proyecto, se utilizaron las anotaciones “N” para identificar los ciclos cardíacos clasificados como normales, y las anotaciones “V” para ciclos cardíacos clasificados con extrasístole ventricular (PVC).

Para obtener el recorte de cada ciclo con un fondo blanco, se utilizaron las herramientas que se ubican del lado izquierdo del recuadro de visualización del gráfico, que se presentan como un círculo azul, un círculo rojo y las letras “atr” en color azul (Figura. 25 D). Desactivando todas las herramientas, excepto la que contenga la etiqueta de la derivación MLII, que es objeto de esta investigación, se obtiene una imagen más limpia del trazo ECG y permite generar los recortes

manualmente con mayor facilidad.

Choose input View/edit **Tables** Settings Help

Go to: 00:00:00

View annotations as text  View signals as text

.../1.0.0/100  
00:00:01.870

### Summary

Record length 00:30:05  
Clock frequency 360 ticks per second  
Annotator: atr (2274 annotations)  
N 2239  
A 33  
(N 1  
V 1

Signal: MLII 1 tick per sample; 200 adu/mV; 11-bit ADC, zero at 1024; baseline is 1024  
Signal: V5 1 tick per sample; 200 adu/mV; 11-bit ADC, zero at 1024; baseline is 1024

Notes:

69 M 1085 1629 x1  
Aldomet, Inderal

Figura. 26 Sección Tables de la aplicación LightWAVE con descripción del paciente/registro "100"



Figura. 27 Localización de un ciclo cardíaco con PVC en el registro 100 con herramientas de gráfico ocultas.

Cada recorte fue almacenado en formato .png, y clasificado en 3 distintas carpetas para la creación del conjunto de datos para entrenamiento del algoritmo de aprendizaje profundo. Fueron almacenados un total de 2053 imágenes en formato .png, que se conforman por 1000 recortes de ciclos cardíacos con anotaciones normales en la carpeta “NSR”, 1000 recortes de ciclos cardíacos con anotaciones de extrasístole ventricular en la carpeta “PVC”, y 53 ciclos con anotaciones de fibrilación ventricular y contracción auricular prematura en la carpeta “Otros” (véase Figura 28). Estas carpetas fueron almacenadas en la unidad de Google Drive de la cuenta institucional propia, a la que se tuvo acceso para el entrenamiento del algoritmo.




Figura. 28 Carpetas clasificadas por tipo de arritmia



Figura. 29 Muestra de imágenes numeradas de la carpeta PVC

### 3.4.5.3 Modelado

Google Colab permite acceder a la unidad de Google Drive para lectura y escritura de archivos, lo que facilitó el acceso al conjunto de datos.

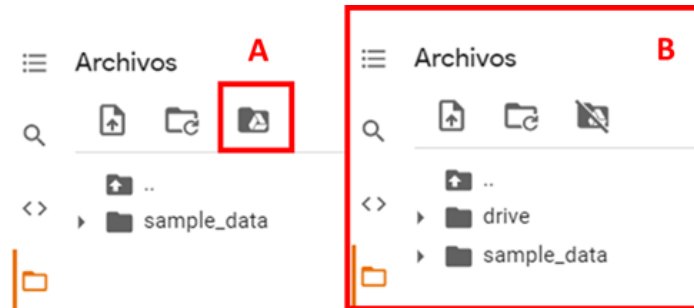


Figura. 30 A) Botón para activar Google Drive en CoLab, B) vista con Google Drive activado

Una vez activada esta función, se generó una función para mandar a llamar al conjunto de datos, imagen por imagen, para transformarlo de formato .png a un arreglo.

Para llevar a cabo la detección de la arritmia PVC, se utilizó una Red Neuronal Convolutiva (del inglés Convolutional Neural Networks, CNN) de 20 capas, de las cuales 4 capas son de convolución, seguidas cada una con una capa con la función de activación ReLu (del inglés Rectifier Lineal Unit), 4 de MaxPooling, 3 de Dropout, 1 capa Flatten, 2 capas Densas y finalmente, una de Softmax como función de activación de salida (Fig. 4.20).

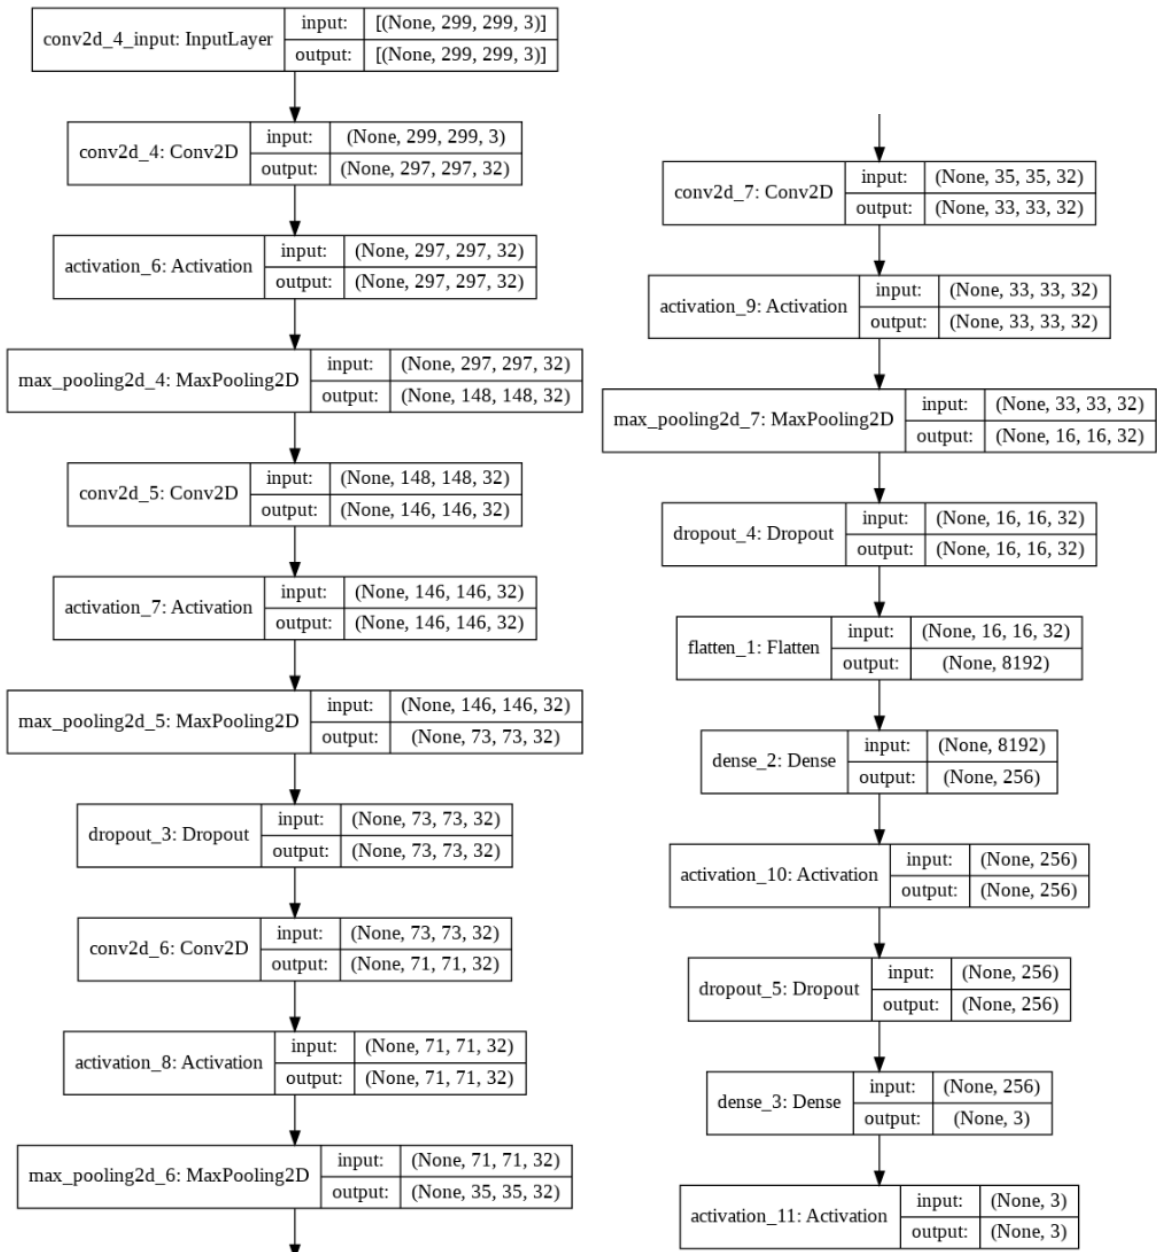


Figura. 31 Arquitectura de la CNN utilizada

Input dimensions: (299, 299, 3)  
 Model: "sequential\_1"

Layer (type)	Output Shape	Param #
conv2d_4 (Conv2D)	(None, 297, 297, 32)	896
activation_6 (Activation)	(None, 297, 297, 32)	0
max_pooling2d_4 (MaxPooling2D)	(None, 148, 148, 32)	0
conv2d_5 (Conv2D)	(None, 146, 146, 32)	9248
activation_7 (Activation)	(None, 146, 146, 32)	0
max_pooling2d_5 (MaxPooling2D)	(None, 73, 73, 32)	0
dropout_3 (Dropout)	(None, 73, 73, 32)	0
conv2d_6 (Conv2D)	(None, 71, 71, 32)	9248
activation_8 (Activation)	(None, 71, 71, 32)	0
max_pooling2d_6 (MaxPooling2D)	(None, 35, 35, 32)	0
conv2d_7 (Conv2D)	(None, 33, 33, 32)	9248
activation_9 (Activation)	(None, 33, 33, 32)	0
max_pooling2d_7 (MaxPooling2D)	(None, 16, 16, 32)	0
dropout_4 (Dropout)	(None, 16, 16, 32)	0
flatten_1 (Flatten)	(None, 8192)	0
dense_2 (Dense)	(None, 256)	2097408
activation_10 (Activation)	(None, 256)	0
dropout_5 (Dropout)	(None, 256)	0
dense_3 (Dense)	(None, 3)	771
activation_11 (Activation)	(None, 3)	0
=====		
Total params: 2,126,819		
Trainable params: 2,126,819		
Non-trainable params: 0		

Figura. 32 Parámetros del modelo entrenado

## Capítulo 4: Resultados

Utilizando los servidores de Google Colab, todas las pruebas fueron realizadas con una tarjeta gráfica para Backend de Google Compute Engine, 12.69 GB de memoria RAM disponibles para el procesamiento y un disco duro con disponibilidad de uso de 68.35 GB (véase Figura 33).




Figura. 33 Características del servidor proporcionado por Google Colab

### 4.1 Conjunto de datos de prueba

Fue utilizado el 70% de las 2,053 imágenes para el entrenamiento del modelo de predicción, el 15% para validación del algoritmo y el otro 15% para realizar pruebas de precisión. Los conjuntos de datos para entrenamiento, validación y pruebas se generaron de manera aleatoria.




Figura. 34 División del conjunto de datos para entrenamiento y validación del modelo de predicción

Se tomaron 5 trazos completos de electrocardiograma de aproximadamente 30 minutos de la base de datos MIT-BIH para la evaluación del modelo de predicción. Fueron seleccionados en base a las anotaciones que presenta la base de datos ya

que los trazos fueron adquiridos mediante la derivación MLII y presentan ciclos cardiacos normales, ciclos con contracción ventricular prematura (PVC), contracción auricular prematura (PAC) y fibrilación auricular, colocando a estas dos últimas en la categoría “Otros”.

Se tomó únicamente la derivación MLII del trazo de los registros R100, R105, R106, R119 y R121, y fueron almacenados en formato .csv para su procesamiento mediante la aplicación web PÉEK.

## 4.2 Evaluación del modelo

Se evaluó el modelo utilizando 25 épocas, arrojando una precisión total de 98.93% y una pérdida del 4.52%.

```

Epoch 1/25
11/11 [=====] - 6s 440ms/step - loss: 0.0218 - accuracy: 0.9954 - val_loss: 0.0962 - val_accuracy: 0.9894
Epoch 2/25
11/11 [=====] - 4s 397ms/step - loss: 0.0102 - accuracy: 0.9962 - val_loss: 0.1188 - val_accuracy: 0.9859
Epoch 3/25
11/11 [=====] - 4s 404ms/step - loss: 0.0154 - accuracy: 0.9954 - val_loss: 0.0621 - val_accuracy: 0.9894
Epoch 4/25
11/11 [=====] - 4s 406ms/step - loss: 0.0094 - accuracy: 0.9977 - val_loss: 0.0431 - val_accuracy: 0.9894
Epoch 5/25
11/11 [=====] - 4s 402ms/step - loss: 0.0036 - accuracy: 0.9985 - val_loss: 0.0681 - val_accuracy: 0.9859
Epoch 6/25
11/11 [=====] - 4s 399ms/step - loss: 0.0063 - accuracy: 0.9977 - val_loss: 0.1312 - val_accuracy: 0.9859
Epoch 7/25
11/11 [=====] - 4s 401ms/step - loss: 0.0086 - accuracy: 0.9977 - val_loss: 0.1062 - val_accuracy: 0.9894
Epoch 8/25
11/11 [=====] - 4s 399ms/step - loss: 0.0156 - accuracy: 0.9977 - val_loss: 0.0451 - val_accuracy: 0.9859
Epoch 9/25
11/11 [=====] - 4s 403ms/step - loss: 0.0065 - accuracy: 0.9985 - val_loss: 0.0317 - val_accuracy: 0.9894
Epoch 10/25
11/11 [=====] - 4s 402ms/step - loss: 0.0042 - accuracy: 0.9985 - val_loss: 0.0693 - val_accuracy: 0.9859
Epoch 11/25
11/11 [=====] - 4s 406ms/step - loss: 0.0045 - accuracy: 0.9985 - val_loss: 0.0969 - val_accuracy: 0.9823
Epoch 12/25
11/11 [=====] - 4s 400ms/step - loss: 7.0776e-04 - accuracy: 1.0000 - val_loss: 0.0987 - val_accuracy: 0.9823
Epoch 13/25
11/11 [=====] - 4s 401ms/step - loss: 0.0309 - accuracy: 0.9947 - val_loss: 0.0640 - val_accuracy: 0.9859
Epoch 14/25
11/11 [=====] - 4s 401ms/step - loss: 0.0105 - accuracy: 0.9962 - val_loss: 0.0740 - val_accuracy: 0.9823
Epoch 15/25
11/11 [=====] - 4s 409ms/step - loss: 0.0181 - accuracy: 0.9962 - val_loss: 0.0504 - val_accuracy: 0.9859
Epoch 16/25
11/11 [=====] - 4s 401ms/step - loss: 0.0077 - accuracy: 0.9947 - val_loss: 0.1101 - val_accuracy: 0.9859
Epoch 17/25
11/11 [=====] - 4s 402ms/step - loss: 0.0404 - accuracy: 0.9970 - val_loss: 0.0585 - val_accuracy: 0.9894
Epoch 18/25
11/11 [=====] - 4s 400ms/step - loss: 0.0070 - accuracy: 0.9970 - val_loss: 0.0138 - val_accuracy: 0.9929
Epoch 19/25
11/11 [=====] - 4s 405ms/step - loss: 0.0059 - accuracy: 0.9977 - val_loss: 0.0703 - val_accuracy: 0.9894
Epoch 20/25
11/11 [=====] - 4s 402ms/step - loss: 0.0228 - accuracy: 0.9977 - val_loss: 0.0400 - val_accuracy: 0.9929
Epoch 21/25
11/11 [=====] - 4s 404ms/step - loss: 0.0208 - accuracy: 0.9962 - val_loss: 0.0485 - val_accuracy: 0.9823
Epoch 22/25
11/11 [=====] - 4s 401ms/step - loss: 0.0104 - accuracy: 0.9985 - val_loss: 0.0391 - val_accuracy: 0.9894
Epoch 23/25
11/11 [=====] - 4s 404ms/step - loss: 0.0130 - accuracy: 0.9977 - val_loss: 0.0484 - val_accuracy: 0.9823
Epoch 24/25
11/11 [=====] - 4s 404ms/step - loss: 0.0040 - accuracy: 0.9992 - val_loss: 0.0933 - val_accuracy: 0.9788
Epoch 25/25
11/11 [=====] - 4s 402ms/step - loss: 0.0147 - accuracy: 0.9962 - val_loss: 0.0535 - val_accuracy: 0.9859

```

*Figura. 35 Evaluación del modelo propuesto utilizando 25 épocas*




Figura. 36 Gráficas de precisión y pérdida presentadas por el modelo propuesto

Test loss: 0.045281313359737396  
 Test accuracy: 0.9893993139266968

Figura. 37 Resultado de la evaluación final del algoritmo con el conjunto de datos de entrenamiento

Los resultados obtenidos tras la evaluación con los trazos de electrocardiograma de 30 minutos registrados mediante la derivación MLII se muestran en la Figura 38. Se aplicaron los cálculos estadísticos mostrados en la Figura 39 para la evaluación métrica del modelo y estos fueron calculados por clases.

R100	Encontrados	Anotaciones	%E
Normal	2264	2240	1.07
PVC	1	1	0.00
Otro	4	33	87.88

R119	Encontrados	Anotaciones	%E
Normal	1979	1592	24.31
PVC	2	444	99.55
Otro	0	58	100.00

R105	Encontrados	Anotaciones	%E
Normal	2341	2527	7.36
PVC	205	41	400.00
Otro	30	123	75.61

R121	Encontrados	Anotaciones	%E
Normal	1834	1862	1.50
PVC	54	1	5300.00
Otro	10	13	23.08

R106	Encontrados	Anotaciones	%E
Normal	1444	1528	5.50
PVC	242	520	53.46
Otro	17	18	5.56

Totales			
	Encontrados	Anotaciones	%Error
Normal	9862	9749	1.16
PVC	504	1007	49.95
Otro	61	245	75.10

Figura. 38 Conteo de ciclos cardiacos encontrados por el modelo propuesto y las anotaciones de la base de datos MIT-BIH

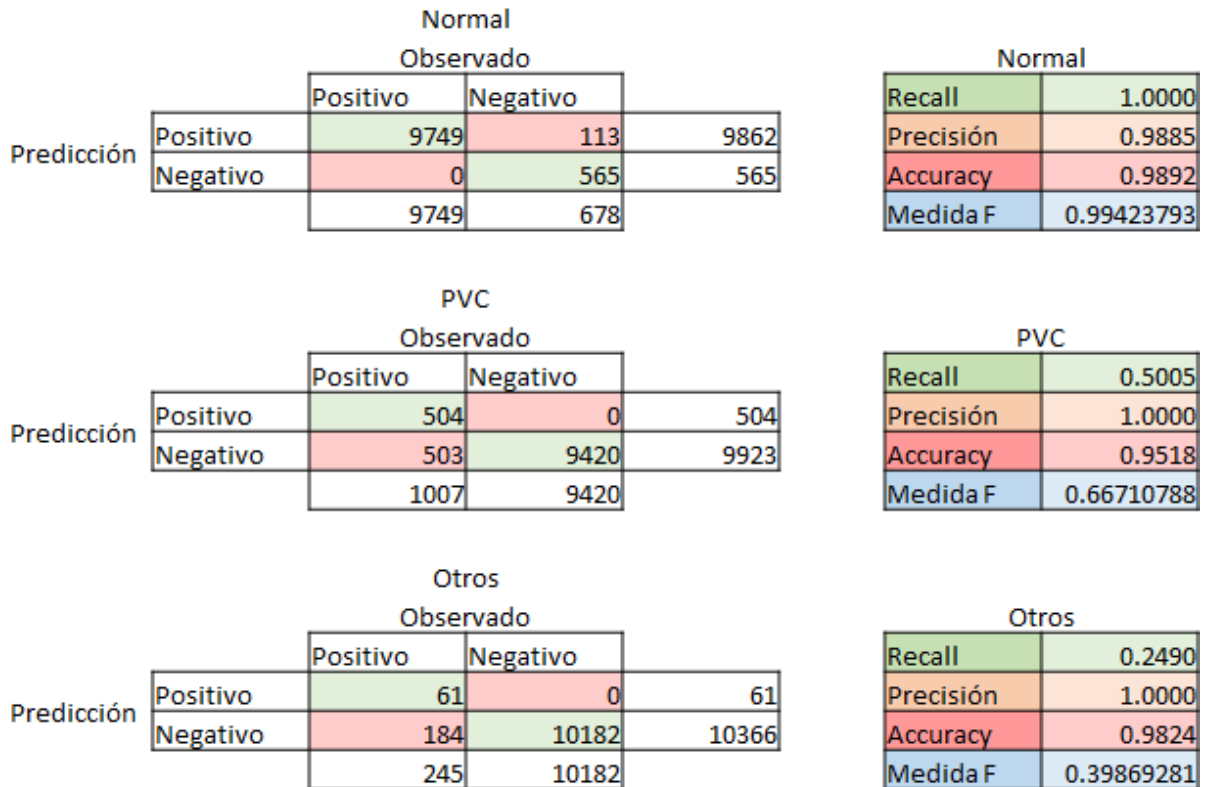
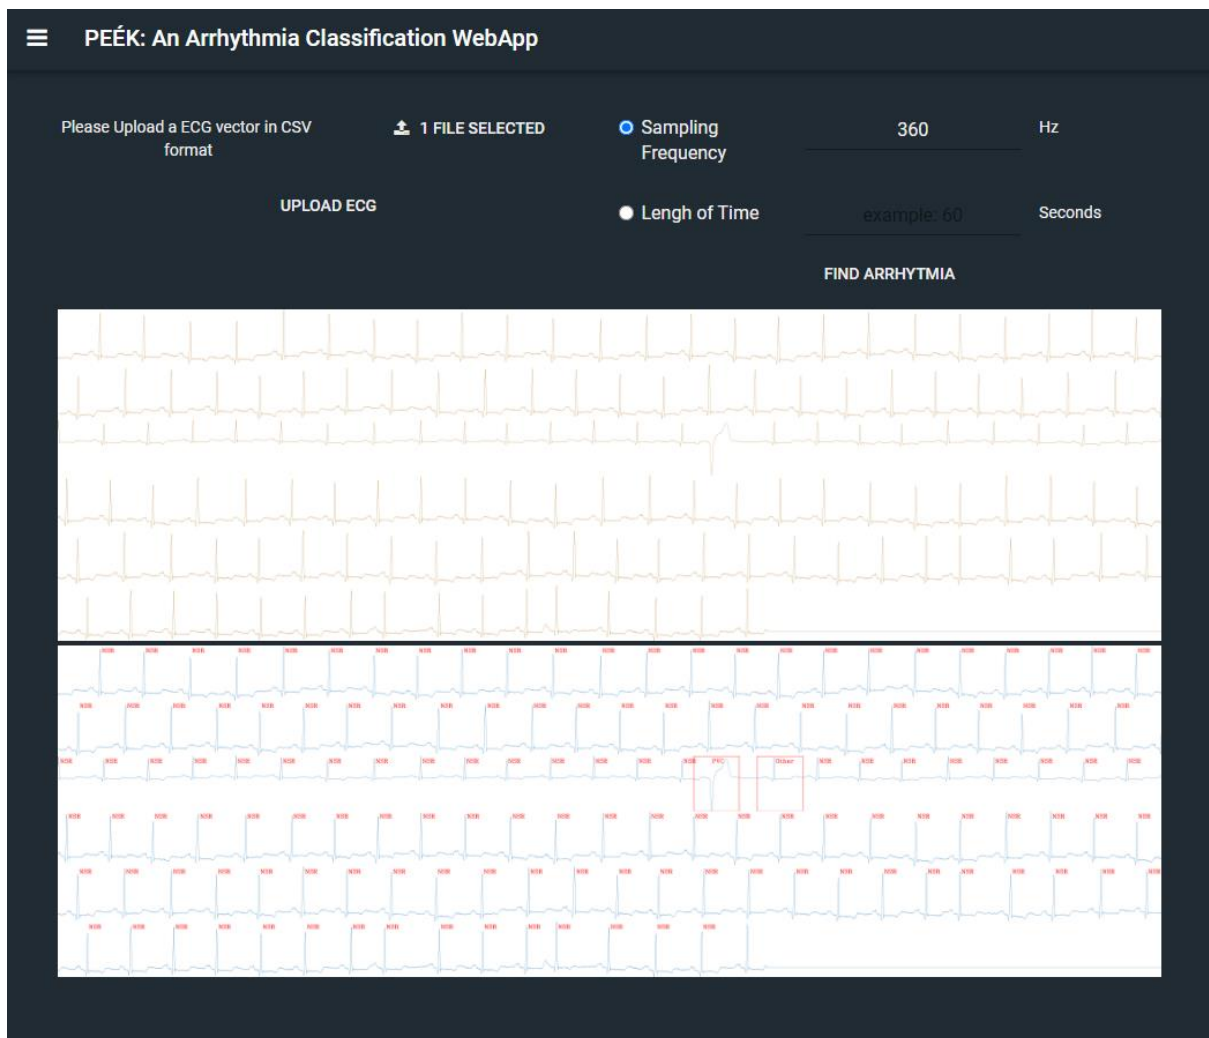


Figura. 39 Matriz de confusión y evaluación estadística del algoritmo propuesto

### 4.3 Interpretación del trazo electrocardiográfico.

Como resultado de la aplicación web, se presenta una muestra de trazo de electrocardiograma de 113 segundos con anotaciones en la imagen del trazo. En la parte superior se observa el trazo de electrocardiograma completo, sin anotaciones, y en la parte inferior se muestra el trazo con las marcas de ciclo cardiaco normal (NSR), contracción ventricular prematura (PVC) y otros (Other).



*Figura. 40 Resultado mostrado desde la aplicación web PEEK al finalizar el proceso de identificación de arritmias*

Cada trazo de 30 minutos fue almacenado en 3 partes en imágenes con formato .png de 8,640 píxeles de ancho y 13,104 píxeles de alto (véase anexo 1).

# Capítulo 5: Conclusiones y Trabajo Futuro

## 5.1 Conclusiones

Los resultados de la clasificación que se llevó a cabo en trazos completos de electrocardiogramas con una duración aproximada de 30 minutos cada uno, muestra superior al 98.8%. Sin embargo, ninguno de los trazos presentaba algún tipo de bloqueo de rama o bloqueo completo del corazón, por lo que los porcentajes podrían reducirse significativamente si no se lleva a cabo un entrenamiento previo para el reconocimiento de dichas condiciones.

Debido a la similitud que tienen ambas condiciones con algunas de las formas de onda que puede presentar la contracción ventricular prematura (PVC), el modelo actual resultará confundiendo las con esta última ya que no fue entrenado con muestras de bloqueos, por lo que no podría diferenciarlas de una PVC. Es necesario llevar a un cabo un entrenamiento más amplio del modelo, incluyendo la totalidad de arritmias que presenta la base de datos MIT-BIH para que este tenga la capacidad de diferenciar entre un bloqueo de rama o bloqueo completo y una PVC.

Los trazos del conjunto de datos de pruebas presentaban algunos ciclos de contracción auricular prematura (PAC) y, debido a la escasa cantidad de muestras de dicha arritmia que fueron utilizadas para el entrenamiento del modelo de predicción, este no logra diferenciarlas por completo de un ciclo cardíaco normal debido a su similitud en forma de onda. Para la identificación específica de esta arritmia, puede ser necesario analizar el ciclo cardíaco por segmentos, ya que su identificación se puede llevar a cabo observando solamente la onda P.

El conjunto de datos etiquetados como ciclo cardíaco normal que fueron utilizados para el entrenamiento del modelo, contiene muestras que presentan algún tipo de bloqueo de rama y fueron clasificados como “normales” según las anotaciones de la base de datos MIT-BIH; sin embargo, el registro tenía la nota sobre la presencia de bloqueo en todo el trazo de 30 minutos. Estas muestras podrían ser un factor a considerar para justificar el error obtenido con algunos ciclos cardíacos.

Todos los resultados se obtuvieron sin llevar a cabo el proceso de limpieza de la señal para eliminar el ruido blanco y otros artefactos, lo que compromete los porcentajes de precisión según Peimankar (Peimankar & Puthusserypady, 2021). Una posible solución para reducir el margen de error en la identificación de arritmias cardíacas sería llevar a cabo una etapa de preprocesamiento para realizar dicha limpieza, adicional al entrenamiento del algoritmo para el reconocimiento de arritmias y ciclos cardíacos normales que presentan artefactos, o entrenarlo para reconocer la existencia de los mismos con la finalidad de ignorarlos o crear anotaciones en el trazo electrocardiográfico.

El análisis de cada trazo de electrocardiograma de 30 minutos tuvo una duración promedio de 5 minutos. Lo que significa que el análisis de un trazo Holter de 24 horas podría tener una duración de al menos 4 horas de procesamiento. Esto implica que debe mejorarse la metodología de procesamiento del trazo, pues la metodología propuesta implica el generar una imagen por cada ciclo cardíaco para ser evaluado por el modelo de predicción, aumentando así el costo computacional.

Para poder realizar un análisis de trazo ECG de 24 horas. Se debe tomar en consideración que se ocuparan 4 horas para su procesamiento. Por lo que se recomienda alojar el procesamiento en una PC o servidor propio, ya que Google Colab cuenta con varias restricciones, una de ellas es el tiempo de procesamiento. Colab pausa el procesamiento y la sesión actual cuando este ya ha durado más de 30 minutos sin detenerse. Esta situación obliga al programador a reiniciar la sesión manualmente y, en ocasiones, instalar nuevamente las librerías en caso de que Google Colab le asigne un servidor nuevo.

## 5.2 Contribuciones

Con los resultados de la tesis se obtuvo el registro de software

- Nestor Alexander Zermeño Campos, Juan Pablo García Vázquez, Roberto López Avitia, Miguel Bravo Zanoguera, Daniel Cuevas Gonzalez, **PÉEK**

Artículos de revista:

- Nestor Alexander Zermeño Campos, Juan Pablo García Vázquez, Roberto López Avitia, Miguel Bravo Zanoquera, Daniel Cuevas Gonzalez,(2022). PÉEK: A Web-Based Application For Detecting Cardiac Arrhythmias, *SoftwareX*

En este artículo se presenta el diseño de la aplicación PÉEK la cual utiliza imágenes de trazos electrocardiográficos y redes neuronales convolucionales para detectar arritmias cardíacas.

### 5.3 Trabajo Futuro

- Explorar la evaluación de hiperparámetros de arquitectura y aprendizaje de la red convolucional para mejorar la precisión y costo computacional de la red convolucional utilizada en la aplicación PÉEK.
- Explorar la evaluación de diversas arquitecturas de redes convolucionales, por ejemplo, VGG16, VGG19, ResNet, Inception V3 para determinar qué arquitectura de red convolucional ofrece mejores resultados de precisión.
- Incorporar la detección de otras arritmias cardíacas, tales como los bloqueos de rama izquierda y derecha, bloqueo completo del corazón, y la depresión de la onda T.


## Referencias

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data* 2021 8:1, 8(1), 1–74.  
<https://doi.org/10.1186/S40537-021-00444-8>
- Andersen, R. S., Peimankar, A., & Puthusserypady, S. (2019). A deep learning approach for real-time detection of atrial fibrillation. *Expert Systems with Applications*, 115, 465–473. <https://doi.org/10.1016/j.eswa.2018.08.011>
- Barría Rumbaut, L. (2013). *DISEÑO Y ANÁLISI DE USABILIDAD, DEL SOFTWARE DEDICADO A APRENDIZAJES DE EDUCACIÓN AMBIENTAL , “ JUEGA Y APRENDE , FLAMENCO ROSADO ” Tesis para optar por el grado de Magíster en Educación mención Informática Educativa.*
- Dé, I. R., Elosua, R., & Marrugat, J. (2013). Epidemiología del síndrome coronario agudo en España: estimación del número de casos y la tendencia de 2005 a 2049. *Revista Española de Cardiología*, 66(6), 472–481.  
<https://doi.org/10.1016/j.recesp.2013.01.019>
- Elgendi, M., Jonkman, M., & Deboer, F. (2010). Frequency bands effects on QRS detection. *BIOSIGNALS 2010 - Proceedings of the 3rd International Conference on Bio-Inspired Systems and Signal Processing, Proceedings*, 428–431.  
<https://doi.org/10.5220/0002742704280431>
- Faust, O., Shenfield, A., Kareem, M., San, T. R., Fujita, H., & Acharya, U. R. (2018). Automated detection of atrial fibrillation using long short-term memory network with RR interval signals. *Computers in Biology and Medicine*, 102(May), 327–335. <https://doi.org/10.1016/j.compbiomed.2018.07.001>
- Francisco Jiménez-Navarrete, M., Arguedas-Chaverri, C., & Romero-Triana, L. (2013). Original Coronary syndrome and other diagnosis result in under reporting of acute myocardial infarction in the Mexico Hospital, Costa Rica. *Acta Médica Costarricense.*
- Galvão, M. C., Simas, E. M. P., Marques, C. V. M., & Motta, C. L. R. (2021). UX Design, Education, and Cognition: An Exploration of a Metacognitive Systematic Model of Digital Interface to Mediate Knowledge Construction. In C. Stephanidis, M. Antona, & S. Ntoa (Eds.), *HCI International 2021 - Posters* (pp. 12–17). Springer International Publishing.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet. *Circulation*, 101(23).  
<https://doi.org/10.1161/01.CIR.101.23.E215>
- Guo, L., Sim, G., & Matuszewski, B. (2019). Inter-patient ECG classification with convolutional and recurrent neural networks. *Biocybernetics and Biomedical Engineering*, 39(3), 868–879. <https://doi.org/10.1016/j.bbe.2019.06.001>
- Habibi Aghdam, H., & Jahani Heravi, E. (2017). Guide to Convolutional Neural Networks. *Guide to Convolutional Neural Networks*. <https://doi.org/10.1007/978-3-319-57550-6>
- INEGI. (2021). *Principales causas*. Principales Causas de Mortalidad Por Residencia Habitual, Grupos de Edad y Sexo Del Fallecido.  
<https://www.inegi.org.mx/sistemas/olap/registros/vitales/mortalidad/tabulados/ConsultaMortalidad.asp>

- Kalidas, V., & Tamil, L. (2017). Real-time QRS detector using stationary wavelet transform for automated ECG analysis. *Proceedings - 2017 IEEE 17th International Conference on Bioinformatics and Bioengineering, BIBE 2017, 2018-Janua*(512), 457–461. <https://doi.org/10.1109/BIBE.2017.00-12>
- Ketkar, N. (2017). *Deep learning with Python : a hands-on introduction. Springer Nature.*
- Liu, X., Wang, H., Li, Z., & Qin, L. (2021). Deep learning in ECG diagnosis: A review. *Knowledge-Based Systems, 227*, 107187. <https://doi.org/https://doi.org/10.1016/j.knosys.2021.107187>
- Lowgren, J. (1995). Applying design methodology to software development. *Proceedings of the Conference on Designing Interactive Systems: Processes, Practices, Methods, and Techniques, DIS, 23-25-Augu*, 87–95. <https://doi.org/10.1145/225434.225444>
- Luis, B., Marin, B., Martínez Rodríguez, I., Yanes, E. S., & Calero Pérez, Y. (2013). Caracterización clínico-epidemiológica del infarto agudo del miocardio trombolizado en la unidad de cuidados intensivos de adultos. Clinical-epidemiologist characterization of the trombolized acute myocardial infarction in the Adult Intensive Care unit. *MEDICIEGO, 19*.
- Luis, & Porr, B. (2019). *Popular ECG R peak detectors written in python.* <https://doi.org/10.5281/ZENODO.3588108>
- Mfcc, W. (2018). *Acoustics-based Vehicle Classification System Using MFCC and January*, 1–5.
- Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine, 20*(3), 45–50. <https://doi.org/10.1109/51.932724>
- Ortega, Z. (2017). *Menú hamburguesa en diseño web ¿Sí o no? Menú Hamburguesa En Diseño Web ¿Sí o No?* <https://www.irudigital.com/menu-hamburguesa/>
- Peimankar, A., & Puthusserypady, S. (2021). DENS-ECG: A deep learning approach for ECG signal delineation. *Expert Systems with Applications, 165*(August 2020), 113911. <https://doi.org/10.1016/j.eswa.2020.113911>
- Ping, Y., Chen, C., Wu, L., Wang, Y., & Shu, M. (2020). Automatic Detection of Atrial Fibrillation Based on CNN-LSTM and Shortcut Connection. *Healthcare 2020, Vol. 8, Page 139, 8*(2), 139. <https://doi.org/10.3390/HEALTHCARE8020139>
- Rath, A., Mishra, D., Panda, G., & Satapathy, S. C. (2021). Heart disease detection using deep learning methods from imbalanced ECG samples. *Biomedical Signal Processing and Control, 68*(April), 102820. <https://doi.org/10.1016/j.bspc.2021.102820>
- Rodriguez, C. A., Orozco-Duque, A., & Bustamante, J. (2014). Clasificación De Latidos De Contracción Ventricular Prematura Basados En Métodos De Aprendizaje No Supervisado. *Revista Ingeniería Biomédica, 8*(15), 51–58. <https://doi.org/10.24050/19099762.n15.2014.608>
- Saadatnejad, S., Oveisi, M., & Hashemi, M. (2020). LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices. *IEEE Journal of Biomedical and Health Informatics, 24*(2), 515–523. <https://doi.org/10.1109/JBHI.2019.2911367>
- Sánchez Díaz, M., Ramírez Céspedes, Z., Soriano Suárez, Y., Sánchez Díaz, M., Ramírez Céspedes, Z., & Soriano Suárez, Y. (2019). Rediseño del Sitio Web del Centro Nacional de Biopreparados de acuerdo con las tendencias actuales en homólogos. *Revista Cubana de Información En Ciencias de La Salud, 30*(3).

- [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S2307-21132019000300004&lng=es&nrm=iso&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2307-21132019000300004&lng=es&nrm=iso&tlng=es)
- Sherwood, L. (2011). *FISIOLOGIA HUMANA: DE LAS CELULAS A LOS SISTEMAS de LAURALEE SHERWOOD en Gandhi* (7th ed.). Cengage Learning.
- Silverthorn, D. U. 1948-. (2019). *Fisiología humana : un enfoque integrado / Dee Unglaub Silverthorn con colaboración de Bruce R. Johnson y William C. Ober (coordinador de ilustración), Claire E. Ober (ilustradora), Anita Impaglizzo (ilustradora), Andrew C. Silverthorn (asesor clínico)*.  
[http://cercabib.ub.edu/iii/encore/record/C\\_\\_Rb2304103\\_\\_SPanamericana GIGA en I%EDnia\\_\\_P0,9\\_\\_Orightresult\\_\\_U\\_\\_X1;jsessionid=D89853A057D925E1D568310A4A54A8AB?lang=cat](http://cercabib.ub.edu/iii/encore/record/C__Rb2304103__SPanamericana GIGA en I%EDnia__P0,9__Orightresult__U__X1;jsessionid=D89853A057D925E1D568310A4A54A8AB?lang=cat)
- Sun, Y., Chan, K. L., & Krishnan, S. M. (2005). Characteristic wave detection in ECG signal using morphological transform. *BMC Cardiovascular Disorders*, 5, 1–7. <https://doi.org/10.1186/1471-2261-5-28>
- Tortora, G. J., & Derrickson, B. (2018). *Principios de Anatomía y Fisiología* (M. Panamericana (ed.); 11th ed.).
- Wang, G., Zhang, C., Liu, Y., Yang, H., Fu, D., Wang, H., & Zhang, P. (2019). A global and updatable ECG beat classification system based on recurrent neural networks and active learning. *Information Sciences*, 501, 523–542. <https://doi.org/10.1016/j.ins.2018.06.062>
- World Health Organization. (2021). *No Title*. Cardiovascular Diseases (CVDs). [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- Yildirim, Ö. (2018). A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification. *Computers in Biology and Medicine*, 96, 189–202. <https://doi.org/10.1016/J.COMPBIOMED.2018.03.016>
- Zaccone, G., & Karim, M. R. (2018). *Deep Learning with TensorFlow : Explore neural networks and build intelligent systems with Python, 2nd Edition*. 483.
- Zhao, H., Gallo, O., Frosio, I., & Kautz, J. (2016). Loss Functions for Image Restoration With Neural Networks. *IEEE Transactions on Computational Imaging*, 3(1), 47–57. <https://doi.org/10.1109/TCI.2016.2644865>

# Anexos



ANEXO 1