



PROGRAMA DE MAESTRÍA EN INGENIERÍA BIOMÉDICA

Título/ Tema:

“IDENTIFICACIÓN Y CLASIFICACIÓN DE ELECTROCARDIOGRAMAS (EKG) UTILIZANDO ALGORITMOS DE INTELIGENCIA ARTIFICIAL BASADOS EN APRENDIZAJE PROFUNDO.”

TRABAJO DE TITULACIÓN

Previo a la obtención del Título de:

MAGÍSTER EN INGENIERÍA BIOMÉDICA

Presentado por:

Daniel Alejandro Mejía de la Cadena

GUAYAQUIL - ECUADOR

Año: 2024

DEDICATORIA

Dedico este trabajo a mi familia, por su apoyo incondicional; a mis profesores, por ser guías esenciales en este camino; a mis amigos, por su constante aliento; a mis colaboradores, por su valiosa contribución; y a todos aquellos que creyeron en mí desde el primer día.

Daniel Alejandro Mejía de la Cadena

AGRADECIMIENTOS

Quiero expresar mi más sincero agradecimiento a mi familia, por su apoyo incondicional a lo largo de cada etapa del proceso académico. A mis amigos, algunos de los cuales considero como hermanos, por estar presentes y ofrecer su respaldo en los momentos más cruciales. A los profesores, ahora colegas, que compartieron generosamente sus conocimientos y sabiduría. A mi tutor y evaluador del proyecto, por creer en la idea y permitirme desarrollar una solución crucial para sectores de gran avance tecnológico. Estoy profundamente agradecido con todos.

Daniel Alejandro Mejía de la Cadena

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; DANIEL ALEJANDRO MEJIA DE LA CADENA da consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”

Ing. Daniel Alejandro

Mejía de la Cadena

TRIBUNAL DE EVALUACIÓN

MSc. Miguel Yapur Auad
DIRECTOR DEL TRABAJO DE TITULACIÓN

PhD. Edwin Valarezo Añezco
MIEMBRO PRINCIPAL DEL TRIBUNAL EVALUADOR

RESUMEN

La propuesta del proyecto busca desarrollar un sistema de clasificación de arritmias utilizando algoritmos de inteligencia artificial y herramientas de aprendizaje profundo. Este sistema aprovechará una base de datos del Instituto Tecnológico de Massachusetts (MIT), que contiene grabaciones detalladas de electrocardiogramas (ECG). El objetivo es crear un sistema que identifique con alta precisión diferentes señales cardíacas y las clasifique en arritmias cardíacas (ARR), insuficiencia cardíaca congestiva (CHF) y ritmos sinusales normales (NSR).

Esta herramienta de clasificación permitirá una detección temprana y confiable de enfermedades cardiovasculares, facilitando la identificación y tratamiento de condiciones cardíacas en pacientes. Además, el sistema permitirá a los médicos cardiólogos especializados ofrecer atención a personas en zonas rurales o de difícil acceso, donde los recursos médicos son limitados. Al mejorar la detección y diagnóstico de arritmias y otras anomalías cardíacas, se espera reducir la mortalidad asociada a ECV y mejorar la calidad de vida de los pacientes.

Palabras clave: Enfermedades Cardiovasculares (ECV), arritmias cardíacas, inteligencia artificial, aprendizaje profundo, arritmias cardíacas (ARR), insuficiencia cardíaca congestiva (CHF), ritmos sinusales normales (NSR).

ABSTRACT

The project proposal aims to develop a system for classifying arrhythmias using artificial intelligence algorithms and deep learning tools. This system will leverage a database from the Massachusetts Institute of Technology (MIT), which contains detailed recordings of electrocardiograms (ECG). The goal is to create a system that accurately identifies and classifies different cardiac signals into categories such as arrhythmias (ARR), congestive heart failure (CHF), and normal sinus rhythms (NSR).

This classification tool will enable early and reliable detection of cardiovascular diseases, facilitating the identification and treatment of cardiac conditions in patients. Additionally, the system will allow specialized cardiologists to provide care to individuals in rural or hard-to-reach areas where medical resources are limited. By improving the detection and diagnosis of arrhythmias and other cardiac anomalies, the project aims to reduce mortality associated with cardiovascular diseases (CVD) and enhance the quality of life for patients.

Keywords: Cardiovascular Diseases (CVD), arrhythmias, artificial intelligence, deep learning, arrhythmias (ARR), congestive heart failure (CHF), normal sinus rhythms (NSR).

ÍNDICE GENERAL

<i>DEDICATORIA</i>	2
<i>AGRADECIMIENTOS</i>	3
<i>DECLARACIÓN EXPRESA</i>	4
<i>TRIBUNAL DE EVALUACIÓN</i>	5
<i>RESUMEN</i>	6
<i>ABSTRACT</i>	7
<i>ÍNDICE GENERAL</i>	8
<i>ABREVIATURAS</i>	10
<i>ÍNDICE DE FIGURAS</i>	11
<i>ÍNDICE DE TABLAS</i>	12
<i>CAPÍTULO I: INTRODUCCIÓN</i>	13
<i>1.1 Identificación del problema</i>	13
<i>1.2 Justificación del problema</i>	16
<i>1.3 Objetivos:</i>	16
<i>1.3.1 Objetivo General:</i>	16
<i>1.3.2 Objetivos Específicos:</i>	16
<i>1.4 Metodología</i>	17
<i>1.4.1 Fase Teórica:</i>	17
<i>1.4.2 Fase de Diseño:</i>	17
<i>1.4.3 Fase de Implementación:</i>	17
<i>1.4.4 Fase de Validación:</i>	17
<i>1.5 Alcance</i>	18
<i>CAPÍTULO 2: MARCO TEÓRICO</i>	19
<i>2.1 El corazón</i>	19
<i>2.1.1 Anatomía</i>	19
<i>2.1.2 Fisiología</i>	20
<i>2.2 Enfermedades cardiovasculares</i>	21
<i>2.3 Arritmias</i>	21
<i>2.3.1 Taquiarritmias</i>	22

2.3.2 Bradiparritmias. 23

2.4 Sistema de Adquisición de biopotenciales eléctricos. 24

2.5 Inteligencia Artificial..... 25

CAPÍTULO 3: DISEÑO E IMPLEMENTACIÓN27

3.1 Pre-procesamiento de la señal. 28

3.2 Entrenamiento y clasificación de la señal..... 30

3.3 GoogleNet..... 32

3.4 AlexNet 42

3.5 Herramientas de Visualización..... 47

CAPÍTULO 4: RESULTADOS49

4.1 Matriz de Confusión..... 49

4.2 ROC 52

4.3 Precisión 53

4.4 Pérdida..... 54

4.5 Tabla de resultados 55

4.6 Análisis de Resultados..... 56

CONCLUSIONES58

RECOMENDACIONES60

Bibliografía61

ABREVIATURAS

ECV	Enfermedades Cardiovasculares
OMS	Organización Mundial de la Salud
ARR	Arritmias Cardíacas
CHF	Insuficiencia Cardíaca Congestiva
NSR	Ritmos Sinusales Normales
MIT	Tecnológico de Massachussets
ECG	Electrocardiogramas
AAMI	Asociación Avanzada de Instrumentación Médica
AP	Auricular Prematura
NP	Unido Nodal
P	Latido Acelerado
SP	Supra-Ventricular
SA	Sino-Auricular
AV	Aurículo-Ventricular
BPM	Latidos Por Minuto
IA	Inteligencia Artificial
CNN	Redes Neuronales Convolucionales
CWT	Transformada Onda Continua

ÍNDICE DE FIGURAS

Figura 2.1. Las 4 válvulas internas del corazón.....	20
Figura 2.2. Los nodos del corazón.....	21
Figura 3.1 Proceso de clasificación de la señal ECG.....	27
Figura 3.2. Aplicación de la CWT.....	29
Figura 3.3. Segmentación de imágenes.....	30
Figura 3.4. Nuevas capas en la CNN de Google Net.....	34
Figura 3.5. Parámetros de entrenamiento.....	37
Figura 3.6. Entrenamiento de la red.....	39
Figura 3.7. Clase “ARR”	40
Figura 3.8. Identificación de la canal más fuerte.....	42
Figura 3.9. Identificación de la capa 23 y capa 25.....	45
Figura 3.10. Preparación de datos RGB.....	47
Figura 3.11. Proceso de entrenamiento.....	47
Figura 3.12. Implementación de GUIDEMO.....	49
Figura 4.1. Matriz de confusión, extraída del modelo de clasificación en Matlab....	51
Figura 4.2. Matriz de confusión en porcentajes, extraída del modelo de clasificación en Matlab.....	52
Figura 4.3. Matriz ROC, extraída del modelo de clasificación en Matlab.....	54
Figura 4.4. Precisión, extraída del modelo de clasificación en Matlab.....	55
Figura 4.5. Pérdida, extraída del modelo de clasificación en Matlab.....	56

ÍNDICE DE TABLAS

Tabla 1. Resultados de las métricas del modelo de clasificación en Matlab.....57

CAPÍTULO I: INTRODUCCIÓN

1.1. Identificación del problema

Las Enfermedades Cardiovasculares (ECV) a nivel mundial representan aproximadamente el 31% de todas las muertes registradas en el mundo. Aproximadamente tres cuartas partes de las defunciones por ECV, se presentan en países del tercer mundo, con ingresos medios y bajos. La Organización Mundial de la Salud (OMS) informa que “Las ECV son la principal causa de muerte en todo el mundo.” [1].

El musculo cardiaco posee 4 cavidad, dos aurículas (derecha e izquierda) y dos ventrículos (derecho e izquierdo). El proceso que realiza se divide en dos etapas. Diástole, donde las cavidades de las aurículas se relajan para llenar con sangre y sístole, donde las cavidades de los ventrículos se contraen para expulsar al torrente sanguíneo [2]. Las arritmias cardíacas son ritmos irregulares o alteraciones de la frecuencia de los latidos del corazón [3]. Estas ocurren cuando los impulsos eléctricos que determinan los latidos cardiacos producen una palpitación rápida, lenta o de forma irregular. Los tratamientos logran controlar o disminuir estos latidos irregulares, lentos o rápidos con el fin, de disminuir el riesgo de que el paciente desarrolle un ECV.

Las arritmias se clasifican por su frecuencia cardiaca en dos grupos. En los casos de presentarse una frecuencia cardiaca en reposo superior a 100 latidos por minuto se le denomina una Taquiarritmias. Al presentarse una frecuencia cardiaca en reposo inferior a

60 latidos por minuto se le denomina una Bradiarritmias. Las Taquiarritmias se dividen en dos grandes grupos, las Supraventriculares y las Ventriculares.

Las Taquiarritmias Supraventriculares se producen en las aurículas o en el nodo auriculoventricular. Se clasifican en: la Arritmia Sinusal Respiratoria se produce por la variación en la respiración y no precisa un tratamiento. La Arritmia Taquicardia Sinusal es un ritmo normal con frecuencia cardiaca mayor, se produce por ansiedad, ejercicio o consumo de estupefacientes como alcohol o nicotina. No precisa un tratamiento. La Arritmia Extrasístoles Auriculares se genera por un adelanto en el impulso eléctrico sinusal, pueden producir una isquemia miocárdica, insuficiencia cardiaca o una enfermedad pulmonar. La Arritmia Taquicardias Supraventriculares puede generar una fibrilación o un aleteo auriculares. Se asocian con cardiopatías crónicas que generan coágulos en los vasos sanguíneos provocando un bloqueo y una falta de riego en esa zona.

Las Taquiarritmias Ventriculares se presenta con mayor frecuencia en pacientes con cardiopatías. Se clasifican en: la Arritmia Extrasístoles Ventriculares que se genera en un punto aislado del ventrículo, ocasionando una pausa en el latido normal y continua con un latido más fuerte. La Arritmia Taquicardia Ventricular No Sostenida se genera por impulsos ventriculares consecutivos y luego cede de forma espontánea [4]. La Arritmia Taquicardia Ventricular Sostenida se genera por impulsos ventriculares consecutivos por más de 30 segundos. El paciente siente molestias, mareo, dolor torácico y hasta pérdida de consciencia. La Arritmia Fibrilación Ventricular se genera por una variación extensa de los impulsos ventriculares eléctricos. Es una de las más agresivas, presenta una ausencia de

ESPOL - FIEC MAESTRÍA EN INGENIERÍA BIOMÉDICA
--

pulso y pérdida inmediata de la consciencia. En pocos minutos puede ser mortal. Al presentarse una frecuencia cardiaca en reposo inferior a 60 latidos por minuto se le denomina una Bradiarritmias. En el desarrollo de este trabajo se realiza una clasificación de personas con arritmias cardíacas (ARR), personas con insuficiencia cardiaca congestiva (CHF) y personas ritmos sinusales normales (NSR).

En el desarrollo del algoritmo se utiliza la base de datos de arritmias del Instituto Tecnológico de Massachussets (MIT) con colaboración de los laboratorios del Hospital Beth Israel. Distribuida en 1980, contiene 48 segmentos de media hora de grabaciones de electrocardiogramas (ECG) correspondientes a 47 sujetos. De los 48 segmentos, el 60% fueron de pacientes del Hospital Beth Israel y el otro 40% fueron de pacientes externos. Las grabaciones fueron digitalizadas 360 muestras por segundos por canal con una resolución de 11-bit y un rango superior a 10 [mV]. La base de datos fue revisada por cardiólogos independientes y agregaron en ella sus observaciones [3]. La Asociación Avanzada de Instrumentación Médica (AAMI) recomienda realizar la clasificación de los latidos en 5 clases de interés: Clase N, Clase V, Clase S, Clase F y Clase Q [4]. Dentro de la Clase N tenemos: Latido normal, bloqueo de rama izquierda, bloqueo de rama derecha, escape auricular y latido de escape de la union nodal. La Clase V contiene Contracciones ventricular prematuras y latidos de escape ventricular. La Clase S consiste de latidos auricular prematura (AP), latido aberrado prematuro (aAP), latido prematuro unido nodal (NP) y el latido prematuro supra-ventricular (SP). La Clase F esta formada por un latido normal con uno ventricular (fVN). Finalmente, la Clase Q esta conformada por latidos desconocidos, latidos acelerados (P) y latidos sin clasificar. La inteligencia artificial nos

permite utilizar algoritmos de aprendizaje profundo con redes neuronales para la clasificación de arritmias [5].

1.2. Justificación del problema.

La tecnología en los últimos años ha logrado contribuir de forma significativa en la detección oportuna de enfermedades con alto índice de mortalidad. Las arritmias son alteraciones de la frecuencia cardíaca. Las cuales, son herramientas de detección temprana de ECV como cerebrovasculares y cardiopatías coronarias. Al realizar una clasificación de arritmias utilizando una base de datos y redes neuronal artificiales, es posible detectar una cardiopatía con alto índice de confiabilidad. Los médicos cardiólogos especializados pueden atender a personas en zonas rurales de difícil acceso utilizando un sistema de clasificación de arritmias. Dado que, es posible atender a las personas que presentan anomalías.

1.3. Objetivos:

1.3.1. Objetivo General:

Desarrollar un sistema de clasificación de arritmias utilizando algoritmos de inteligencia artificial con herramientas de aprendizaje profundo.

1.3.2. Objetivos Específicos:

- Determinar la fisiología del corazón humano y su funcionamiento.

- Realizar el procesamiento de señales cardiacas de la base de datos proporcionada por el Instituto Tecnológico de Massachussets (MIT).
- Clasificar a personas con arritmias cardiacas (ARR), personas con insuficiencia cardiaca congestiva (CHF) y personas ritmos sinusales normales (NSR).

1.4. Metodología

La metodología general de la investigación comprende cuatro fases.

1.4.1. Fase Teórica:

Se abarca la información relacionada a la anatomía y fisiología de músculo cardiaco. Se explica el proceso que realiza el sistema cardiovascular en el cuerpo humano. Se identifica las enfermedades cardiovasculares (ECV) y los tipos de arritmias.

1.4.2. Fase de Diseño:

Se diseña un sistema de clasificación e identificación de arritmias utilizando redes neuronales con algoritmos de aprendizaje profundo con herramientas de código abierto.

1.4.3. Fase de Implementación:

Se utiliza una base de datos de electrocardiogramas para retroalimentar el sistema de clasificación de arritmias.

1.4.4. Fase de Validación:

Se valida los resultados obtenidos con una matriz de confusión.

1.5. Alcance

En este trabajo de investigación se realiza un sistema implementable como herramienta de diagnóstico temprano para sectores rurales. Donde actualmente no hay la capacidad que un médico especialista en cardiología pueda atender a los pacientes de la comuna. Con este sistema, el medico podrá enfocarse en los pacientes más críticos, que presente cardiopatía que requieran una atención primordial. Esto permite garantizar la salud y mejorar el estilo de vida de los ciudadanos que no pueden movilizarse y acceder a un servicio de salud privada y requieren ser atendidos de manera urgente para detectar una anomalía.

CAPÍTULO 2: MARCO TEÓRICO

2.1 El corazón.

El músculo cardíaco se ubica en la caja torácica en la mitad del pecho, ligeramente a la izquierda. Su función principal es bombear sangre por todo el sistema circulatorio del cuerpo. Bombea sangre oxigenada enriquecida con nutrientes a todas las partes del cuerpo y transporta fuera del cuerpo elementos no deseados como el dióxido de carbono [1].

2.1.1 Anatomía.

Está conformado por tres capas de tejidos. El endocardio, miocardio y pericardio. El endocardio es la capa más delgada, interna de las cámaras del corazón. En el centro se encuentra el miocardio, que permite al corazón que se contraiga y se relaje para bombear sangre al cuerpo. Finalmente, el pericardio es la capa externa que envuelve al corazón y lo mantiene en su posición [1]. Internamente el corazón posee 4 cavidades, dos aurículas (derecha e izquierda) y dos ventrículos (derecho e izquierdo).

El corazón posee 4 válvulas, funcionan como compuertas para permitir el movimiento de la sangre en la dirección correcta. La válvula aórtica y la válvula mitral se encuentran en el lado izquierdo. Mientras que la válvula pulmonar y la válvula tricúspide se encuentran en el lado derecho (figura 2.1).




Figura 2.1. Las 4 válvulas internas del corazón.

2.1.2 Fisiología.

El proceso que realiza el corazón se divide en dos etapas: Diástole, donde las cavidades de las aurículas se relajan para llenar con sangre y Sístole, donde las cavidades de los ventrículos se contraen para expulsar sangre al cuerpo [2]. Para que el corazón pueda seguir bombeando sangre de forma regular, son necesarias las señales eléctricas que permiten al corazón que se contraiga y se relaje. Estas señales inician en el atrio derecho donde se encuentra el marcapaso natural del corazón, llamado “nodo sino-auricular (SA)”. Esta señal eléctrica permite a las aurículas transportar la sangre a los ventrículos. Luego, el “nodo aurículo-ventricular (AV)” emite una señal para que los ventrículos permitan

circula la sangre al sistema cardiovascular. En la figura 2.2 se puede observar la ubicación de los nodos SA y AV.




Figura 2.2. Las nodos del corazón.

2.2 Enfermedades cardiovasculares.

Las enfermedades cardiovasculares (ECV) a nivel mundial representan aproximadamente el 31% de todas las muertes registradas en el mundo. Aproximadamente tres cuartas partes de las defunciones por ECV, se presentan en países del tercer mundo, con ingresos medios y bajos. La Organización Mundial de la Salud (OMS) en el año 2017 publicó que las ECV son una de las principales causas de muerte a nivel mundial [2].

2.3 Arritmias.

Las arritmias cardíacas son ritmos irregulares o alteraciones de la frecuencia de los latidos del corazón [3]. Éstas ocurren cuando los impulsos eléctricos que determinan los latidos cardiacos producen una palpitación rápida, lenta o de forma irregular. Los

tratamientos logran controlar o disminuir estos latidos irregulares, lentos o rápidos con el fin de disminuir el riesgo de que el paciente desarrolle una ECV.

Las arritmias se clasifican por su frecuencia cardíaca en dos grupos. En los casos de presentarse una frecuencia cardíaca en reposo superior a 100 latidos por minuto se le denomina una Taquiarritmias. Al presentarse una frecuencia cardíaca en reposo inferior a 60 latidos por minuto se le denomina una Bradiarritmias. Las Taquiarritmias se dividen en dos grandes grupos, las Supra-ventriculares y las Ventriculares.

2.3.1 Taquiarritmias.

Las Taquiarritmias Supra-ventriculares se producen en las aurículas o en el nodo aurículo-ventricular. Se clasifican en:

- Arritmia Sinusal Respiratoria: que se produce por la variación en la respiración y no precisa un tratamiento.
- Arritmia Taquicárdica Sinusal: es un ritmo normal con frecuencia cardíaca mayor, se produce por ansiedad, ejercicio o consumo de estupefacientes como alcohol o nicotina. No precisa un tratamiento.
- Arritmia Extrasístoles Auriculares: se genera por un adelanto en el impulso eléctrico sinusal; puede producir una isquemia miocárdica, insuficiencia cardíaca o una enfermedad pulmonar.
- Arritmia Taquicárdica Supra-ventricular: puede generar una fibrilación o un aleteo auricular. Se asocia con cardiopatías crónicas que generan

coágulos en los vasos sanguíneos provocando un bloqueo y una falta de riego en esa zona.

Las Taquiarritmias Ventriculares se presentan con mayor frecuencia en pacientes con cardiopatías. Se clasifican en:

- Arritmia Extrasístoles Ventriculares: que se genera en un punto aislado del ventrículo, ocasionando una pausa en el latido normal y continuo con una contracción más fuerte.
- Arritmia Taquicárdica Ventricular No Sostenida: se genera por impulsos ventriculares consecutivos y luego cede de forma espontánea [4].
- Arritmia Taquicárdica Ventricular Sostenida: se genera por impulsos ventriculares consecutivos por más de 30 segundos. El paciente siente molestias, mareo, dolor torácico y hasta pérdida de conciencia.
- Arritmia Fibrilación Ventricular: se genera por una variación extensa de los impulsos ventriculares eléctricos. Es una de las más agresivas, presenta una ausencia de pulso y pérdida inmediata de la conciencia. En pocos minutos puede ser mortal.

2.3.2 Bradiarritmias.

Las Bradiarritmias se caracterizan por generar una frecuencia cardíaca menor de lo habitual. Se producen por una falla de la señal eléctrica. Hay tres tipos de Bradiarritmias:

- Bradicardia Sinusal: se genera un impulso cardíaco y conduce normalmente, pero con una frecuencia inferior a 60 latidos por minuto (bpm). Es muy frecuente en personas sin cardiopatías, como por ejemplo deportistas que entrenan habitualmente. En general, no precisa tratamiento.
- Bloqueo Sino-auricular: se produce por problemas en la génesis del impulso eléctrico en el nodo sino-auricular (SA) para su transmisión del nodo a las aurículas. Generalmente aparece en personas mayores. Si ocasiona síntomas, puede ser necesario tratarla con marcapasos.
- Bloqueo Aurículo-ventricular: se produce cuando el estímulo eléctrico no se conduce adecuadamente desde las aurículas a los ventrículos. Se clasifican en primer grado cuando ocurre el retraso en la conducción del impulso, pero sin que se bloquee ninguno. En segundo grado cuando algunos impulsos se conducen y otros se bloquean. En tercer grado cuando todos se bloquean. Los de tercer grado y algunos casos de segundo, generalmente, precisan de la colocación de un marcapasos. Los de primer grado no suelen requerir tratamiento.

2.4 Sistema de Adquisición de biopotenciales eléctricos.

El corazón genera biopotenciales eléctricos durante la emisión de señales eléctricas por el nodo SA y el nodo AV. Se utiliza electrodos de plata o cloruro de plata para obtener las señales de los biopotenciales eléctricos. Se utiliza un gel conductor para mejorar el sistema de adquisición de señales.

Para diagnosticar las arritmias se realizan pruebas de monitoreo cardíaco. Existen equipos como el electrocardiógrafo que permite detectar la actividad eléctrica del corazón en ese instante. Incluso, se utilizan equipos de monitoreo prolongado, puede ser un día o más, que permiten detectar la actividad eléctrica del corazón bajo una rutina diaria de cada persona, como son los Monitores Holters y Monitores de Evento. También hay pruebas más rigurosas en las que somete al corazón a un evento de estrés, como son las Pruebas de esfuerzo. Consiste en que el paciente realice ejercicios en una banda o bicicleta mientras un electrocardiógrafo determina la actividad eléctrica del corazón y una posible obstrucción de las arterias coronarias. Los métodos antes expuestos son no invasivos, pero también hay uno que es invasivo, que es el estudio electrofisiológico dentro del quirófano; por medio de catéteres se realiza un estudio de la actividad eléctrica del corazón [5].

2.5 Inteligencia Artificial

La inteligencia artificial (AI) es la extensión de la inteligencia humana aplicada en algoritmos complejos para automatizar procesos. Puede ser entrenada para aprender de experiencias y desarrollar tareas que requieran inteligencia humana, como es la percepción visual, la toma de decisiones y la traducción de lenguajes. La AI es un campo grande que engloba varios sub-campos como aprendizaje de máquinas, aprendizaje automático, procesamiento de datos y redes neuronales convolucionales (por sus siglas en inglés CNN) [2].

Las CNN son una clase de redes neuronales de aprendizaje profundo, se las utiliza para analizar imágenes por capas aplicando operaciones convolucionales. En estas operaciones se aplican filtros (conocidos como kernel) para extraer características como formas, figuras y texturas. Cada filtro está conformado de matrices que contienen valores que se deben aprender durante el entrenamiento [3].

CAPÍTULO 3: DISEÑO E IMPLEMENTACIÓN

En capítulo de diseño e implementación se describe el proceso realizado para la clasificación de actividad eléctrica generada por el musculo del corazón. Se utiliza 162 segmentos de grabaciones, que fueron digitalizadas con una frecuencia de muestreo de 360 Hz por canal con una resolución de 11-bit y un rango superior a 10 [mV], provenientes de tres bases de datos distribuidas de forma pública por el MIT. La clasificación fue en personas con arritmias cardíacas (ARR), personas con insuficiencia cardíaca congestiva (CHF) y personas ritmos sinusales normales (NSR).

El proceso está conformado por las siguientes etapas (figura 3.1):

- Ingreso de data.
- Pre-procesado.
- Entrenamiento y clasificación.
- Interfaz.




Figura 3.1 Proceso de clasificación de la señal ECG.

3.1 Pre-procesamiento de la señal.

El preprocesamiento es una parte esencial para aplicar técnicas de aprendizaje automático que se utilizan para completar y eliminar ruido del conjunto de datos. Estos procesos se utilizan para realizar un examen elocuente de los datos y, por último, proporcionan un resultado óptimo [4, 5].

En primer lugar, podemos aplicar el método de umbral de wavelet y el algoritmo de reconstrucción de descomposición de wavelet juntos para eliminar el ruido de la onda ECG original. La técnica de umbral de wavelet puede reducir el ruido de electromiografía, así como la interferencia del ruido de la línea de alimentación. Por otro lado, el algoritmo de

reconstrucción de descomposición de wavelet reduce el ruido de deriva de la línea base de la señal ECG ruidosa. Estos dos métodos esenciales se utilizan inicialmente para eliminar el ruido de la onda ECG para que la onda pueda ser utilizada para un procesamiento adicional [6].

Finalmente, la señal de latido cardíaco como datos de entrada se presenta directamente para el modelo CNN para que se extraigan las mejores características y se puedan clasificar las señales ECG.

En la etapa del pre-procesamiento de la señal usamos la onda ECG unidimensional y la convertimos en una representación 2D en tiempo y frecuencia. El eje horizontal representa el tiempo y el eje vertical la frecuencia. Estas representaciones se llaman escalogramas y para obtenerlas se aplica la transformada de onda continua (CWT) (figura 3.2) [10].

```
Fs = 128;  
fb = cwtfilterbank('SignalLength',1000,...  
    'SamplingFrequency',Fs,...  
    'VoicesPerOctave',12);  
sig = ECGData.Data(1,1:1000);  
[cfs,frq] = wt(fb,sig);  
t = (0:999)/Fs;figure;pcolor(t,frq,abs(cfs))  
set(gca,'yscale','log');shading interp;axis tight;  
title('Scalogram');xlabel('Time (s)');ylabel('Frequency (Hz)')
```

Figura 3.2. Aplicación de la CWT.

De manera aleatoria dividimos las imágenes en dos grupos, uno para entrenamiento y el otro para validación. El 80% de imágenes se destina para entrenamiento y el otro 20% para validación (figura 3.3).

```
rng default
[imgsTrain,imgsValidation] =
splitEachLabel(allImages,0.8,'randomized');
disp(['Number of training images: ',num2str(numel(imgsTrain.Files))]);
disp(['Number of validation images:
',num2str(numel(imgsValidation.Files))]);
```

Figura 3.3. Segmentación de imágenes.

3.2 Entrenamiento y clasificación de la señal.

El entrenamiento de una red neuronal convolucional (CNN) implica el proceso de ajuste de los parámetros de la red para que pueda aprender a identificar patrones y características relevantes en los datos de entrada. En el caso de señales, como las de ECG (electrocardiograma), el proceso de entrenamiento se lleva a cabo de la siguiente manera:

Preparación de Datos: Se deben preparar los datos de señales en un formato adecuado. Esto a menudo implica la segmentación de las señales en fragmentos más pequeños, normalización de los datos y, en algunos casos, la transformación de las señales en representaciones visuales (por ejemplo, espectrogramas) si la red requiere imágenes como entrada [11].

Definición del Modelo: Se selecciona y configura una arquitectura de red neuronal adecuada, como GoogLeNet o AlexNet. Ambas redes se componen de múltiples capas

convolucionales, capas de activación, y capas de agrupamiento, lo que les permite extraer y aprender características jerárquicas de los datos [12].

Entrenamiento: Durante el entrenamiento, la red ajusta sus parámetros (pesos y sesgos) para minimizar la diferencia entre las predicciones de la red y las etiquetas reales (es decir, la clase correcta para cada señal). Este proceso se realiza mediante algoritmos de optimización, como el descenso de gradiente, y se valida usando un conjunto de datos de validación para evitar el sobreajuste [13].

Clasificación:

Una vez que el modelo ha sido entrenado, se utiliza para clasificar nuevas señales:

Predicción: Se alimentan señales nuevas o no vistas en el modelo entrenado. La red neuronal procesa estas señales a través de sus capas para extraer características relevantes y hacer una predicción sobre la clase a la que pertenece cada señal (por ejemplo, arritmia, insuficiencia cardíaca congestiva, o ritmo sinusal normal).

Evaluación del Rendimiento: El rendimiento del modelo se evalúa utilizando métricas de clasificación, como la precisión, la sensibilidad, y la especificidad, para asegurar que el modelo generaliza bien a datos no vistos y realiza clasificaciones precisas [14].

En resumen, el entrenamiento de CNNs como GoogLeNet y AlexNet para señales implica ajustar el modelo para aprender de los datos de entrenamiento, mientras que la clasificación se refiere a la aplicación del modelo entrenado para asignar etiquetas a nuevas señales basadas en el conocimiento adquirido durante el entrenamiento.

3.3 GoogleNet

Utilizamos la red pre-entrenada de GoogleNet, una CNN con 8 capas de profundidad, ha sido aplicada en más de un millón de imágenes desde la base de datos de ImageNet. La red requiere imágenes de 224 por 224. Cada una de las capas se consideran un filtro. Las primeras capas identifican las características más comunes como bordes y colores. Mientras que, las ultimas capas en características más específicas como frecuencias [15].

Para volver a entrenar GoogleNet para nuestro trabajo de clasificación de ECG, reemplazamos las últimas cuatro capas de la red. La primera de las cuatro capas, “pool5-drop_7x7_s1”, es una capa de eliminación aleatoria (dropout). Una capa de eliminación aleatoria establece aleatoriamente elementos de entrada a cero con una probabilidad dada [16]. La capa de eliminación aleatoria se utiliza para ayudar a prevenir el sobreajuste. La probabilidad predeterminada es 0.5.

Para llevar a cabo este proceso en MATLAB, primero cargamos la red GoogleNet pre entrenada y luego reemplazamos las últimas capas de la red con nuestras propias capas personalizadas. Es importante ajustar las capas finales para que coincidan con el número de clases en nuestro problema de clasificación de ECG. Una vez que se ha realizado este ajuste, podemos entrenar la red con nuestros datos de ECG [17]. Durante el proceso de entrenamiento, se pueden ajustar parámetros como la tasa de aprendizaje y el número de épocas para mejorar el rendimiento de la red en la clasificación de ECG.

Las tres capas restantes, “loss3-classifier”, “prob” y “output” (figura 3.4), contienen información sobre cómo combinar las características que extrae la red en probabilidades de clase y etiquetas. De forma predeterminada, las últimas tres capas están configuradas para 1000 categorías.

Además, es importante tener en cuenta que reentrenar una red pre entrenada como GoogleNet puede requerir una cantidad significativa de datos y poder computacional [18]. Sin embargo, al reentrenar una red pre entrenada, podemos aprovechar el conocimiento previo aprendido por la red y adaptarlo a nuestro problema específico de clasificación de ECG, lo que puede resultar en un mejor rendimiento que entrenar una red desde cero.

Para adaptar la red GoogleNet a nuestro nuevo conjunto de datos, agregamos cuatro nuevas capas: una capa de eliminación aleatoria (dropout) con una probabilidad del 60% de eliminación, una capa softmax y una capa de salida de clasificación. Configuramos la capa completamente conectada final para que tenga el mismo tamaño que el número de clases en el nuevo conjunto de datos (3, en este ejemplo). Para que el aprendizaje en las nuevas capas sea más rápido que en las capas transferidas. Luego, se almacenan las dimensiones de la imagen de GoogleNet en “inputSize”.

Al agregar estas nuevas capas y ajustar las configuraciones de la red, estamos preparando la red GoogleNet para aprender y clasificar las características específicas de nuestro conjunto de datos de ECG. Esto permitirá aprovechar el poder de la red pre

entrenada mientras se adapta a nuestra tarea específica de clasificación de ECG. En la figura 3.4 se observa el procedimiento descrito.

```
lgraph = removeLayers(lgraph,{'pool5-drop_7x7_s1','loss3-  
classifier','prob','output'});  
  
numClasses = numel(categories(imgsTrain.Labels));  
newLayers = [  
    dropoutLayer(0.6,'Name','newDropout')  
  
    fullyConnectedLayer(numClasses,'Name','fc','WeightLearnRateFactor',5,'  
BiasLearnRateFactor',5)  
    softmaxLayer('Name','softmax')  
    classificationLayer('Name','classoutput')];  
lgraph = addLayers(lgraph,newLayers);  
  
lgraph = connectLayers(lgraph,'pool5-7x7_s1','newDropout');  
inputSize = net.Layers(1).InputSize;
```

Figura 3.4. Nuevas capas en la CNN de GoogleNet.

Una red neuronal debe ser entrenada que involucra la ejecución de procesos iterativos el cual, implica minimizar una función de pérdida. El proceso de entrenamiento de un modelo generalmente puede tomar unos minutos u horas dependiendo del procesador disponible [19]. Durante este tiempo, la ventana de comandos en el entorno de desarrollo o en el software de entrenamiento muestra información detallada sobre el progreso del entrenamiento. Esta información incluye diversos aspectos clave del proceso de entrenamiento y validación del modelo.

Entre los datos que se muestran están:

	ESPOL - FIEC MAESTRÍA EN INGENIERÍA BIOMÉDICA	
--	--	--

- **Número de Época:** Indica cuántas veces el modelo ha pasado por todo el conjunto de datos de entrenamiento [20]. Una época completa corresponde a una iteración sobre el conjunto de datos completo.
- **Número de Iteración:** Refleja los pasos individuales dentro de cada época, donde cada iteración se refiere al procesamiento de un mini-lote de datos [21]. El número de iteración ayuda a monitorear el progreso dentro de cada época.
- **Tiempo Transcurrido:** Muestra el tiempo total desde el inicio del entrenamiento hasta el momento actual [21]. Es una medida importante para evaluar la duración y eficiencia del proceso de entrenamiento.
- **Precisión del Mini-Lote:** Mide la exactitud del modelo en cada mini-lote durante el entrenamiento. Esta métrica muestra la capacidad del modelo para aprender y mejorar a partir de cada subconjunto de datos [21].
- **Precisión en la Validación:** Indica el rendimiento del modelo en un conjunto de datos de validación, que es un conjunto de datos separado del conjunto de entrenamiento [21]. La precisión en la validación es fundamental para evaluar cómo de bien el modelo generaliza a nuevos datos.
- **Valor de la Función de Pérdida para los Datos de Validación:** Mide la diferencia entre las predicciones del modelo y los valores reales en los datos de validación. Un valor bajo en esta función de pérdida indica que el modelo está produciendo resultados precisos [22].

Para lograr esto, se utiliza un algoritmo de descenso de gradiente. En cada iteración, se evalúa el gradiente de la función de pérdida y se actualizan los pesos del algoritmo de descenso. El entrenamiento se puede ajustar configurando varias opciones. Por ejemplo, “InitialLearnRate” especifica el tamaño inicial del paso en la dirección del gradiente negativo de la función de pérdida. “MiniBatchSize” especifica qué tan grande es el subconjunto del conjunto de entrenamiento que se utiliza en cada iteración. “MaxEpochs” especifica el número máximo de “epochs” (épocas) a usar para el entrenamiento. Reducir el número de “epochs” tiene el efecto de subajustar el modelo, y aumentar el número resulta en sobreajuste [22].

Es importante tener en cuenta que el ajuste de estas opciones puede afectar significativamente el rendimiento y la capacidad de generalización de la red neuronal. Por ejemplo, un valor demasiado bajo para “InitialLearnRate” puede hacer que el entrenamiento sea demasiado lento, mientras que un valor demasiado alto puede provocar que la red no converja adecuadamente. Del mismo modo, un valor demasiado pequeño para “MiniBatchSize” puede hacer que el entrenamiento sea ineficiente, mientras que un valor demasiado grande puede hacer que la red se sobreajuste a los datos de entrenamiento.

Por lo tanto, es importante experimentar con diferentes configuraciones y ajustarlas según sea necesario para obtener el mejor rendimiento de la red neuronal en la tarea específica para la que se está entrenando. Los parámetros que se establecieron fueron “MiniBatchSize”: 10, “MaxEpochs”: 10 y “InitialLearnRate” en 0.0001 (figura 3.5).

```
options = trainingOptions('sgdm',...
    'MiniBatchSize',15,...
    'MaxEpochs',20,...
    'InitialLearnRate',1e-4,...
    'ValidationData',imgsValidation,...
    'ValidationFrequency',10,...
    'Verbose',1,...
    'ExecutionEnvironment','cpu',...
    'Plots','training-progress');
```

Figura 3.5. Parámetros de entrenamiento.

Se procede a evaluar la Precisión de GoogLeNet. Primero, se evalúa el rendimiento de la red neuronal utilizando los datos de validación. La precisión calculada en esta etapa es equivalente a la precisión de validación reportada en la figura de visualización del entrenamiento. Para entrenar a GoogLeNet, los escalogramas se dividieron en dos colecciones: una para el entrenamiento y otra para la validación. Ambas colecciones se emplearon durante el proceso de entrenamiento.

Las Redes Neuronales Convolucionales (CNN) son herramientas poderosas en el análisis y procesamiento de imágenes médicas, como resonancias magnéticas, tomografías computarizadas y fotografías microscópicas. Cada capa de una CNN transforma la imagen de entrada mediante filtros convolucionales que extraen características a diferentes niveles de abstracción [23]. Estas características pueden ser desde patrones simples, como bordes y texturas, hasta representaciones más complejas, como formas específicas de tejidos o estructuras internas.

En las primeras capas de una CNN, los filtros son responsables de detectar características básicas de la imagen. Por ejemplo, en imágenes médicas, estos filtros pueden identificar bordes de órganos, tejidos y estructuras anatómicas. La visualización de los pesos de estos filtros en la primera capa convolucional revela cómo la red aprende a detectar estos patrones básicos. Los 64 conjuntos de pesos en la primera capa de una CNN representan diferentes filtros convolucionales que responden a características distintas [23]. Estos filtros se entrenan para identificar características específicas que luego se utilizarán en capas posteriores para construir representaciones más complejas.

A medida que se avanza hacia capas más profundas en la red, las características detectadas se combinan para formar representaciones más abstractas y complejas. Por ejemplo, mientras que las primeras capas pueden identificar bordes, las capas intermedias podrían detectar formas más complejas y patrones texturales.

Las capas finales pueden reconocer patrones más abstractos, como la presencia de enfermedades o anomalías en imágenes médicas. Las capas iniciales ayudan a identificar características básicas de tejidos y estructuras anatómicas, mientras que las capas más profundas pueden identificar características más específicas asociadas con diferentes patologías [24]. Este proceso permite a los sistemas de diagnóstico asistidos por computadora (CAD, por sus siglas en inglés) realizar tareas como la detección de cáncer en imágenes mamográficas, el análisis de tejidos en biopsias digitales y el reconocimiento de patrones en imágenes de resonancia magnética.

```
wgths = trainedGN.Layers(2).Weights;  
wgths = rescale(wgths);  
wgths = imresize(wgths,5);  
figure  
montage(wgths)  
title('First Convolutional Layer Weights')
```

Figura 3.6. Entrenamiento de la red.

Es fundamental comprender cómo las diferentes capas de la red responden a características específicas de la imagen. A continuación, se detallan los pasos y conceptos clave asociados con la tarea de examinar las áreas activadas en una imagen y compararlas con la imagen original.

Cada capa convolucional de una CNN está diseñada para extraer y detectar características específicas de una imagen. Para una imagen de la clase “ARR”, debes observar qué áreas de la imagen provocan una mayor activación en la primera capa convolucional, llamada “conv1-7x7_s2” (figura 3.7). Esta capa utiliza filtros convolucionales de tamaño 7x7 con un paso de 2 píxeles (stride) para generar una representación inicial de la imagen.

```
convLayer = 'conv1-7x7_s2';  
  
imgClass = 'ARR';  
imgName = 'ARR_10.jpg';  
imarr = imread(fullfile(parentDir,dataDir,imgClass,imgName));  
  
trainingFeaturesARR = activations(trainedGN,imarr,convLayer);  
sz = size(trainingFeaturesARR);  
trainingFeaturesARR = reshape(trainingFeaturesARR,[sz(1) sz(2) 1  
sz(3)]);  
figure  
montage(rescale(trainingFeaturesARR),'Size',[8 8])  
title([imgClass,' Activations'])
```

Figura 3.7. Clase “ARR”.

Es útil identificar cuál de los canales en una capa convolucional produce la respuesta más fuerte para una imagen dada. Esto puede proporcionar información valiosa sobre qué características específicas de la imagen están siendo más prominentes para la red.

Cada capa convolucional en una CNN contiene varios canales que corresponden a diferentes filtros convolucionales [25]. Cada canal genera un conjunto de activaciones que representa cómo el filtro detecta características en la imagen. Para encontrar el canal más fuerte y compararlo con la imagen original se realiza el siguiente procedimiento:

- **Obtén las Activaciones de la Capa:** Pasa la imagen a través de la red y obtén las activaciones de la primera capa convolucional, “conv1-7x7_s2”.
- **Evalúa las Activaciones por Canal:** Dentro de la capa, cada uno de los 64 canales producirá un mapa de características que muestra la respuesta del filtro a diferentes regiones de la imagen.

- Identifica el Canal con la Mayor Activación: Compara los mapas de características generados por cada canal para determinar cuál tiene la respuesta más fuerte. Esto puede hacerse calculando estadísticas como la suma de todas las activaciones en cada canal, o buscando el máximo valor en el mapa de características.

Una vez que se ha identificado el canal con la mayor activación, el siguiente paso es comparar este canal con la imagen original para entender qué características específicas están siendo destacadas [26]. Este procedimiento es de comparación, entre el canal más fuerte con la imagen original. Durante el desarrollo del proyecto se realiza el siguiente procedimiento:

- Visualiza el Mapa de Características del Canal Más Fuerte: Extrae y muestra el mapa de características del canal más fuerte. Este mapa de características revela las regiones de la imagen original que generan las respuestas más significativas del filtro.
- Analiza la Comparación: Observa las áreas de alta activación en el mapa de características y compáralas con la imagen original. Identifica qué partes de la imagen son más prominentes para el filtro del canal más fuerte.

```
imgSize = size(imarr);  
imgSize = imgSize(1:2);  
[~,maxValueIndex] = max(max(max(trainingFeaturesARR)));  
arrMax = trainingFeaturesARR(:,:,maxValueIndex);  
arrMax = rescale(arrMax);  
arrMax = imresize(arrMax,imgSize);  
figure;  
imshowpair(imarr,arrMax,'montage')  
title(['Strongest ',imgClass,' Channel: ',num2str(maxValueIndex)])
```

Figura 3.8. Identificación de la canal más fuerte.

3.4 AlexNet

AlexNet es una red neuronal convolucional profunda cuya arquitectura soporta imágenes de tamaño 227x227x3. Aunque las dimensiones de la imagen son diferentes para GoogLeNet, no es necesario generar nuevas imágenes RGB con las dimensiones de AlexNet. Se puede utilizar las imágenes RGB originales. La versión preentrenada de AlexNet se puede cargar y adaptar para nuevas tareas de clasificación, como la identificación de patrones en imágenes de ECG [27].

Para volver a entrenar AlexNet para clasificar nuevas imágenes, debes realizar cambios similares a los que se hicieron para GoogLeNet. Por defecto, las últimas tres capas de AlexNet están configuradas para 1000 categorías. Estas capas deben ajustarse a nuestro problema de clasificación de ECG. La Capa 23, la capa completamente conectada, debe ajustarse para que tenga el mismo tamaño que el número de categorías en nuestros datos de ECG. La Capa 24 no necesita cambiarse para nuestro problema de clasificación de ECG.

AlexNet, originalmente diseñado para la clasificación de imágenes en 1000 categorías, debe ser modificado para adaptarse a un nuevo problema de clasificación, como el diagnóstico de enfermedades cardíacas a partir de imágenes de ECG. A continuación, se detallan los pasos para adaptar AlexNet a este nuevo problema:

1. Reemplazar la Capa de Salida de la Red

AlexNet tiene varias capas al final de su arquitectura que se pueden modificar para ajustarse a una nueva tarea de clasificación [28], como son la capa 23 y la capa 25.

- **Capa 23: Capa Totalmente Conectada (Fully Connected Layer):** Esta capa debe ser ajustada para que tenga el número de neuronas correspondiente al número de categorías en el problema de ECG. En nuestro caso, si estamos clasificando imágenes de ECG en 3 categorías, esta capa debe ser cambiada para tener 3 salidas.
- **Capa 25: Capa de Salida de Clasificación:** Esta capa es responsable de la función de pérdida utilizada durante el entrenamiento y de las etiquetas de clase. Dado que hay 3 categorías en nuestro problema de ECG, esta capa debe ser configurada para la clasificación en 3 clases. La función de pérdida es típicamente cross-entropy en clasificación múltiple.

2. Entrenamiento del Modelo Ajustado

Una vez que hayas modificado las capas, el siguiente paso es entrenar el modelo ajustado con un nuevo conjunto de datos de ECG. Esto implica ajustar los hiperparámetros de entrenamiento como la tasa de aprendizaje, el número de épocas y el tamaño del lote.

3. Evaluación del Modelo

Después del entrenamiento, evalúa el modelo ajustado usando datos de prueba para verificar su precisión en la clasificación de las categorías de ECG.

Modificar AlexNet para clasificar imágenes de ECG implica ajustar las últimas capas del modelo para que se adapten al número de categorías en el nuevo problema. Esta tarea incluye reemplazar la capa de salida, ajustar los parámetros del modelo, y entrenarlo con datos específicos de ECG. Estas modificaciones permiten que AlexNet, un modelo originalmente diseñado para la clasificación general de imágenes sea eficaz en aplicaciones específicas como el análisis de ECG para el diagnóstico de enfermedades cardíacas.

```
layers(23) = fullyConnectedLayer(3);  
layers(25) = classificationLayer;
```

Figura 3.9. Identificación de la capa 23 y capa 25.

Preparar Datos RGB para AlexNet

Las imágenes RGB tienen dimensiones apropiadas para la arquitectura de GoogleNet. De la primera capa de AlexNet, se obtienen las dimensiones de la imagen. Utiliza esas dimensiones para crear almacenes de imágenes aumentadas que

redimensionarán automáticamente las imágenes RGB existentes para la arquitectura de AlexNet.

Posteriormente, se realiza la preparación de datos RGB, que se van a utilizar en el entrenamiento. AlexNet tiene requerimientos específicos para las dimensiones de las imágenes de entrada. Este proceso asegura que tus datos sean compatibles con el model [29].

Una vez que conoces las dimensiones requeridas, debes crear un almacén de imágenes aumentadas que ajuste automáticamente tus imágenes RGB existentes al tamaño adecuado para AlexNet [30]. Este proceso también puede incluir técnicas de aumento de datos, que ayudan a mejorar la capacidad general del modelo al introducir variaciones en los datos de entrenamiento.

Técnicas Comunes de Aumento de Datos [30]:

- Redimensionamiento: Cambiar el tamaño de las imágenes a las dimensiones requeridas.
- Rotación: Rotar imágenes para aumentar la diversidad de datos.
- Espejado: Reflejar imágenes horizontalmente.
- Cambio de Brillo/Contraste: Modificar las características visuales para hacer el modelo más robusto a variaciones en las imágenes.

Después de crear el almacén de imágenes aumentadas, puedes usar este almacén para entrenar AlexNet. Este paso involucra ajustar los parámetros de entrenamiento del

modelo y ejecutar el proceso de entrenamiento con los datos preparados. Después del entrenamiento, es fundamental evaluar el rendimiento del modelo en un conjunto de datos de prueba para verificar su capacidad de generalización.

Preparar datos RGB para AlexNet implica redimensionar las imágenes a las dimensiones especificadas por el modelo y aplicar técnicas de aumento de datos para mejorar el rendimiento del modelo. Este proceso es fundamental en aplicaciones biomédicas, donde se busca adaptar modelos de visión por computadora a tareas específicas de clasificación de imágenes médicas.

```
inputSize = alex.Layers(1).InputSize;  
augimgsTrain = augmentedImageDatastore(inputSize(1:2), imgsTrain);  
augimgsValidation =  
augmentedImageDatastore(inputSize(1:2), imgsValidation);
```

Figura 3.10. Preparación de datos RGB.

```
rng default  
mbSize = 10;  
mxEpochs = 10;  
ilr = 1e-4;  
plt = 'training-progress';  
  
opts = trainingOptions('sgdm',...  
    'InitialLearnRate',ilr, ...  
    'MaxEpochs',mxEpochs ,...  
    'MiniBatchSize',mbSize, ...  
    'ValidationData',augimgsValidation,...  
    'ExecutionEnvironment','cpu',...  
    'Plots',plt);  
  
trainedAN = trainNetwork(augimgsTrain, layers, opts);
```

Figura 3.11. Proceso de entrenamiento.

3.5 Herramientas de Visualización

GUIDEMO

Con GUIDEMO permite utilizar el código de MATLAB para el archivo de interfaz gráfica. El objetivo es crear una interfaz gráfica de usuario (GUI) básica que permita a los usuarios que buscan entender cómo se desarrollan y utilizan las GUIs en MATLAB [31].

Con la herramienta de desarrollo de GUIs en MATLAB podemos realizar una interfaz gráfica con las siguientes funciones:

1. Crear una Nueva Instancia o Activar la Existente:

El comando GUIDEMO se usa para crear una nueva instancia de la GUI guidemo o para activar la instancia existente si ya está abierta.

2. Modificar Propiedades de la GUI

Puedes modificar las propiedades de GUIDEMO al crear o activar la GUI. Esto se hace mediante pares de propiedad-valor que se aplican antes de que se llame a guidemo_OpeningFcn (figura 3.12).

La herramienta GUIDEMO puede ser utilizado como una plantilla básica para desarrollar GUIs que interactúan con datos médicos. Permite crear interfaces gráficas para herramientas de análisis de datos, permitiendo a los profesionales de la salud interactuar

con algoritmos de diagnóstico. Es versátil para diseñar GUIs que permite visualizar datos médicos, como gráficos de ECG.

```
gui_Singleton = 1;
gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',  gui_Singleton, ...
                  'gui_OpeningFcn', @guidemo_OpeningFcn, ...
                  'gui_OutputFcn',  @guidemo_OutputFcn, ...
                  'gui_LayoutFcn',  [] , ...
                  'gui_Callback',   []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
```

Figura 3.12. Implementación de GUIDEMO.

CAPÍTULO 4: RESULTADOS

4.1 Matriz de Confusión

Un matriz de confusión es una herramienta que se utiliza para evaluar la precisión de un modelo. Se puede visualizar una predicción al comparar los valores actuales con la precisión del modelo. Los valores en la diagonal son los Verdaderos Positivos, en inglés “True Positives” (TP). Estos valores representan el número correcto de predicciones del modelo [32].

Se entrenaron 1000 datos, los cuales pueden ser visualizados en la figura 4.1, y los TP se clasificaron de la siguiente manera:

- 752 está prediciendo de forma correcta la clase ARR.
- 917 está prediciendo de forma correcta la clase CHF.
- 924 está prediciendo de forma correcta la clase NSR.

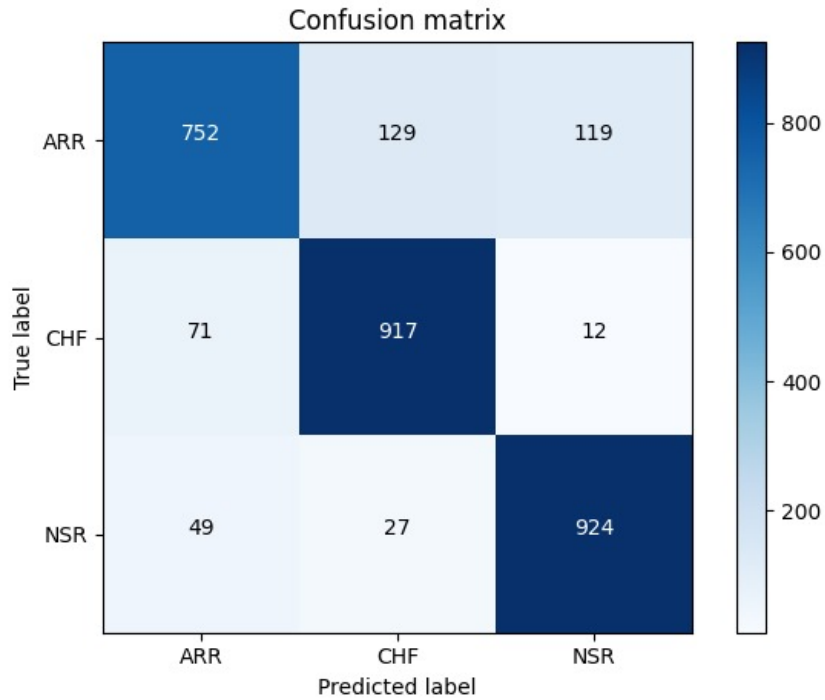


Figura 4.1. Matriz de confusión, extraída del modelo de clasificación en Matlab.

La matriz de confusión es posible visualizar en porcentajes. En la figura 4.2 se visualiza los TP que se clasificaron de la siguiente manera:

- 75,20% está prediciendo de forma correcta la clase ARR.
- 91,70% está prediciendo de forma correcta la clase CHF.
- 92,40% está prediciendo de forma correcta la clase NSR.

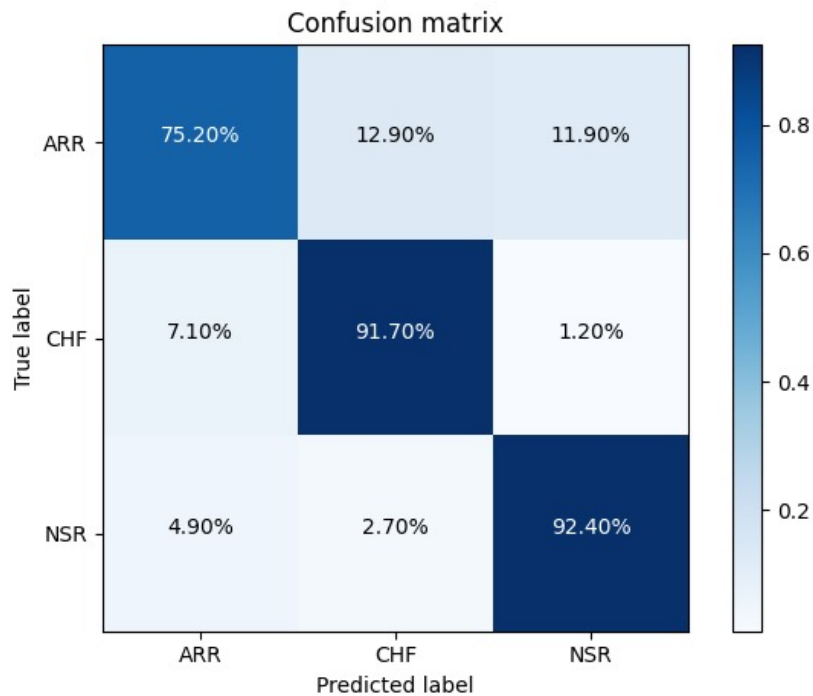


Figura 4.2. Matriz de confusión en porcentajes, extraída del modelo de clasificación en Matlab.

Mientras tanto, los valores que están arriba de la diagonal principal son los Falsos Positivos, en inglés “False Positives” (FP); en este caso, el modelo incorrectamente predijo una clase positiva cuando realmente es negativa. En este proyecto, el modelo identificó una arritmia cuando el paciente en realidad no la tiene. Los valores que se encuentran por debajo de la diagonal principal son los Falso Negativos, en inglés “False Negatives” (FN); en este caso, el modelo incorrectamente predijo una clase negativa mientras que en realidad la clase es positiva. Los FN, en nuestro modelo, son los de mayor riesgo porque si el modelo detecta que un paciente no posee una arritmia y en realidad sí la tiene, lo cual podría ser comprometedor para la salud. Tradicionalmente, la tasa de FN debe reducirse para evitar exposición de los pacientes.

4.2 ROC

Una matriz ROC (Receiver Operating Characteristics) es una curva que se utiliza para el análisis, clasificación y rendimiento de los modelos. Nos muestra la relación entre la tasa de TP y la tasa de FP. El área bajo la curva (AUC) es una métrica que proporciona un resumen del entrenamiento entre 0.10 y 1.00 [33]. Mientras más cerca esté del 1.00 indicará que el modelo tiene mejor capacidad de discriminación, *i.e.*, mayor área bajo la curva implica mejor sistema de clasificación.

En el caso de la matriz ROC, ver figura 4.3, da los siguientes resultados:

- Área bajo la curva de la clase ARR: 0.93
- Área bajo la curva de la clase CHF: 0.98
- Área bajo la curva de la clase NSR: 0.98

Los resultados dieron un área bajo la curva relativamente alto, lo que indica que el modelo es eficaz en la clasificación. En la clase ARR, un área bajo la curva de 0.93 es una tasa de aciertos del 93% y, en la clase CHF y NSR da una tasa de aciertos del 98%. El modelo posee un mejor desempeño al distinguir las clases CHF y NSR.

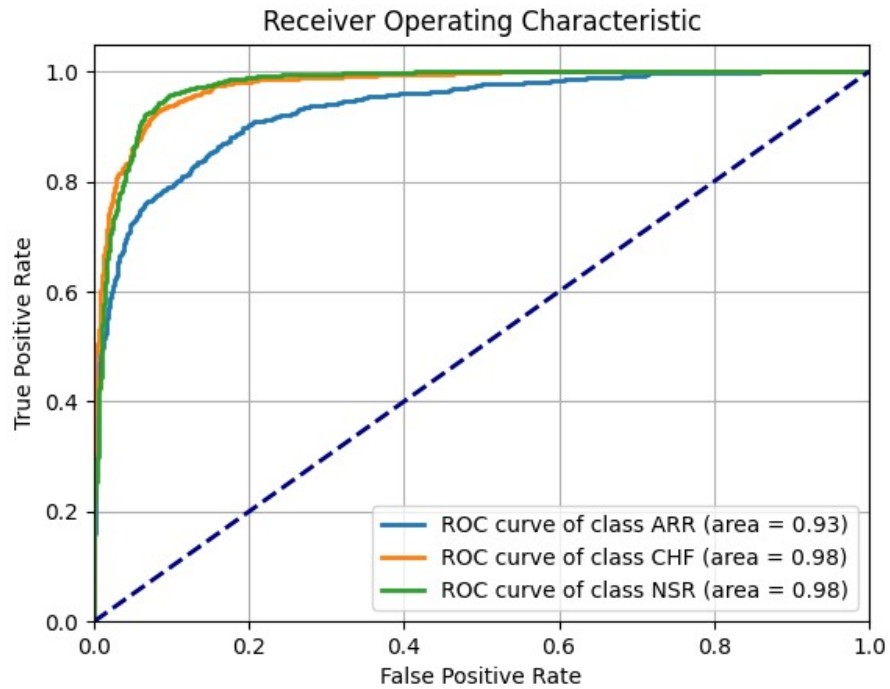


Figura 4.3. Matriz ROC, extraída del modelo de clasificación en Matlab.

4.3 Precisión

Una matriz de precisión es una métrica que mide la proporción de predicciones correctas sobre las predicciones realizadas de un modelo [34]. Se la puede también definir como:

$$\text{Precisión (accuracy)} = \frac{TP}{TP+FP} \quad (1)$$

En la figura 4.4 se puede observar el comportamiento de los datos de validación en comparación con los datos entrenados, dando una precisión de 0.864 en el modelo. Esto quiere decir que identifica de forma correcta el 86% de los datos.




Figura 4.4. Precisión, extraída del modelo de clasificación en Matlab.

4.4 Pérdida

Una matriz de pérdida (loss) mide el error entre las predicciones del modelo y los valores reales. En la figura 4.5 se puede observar el comportamiento de los datos de validación en comparación con los datos entrenados [35]. La pérdida, en la representación de datos entrenados muestra el error del modelo en el conjunto de datos que se utilizaron

para entrenar el modelo. Mientras que, la pérdida de validación muestra el error en el conjunto de datos que se ingresaron al modelo para clasificar.




Figura 4.5. Pérdida, extraída del modelo de clasificación en Matlab.

4.5 Tabla de resultados

El modelo ha sido evaluado en base a tres métricas promedio (tabla 1), reflejan los resultados y su rendimiento en la clasificación.

METRICAS PROMEDIO	
Precisión	0.8642
Recall	0.8643

ESPOL - FIEC MAESTRÍA EN INGENIERÍA BIOMÉDICA	
--	--

F1-Score	0.8624
----------	--------

Tabla 1. Resultados de las métricas del modelo de clasificación en Matlab.

El modelo tiene una precisión del 86,42%, lo que indica que el 86,42% de las predicciones TP son correctas. El recall muestra que la sensibilidad del modelo para identificar los TP es del 86,43%. El F1-Score de 0.8624 propone un buen equilibrio entre la precisión y el recall del modelo, por lo que es eficaz en obtener TP y minimizar los valores FP.

La curva ROC muestra el comportamiento del modelo en diferentes umbrales. Un modelo con buen rendimiento tiene una curva ROC que se aproxima al ángulo superior izquierdo del gráfico.

4.6 Análisis de Resultados

En base a los resultados obtenidos en la matriz de confusión (figura 4.2), podemos determinar con un 92.40% de certeza que la clase NSR no tiene confusión con una arritmia. Por lo tanto, una persona con un ritmo sinusal normal tiene un porcentaje de error muy bajo. La clase CHF tiene un 1,20% de confusión con la clase NSR, por lo tanto, la tasa de FP es muy baja, entonces evitamos que una persona que realmente tenga una arritmia que pueda derivar en un fallo congestivo, deje de percibir atención médica. Ambas clases le

permiten al médico llegar a un análisis más concreto y reducir considerablemente la tasa de personas con un CHF.

El desarrollo de este sistema de clasificación nos podría software de deep learning para la detección de arritmias representa un avance significativo en el monitoreo cardiovascular.

A medida que la tecnología se integra en dispositivos “wearables”, su capacidad para realizar un seguimiento constante y en tiempo real de la actividad cardíaca ofrece una oportunidad sin precedentes para la prevención de arritmias. Este sistema de clasificación no solo identifica arritmias con alta precisión, sino que también evalúa la probabilidad de eventos cardíacos determinísticos futuros. Esta capacidad predictiva permite intervenciones tempranas y oportunas que podrían reducir significativamente el riesgo de fallos cardíacos y mejorar la calidad de vida de los pacientes.

CONCLUSIONES

El modelo de clasificación ha demostrado un rendimiento satisfactorio en la clasificación de las tres clases de arritmias: ARR (arritmias), CHF (insuficiencia cardiaca congestiva) y NSR (ritmo sinusal normal). Los valores de AUC (área bajo la curva) de 0.93 para ARR y de 0.98 para CHF y NSR indican que el modelo puede clasificar y diferenciar entre estas clases. La precisión de 86% y el recall (sensibilidad del modelo) de 86% subrayan que el modelo no solo es efectivo en identificar correctamente los casos positivos, sino que también mantiene un equilibrio adecuado entre sensibilidad y especificidad. El F1-score (evaluador de rendimiento) de 0.862 confirma que el modelo es capaz de mantener un buen balance entre precisión y recall, lo cual es crucial para aplicaciones clínicas donde ambos aspectos deben ser optimizados.

El desarrollo del sistema de clasificación de arritmias utilizando técnicas de aprendizaje profundo ha dado resultados satisfactorios en términos de rendimiento. El modelo no solo cumple con el objetivo general de aplicar algoritmos de inteligencia artificial, sino que también demuestra una capacidad robusta para procesar y clasificar datos complejos de señales cardíacas. Al lograr un alto AUC para las tres clases indica que el sistema desarrollado puede identificar arritmias de manera confiable.

El resultado de pérdida de 0.38 refleja un nivel aceptable de error en las predicciones del modelo. Aunque la pérdida no es extremadamente baja, se encuentra en un rango que sugiere que el modelo está bien entrenado y es capaz de hacer predicciones

precisas sobre los datos procesados. La calidad del procesamiento de las señales cardíacas proporcionadas por el MIT ha sido adecuadamente manejada por el modelo, pero hay oportunidades para optimizar aún más la pérdida mediante ajustes adicionales y técnicas de mejora en el preprocesamiento de datos.

La precisión, el recall y el F1-score del modelo tienen importantes implicaciones clínicas y prácticas. Un modelo con un recall del 86.4% es valioso en contextos médicos, donde la detección temprana de arritmias es crucial para prevenir complicaciones graves. Además, la precisión del 86% y el equilibrio demostrado por el F1-score de 0.862 sugieren que el modelo es capaz de ofrecer diagnósticos confiables y reducir la tasa de falsos positivos y falsos negativos. Esto facilita una toma de decisiones más informada en el diagnóstico y tratamiento de arritmias cardíacas.

RECOMENDACIONES

A pesar del desempeño óptimo del modelo, hay áreas que podrían beneficiarse de mejoras adicionales:

- Implementar métodos como el ajuste de hiperparámetros.
- Utilizar técnicas de regularización.
- Incorporar más datos o características relevantes.

La pérdida del modelo de 0.38, aunque aceptable, sugiere que se pueden explorar técnicas avanzadas de optimización durante el entrenamiento. Realizar un análisis más detallado de los casos en los que el modelo falle puede proporcionar información sobre cómo ajustar el enfoque para mejorar la precisión y la sensibilidad (recall) en clases específicas.

Bibliografía

- [1] P. Jesus, A. Marco y T. Saull, «ResearchGate,» 12 Junio 2021. [En línea]. Available: https://www.researchgate.net/publication/371904384_Metaheuristicas_y_CNN_Comparacion_de_modelos_hibridos_para_mejorar_la_clasificacion_de_imagenes. [Último acceso: 19 Julio 2024].
- [2] J. R. Puchol, «Linkedin,» 21 Agosto 2021. [En línea]. Available: <https://es.linkedin.com/pulse/clasificaci%C3%B3n-de-%C3%A1reas-hospitalarias-jos%C3%A9-ram%C3%B3n-puchol>.
- [3] J. C. G. Aviñoá, «Revista Ocronos. Vol. III. Nº 3,» 16 Julio 2020. [En línea]. Available: QUIRÓFANOS: SUCINTA REFERENCIA A SUS SECTORES..
- [4] Ministerio de Salud Pública, «salud.gob.ec,» [En línea]. Available: <https://www.salud.gob.ec/hospital-general-teofilo-davila/>.
- [5] J. Barrios, «BIG DATA,» 21 Abril 2022. [En línea]. Available: <https://www.juanbarrios.com/redes-neurales-convolucionales/>. [Último acceso: 10 Julio 2024].
- [6] L. López-Cerero, «Papel del ambiente hospitalario y los equipamientos en la transmisión,» *ENFERMEDADES INFECCIOSAS Y MICROBIOLOGÍA CLÍNICA*, p. 1, 2013.
- [7] SATYAMN, «Geeks for Geeks,» 31 Julio 2023. [En línea]. Available: <https://www.geeksforgeeks.org/difference-between-alexnet-and-googlenet/>.
- [8] F. Bashar y H. Yassen, «Research Gate,» Diciembre 2022. [En línea]. Available: https://www.researchgate.net/publication/366232466_ECG_Signal_Classification_Based_on_Neural_Network.
- [9] D. Vipul y J. Shweta, «Research Gate,» Marzo 2015. [En línea]. Available: https://www.researchgate.net/publication/280462158_Classification_of_ECG_signals_using_machine_learning_techniques_A_survey.
- [10] H. Youhe, L. Hongru y X. Yu, «ELSEVIER,» Mayo 2023. [En línea]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S1746809423000617>.
- [11] C. M. Shadhon, A. M. Mohammad y K. K. Dinesh, «ELSEVIER,» AGOSTO 2022. [En línea]. Available: <https://www.sciencedirect.com/science/article/pii/S2214180422000319>.
- [12] S. Abdulhamit, D. Sengul y T. Turker, «SPRINGER LINK,» 17 Junio 2021. [En línea]. Available: <https://link.springer.com/article/10.1007/s12652-021-03324-4>.
- [13] F. Safa y D. Mustafa, «Research Gate,» Febrero 2023. [En línea]. Available: https://www.researchgate.net/publication/381101981_Classification_of_ECG_Signal_Using_Deep_Convolutional_Neural.
- [14] A. Gajre, «Research Gate,» November 2021. [En línea]. Available: https://www.researchgate.net/publication/357755859_MATLAB-based_ECG_R-peak_Detection_and_Signal_Classification_using_Deep_Learning_Approach.
- [15] K. Jeong-Hwan, S. Seung-Yeon y S. Chul-Gyu, «NIH,» 28 Abril 2019. [En línea]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6512052/>.
- [16] M. Works, «MathWorks,» Enero 2024. [En línea]. Available: <https://la.mathworks.com/help/signal/ug/classify-ecg-signals-using-long-short-term-memory-networks.html>.
- [17] Ministerio de Salud Pública, «salud.gob.ec,» [En línea]. Available: <https://www.salud.gob.ec/hospital-general-isidro-ayora/>.
- [18] Hospital General Teófilo Dávila, «htdeloro.blogspot.com,» [En línea]. Available: <http://htdeloro.blogspot.com/p/mision-vision.html>.

ESPOL - FIEC MAESTRÍA EN INGENIERÍA BIOMÉDICA
--

- [19 M. F. Tupiza, *EVALUACIÓN DEL PROCESO DE LIMPIEZA Y DESINFECCIÓN*, Pichincha, 2015.
]
- [20 J. C. V. Garcia, *TÉCNICAS DE DESCONTAMINACIÓN*, Madrid: Paraninto, S.A., 2003.
]
- [21 M. M. Grau, *Higiene del medio hospitalario y limpieza de material*, Editex S.A.
]
- [22 S. López, «CONEXIÓN ABASTUR,» 12 10 2020. [En línea]. Available: <https://www.conexiones365.com/nota/abastur/innovacion-y-tecnologia/luz-ultravioleta-metodo-desinfeccion>.
]
- [23 M. Sánchez, «Sistemas de desinfección,» *Informes, estudios e investigación IACS*, pp. 29-30, 2021.
]
- [24 Organización Mundial de la Salud, «WHO.INT,» 17 Mayo 2017. [En línea]. Available: [https://www.who.int/es/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/es/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)). [Último acceso: 17 Julio 2022].
]
- [25 MAYO CLINIC, «MAYO CLINIC,» 22 Mayo 2022. [En línea]. Available: <https://www.mayoclinic.org/es-es/diseases-conditions/heart-arrhythmia/symptoms-causes/syc-20350668#:~:text=En%20general%2C%20las%20complicaciones%20de,mayor%20riesgo%20de%20co%C3%A1gulos%20sangu%C3%ADneos..> [Último acceso: 17 Julio 2022].
]
- [26 MAYO CLINIC, «Arritmia Cardíaca,» 30 Abril 2022. [En línea]. Available: <https://www.mayoclinic.org/es-es/diseases-conditions/heart-arrhythmia/symptoms-causes/syc-20350668>. [Último acceso: 2023 Enero 19].
]
- [27 Clínica Universidad de Navarra, «Arritmias Cardíacas,» 22 Febrero 2022. [En línea]. Available: [https://www.cun.es/enfermedades-tratamientos/enfermedades/arritmias-cardiacas#:~:text=Existen%20dos%20grandes%20grupos%20de,o%20parox%C3%ADsticas%20\(ocasiones%20puntuales\)..](https://www.cun.es/enfermedades-tratamientos/enfermedades/arritmias-cardiacas#:~:text=Existen%20dos%20grandes%20grupos%20de,o%20parox%C3%ADsticas%20(ocasiones%20puntuales)..) [Último acceso: 19 Enero 2022].
]
- [28 Fundación del Corazón, «Tipos de arritmia,» 2022. [En línea]. Available: <https://fundaciondelcorazon.com/informacion-para-pacientes/enfermedades-cardiovasculares/arritmias/tipo-de-arritmias.html>. [Último acceso: 14 Enero 2023].
]
- [29 R. M. George Moody, «MIT-BIH Arrhythmia Database,» MIT , 24 February 2005. [En línea]. Available: <https://physionet.org/content/mitdb/1.0.0/>.
]
- [30 D. Manab K y A. Samit, «Patient-specific ECG beat classification technique,» 26 September 2014. [En línea]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4611171/#C6>.
]
- [31 INESDI, «¿Cuáles son los tipos de inteligencia artificial que existen?,» 18 Enero 2022. [En línea]. Available: <https://www.inesdi.com/blog/tipos-de-inteligencia-artificial/>.
]
- [32 M. Rivera, «CIMAT,» 18 Noviembre 2017. [En línea]. Available: http://personal.cimat.mx:8181/~mrivera/cursos/aprendizaje_profundo/aumentacion/aumentacion_datos.html. [Último acceso: 12 Julio 2024].
]
- [33 J. J. Cabrera, «Repositorio UMH,» Septiembre 2021. [En línea]. Available: <https://dspace.umh.es/bitstream/11000/26485/1/TFG-Cabrera%20Mora%2C%20Juan%20Jos%C3%A9.pdf>. [Último acceso: 12 julio 2024].
]
- [34 D. Scientist, «Convolutional Neural Network : definición y funcionamiento,» 12 abril 2023. [En línea]. Available: <https://datascientest.com/es/convolutional-neural-network-es>. [Último acceso: 22 julio 2024].
]
- [35 Mathworks, «Redes Neuronales Convolucionales,» 2024, 16 Enero 2024. [En línea]. Available: <https://la.mathworks.com/discovery/convolutional-neural-network.html>. [Último acceso: 01 Agosto 2024].
]