



Pontificia Universidad
JAVERIANA
Cali

**Facultad de Ingeniería
y Ciencias**

Ingeniería Biomédica

INFORME FINAL DE TRABAJO DE GRADO

MyoAlert Vision: sistema inteligente de apoyo
diagnóstico para la identificación automática del infarto
agudo de miocardio con elevación del segmento ST
mediante análisis electrocardiográfico

Julieth Alejandra Daza Ceron
William Felipe Obregon Londoño

Director

Dr. Cristian Alejandro Torres Valencia

Codirector

MSc. Valentina Corchuelo Guzmán

22 de enero de 2026

Santiago de Cali, 22 de enero de 2026

Señores
Pontificia Universidad Javeriana – Cali
Dra. María Constanza Pabón Burbano
Decano
Facultad de Ingeniería y Ciencias
Ciudad

Cordial Saludo.

Por medio de la presente nos permitimos presentarle el Trabajo de Grado titulado “MyoAlert Vision: sistema inteligente de apoyo diagnóstico para la identificación automática del infarto agudo de miocardio con elevación del segmento ST mediante análisis electrocardiográfico”.

Esperamos que este trabajo reúna todos los requisitos académicos, cumpla el propósito para el cual fue creado y sirva de apoyo para futuros proyectos relacionados con la profesión.

Atentamente,



Julieth Alejandra Daza Ceron



William Felipe Obregon Londoño

Santiago de Cali, 22 de enero de 2026

Señores

Pontificia Universidad Javeriana – Cali

Dra. María Constanza Pabón Burbano

Decano

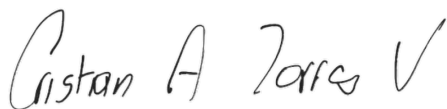
Facultad de Ingeniería y Ciencias

Ciudad

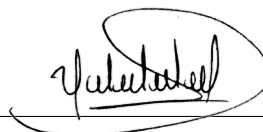
Cordial Saludo.

Certificamos que el presente Trabajo de Grado titulado “MyoAlert Vision: sistema inteligente de apoyo diagnóstico para la identificación automática del infarto agudo de miocardio con elevación del segmento ST mediante análisis electrocardiográfico”, realizado por Julieth Alejandra Daza Ceron y William Felipe Obregon Londoño, estudiantes de Ingeniería Biomédica, se encuentra terminado y puede ser presentado para su sustentación.

Atentamente,



Dr. Cristian Alejandro Torres Valencia
Director Trabajo de Grado



MSc. Valentina Corchuelo Guzmán
Co-Director Trabajo de Grado

Agradecimientos

Primero y, sobre todo, a Dios, por guiarnos en cada paso, por darnos fortaleza en los momentos de incertidumbre, y por permitirnos llegar hasta este logro. A nuestras familias, por ser nuestro refugio y nuestra inspiración. A Lorena Cerón, María Luz Ruiz, Carmen Londoño, William Alberto Obregon y Anderson Obregon, gracias por su amor incondicional, por comprender nuestras ausencias y por celebrar cada pequeño triunfo a nuestro lado. Su apoyo ha sido el pilar sobre el cual construimos nuestros sueños.

A nuestras parejas, Andrés Tulcán y Vanessa Cuaichar, por caminar junto a nosotros con amor y fe en lo que hacíamos. Por ser ese espacio de calma en medio del esfuerzo y recordarnos siempre por qué valía la pena continuar. Su presencia hizo de este proceso no solo un logro académico, sino también una etapa significativa en nuestras vidas.

Agradecemos profundamente a nuestros profesores, en especial a Cristian Torres, director de tesis, cuya guía, conocimientos y paciencia nos orientaron durante todo este proceso; y a Valentina Corchuelo, codirectora, quien desde nuestros inicios en la carrera nos brindó las herramientas necesarias para enfrentar los retos académicos y profesionales con seguridad y pasión. Asimismo, extendemos nuestra gratitud a todos aquellos que, de alguna manera, contribuyeron a nuestra formación, enseñándonos que el aprendizaje va más allá de los libros y las clases.

Finalmente, queremos agradecer a nosotros mismos. Por la constancia, la lealtad y el esfuerzo diario; por motivarnos mutuamente, por compartir risas y desafíos, y por construir experiencias que quedarán grabadas para siempre en nuestra memoria. Este trabajo de grado, y toda nuestra trayectoria universitaria, es también el reflejo de nuestra perseverancia y unión.

Con nostalgia y alegría, cerramos este capítulo, conscientes de que lo vivido y aprendido nos acompañará siempre, y que lo mejor aún está por venir.

Glosario

Símbolos

δ Número aleatorio en $[0, 1]$ que regula la interpolación en SMOTE.

Acrónimos y Abreviaturas

<i>ACC</i>	American College of Cardiology.
<i>AHA</i>	American Heart Association.
<i>AV</i>	Aurículo Ventricular.
<i>BRI</i>	Bloqueo de Rama Izquierda.
<i>CK-MB</i>	Creatina Quinasa Isoenzima MB.
<i>CNN</i>	Red Neuronal Convolutiva (Convolutional Neural Network).
<i>cTnI</i>	Troponina Cardíaca I.
<i>cTnT</i>	Troponina Cardíaca T.
<i>DAI</i>	Descendente Anterior Izquierda.
<i>DANE</i>	Departamento Administrativo Nacional de Estadística.
<i>EAC</i>	Enfermedad Arterial Coronaria.
<i>ECG</i>	Electrocardiograma.
<i>ECV</i>	Enfermedades Cardiovasculares.
<i>ESC</i>	European Society of Cardiology.
<i>GNUS</i>	Aumento de datos mediante adición de ruido gaussiano (Gaussian Noise Upsampling).
<i>IA</i>	Inteligencia Artificial.
<i>IAM</i>	Infarto Agudo de Miocardio.
<i>IAMCEST</i>	Infarto Agudo de Miocardio con Elevación del Segmento ST.
<i>IAMSEST</i>	Infarto Agudo de Miocardio sin Elevación del Segmento ST.
<i>JSON</i>	Formato de intercambio de datos (JavaScript Object Notation).
<i>OMS</i>	Organización Mundial de la Salud.
<i>RWMA_s</i>	Regional Wall Motion Abnormalities.
<i>SCA</i>	Síndrome Coronario Agudo.
<i>SHAP</i>	Explicaciones aditivas de Shapley (SHapley Additive exPlanations).
<i>SMOTE</i>	Synthetic Minority Oversampling Technique.
<i>VI</i>	Ventrículo Izquierdo.
<i>VSCo_{de}</i>	Visual Studio Code.
<i>WHF</i>	World Heart Federation.

Resumen

El infarto agudo de miocardio es una de las principales causas de mortalidad a nivel mundial, con aproximadamente 3 millones de casos al año, siendo su variante con elevación del segmento ST una de las presentaciones más críticas. En Colombia, esta condición figura entre las principales causas de defunción, lo que resalta la necesidad de herramientas que mejoren la detección temprana y la precisión diagnóstica en entornos clínicos. Con el objetivo de brindar soporte diagnóstico a los profesionales de la salud, este trabajo desarrolló MyoAlert Vision, una aplicación web capaz de identificar patrones asociados a la enfermedad en registros de ECG de 12 derivaciones y estimar la localización anatómica del infarto (anterior, inferior, lateral o septal). El sistema integra modelos de aprendizaje automático XGBoost y CNN-1D, alcanzando precisiones del 93% y 91% en la detección del evento isquémico, y emplea LightGBM para la identificación de la zona afectada, con una precisión del 86%. Para esta última etapa, se incorporó un proceso previo que combinó un segundo modelo XGBoost con valores SHAP, con el fin de mejorar la interpretabilidad de los resultados y respaldar la asignación anatómica de las predicciones. En conjunto, estos resultados consolidan a MyoAlert Vision como un prototipo eficiente, que constituye un primer acercamiento al soporte diagnóstico asistido por inteligencia artificial en el infarto agudo de miocardio con elevación del segmento ST.

Palabras Clave: Infarto Agudo de Miocardio, Electrocardiograma, Procesamiento de señales, Aprendizaje automático, Aplicación web de diagnóstico

Abstract

Acute myocardial infarction is one of the leading causes of mortality worldwide, with approximately 3 million cases annually, and its ST-segment elevation variant being one of the most critical manifestations. In Colombia, this condition ranks among the main causes of death, underscoring the need for tools that enhance early detection and diagnostic accuracy in clinical settings. To provide diagnostic support to healthcare professionals, this work developed *MyoAlert Vision*, a web application capable of identifying disease-associated patterns in 12-lead ECG recordings and estimating the anatomical location of the infarction (anterior, inferior, lateral, or septal). The system integrates machine learning models such as XGBoost and CNN-1D, achieving accuracies of 93% and 91% in ischemic event detection, while LightGBM is employed for identifying the affected region, reaching an accuracy of 86%. For this latter stage, a preliminary process combining XGBoost with SHAP values was incorporated to enhance interpretability and support the anatomical assignment of predictions. Altogether, these results position *MyoAlert Vision* as an efficient prototype that represents an initial step toward AI-assisted diagnostic support in ST-segment elevation myocardial infarction.

Keywords: Acute Myocardial Infarction, Electrocardiogram, Signal processing, Machine learning, Diagnostic web application

Índice general

1. Introducción	1
2. Planteamiento del Problema	3
3. Justificación	6
4. Objetivos	9
4.1. Objetivo General	9
4.2. Objetivos Específicos	9
5. Marco de Referencia	10
5.1. Áreas Temáticas	10
5.2. Marco Teórico	10
5.2.1. Sistema cardiovascular	10
5.2.2. Infarto agudo de miocardio	11
5.2.3. Pruebas diagnósticas complementarias	13
5.2.4. Electrocardiograma	15
5.2.5. Procesamiento digital de señales	20
5.2.6. Extracción de características	24
5.2.7. Shapley Additive Explanations	28
5.2.8. Aprendizaje automático	29
5.2.9. Técnicas de aprendizaje automático	30
5.2.10. Técnicas de aumento de datos	31
5.2.11. Herramientas de desarrollo computacional	34
5.2.12. Entornos de desarrollo multiplataforma	35
5.3. Trabajos Relacionados	36
6. Materiales y Métodos	38
6.1. Etapa 1: Análisis y correlación electrocardiográfica del IAMCEST	40
6.1.1. Revisión de literatura sobre fisiopatología del IAMCEST	40
6.1.2. Entrevista con el asesor clínico especialista en cardiología	40
6.1.3. Sistematización de criterios diagnósticos y umbrales electrocardiográficos	41
6.1.4. Correlación anatómica y análisis de regiones miocárdicas	42
6.2. Etapa 2: Obtención y preprocesamiento de base de datos	42
6.2.1. Búsqueda de bases de datos de señales ECG	43
6.2.2. Selección y validación de base de datos	44
6.2.3. Visualización de las señales ECG	45
6.2.4. Preprocesamiento	46

6.3.	Etapa 3: Extracción de características de las señales ECG	51
6.3.1.	Implementación computacional y generación de la base de características	52
6.4.	Etapa 4: Entrenamiento de los modelos de aprendizaje automático	52
6.4.1.	Desarrollo de modelos de clasificación para la detección de IAMCEST	53
6.4.2.	Implementación del modelo de determinación de la localización anatómica del IAMCEST mediante valores SHAP	54
6.4.3.	Entrenamiento del modelo de clasificación por localización anatómica del infarto	59
6.5.	Etapa 5: Evaluación de modelos de aprendizaje automático	61
6.5.1.	Organización de los modelos entrenados para la implementación	61
6.5.2.	Evaluación de desempeño y métricas de clasificación	61
6.6.	Etapa 6: Desarrollo de la aplicación web	63
6.6.1.	Diseño de la arquitectura de la aplicación	63
6.6.2.	Integración con el backend y procesamiento de datos	64
7.	Resultados y Discusión	66
7.1.	Estructuración del conjunto de datos y publicación del código fuente en GitHub	66
7.2.	Evaluación del desempeño de los modelos de aprendizaje automático	67
7.2.1.	Modelo XGBoost	67
7.2.2.	Modelo CNN-1D	69
7.2.3.	Modelo LightGBM	72
7.3.	Implementación de la aplicación web	74
7.3.1.	Vistas de la aplicación	74
7.3.2.	Visualización anatómica del IAMCEST	76
7.3.3.	Interacción con la aplicación y generación de registros clínicos	76
7.4.	Evaluación de la aplicación web por un especialista en cardiología	79
8.	Conclusiones	80
9.	Trabajos futuros	81
10.	Anexos	83
Anexos		83
	Anexo 1 – Guía de códigos y recursos del proyecto MyoAlert Vision	83
	Anexo 2 – Manual de usuario de MyoAlert Vision	84
Bibliografía		97

Índice de figuras

5.1. Ilustración del Infarto Agudo de Miocardio	12
5.2. Ecocardiograma de un fumador hipertenso de 50 años que presentó un infarto de miocardio	14
5.3. Derivaciones periféricas	16
5.4. Derivaciones precordiales	17
5.5. Señal ECG	18
5.6. Esquema general del procesamiento digital de señales	20
5.7. Representación de los cuatro tipos de filtros. (a) Filtro paso bajo. (b) Filtro paso alto. (c) Filtro paso banda. (d) Filtro rechaza banda	22
6.1. Esquema general del proceso de detección y clasificación del IAMCEST	39
6.2. Señales ECG de la base de datos MIMIC-IV	46
6.3. Señales ECG de la derivada II antes y después del preprocesamiento	49
6.4. Representación unidimensional de señales ECG aplanadas para paciente normal y paciente con IAMCEST	50
6.5. Valores absolutos medios de SHAP por derivación del ECG	59
6.6. Esquema general de comunicación entre el frontend y el backend	64
7.1. Matriz de confusión del modelo XGBoost	68
7.2. Curva ROC del modelo XGBoost	69
7.3. Matriz de confusión del modelo CNN-1D	70
7.4. Evolución del loss (a) y de la exactitud (b) durante el entrenamiento y validación del modelo CNN-1D	71
7.5. Curva ROC del modelo CNN-1D	71
7.6. Matriz de confusión promedio del modelo LightGBM con la técnica GNUS	73
7.7. Matriz de confusión promedio del modelo LightGBM con la técnica SMOTE	74
7.8. Ventana principal de MyoAlert Vision con secciones delimitadas por colores	75
7.9. Representación esquemática de las regiones del corazón según la localización del Infarto Agudo de Miocardio con elevación del segmento ST (IAMCEST)	76
7.10. Diagrama de navegación de la aplicación Myoalert Vision	77
7.11. Ejemplo de reporte clínico generado por la aplicación MyoAlert Vision	78

Índice de tablas

5.1. Características electrocardiográficas organizadas según los dominios de análisis temporal, espectral y no lineal	25
6.1. Correlación entre la localización del IAMCEST y las derivaciones afectadas	42
6.2. Comparativa de bases de datos de señales ECG	43
6.3. Depuración de registros ECG no válidos en la extracción de características	51
6.4. Grupos de derivaciones y pares contiguos utilizados en la detección del IAMCEST	55
6.5. Resumen de las estrategias aplicadas para la determinación de la localización anatómica del IAMCEST	58
6.6. Distribución anatómica de los casos de IAMCEST identificados mediante valores SHAP	58
6.7. Distribución de registros por clase antes y después de las técnicas de aumento de datos	61
7.1. Métricas de desempeño del modelo XGBoost	68
7.2. Métricas de desempeño del modelo CNN-1D	70
7.3. Promedio de métricas de validación obtenidas con las técnicas GNUS y SMOTE	72

Introducción

Las enfermedades cardiovasculares (ECV) constituyen una preocupación de primer orden en el ámbito de la salud global, siendo responsables de una proporción significativa de la morbilidad y mortalidad a nivel mundial. Se estima que causan más de 17 millones de muertes anuales, lo que equivale a aproximadamente una de cada tres muertes en el mundo. Dentro de este grupo, el Infarto Agudo de Miocardio (IAM) se ha mantenido durante décadas como una de las principales causas de muerte, tanto a nivel global como en diversos países [1], [2]. En el caso de Colombia, las ECV figuran entre las primeras causas de mortalidad: solo en 2021, el IAM fue responsable de más de 12000 muertes, lo que subraya su impacto tanto en la población como en el sistema de salud nacional [3].

Dada la gravedad del IAM, resulta fundamental fortalecer las estrategias que permitan su detección temprana y precisa, especialmente en los casos de Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST). Esta forma crítica del IAM se caracteriza por una interrupción completa del flujo sanguíneo coronario, lo que conduce a isquemia y necrosis del tejido miocárdico. No obstante, la interpretación del electrocardiograma (ECG), aunque constituye una herramienta esencial para el diagnóstico inicial, puede resultar compleja, pues las alteraciones características del IAMCEST no siempre se presentan de forma evidente o pueden verse enmascaradas por otras condiciones clínicas. Esta dificultad incrementa el riesgo de diagnósticos erróneos o tardíos, ya que hasta un 30% de los casos pueden ser mal diagnosticados debido a una interpretación incorrecta del ECG, especialmente en presencia de variaciones anatómicas o patrones atípicos [4].

La aplicación de algoritmos de aprendizaje automático para la predicción del IAMCEST ha cobrado un notable impulso en los últimos años, aunque gran parte de estos enfoques se basa en el análisis de una única derivación del ECG, lo que limita significativamente la capacidad de detección precisa del infarto [5]. Esta limitación resalta la necesidad de adoptar un enfoque más integral, que contemple el análisis conjunto de las 12 derivaciones del ECG, aspecto fundamental para optimizar la identificación y detección temprana de la enfermedad.

En respuesta a esta necesidad, este trabajo de grado planteó el desarrollo de una herramienta computacional diseñada para identificar patrones en registros de ECG de 12 derivaciones asociados al IAMCEST, con el propósito de proporcionar un soporte diagnóstico eficiente a los profesionales de la salud. En este informe se describió el flujo de trabajo implementado, que abarca desde el pre-procesamiento de las señales y la extracción de características hasta la clasificación y la localización anatómica del infarto mediante técnicas de aprendizaje automático. Para ello, se implementaron dos

modelos independientes: una red neuronal convolucional unidimensional (CNN-1D) y un clasificador basado en XGBoost, ambos orientados a detectar la presencia o ausencia de infarto como paso previo a la localización anatómica del evento. Posteriormente, se incorporó un análisis basado en valores SHAP, el cual permitió identificar las derivaciones con mayor contribución a las predicciones y, a partir de ellas, establecer la localización anatómica del infarto mediante reglas de contigüidad entre derivaciones afectadas. Con las etiquetas generadas a partir de este análisis, se desarrolló un clasificador basado en LightGBM, orientado a determinar la zona anatómica comprometida, considerando las cuatro principales localizaciones afectadas en el IAMCEST: anterior, inferior, lateral y septal.

La evaluación del sistema se llevó a cabo utilizando la base de datos reestructurada, que incluyó registros de ECG normales y de pacientes con IAMCEST, garantizando un balance adecuado entre clases para el entrenamiento de los modelos. El desempeño de los clasificadores se analizó mediante métricas como precisión, recall, F1-score y exactitud global, apoyadas en matrices de confusión que permitieron examinar la capacidad del sistema para diferenciar entre las distintas regiones anatómicas afectadas. Adicionalmente, la herramienta se implementó en una aplicación web, denominada MyoAlert Vision, que proporciona un entorno funcional para la visualización de señales, interpretación automatizada de resultados y generación de reportes clínicos. La evaluación preliminar de la aplicación, incluida la opinión de un especialista en cardiología, permitió validar la utilidad y la pertinencia del sistema como soporte diagnóstico. Estos resultados no solo demuestran la efectividad de los modelos desarrollados, sino que también reflejan la viabilidad de integrar la inteligencia artificial en una plataforma práctica para el análisis del IAMCEST.

Planteamiento del Problema

Según datos de la Organización Mundial de la Salud (OMS), las enfermedades cardiovasculares representan la principal causa de muerte en el mundo, siendo responsables de aproximadamente 17.9 millones de fallecimientos en 2019, lo que equivale al 32 % de todas las muertes a nivel global. De estas defunciones, el 85 % se deben a dos eventos principales: infartos de miocardio y accidentes cerebrovasculares. De los 17 millones de muertes prematuras (menores de 70 años) asociadas a enfermedades no transmisibles en 2019, el 38 % son atribuibles a enfermedades cardiovasculares [6].

En Colombia, el infarto agudo de miocardio (IAM) ocupó el primer lugar en el boletín técnico de estadísticas vitales del DANE en 2022, como la principal causa de defunciones, con un total de 44703 fallecimientos. Esto representó el 15.7% de las defunciones en el país, afectando en mayor proporción a los hombres con el 53.6 % de los casos [7]. Por lo general, el diagnóstico de IAM se basa en la evaluación de los síntomas clínicos, el análisis de biomarcadores en sangre y la interpretación de electrocardiogramas. Sin embargo, estos métodos pueden no ser lo suficientemente específicos, y pueden requerir la intervención de personal altamente capacitado y tecnología avanzada, que no siempre están disponibles en todos los entornos clínicos. Esta combinación de factores contribuye a una alta tasa de mortalidad asociada al IAM, destacando la necesidad de explorar y desarrollar soluciones que mejoren la detección y control de la enfermedad.

En pacientes con sospecha de infarto agudo de miocardio (IAM), la evaluación inicial del médico se basa en una historia clínica detallada y un examen físico, con el objetivo de identificar signos y síntomas sugestivos que orienten el diagnóstico. Aunque la mayoría de los médicos reconocen las manifestaciones clásicas del IAM, como el dolor torácico subesternal prolongado, la disnea y la diaforesis, solo una minoría de los pacientes presenta este cuadro típico; por ello, es fundamental obtener un historial clínico completo que permita no solo determinar la causa del dolor torácico, sino también identificar enfermedades coexistentes que puedan influir en el manejo del paciente [8]. Además, los síntomas del IAM pueden manifestarse de diversas formas, ya que, si bien las señales de alerta más frecuentes incluyen presión en el pecho, mareos o desmayos con sudoración excesiva, dificultad para respirar, alteraciones en el ritmo cardíaco, debilidad sin causa aparente y dolor irradiado a la mandíbula o el cuello [9], en algunos casos pueden presentarse de manera atípica, lo que dificulta su reconocimiento oportuno. En consecuencia, dado que el dolor torácico es uno de los síntomas más representativos de la isquemia miocárdica, su presencia justifica la realización inmediata de un electrocardiograma (ECG) para confirmar o descartar un IAM. Por esta razón, independientemente de la variabilidad en la presentación clínica, el ECG sigue siendo una herramienta esencial en la evaluación inicial y en la toma de decisiones médicas [10].

Por otra parte, el análisis de biomarcadores en sangre es otra de las herramientas empleadas para la detección del IAM, ya que permite identificar la presencia de sustancias liberadas por el tejido cardíaco lesionado, como la troponina. Este método presenta varias desventajas que deben considerarse. En primer lugar, la sensibilidad y especificidad de los biomarcadores pueden ser limitadas en las etapas tempranas de la enfermedad, ya que algunos, como las troponinas, requieren tiempo para elevarse significativamente, lo cual puede retrasar la detección precoz. De hecho, biomarcadores como la troponina T (TnT) pueden presentar niveles elevados en pacientes con insuficiencia renal o infecciones sistémicas, generando falsos positivos y reduciendo la precisión diagnóstica. En segundo lugar, la efectividad de ciertos biomarcadores está estrechamente vinculada al tiempo transcurrido desde el inicio del evento; por ejemplo, la CK-MB resulta útil únicamente hasta las 72 horas posteriores al inicio del IAM, lo que implica la necesidad de monitoreos frecuentes para captar variaciones significativas en sus niveles [11]. A diferencia de otras herramientas diagnósticas, como el electrocardiograma o las imágenes cardíacas, que permiten identificar la región afectada, estos solo indican la presencia de lesión sin precisar su ubicación.

El ECG es la herramienta diagnóstica inicial más accesible y ampliamente utilizada para guiar el manejo en pacientes con sospecha de IAM, ya que permite una evaluación rápida y no invasiva de la actividad eléctrica del corazón [12]. Según los cambios observados en el trazado electrocardiográfico, el IAM se clasifica en dos tipos principales: con elevación del segmento ST (IAMCEST) y sin elevación del segmento ST (IAMSEST). En el IAMCEST, la arteria coronaria suele estar gravemente obstruida, lo que convierte al ECG en una herramienta clave para su diagnóstico, al permitir reconocer patrones específicos que indican la oclusión coronaria y favorecen una intervención inmediata. Por otro lado, el IAMSEST se asocia con una obstrucción parcial o una disminución significativa del flujo sanguíneo sin llegar a una oclusión completa, lo que puede generar una isquemia localizada en la parte interna del miocardio [13]. Sin embargo, este tipo de infarto suele presentar trazados electrocardiográficos poco característicos, lo que limita la capacidad del ECG para su identificación y hace necesario recurrir a biomarcadores como la troponina para su confirmación. En contraste, en el IAMCEST, la correcta interpretación del ECG no solo es crucial para su identificación, sino que puede marcar la diferencia en la rapidez y eficacia de la atención médica, lo que subraya la importancia de optimizar los métodos de análisis y mejorar la precisión diagnóstica basada en esta herramienta para este tipo de infartos [12].

A pesar de su importancia en el diagnóstico, el ECG es una de las pruebas con mayor dificultad para una interpretación precisa [14]. Esto se debe a varios desafíos, como la presencia de condiciones preexistentes que pueden enmascarar las anomalías típicas de un infarto, ya que pueden producir patrones de ECG irregulares que dificultan la identificación de los cambios en etapas tempranas del IAM. La prevalencia de condiciones preexistentes puede respaldarse por un estudio de cohorte a nivel nacional realizado en el Reino Unido, reportó datos de 693388 pacientes con IAM. En este estudio, se encontró que el 59.5% de los pacientes presentaba al menos una comorbilidad, siendo la hipertensión la más común, con una prevalencia del 48.7%, seguida de la diabetes, que afectaba al

19.4 % de los pacientes [15]. Otro aspecto que se enfrentan, son los problemas de baja calidad de las señales de ECG debido al ruido de alta frecuencia generado por la actividad muscular y al ruido de baja frecuencia causado por el movimiento del cuerpo y la respiración, lo que provoca complicaciones en los resultados del examen [16]. Sumado a esto, la interpretación del ECG realizada de manera manual representa un reto adicional, este tipo de evaluación requiere un alto nivel de experiencia y conocimiento especializado para reconocer patrones sutiles que indiquen problemas cardíacos.

Un estudio realizado por investigadores de la Clínica Mayo en Estados Unidos, en colaboración con universidades como Washington en San Luis, SUNY Upstate y el Sur de California, analizó los factores que afectan la competencia de los profesionales médicos en la interpretación del ECG. La investigación encuestó a 2515 participantes de distintas áreas de la salud, incluyendo cardiólogos en formación, médicos residentes, internos, estudiantes de medicina, enfermeros, técnicos en electrocardiografía y otros profesionales de salud aliados. Se encontró que el 79 % de ellos reportó que la interpretación del ECG formaba parte de su práctica clínica habitual. Sin embargo, un 45 % expresó sentirse incómodo al realizar esta tarea de manera independiente, lo que evidencia la complejidad que implica un análisis preciso del trazado electrocardiográfico. Además, el estudio reveló que el 87 % de los encuestados tenía supervisión limitada o inexistente de expertos en interpretación de ECG, lo que resalta la necesidad de contar con mecanismos de apoyo o sistemas que faciliten la verificación y validación de los diagnósticos. A pesar de estas dificultades, el 98 % de los participantes manifestó interés en disponer de más herramientas y recursos para mejorar su desempeño en la interpretación del ECG. Estos hallazgos destacan la importancia de complementar la práctica clínica con sistemas de soporte que permitan reducir la incertidumbre y mejorar la precisión diagnóstica, especialmente en condiciones críticas como el IAMCEST. Dado que el diagnóstico oportuno de esta patología es crucial para mejorar los resultados clínicos, el acceso a asesoramiento experto o una tecnología de apoyo podría representar una estrategia clave para optimizar el uso del ECG en la toma de decisiones médicas [17]. Por lo tanto, este proyecto busca desarrollar una herramienta de soporte clínico que optimice la interpretación del ECG y reduzca la incertidumbre diagnóstica en el IAMCEST.

Justificación

En las últimas décadas, el pronóstico del infarto agudo de miocardio (IAM) ha mejorado considerablemente, en gran parte debido a los avances en la terapia médica y la implementación de una atención estandarizada [18]. Sin embargo, a pesar de esta evolución positiva en el tratamiento inmediato, las tasas de mortalidad y recurrencia a largo plazo siguen siendo preocupantes, especialmente en pacientes que han presentado un IAMCEST, la manifestación más grave de la enfermedad coronaria, caracterizada por una oclusión coronaria completa y sostenida que provoca una interrupción abrupta del flujo sanguíneo al miocardio [19]. Esta obstrucción desencadena una cascada isquémica, un proceso progresivo que compromete la viabilidad de los cardiomiocitos debido a la privación de oxígeno y nutrientes. Si no se interviene a tiempo, la función de bombeo del corazón se ve gravemente afectada, lo que puede llevar a la muerte.

Entre los años 2010 y 2021, la mortalidad por Infarto Agudo de Miocardio (IAM) en Colombia ha mostrado un incremento progresivo, especialmente acentuada en los años 2020 y 2021. Durante este periodo, el IAM se posicionó entre las cinco principales causas de muerte en el país. A partir de las tasas de mortalidad reportadas por el Ministerio de Salud y Protección Social, expresadas por cada 100000 habitantes y utilizando las proyecciones poblacionales, se estimó que aproximadamente 400000 personas fallecieron por esta causa [20]. Esta evolución en los registros de mortalidad no solo refleja la magnitud del impacto del IAM en la salud pública nacional, sino que también resalta la necesidad urgente de fortalecer las estrategias de detección y prevención oportuna. En este contexto, el desarrollo de algoritmos de aprendizaje automático se perfila como una herramienta clave para transformar la atención de eventos cardiovasculares agudos, optimizando el diagnóstico, reduciendo los tiempos de respuesta y mejorando el pronóstico de los pacientes. Al actuar como un respaldo adicional para los especialistas, no solo se incrementa la confianza en las decisiones clínicas, sino que también se minimiza el riesgo de diagnósticos incorrectos, abriendo así nuevas oportunidades para la mejora de los cuidados de salud.

Estudios previos han evidenciado el papel crucial del electrocardiograma estándar en el diagnóstico del infarto agudo de miocardio, especialmente en variantes como el infarto del ventrículo derecho. En estos casos, alteraciones específicas del segmento ST permiten no solo identificar la presencia del evento isquémico, sino también localizar con precisión la oclusión coronaria y estimar la extensión del daño miocárdico [21]. En línea con estos avances, la inteligencia artificial ha emergido como un recurso prometedor en electrocardiografía, ampliando considerablemente sus capacidades diagnósticas. La aplicación de algoritmos de IA ha demostrado mejorar significativamente la detección de anomalías como arritmias, elevación del segmento ST o prolongación del intervalo QT, al

tiempo que permite una interpretación más ágil, precisa y continua del ECG, incluso en contextos ambulatorios o mediante dispositivos portátiles [22]. Esta capacidad de procesar grandes volúmenes de datos en tiempo real, identificar patrones invisibles al ojo humano y optimizar la respuesta clínica, posiciona a la IA como un diferenciador clave en el desarrollo de herramientas de soporte diagnóstico que superen las limitaciones de la interpretación convencional.

Dado el contexto clínico y la creciente necesidad de herramientas diagnósticas automatizadas [23], el presente proyecto propone el desarrollo de un prototipo de herramienta computacional de soporte diagnóstico basada en inteligencia artificial, orientada específicamente al análisis automatizado de señales electrocardiográficas en pacientes con sospecha de infarto agudo de miocardio con elevación del segmento ST (IAMCEST). A través de la implementación de algoritmos de aprendizaje automático, el sistema estará capacitado para procesar señales ECG en tiempo real, identificar patrones característicos del IAMCEST, determinar las derivaciones comprometidas, localizar la región miocárdica afectada y emitir alertas o interpretaciones diagnósticas que sirvan como apoyo complementario en la toma de decisiones clínicas.

Desde el enfoque actual, las herramientas de estratificación de riesgo son frecuentemente empleadas en la evaluación pronóstica de pacientes con IAM. Sin embargo, estas presentan limitaciones sustanciales debido a su dependencia de variables clínicas estáticas, la utilización de enfoques lineales y la necesidad de interpretación manual, lo cual restringe su eficacia frente a la creciente complejidad de los entornos clínicos contemporáneos [24]. Su baja capacidad para capturar relaciones no lineales e interacciones complejas entre variables compromete su aplicabilidad en escenarios de alta variabilidad y exige herramientas más robustas y adaptativas [25].

En respuesta a la creciente demanda de precisión y adaptabilidad en el análisis clínico, los algoritmos de aprendizaje automático emergen como una solución tecnológica avanzada y altamente adaptable. Su habilidad para procesar grandes volúmenes de datos multidimensionales, identificar patrones no evidentes al ojo humano y generar predicciones precisas en tiempo real los convierte en componentes clave dentro de los sistemas modernos de soporte clínico [26]. Particularmente en el manejo del IAMCEST, estas metodologías permiten una identificación precoz y más precisa de pacientes en riesgo, mejorando significativamente la eficiencia en la toma de decisiones médicas y optimizando el uso de los recursos en unidades de cardiología [27]. Es importante destacar que la intención de esta implementación no es reemplazar al especialista, sino potenciar su capacidad diagnóstica mediante un sistema inteligente que disminuya los errores, aumente la sensibilidad clínica y contribuya a una atención más oportuna y efectiva.

Para la fase de entrenamiento del modelo, se utilizarán una base de datos abiertas que contengan registros de ECG validados, tanto normales como correspondientes a eventos confirmados de la patología a tratar. Esta estrategia permitirá construir un conjunto de datos representativo y balanceado, alineado con la variabilidad electrofisiológica observada en entornos clínicos reales [28]. Asimismo, se priorizará el uso de datos provenientes de contextos hospitalarios, debidamente eti-

quetados, lo que garantizará la calidad del entrenamiento y una mayor capacidad de generalización del sistema. Se implementarán también criterios estandarizados para la anotación de características relevantes, como las alteraciones del segmento ST, asegurando la consistencia y precisión del proceso de etiquetado.

El sistema resultante está concebido como una herramienta de apoyo para la toma de decisiones médicas en el ámbito de la cardiología clínica, desempeñando funciones como segunda opinión diagnóstica o integrándose dentro de un flujo de trabajo automatizado ante la sospecha de un IAM. Su principal objetivo es optimizar los tiempos de respuesta del equipo médico y facilitar un diagnóstico más ágil y preciso en situaciones críticas. En el momento en que se le entregue un electrocardiograma, el sistema procesará de manera automática la señal y analizará en tiempo real los patrones eléctricos del corazón, emitiendo alertas tempranas si detecta signos compatibles con eventos isquémicos agudos. Esto permitirá al personal clínico identificar de forma oportuna alteraciones relevantes, reduciendo significativamente el riesgo de omisiones diagnósticas o interpretaciones subjetivas.

Esta solución tecnológica representa un paso firme hacia una medicina más precisa, predictiva y basada en evidencia cuantificable. Fortalece el criterio clínico en escenarios de alta exigencia y se convierte en un aliado estratégico en la atención de urgencias cardiovasculares. En definitiva, este proyecto busca cerrar la brecha entre el diagnóstico tradicional y las capacidades del análisis computacional moderno, dotando a los profesionales de herramientas que potencien su capacidad diagnóstica y mejoren los estándares de calidad y seguridad en el manejo de una de las principales causas de mortalidad cardiovascular.

Objetivos

4.1. Objetivo General

Desarrollar una herramienta computacional de soporte al diagnóstico clínico que permita la detección de patrones electrocardiográficos asociados al Infarto Agudo de Miocardio con elevación del segmento ST (IAMCEST), utilizando algoritmos de aprendizaje automático.

4.2. Objetivos Específicos

1. Analizar la fisiopatología del Infarto Agudo de Miocardio con elevación del segmento ST (IAMCEST), identificando las zonas del corazón afectadas y su relación con las distintas derivaciones del electrocardiograma (ECG).
2. Estructurar una base de datos a partir de fuentes públicas que contenga registros de señales ECG correspondientes a pacientes con trazos normales y pacientes diagnosticados con Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), con el fin de facilitar su análisis y procesamiento posterior.
3. Extraer las características relevantes de los registros de ECG para el mejoramiento del desempeño de los algoritmos de aprendizaje automático en la detección del IAMCEST.
4. Entrenar modelos de aprendizaje automático supervisado a partir de las características extraídas de los registros de ECG para la identificación del IAMCEST.
5. Evaluar el rendimiento de los modelos entrenados para la identificación del IAMCEST mediante métricas de desempeño.

Marco de Referencia

5.1. Áreas Temáticas

De acuerdo con la taxonomía IEEE (IEEE Taxonomy: A Subset Hierarchical Display of IEEE Thesaurus Terms), las áreas temáticas asociadas al trabajo de grado son:

- Engineering in medicine and biology - Cardiology - Cardiac tissue.
- Engineering in medicine and biology - Cardiography - Electrocardiography.
- Engineering in medicine and biology - Biomedical engineering - Biomedical signal processing.
- Computational and artificial intelligence - Artificial intelligence - Machine learning.
- Computational and artificial intelligence - Artificial intelligence - Deep learning.
- Computers and information processing - Software - Application software.

5.2. Marco Teórico

5.2.1. Sistema cardiovascular

Uno de los sistemas vitales del cuerpo humano es el sistema cardiovascular. Es responsable de la circulación de la sangre a través del cuerpo, cuya función principal es transportar oxígeno, nutrientes y hormonas a los tejidos, al tiempo que elimina los productos de desecho generados por el metabolismo celular [29]. Este sistema está compuesto por el corazón, las arterias, las venas y los capilares, que trabajan de manera coordinada para mantener un flujo sanguíneo eficiente. La sangre circula en dos circuitos: la circulación pulmonar, donde la sangre desoxigenada es enviada a los pulmones para oxigenarse, y la circulación sistémica, que distribuye la sangre oxigenada al resto del cuerpo. El intercambio de gases y nutrientes ocurre en los capilares, y la sangre regresa al corazón a través de las venas [30].

- **El corazón:** El corazón es un órgano muscular responsable de bombear sangre a través de los vasos sanguíneos mediante contracciones repetidas y rítmicas. Este proceso asegura la circulación continua de la sangre por todo el cuerpo, permitiendo el transporte de oxígeno, nutrientes y la eliminación de desechos metabólicos [31].

- **Vasos sanguíneos:** Los vasos sanguíneos constituyen una red tubular que permite la circulación continua de la sangre a lo largo de todo el organismo. De acuerdo con su estructura y función, se clasifican en:
 - **Arterias:** Las arterias son vasos sanguíneos encargados de transportar la sangre desde el corazón hacia los diferentes tejidos del cuerpo. La sangre fluye a través de las arterias debido a la presión generada por las contracciones del corazón. La mayoría de las arterias transportan sangre oxigenada, a excepción de la arteria pulmonar, que lleva sangre desoxigenada hacia los pulmones para su oxigenación.
 - **Venas:** Las venas son vasos sanguíneos encargados de transportar la sangre de vuelta al corazón. A diferencia de las arterias, la sangre en las venas no está sometida a la misma presión generada por el bombeo del corazón. El flujo sanguíneo en las venas se ve asistido por la contracción de los músculos esqueléticos y las válvulas venosas, que impiden el reflujo de sangre. Aunque la mayoría de las venas transportan sangre desoxigenada, existen excepciones como las venas pulmonares, que llevan sangre oxigenada desde los pulmones hacia el corazón.
 - **Capilares:** Los capilares son los vasos sanguíneos más pequeños y delgados del sistema cardiovascular, y son esenciales para el intercambio de oxígeno, nutrientes, dióxido de carbono y desechos entre la sangre y los tejidos. Estos vasos están distribuidos por todo el cuerpo en una extensa red, denominada lecho capilar, lo que permite un gran área de intercambio [32].

5.2.2. Infarto agudo de miocardio

El infarto agudo de miocardio (IAM) es un síndrome coronario agudo caracterizado por la aparición súbita de un cuadro de sufrimiento isquémico (falta de irrigación) en una parte del músculo cardíaco, causado por la obstrucción aguda y total de una de las arterias coronarias que lo alimentan [33]. Esta obstrucción coronaria, característica del IAM, suele originarse por la ruptura de una placa aterosclerótica, una estructura compuesta por colesterol, lípidos, restos celulares, células inflamatorias y músculo liso que se acumula lentamente en la capa íntima de las arterias coronarias. Con el paso del tiempo, esta placa puede volverse inestable, especialmente cuando presenta una delgada cubierta fibrosa, y ante estímulos inflamatorios, puede desgarrarse. Esta ruptura expone el núcleo lipídico altamente trombogénico al flujo sanguíneo, desencadenando una rápida respuesta hemostática del organismo. En consecuencia, se forma un trombo (coágulo) en el interior de la arteria, el cual puede crecer progresivamente hasta bloquear total o parcialmente el flujo de sangre hacia el miocardio. Esta interrupción súbita del flujo coronario priva al tejido cardíaco de oxígeno y nutrientes, dando lugar a isquemia y posterior necrosis del músculo cardíaco si no se revierte a tiempo [34]. Como se muestra en la Figura 5.1, la obstrucción de las arterias coronarias, causada por la ruptura de una placa aterosclerótica, puede comprometer el flujo sanguíneo y desencadenar un infarto agudo de miocardio.




Figura 5.1: Ilustración del Infarto Agudo de Miocardio (Fuente: [35])

Según su mecanismo fisiopatológico, el IAM se clasifica en cinco categorías. La primera corresponde a un evento espontáneo, vinculado a procesos coronarios primarios como la ruptura o erosión de una placa aterosclerótica, lo que desencadena la formación de un trombo e induce isquemia miocárdica. La segunda se origina por un desequilibrio entre el aporte y la demanda de oxígeno en el tejido miocárdico, sin evidencia de ruptura de placa, y puede estar asociada a condiciones como arritmias, anemia, espasmo coronario o hipertensión severa. La tercera categoría abarca los casos de muerte súbita de origen cardíaco, en los que no se alcanzan a documentar biomarcadores, pero existen indicios clínicos que sugieren un infarto. La cuarta está relacionada con procedimientos invasivos; se subdivide en 4a, asociado a la intervención coronaria percutánea, y 4b, vinculado a la trombosis de un stent previamente implantado. La quinta y última categoría se refiere a infartos ocurridos en el contexto de una cirugía de revascularización coronaria mediante injerto (bypass). Diversos factores contribuyen al desarrollo y la progresión de los mecanismos que originan cada tipo de IAM. Entre los principales se encuentra el tabaquismo, la hipertensión, la diabetes, la dislipidemia, la obesidad y el síndrome metabólico. Estas condiciones favorecen el desarrollo y desestabilización de placas ateroscleróticas. Además, el estrés crónico y el consumo excesivo de alcohol pueden potenciar la respuesta inflamatoria sistémica, incrementando la probabilidad de ruptura de la placa [36].

Los síntomas típicos del IAM incluyen dolor opresivo en el pecho que puede irradiarse hacia el brazo izquierdo, el cuello, la mandíbula o la espalda, acompañado de dificultad para respirar, sudoración excesiva, náuseas y palpitaciones. Sin embargo, en algunos casos, especialmente en personas con diabetes, el IAM puede ser "silente", es decir, no presentar síntomas claros, lo que dificulta su diagnóstico precoz [37].

En cuanto a la extensión del infarto, se pueden clasificar en dos tipos principales: infartos transmurales y infartos no transmurales. Los infartos transmurales afectan todo el grosor del miocardio y se caracterizan por la presencia de ondas Q anormales en el ECG, lo que indica necrosis extensa del tejido cardíaco. Por otro lado, los infartos no transmurales suelen limitarse al tercio interno del miocardio y se manifiestan con anomalías en los segmentos ST y T del electrocardiograma.

Clínicamente, el IAM se clasifica en dos tipos principales, según la presencia o ausencia de elevación del segmento ST:

- **IAMCEST (Infarto Agudo de Miocardio con Elevación del Segmento ST):** Este tipo de infarto ocurre por la oclusión de una o más arterias coronarias, lo que causa isquemia transmural y necrosis del tejido miocárdico. Suele deberse a la rotura de una placa aterosclerótica y la formación de un trombo. Se diagnostica por la elevación del segmento ST en el electrocardiograma. El tratamiento inmediato incluye terapia de reperfusión, generalmente mediante intervención coronaria percutánea, junto con el uso de antiagregantes y anticoagulantes para prevenir nuevos eventos trombóticos.
- **IAMSEST (Infarto Agudo de Miocardio sin Elevación del Segmento ST):** En este caso, aunque hay elevación de los biomarcadores cardíacos (como la troponina), el segmento ST no muestra elevación en el electrocardiograma. Esto indica que el infarto es menos extenso que en el IAMCEST, pero aún así se observa daño al miocardio debido a la interrupción parcial del flujo sanguíneo. Este tipo de infarto suele requerir un tratamiento con medicamentos anticoagulantes y, en algunos casos, intervención quirúrgica.

El diagnóstico temprano y adecuado del Infarto Agudo de Miocardio (IAM), especialmente de sus variantes con elevación del segmento ST (IAMCEST) y sin elevación del segmento ST (IAMSEST), es crucial para la supervivencia del paciente. Mientras que el IAMCEST representa una forma grave que requiere atención urgente para restaurar el flujo sanguíneo, el IAMSEST, aunque igualmente serio, puede tratarse mediante intervenciones menos invasivas, según la extensión del daño miocárdico [38], [39].

5.2.3. Pruebas diagnósticas complementarias

Para la detección del IAM, se emplean diversas pruebas complementarias que permiten evaluar con mayor precisión el estado funcional y estructural del corazón. Entre ellas destacan la medición de biomarcadores cardíacos en sangre, como las troponinas, el ecocardiograma para visualizar alteraciones en la contractilidad miocárdica, y las pruebas de esfuerzo, que ayudan a identificar isquemia inducida durante la actividad física controlada.

5.2.3.1. Biomarcadores cardíacos

Los biomarcadores cardíacos son sustancias liberadas en el torrente sanguíneo como consecuencia del daño al tejido miocárdico. Su detección es fundamental para el diagnóstico de condiciones como el síndrome coronario agudo (SCA) y la isquemia cardíaca, patologías asociadas a un suministro inadecuado de sangre al músculo cardíaco. Además de su utilidad diagnóstica, estos marcadores permiten estratificar el riesgo de eventos cardiovasculares futuros y resultan valiosos en el seguimiento clínico y la evaluación de la evolución de la enfermedad a lo largo del tiempo [40].

A continuación, se detallan los biomarcadores de mayor relevancia clínica:

- **Troponina:** Es el biomarcador más específico y sensible para el diagnóstico de infarto de miocardio (IM). Las isoformas cTnI y cTnT se liberan ante daño miocárdico, detectando incluso lesiones mínimas. Permanece elevada hasta por dos semanas, facilitando el seguimiento. Sin embargo, también puede aumentar en otras patologías como la insuficiencia cardíaca [41].
- **Creatina Quinasa (CK-MB):** Isoenzima específica del tejido cardíaco que se eleva rápidamente tras un infarto. Su especificidad es menor que la de la troponina, ya que puede elevarse por causas no cardíacas como traumatismos musculares. Se utiliza en conjunto con troponina y ECG para mejorar el diagnóstico [41].

5.2.3.2. Ecocardiografía

La ecocardiografía, como técnica no invasiva y de alta precisión, constituye una herramienta complementaria en la evaluación del infarto agudo de miocardio, especialmente útil cuando el electrocardiograma (ECG) no proporciona información concluyente o los síntomas clínicos son atípicos. Permite una valoración en tiempo real de la función cardíaca y resulta eficaz en la detección de disfunciones miocárdicas inducidas por isquemia o necrosis. Su capacidad para visualizar anomalías regionales del movimiento de la pared (RWMA) es crítica, ya que estas pueden manifestarse segundos después de la oclusión de una arteria coronaria, incluso antes de que se evidencien cambios electrocardiográficos [42]. En la Figura 5.2, se observa un ecocardiograma que evidencia acinesia en el territorio de la arteria descendente anterior izquierda (DAI) y disfunción severa del ventrículo izquierdo (VI), hallazgos que reflejan un compromiso miocárdico extenso. Además, la ecocardiografía contribuye a la estratificación de riesgo, la identificación de complicaciones mecánicas y el monitoreo hemodinámico, ofreciendo así una evaluación integral del paciente cuando el diagnóstico inicial no es claro o se requiere mayor caracterización del daño miocárdico.




Figura 5.2: Ecocardiograma de un fumador hipertenso de 50 años que presentó un infarto de miocardio (Fuente: [43])

5.2.3.3. Pruebas de estrés cardíaco:

La prueba de esfuerzo, o prueba de estrés cardíaco, es una herramienta diagnóstica fundamental para evaluar la respuesta del corazón ante un aumento de la demanda, permitiendo detectar zonas isquémicas en riesgo de IAM. Se realiza mediante ejercicio físico o con fármacos que inducen estrés cardiovascular, y suele ir acompañada de monitoreo electrocardiográfico y, en algunos casos, técnicas de imagen. Durante el esfuerzo, el flujo coronario puede volverse insuficiente en pacientes con enfermedad arterial coronaria (EAC), revelando posibles áreas de isquemia. El método preferido es el ejercicio físico, comúnmente bajo el protocolo de Bruce, aunque en pacientes con limitaciones físicas se opta por estrés farmacológico usando agentes como adenosina, o dobutamina, cada uno con mecanismos y efectos específicos.

Aunque menos invasiva que el cateterismo, esta prueba tiene limitaciones, especialmente en pacientes con baja probabilidad de EAC o en presencia de placas no significativas que podrían romperse. Es útil en el diagnóstico, estratificación de riesgo y seguimiento de pacientes con enfermedad coronaria. Presenta riesgos bajos, pero no nulos, y está contraindicada en casos como síndrome coronario agudo reciente o arritmias inestables [44].

5.2.4. Electrocardiograma

El electrocardiograma (ECG) es una herramienta diagnóstica esencial en cardiología, utilizada para registrar la actividad eléctrica del corazón desde múltiples perspectivas anatómicas. Este procedimiento se lleva a cabo mediante la colocación de 10 electrodos en ubicaciones estratégicas del cuerpo, lo que permite obtener 12 derivaciones estándar. Estas derivaciones proporcionan diferentes perspectivas del corazón, facilitando un análisis detallado de la despolarización y repolarización del músculo cardíaco en diferentes regiones. Gracias a esta configuración, el ECG permite detectar de manera precisa alteraciones en la conducción eléctrica que pueden reflejar condiciones como arritmias, isquemia miocárdica, infarto agudo de miocardio, hipertrofias ventriculares, entre otras patologías [45].

Las derivaciones utilizadas en el registro de la actividad eléctrica del corazón se organizan en dos conjuntos principales: las derivaciones periféricas y las precordiales. Como se puede ver en la Figura 5.3 se identifica la ubicación y orientación de estas derivaciones periféricas, donde se incluyen tres derivaciones bipolares y tres unipolares, las cuales capturan la actividad eléctrica del corazón desde diversas perspectivas en el plano frontal.

Las derivaciones bipolares estándar, denominadas I, II y III, registran diferencias de potencial eléctrico entre dos electrodos activos ubicados en las extremidades. La derivación I evalúa la diferencia de potencial entre el brazo derecho y el brazo izquierdo; la derivación II, entre el brazo derecho y la pierna izquierda; y la derivación III, entre el brazo izquierdo y la pierna izquierda. Estas tres derivaciones conforman el triángulo de Einthoven, una disposición geométrica que permite analizar la actividad eléctrica cardíaca desde distintas orientaciones dentro del plano frontal. En contraste,

las derivaciones unipolares de las extremidades aVR, aVL y aVF utilizan un electrodo explorador positivo ubicado en una extremidad específica (brazo derecho, brazo o pierna izquierdos, respectivamente), mientras que el terminal negativo se construye como una referencia común generada por la suma promedio de los potenciales de los otros dos electrodos. Este sistema permite obtener vectores eléctricos orientados hacia regiones específicas del corazón, complementando el análisis espacial brindado por las derivaciones bipolares y proporcionando una representación más detallada del eje eléctrico cardíaco [46].

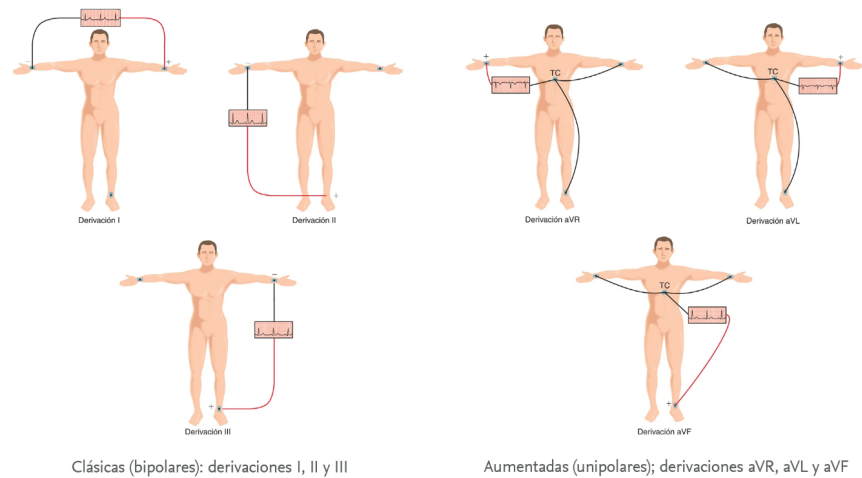


Figura 5.3: Derivaciones periféricas (Fuente: [47])

Complementando las derivaciones periféricas, las derivaciones precordiales se obtienen mediante la colocación de seis electrodos en la región torácica, cerca del corazón, y se identifican como V1 a V6. Estas derivaciones permiten registrar la actividad eléctrica en el plano horizontal, proporcionando una visión detallada de las regiones anterior, septal y lateral del miocardio. La colocación de los electrodos sigue un protocolo estandarizado, como se muestra en la Figura 5.4: V1 se posiciona en el cuarto espacio intercostal, justo a la derecha del esternón; V2, en el cuarto espacio intercostal a la izquierda del esternón; V3 se ubica equidistante entre V2 y V4; V4 se localiza en el quinto espacio intercostal, sobre la línea medio clavicular izquierda; V5 se coloca al nivel de V4, sobre la línea axilar anterior; y V6, también al nivel de V4 y V5, sobre la línea axilar media [46]. Esta disposición anatómica estandarizada es esencial para una correcta adquisición del ECG, ya que garantiza la fidelidad de las señales obtenidas y facilita la identificación precisa de alteraciones eléctricas propias de diversas patologías cardíacas.

En cada derivación del ECG se representan las ondas, segmentos e intervalos que reflejan los eventos eléctricos fundamentales del corazón. Estas señales permiten analizar con detalle dos procesos esenciales en la fisiología cardíaca: la despolarización y la repolarización. La despolarización, que precede a la contracción muscular, se inicia en los atrios, provocando su contracción y facilitando el paso de sangre hacia los ventrículos. Este paso es crítico para asegurar un llenado ventricular eficaz

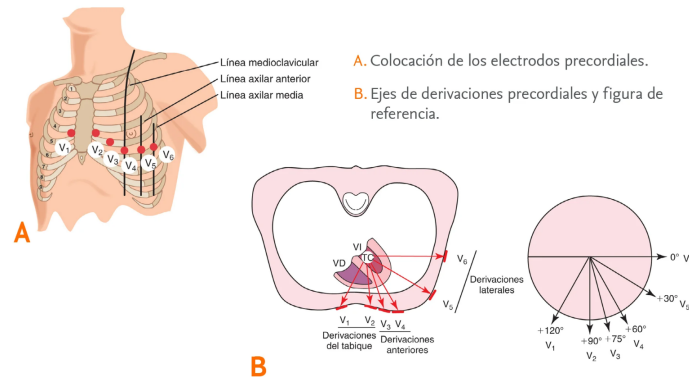


Figura 5.4: Derivaciones precordiales (Fuente: [47])

antes de la sístole. Posteriormente, tiene lugar la repolarización, proceso que indica el retorno de las células miocárdicas a su estado de reposo, permitiendo la relajación ventricular y el adecuado llenado diastólico. La lectura de los segmentos e intervalos del ECG, como el intervalo PR y el segmento ST, aporta información clave sobre la duración y sincronización de estos procesos eléctricos, ayudando a detectar anomalías en la conducción o en la recuperación del tejido miocárdico [48].

Según Sattar y Chhabra [49], la interpretación de la señal de electrocardiograma debe realizarse de manera sistemática, lo que implica una identificación clara de sus ondas y segmentos:

- **Onda P:** Representa la despolarización de las aurículas, es decir, la contracción de las cámaras superiores del corazón. Normalmente, es una onda pequeña y redondeada, aunque su forma y duración pueden variar ligeramente entre individuos. Una onda P anormal o ausente puede ser indicativa de problemas en la conducción eléctrica de las aurículas, como en casos de bloqueo auriculoventricular (AV) o agrandamiento auricular. La onda P también puede reflejar trastornos del ritmo, como la fibrilación auricular.
- **Intervalo PR:** Este intervalo mide el tiempo entre el inicio de la despolarización auricular (onda P) y el inicio de la despolarización ventricular (complejo QRS). Representa el tiempo que tarda el impulso eléctrico en viajar desde las aurículas a los ventrículos, pasando por el nodo AV y el Haz de His. Un intervalo PR prolongado puede indicar un bloqueo AV de primer grado, mientras que un intervalo PR corto puede estar relacionado con trastornos como el síndrome de preexcitación.
- **Complejo QRS:** Representa la despolarización de los ventrículos, es decir, la contracción de las cámaras inferiores del corazón. El complejo QRS es el componente más prominente del ECG y está compuesto por las ondas Q, R y S. Un complejo QRS ancho o prolongado puede ser un indicio de bloqueo de rama, hipertrofia o arritmias ventriculares.
 - **Onda Q:** Es la primera deflexión negativa del complejo QRS, aunque no siempre está presente. Su presencia indica una despolarización interventricular.

- **Onda R:** Es la primera deflexión positiva tras la onda Q, y generalmente es la más prominente del complejo QRS.
 - **Onda S:** Es la deflexión negativa que sigue a la onda R.
- **Segmento ST:** Conecta el final del complejo QRS con el inicio de la onda T. Este segmento representa el período entre el final de la despolarización ventricular y el inicio de la repolarización ventricular. El segmento ST es crucial para la identificación de isquemia y lesiones miocárdicas. Un segmento ST elevado o deprimido puede ser un signo temprano de un infarto de miocardio o de una angina de pecho inestable.
 - **Onda T:** Representa la repolarización de los ventrículos, es decir, la fase en que los ventrículos se preparan para el próximo ciclo de contracción. La onda T normalmente tiene una deflexión positiva, pero puede ser invertida o anormal en casos de isquemia, infarto o alteraciones en los electrolitos. Además, la amplitud y forma de la onda T pueden variar dependiendo de la derivación y el estado clínico del paciente.




Figura 5.5: Señal ECG (Fuente: [50])

En la interpretación de un electrocardiograma (ECG) normal, la actividad eléctrica del corazón se presenta de manera organizada y armónica, reflejada en las ondas características del trazado. La frecuencia cardíaca oscila entre 60 y 100 latidos por minuto, y los intervalos entre las ondas P y los complejos QRS son regulares, lo que indica un ritmo constante. La onda P, que representa la despolarización de las aurículas, tiene una forma suave y redondeada, y siempre aparece antes de cada complejo QRS, lo que muestra que la conducción auriculoventricular es adecuada. El complejo QRS, asociado a la despolarización ventricular, tiene una forma estrecha y puntiaguda, lo que refleja una conducción rápida y sincronizada. La onda T, que señala la repolarización ventricular, generalmente es redondeada y está orientada en la misma dirección que el complejo QRS. Finalmente, el segmento ST permanece alineado con la línea base, sin elevaciones ni depresiones, lo que indica una oxigenación miocárdica adecuada.

Por otro lado, un ECG anormal puede mostrar alteraciones en la forma, el tamaño o la disposición de las ondas, lo que puede estar relacionado con diversas condiciones cardíacas. La frecuencia puede ser anormal, como en la taquicardia, donde la distancia entre las ondas es más corta debido a una frecuencia superior a 100 latidos por minuto, o en la bradicardia, donde los latidos son más espaciados y la frecuencia es inferior a 60. El ritmo también puede volverse irregular, con intervalos variables entre las ondas P o los complejos QRS, lo que sugiere arritmias o problemas en la conducción. Las ondas P pueden faltar, deformarse, o aparecer más grandes de lo normal, lo que puede señalar alteraciones auriculares o trastornos del nodo sinusal. El complejo QRS podría aparecer ensanchado o fragmentado, indicando bloqueos de rama, hipertrofias o daños en el músculo cardíaco. La onda T podría invertirse, volverse puntiaguda o aplanada, lo que puede ser señal de isquemia o alteraciones en los electrolitos. Finalmente, el segmento ST podría elevarse o deprimirse, lo que es particularmente relevante en el diagnóstico de infarto agudo de miocardio o síndromes coronarios agudos [51].

Los patrones electrocardiográficos específicos, como la elevación del segmento ST, la inversión de la onda T y las ondas Q patológicas, son indicativos clave de la presencia y la extensión del infarto agudo de miocardio (IAM). Estos hallazgos reflejan alteraciones en la conducción eléctrica cardíaca provocadas por la isquemia o necrosis del miocardio [52], [53].

- **Elevación del segmento ST:** La elevación del segmento ST es uno de los hallazgos electrocardiográficos más distintivos en el IAM. Este patrón refleja una oclusión completa de una arteria coronaria principal, lo que resulta en una isquemia severa y una lesión transmural del miocardio. La elevación del segmento ST indica un desequilibrio entre el suministro y la demanda de oxígeno en el tejido cardíaco. Si no se restablece la perfusión coronaria de manera oportuna, puede evolucionar hacia una necrosis miocárdica irreversible. La presencia de esta elevación en el ECG es fundamental para el diagnóstico temprano del IAM, lo que posibilita la implementación inmediata de estrategias terapéuticas, como trombólisis o angioplastia primaria, mejorando el pronóstico y la viabilidad del miocardio afectado.
- **Inversión de la onda T:** La inversión de la onda T constituye un hallazgo relevante en el ECG, sugiriendo la presencia de isquemia miocárdica. Aunque este patrón es menos específico que la elevación del segmento ST, la inversión de la onda T puede indicar un signo temprano de isquemia subepicárdica o incluso de un infarto en fase evolutiva. Este fenómeno se produce cuando la perfusión coronaria al miocardio se ve comprometida, lo que genera un desequilibrio en la repolarización ventricular. La inversión de la onda T actúa como un marcador de daño miocárdico progresivo. Dependiendo de la severidad del infarto, este hallazgo puede persistir durante días o incluso semanas, siendo su identificación temprana crucial para la toma de decisiones terapéuticas oportunas.
- **Ondas Q patológicas:** Las ondas Q patológicas son un signo de necrosis miocárdica. Se definen como ondas Q que duran 0.04 segundos o más, o que tienen una amplitud mayor al 25 % de la onda R siguiente en la misma derivación. Las ondas Q patológicas suelen aparecer

más tarde en el curso de un infarto, generalmente entre las 6 y 16 horas, y su presencia indica que una porción significativa del músculo cardíaco ha muerto debido a la falta prolongada de oxígeno. Este hallazgo es clave para confirmar el diagnóstico de un infarto de miocardio, especialmente si el paciente presenta síntomas que sugieren una lesión cardíaca.

5.2.5. Procesamiento digital de señales

El procesamiento digital de señales es una disciplina que emplea tecnología digital para analizar, modificar y mejorar señales, transformándolas en datos discretos mediante muestreo y operaciones matemáticas. A diferencia del procesamiento analógico, donde se utilizan elementos componentes electrónicos para tratar señales continuas, el paradigma del procesamiento implica varios pasos. Como se muestra en la Figura 5.6, una señal analógica $x(t)$ se convierte en una secuencia discreta $x[n]$ mediante un convertidor analógico-digital (A/D) que toma muestras de la señal a una velocidad de f_s muestras por segundo. Luego, un algoritmo matemático procesa esa secuencia, generando una salida $y[n]$, la cual puede ser reconvertida a una señal analógica $y(t)$ mediante un convertidor digital-analógico (D/A) [54].




Figura 5.6: Esquema general del procesamiento digital de señales (Fuente: [54])

A través de este proceso de conversión y procesamiento digital, se pueden aplicar técnicas que permiten analizar de manera precisa las señales. En este contexto, se explorarán los siguientes conceptos clave para el procesamiento digital de señales:

5.2.5.1. Convolución

Es una operación matemática, la cual describe cómo una señal de entrada $x[n]$ interactúa con un sistema que responde a través de una función $h[n]$. A partir de esta interacción, se obtiene una salida $y[n]$, calculada mediante la expresión de convolución. Este proceso es fundamental en la teoría de sistemas lineales y se usa para analizar cómo las señales son modificadas por sistemas, como en el procesamiento de señales digitales, filtros y en la simulación de respuestas a estímulos en sistemas dinámicos [55]. La expresión de la convolución es la siguiente:

$$y[n] = \sum_{k=-\infty}^{\infty} x[k] h[n - k] \quad (5.1)$$

donde:

1. $y[n]$ representa la salida del sistema.
2. $x[n]$ es la señal de entrada.
3. $h[n]$ es la respuesta al impulso del sistema.
4. k es la variable de suma.

5.2.5.2. Normalización

Consiste en transformar los valores de una señal o conjunto de características para que se ubiquen dentro de un rango común, permitiendo su comparación o análisis sin que las disparidades en unidades físicas, magnitudes o variaciones de valores influyan en los resultados [56]. Para ello, existen enfoques que ajustan los datos de acuerdo con las características de sus distribuciones o rangos específicos, ya sea mediante métodos estadísticos o por escalado. Entre los procedimientos más empleados se encuentra la normalización Z-score, la cual centra los datos en torno a su media y los reescala según su desviación estándar, garantizando que las variables adquieran una distribución con media cero y varianza unitaria. En el caso de las señales, cada valor se normaliza de forma individual sin considerar su posición original dentro de la secuencia, lo que permite aplicar un enfoque uniforme tanto a señales unidimensionales como a conjuntos de características extraídas de ellas, asegurando que los valores sean homogéneos y directamente comparables entre sí.

5.2.5.3. Filtros

Son herramientas esenciales utilizadas para modificar o extraer información relevante de una señal, mediante la manipulación de sus componentes en el dominio de la frecuencia. Su función principal es permitir el paso de ciertas frecuencias mientras se atenúan o eliminan otras, de acuerdo con los requerimientos del sistema. Para lograr esto, el diseño del filtro debe cumplir con ciertas especificaciones fundamentales, entre las que se destacan la banda de paso (rango de frecuencias permitidas), la banda de rechazo (rango de frecuencias atenuadas) y la banda de transición (rango de frecuencias donde la respuesta del filtro cambia gradualmente). Estas características determinan el comportamiento del filtro y su capacidad para procesar señales en distintas aplicaciones [55].

Existen cuatro tipos básicos de filtros, cada uno diseñado para conservar o suprimir rangos específicos de frecuencia:

- **Filtro paso bajo:** Permite el paso de las frecuencias por debajo de una frecuencia de corte y atenúa las superiores.
- **Filtro paso alto:** Permite el paso de las frecuencias por encima de una frecuencia de corte y atenúa las inferiores.

- **Filtro paso banda:** Permite el paso de las frecuencias dentro de un rango específico y atenúa las que están fuera de ese rango.
- **Filtro rechaza banda:** Permite el paso de las frecuencias fuera de un rango específico y atenúa únicamente las que se encuentran dentro de ese rango.




Figura 5.7: Representación de los cuatro tipos de filtros. (a) Filtro paso bajo. (b) Filtro paso alto. (c) Filtro paso banda. (d) Filtro rechaza banda. (Fuente: [57])

5.2.5.4. Derivada

Es una operación matemática fundamental que permite evaluar el cambio instantáneo de una señal con respecto a una variable independiente. En el análisis de señales, resulta especialmente útil para detectar transiciones, discontinuidades y variaciones rápidas, como picos o bordes, ya que proporciona información detallada sobre los cambios locales, facilitando así su caracterización y el estudio de su comportamiento dinámico en el dominio temporal.

La primera derivada de una señal discreta no se define mediante cálculo diferencial, sino que se aproxima mediante diferencias finitas. Dada una señal discreta $x[n]$, una forma de expresar la derivada discreta es:

$$y[n] = x[n] - x[n - 1] \quad (5.2)$$

Esta expresión representa la diferencia entre muestras consecutivas, proporcionando una estimación de la tasa de cambio entre dos instantes de tiempo discretos. Es decir, esta magnitud indica la velocidad con la que varía la señal entre un instante y el anterior.

La segunda derivada de una señal discreta al igual se aproxima mediante diferencias finitas. La expresión correspondiente es:

$$y[n] = x[n + 1] - 2x[n] + x[n - 1] \quad (5.3)$$

Al igual que la primera derivada, esta expresión calcula la diferencia entre muestras consecutivas y permite analizar cómo varía dicha diferencia. De esta forma, proporciona una estimación de la tasa de cambio entre dos instantes de tiempo discretos, lo que es útil para detectar puntos de inflexión en señales discretas.

5.2.5.5. Ventana

Consiste en limitar la observación de una señal a un intervalo finito en el dominio temporal o espacial. Este procedimiento se lleva a cabo mediante funciones ventana que permiten seleccionar una porción específica del registro total. Al aplicar una ventana, se atenúan los efectos asociados a bordes o transiciones abruptas, y se pueden resaltar características particulares del segmento de la señal [58].

Entre las funciones ventana más utilizadas se encuentran:

- **Ventana rectangular:** Corresponde al caso en que todas las muestras dentro del intervalo de observación reciben el mismo peso, mientras que las muestras fuera de dicho intervalo se eliminan. La definición de esta ventana se presenta en la ecuación (5.4), conforme a lo expuesto en [58].

$$w_R(n) = \begin{cases} 1, & 0 \leq n \leq N - 1 \\ 0, & \text{en otro caso} \end{cases} \quad (5.4)$$

- **Ventana de Hann:** Es una función que reduce progresivamente el peso de las muestras hacia los extremos del intervalo de análisis, aplicando una ponderación gradual en lugar de transiciones bruscas. En el procesamiento de señales, esta ventana se utiliza para suavizar los bordes del segmento de señal seleccionada, con el objetivo de minimizar las distorsiones que pueden surgir al delimitar una sección de la señal de forma directa. La definición de esta ventana se presenta en la ecuación (5.5), conforme a lo expuesto en [58].

$$w_H(n) = \begin{cases} 0.5 \left[1 - \cos \left(\frac{2\pi n}{N} \right) \right], & 0 \leq n \leq N - 1 \\ 0, & \text{en otro caso} \end{cases} \quad (5.5)$$

- **Aplanamiento de señales:** El aplanamiento (flattening) es una operación fundamental en el procesamiento digital de señales y en el aprendizaje profundo, cuyo propósito es transformar una estructura multidimensional (como una matriz o un tensor) en un vector unidimensional, preservando la totalidad de los valores originales. Este proceso reorganiza los elementos en una

sola dimensión sin alterar su contenido numérico, permitiendo que los datos sean compatibles con capas densas o clasificadores que requieren entradas vectorizadas [59] [60].

Desde una perspectiva matemática, el aplanamiento puede representarse como la conversión de una matriz $X \in \mathbb{R}^{m \times n}$ en un vector $x' \in \mathbb{R}^{mn}$, según la siguiente expresión:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix} \Rightarrow x' = [x_{11}, x_{12}, \dots, x_{mn}] \quad (5.6)$$

De esta forma, cada elemento de la estructura original se reordena secuencialmente, generando un vector que conserva la información completa de la señal, pero en una sola dimensión.

En el contexto del procesamiento digital de señales fisiológicas, como el electrocardiograma (ECG), el aplanamiento cumple un papel clave al reorganizar los registros en un formato lineal adecuado para su análisis computacional. Al convertir las señales en vectores, se facilita su almacenamiento, manipulación y posterior ingreso en modelos de aprendizaje automático o redes neuronales, que requieren entradas vectorizadas.

Este procedimiento permite conservar los patrones morfológicos característicos de la señal (como las ondas P, QRS y T en el caso del ECG), garantizando que la información temporal y estructural esencial se mantenga intacta para etapas posteriores de procesamiento o clasificación. En este sentido, el aplanamiento actúa como un puente entre la representación fisiológica de las señales y su interpretación mediante técnicas computacionales avanzadas [61].

5.2.6. Extracción de características

La extracción de características constituye una etapa esencial dentro del procesamiento y análisis de señales biomédicas, particularmente en aquellas orientadas al diagnóstico automatizado mediante técnicas de aprendizaje automático. Su propósito principal es transformar la señal en un conjunto de descriptores cuantitativos que representen de manera compacta y significativa la información fisiológica relevante. En esencia, esta etapa busca reducir la dimensionalidad y depurar la información contenida en la señal, conservando únicamente los atributos que describan con mayor fidelidad su comportamiento dinámico [62].

En el análisis de señales de ECG, la etapa de extracción de características suele abordarse desde tres dominios complementarios, cada uno orientado a capturar distintos aspectos de la estructura y el comportamiento eléctrico del corazón:

- **Dominio temporal:** Se enfoca en el análisis directo de la señal en función del tiempo. Describe cuantitativamente las variaciones de amplitud, duración y secuencia de los eventos eléctricos cardíacos, sin requerir transformaciones a otros espacios de representación. Este enfoque se asocia a la caracterización de la morfología y los intervalos del ECG, elementos fundamentales para la evaluación cronológica de la actividad cardíaca.
- **Dominio espectral:** Se fundamenta en la representación de la señal en función de la frecuencia, mediante la descomposición de sus componentes armónicos. Analiza la distribución de energía del ECG en el plano frecuencial, destacando la presencia de ritmos y oscilaciones que describen la actividad eléctrica global del corazón.
- **Dominio no lineal:** Analiza la señal desde la perspectiva de los sistemas dinámicos, considerando el carácter no lineal del sistema cardiovascular. Este dominio se orienta a la cuantificación de características complejas como la entropía, la irregularidad y la complejidad estructural del ECG, las cuales reflejan la interacción de múltiples mecanismos fisiológicos y permiten caracterizar el comportamiento global del corazón más allá de los modelos lineales tradicionales.

Esta aproximación multidimensional ha demostrado su efectividad en aplicaciones clínicas críticas. En particular, un estudio orientado al diagnóstico automatizado del paro cardíaco súbito (SCA) desarrolló un modelo computacional destinado a su implementación en desfibriladores externos automáticos (DEA), con el propósito de discriminar ritmos desfibrilables de no desfibrilables a partir de señales ECG. El modelo integró 31 características distribuidas en los dominios temporal, espectral y no lineal, utilizadas como variables de entrada en algoritmos de aprendizaje automático. Dicho enfoque alcanzó una precisión diagnóstica del 99.52% y una sensibilidad del 97.69% [63].

La Tabla 5.1 resume las características seleccionadas en el estudio, clasificadas por dominio de análisis, las cuales servirán como base para su adaptación en el desarrollo del presente trabajo de grado.

Tabla 5.1: Características electrocardiográficas organizadas según los dominios de análisis temporal, espectral y no lineal

Dominio	Característica	Abrev.	Descripción
Temporal	Valor absoluto medio	MAva	Promedio del valor absoluto de la señal, representa la magnitud promedio de las variaciones del ECG.
	b-count parameter	bCP	Conteo de transiciones alrededor de un umbral bajo de amplitud, asociado con la estabilidad del segmento.

Dominio	Característica	Abrev.	Descripción
	Recuento de muestras de cruce de umbral	TCSC	Número total de cruces de un umbral predefinido, útil para describir la variabilidad del ritmo cardíaco.
	Intervalo de cruce de umbral	TCin	Promedio del tiempo entre cruces consecutivos de umbral, indicador de la regularidad de la señal.
	Algoritmo exponencial estándar	SEal	Promedio obtenido al aplicar una función exponencial decreciente sobre la amplitud, resalta atenuaciones leves.
	Algoritmo exponencial modificado	MEal	Promedio basado en una función exponencial cuadrática aplicada a la amplitud, enfatiza picos pronunciados.
	Conteo de amplitudes en rango ± 0.1	Count1	Número de muestras con amplitudes comprendidas entre -0.1 y 0.1.
	Conteo de amplitudes en rango ± 0.2	Count2	Número de muestras con amplitudes dentro del rango -0.2 a 0.2.
	Conteo de amplitudes en rango ± 0.3	Count3	Número de muestras con amplitudes entre -0.3 y 0.3.
Espectral	Frecuencia central	CFre	Media ponderada de la densidad espectral de potencia que determina la frecuencia dominante.
	Análisis espectral banda baja	A1	Energía promedio en bajas frecuencias.
	Análisis espectral banda alta	A2	Energía promedio en altas frecuencias.
	Análisis espectral de potencia media	PSan	Potencia media total de la señal, representación de la energía global del espectro.
	Potencia central	CPow	Potencia correspondiente a la frecuencia central, punto de máxima concentración energética.
	Energía relativa	Y_Li	Proporción entre la energía útil del rango 0.5-40 Hz y la energía total del ECG.

Dominio	Característica	Abrev.	Descripción
	Ancho de banda	bW	Desviación estándar espectral que describe la distribución de la energía en el dominio frecuencial.
	Medida de fugas del filtro VF	VFLM	Proporción de energía contenida en la banda 4–8 Hz.
	Energía de wavelet total	bWT	Energía calculada a partir de los coeficientes wavelet, refleja el contenido multiescala de la señal.
No lineal	Transformada de Hilbert	HTra	Magnitud media de la envolvente analítica, asociada con las variaciones instantáneas de amplitud.
	Cálculo de covarianza	CCal	Medida de dispersión de las amplitudes del ECG.
	Cálculo de área	ACal	Área bajo la curva del ECG, expresión de la magnitud acumulada de la señal.
	Cálculo de frecuencia dominante	FCal	Frecuencia con mayor potencia espectral, correspondiente a la oscilación principal del ECG.
	Curtosis	Kurt	Medida estadística del grado de apuntamiento o concentración de picos en la señal.
	Medida de complejidad	CMea	Promedio de la variación absoluta entre muestras consecutivas, relacionado con la irregularidad del trazo.
	Entropía de dispersión	DEnt	Medida de la dispersión de patrones de amplitud y su grado de impredecibilidad local.
	Entropía de muestra	SEnt	Estimación de la regularidad de la señal comparando la probabilidad de ocurrencia de patrones similares.
	Energía total	Ener	Energía total de la señal en el dominio temporal.
	Entropía de Rényi	REnt	Medida de diversidad en la distribución de amplitudes.
	Entropía wavelet	WEnt	Indicador de complejidad multiescala que caracteriza irregularidades transitorias.

Dominio	Característica	Abrev.	Descripción
	Entropía difusa	FEnt	Incertidumbre difusa en los patrones de amplitud.
	Cálculo de potencia espectral residual	PSre	Energía restante fuera de las componentes dominantes, útil para caracterizar ruido y variabilidad.

5.2.7. Shapley Additive Explanations

Basado en los principios de la teoría de juegos cooperativos, Lundberg et al. [64] introdujeron el enfoque SHapley Additive exPlanations (SHAP), el cual formula un modelo aditivo para la interpretación de predicciones en algoritmos de aprendizaje automático. El principio fundamental de SHAP establece que cada característica contribuye de manera marginal al resultado global del modelo, y dicha aportación puede cuantificarse mediante los valores SHAP, que representan la media ponderada de las contribuciones marginales de una característica a lo largo de todas las combinaciones posibles de las demás. Este procedimiento permite estimar de forma equitativa y coherente el impacto individual que cada variable ejerce sobre la predicción final. La formulación matemática del método SHAP se presenta en la ecuación (5.7).

$$g(z') = \phi_0 + \sum_{j=1}^M \phi_j z'_j \quad (5.7)$$

donde:

1. $g(z')$ representa el modelo explicativo aproximado del método SHAP.
2. ϕ_0 corresponde al valor esperado de la predicción del modelo (valor base).
3. ϕ_j representa el valor de Shapley asociado a la característica j .
4. z'_j indica la presencia (1) o ausencia (0) de la característica j en la coalición.
5. M corresponde al número total de características consideradas.

Existen diversas variantes del método SHAP que permiten adaptarlo a distintos tipos de modelos y reducir su complejidad computacional. Entre ellas, KernelSHAP se emplea para acelerar el cálculo de los valores de Shapley en modelos de aprendizaje automático con grandes conjuntos de características, utilizando una aproximación basada en pesos lineales. Por otro lado, TreeSHAP aprovecha la estructura interna de los modelos basados en árboles de decisión para estimar de manera eficiente las contribuciones de cada característica [65]. Estas variantes amplían la aplicabilidad del enfoque SHAP, permitiendo su uso en contextos donde el número de características o la naturaleza del modelo dificultarían un cálculo exhaustivo de los valores de Shapley.

5.2.8. Aprendizaje automático

El aprendizaje automático es una rama de la inteligencia artificial que permite a las máquinas aprender y mejorar de forma autónoma a partir de datos. Este proceso automatizado consiste en la identificación de patrones dentro de grandes volúmenes de información, lo cual facilita la toma de decisiones sin intervención humana directa. Esta evoluciona continuamente debido al rápido crecimiento de los datos disponibles. A medida que los volúmenes de datos aumentan, también lo hacen las capacidades de los modelos para aprender y adaptarse a nuevas situaciones [66].

Dos de las categorías principales del aprendizaje automático son el aprendizaje supervisado y el aprendizaje no supervisado.

- **Aprendizaje supervisado:** Este enfoque se basa en la utilización de un conjunto de datos etiquetados, donde cada muestra está vinculada a una etiqueta o clase específica. El modelo aprende a partir de estas relaciones, lo que le permite realizar predicciones al asociar nuevas instancias de datos con las etiquetas correspondientes. Este tipo de aprendizaje se clasifica en dos áreas fundamentales: clasificación y regresión. En la clasificación, el objetivo es asignar cada muestra a una categoría predefinida, mientras que, en la regresión, el modelo busca predecir un valor numérico continuo [66]. Una de las principales fortalezas del aprendizaje supervisado es su capacidad para generar modelos precisos y controlados, siempre y cuando los datos de entrenamiento sean de alta calidad y representativos del fenómeno que se desea modelar.
- **Aprendizaje no supervisado:** Este enfoque implica el análisis de conjuntos de datos no etiquetados, en los cuales no se dispone de información previa sobre clases o categoría. En este caso, el algoritmo no tiene información explícita sobre las categorías o etiquetas asociadas a los datos, lo que implica que el modelo debe identificar patrones y estructuras subyacentes por sí mismo [66].

Uno de los aspectos fundamentales a considerar en la aplicación de algoritmos de aprendizaje automático es el equilibrio entre la capacidad del modelo para generalizar y su tendencia a ajustarse en exceso a los datos de entrenamiento. En este sentido, surgen dos conceptos clave: overfitting y underfitting. El overfitting ocurre cuando un modelo se ajusta demasiado a los datos de entrenamiento, incluso al ruido, lo que afecta su desempeño al enfrentarse a datos nuevos. Por el contrario, el underfitting aparece cuando el modelo no logra captar la estructura interna de los datos, mostrando un mal desempeño tanto en entrenamiento como en prueba.

Para mitigar estos comportamientos se emplean técnicas de regularización, entre las cuales destacan L1 y L2. La regularización L1 promueve la selección de características al inducir que algunos parámetros tomen valores cercanos a cero, de modo que el modelo conserva únicamente los pesos más relevantes. Por su parte, la regularización L2 evita que los pesos crezcan excesivamente, distribuyendo la penalización de manera equilibrada y contribuyendo a mejorar la capacidad de generalización del modelo.

5.2.9. Técnicas de aprendizaje automático

5.2.9.1. XGBoost

El algoritmo eXtreme Gradient Boosting (XGBoost) se fundamenta en el principio del gradient boosting, combinando de manera secuencial múltiples modelos débiles como árboles de decisión para conformar un modelo predictivo robusto y preciso [67]. A diferencia de otros métodos de boosting, XGBoost optimiza la función objetivo mediante la incorporación de términos de regularización que penalizan la complejidad del modelo, favoreciendo una mejor generalización y reduciendo el riesgo de sobreajuste. Su funcionamiento se basa en un proceso iterativo, en el cual cada nuevo árbol se entrena para modelar los errores residuales generados por los árboles anteriores, mejorando progresivamente el desempeño del modelo. Su diseño eficiente y capacidad para manejar datos dispersos lo convierten en una herramienta altamente competitiva para tareas de clasificación y regresión.

La combinación de XGBoost con los valores SHAP se ha consolidado como una estrategia eficaz para la selección e interpretación de características. Los valores SHAP permiten cuantificar la contribución individual de cada variable en la predicción del modelo, otorgando interpretabilidad tanto a nivel global como local. A diferencia de métodos tradicionales de evaluación de relevancia, como la información mutua, que mide la dependencia estadística entre las variables de entrada y la salida. SHAP mantiene una consistencia teórica con la estructura interna del modelo y presenta menor sensibilidad a las perturbaciones de los datos. Esta integración entre XGBoost y SHAP permite una identificación más precisa y estable de las características relevantes, garantizando además una interpretabilidad adecuada en contextos clínicos [68].

5.2.9.2. LightGBM

LightGBM, al igual que XGBoost, se fundamenta en el principio del gradient boosting y utiliza árboles de decisión como clasificadores base. Su principal ventaja radica en su alta eficiencia computacional, que permite un entrenamiento más rápido, con menor uso de memoria y una notable capacidad para manejar grandes volúmenes de datos. Durante el proceso de aprendizaje, los árboles se construyen de manera iterativa, ajustando los pesos de los clasificadores para reducir progresivamente el error y optimizar el rendimiento del modelo [69]. A diferencia de XGBoost, que emplea un enfoque level-wise para expandir los árboles de manera equilibrada por niveles, LightGBM utiliza una estrategia leaf-wise, donde el crecimiento se produce desde las hojas que presentan mayor ganancia de información. Esta técnica prioriza las ramas que maximizan la reducción del error, logrando un mejor desempeño en tareas complejas.

5.2.9.3. Redes Neuronales Convolucionales

Las redes neuronales convolucionales (CNN) constituye una de las arquitecturas más representativas del aprendizaje profundo (Deep learning) especialmente destacadas por su capacidad para la extracción automática de características y el reconocimiento de patrones espaciales y temporales [70], estas redes fueron inicialmente concebidas para el procesamiento de imágenes bidimensionales,

donde las capas convolucionales permiten identificar estructuras jerárquicas (desde bordes simples, hasta formas complejas) sin necesidad de definir manualmente los descriptores de entrada.

La convolución es el proceso principal de esta arquitectura. Consiste en aplicar filtros que recorren los datos para detectar patrones importantes en la señal. Al usar los mismos pesos en diferentes partes, el modelo necesita menos parámetros y aprende de forma más eficiente [71].

Debido a su rendimiento, las redes neuronales convolucionales (CNN) han sido progresivamente adaptadas a otros dominios de datos estructurados, extendiendo su aplicabilidad más allá de las imágenes bidimensionales. Esto permite abordar el procesamiento de señales unidimensionales, donde las relaciones temporales y morfológicas tienen una relevancia esencial, las CNN ha demostrado potencia en el análisis automático de señales fisiológicas como la electrocardiografía, esto da origen a las redes convolucionales de 1 dimensión (CNN-1D), la cual representan una extensión de las CNN tradicionales, diseñada para procesar secuencias temporales o señales unidimensionales, estas utilizan filtros unidimensionales que se desplazan a lo largo del eje temporal de la señal, lo que las hace adecuadas para datos como señales ECG [72].

La convolución unidimensional (1D) constituye el núcleo de las redes neuronales convolucionales aplicadas al procesamiento de señales temporales. En este tipo de operación, un conjunto de filtros o kernels se desplaza a lo largo del eje temporal de la señal, realizando multiplicaciones y sumas acumulativas que generan mapas de características que representan la información local de la secuencia. Esta arquitectura permite capturar automáticamente patrones relevantes sin requerir una extracción manual de características, lo que resulta especialmente ventajoso para datos fisiológicos donde las variaciones temporales son significativas [73].

En el contexto de las señales electrocardiográficas (ECG), las CNN-1D aprenden representaciones jerárquicas de la actividad cardíaca, donde las primeras capas identifican rasgos morfológicos locales (como ondas P, complejos QRS y ondas T), y las capas más profundas integran información contextual para detectar alteraciones en el segmento ST, fundamentales en el diagnóstico del infarto agudo de miocardio con elevación del ST (IAMCEST) Cada filtro actúa como un detector especializado que contribuye a una representación robusta de la señal, mejorando la precisión diagnóstica frente a variaciones entre paciente y ruido fisiológico [74].

5.2.10. Técnicas de aumento de datos

En el ámbito de la inteligencia artificial aplicada a la medicina, uno de los desafíos más significativos es el manejo de conjuntos de datos desbalanceados. Este desbalance puede llevar a que los modelos de aprendizaje automático (ML) presenten un sesgo hacia la clase mayoritaria, afectando especialmente la predicción de la clase minoritaria, la cual generalmente corresponde a situaciones clínicas de mayor relevancia para la toma de decisiones o posee un nivel de importancia equivalente al de los demás casos [75].

Con el objetivo de corregir el desbalance en los conjuntos de datos clínicos, se han desarrollado diversas estrategias de aumento de datos (oversampling) que generan nuevas muestras sintéticas. Dos de las más reconocidas son la técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) y el aumento de datos mediante ruido gaussiano (GNUS). Ambas buscan equilibrar la distribución de las clases, aunque difieren en su enfoque y eficacia dependiendo del contexto y del modelo de aprendizaje automático empleado.

5.2.10.1. SMOTE

La técnica SMOTE es una metodología ampliamente utilizada para abordar el desequilibrio de clases en conjuntos de datos, especialmente en contextos donde la clase minoritaria es de importancia crítica. Este método genera instancias sintéticas a partir de las muestras existentes de la clase minoritaria, evitando la duplicación directa de los datos y reduciendo el riesgo de sobreajuste [76].

El proceso consiste en los siguientes pasos:

- Para cada muestra de la clase minoritaria, se identifican sus k vecinos más cercanos (usualmente $k = 5$) dentro de la misma clase, utilizando métricas de distancia como la euclidiana.
- Se selecciona aleatoriamente uno de estos vecinos y se genera un nuevo punto de datos sintético interpolando entre la muestra original y el vecino seleccionado. La fórmula básica es:

$$x_{\text{new}} = x_i + \delta \cdot (x_{\text{neighbor}} - x_i) \quad (5.8)$$

donde x_i representa la muestra original, x_{neighbor} uno de sus vecinos más cercanos, y $\delta \in [0, 1]$ es un número aleatorio.

Este enfoque permite generar un espacio de características más continuo para la clase minoritaria, lo que facilita que los algoritmos de aprendizaje automático identifiquen patrones más generales y reduzcan el riesgo de sobreajuste a ejemplos específicos.

SMOTE ofrece varias ventajas importantes para el manejo de conjuntos de datos desbalanceados. Al generar nuevas instancias sintéticas de la clase minoritaria, preserva la información de la clase mayoritaria, manteniendo la integridad del conjunto original. Además, la creación de estas muestras permite que los modelos de aprendizaje automático identifiquen patrones de la clase minoritaria con mayor precisión, mejorando así el rendimiento global. Otro beneficio es la reducción del sobreajuste, ya que SMOTE genera datos interpolados en lugar de duplicar ejemplos existentes, evitando que el modelo memorice casos específicos.

No obstante, esta técnica también presenta limitaciones que deben considerarse. La calidad de las muestras sintéticas depende en gran medida de la densidad de la clase minoritaria; si existen pocos ejemplos o estos están dispersos, los datos generados pueden ser poco representativos o introducir

ruido. Asimismo, la elección del parámetro k , que define el número de vecinos más cercanos, puede afectar la generación de ejemplos: un valor demasiado bajo o alto puede provocar redundancia o sobreajuste. En contextos clínicos, existe el riesgo de generar combinaciones irreales, ya que algunas muestras sintéticas pueden no ser fisiológicamente posibles, lo que limita la interpretabilidad del modelo. Finalmente, cuando se trabaja con volúmenes de datos grandes o con alta dimensionalidad, SMOTE puede ser computacionalmente costoso debido al cálculo de vecinos y la generación de nuevas instancias [77].

Si bien SMOTE ha demostrado ser efectiva en muchos escenarios, su complejidad computacional y ciertas limitaciones en la representación de datos minoritarios han llevado al desarrollo de métodos alternativos como GNUS, que buscan generar muestras sintéticas de manera más rápida y flexible.

5.2.10.2. GNUS

La técnica GNUS propone un enfoque de sobremuestreo que genera nuevas muestras de la clase minoritaria mediante la adición de ruido gaussiano a las instancias existentes. A diferencia de SMOTE, GNUS no interpola entre vecinos, sino que perturba ligeramente los valores de cada característica de los datos originales, creando así variabilidad dentro de la clase minoritaria [78].

El proceso consiste en los siguientes pasos:

- Seleccionar aleatoriamente una muestra de la clase minoritaria.
- Para cada característica de la muestra, añadir un valor de ruido gaussiano:

$$x_{\text{new}} = x_i + N(\mu, \sigma^2)$$

donde $N(\mu, \sigma^2)$ representa ruido gaussiano con media μ (generalmente cercana a 0) y desviación estándar σ proporcional a la variabilidad de la característica.

- Repetir el proceso hasta generar el número deseado de instancias sintéticas.

Este enfoque permite incrementar el tamaño de la clase minoritaria, preservando parte de la variabilidad natural de los datos y suavizando los límites de decisión del modelo [79].

GNUS se destaca por ser computacionalmente más eficiente que SMOTE, lo que lo hace especialmente adecuado para conjuntos de datos de alta dimensionalidad. Al añadir ruido gaussiano a las muestras de la clase minoritaria, GNUS incrementa la variabilidad del espacio de características, lo que ayuda a los modelos a generalizar mejor y a reducir el riesgo de sobreajuste. Además, el nivel de ruido puede ajustarse según las necesidades del conjunto de datos, permitiendo generar muestras representativas de la clase minoritaria de manera flexible. Aunque no utiliza vecinos cercanos como SMOTE, esta independencia permite una generación más rápida y sencilla de nuevas instancias, manteniendo la diversidad de los datos y mejorando el desempeño de los modelos de aprendizaje automático en la clasificación de clases minoritarias.

Los resultados del estudio de Kramer et al. [80] demuestran que, aunque SMOTE es efectivo para mejorar la clasificación en conjuntos de datos clínicos desequilibrados, GNUS se presenta como una alternativa más eficiente y robusta. Esta técnica no solo reduce significativamente el tiempo de ejecución en comparación con SMOTE, sino que también mejora métricas clave como F1, MCC y AUC en múltiples conjuntos de datos, especialmente cuando se trabaja con datasets pequeños o altamente desbalanceados. Por estas razones, GNUS puede considerarse la estrategia de aumento de datos más adecuada en entornos clínicos, donde la rapidez, la diversidad de los datos sintéticos y la reducción del sobreajuste son fundamentales para la implementación práctica de modelos de aprendizaje automático confiables.

5.2.11. Herramientas de desarrollo computacional

El desarrollo del proyecto requiere un entorno sólido y adaptable que facilite el manejo eficiente de datos, el entrenamiento de modelos de aprendizaje automático y la implementación de herramientas destinadas tanto al análisis de señales como al desarrollo de la interfaz del sistema. La selección de las tecnologías y bibliotecas se basó en criterios de rendimiento, compatibilidad y facilidad de integración, con el propósito de optimizar el flujo de trabajo desde la adquisición y procesamiento de las señales electrocardiográficas hasta la visualización y validación de los resultados. Este enfoque integral permite combinar el procesamiento de datos clínicos con modelos predictivos y una interfaz funcional, garantizando un ciclo de desarrollo ágil y seguro.

- Python: Lenguaje de programación de alto nivel, interpretado y de propósito general, conocido por su legibilidad, versatilidad y amplia comunidad de desarrolladores. Permite implementar algoritmos de procesamiento de señales, aprendizaje automático y análisis de datos clínicos de manera eficiente [81].
- NumPy: Librería fundamental para computación numérica en Python. Proporciona estructuras de datos como arrays multidimensionales y funciones matemáticas optimizadas para operaciones vectoriales y matriciales, esenciales en el procesamiento de señales biomédicas [82].
- Pandas: Biblioteca para la manipulación y análisis de datos estructurados. Ofrece estructuras flexibles como DataFrames y Series, facilitando la limpieza, transformación y exploración de grandes volúmenes de datos [83].
- Matplotlib: Librería para la creación de gráficos estáticos, interactivos y animados en Python. Permite la visualización de datos clínicos y resultados de análisis de manera clara y personalizable [84].
- TensorFlow: Framework de código abierto para aprendizaje profundo y redes neuronales. Facilita la construcción, entrenamiento y despliegue de modelos predictivos sobre datos biomédicos [85].

- Flask: Micro-framework de desarrollo web que permite crear aplicaciones ligeras e interactivas, facilitando la visualización de resultados y prototipos de herramientas de apoyo al análisis clínico [86].
- JSON: Biblioteca estándar de Python para el manejo de datos en formato JSON (JavaScript Object Notation), utilizada para el intercambio estructurado de información entre módulos del proyecto y compatibilidad con bases de datos externas [87].
- WFDB: Librería especializada en la lectura, escritura y manipulación de señales fisiológicas almacenadas en bases de datos como ECG, permitiendo acceder de manera eficiente a datos clínicos y procesarlos para análisis y modelado [88].
- Visual Studio Code: Entorno de desarrollo integrado que facilita la escritura, depuración y organización del código, soportando múltiples lenguajes y extensiones especializadas para Python y análisis de datos [89].

5.2.12. Entornos de desarrollo multiplataforma

Los entornos de desarrollo multiplataforma se refieren a aquellos marcos y tecnologías que permiten crear aplicaciones capaces de ejecutarse en diferentes sistemas operativos sin requerir un desarrollo específico para cada uno. Estas aplicaciones se construyen una sola vez y posteriormente pueden implementarse en plataformas diversas, como Android, iOS, Windows o Linux. Entre los frameworks más utilizados para este propósito se encuentran Flutter, React Native, Xamarin e Ionic, los cuales facilitan la creación de interfaces consistentes y funcionales en distintos dispositivos. Este enfoque posibilita la reutilización del código fuente y de los recursos, reduciendo significativamente los costos y el tiempo de desarrollo.

De acuerdo con Souha et al. [90], dentro del conjunto de tecnologías de desarrollo multiplataforma se reconocen diversas categorías que permiten implementar aplicaciones compatibles con múltiples sistemas operativos. Entre ellas se destacan las aplicaciones web, híbridas, interpretadas y cross-compiled, cada una con características particulares en cuanto a su arquitectura, modo de ejecución y grado de portabilidad. No obstante, en el ámbito clínico, las aplicaciones web y las híbridas son las más empleadas, debido a su flexibilidad, facilidad de implementación y capacidad de adaptación a diferentes entornos de uso.

Las aplicaciones web se ejecutan directamente desde un navegador, sin requerir instalación en el dispositivo, lo que facilita su acceso desde cualquier equipo con conexión a Internet. Este tipo de arquitectura se sustenta en tecnologías estandarizadas como HTML y JavaScript, que permiten desarrollar interfaces interactivas, ligeras y visualmente intuitivas. Su principal fortaleza radica en la independencia de la plataforma, ya que pueden operar de manera uniforme en distintos sistemas operativos sin necesidad de modificar el código fuente, además de simplificar las tareas de mantenimiento y actualización. Por su parte, las aplicaciones híbridas constituyen un enfoque intermedio entre las soluciones web y las aplicaciones nativas. Aunque emplean tecnologías similares a las del

desarrollo web, son empaquetadas dentro de un contenedor que posibilita su instalación directa en el dispositivo. Este enfoque combina la reutilización del código con el acceso a funcionalidades específicas del hardware, aunque puede presentar ciertas limitaciones en cuanto al rendimiento y la experiencia de usuario.

5.3. Trabajos Relacionados

La identificación automatizada de patrones electrocardiográficos asociados al IAM ha sido una línea de investigación de creciente interés, combinando avances tanto en cardiología como en el análisis computacional de señales biomédicas. Diferentes estudios han explorado el uso de bases de datos clínicas, algoritmos de aprendizaje automático y criterios electrocardiográficos avanzados para mejorar la detección de enfermedades cardiovasculares. A continuación, se presentan algunos trabajos relevantes que abordan temáticas afines a la propuesta de este proyecto:

Artificial intelligence-based prediction of acute myocardial infarction mortality risk

Este estudio, realizado por Yu-Wei Li et al. [91], presenta un modelo de predicción del riesgo de mortalidad en pacientes con IAM, utilizando registros clínicos de la base de datos MIMIC-IV, específicamente de pacientes ingresados en unidades de cuidados intensivos del Beth Israel Deaconess Medical Center. Para el desarrollo del modelo, se emplearon variables clínicas como la frecuencia cardíaca mínima, el anion gap máximo, la frecuencia respiratoria máxima, los niveles de creatinina, entre otros parámetros vitales y de laboratorio que reflejan el estado fisiológico del paciente. La relevancia de cada una de estas variables en la predicción fue evaluada utilizando valores de SHAP, lo que permitió una interpretación detallada del impacto individual que cada característica tenía sobre la salida del modelo. A pesar de no incorporar registros de ECG, el modelo logró un desempeño prometedor. Se entrenaron y compararon diversos algoritmos de aprendizaje automático, como Random Forest, LightGBM y XGBoost, siendo este último el que mostró los mejores resultados, alcanzando una precisión del 91.6% y un área bajo la curva (AUC) del 97.5%.

New electrocardiographic algorithm for the diagnosis of acute myocardial infarction in patients with left bundle branch block

Este estudio de cohorte, liderada por Di Marco et al. [92], propone un algoritmo, llamado BARCELONA con el objetivo de mejorar la sensibilidad diagnóstica del IAM en presencia de bloqueo de rama izquierda (BRI). El estudio incluyó 484 pacientes distribuidos en tres grupos, evaluando criterios electrocardiográficos, incluidos los de Sgarbossa modificados. El algoritmo BARCELONA fue definido como positivo ante dos condiciones: (1) presencia de desviación del segmento ST ≥ 1 mm concordante con el QRS o (2) desviación del ST ≥ 1 mm discordante en derivaciones con voltaje máximo ≤ 6 mm, logrando alcanzar una sensibilidad de 93% - 95%, y un área bajo la curva AUC del 92% - 93%. El estudio, respaldado por datos angiográficos y biomarcadores cardíacos, introdujo mejoras metodológicas como la definición operativa de IAM equivalente al IAMCEST y el análisis

de concordancia interobservador, alcanzando coeficientes kappa superiores a 0.96, lo que evidenció el potencial clínico del algoritmo para reducir el sobret ratamiento en pacientes con BRI, optimizar el uso de protocolos de reperfusión y mejorar la precisión diagnóstica del IAM.

LASSO Regression-Based Diagnosis of Acute ST-Segment Elevation Myocardial Infarction (STEMI) on Electrocardiogram (ECG)

En este proyecto, realizado por L. Wu et al. [93], se aborda la problemática del diagnóstico automatizado del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST) a partir de registros electrocardiográficos mediante técnicas de aprendizaje automático. El estudio se justifica por la dificultad del diagnóstico clínico en presencia de arritmias o patrones ECG atípicos, y su objetivo principal fue desarrollar un modelo predictivo utilizando regresión LASSO para identificar pacientes con IAMCEST y localizar arterias relacionadas con el infarto. Para ello, se utilizó una base de datos compuesta por 820 pacientes, confirmando el diagnóstico con angiografía coronaria. Se extrajeron automáticamente 180 características del ECG de 12 derivaciones, y el modelo redujo estas variables a 14 para la detección de IAMCEST y a 4 para la localización de la arteria descendente anterior izquierda (LAD). El modelo LASSO alcanzó áreas bajo la curva (AUC) de 0.94 y 0.93 en conjuntos de prueba internos y externos, superando el rendimiento de médicos no especialistas y siendo comparable al de cardiólogos expertos. Esto demuestra el potencial de herramientas computacionales para apoyar el diagnóstico temprano de IAMCEST.

Development of Clinically Validated Artificial Intelligence Model for Detecting ST-segment Elevation Myocardial Infarction

En este proyecto, realizado por S. H. Lee et al. [94], se aborda la problemática de la detección precisa del infarto agudo de miocardio con elevación del segmento ST (IAMCEST) mediante el desarrollo de un modelo de IA clínicamente validado. Este trabajo surge ante las altas tasas de activaciones innecesarias del laboratorio de cateterismo cardíaco causadas por interpretaciones erróneas de los electrocardiogramas tanto por médicos como por sistemas automatizados. Utilizando una base de datos de 18.697 ECGs obtenidos de un registro multicéntrico coreano, se entrenó un modelo de deep learning basado en un ensamblado de cinco redes neuronales convolucionales. El modelo logró una precisión del 92.1 %, sensibilidad del 95.4 % y especificidad del 91.8 %, superando tanto a los médicos residentes como a los sistemas de ECG comerciales. Además, el modelo fue validado clínicamente con datos de pacientes en el servicio de urgencias y con datos externos del set PTB-XL, logrando también resultados sobresalientes. Para aumentar la confianza en el sistema, se aplicaron técnicas de visualización como Grad-CAM, que revelaron que el modelo se enfoca en segmentos clínicamente relevantes como el ST y la onda T. Este estudio destaca la capacidad de los modelos de IA para apoyar decisiones clínicas en contextos reales, reduciendo errores y optimizando recursos hospitalarios.

Materiales y Métodos

El presente trabajo de grado, titulado “*MyoAlert Vision: sistema inteligente de apoyo diagnóstico para la identificación automática del infarto agudo de miocardio con elevación del segmento ST mediante análisis electrocardiográfico*”, corresponde a un estudio descriptivo retrospectivo fundamentado en registros electrocardiográficos anonimizados obtenidos de un repositorio de datos biomédicos de libre acceso. La naturaleza abierta de este recurso garantiza el cumplimiento de los principios éticos para el manejo de datos biomédicos. El desarrollo metodológico abarcó desde la adquisición de los registros hasta la clasificación del IAMCEST según su localización anatómica, como se muestra en la Figura 6.2. Inicialmente, se seleccionaron datos de la base MIMIC-IV, incluyendo registros normales y de IAMCEST. Durante el preprocesamiento, las señales fueron filtradas con un paso banda Butterworth y suavizadas mediante una ventana Hanning, para luego aplanarse en vectores unidimensionales.

La etapa de extracción de características consideró atributos del dominio temporal, espectral y no lineal, con el propósito de capturar de manera integral las variaciones morfológicas y dinámicas del electrocardiograma. A partir de dichas características, se implementó un modelo de clasificación basado en aprendizaje automático, específicamente XGBoost, orientado a la detección de IAMCEST, y una red neuronal convolucional unidimensional (CNN-1D) empleada como estrategia complementaria para la detección directa a partir de los vectores unidimensionales. Con el fin de lograr un análisis diagnóstico más integral, se desarrolló un segundo modelo XGBoost complementado con valores SHAP, lo que permitió identificar las derivaciones con mayor contribución a las predicciones y, a partir de ellas, determinar la localización anatómica del infarto mediante reglas de contigüidad electrocardiográfica. Finalmente, utilizando las etiquetas generadas a partir de este análisis, se entrenó un clasificador LightGBM orientado a determinar la zona anatómica comprometida, aplicando dos técnicas de aumento de datos; GNUS y SMOTE, de las cuales GNUS mostró el mejor rendimiento y menor sobreajuste. La salida de este modelo final permitió clasificar el tipo de infarto en cuatro localizaciones anatómicas: anterior, inferior, lateral y septal.

Toda esta arquitectura descrita se integró en la aplicación web MyoAlert Vision, una herramienta interactiva que permite analizar señales ECG para detectar casos de IAMCEST y determinar la localización anatómica afectada. La plataforma ofrece una interfaz intuitiva para cargar registros, visualizar resultados y generar estimaciones basadas en los modelos de aprendizaje automático. Además, incorpora la opción de generar reportes en formato PDF, facilitando la documentación y el respaldo clínico de los diagnósticos asistidos por inteligencia artificial.

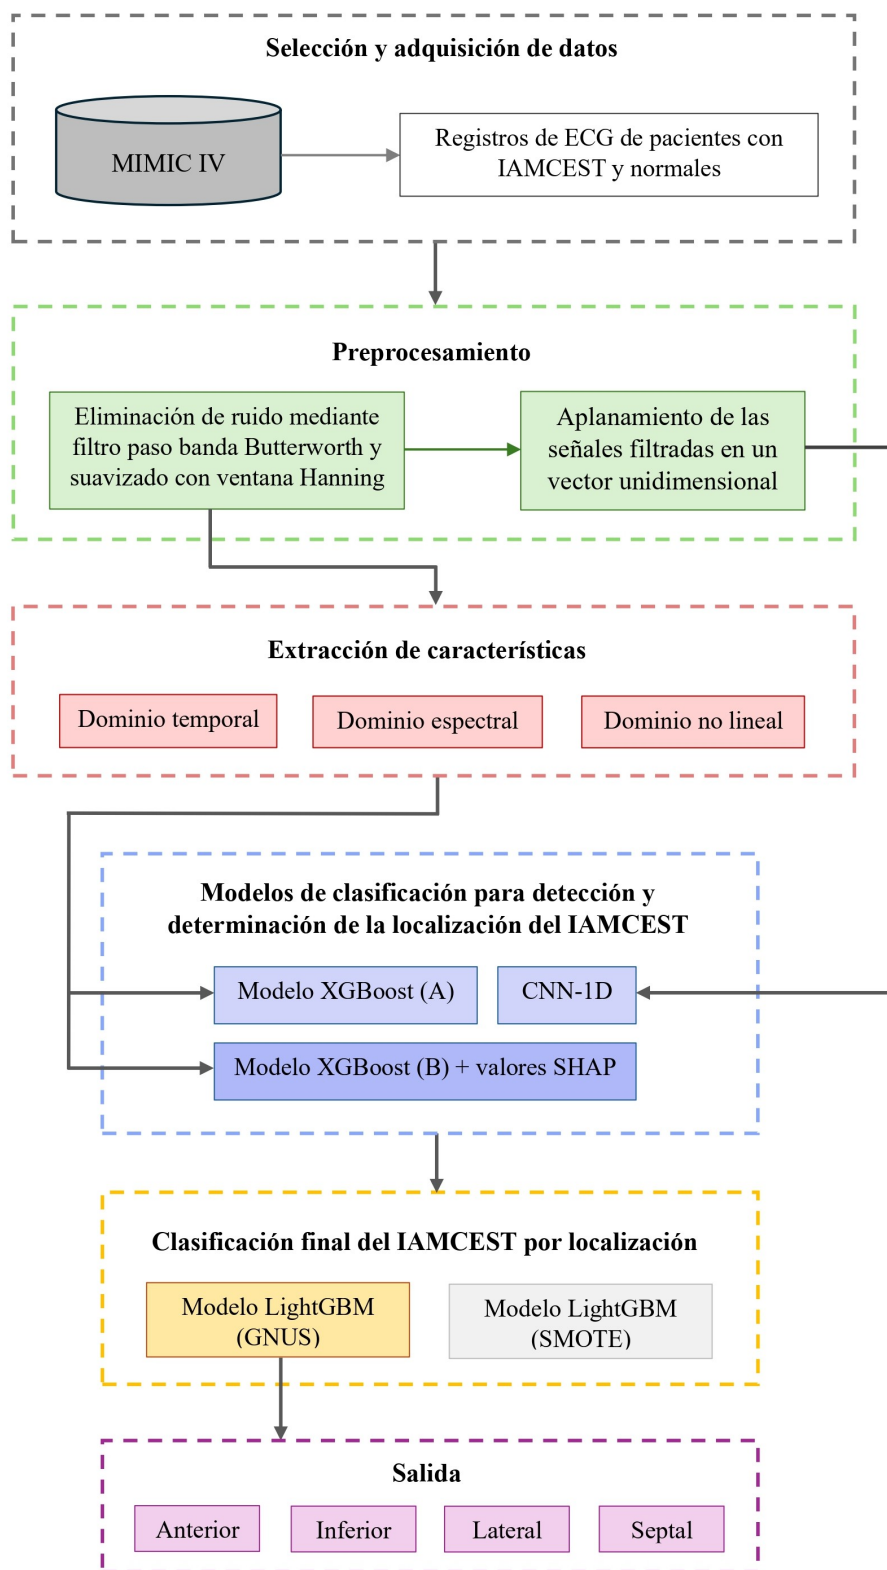


Figura 6.1: Esquema general del proceso de detección y clasificación del IAMCEST

6.1. Etapa 1: Análisis y correlación electrocardiográfica del IAM-CEST

La etapa 1, correspondiente al objetivo de analizar la fisiopatología del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), tuvo como propósito establecer la base anatómica, funcional y eléctrica que sustenta la identificación de los territorios cardíacos comprometidos durante un evento isquémico agudo, así como su relación con las distintas derivaciones del electrocardiograma (ECG). Esta fase se desarrolló mediante una metodología de revisión teórica y validación clínica, estructurada en cuatro actividades principales.

6.1.1. Revisión de literatura sobre fisiopatología del IAMCEST

Para el desarrollo de esta etapa, se llevó a cabo una revisión sistemática de la literatura científica centrada en los mecanismos fisiopatológicos del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST). El propósito de esta revisión fue comprender los procesos que conducen a la isquemia miocárdica y su manifestación electrocardiográfica, con el fin de establecer las bases teóricas necesarias para correlacionar las paredes anatómicas del corazón con las derivaciones del ECG.

La búsqueda de información se realizó en bases de datos científicas especializadas, entre ellas PubMed, Elsevier, ScienceDirect, IEEE Xplore y Google Scholar. Se priorizaron artículos de revisión, guías clínicas y estudios experimentales que abordaran aspectos relacionados con la ruptura de la placa aterosclerótica, la formación del trombo coronario, la cascada isquémica celular y los efectos eléctricos de la necrosis miocárdica.

A partir de esta revisión se consolidaron los conceptos clave de la fisiopatología del IAMCEST, destacando la secuencia de eventos que inicia con la ruptura de la placa ateromatosa, seguida de la activación plaquetaria y la formación del trombo, lo que finalmente provoca la interrupción total del flujo coronario. Asimismo, se identificó la “ventana de viabilidad” del cardiomiocito, estimada en aproximadamente 45 minutos, tras la cual la isquemia se vuelve irreversible y conduce a necrosis transmural del tejido miocárdico.

El análisis bibliográfico permitió establecer la relación entre el daño estructural y los cambios eléctricos observados en el ECG, particularmente la elevación del segmento ST, que constituye el marcador electrocardiográfico característico del IAMCEST. Esta interpretación fisiopatológica sirvió como fundamento para la correlación anatómico-eléctrica desarrollada en las siguientes actividades.

6.1.2. Entrevista con el asesor clínico especialista en cardiología

Con el propósito de validar la información teórica desde una perspectiva clínica, se llevó a cabo una entrevista semiestructurada con el **Dr. Nelson Eduardo Murillo Benítez**, cardiólogo e

internista con reconocida trayectoria en el diagnóstico y tratamiento de patologías cardiovasculares agudas, incluyendo el infarto agudo de miocardio con elevación del segmento ST (IAMCEST).

La entrevista se estructuró con el propósito de obtener una visión clínica sobre la interpretación del electrocardiograma (ECG) en pacientes con Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), y se abordaron los siguientes ejes temáticos:

- Frecuencia y características de los pacientes con infarto atendidos en urgencias.
- Criterios electrocardiográficos utilizados en el diagnóstico de IAMCEST.
- Importancia de la concordancia eléctrica entre derivaciones contiguas para garantizar un diagnóstico preciso.
- Correlación entre las derivaciones alteradas y la pared comprometida del corazón.
- Rol complementario de los biomarcadores cardíacos y la ecocardiografía frente al ECG.

Además, el Dr. Murillo destacó que la correcta interpretación del electrocardiograma debe incluir la evaluación de la concordancia eléctrica y el análisis conjunto de las derivaciones contiguas, lo que permite determinar la localización anatómica del infarto y asociar las alteraciones del segmento ST con la pared cardíaca comprometida, aportando así una validación clínica a los criterios electrocardiográficos empleados en esta investigación.

Su aporte permitió fortalecer la correspondencia entre la evidencia teórica y la práctica clínica, respaldando la selección de derivaciones a analizar en las fases posteriores del estudio y asegurando una interpretación coherente de los patrones electrocardiográficos asociados al IAMCEST.

6.1.3. Sistematización de criterios diagnósticos y umbrales electrocardiográficos

A partir de la entrevista y de las guías internacionales del American College of Cardiology (ACC), la American Heart Association (AHA) y la European Society of Cardiology (ESC), se definieron los criterios electrocardiográficos empleados para el análisis del IAMCEST [39].

Entre ellos se incluyen:

- Elevación nueva del segmento ST en el punto J en al menos dos derivaciones contiguas, con un umbral mayor de 0.1 mV, salvo en V2 y V3.
- En las derivaciones V2 y V3, los umbrales varían según sexo y edad:
 - Mayor de 0.2 mV para hombres mayores de 40 años.
 - Mayor de 0.25 mV para hombres menores de 40 años.
 - Mayor de 0.15 mV para mujeres.

- Concordancia eléctrica entre derivaciones que representen la misma zona anatómica.

Estos criterios sirvieron como referencia para construir una tabla de correlación anatómico-electrocardiográfica, donde se relacionan las derivaciones alteradas con las arterias coronarias implicadas y las zonas miocárdicas comprometidas, como se muestra en la Tabla 6.1.

6.1.4. Correlación anatómica y análisis de regiones miocárdicas

Finalmente, se estableció la correspondencia entre las derivaciones del ECG y las regiones miocárdicas comprometidas mediante la elaboración de una matriz de concordancia anatómico-electrocardiográfica, que permitió asociar cada grupo de derivaciones con la región del miocardio afectada, integrando la información recopilada en las fases previas.

Tabla 6.1: Correlación entre la localización del IAMCEST y las derivaciones afectadas (Fuentes: [95], [96])

Ubicación IAMCEST	Derivaciones afectadas
Pared Lateral	aVL, I, V5, V6
Pared Anterior	V2, V3, V4
Pared Septal	V1, V2
Pared Inferior	aVF, II, III

La información presentada en la Tabla 6.1 permitió establecer la relación entre las derivaciones electrocardiográficas y las regiones del miocardio afectadas durante un evento de IAMCEST. Esta correspondencia sirvió como base para la interpretación posterior de los registros electrocardiográficos, facilitando la identificación de los patrones de elevación del segmento ST según la pared cardíaca comprometida.

La elaboración de esta tabla fue el resultado de la integración entre la evidencia teórica revisada, los criterios clínicos validados por el asesor especialista en cardiología y las recomendaciones de las guías internacionales, garantizando una correlación precisa y respaldada desde el punto de vista científico y clínico.

6.2. Etapa 2: Obtención y preprocesamiento de base de datos

En esta etapa, se da cumplimiento al objetivo específico de estructurar una base de datos a partir de fuentes públicas que contenga registros de señales ECG de pacientes con trazos normales y de pacientes diagnosticados con Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST). Para ello, se centró la atención en actividades concretas de búsqueda, selección, validación, visualización y preprocesamiento de los datos.

6.2.1. Búsqueda de bases de datos de señales ECG

Para la construcción de la base de datos, se realizó un estudio exploratorio y de revisión de literatura sobre las bases de datos de señales ECG utilizadas en investigaciones relacionadas con el infarto de miocardio. Este análisis tuvo como propósito identificar las fuentes más confiables y ampliamente utilizadas en la comunidad científica, con el fin de garantizar que la base de datos recopilada fuera representativa, completa y adecuada para estudios de procesamiento de señales y aprendizaje automático.

Se exploraron diversas fuentes públicas y repositorios académicos como PubMed, IEEE DataPort y PhysioNet. En estas plataformas se evaluó la disponibilidad y accesibilidad de los registros, así como la documentación y los metadatos asociados a cada conjunto de datos. Entre las características más relevantes consideradas se incluyen: el número total de registros y la distribución entre trazos normales y patológicos, el tipo y número de derivaciones registradas, la duración de los registros y la frecuencia de muestreo. Además, se consideró si los registros contaban con anotaciones o etiquetas de diagnóstico disponibles, lo cual permitió determinar su utilidad para la construcción de una base de datos estructurada y adecuada para análisis posteriores.

Para complementar el estudio exploratorio, se resumió la información más relevante de cada base de datos en la Tabla 6.2. Esta tabla muestra las principales características, incluyendo la condición clínica, número de derivaciones, duración y frecuencia de muestreo.

Tabla 6.2: Comparativa de bases de datos de señales ECG

Base de datos	Condición clínica	Número de derivaciones	Duración	Frecuencia de muestreo (Hz)
PTB-XL	Infarto de miocardio Cambios ST/T Perturbación de conducción Hipertrofia	12	10 s	500
European ST-T	Episodios isquémicos	7	2 h	250
MIMIC-IV	Diferentes cardiopatías	12	10 s	500
Long-Term ST	Episodios isquémicos y no isquémicos de ST	2-3	21-24 h	250
MIT-BIH	Arritmias cardíacas	2	30 min	360
Desafío de ECG de 12 derivaciones de Georgia (GA12ECG)	Diferentes cardiopatías	12	10 s	500

6.2.2. Selección y validación de base de datos

Tras la evaluación comparativa de las distintas bases de datos de señales ECG, se seleccionó MIMIC-IV como fuente principal para la construcción de la base de datos de este estudio. Esta decisión se fundamentó en la alta calidad de sus registros, la disponibilidad completa de las 12 derivaciones, la uniformidad en el formato de almacenamiento y el amplio volumen de datos disponibles. El módulo MIMIC-IV contiene aproximadamente 800000 registros de ECG obtenidos de cerca de 160000 pacientes, recopilados entre 2008 y 2019 en el Beth Israel Deaconess Medical Center (BIDMC) [97], [98]. Cada registro está acompañado de información generada automáticamente por el sistema de adquisición, que incluye parámetros de medición y reportes diagnósticos preliminares.

Los registros electrocardiográficos fueron obtenidos en el marco de la atención clínica rutinaria. Se estima que alrededor del 55% de los registros se asocian a ingresos hospitalarios y cerca del 25% a consultas en el servicio de urgencias, lo que proporciona un contexto clínico enriquecido para el estudio de eventos cardiovasculares en distintos niveles de gravedad. Asimismo, las señales fueron adquiridas mediante equipos de diferentes fabricantes, entre ellos Burdick/Spacelabs, Philips y General Electric, lo cual aporta heterogeneidad tecnológica y contribuye a mantener una calidad de registro consistente en todo el conjunto de datos.

La confiabilidad de esta base de datos ha sido respaldada por diversas investigaciones recientes. Verma et al. desarrollaron un modelo basado en redes neuronales de picos (Spiking Neural Networks, SNN) para la detección de arritmias cardíacas, alcanzando una precisión de 0.97 y un F1-Score de 0.95 en sus experimentos. Por su parte, Zhao et al. propusieron el modelo DRL-ECG-HF, fundamentado en aprendizaje de refuerzo profundo, orientado al diagnóstico automatizado de insuficiencia cardíaca, el cual abordó eficazmente el desequilibrio de clases mediante una estrategia de reproducción de experiencias priorizada e integró técnicas de interpretabilidad basadas en SHapley Additive exPlanations (SHAP). En su validación, reportaron un AUROC de 0.90, un F1 Score de 0.58 y una media geométrica de 0.80, superando los métodos convencionales de clasificación de series temporales [99], [100].

Estos antecedentes confirman que la base de datos seleccionada constituye un recurso validado y confiable para el desarrollo de modelos de inteligencia artificial orientados al análisis automatizado de electrocardiogramas. La amplia adopción del módulo MIMIC-IV y los resultados obtenidos en diversas arquitecturas de aprendizaje profundo evidencian su robustez y representatividad clínica. Asimismo, su estructura organizada y la disponibilidad pública de los datos facilitan la replicabilidad de experimentos y la trazabilidad metodológica. En este sentido, su uso en el presente trabajo garantiza la fiabilidad de los registros y proporciona una base sólida para la implementación y validación de algoritmos de clasificación y detección de eventos cardíacos.

6.2.3. Visualización de las señales ECG

Para la visualización de los registros electrocardiográficos se exploró la organización del módulo MIMIC-IV, disponible en el repositorio PhysioNet. La estructura de la base de datos se ilustra en el Listing 6.1, donde se observa la jerarquía de carpetas que agrupa los estudios por sujetos (subjects). Cada sujeto se encuentra identificado por un código único (por ejemplo, p10001725 o p10023771), y cada uno puede contener uno o varios estudios asociados (studies).

Los identificadores de estudio son generados de forma aleatoria y no guardan relación con el orden cronológico de adquisición. Cada estudio está conformado por un par de archivos con el mismo nombre base, pero con extensiones .hea y .dat, los cuales en conjunto constituyen el registro WFDB. El archivo .hea contiene la información de cabecera, como la frecuencia de muestreo, el número de derivaciones y las etiquetas de los canales; mientras que el archivo .dat almacena los valores binarios de las señales de ECG correspondientes a cada derivación.

```
1 Files/  
2 |-- p1000/  
3     |-- p10001725/  
4         |-- s41420867/  
5             |-- 41420867.dat  
6             |-- 41420867.hea
```

Listing 6.1: Estructura de directorios de MIMIC-IV

Adicionalmente, la base de datos incluye archivos complementarios en formato Excel, que contienen las mediciones automáticas generadas por los equipos clínicos. Este archivo recopila información cuantitativa como los intervalos RR, los inicios y finales del complejo QRS, así como los parámetros de filtrado y ancho de banda empleados durante la adquisición de la señal. Asimismo, incorpora las columnas report_0 a report_17, las cuales almacenan los textos del reporte diagnóstico automático emitido por el equipo, donde se consignan las observaciones interpretativas del sistema, tales como la presencia de arritmias cardíacas o, en el contexto de este trabajo de grado, los casos de IAMCEST y los registros de ECG normales. Cabe resaltar que no todos los registros contienen necesariamente los 17 reportes, sino que el número de columnas con texto varía según la información generada automáticamente para cada estudio; en algunos casos, se observan columnas vacías intercaladas entre reportes con contenido.

El proceso de carga y visualización de los registros se llevó a cabo en Visual Studio Code, importando la carpeta correspondiente a cada sujeto y seleccionando los archivos .hea y .dat asociados al estudio de interés. Para la lectura e interpretación de los registros se emplearon las librerías WFDB y NumPy de Python, las cuales permiten decodificar los archivos binarios, extraer la información contenida en los encabezados y graficar las señales electrocardiográficas junto con sus respectivas derivaciones. En la Figura 6.2 se presenta un ejemplo de la visualización correspondiente al registro de un paciente.



Figura 6.2: Señales ECG de la base de datos MIMIC-IV

6.2.4. Preprocesamiento

Previo al preprocesamiento, se realizó una reestructuración y depuración de la base de datos MIMIC-IV-ECG, con el fin de organizar los registros electrocardiográficos (ECG) por diagnóstico y asegurar su compatibilidad con las etapas posteriores del análisis computacional. De esta reestructuración se obtuvo una base de datos propia, ajustada a las necesidades específicas del proyecto.

Una vez estructurada la base de datos, se procedió a la etapa 2, cuyo propósito fue preparar las señales ECG para su análisis y procesamiento, asegurando la calidad y estabilidad de los datos mediante la eliminación de ruido y artefactos, así como la estandarización de las condiciones de registro. Este procedimiento permitió obtener señales filtradas, limpias y comparables entre derivaciones, de manera que los patrones eléctricos analizados reflejaran con precisión la actividad cardíaca

real, especialmente aquellos asociados al infarto agudo de miocardio con elevación del segmento ST (IAMCEST).

6.2.4.1. Construcción y depuración de la base de datos de registros ECG

El proceso de conformación de la base de datos se desarrolló en cuatro etapas principales:

- (a) **Exploración inicial y clasificación de etiquetas.** Durante la revisión preliminar de los reportes diagnósticos automáticos incluidos en los archivos complementarios del módulo MIMIC-IV, se identificó una alta variabilidad en la nomenclatura utilizada para describir las alteraciones asociadas al IAMCEST. Los reportes presentaban múltiples formas textuales para referirse al mismo evento fisiopatológico, reflejando diferencias en la localización anatómica del infarto (anterior, inferior, lateral o septal), pero manteniendo una interpretación clínica equivalente.

Con el fin de estandarizar la información y garantizar coherencia semántica, se realizó una agrupación unificada de términos diagnósticos bajo la etiqueta general IAMCEST. De manera complementaria, los registros con actividad eléctrica cardíaca normal fueron clasificados bajo la etiqueta NORMAL, considerando los diagnósticos automáticos que indicaban “Normal ECG”.

- (b) **Filtrado y conformación del conjunto de datos.** Una vez definidos los criterios de clasificación y analizado el contenido de las columnas `report0-report17`, se procedió al filtrado manual de los registros, empleando el archivo complementario en formato Excel proporcionado por la base de datos seleccionada. Durante este proceso, se revisaron de manera sistemática las etiquetas diagnósticas presentes en cada columna, seleccionando exclusivamente aquellas que correspondían a las categorías IAMCEST y Normal.

Como resultado de esta fase, se identificaron 8868 registros con diagnóstico IAMCEST y 110440 registros normales, conformando un conjunto de datos amplio y clínicamente representativo.

- (c) **Balanceo de clases.** Dado el desequilibrio entre las categorías, se aplicó un submuestreo aleatorio sobre la clase mayoritaria (Normal) con el propósito de equilibrar el conjunto de datos. El conjunto final quedó compuesto por:

- 8868 registros etiquetados como IAMCEST.
- 8868 registros etiquetados como Normales.

- (d) **Reestructuración y organización de archivos.** Posteriormente, los registros seleccionados fueron reorganizados y renombrados para facilitar su manipulación en las etapas de preprocesamiento y entrenamiento de modelos. Se estableció una carpeta principal con dos subcarpetas:

- ECG_IAMCEST/
- ECG_NORMAL/

Cada una contiene los archivos `.hea` (metadatos) y `.dat` (valores crudos). Los archivos fueron renombrados secuencialmente (`s0001–s8868`), garantizando correspondencia directa entre clases. Esta estructura jerárquica permite una gestión eficiente de los registros y su uso en las fases posteriores del estudio.

6.2.4.2. Filtrado y optimización de la señal

Con el fin de suprimir interferencias tanto de alta como de baja frecuencia presentes en los registros electrocardiográficos, se aplicó un filtro paso banda Butterworth de cuarto orden, con frecuencias de corte en 0.5 Hz (pasa alta) y 40 Hz (pasa baja). Tradicionalmente, las guías diagnósticas para registros de 12 derivaciones establecen un rango de respuesta entre 0.05 y 150 Hz, diseñado para capturar la totalidad de los componentes del ciclo cardíaco. No obstante, este rango tan amplio puede introducir artefactos asociados a movimientos musculares, interferencia de red eléctrica y desplazamientos de línea base, lo que compromete la calidad del trazado y dificulta el análisis automatizado de segmentos críticos como el ST. En particular, para aplicaciones centradas en la detección de isquemia y del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), la fidelidad de la morfología del ST resulta prioritaria sobre la preservación de componentes de muy alta frecuencia. Según Sörnmo y Laguna [101], establecer una frecuencia de corte inferior en torno a 0.5–0.67 Hz permite eliminar desplazamientos lentos de la línea base generada por movimientos respiratorios, variaciones de impedancia y desplazamientos de electrodos, sin alterar la forma ni la pendiente del segmento ST. Por su parte, Ricciardi et al. [102] evidenciaron que una frecuencia de corte superior de 40 Hz maximiza la proporción de registros con calidad diagnóstica, aumentando de 54.6% a 93.4% los ECG aptos para interpretación clínica, sin distorsionar el trazado original. Este límite superior permite eliminar interferencias electromiográficas y ruido de alta frecuencia, sin comprometer la amplitud ni la forma de los componentes de interés (P, QRS, ST y T).

Por ello, la adopción del rango 0.5–40 Hz representa un compromiso óptimo entre la eliminación de ruido y la preservación de información fisiológicamente relevante. Dicho rango ha sido ampliamente validado en contextos clínicos y de investigación centrados en el diagnóstico de IAMCEST y en la interpretación automática del ECG. El filtro Butterworth fue seleccionado debido a su respuesta de magnitud suavemente monótona, sin ondulaciones en la banda pasante ni en la banda atenuada, lo cual asegura una transición estable y una mínima distorsión de fase. La implementación se realizó en Python mediante las funciones `butter()` y `filtfilt()` del paquete SciPy, aplicadas en ambas direcciones para evitar desfases y preservar la morfología temporal de los complejos QRS y del segmento ST.

6.2.4.3. Suavizado de la señal

Posteriormente, las señales filtradas fueron sometidas a un suavizado mediante ventana Hanning, cuyo tamaño se ajustó proporcionalmente a la frecuencia de muestreo de cada registro. Este procedimiento permitió atenuar pequeñas oscilaciones residuales y ruido de alta frecuencia que no fueron eliminados completamente por el filtrado paso banda, garantizando al mismo tiempo que no

se alteraran los componentes morfológicos esenciales del ECG, como las ondas P, los complejos QRS y el segmento T. La ventana se normalizó y se aplicó mediante convolución discreta, asegurando que la amplitud de la señal se mantuviera consistente y evitando la introducción de artefactos. Como resultado, se logró una mayor estabilidad de la línea base y una mejor legibilidad visual de las ondas.




Figura 6.3: Señales ECG de la derivada II antes y después del preprocesamiento

La Figura 6.3 muestra un ejemplo de la derivada II de un registro ECG antes y después del preprocesamiento. En la señal sin procesar se observan alteraciones que pueden dificultar su análisis, mientras que la señal procesada presenta una mayor estabilidad y claridad, facilitando la identificación de los patrones electrocardiográficos relevantes. Esta comparación ilustra el efecto general del preprocesamiento en la mejora de la calidad de los datos, asegurando su consistencia para el posterior análisis computacional.

6.2.4.4. Aplanamiento de las señales

Tras el preprocesamiento de los registros ECG mediante filtrado paso banda y suavizado, los archivos de examen seleccionados fueron sometidos a un aplanamiento de señales. Cada registro, compuesto por 12 derivaciones simultáneas, fue transformado en un vector unidimensional mediante la concatenación secuencial de todas las derivaciones, implementada en Python utilizando la función `flatten()` de NumPy. Este procedimiento permitió integrar todas las derivaciones en una sola secuencia lineal, conservando la continuidad temporal de la señal y la morfología de sus compo-

entes principales (ondas P, complejos QRS y segmento T). El objetivo de este aplanamiento fue permitir el análisis unidimensional de la señal, preservando las variaciones de amplitud y los cambios temporales que reflejan la actividad eléctrica cardíaca. Este enfoque resulta especialmente útil para estudiar patrones asociados al IAMCEST, ya que las alteraciones patológicas se manifiestan como modificaciones en la amplitud, la pendiente y la forma de los distintos componentes del ECG a lo largo del tiempo.




Figura 6.4: Representación unidimensional de señales ECG aplanadas para paciente normal y paciente con IAMCEST

La Figura 6.4 muestra un ejemplo comparativo de señales aplanadas de dos pacientes: uno con ECG normal y otro con IAMCEST. Se puede observar cómo, a pesar de consolidar las 12 derivaciones en una sola secuencia, se preservan las diferencias morfológicas relevantes entre un registro normal y uno patológico. Esta visualización evidencia que el aplanamiento mantiene la información crítica para la detección de alteraciones asociadas al infarto.

Una vez aplanadas, las señales fueron almacenadas en directorios separados por clase: IAMCEST y NORMAL. Es importante señalar que esta etapa de aplanamiento se aplicó únicamente para el uso de modelos de redes neuronales 1D (CNN-1D), y no fue necesaria para otras etapas de caracterización de los registros. Cada archivo conservó la correspondencia con su registro original, lo que facilitó la gestión de grandes volúmenes de datos y aseguró la integridad fisiológica de la

información. Esta estructura permitió un manejo eficiente de los registros y preparó los datos para un análisis sistemático, garantizando que los patrones eléctricos de interés permanecieran íntegros y accesibles para esta etapa del estudio.

6.3. Etapa 3: Extracción de características de las señales ECG

El desarrollo de esta etapa tuvo como objetivo extraer las características relevantes de los registros de ECG para el mejoramiento del desempeño de los algoritmos de aprendizaje automático en la detección del IAMCEST. Se evaluaron diferentes estrategias, desde la detección de picos característicos (ondas P, QRS y T) hasta enfoques espectrales. Sin embargo, algunos métodos presentaron limitaciones en la consistencia de los resultados debido a la variabilidad interpaciente y la presencia de artefactos en las señales.

Por este motivo, se adoptó un enfoque integral que combina tres dominios complementarios: temporal, frecuencial y no lineal (complejo). En total se consideraron 31 características, tomando como referencia el estudio *“Diagnosis of sudden cardiac arrest using principal component analysis in automated external defibrillators”* [63].

Durante la ejecución del proceso, se identificaron registros ECG con valores indefinidos (NaN) o iguales a cero en la matriz de características, los cuales afectaban la consistencia de los resultados. Este comportamiento se atribuyó principalmente a múltiples factores, entre los cuales destacan: derivaciones no cargadas correctamente en el archivo fuente, presencia de segmentos planos con valores en cero o fallos en la adquisición del electrocardiograma. Dichas condiciones impidieron el cálculo adecuado de las métricas, generando la ausencia total o parcial de información en determinadas derivaciones.

Con el fin de garantizar la validez y calidad de los datos empleados en las etapas posteriores del estudio, estos registros fueron excluidos del análisis. En la Tabla 6.3 se presenta el resumen del proceso de depuración aplicado a la base de datos, indicando la cantidad inicial de registros ECG por clase, el número de registros ecg descartados por inconsistencias y la cantidad final utilizada para el modelado.

Tabla 6.3: Depuración de registros ECG no válidos en la extracción de características

Clase	Registros iniciales	Registros descartados	Registros finales
Normal (0)	8868	18	8850
IAMCEST (1)	8868	216	8652
Total	17736	234	17502

Posteriormente, se verificó la integridad de las variables calculadas, identificando que tres de las

características: reconstrucción del espacio de fase (PSre), entropía muestral (SEnt) y entropía difusa (FEnt), generaban valores indefinidos o presentaban valores constantes, lo que limitaba su capacidad discriminativa entre clases. Este comportamiento se atribuyó a la presencia de segmentos planos o baja variabilidad en algunas derivaciones, lo cual impidió el cálculo adecuado de medidas no lineales de complejidad, así como a la generación de resultados homogéneos en registros con morfología muy regular. Por tal motivo, estas métricas fueron excluidas del conjunto final de características utilizadas para el entrenamiento de los modelos.

6.3.1. Implementación computacional y generación de la base de características

Con el propósito de obtener un conjunto de datos estructurado que represente de manera cuantitativa la información contenida en los registros de ECG, se implementó un script de Python en VS code que automatiza el proceso de extracción de características a partir de las señales previamente preprocesadas. Este procedimiento se aplicó tanto a los registros de normales como a aquellos diagnosticados con IAMCEST, provenientes de la base de datos reconstruida, organizada en dos carpetas: ECG_NORMAL y ECG_IAMCEST.

El código desarrollado permite recorrer de forma iterativa los registros de cada paciente, aplicando para cada derivación el cálculo de métricas relevantes en distintos dominios. Posteriormente, se establecieron funciones específicas destinadas a operaciones recurrentes dentro del proceso de análisis de las señales, entre ellas el cálculo de la densidad espectral de potencia, la entropía de Rényi, la entropía basada en wavelets y la estimación de la frecuencia dominante, entre otras. Estas funciones fueron integradas en tres diccionarios principales que agrupan las características según su dominio de análisis.

Como resultado, se generó un archivo en formato CSV que consolida de manera estructurada todas las métricas calculadas a partir de las distintas derivaciones de cada paciente. En total, se recopilieron 336 características por registro, producto de combinar 28 métricas con las 12 derivaciones del ECG (I, II, III, aVR, aVL, aVF, V1–V6). Cada columna del archivo corresponde a una característica identificada por el nombre de la derivación y el descriptor de la métrica, lo que facilita su identificación y análisis posterior. Además, se incorporaron los campos “Paciente” y “Clase”, este último representado mediante una codificación binaria que distingue las categorías analizadas. Con ello, el conjunto de datos quedó estructurado para las etapa de entrenamiento de los modelos de aprendizaje automático.

6.4. Etapa 4: Entrenamiento de los modelos de aprendizaje automático

En esta etapa se abordó el proceso de entrenamiento de los modelos de aprendizaje automático supervisado, utilizando diferentes estrategias, entre ellas, utilizar las características previamente extraídas de los registros electrocardiográficos. El objetivo principal fue construir sistemas capaces

de identificar de manera automática los casos de infarto agudo de miocardio con elevación del segmento ST (IAMCEST) y determinar su localización anatómica a partir de los patrones presentes en las señales.

Para definir la estrategia de modelado, se realizó un análisis exhaustivo de enfoques recientes en inteligencia artificial aplicada al diagnóstico cardiológico. Este análisis se centró en identificar algoritmos que han demostrado un rendimiento superior en tareas de clasificación de señales ECG, priorizando aquellos que equilibran precisión, interpretabilidad y eficiencia computacional. Entre los métodos destacados se encuentran los basados en árboles de decisión optimizados, como Random Forest, XGBoost y LightGBM, los cuales sobresalen por su capacidad para manejar conjuntos de datos de alta dimensionalidad, reducir el sobreajuste y ofrecer resultados interpretables. De manera complementaria, se exploraron redes neuronales convolucionales (CNN), ampliamente reconocidas por su capacidad para extraer automáticamente características jerárquicas, capturando tanto las variaciones morfológicas (como elevaciones del segmento ST) como las dinámicas temporales (como fluctuaciones en la frecuencia cardíaca) presentes en las señales ECG. Este enfoque dual permitió evaluar un espectro amplio de algoritmos, desde métodos tradicionales hasta técnicas avanzadas de aprendizaje profundo, con el objetivo de seleccionar los más adecuados para las tareas específicas de detección y localización del IAMCEST.

A partir de los lineamientos definidos en esta etapa, se estructuraron tres actividades principales que se desarrollan a continuación. La primera aborda la creación de modelos de clasificación orientados a la detección automática del IAMCEST. La segunda presenta la implementación de un modelo de determinación anatómica basado en valores SHAP, empleado para estimar la región afectada. Finalmente, la tercera describe el entrenamiento del modelo final de clasificación por localización anatómica, que consolida los resultados obtenidos en las fases previas.

6.4.1. Desarrollo de modelos de clasificación para la detección de IAMCEST

Durante esta actividad se implementaron dos enfoques de clasificación orientados a la detección automática del infarto agudo de miocardio con elevación del segmento ST (IAMCEST), con el propósito de comparar estrategias complementarias que fortalecieran la capacidad de identificación del evento. Ambos modelos fueron entrenados para distinguir entre ECG normales y ECG que evidencian la presencia de un IAMCEST. Para ello, el conjunto de datos se dividió en un 80 % para entrenamiento y un 20 % para prueba, garantizando la evaluación del desempeño sobre registros de ECG no utilizados en el entrenamiento.

A continuación, se describen los dos modelos diseñados como parte de esta fase de entrenamiento:

- **XGBoost:** El modelo se configuró utilizando el archivo consolidado de características obtenido en la etapa anterior. Este archivo integra 336 variables por registro, resultado de la extracción de 28 métricas para cada una de las 12 derivaciones del ECG. De esta manera, la matriz de entrada del clasificador quedó conformada por 17502 registros, cada uno representado por un

vector de 336 características (matriz 17502×336). La variable objetivo correspondió a la columna “Clase”, codificada en formato binario para distinguir entre registros normales (clase 0, 8652 registros) y casos asociados a IAMCEST (clase 1, 8850 registros).

Para la implementación del modelo, se estableció una profundidad máxima de los árboles de decisión de 6, una tasa de aprendizaje de 0.1 y un total de 500 estimadores. Además, se incorporaron términos de regularización L1 y L2 con valores de 0.6 y 0.9, respectivamente. Estos parámetros se seleccionaron tras un proceso iterativo de ajuste, en el cual se evaluaron múltiples combinaciones de valores con el fin de identificar la configuración más estable y adecuada para el modelo. Durante esta etapa exploratoria, se analizaron las métricas de desempeño obtenidas con el objetivo de identificar configuraciones que minimizaran el sobreajuste sin comprometer la capacidad predictiva.

- **CNN-1D:** Se implementó un modelo de red neuronal convolucional unidimensional, diseñado para procesar directamente las señales ECG aplanadas obtenidas en la etapa de preprocesamiento. Este enfoque permite a la red capturar patrones temporales y variaciones de amplitud a lo largo de toda la señal, aspectos esenciales para la identificación de alteraciones electrocardiográficas asociadas al IAMCEST.

Para el entrenamiento de la CNN-1D, se desarrolló un generador de datos personalizado, capaz de cargar los registros ECG aplanados en lotes (batches) de tamaño configurable. Esta estrategia optimiza el uso de memoria y facilita un entrenamiento eficiente sobre conjuntos de datos de gran tamaño. Las etiquetas de clase se codificaron en formato categórico binario (IAMCEST vs NORMAL) mediante un LabelEncoder, asegurando compatibilidad con la función de pérdida categórica empleada durante el entrenamiento. Adicionalmente, el generador incorpora un mecanismo de aleatorización (shuffle) al final de cada época, evitando que la red aprenda patrones relacionados con el orden de los datos y favoreciendo su capacidad de generalización. Esta metodología resulta especialmente útil para señales largas y multiderivación aplanadas, ya que evita la necesidad de cargar todos los registros en memoria de manera simultánea y preserva la secuencia temporal de la señal, manteniendo las relaciones morfológicas críticas entre ondas y segmentos del ECG. En consecuencia, el uso del generador garantiza un entrenamiento eficiente, reproducible y robusto de la CNN-1D, maximizando su capacidad para detectar patrones indicativos de IAMCEST en registros electrocardiográficos complejos.

6.4.2. Implementación del modelo de determinación de la localización anatómica del IAMCEST mediante valores SHAP

Tras la detección inicial de registros ECG con IAMCEST mediante los modelos de clasificación binaria, se implementó un segundo modelo XGBoost destinado a la asignación anatómica del infarto. Para esta etapa, se mantuvo la misma matriz de características utilizada previamente, integrada por 336 variables derivadas de 28 métricas calculadas para cada una de las 12 derivaciones del ECG. Sin embargo, los hiperparámetros del modelo fueron ajustados para optimizar la estabilidad y precisión

en la evaluación de la contribución de cada característica; este ajuste consistió en reducir la velocidad de aprendizaje, aumentar el número de árboles y fortalecer la regularización, permitiendo que el modelo aprendiera de manera más gradual y controlada. De esta forma, se redujo la variabilidad en las predicciones y se obtuvo un comportamiento más consistente en los valores SHAP utilizados para determinar la relevancia relativa de cada métrica.

En este segundo modelo se utilizaron los siguientes parámetros: una profundidad máxima de los árboles de 6 niveles, una tasa de aprendizaje de 0.05, un total de 1200 estimadores y regularización L1 y L2 con valores de 0.5 y 1.0 respectivamente. Estas modificaciones, en comparación con el primer modelo (profundidad de 6, tasa de aprendizaje 0.1, 500 estimadores, regularización L1=0.6 y L2=0.9), permiten que el modelo capture relaciones más finas entre las métricas de las derivaciones, generando valores SHAP más estables y precisos que reflejan la relevancia relativa de cada variable en la determinación de la localización del infarto.

Posteriormente, las derivaciones fueron agrupadas de acuerdo con su correspondencia anatómica en las regiones anterior, inferior, lateral y septal. Estos grupos fueron organizados como listas dentro de un diccionario en Python, mientras que las reglas de contigüidad se estructuraron como listas de tuplas, las cuales se presentan en la Tabla 6.4. Estas reglas permiten identificar pares de derivaciones contiguas y garantizan coherencia fisiológica en la determinación de la localización del IAMCEST. Cabe destacar que la correlación entre la ubicación anatómica del infarto y las derivaciones afectadas fue establecida durante la primera etapa de análisis y validación de los registros, lo que proporcionó un marco de referencia clínicamente fundamentado para la interpretación de los valores SHAP.

Tabla 6.4: Grupos de derivaciones y pares contiguos utilizados en la detección del IAMCEST

Región	Derivaciones del grupo	Pares contiguos
Lateral	I, aVL, V5, V6	(I, aVL), (V5, V6)
Anterior	V2, V3, V4	(V2, V3), (V3, V4)
Septal	V1, V2	(V1, V2)
Inferior	II, III, aVF	(II, III), (III, aVF), (aVF, II)

Para interpretar la relevancia de cada derivación en la predicción del modelo XGBoost, se implementó un procedimiento que suma las contribuciones individuales de todas las métricas asociadas a cada derivación, previamente calculadas mediante valores SHAP. Para ello, se definió una función que identifica la derivación principal de cada variable y, posteriormente, se agregaron las contribuciones absolutas de todas las métricas pertenecientes a la misma derivación, generando así una matriz de contribuciones por derivación.

Con el fin de garantizar la comparabilidad entre pacientes, se llevó a cabo una normalización inter-paciente de las contribuciones por derivación mediante el cálculo de z-score. Para ello, se identificaron primero los registros normales (clase 0) y, sobre estos, se calcularon las medias y desviaciones estándar de cada derivación, estableciendo así un patrón de referencia. Estos parámetros

fueron fundamentales para estandarizar las contribuciones de todos los pacientes, de manera que cada valor representara cuántas desviaciones estándar se encontraba respecto al promedio normal de la derivación correspondiente. Posteriormente, se aplicó esta normalización a todos los registros, incluyendo tanto pacientes normales como aquellos con IAMCEST, obteniendo así una matriz de contribuciones normalizadas por derivación. Este procedimiento permitió minimizar el efecto de variaciones individuales, facilitando la detección de derivaciones con alteraciones significativas y asegurando que los resultados fueran comparables entre diferentes sujetos. La matriz final incluyó, para cada paciente, las contribuciones normalizadas, la clase correspondiente y el identificador del paciente, constituyendo la base sólida para la posterior asignación anatómica del IAMCEST.

En primer lugar, para determinar la localización anatómica afectada en cada registro correspondiente a la clase IAMCEST, se realizó un análisis individual de las derivaciones evaluando su nivel de contribución a la predicción del modelo mediante los valores normalizados (z-score), derivados de las magnitudes SHAP. Con base en estos valores se aplicaron los umbrales originales, definidos para identificar derivaciones con diferente grado de relevancia. Así, aquellas con un z-score superior a 1.3 se clasificaron como de contribución fuerte, al presentar un impacto marcado en la predicción y una asociación clara con la zona afectada. Por su parte, las derivaciones con valores entre 1.0 y 1.3 se catalogaron como de contribución moderada, asociada a zonas adyacentes o a una afectación parcial.

En los casos en que no se cumplían los criterios de contigüidad anatómica entre derivaciones, condición necesaria para garantizar coherencia fisiológica en la detección, se aplicaron umbrales relajados (1.0 para contribuciones fuertes y 0.8 para moderadas), con el propósito de capturar alteraciones más sutiles sin comprometer la sensibilidad del sistema. Estos valores fueron determinados mediante un proceso de calibración iterativa, en el que los umbrales se ajustaron progresivamente hasta lograr una correspondencia óptima entre la respuesta del modelo y los patrones electrocardiográficos esperados en cada región del miocardio. Posteriormente, se incorporó un procedimiento de verificación de contigüidad entre derivaciones, orientado a garantizar la coherencia anatómica de las regiones identificadas. La implementación de esta función auxiliar, que evalúa las derivaciones que superan los umbrales definidos y determina las zonas con patrones compatibles con la distribución fisiológica del IAMCEST.

En segundo lugar, se implementó el procedimiento principal encargado de asignar la región anatómica afectada en cada registro. En esta etapa, para cada paciente, se iteraron los valores normalizados por derivación y se identificaron aquellas derivaciones que superaban los umbrales definidos. Posteriormente, mediante la función auxiliar de contigüidad, se evaluó si dichas derivaciones cumplían las reglas de contigüidad dentro de cada región (anterior, inferior, lateral y septal).

Cuando una zona presentaba pares de derivaciones contiguas con contribuciones fuertes o combinaciones de una fuerte y una moderada, esta se clasificaba como la región afectada bajo los umbrales originales. En caso de que no se cumplieran dichas condiciones, el algoritmo aplicaba automática-

mente los umbrales relajados, otorgando una segunda oportunidad de detección a derivaciones con contribuciones más discretas. Si aun así no se lograba identificar una zona contigua válida, se recurría a una estrategia de respaldo (fallback), basada en el cálculo de la contribución global de todas las derivaciones por región, seleccionando aquella con la mayor suma total como la más afectada.

Finalmente, para los registros pertenecientes a la clase IAMCEST, los resultados se almacenaron en una estructura tabular que incluía las derivaciones clasificadas como fuertes y moderadas, la zona anatómica afectada y la estrategia o método empleado en su detección. Esta metodología permitió obtener una asignación anatómica coherente, robusta y clínicamente interpretable, enfocada en la caracterización del infarto agudo de miocardio con elevación del segmento ST y en la correspondencia entre la respuesta del modelo y la fisiología cardíaca subyacente. Todo el proceso descrito desde la evaluación de los valores SHAP hasta la selección final de la zona afectada se resume de manera estructurada en el pseudocódigo presentado a continuación.

Pseudocódigo: Estimación de la zona de IAMCEST mediante valores SHAP

1. Entrenar un clasificador XGBoost utilizando la matriz de 336 características por registro.
2. Calcular los valores SHAP absolutos para todos los pacientes.
3. Sumar las contribuciones SHAP por cada derivación del ECG (12 derivaciones).
4. Normalizar estas contribuciones mediante z-score usando únicamente pacientes con ECG normal.
5. Definir los grupos anatómicos correspondientes a cada región del corazón.
6. Definir las reglas de contigüidad como pares de derivaciones adyacentes dentro de cada grupo.
7. Para cada registro correspondiente a la clase IAMCEST (Clase = 1):
 - 7.a. Identificar derivaciones con contribución fuerte y moderada según umbrales establecidos.
 - 7.b. Evaluar si existe contigüidad entre derivaciones fuertes o fuertes + moderadas.
 - 7.c. Si la contigüidad se cumple con los umbrales originales:
 - Seleccionar la zona anatómica con mayor contribución total.
 - 7.d. Si no se cumple, probar la contigüidad utilizando umbrales relajados:
 - Si se cumple, seleccionar la zona con mayor contribución.
 - 7.e. Si no existe contigüidad con ninguno de los dos umbrales:
 - Seleccionar la zona con mayor contribución global.
8. Registrar para cada paciente la zona detectada, las derivaciones que aportaron mayor contribución y el método aplicado (umbral original, umbral relajado o contribución global).

A partir de la aplicación del procedimiento de asignación anatómica descrito previamente, la Tabla 6.5 presenta el resumen de los métodos utilizados durante la detección anatómica de los casos de IAMCEST. El proceso se desarrolló de manera secuencial, iniciando con la evaluación por reglas de contigüidad bajo umbrales originales (1.3 para contribuciones fuertes y 1.0 para moderadas), los cuales permitieron clasificar correctamente la mayoría de los registros, representando aproximadamente el 77% del total. En los casos donde no se cumplían los criterios de contigüidad, se aplicó un segundo filtro con umbrales flexibles (1.0 para contribuciones fuertes y 0.8 para moderadas), orientado a capturar patrones menos evidentes pero fisiológicamente coherentes. Finalmente, el método de contribución global se utilizó como etapa complementaria para aquellos registros con mayor dispersión o ruido, asegurando que todos los casos obtuvieran una asignación anatómica válida.

Tabla 6.5: Resumen de las estrategias aplicadas para la determinación de la localización anatómica del IAMCEST

Estrategia de detección	Número de casos	Porcentaje (%)
Contigüidad con umbrales originales	6692	77.3
Contigüidad con umbrales flexibles	551	6.4
Contribución global	1409	16.3
Total	8652	100

Con base en los resultados obtenidos tras la asignación anatómica, se determinó la distribución de las regiones afectadas en los registros clasificados como IAMCEST, la cual se presenta en la Tabla 6.6. Se evidencia una mayor prevalencia de infartos en la región anterior, seguida de las zonas inferior y lateral, mientras que los casos septales fueron menos frecuentes. Esta nueva distribución se incorporó a la matriz de características, reemplazando la etiqueta original de la clase IAMCEST por la región anatómica correspondiente, con el fin de facilitar el análisis diferenciado por localización del evento.

Tabla 6.6: Distribución anatómica de los casos de IAMCEST identificados mediante valores SHAP

Región afectada	Registros IAMCEST
Anterior	3133
Inferior	2496
Lateral	2341
Septal	682

Como complemento al análisis anterior, en la Figura 6.5 se presenta la representación gráfica de los valores absolutos medios de SHAP correspondientes a las doce derivaciones del ECG, la cual permite visualizar la contribución relativa de las características empleadas por el modelo en la clasificación. Si bien el análisis incluyó las 28 métricas definidas para cada derivación, en la figura se muestran únicamente las 14 con mayor relevancia según su valor medio de importancia, con el fin de

facilitar la interpretación de los resultados. Este enfoque permitió identificar variaciones notables en la influencia de las características entre derivaciones, evidenciando que ciertos parámetros adquieren un peso diferencial en regiones específicas del trazado electrocardiográfico, lo cual aporta información valiosa sobre los mecanismos que el modelo utiliza para la asignación anatómica del IAMCEST.




Figura 6.5: Valores absolutos medios de SHAP por derivación del ECG

6.4.3. Entrenamiento del modelo de clasificación por localización anatómica del infarto

A partir de los resultados obtenidos en la etapa anterior, se identificaron las características electrocardiográficas con mayor influencia en la predicción de las regiones de infarto, a través del modelo XGBoost y el análisis interpretativo mediante valores SHAP. Con base en estos hallazgos, se procedió a construir el modelo final de clasificación, orientado a la detección automática de la

localización anatómica del daño miocárdico.

El entrenamiento se realizó empleando el algoritmo LightGBM, seleccionado por su buen rendimiento en tareas de clasificación multiclase y su eficiencia computacional en grandes volúmenes de datos. El modelo fue configurado para clasificar las cuatro regiones anatómicas afectadas por el infarto agudo de miocardio con elevación del segmento ST (IAMCEST): anterior, inferior, lateral y septal.

6.4.3.1. Modelo LightGBM

El modelo LightGBM fue ajustado tras una etapa de exploración de hiperparámetros que permitió definir una configuración equilibrada entre rendimiento y estabilidad. Las regularizaciones L1 y L2 se mantuvieron activas para prevenir el sobreajuste, mientras que el ajuste de clase mediante `class weight: balanced` se empleó para compensar la desigualdad entre clases. Adicionalmente, se ajustaron parámetros estructurales como el número máximo de hojas (`num_leaves`), la fracción de datos por bagging (`subsample`) y la fracción de características por árbol (`colsample_bytree`), con el fin de controlar la profundidad de los árboles, introducir aleatoriedad y optimizar el tiempo de entrenamiento.

Durante el proceso de entrenamiento se evidenció un desbalance considerable entre las clases, lo que podría generar un sesgo en la predicción hacia las categorías más representadas. Para mitigar este problema, se implementaron dos estrategias de aumento de datos: GNUS (Aumento de datos mediante adición de ruido gaussiano) y SMOTE (Synthetic Minority Oversampling Technique). Ambas se aplicaron únicamente sobre el conjunto de entrenamiento.

- **Técnica GNUS:** Se generaron nuevas muestras sintéticas a partir de los registros reales mediante la adición de un ruido gaussiano controlado, cuya intensidad correspondió al 5% de la variabilidad de cada característica. El proceso de aumento se realizó de manera proporcional al tamaño de cada clase: la clase septal duplicó su número de registros, pasando de 682 a 1364; la clase lateral incrementó su tamaño de 2341 a 3511 registros; la clase inferior aumentó de 2496 a 3744 registros; mientras que la clase anterior se mantuvo sin modificaciones, con 3133 registros. Tras este procedimiento, el conjunto de entrenamiento incrementó su tamaño total de 8652 a 11752 registros, garantizando una representación más equilibrada entre las clases.
- **Técnica SMOTE:** Esta técnica se aplicó directamente sobre los registros del conjunto de entrenamiento con el propósito de alcanzar un equilibrio total entre las clases. A partir de un proceso de interpolación entre muestras existentes, se generaron instancias sintéticas que permitieron igualar la cantidad de registros respecto a la clase más representada. Como resultado, se obtuvo un conjunto final compuesto por 12532 registros distribuidos equitativamente entre las cuatro categorías.

En la Tabla 6.7 se resume la redistribución de los registros de las cuatro zonas de infarto tras aplicar las técnicas de aumento de datos. El conjunto resultante fue empleado en el entrenamiento

y validación del modelo LightGBM, garantizando una representación equitativa de cada clase y reduciendo el sesgo hacia las categorías dominantes.

Tabla 6.7: Distribución de registros por clase antes y después de las técnicas de aumento de datos

Clase	Registros iniciales	Después de GNUS	Después de SMOTE
Inferior	2496	3744	3133
Lateral	2341	3511	3133
Anterior	3133	3133	3133
Septal	682	1364	3133
Total	8652	11752	12532

6.5. Etapa 5: Evaluación de modelos de aprendizaje automático

En esta fase se llevó a cabo la evaluación sistemática de los modelos de clasificación desarrollados para la identificación del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), con el propósito de verificar su rendimiento, estabilidad y adecuación técnica para su posterior integración al sistema principal.

Cada modelo fue almacenado y documentado para facilitar su uso posterior dentro del entorno de ejecución de la interfaz. Asimismo, se realizó un análisis cuantitativo de su desempeño mediante diversas métricas de evaluación, con el fin de comprobar su correcto funcionamiento y capacidad de generalización.

6.5.1. Organización de los modelos entrenados para la implementación

Una vez finalizado el proceso de entrenamiento, cada modelo fue exportado y almacenado dentro de una carpeta específica con el fin de garantizar una fácil accesibilidad y trazabilidad durante su implementación. Los modelos se guardaron en formatos compatibles con las librerías empleadas en su desarrollo:

- **pkl**: modelos basados en gradient boosting (XGBoost y LightGBM).
- **h5**: modelo de red neuronal convolucional unidimensional (CNN-1D).

Esta organización permitió utilizar los modelos de manera directa desde el sistema principal, facilitando su integración funcional con la interfaz gráfica desarrollada para la ejecución de las predicciones en tiempo real.

6.5.2. Evaluación de desempeño y métricas de clasificación

El rendimiento de los modelos de clasificación fue evaluado mediante un conjunto de métricas cuantitativas ampliamente utilizadas en el ámbito del aprendizaje automático supervisado. Estas

métricas permiten analizar la capacidad del modelo para distinguir entre registros Normales e IAM-CEST y cuantificar su eficacia en términos de predicciones correctas, errores y equilibrio entre sensibilidad y precisión.

6.5.2.1. Métricas de evaluación

- **Accuracy (Exactitud):** representa la proporción total de predicciones correctas realizadas por el modelo respecto al número total de muestras evaluadas. Esta métrica proporciona una visión global del desempeño, aunque puede verse afectada por el desbalance de clases, ya que un modelo puede obtener alta exactitud si la clase mayoritaria domina el conjunto de datos.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.1)$$

donde TP corresponde a verdaderos positivos, TN a verdaderos negativos, FP a falsos positivos y FN a falsos negativos.

- **Precision (Precisión):** indica la proporción de predicciones positivas que realmente pertenecen a la clase positiva (IAMCEST). Es decir, mide la confiabilidad de las predicciones positivas del modelo. Una precisión alta implica que los falsos positivos son escasos.

$$Precision = \frac{TP}{TP + FP} \quad (6.2)$$

- **Recall (Sensibilidad):** también conocida como tasa de verdaderos positivos, mide la capacidad del modelo para identificar correctamente todos los casos positivos existentes. En el contexto clínico, un valor alto de Recall es crucial, ya que refleja la habilidad del sistema para detectar verdaderos casos de infarto y minimizar los falsos negativos.

$$Recall = \frac{TP}{TP + FN} \quad (6.3)$$

- **F1-Score:** corresponde a la media armónica entre la precisión y la sensibilidad. Esta métrica ofrece una medida equilibrada del rendimiento general del modelo, especialmente útil en situaciones donde las clases están desbalanceadas. En este proyecto, el F1-Score se empleó como métrica principal para determinar el desempeño global, ya que combina la capacidad de detección (Recall) con la fiabilidad de las predicciones (Precision).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6.4)$$

Estas métricas fueron calculadas empleando la librería `sklearn.metrics`, generando además matrices de confusión normalizadas que permiten visualizar la distribución de aciertos y errores entre las clases Normal e IAMCEST. Dichas matrices facilitaron el análisis de posibles patrones de clasificación errónea o sesgos hacia una clase específica.

6.5.2.2. Evaluación por modelo

- **Modelo XGBoost:** entrenado con una partición del 80 % para entrenamiento y 20 % para prueba (estratificada). Los reportes de métricas y la matriz de confusión se generaron automáticamente. El modelo final fue exportado como `xgb_model.pkl`.
- **Modelo CNN-1D:** el entrenamiento se reguló mediante callbacks de `EarlyStopping` y `ModelCheckpoint` para prevenir el sobreajuste. Las métricas fueron obtenidas a partir del conjunto de validación, y el modelo final se almacenó como `final_model_CNN.h5`.
- **Modelo LightGBM:** entrenado sobre conjuntos balanceados utilizando los métodos GNUS y SMOTE. Se realizaron cinco repeticiones independientes para calcular promedios y desviaciones estándar de cada métrica. El modelo final fue exportado como `lgb_model.pkl`.

Los resultados obtenidos con cada uno de estos modelos, junto con sus respectivas métricas de desempeño y el análisis de las matrices de confusión, se presentan en el Capítulo 7 (Capítulo de Resultados), donde se evalúa su efectividad en la detección del IAMCEST y la identificación de la zona afectada.

6.6. Etapa 6: Desarrollo de la aplicación web

El desarrollo de la aplicación web MyoAlert Vision se llevó a cabo con base en los requerimientos definidos en etapas previas. El nombre de la aplicación refleja su propósito y funcionalidad: “Myo” hace referencia al myocardium, el músculo cardíaco, indicando que el sistema está enfocado en el análisis del corazón; “Alert” se refiere a la generación de alertas frente a posibles eventos de infarto agudo de miocardio con elevación del segmento ST (IAMCEST); y “Vision” alude a la capacidad de la aplicación de proporcionar una estimación visual de la localización anatómica del infarto. De esta manera, el nombre integra de forma clara la finalidad de la herramienta: alertar sobre eventos asociados al IAMCEST y ofrecer una visión de su localización anatómica.

A continuación se describe la arquitectura de la aplicación, su organización modular y la integración con los servicios de procesamiento de datos, que sustentaron el desarrollo de la aplicación.

6.6.1. Diseño de la arquitectura de la aplicación

El diseño de MyoAlert Vision contempló desde sus etapas iniciales la definición detallada de los parámetros de la aplicación, incluyendo los requerimientos funcionales, la disposición de las pantallas, la jerarquía de los componentes y los flujos de interacción con el usuario. Se elaboraron

bocetos y diagramas conceptuales que permitieron anticipar la estructura general, la secuencia de los módulos y la integración de funcionalidades esenciales, como la captura de información del paciente y la gestión de los registros ECG. Esta planificación rigurosa permitió construir una arquitectura modular y jerárquica, estableciendo de manera clara la distribución de responsabilidades entre los distintos elementos de la interfaz.

El frontend se implementó utilizando Flutter, estructurando la interfaz en módulos jerárquicos y funcionales. Se crearon módulos específicos para la captura de información del paciente, la carga y gestión de archivos ECG en formato .hea y .dat, la visualización simultánea de las doce derivaciones del examen y la ampliación de derivaciones individuales para un análisis más detallado. Asimismo, se incorporaron módulos dedicados a la generación de gráficos interactivos y la creación de reportes en PDF, los cuales integran la representación gráfica de las derivaciones y los datos asociados al paciente. La organización modular de la interfaz permite que cada componente gestione de manera autónoma la interacción del usuario, la selección de derivaciones, la visualización de resultados y la generación de reportes, sin entrar en detalles sobre los resultados que provienen del backend.

6.6.2. Integración con el backend y procesamiento de datos

La comunicación entre la aplicación web y el backend se realiza mediante solicitudes HTTP, a través de las cuales se envían los registros ECG del paciente en formato .hea y .dat. El backend se desarrolló en Python utilizando Flask, exponiendo servicios REST que gestionan la recepción de los archivos, su procesamiento y la devolución de los resultados al frontend en formato JSON, asegurando una estructura consistente y fácilmente interpretable por la aplicación web. En la Figura 6.6 se ilustra de manera general este flujo de interacción, mostrando la relación entre el frontend y el backend.

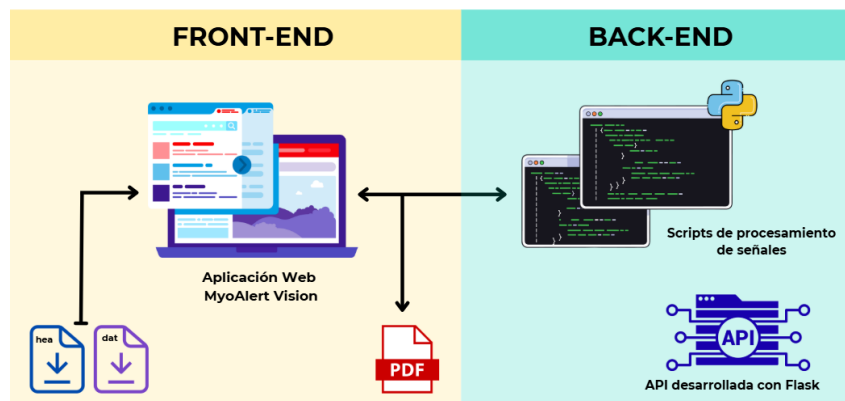


Figura 6.6: Esquema general de comunicación entre el frontend y el backend

El procesamiento de los registros ECG se centraliza en el archivo `main.py`, que gestiona todo el flujo, desde la normalización de los nombres de las derivaciones hasta la predicción de IAMCEST y la estimación de la localización anatómica del infarto. Inicialmente, las derivaciones se normalizan

para garantizar consistencia entre distintos formatos de registro. Posteriormente, las señales se someten a preprocesamiento y se extraen características relevantes, las cuales sirven como entrada para los modelos de aprendizaje automático. Un clasificador XGBoost calcula la estimación primaria de IAMCEST, mientras que una red neuronal convolucional unidimensional (CNN-1D) genera la estimación complementaria, correspondiendo ambas a las probabilidades de presencia del evento. En caso de que alguno de los modelos indique la presencia de infarto, un modelo adicional basado en LightGBM estima la localización anatómica más probable del evento. Todas estas probabilidades y resultados se envían al frontend en formato JSON, donde se presentan en la interfaz de acuerdo con el diseño de la aplicación, mostrando de manera diferenciada y clara la estimación primaria y complementaria de IAMCEST.

Paralelamente, el backend genera una representación gráfica de las doce derivaciones del ECG, codificada en un formato compatible con el frontend. La información devuelta incluye las probabilidades de IAMCEST, la localización anatómica estimada y la imagen completa de las derivaciones preprocesadas. Estos resultados se integran en la interfaz para su visualización inmediata y se incorporan automáticamente en los reportes PDF generados por la aplicación, garantizando que los resultados de los modelos de aprendizaje automático y las representaciones gráficas se presenten de forma coherente, estructurada y directamente interpretable por el usuario.

Con el fin de optimizar el proceso de ejecución y facilitar la integración entre el backend desarrollado en Flask y la aplicación web construida en Flutter, se implementó el comando:

```
npx concurrently "python myoalert_signal/app.py" "flutter run -d chrome"
```

Este comando utiliza la librería `concurrently`, perteneciente al ecosistema de Node.js, la cual permite ejecutar múltiples procesos en paralelo dentro de una misma terminal. De esta forma, se logra iniciar simultáneamente el servidor backend en Flask y la aplicación web en Flutter, garantizando la comunicación en tiempo real entre ambos entornos. Esta integración simplifica el flujo de trabajo, reduce el tiempo de despliegue y mejora la eficiencia durante la fase de desarrollo y pruebas de la aplicación.

Resultados y Discusión

Este proyecto culminó con resultados consistentes, demostrando la efectividad del enfoque metodológico implementado. Se diseñó y desplegó una aplicación web orientada a la detección automatizada del Infarto Agudo de Miocardio con elevación del segmento ST (IAMCEST), basada en el análisis de señales electrocardiográficas mediante técnicas avanzadas de procesamiento digital de señales y algoritmos de aprendizaje automático. Tal como se describió en la sección anterior, el proceso se desarrolló de forma sistemática, integrando etapas de preprocesamiento, extracción de características y modelado predictivo. El resultado fue una herramienta funcional con un desempeño sobresaliente y un alto potencial de aplicación en entornos clínicos, contribuyendo al apoyo diagnóstico y a la optimización de la toma de decisiones médicas en situaciones críticas.

7.1. Estructuración del conjunto de datos y publicación del código fuente en GitHub

La primera fase del proyecto se centró en la reestructuración del conjunto de datos empleado para su desarrollo. A partir de los registros originales provenientes de MIMIC-IV, se implementó un proceso sistemático de depuración, organización y validación de los datos, con el propósito de construir una base propia en formato CSV, junto con las carpetas que contienen los registros de los exámenes, optimizada para su posterior procesamiento computacional y análisis mediante algoritmos de aprendizaje automático. La nueva estructura de datos se organizó en subdirectorios diferenciados por categoría diagnóstica (IAMCEST y Normal), garantizando una separación clara de las clases y una correcta correspondencia entre las señales electrocardiográficas y sus respectivas etiquetas clínicas.

El archivo CSV resultante consolidó los parámetros clínicos, técnicos y de adquisición más relevantes de los estudios electrocardiográficos, generando un conjunto de datos limpio y consistente. Durante la fase de verificación, se realizó una validación exhaustiva del campo *Label* con el fin de confirmar la correcta asignación de etiqueta de cada registro a su categoría correspondiente (Normal o IAMCEST). Asimismo, se incorporó un nuevo campo denominado *new_id*, diseñado específicamente para esta investigación. Este campo asigna un identificador único y secuencial a cada registro, actuando como un índice interno que facilita la trazabilidad de los datos, su referenciación cruzada con los estudios originales y su manipulación automatizada dentro del flujo de procesamiento.

Adicionalmente, el archivo incluye la columna *Report*, la cual contiene valores numéricos del 0 al 8 que indican de qué reporte diagnóstico proviene cada examen dentro de la base MIMIC-IV. Este parámetro permite mantener la vinculación con el origen del registro clínico original, contribuyendo a la trazabilidad y fidelidad de la información procesada. Dicho identificador, junto con la correcta estandarización de la nomenclatura de las columnas (basada en la estructura de la base original) y la eliminación de registros incompletos o inconsistentes, mejoró la calidad, coherencia y confiabilidad estadística del conjunto de datos empleado en el modelado.

Finalmente, con el fin de asegurar la transparencia metodológica, la reproducibilidad experimental y la difusión abierta de los resultados, tanto el archivo CSV reestructurado como los scripts de preprocesamiento, extracción de características, entrenamiento de modelos y análisis de resultados (junto con los demás elementos computacionales utilizados en esta herramienta) fueron integrados en un repositorio público en GitHub, bajo el nombre MyoAlert Visión [ver Anexo 1]. Dicho repositorio incluye, además, el código fuente de la aplicación web desarrollada en Dart mediante el framework Flutter, junto con su backend integrado, conformando una herramienta completa que permite la visualización interactiva de los registros electrocardiográficos y la ejecución de los modelos de clasificación en tiempo real.

GitHub cumple una función fundamental en la gestión y difusión del proyecto, al proporcionar un entorno robusto para el control de versiones, documentación técnica y colaboración científica. Su integración garantiza la trazabilidad del proceso investigativo, así como la transparencia metodológica, reproducibilidad de resultados y preservación estructurada del código y los datos. La publicación abierta del repositorio MyoAlert Visión potencia la credibilidad y visibilidad académica del trabajo, al permitir la verificación independiente, el intercambio de conocimiento y la creación de iniciativas colaborativas a nivel global. Este enfoque refuerza el compromiso con la ciencia abierta al garantizar la accesibilidad y continuidad del conocimiento, permitiendo que los resultados sean verificables, reutilizables y sirvan como base para futuros desarrollos en inteligencia artificial aplicada a la salud.

7.2. Evaluación del desempeño de los modelos de aprendizaje automático

7.2.1. Modelo XGBoost

El modelo XGBoost mostró un desempeño global sobresaliente en la clasificación binaria entre registros electrocardiográficos normales y aquellos asociados a Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), alcanzando una exactitud general del 93%. Este nivel de rendimiento evidencia la alta capacidad del algoritmo para generalizar frente a nuevos registros y para identificar de manera precisa los patrones morfológicos característicos de ambas clases. La Tabla 7.1 resume las métricas obtenidas, donde se aprecia un equilibrio entre precisión, sensibilidad y F1-score, lo cual refleja un comportamiento estable del modelo durante la fase de validación.

En cuanto al desempeño por clase, el modelo alcanzó una precisión de 0.91 y un recall de 0.95 para la clase Normal, lo que indica una baja tasa de falsos positivos y, por tanto, una adecuada capacidad para identificar correctamente los registros sin alteraciones isquémicas. En contraste, para la clase IAMCEST se obtuvo una precisión de 0.95 y un recall de 0.91, evidenciando una ligera tendencia del modelo a subestimar algunos episodios de infarto (falsos negativos). Sin embargo, el equilibrio entre ambos indicadores, reflejado en un F1-score promedio de 0.93, demuestra que el modelo mantiene una clasificación confiable sin sesgo significativo hacia ninguna clase.

Tabla 7.1: Métricas de desempeño del modelo XGBoost

Clase	Precisión	Recall	F1-Score
Normal	0.91	0.95	0.93
IAMCEST	0.95	0.91	0.93
Accuracy	0.93		

En la Figura 7.1 se presenta la matriz de confusión, la cual complementa el análisis de las métricas de desempeño al mostrar de forma detallada la distribución de aciertos y errores en la clasificación. En ella se evidencia una proporción reducida de falsos negativos, equivalente al 9% de los casos de IAMCEST que fueron clasificados erróneamente como normales. Este hallazgo resulta especialmente relevante desde el punto de vista clínico, ya que una menor tasa de falsos negativos disminuye el riesgo de omitir episodios de infarto agudo de miocardio, favoreciendo la detección temprana y la intervención oportuna.

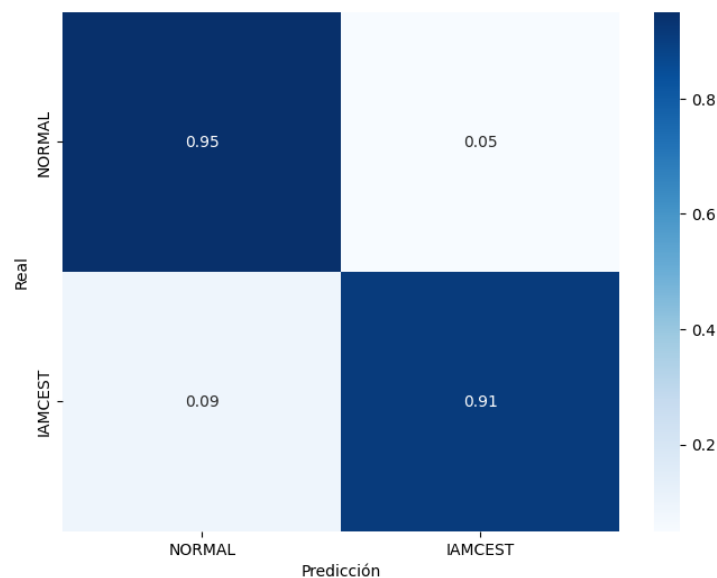


Figura 7.1: Matriz de confusión del modelo XGBoost

El rendimiento alcanzado por el modelo se sustenta en la capacidad de XGBoost para identificar relaciones no lineales y detectar interacciones complejas entre las características derivadas del ECG. El modelo fue entrenado con una matriz compuesta por 28 características cuantitativas extraídas de cada una de las 12 derivaciones, lo que permitió representar de manera integral la dinámica eléctrica del corazón desde múltiples perspectivas. Esta estructura multicanal incrementó la complejidad del espacio de datos; sin embargo, el algoritmo demostró ser robusto frente a dicha heterogeneidad, manteniendo un desempeño estable incluso ante posibles variaciones interpaciente y la presencia de ruido fisiológico. Asimismo, la configuración de sus parámetros internos permitió preservar un equilibrio adecuado entre sesgo y varianza, evitando el sobreajuste y fortaleciendo la capacidad de generalización del modelo. Este comportamiento se ve respaldado por la curva ROC mostrada en la Figura 7.2, donde se obtuvo un área bajo la curva (AUC) de 98 %. Dicho valor evidencia una excelente capacidad discriminativa del modelo para distinguir entre registros normales y aquellos correspondientes a IAMCEST.




Figura 7.2: Curva ROC del modelo XGBoost

7.2.2. Modelo CNN-1D

El modelo de red neuronal convolucional unidimensional (CNN-1D) mostró un desempeño destacado en la clasificación binaria entre registros electrocardiográficos normales y aquellos asociados a Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), alcanzando una exactitud general del 91 %. Este resultado evidencia la capacidad del modelo para generalizar frente a nuevos registros y para identificar patrones morfológicos característicos de cada clase.

La Tabla 7.2 resume las métricas obtenidas, donde se aprecia un balance adecuado entre precisión, sensibilidad y F1-score durante la fase de validación, lo que refleja estabilidad en el desempeño del modelo. En cuanto al desempeño por clase, la clase Normal alcanzó una precisión de 0.88 y un recall de 0.96, lo que indica una baja tasa de falsos positivos y una adecuada capacidad para identificar registros sin alteraciones isquémicas. Por su parte, la clase IAMCEST presentó una precisión de 0.95 y un recall de 0.87, mostrando que el modelo reconoce la mayoría de los episodios de infarto,

aunque con algunos casos subestimados (falsos negativos). El F1-score promedio de 0.91 evidencia que la clasificación general se mantiene confiable sin sesgo significativo hacia ninguna clase.

Tabla 7.2: Métricas de desempeño del modelo CNN-1D

Clase	Precisión	Recall	F1-Score
Normal	0.88	0.96	0.92
IAMCEST	0.95	0.87	0.91
Accuracy	0.91		

A continuación, en la Figura 7.3 se presenta la matriz de confusión del modelo, que complementa el análisis de las métricas mostrando la distribución detallada de aciertos y errores por clase. Se evidencia una proporción reducida de falsos negativos para la clase IAMCEST, lo cual es crucial desde el punto de vista clínico, ya que disminuye el riesgo de omitir episodios de infarto agudo y favorece la detección temprana.

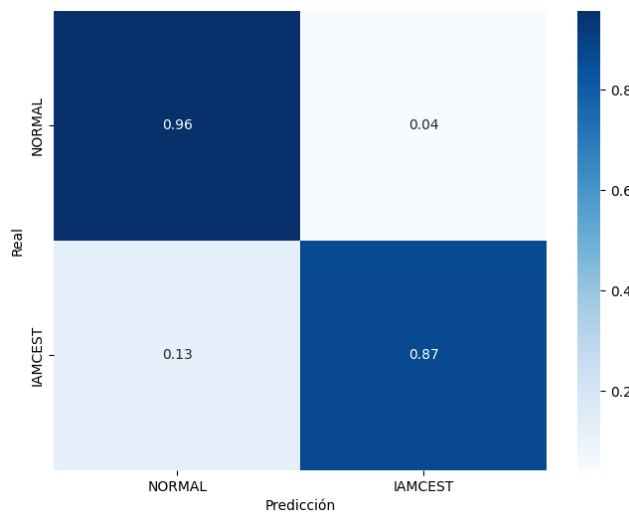


Figura 7.3: Matriz de confusión del modelo CNN-1D

En complemento a las métricas de desempeño presentadas, la Figura 7.4 muestra la evolución de la pérdida (loss) y la exactitud (accuracy) durante el proceso de entrenamiento del modelo CNN-1D. Se aprecia una disminución progresiva del loss de entrenamiento hasta un valor final de 0.1937, mientras que el loss de validación se mantiene alrededor de 0.2210, con leves fluctuaciones entre épocas. Esta tendencia refleja un aprendizaje estable y sin evidencia de sobreajuste.

Por su parte, la exactitud del entrenamiento y validación (Figura 7.4b) exhiben una trayectoria ascendente y paralela, alcanzando valores finales de 0.9247 y 0.9117, respectivamente. La cercanía entre ambas curvas confirma una adecuada capacidad de generalización y un ajuste equilibrado del modelo.




Figura 7.4: Evolución del loss (a) y de la exactitud (b) durante el entrenamiento y validación del modelo CNN-1D

El modelo presentó además un Área Bajo la Curva (AUC) de 0.97, confirmando su excelente capacidad discriminativa para diferenciar entre registros normales y registros IAMCEST, lo que respalda su utilidad potencial como herramienta de soporte diagnóstico. El rendimiento observado se sustenta en la capacidad de la CNN-1D para extraer características relevantes de la señal ECG mediante convoluciones jerárquicas y capas de pooling, detectando patrones complejos asociados a eventos isquémicos. La arquitectura multicanal y la optimización de sus parámetros internos favorecieron un equilibrio adecuado entre sesgo y varianza, fortaleciendo la generalización del modelo frente a nuevas señales y la variabilidad fisiológica entre pacientes.

Finalmente, la curva ROC (Figura 7.5) ilustra la alta discriminación lograda, evidenciando que el modelo CNN-1D constituye una herramienta confiable para apoyar la interpretación de ECG en contextos clínicos.




Figura 7.5: Curva ROC del modelo CNN-1D

7.2.3. Modelo LightGBM

Con el propósito de garantizar un entrenamiento robusto y evitar sesgos asociados a un subconjunto específico de registros, se implementó una estrategia de validación cruzada con cinco repeticiones independientes en el modelo LightGBM. Este procedimiento permitió dividir los datos en distintos subconjuntos de entrenamiento y validación de manera iterativa, asegurando que cada registro fuera utilizado tanto para el aprendizaje como para la evaluación. Así, se promovió una adecuada capacidad de generalización del modelo. Además, el cálculo de los valores promedio y las desviaciones estándar de las métricas de precisión, recall y F1-score proporcionó una estimación más estable y representativa del rendimiento global del clasificador. Los resultados consolidados de estas métricas para las técnicas de aumento GNUS y SMOTE se presentan en la Tabla 7.3, donde se observa el desempeño promedio obtenido en cada clase anatómica del infarto. Finalmente, las matrices de confusión generadas para cada método de aumento (SMOTE y GNUS) permitieron comparar visual y cuantitativamente su efectividad en la identificación de las distintas clases anatómicas del infarto.

Tabla 7.3: Promedio de métricas de validación obtenidas con las técnicas GNUS y SMOTE

Técnica GNUS			
Clase	Precisión	Recall	F1-Score
Anterior	0.84 ± 0.014	0.81 ± 0.009	0.82 ± 0.006
Inferior	0.89 ± 0.014	0.90 ± 0.018	0.89 ± 0.013
Lateral	0.86 ± 0.014	0.88 ± 0.020	0.87 ± 0.012
Septal	0.86 ± 0.023	0.86 ± 0.011	0.86 ± 0.010
Accuracy global	0.86 ± 0.009		
Técnica SMOTE			
Clase	Precisión	Recall	F1-Score
Anterior	0.78 ± 0.011	0.79 ± 0.007	0.79 ± 0.007
Inferior	0.79 ± 0.009	0.78 ± 0.015	0.78 ± 0.008
Lateral	0.73 ± 0.010	0.75 ± 0.018	0.74 ± 0.013
Septal	0.57 ± 0.023	0.53 ± 0.027	0.55 ± 0.023
Accuracy global	0.76 ± 0.006		

En primer lugar, se entrenó el modelo LightGBM utilizando la técnica de aumento GNUS. Durante la validación cruzada, el modelo alcanzó un accuracy global promedio de 0.86 ± 0.008 , evidenciando una alta capacidad de generalización. Las clases inferior y lateral obtuvieron los mejores desempeños, con valores de F1-score de 0.89 ± 0.013 y 0.87 ± 0.012 , respectivamente, mientras que las categorías anterior y septal mantuvieron resultados estables en torno a 0.82 y 0.86. Las desviaciones estándar reducidas observadas en las métricas de precisión, recall y F1-score reflejan una consistencia en el comportamiento del modelo a lo largo de las distintas particiones, indicando que el proceso de validación cruzada logró mitigar el sesgo asociado a la selección aleatoria de los conjuntos de entrenamiento y prueba. En la Figura 7.6 se muestra la matriz de confusión pro-

medio correspondiente al modelo LightGBM con GNUS, en la cual se aprecia una concentración pronunciada de valores a lo largo de la diagonal principal, señal de un alto número de predicciones correctas. Se destaca además una reducción notable de los falsos negativos en la clase septal, una región de relevancia clínica significativa por su alta dificultad de detección en señales electrocardiográficas. Este comportamiento sugiere que el método GNUS permitió generar ejemplos sintéticos más representativos de la distribución real de las señales, favoreciendo la robustez del aprendizaje y la capacidad discriminativa del modelo entre las distintas manifestaciones anatómicas del infarto.

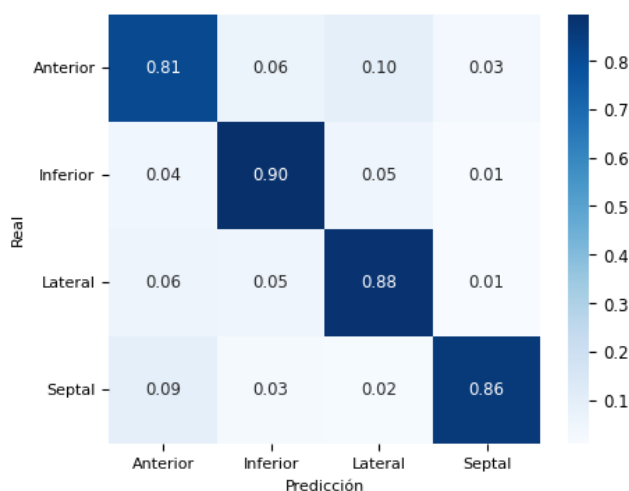


Figura 7.6: Matriz de confusión promedio del modelo LightGBM con la técnica GNUS

Por otro lado, al aplicar la técnica SMOTE se observó un rendimiento inferior en comparación con GNUS. Aunque este método busca equilibrar las clases mediante la generación de nuevas muestras sintéticas a partir de los vecinos más cercanos, sus resultados evidenciaron una menor capacidad del modelo para capturar la variabilidad morfológica presente en las señales electrocardiográficas. El modelo obtuvo un accuracy global promedio de 0.76 ± 0.006 , con un comportamiento desigual entre las distintas clases. En particular, la categoría septal presentó el desempeño más bajo (F1-score de 0.55 ± 0.023), seguida por la clase lateral (0.74 ± 0.013), indicando una tendencia del modelo a confundir estas regiones con las clases anterior e inferior.

La Figura 7.7 muestra la matriz de confusión promedio del modelo LightGBM entrenado con SMOTE, donde se aprecia una mayor dispersión de los valores fuera de la diagonal principal, especialmente en las clases minoritarias. Este patrón refleja la pérdida de especificidad del modelo en dichas categorías y una mayor proporción de falsos negativos, lo cual puede comprometer la detección de regiones críticas del infarto. En contraste con GNUS, las desviaciones estándar más elevadas en las métricas de desempeño indican una menor estabilidad del modelo entre las diferentes particiones de validación, sugiriendo una dependencia mayor de los datos particulares empleados en el entrenamiento.




Figura 7.7: Matriz de confusión promedio del modelo LightGBM con la técnica SMOTE

La comparación global entre ambas estrategias evidencia que GNUS superó de forma consistente a SMOTE en todas las métricas de desempeño, mostrando además menor variabilidad entre repeticiones. Su mejor estabilidad, junto con la reducción de errores cruzados en la matriz de confusión, demuestra una mayor capacidad de generalización y una representación más fiel de las señales electrocardiográficas reales. Por estos motivos, se seleccionó el modelo LightGBM entrenado con GNUS como la configuración final para la clasificación de la localización anatómica del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST).

7.3. Implementación de la aplicación web

7.3.1. Vistas de la aplicación

La aplicación MyoAlert Vision está diseñada con varias vistas que guían al usuario a través del flujo de registro y análisis de datos. La primera vista corresponde a la **pantalla de inicio de sesión**, donde, en esta versión prototipo, el acceso se realiza únicamente con el usuario 'demo' y la contraseña '8888'.

Una vez iniciada la sesión, el usuario accede a la vista de **registro de paciente**, una ventana compacta que permite ingresar y almacenar información básica del paciente. Los campos disponibles incluyen: nombre completo, tipo de identificación, número de identificación y edad. Además, la fecha y hora se completan automáticamente con la fecha y hora actuales, aunque también pueden ser modificadas manualmente según sea necesario.

Tras registrar al paciente, el usuario es dirigido a la **ventana principal**, la cual se organiza en diferentes secciones delimitadas en colores, como se muestra en la Figura 7.8. Cada sección facilita la interacción con la información y la visualización de resultados:

- La sección delimitada en negro muestra la información registrada del paciente, junto con un campo de comentarios para que el personal clínico documente datos relevantes como síntomas, antecedentes o servicio de ingreso.
- La sección delimitada en rojo presenta el registro de ECG de 12 derivaciones. Inicialmente se visualizan las derivaciones I, II, III, aVR, aVF, aVL; mediante una barra de desplazamiento vertical se pueden consultar las derivaciones precordiales V1-V6.
- La sección delimitada en verde muestra la probabilidad de Infarto Agudo de Miocardio con elevación del segmento ST, calculada a partir de dos estimaciones: la estimación primaria que corresponde al modelo XGBoost y la estimación complementaria al modelo CNN-1D. Estas estimaciones se obtienen luego de que la señal de ECG pasa por el preprocesamiento, extracción de características y análisis automatizado en el backend de la aplicación, y la información resultante se envía a la interfaz para su visualización. Adicionalmente, esta sección presenta la localización anatómica estimada del infarto, representada gráficamente en un corazón, resaltando las derivaciones asociadas a la región afectada.
- La sección delimitada en amarillo funciona como un visor ampliado de la señal, mostrando por defecto la derivación II. Adicionalmente, el visor permite al personal clínico seleccionar cualquier otra derivación para un análisis más detallado y específico según la necesidad diagnóstica.




Figura 7.8: Ventana principal de MyoAlert Vision con secciones delimitadas por colores

7.3.2. Visualización anatómica del IAMCEST

Se diseñó una representación esquemática de las regiones del corazón según la localización del Infarto Agudo de Miocardio con elevación del segmento ST (IAMCEST) con el fin de facilitar la visualización anatómica de las diferentes zonas afectadas y apoyar la interpretación clínica, así como la comprensión de los resultados obtenidos a través de la aplicación Myoalert Vision. Como se muestra en la Figura 7.9, este esquema permite integrar de manera visual la información proporcionada por los modelos de aprendizaje automático, mostrando de forma clara cuáles regiones del corazón podrían estar comprometidas. En la figura, las letras A–E indican las distintas condiciones del corazón: A) Normal, B) Septal, C) Anterior, D) Inferior y E) Lateral. Esta representación ayuda al usuario a identificar rápidamente la región afectada por el infarto, comparar los resultados con registros de ECG previos y facilitar la toma de decisiones clínica.




Figura 7.9: Representación esquemática de las regiones del corazón según la localización del Infarto Agudo de Miocardio con elevación del segmento ST (IAMCEST)

7.3.3. Interacción con la aplicación y generación de registros clínicos

La interacción dentro de la aplicación MyoAlert Vision fue diseñada para ofrecer una experiencia fluida, estructurada y adaptada al entorno clínico, permitiendo al usuario recorrer de manera intuitiva cada una de las etapas del proceso diagnóstico. En la Figura 7.10 se presenta el diagrama de navegación de la aplicación, el cual resume la secuencia lógica de acciones desde el ingreso del usuario hasta la generación del reporte final.

El proceso inicia en la pantalla de autenticación, donde el usuario accede a la plataforma. Una vez validado el ingreso, se despliega una ventana emergente de registro de paciente, de formato compacto, que permite ingresar la información del paciente. Este paso garantiza la correcta vinculación de cada registro con la información clínica correspondiente antes de proceder al análisis electrocardiográfico.

A continuación, el usuario accede a la ventana principal, desde donde se cargan los archivos del registro ECG, los cuales corresponden a los formatos .hea y .dat. Estos archivos contienen la información necesaria para la visualización y análisis del registro de ECG y deben seleccionarse mediante el icono ubicado en la esquina inferior derecha de la interfaz. Una vez cargados, se muestra el trazado electrocardiográfico completo junto con la información del paciente y un campo de comentarios en el que el personal clínico puede registrar observaciones o datos complementarios relevantes para el estudio.

En esta vista se muestra la probabilidad de IAMCEST, estimada a partir de dos modelos complementarios: XGBoost (estimación primaria) y CNN-1D (estimación complementaria). Un mayor porcentaje indica una mayor probabilidad de un evento isquémico agudo, mientras que valores inferiores al 80 % no muestran patrones asociados a IAMCEST, aunque podrían reflejar otras alteraciones cardíacas, como arritmias u otras condiciones. Cuando la probabilidad es igual o superior al 80 %, la aplicación clasifica el registro como IAMCEST y muestra la localización anatómica del infarto, la cual se representa gráficamente sobre un esquema cardíaco para facilitar su interpretación clínica.

En la esquina superior derecha, un menú desplegable permite acciones adicionales como salir (cerrar sesión) o descargar el reporte del estudio. Este se genera automáticamente en formato PDF, incluyendo la información del paciente, resultados de los modelos, comentarios y el registro completo del ECG. La Figura 7.11 presenta un ejemplo del reporte exportado, donde se integran los resultados analíticos y gráficos en un formato claro y estructurado para su revisión clínica.




Figura 7.10: Diagrama de navegación de la aplicación Myoalert Vision

MyoAlert Vision

Información del paciente

Nombre: William Obregon
Tipo de identificación: CC
Número de identificación: 123456789
Edad: 20
Fecha y hora del reporte: 2025-10-25 10:58:01

Probabilidad de Infarto Agudo de Miocardio con Elevación del Segmento ST

Estimación primaria: 97.57% Estimación complementaria: 95.05%

Localización anatómica estimada del infarto

Anterior

Comentarios

Paciente ingresa a urgencias presentando dolor torácico opresivo, irradiado al brazo izquierdo. Refiere disnea, sudoración fría y náuseas asociadas. Se genera el reporte y se confirma infarto anterior.

Electrocardiograma




Figura 7.11: Ejemplo de reporte clínico generado por la aplicación MyoAlert Vision

7.4. Evaluación de la aplicación web por un especialista en cardiología

Con el propósito de evaluar la facilidad de uso y la comprensión del sistema por parte del personal de salud, se llevó a cabo una validación cualitativa de la aplicación web junto al Dr. Nelson Eduardo Murillo Benítez, cardiólogo e internista con amplia experiencia en el diagnóstico y tratamiento de patologías cardiovasculares agudas, incluyendo el Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST).

Durante la sesión de evaluación, se presentó de forma detallada el funcionamiento interno del sistema, mostrando el flujo completo de procesamiento de las señales electrocardiográficas, los algoritmos de clasificación implementados y fragmentos del código fuente desarrollado, con el fin de evidenciar la rigurosidad técnica y el trabajo de ingeniería detrás de la aplicación. Posteriormente, se realizó una demostración práctica del entorno web, explicando cada una de sus herramientas y funcionalidades, tales como la carga de registros ECG, la visualización de las señales procesadas, la generación del diagnóstico automático y la identificación anatómica de las regiones afectadas.

El Dr. Murillo destacó la facilidad de manejo y la claridad de la interfaz, resaltando que la herramienta constituye una propuesta innovadora, pertinente y de gran utilidad práctica para el personal médico. Señaló que su diseño resulta intuitivo y alineado con las necesidades del entorno clínico, facilitando una interpretación rápida y precisa de los registros electrocardiográficos y favoreciendo la toma de decisiones oportunas en escenarios de urgencia. Finalmente, el especialista recomendó ampliar el proceso de validación con otros profesionales de la salud, con el propósito de fortalecer su aplicabilidad clínica y consolidarla como una herramienta de apoyo diagnóstico confiable y accesible.

Conclusiones

El desarrollo de MyoAlert Vision representó un abordaje sistemático orientado a fortalecer el diagnóstico asistido del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST) mediante la implementación de un sistema inteligente basado en procesamiento de señales electrocardiográficas y algoritmos de aprendizaje automático. El trabajo se centró en la detección y clasificación de patrones característicos del IAMCEST, alcanzando desempeños notables con precisiones del 93 % y 91 % en la detección general del evento, y del 86 % en la localización anatómica de la región afectada. Estos resultados adquieren especial relevancia al considerar la complejidad que implica determinar la zona del miocardio comprometida a partir de una señal de ECG, en la que pequeñas variaciones pueden tener significancia clínica.

El alto desempeño obtenido por los modelos se debe a la calidad de las etapas de preprocesamiento y a la exploración de diferentes enfoques de aprendizaje, que abarcaron desde técnicas de Machine Learning hasta arquitecturas de Deep Learning. Estas estrategias permitieron optimizar la representación de las señales electrocardiográficas y maximizar la capacidad discriminativa del sistema. Además, la integración de métodos avanzados como los valores SHAP aportó interpretabilidad al modelo y evidenció su coherencia con los fundamentos clínicos, fortaleciendo la confiabilidad y el valor diagnóstico del sistema inteligente desarrollado. De manera complementaria, durante la etapa final se evaluó la técnica SMOTE para aumentar la cantidad de datos en las clases minoritarias; no obstante, su desempeño fue inferior al esperado, posiblemente debido a la generación de muestras sintéticas que no lograban preservar la relación fisiológica entre derivaciones contiguas. Este efecto se reflejó especialmente en la confusión entre las regiones septal y anterior, cuyas derivaciones (V1-V2 y V2-V4, respectivamente) presentan una transición eléctrica estrecha y una correlación natural. Ante ello, la técnica GNUS demostró ser una alternativa más efectiva, al introducir variabilidad controlada sin alterar la coherencia espacial del trazado, lo que se tradujo en una mejora significativa en la localización anatómica del IAMCEST.

Por otro lado, la implementación del sistema en una aplicación web consolida la transición del modelo desde un entorno experimental hacia una herramienta funcional y accesible, capaz de apoyar el diagnóstico clínico en tiempo real. Esta integración facilita la visualización de señales, la interpretación automatizada de resultados y la generación de reportes diagnósticos, brindando a los profesionales de la salud una asistencia ágil y confiable en la toma de decisiones. MyoAlert Vision se posiciona como una herramienta de apoyo que combina inteligencia artificial y análisis electrocardiográfico para fortalecer la toma de decisiones médicas y optimizar la respuesta ante eventos cardiovasculares agudos.

Trabajos futuros

Los resultados alcanzados en este proyecto evidencian el potencial de MyoAlert Vision como herramienta de apoyo diagnóstico y, al mismo tiempo, permiten plantear nuevas líneas de investigación orientadas a optimizar su desempeño, robustez y aplicabilidad clínica. En primer lugar, resulta fundamental realizar una validación clínica prospectiva del sistema en entornos hospitalarios reales, con la participación de personal médico especializado, que permita comparar las predicciones del modelo frente al diagnóstico clínico confirmado y evaluar su impacto en los tiempos de atención y la toma de decisiones terapéuticas. Esta validación permitiría determinar la efectividad del sistema en condiciones reales y avanzar hacia su potencial implementación como herramienta de apoyo diagnóstico en instituciones de salud.

De igual manera, se plantea como una proyección futura el desarrollo de un módulo capaz de identificar no solo la localización anatómica del infarto, sino también las arterias coronarias involucradas en el evento, como la descendente anterior, la circunfleja o la coronaria derecha. Esta funcionalidad podría alcanzarse mediante el entrenamiento de nuevos modelos supervisados que integren los resultados obtenidos a partir del análisis electrocardiográfico con información proveniente de estudios angiográficos o reportes clínicos, permitiendo así estimar la arteria ocluida y la probabilidad de obstrucción coronaria. De lograrse, esta extensión representaría un avance sustancial hacia una caracterización más completa y específica del infarto, con un valor clínico considerable en la planificación del tratamiento.

Asimismo, se propone ampliar las clases anatómicas consideradas en el modelo actual, dado que en este trabajo solo se abordaron las caras anterior, inferior, lateral y septal. En investigaciones futuras, sería pertinente incorporar combinaciones y subregiones como las caras anteroseptal, anterolateral o inferolateral, que reflejan con mayor precisión la diversidad de presentaciones electrocardiográficas del infarto agudo de miocardio con elevación del segmento ST. Este enfoque permitiría una localización más detallada de las lesiones y una mejor correspondencia con la distribución real de la perfusión coronaria.

Otro aspecto relevante consiste en validar el sistema con otras bases de datos de señales electrocardiográficas, tanto públicas como hospitalarias, con el fin de evaluar su capacidad de generalización frente a diferentes equipos de adquisición, frecuencias de muestreo y poblaciones clínicas. Esta validación externa permitiría identificar posibles sesgos, ajustar los procesos de preprocesamiento y garantizar un desempeño robusto en escenarios heterogéneos. Además, la inclusión de bases de datos que contengan otros tipos de infarto, como los IAM sin elevación del segmento ST (IAMSEST) o los

infartos silentes, ofrecería la oportunidad de expandir el modelo hacia una detección más integral de los síndromes coronarios agudos.

También se recomienda explorar arquitecturas más avanzadas de aprendizaje profundo, como redes híbridas CNN-LSTM o modelos basados en Transformers, que podrían capturar de forma más precisa la dinámica temporal de las señales ECG y mejorar la sensibilidad ante patrones sutiles de isquemia. La integración de información multimodal, combinando señales electrocardiográficas con datos clínicos, biomarcadores o imágenes cardíacas, permitiría desarrollar un sistema más completo, capaz de ofrecer un análisis integral del estado del paciente.

Por último, la implementación del sistema en plataformas portátiles o móviles representaría un avance hacia su aplicación en contextos de telemedicina o atención primaria, donde el acceso a especialistas es limitado. La integración con dispositivos de monitoreo inalámbrico posibilitaría el análisis en tiempo real y el envío automático de alertas ante eventos críticos. En conjunto, estas líneas de trabajo permitirán que MyoAlert Vision evolucione desde un prototipo experimental hacia una herramienta clínica robusta, validada y escalable, capaz de contribuir de manera significativa al diagnóstico oportuno y al manejo eficaz del infarto agudo de miocardio con elevación del segmento ST.

Anexo 1 – Guía de códigos y recursos del proyecto MyoAlert Vision

Tabla 1: Enlaces a los recursos del proyecto MyoAlert Vision

Título	Tipo de enlace	Enlace
Repositorio principal de MyoAlert Vision con todos los notebooks implementados en la herramienta, información esencial y herramientas utilizadas en el desarrollo	Repositorio GitHub	MyoAlert Vision
Base de datos reestructurada	Releases GitHub	Base de datos

Anexo 2 – Manual de usuario de MyoAlert Vision

MyoAlert Vision

Manual de usuario

Aplicación web para la detección de
Infarto Agudo de Miocardio con
Elevación del ST



Pontificia Universidad
JAVERIANA
Cali

Título del documento

MyoAlert Vision - Manual de usuario

Autores

Julieth Alejandra Daza Ceron y William Felipe Obregon Londoño

Programa académico

Ingeniería Biomédica

Institución

Pontificia Universidad Javeriana Cali, Colombia

Versión del documento

1.0

Fecha de emisión

31/10/2025

Estado del documento

Versión final

Alcance

El presente manual tiene como objetivo orientar al usuario en el manejo del prototipo de la aplicación web MyoAlert Vision, desarrollada por estudiantes de Ingeniería Biomédica como una herramienta de apoyo para la detección temprana del Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST).

El proyecto surge ante la alta prevalencia del infarto agudo de miocardio, una de las principales causas de mortalidad cardiovascular a nivel mundial y nacional. En Colombia, esta patología representa una proporción significativa de las defunciones por causas naturales, lo que evidencia la necesidad de fortalecer las estrategias de diagnóstico oportuno. En este contexto, MyoAlert Vision busca integrar el procesamiento automatizado de señales electrocardiográficas (ECG) con algoritmos de aprendizaje automático, facilitando el reconocimiento de patrones asociados al IAMCEST y brindando apoyo al personal médico en la interpretación clínica y la toma de decisiones en escenarios de emergencia cardiovascular.

El manual describe de manera general las funciones principales de la aplicación, su flujo de navegación e interacción, así como la generación e interpretación de reportes. Está dirigido al personal médico interesado en conocer el funcionamiento y las capacidades del sistema con fines de evaluación, en el marco del desarrollo de herramientas computacionales orientadas al apoyo diagnóstico en cardiología.

Contenido

1. Descripción general del sistema	5
2. Diagrama de navegación	6
3. Uso de la aplicación	
3.1. Acceso e inicio de sesión	7
3.2. Carga de registros ECG	8
3.3. Visualización del registro ECG	9
3.4. Análisis y resultados automáticos	10
3.5. Generación del reporte clínico	11


Descripción general del sistema

MyoAlert Vision es una aplicación web interactiva orientada al análisis y visualización de registros electrocardiográficos (ECG) de 12 derivaciones. Su estructura integra una interfaz gráfica intuitiva con un módulo de procesamiento automático que ejecuta el análisis mediante modelos de aprendizaje automático, ofreciendo resultados en tiempo real sobre la probabilidad de Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST) y su posible localización anatómica.

El sistema se compone de cuatro secciones principales: acceso del usuario, registro del paciente, análisis del ECG y generación del reporte clínico. Cada etapa está diseñada para garantizar una navegación sencilla y un flujo de trabajo coherente con el entorno hospitalario. La interfaz combina elementos de visualización ampliada de señales, paneles de resultados automáticos y opciones de interacción que permiten añadir comentarios o generar reportes en formato PDF.

Además de servir como prototipo demostrativo, la aplicación busca ilustrar la integración entre algoritmos de inteligencia artificial y herramientas de apoyo diagnóstico, mostrando el potencial de las tecnologías computacionales en la mejora de la precisión y eficiencia de los procesos clínicos relacionados con el diagnóstico del IAMCEST.

Diagrama de navegación



1 Acceso e inicio de sesión

2 Registro de información del paciente

3 Carga de archivos de registro ECG

4 Generación automática de alerta diagnóstica


5 Visualización y análisis del registro ECG

6 Descarga del reporte clínico en formato PDF

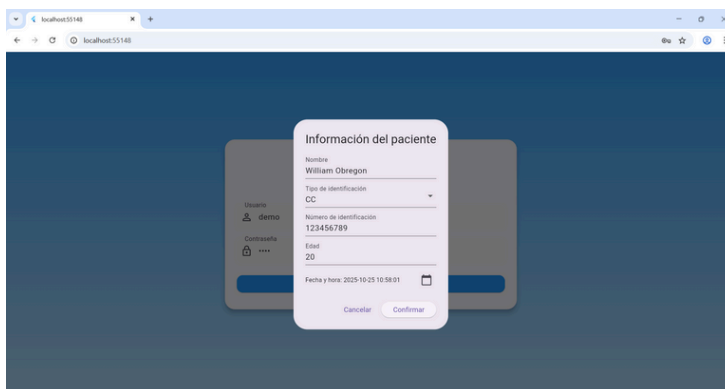
Uso de la aplicación

3.1 Acceso e inicio de sesión

El primer paso para utilizar la aplicación consiste en acceder a MyoAlert Vision desde el navegador web. Al ingresar, se muestra la pantalla de inicio de sesión, donde el usuario debe introducir sus credenciales en los campos correspondientes. En esta versión prototipo, el acceso se realiza con el usuario “demo” y la contraseña “8888”. Una vez ingresados los datos, se presiona el botón “Iniciar sesión” para continuar al registro del paciente.




El segundo paso consiste en registrar la información del paciente. En esta ventana se deben ingresar los datos básicos: nombre completo, tipo y número de identificación, y edad. La fecha y hora se completan automáticamente, pero pueden modificarse si es necesario. Una vez diligenciados los campos, se presiona “Confirmar” para guardar la información y continuar con el análisis.




Uso de la aplicación

3.2 Carga de registros ECG

El tercer paso corresponde al ingreso a la interfaz principal de la aplicación, donde se agrupan las herramientas de visualización y análisis. En la parte inferior derecha de la pantalla se encuentra un ícono de carga, identificado junto al símbolo gráfico del corazón, mediante el cual el usuario puede seleccionar y subir los archivos del registro electrocardiográfico para su posterior análisis.



Al seleccionar el ícono, se abre una ventana del explorador de archivos desde donde el usuario debe elegir los archivos del registro ECG en formato .hea y .dat. Una vez seleccionados ambos archivos, se debe presionar el botón “Abrir” para cargarlos en la interfaz y continuar con el análisis.



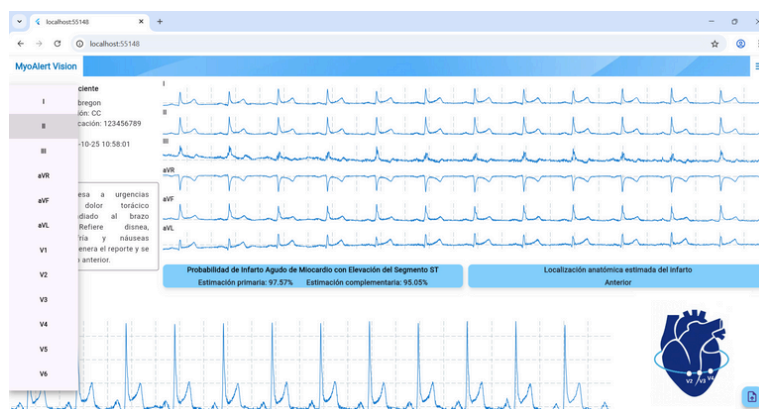
Uso de la aplicación

3.3 Visualización del registro ECG

Al subir los archivos, el usuario visualiza el examen electrocardiográfico dentro de la interfaz principal. Una vez cargados los archivos, el sistema muestra el registro en un recuadro central donde se presentan las 12 derivaciones del ECG. Inicialmente se observan las primeras seis, y para visualizar las restantes, el usuario debe emplear la barra deslizadora lateral, que permite desplazarse entre las diferentes señales. En un segundo recuadro, ubicado en la parte inferior, el usuario puede ver cada derivación por separado para un análisis más detallado.



En la esquina superior izquierda de este recuadro se encuentra un menú desplegable que permite seleccionar cualquiera de las 12 derivaciones para su revisión individual.



Uso de la aplicación

3.4 Análisis y resultados automáticos

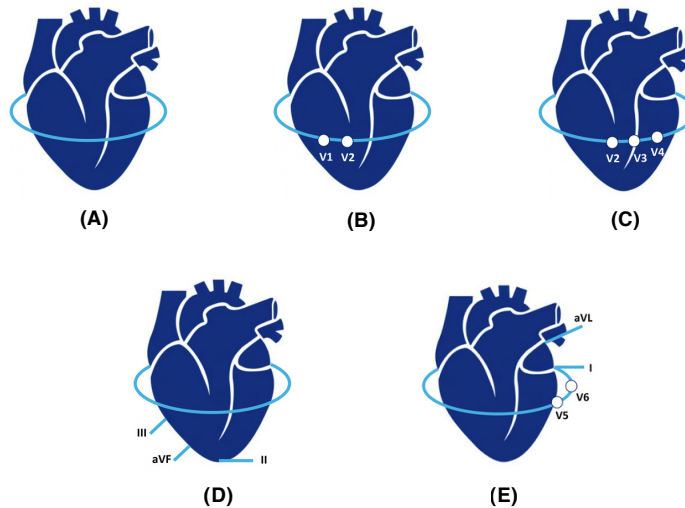
En el cuarto paso, una vez cargados los archivos del examen electrocardiográfico, el sistema realiza un análisis automático de la señal. Si el registro presenta indicios compatibles con un posible Infarto Agudo de Miocardio con Elevación del Segmento ST (IAMCEST), se despliega una ventana emergente que notifica al usuario sobre esta alerta.

ALERTA

El sistema ha identificado patrones indicativos de un posible Infarto Agudo de Miocardio con Elevación del Segmento ST. Se recomienda valoración y supervisión médica inmediata.

Aceptar

Al cerrar la alerta, en la parte inferior derecha de la pantalla se despliega un esquema del corazón que señala la región posiblemente afectada o sin ningún posible indicio de IAMCEST. Las letras A–E identifican las condiciones cardíacas: A) Normal, B) Septal, C) Anterior, D) Inferior y E) Lateral, facilitando la interpretación visual del resultado.



Uso de la aplicación

En la parte central de la interfaz se presentan los resultados de los modelos de estimación primaria y estimación complementaria, cada uno en un recuadro que muestra la probabilidad de IAMCEST y la localización anatómica correspondiente. Cuando un paciente presenta alta probabilidad de IAMCEST (valores iguales o superiores al 80%), se indica la localización del infarto, lo que refleja un posible evento isquémico agudo. En cambio, si la probabilidad es inferior al 80%, la localización se muestra como “Ninguna”, lo que indica que no se identifican patrones asociados a IAMCEST, aunque podrían existir otras alteraciones cardíacas, como arritmias u otras condiciones.




3.5 Generación del reporte clínico

En la esquina superior derecha de la pantalla se encuentra un menú desplegable que ofrece acciones adicionales, como cerrar sesión o descargar el reporte del estudio.

Al seleccionar la opción “Descargar reporte”, el sistema iniciará el proceso de generación del archivo, el cual puede tardar aproximadamente entre 15 y 30 segundos.

Una vez completado, se abrirá una ventana emergente que permitirá al usuario guardar el reporte en formato PDF o enviarlo a impresión directamente.



Uso de la aplicación

El reporte en formato PDF contiene la información del paciente, los resultados de los modelos de detección de IAMCEST a partir de dos estimaciones: primaria y complementaria, la localización anatómica estimada del infarto, un espacio para comentarios, y el registro completo del ECG de 12 derivaciones.

MyoAlert Vision

Información del paciente

Nombre: William Obregon
Tipo de identificación: CC
Número de identificación: 123456789
Edad: 20
Fecha y hora del reporte: 2025-10-25 10:58:01

Probabilidad de Infarto Agudo de Miocardio con Elevación del Segmento ST

Estimación primaria: 97.57% Estimación complementaria: 95.05%

Localización anatómica estimada del infarto

Anterior

Comentarios

Paciente ingresa a urgencias presentando dolor torácico opresivo, irradiado al brazo izquierdo. Refiere disnea, sudoración fría y náuseas asociadas. Se genera el reporte y se confirma infarto anterior.

Electrocardiograma



Bibliografía

- [1] R. S. de Investigación, “Infarto agudo de miocardio: Un artículo monográfico,” *Revista Sanitaria de Investigación*, 2025, accedido: 2025-04-28. [Online]. Available: <https://revistasanitariadeinvestigacion.com/infarto-agudo-de-miocardio-articulo-monografico/>
- [2] A. H. Association, “Las enfermedades cardiovasculares siguen siendo la principal causa de muerte, mientras aumentan los principales factores de riesgo para la salud,” 2025, accedido: 2025-04-28. [Online]. Available: <https://newsroom.heart.org/news/las-enfermedades-cardiovasculares-siguen-siendo-la-principal-causa-de-muerte-mientras-aumentan-los-principales-factores-de-riesgo-para-la-salud>
- [3] M. de Salud y Protección Social de Colombia, “Enfermedades cardiovasculares,” 2025, accedido: 2025-04-28. [Online]. Available: <https://www.minsalud.gov.co/salud/Paginas/Enfermedades-cardiovasculares.aspx>
- [4] J. Aboal, R. Ramos, P. Loma-Osorio, M. Núñez, M. Comas-Cufí, J. Iglesias, S. Moral, D. Bosch, R. Martí-Lluch, L. Alves-Cabratosa, and R. Brugada, “Factores asociados a retrasos de tiempo desde el electrocardiograma diagnóstico hasta el paso de guía en el infarto agudo de miocardio con elevación del segmento st transferido para angioplastia primaria,” *Emergencias*, vol. 33, pp. 195–202, 2021. [Online]. Available: <https://emergencias.portalsemes.org/descargar/factores-asociados-a-retrasos-de-tiempo-desde-el-electrocardiograma-diagnostico-hasta-el-paso-de-guia-en-el-infarto-agudo-de-miocardio-con-elevacion-del-segmento-st-transferido-para-angioplastia-primaria/>
- [5] K.-C. Chang, P.-H. Hsieh, M.-Y. Wu, Y.-C. Wang, J.-T. Wei, E. S. C. Shih, M.-J. Hwang, W.-Y. Lin, W.-T. Lin, K.-J. Lee, and T.-H. Wang, “Usefulness of multi-labelling artificial intelligence in detecting rhythm disorders and acute st-elevation myocardial infarction on 12-lead electrocardiogram,” *European Heart Journal - Digital Health*, vol. 2, no. 2, pp. 299–310, Jun 2021.
- [6] World Health Organization, “Enfermedades cardiovasculares,” June 2021, accessed: January 28, 2024. [Online]. 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))
- [7] Departamento Administrativo Nacional de Estadística (DANE), “Boletín técnico de estadísticas vitales: Defunciones fetales y no fetales iv trimestre 2022pr, acumulado 2022pr y año corrido 2023pr,” Departamento Administrativo Nacional de Estadística (DANE), Tech. Rep., 2023, documento obtenido de archivo personal.
- [8] Mayo Clinic Proceedings, “Comprehensive electrocardiographic evaluation of acute myocardial infarction,” *Mayo Clinic Proceedings*, vol. 87, no. 1, pp. 73–76, 2012.

- [9] Fundación Cardiovascular de Colombia, “Infarto cardíaco: Detectar los síntomas a tiempo salva vidas,” 2024, [Accessed: Mar. 14, 2025]. [Online]. Available: <https://hic.fcv.org/co/blog/instituto-cardiovascular/infarto-cardiaco-detectar-los-sintomas-a-tiempo-salva-vidas>
- [10] National Institutes of Health (NIH), *Coronary Artery Disease*, 1st ed. USA: National Center for Biotechnology Information (NCBI), 2023. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK459269/>
- [11] S. Aydin, K. Ugur, S. Aydin, Sahin, and M. Yardim, “Biomarkers in acute myocardial infarction: current perspectives,” *Vascular Health and Risk Management*, vol. 15, pp. 1–10, 2019.
- [12] B. W. Y. S. D. F. Miranda, A. S. Lobo and S. W. Smith, “New insights into the use of the 12-lead electrocardiogram for diagnosing acute myocardial infarction in the emergency department,” *Canadian Journal of Cardiology*, vol. 34, pp. 132–145, 2018.
- [13] ECG Waves, “Acute coronary syndromes (acs) & myocardial infarction (ami),” 2025, accessed: Mar. 14, 2025. [Online]. Available: <https://ecgwaves.com/topic/acute-coronary-syndromes-acs-myocardial-infarction-ami/#toc-heading-2>
- [14] A. Kashou, A. May, C. DeSimone, , and P. Noseworthy, “The essential skill of ecg interpretation: How do we define and improve competency?” *Postgraduate Medical Journal*, vol. 96, no. 1133, pp. 125–127, 2019.
- [15] M. E. Yadegarfar, C. P. Gale, T. B. Dondo, R. K. Hall, K. Stables, M. C. Rutherford, C. Ludman, , and C. P. Rao, “Association of treatments for acute myocardial infarction and survival for seven common comorbidity states: a nationwide cohort study,” *BMC Medicine*, vol. 18, no. 231, 2020.
- [16] Y. K. J.-H. K. H.-J. P. H. Yoo, Y. Yum and H. J. Joo, “Restoration of missing or low-quality 12-lead ecg signals using ensemble deep-learning model with optimal combination,” *Biomedical Signal Processing and Control*, vol. 83, p. Art. no. 104690, 2023, online.
- [17] C. D.-P. N. T. J. B. N. S. A. K. B. A. M. W. C. B. J. S. P. A. F. B. P. S. B. W. W. A. M. K. A. H. Kashou, A. May and A. Braisted, “Exploring factors influencing ecg interpretation proficiency of medical professionals,” *Current Problems in Cardiology*, vol. 48, no. 10, p. Art. no. 101865, 2023, online.
- [18] E. C. L. Y. Wang and H. M. Krumholz, “Title of the article,” *JAMA Cardiology*, vol. 7, no. 6, pp. 613–622, Jun 2022.
- [19] C. M.-L. R.-P. A. Gadella, M. Á. Sastre and M. Arias, “Infarto agudo de miocardio con elevación del segmento st en tiempos de covid-19: ¿regreso al siglo pasado? una llamada de atención,” *Revista Española de Cardiología*, vol. 73, no. 7, pp. 582–583, May 2020.

- [20] Ministerio de Salud y Protección Social, “Mortalidad en Colombia periodo 2020 -2021,” 2024, accessed: Apr. 2025. [Online]. Available: <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/VS/ED/GCFI/mortalidad-colombia-periodo-2020-2021.pdf>
- [21] A. Taherinia *et al.*, “Diagnostic value of standard electrocardiogram in acute right ventricular myocardial infarction,” *European Journal Of Translational Myology*, vol. 29, no. 2, May 2019.
- [22] M. Martínez-Sellés and M. Marina-Breyse, “Current and future use of artificial intelligence in electrocardiography,” *Journal of Cardiovascular Development and Disease*, vol. 10, no. 4, p. 175, 2023.
- [23] Z. I. Attia, D. M. Harmon, E. R. Behr, and P. A. Friedman, “Application of artificial intelligence to the electrocardiogram,” *The Lancet Digital Health*, vol. 4, no. 7, pp. e446–e455, 2022, accessed: 2025-04-16.
- [24] K. Abdu, A. O. Elfaki, M. Boulahya, and A. Abdalla, “Deep learning-based computer-aided diagnosis systems for chest x-ray lung image classification: A survey,” *Computer Methods and Programs in Biomedicine*, vol. 208, p. 106239, 2021, accessed: 2025-04-16.
- [25] N. J. Mehta and I. A. Khan, “Cardiology’s 10 greatest discoveries of the 20th century,” *Journal of the American College of Cardiology*, vol. 53, no. 10, pp. 930–942, 2009, accessed: 2025-04-16.
- [26] Z. Liu, W. Zhang, Y. Zhang, and H. Li, “Advancements and applications of artificial intelligence in cardiovascular disease diagnosis and treatment,” *Journal of Cardiovascular Translational Research*, vol. 15, no. 4, pp. 1234–1247, 2024, accessed: 2025-04-16.
- [27] P. Xiong, S. M.-Y. Lee, and G. Chan, “Deep learning for detecting and locating myocardial infarction by electrocardiogram: A literature review,” *Frontiers in Cardiovascular Medicine*, vol. 9, p. 860032, 2022, accessed: 2025-04-16.
- [28] Z. Liu, W. Zhang, Y. Zhang, and H. Li, “Ecg data analysis to determine st-segment elevation myocardial infarction and infarction territory type: An integrative approach of artificial intelligence and clinical guidelines,” *Frontiers in Physiology*, vol. 15, p. 1462847, 2024, accessed: 2025-04-16.
- [29] R. Chaudhry, J. H. Miao, and A. Rehman, “Physiology, cardiovascular,” in *StatPearls [Internet]*. Treasure Island (FL): StatPearls Publishing, 2022, accessed: 2025-04-16. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK493197/>
- [30] A. R. Lee. (2024) How the cardiovascular system works (and fails). Reviewed by Jeffrey S. Lander, MD. [Online]. Available: <https://www.verywellhealth.com/cardiovascular-system-8695175>
- [31] Raritan Valley Community College, “Heart and blood vessels,” in *Human Biology*. Treasure Island, FL: Raritan Valley Community College, 2024, accessed: 2025-04-16. [Online]. Available: <https://rvcc.pressbooks.pub/humanbiology/chapter/heart-and-blood-vessels/>

- [32] K. Carter and M. Rutherford. (2024) Cardiovascular system – blood vessels and blood. Accessed: 2025-04-16. [Online]. Available: <https://ecampusontario.pressbooks.pub/medicalterminology/chapter/cardiovascular-system/>
- [33] Clínica Universidad de Navarra. (2025) Infarto de miocardio. Accessed: 2025-04-16. [Online]. Available: <https://www.cun.es/enfermedades-tratamientos/enfermedades/infarto-miocardio>
- [34] J. A. Ambrose and M. Singh, “Pathophysiology of coronary artery disease leading to acute coronary syndromes,” *F1000Prime Reports*, vol. 7, p. 08, 2015, accessed: 2025-04-16.
- [35] J. Reyes-Retana and L. Duque-Ossa, “Acute myocardial infarction biosensor: A review from bottom up,” *Current Problems In Cardiology*, vol. 46, no. 3, p. 100739, 2021.
- [36] X. Zhao, Y. Zhang, Y. Zhang, Y. Zhang, and Y. Zhang, “Acute myocardial infarction biosensor: A review from bottom up,” *Biosensors and Bioelectronics*, vol. 165, p. 112393, 2020, accessed: 2025-04-16.
- [37] Mayo Clinic. (2023) Síndrome coronario agudo – síntomas y causas. Accedido: 2025-04-16. [Online]. Available: <https://www.mayoclinic.org/es/diseases-conditions/acute-coronary-syndrome/symptoms-causes/syc-20352136>
- [38] R. N. Sweis and A. Jivan. (2024) Acute myocardial infarction (mi). Accessed: 2025-04-16. [Online]. Available: <https://www.merckmanuals.com/professional/cardiovascular-disorders/coronary-artery-disease/acute-myocardial-infarction-mi>
- [39] H. Akbar, C. Foth, R. A. Kahloon, and S. Mountfort, “Acute st-segment elevation myocardial infarction (STEMI),” in *StatPearls*. Treasure Island (FL): StatPearls Publishing, 2024, accessed: 2025-04-16. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK532281/>
- [40] Testing.com. (2021) Cardiac biomarkers. Accessed: 2025-04-16. [Online]. Available: <https://www.testing.com/tests/cardiac-biomarkers/>
- [41] D. Chan and L. L. Ng, “Biomarkers in acute myocardial infarction,” *BMC Medicine*, vol. 8, p. 34, 2010, accessed: 2025-04-16.
- [42] Y. T. Sia, E. O’Meara, and A. Ducharme, “Role of echocardiography in acute myocardial infarction,” *Current Heart Failure Reports*, vol. 5, no. 4, pp. 189–196, 2008, accessed: 2025-04-16. [Online]. Available: <https://link.springer.com/article/10.1007/s11897-008-0029-6>
- [43] A. Nair, C. G. Sajeev, and K. Muneer, “A case of recent myocardial infarction with cardiac failure,” *Heart*, vol. 103, no. 7, p. 508, 2017, accessed: 2025-04-16.
- [44] T. Cascino and M. J. Shea. (2023) Stress testing. Accessed: 2025-04-16. [Online]. Available: <https://www.merckmanuals.com/professional/cardiovascular-disorders/cardiovascular-tests-and-procedures/stress-testing>

- [45] ECG Waves. (2016) The ecg leads: Electrodes, limb leads, chest (precordial) leads and the 12-lead ecg. Accessed: 2025-04-16. [Online]. Available: <https://ecgwaves.com/topic/ekg-ecg-leads-electrodes-systems-limb-chest-precordial/>
- [46] M. A. Karim and N. Mishra, *Electrocardiogram*. Treasure Island (FL): StatPearls Publishing, 2023, available from: <https://www.ncbi.nlm.nih.gov/books/NBK549803/>, Accessed: 2025-04-17.
- [47] K. Wesley, *Huszar's ECG and 12-Lead Interpretation*, 6th ed. Elsevier, 2021.
- [48] E. Waves, "Cardiac electrophysiology: Action potentials, automaticity and vectors," n.d., accessed: 2025-04-17. [Online]. Available: <https://ecgwaves.com/topic/cardiac-electrophysiology-ecg-action-potential-automaticity-vector/>
- [49] Y. Sattar and L. Chhabra, *Electrocardiogram*. Treasure Island (FL): StatPearls Publishing, 2023, disponible en: <https://www.ncbi.nlm.nih.gov/books/NBK549803/>, Accedido: 2025-04-17.
- [50] Laboratorio Clínico Hematológico. (2023) Ayudas cardiagnósticas. [Online]. Available: <https://lch.co/ayudas-cardiagnosticas/>
- [51] Big Apollo Spectra Hospital. (2025) Normal vs abnormal ecg: Understanding 6 key differences. [Online]. Available: <https://bigapollospectra.com/blog/normal-vs-abnormal-ecg-understanding-key-differences/>
- [52] ACLSNow. (2025) Ecgs in acute myocardial infarction. Disponible en: <https://aclsnow.com/blog/ecgs-in-acute-myocardial-infarction/>, Accedido: 2025-04-17. [Online]. Available: <https://aclsnow.com/blog/ecgs-in-acute-myocardial-infarction/>
- [53] ECG Waves. (2025) Criterios diagnósticos para el infarto agudo de miocardio: troponinas cardíacas, ecg y síntomas. [Online]. Available: <https://ecgwaves.com/topic/diagnostic-criteria-acute-myocardial-infarction-troponins-ecg-symptoms/#toc-heading-3>
- [54] T. Holton, *Digital Signal Processing: Principles and Applications*. Cambridge, U.K.: Cambridge University Press, 2021.
- [55] L. Tan, *Digital Signal Processing: Fundamentals and Applications*. Amsterdam: Academic Press, 2007.
- [56] L. da F. Costa. (2022) Data normalization in signal and pattern analysis and recognition: A modeling approach. [Online]. [Online]. Available: <https://hal.science/hal-03688208v2>
- [57] M. Alivon *et al.*, "A novel device for measuring arterial stiffness using finger-toe pulse wave velocity: Validation study of the popmètre®," *Archives of Cardiovascular Diseases*, vol. 108, no. 4, pp. 227–234, Feb. 2015.

- [58] S. G. Braun, D. J. Ewins, and S. S. Rao, *Encyclopedia of Vibration, Volumes 1-3*. Elsevier, 2002.
- [59] Keras, “Flatten layer — keras api,” n.d., accessed: 2025-10-16. [Online]. Available: https://keras.io/api/layers/reshaping_layers/flatten/
- [60] NumPy, “numpy.ndarray.flatten — numpy v1.x manual,” n.d., accessed: 2025-10-16. [Online]. Available: <https://numpy.org/doc/stable/reference/generated/numpy.ndarray.flatten.html>
- [61] M. M. E. Vasconcellos, B. G. Ferreira, J. S. Leandro, B. F. S. Neto, F. R. Cordeiro, and I. A. Cestari, “Siamese convolutional neural network for heartbeat classification using limited 12-lead ecg datasets,” *IEEE Access*, vol. 11, pp. 5365–5376, 2023, accessed: 2025-10-16. [Online]. Available: <https://ieeexplore.ieee.org/document/10015021>
- [62] A. K. Singh and S. Krishnan, “Ecg signal feature extraction trends in methods and applications,” *BioMed Engineering OnLine*, vol. 22, no. 22, 2023.
- [63] V. S. Pham, A. Nguyen, H. B. Dang *et al.*, “Diagnosis of sudden cardiac arrest using principal component analysis in automated external defibrillators,” *Scientific Reports*, vol. 13, p. 8768, 2023.
- [64] S. M. Lundberg and S. I. Lee, “A unified approach to interpreting model predictions,” in *Advances in Neural Information Processing Systems (NeurIPS)*, vol. 30, 2017.
- [65] N. A. Wani, R. Kumar, Mamta, J. Bedi, and I. Rida, “Explainable ai-driven iomt fusion: Unravelling techniques, opportunities, and challenges with explainable ai in healthcare,” *Information Fusion*, vol. 110, p. 102472, 2024.
- [66] C. A. Berry and B. Marshall, *Mitigating Bias in Machine Learning*, 1st ed. New York, NY, USA: McGraw Hill, 2025.
- [67] J. Fan, W. Meng, G. Liu, H. Wang, and J. Liu, “Comparison of support vector machine and extreme gradient boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in china,” *Energy Conversion and Management*, vol. 164, pp. 102–111, March 2018.
- [68] L. Li, W. Ren, Y. Lei *et al.*, “Hybrid cnn-transformer-woa model with xgboost-shap feature selection for arrhythmia risk prediction in acute myocardial infarction patients,” *BMC Medical Informatics and Decision Making*, vol. 25, p. 291, 2025.
- [69] B. S. Wardani, S. Sa’adah, and D. Nurjanah, “Measuring and mitigating bias in bank customers data with xgboost, lightgbm, and random forest algorithm,” *J. Ilm. Tek. Elektro Komput. Dan Inform.*, vol. 9, no. 1, pp. 142–155, Mar. 2023.
- [70] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaria, M. A. Fadhel, M. Al-Amidie, and L. Farhan, “Review of deep

- learning: concepts, cnn architectures, challenges, applications, future directions,” *Journal of Big Data*, vol. 8, no. 1, p. 53, 2021, accessed: 2025-10-16. [Online]. Available: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-021-00444-8>
- [71] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, “Convolutional neural networks: an overview and application in radiology,” *Insights into Imaging*, vol. 9, no. 4, pp. 611–629, 2018, accessed: 2025-10-16. [Online]. Available: <https://insightsimaging.springeropen.com/articles/10.1007/s13244-018-0639-9>
- [72] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, and M. Gabbouj, “1-d convolutional neural networks for signal processing applications,” in *ICASSP 2019 – 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 8360–8364, accessed: 2025-10-16. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8682194>
- [73] S. Kiranyaz, T. Ince, O. Avci, O. Abdeljaber, and M. Gabbouj, “1d convolutional neural networks and applications: A survey,” *Mechanical Systems and Signal Processing*, vol. 151, p. 107398, 2021, accessed: 2025-10-16. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0888327020307846>
- [74] F. Khan, X. Yu, Z. Yuan, and A. U. Rehman, “Ecg classification using 1-d convolutional deep residual neural network,” *PLoS One*, vol. 18, no. 4, p. e0284791, 2023, accessed: 2025-10-16. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10128986/>
- [75] A. M. Sowjanya and O. Mrudula, “Effective treatment of imbalanced datasets in health care using modified smote coupled with stacked deep learning algorithms,” *Applied Nanoscience*, vol. 13, no. 3, pp. 1829–1840, 2023, accessed: 2025-10-16. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8811587/>
- [76] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “Smote: Synthetic minority over-sampling technique,” *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002, accessed: 2025-10-16. [Online]. Available: <https://www.jair.org/index.php/jair/article/view/10302>
- [77] A. Fernández, S. García, M. Galar, R. C. Prati, B. Krawczyk, and F. Herrera, “Sampling methods for imbalanced learning,” in *Learning from Imbalanced Data Sets*. Springer, 2018, ch. 5, pp. 123–145. [Online]. Available: https://doi.org/10.1007/978-3-319-98074-4_5
- [78] M. Imani, A. Beikmohammadi, and H. R. Arabnia, “Comprehensive analysis of random forest and xgboost performance with smote, adasyn, and gnus under varying imbalance levels,” *Technologies*, vol. 13, no. 3, p. 88, 2025, accessed: 2025-10-16. [Online]. Available: <https://www.mdpi.com/2227-7080/13/3/88>
- [79] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” *Journal of Big Data*, vol. 6, no. 1, p. 60, 2019, accessed: 2025-10-16. Referenced

- section: 3.2, “Noise Injection”. [Online]. Available: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-019-0197-0>
- [80] J. Beinecke and D. Heider, “Gaussian noise up-sampling is better suited than smote and adasyn for clinical decision making,” *BioData Mining*, vol. 14, no. 1, p. 49, 2021, accessed: 2025-10-16. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8628399/>
- [81] P. S. Foundation, “What is python? executive summary,” <https://www.python.org/doc/essays/blurb/>, n.d., accessed: 2025-10-16.
- [82] NumPy, “What is numpy?” <https://numpy.org/doc/stable/user/whatisnumpy.html>, n.d., accessed: 2025-10-16.
- [83] pandas Development Team, “Overview — pandas: Getting started,” https://pandas.pydata.org/docs/getting_started/overview.html, n.d., accessed: 2025-10-16.
- [84] M. D. Team, “Matplotlib: Visualization with python,” <https://matplotlib.org/>, n.d., accessed: 2025-10-16.
- [85] T. Team, “Tensorflow,” <https://www.tensorflow.org/>, n.d., accessed: 2025-10-16.
- [86] P. Projects, “Flask — web development, one drop at a time,” <https://flask.palletsprojects.com/en/stable/>, n.d., accessed: 2025-10-16.
- [87] P. S. Foundation, “json — json encoder and decoder,” <https://docs.python.org/3/library/json.html>, n.d., accessed: 2025-10-16.
- [88] W. D. Team, “wfdb — wfdb documentation,” <https://wfdb.readthedocs.io/en/latest/>, n.d., accessed: 2025-10-16.
- [89] Microsoft, “Visual studio code documentation,” <https://code.visualstudio.com/docs>, n.d., accessed: 2025-10-16.
- [90] A. Souha, L. Benaddi, C. Ouaddi, and A. Jakimi, “Comparative analysis of mobile application frameworks: A developer’s guide for choosing the right tool,” *Procedia Computer Science*, vol. 236, pp. 597–604, 2024.
- [91] Y.-W. Li, X.-D. Yang, Y.-C. Cai, and X.-Y. Kong, “Artificial intelligence-based prediction of acute myocardial infarction mortality risk,” in *2023 2nd International Conference on Health Big Data and Intelligent Healthcare (ICHIH)*, vol. 21. Fuzhou, China: IEEE, October 2023, pp. 164–169.
- [92] A. D. Marco, M. Rodriguez, J. Cinca, A. Bayes-Genis, J. T. Ortiz-Perez, A. Ariza-Solé, J. C. Sanchez-Salado, A. Sionis, J. Rodriguez, B. Toledano, P. Codina, E. Solé-González, M. Masotti, J. A. Gómez-Hospital, Ángel Cequier, and I. Anguera, “New electrocardiographic algorithm for the diagnosis of acute myocardial infarction in patients with left bundle branch

- block,” *Journal of the American Heart Association*, vol. 9, no. 14, p. e015573, 2020. [Online]. Available: <https://www.ahajournals.org/doi/abs/10.1161/JAHA.119.015573>
- [93] L. Wu, B. Zhou, D. Liu, L. Wang, X. Zhang, L. Xu, L. Yuan, H. Zhang, Y. Ling, G. Shi, S. Ke, X. He, B. Tian, Y. Chen, and X. Qian, “Lasso regression-based diagnosis of acute st-segment elevation myocardial infarction (STEMI) on electrocardiogram (ECG),” *Journal of Clinical Medicine*, vol. 11, no. 18, 2022.
- [94] J. Doe, J. Smith, and R. Johnson, “Development of clinically validated artificial intelligence model for early detection of coronary artery disease,” *Journal of Vascular Surgery*, vol. 80, no. 5, pp. 1175–1185, 2024.
- [95] ECG Waves. (2025) STEMI (ST elevation myocardial infarction): Diagnosis, ECG, criteria, and management. [Online]. Available: <https://ecgwaves.com/topic/stemi-st-elevation-myocardial-infarction-criteria-ecg/>
- [96] A. L. Goldberger, J. S. Alpert, G. S. Reeder, and et al., “A new terminology for left ventricular walls and location of myocardial infarction,” *Circulation*, vol. 114, no. 17, pp. 1755–1760, 2006, accessed: 2025-04-17.
- [97] B. Gow, T. Pollard, L. A. Nathanson, A. Johnson, B. Moody, C. Fernandes, N. Greenbaum, J. W. Waks, P. Eslami, T. Carbonati, A. Chaudhari, E. Herbst, D. Moukheiber, S. Berkowitz, R. Mark, and S. Horng, “Mimic-iv-ecg: Diagnostic electrocardiogram matched subset (version 1.0),” PhysioNet, 2023, rRID:SCR_007345.
- [98] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. C. Ivanov, R. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, “Physiobank, physiokit, and physionet: Components of a new research resource for complex physiologic signals,” *Circulation [Online]*, vol. 101, no. 23, pp. e215–e220, 2000, rRID:SCR_007345.
- [99] G. Verma, H. Gocher, and S. Verma, “Enhanced arrhythmia detection using spiking neural networks: An in-depth analysis of ECG data from the MIMIC-IV clinical database,” *Neural Computing and Applications*, vol. 37, pp. 24365–24384, 2025.
- [100] B. Zhao, Z. Gao, X. Liu, Z. Zhang, W. Xiao, and S. Zhang, “DRL-ECG-HF: Deep reinforcement learning for enhanced automated diagnosis of heart failure with imbalanced ECG data,” *Bio-medical Signal Processing and Control*, vol. 107, p. 107680, 2025.
- [101] M. E. Valentinuzzi, “Bioelectrical signal processing in cardiac and neurological systems,” *Journal of Neuroscience Methods*, vol. 162, no. 1-2, pp. 1–3, 2007. [Online]. Available: <https://pmc.ncbi.nlm.nih.gov/articles/PMC1939853/>
- [102] D. Ricciardi, I. Cavallari, A. Creta, G. Di Giovanni, V. Calabrese, N. Di Belardino, S. Mega, I. Colaiori, L. Ragni, C. Proscia, A. Nenna, and G. Di Sciascio, “Impact of the high-frequency cutoff of bandpass filtering on ECG quality and clinical interpretation:

A comparison between 40hz and 150hz cutoff in a surgical preoperative adult outpatient population,” *J Electrocardiol*, vol. 49, no. 5, pp. 691–695, 2016. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/27498055/>