



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ
FACULTAD DE CIENCIAS E INGENIERÍA

UNIVERSIDAD PERUANA CAYETANO HEREDIA
FACULTAD DE CIENCIAS E INGENIERÍA “Alberto
Cazorla Talleri”

“TECNOLOGÍAS BASADAS EN INTELIGENCIA
ARTIFICIAL PARA EL DIAGNÓSTICO DEL SÍNDROME
CORONARIO AGUDO: UNA REVISIÓN SISTEMÁTICA”

Tesis para obtener el título profesional de Ingeniero Biomédico

que presenta:

Jesus Francisco Paucar Escalante


Asesor(es):

Pablo Alejandro Fonseca Arroyo
Pedro Antonio Segura Saldaña

Lima, 2023

TECNOLOGIAS BASADAS EN INTELIGENCIA ARTIFICIAL PARA EL DIAGNOSTICO DEL SINDROME CORONARIO AGUDO.docx

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	Submitted to Universidad de Salamanca Trabajo del estudiante	3%
2	repositorio.unfv.edu.pe Fuente de Internet	2%
3	pubmed.ncbi.nlm.nih.gov Fuente de Internet	1%
4	cdn.amegroups.cn Fuente de Internet	1%
5	assets.researchsquare.com Fuente de Internet	1%

Asesor:

Pablo Alejandro Fonseca Arroyo, Ing. MSc.

Facultad de Ciencias e Ingeniería Alberto Cazorla Talleri

Co Asesor:

Pedro Antonio Segura Saldaña, MD

Facultad de Ciencias e Ingeniería Alberto Cazorla Talleri

Dedicatoria:

A mis padres, fuente inagotable de amor, apoyo y sabiduría. Este logro es el reflejo de sus sacrificios y dedicación. A mi familia, por ser el pilar en el que me he apoyado en cada paso de este camino. A mis amigos, por su aliento y compañía a lo largo de esta travesía académica.

Agradecimiento:

Quiero expresar mi profundo agradecimiento a mi asesor, MSc. Pablo Fonseca y co asesor, MD Pedro Segura; cuyas orientaciones expertas y paciencia infinita han sido fundamentales para el desarrollo de esta tesis. Sus valiosos comentarios y dirección han dejado una huella duradera en mi formación académica.

Este viaje académico ha sido una experiencia transformadora, y a cada persona que ha contribuido a mi crecimiento, les doy las gracias de corazón.

Fuentes de financiamiento:

El presente proyecto de investigación ha sido autofinanciado por el autor

TABLA DE CONTENIDOS

TABLA DE CONTENIDOS	
Resumen	2
Abstract	3
I. INTRODUCCIÓN	4
II. PREGUNTA DE INVESTIGACIÓN Y OBJETIVOS	7
1. Pregunta de investigación	7
2. Objetivos	7
III. MARCO TEÓRICO	8
1. Conceptos claves	8
1.1. Definición Operacional de Inteligencia Artificial	8
1.2. Clasificación de Inteligencia Artificial	8
a. Inteligencia Artificial (IA)	9
b. Machine Learning (ML)	9
c. Deep Learning (DL)	9
d. Data Science (DS)	10
1.3. Métricas importantes	11
a. Precisión	12
b. Sensibilidad	12
c. Especificidad	12
d. Índice de Jaccard	12
e. Índice de Dice	12
IV. METODOLOGÍA	14
1. Diseño del estudio	14
2. Estrategia de búsqueda	14
3. Criterios de inclusión y exclusión	14
4. Selección de estudios	15
5. Extracción de datos	15
6. Procedimientos para evaluación de calidad de estudios científicos	15
V. RESULTADOS	16
1. Búsqueda	16
2. Evaluación del riesgo del sesgo	16
3. Características de los estudios	16
Tabla 1.a. Tabla de tiempo para algoritmos de primera generación	22
Tabla 1.b Tabla de tiempo para algoritmos de segunda generación	22
Tabla 1.c Tabla de tiempo para algoritmos de tercera generación	23
VI. DISCUSIÓN	29
VII. CONCLUSIONES	40
VIII. RECOMENDACIONES	42
Referencias bibliográficas:	43
IX. ANEXOS	47
Tablas y Figuras	47
Figura 6. Diagrama de flujo para la selección de los estudios incluidos	47
Tabla 2. Características de los estudios	48
Tabla 3. Evaluación de la calidad de los estudios de incidencia según escala de New Castle Ottawa – Cohorte	67

Tabla 4. Evaluación de la calidad de los estudios de incidencia según escala de New Castle Ottawa – Casos y controles	68
Tabla 5. Características de los estudios incluidos	69
Tabla 6: Métricas según Modelo para el estudio 18	74
MATERIAL SUPLEMENTARIO	75
Tabla suplementaria 1: PRISMA Statement for Reporting Systematic Reviews and Meta-Analyses.	75
Tabla suplementaria 2: Estrategia de búsqueda.	77

Resumen

Objetivo: Identificar el desarrollo de las tecnologías basadas en inteligencia artificial que sean capaces de diagnosticar el síndrome coronario agudo (SCA).

Materiales y métodos: Se llevó a cabo una búsqueda sistemática en múltiples bases de datos, incluyendo Medline, SCOPUS, IEEE XPLORE y EMBASE, con el propósito de identificar investigaciones relacionadas con la aplicación de herramientas inteligentes como Machine Learning (ML) y Deep Learning (DL) con la capacidad de diagnosticar el SCA. Esta búsqueda se centró en estudios que siguieran la definición proporcionada en la guía práctica clínica de la Sociedad Europea de Cardiología 2021 y que estuvieran disponibles hasta el 2 de agosto del 2021. Se incluyeron investigaciones de tipo cohorte, casos y controles cuyos resultados incidieran directamente en la posibilidad de diagnóstico del SCA. Sin embargo, se excluyeron aquellos estudios donde solo se utilizaron señales ECG. Para evaluar el riesgo del sesgo en los estudios, utilizamos la escala de New Castle – Ottawa.

Resultados: Un total de 24 artículos científicos fueron identificados para la revisión sistemática. No se realizó meta – análisis debido a la heterogeneidad clínica de los estudios mientras que el enfoque realizado se basó en tres perspectivas: 1) Tecnología usada, 2) Países de desarrollo del estudio y 3) Generación del algoritmo aplicado en cada estudio. Se halló una mayor frecuencia para estudios realizados por tomografía con un gran desarrollo de algoritmos basados en ML y DL encontrando los mejores resultados para el caso de DL con un 99.5% de precisión. Así mismo, por países, se encontró la predominancia de estudios en China seguido por Estados Unidos cuyas aspiraciones se basan en el liderazgo en el campo de la Inteligencia Artificial.

Conclusión: Se encontró una precisión del 99.5% en DL para el diagnóstico de SCA y algunas otras con una precisión por encima del 90% con oportunidades de mejora.

Palabras clave: Síndrome Coronario Agudo, Inteligencia Artificial, Diagnóstico, Revisión sistemática

Abstract

Objective: To identify the development of artificial intelligence-based technologies capable of diagnosing acute coronary syndrome (ACS).

Materials and methods: Certain systematic searches were conducted across multiple databases, including Medline, SCOPUS, IEEE XPLORE, and EMBASE, to identify studies related to the use of intelligent tools such as Machine Learning (ML) and Deep Learning (DL) for diagnosing Acute Coronary Syndrome (ACS) in accordance with the definition provided in the 2021 practical clinical guidelines of the European Society of Cardiology. This search encompassed studies published up to August 2, 2021. We considered cohort and case-control studies that directly impacted the diagnostic potential of ACS, while excluding studies exclusively utilizing ECG signals. The assessment of study bias was carried out using the Newcastle-Ottawa Scale..

Results: A total of 24 scientific articles were identified for the systematic review. No meta-analysis was performed due to the clinical heterogeneity of the studies while the approach was based on three perspectives: 1) Technology used, 2) Countries of study development and 3) Generation of the algorithm applied in each study. A higher frequency was found for studies performed by tomography with a great development of algorithms based on ML and DL finding the best results for the case of DL with 99.5% accuracy. Likewise, by countries, it was found the predominance of studies in China followed by the United States whose aspirations are based on the leadership in the field of AI.

Conclusion: An accuracy of 99.5% was found in DL for the diagnosis of ACS and some others with an accuracy above 90% with opportunities for improvement.

Key words: Acute Coronary Syndrome, Artificial Intelligence, Diagnosis, Systematic review.

I. INTRODUCCIÓN

El síndrome coronario agudo (SCA) comprende una diversidad de manifestaciones relacionadas con enfermedades coronarias, siendo su característica central la presencia de isquemia cardiaca aguda. Estas manifestaciones se dividen en dos categorías principales: angina inestable e infarto del miocardio agudo (IAM), con una subclasificación de tres tipos característicos que son: 1) Infarto de miocardio de tipo 1, 2) Infarto de miocardio de tipo 2, 3) Infarto de miocardio de tipo 3 – 5, según la guía de práctica clínica de SCA publicada el 2021 por la Sociedad Europea de Cardiología (ECS por sus siglas en inglés). [1]

En tal sentido para el diagnóstico se recomienda tener en cuenta tres aspectos: la historia clínica, las alteraciones electrocardiográficas y las alteraciones enzimáticas (troponinas, CPK – MB). La angiografía coronaria, considerada el “estándar de oro”, juega un papel fundamental en la confirmación diagnóstica. No obstante, la primera evaluación se fundamenta, típicamente, en el electrocardiograma y/o exámenes complementarios basados en imágenes. En el mismo sentido, dentro de la historia clínica se deben recoger como referencia los principales factores de riesgo como enfermedades asociadas con aspectos de edad, antecedentes hereditarios, etc. Cabe mencionar algunos otros signos clínicos que pueden acompañar al dolor torácico, como la sudoración fría, palpitaciones, desorientación y síncope, enriqueciendo el cuadro clínico. Asimismo, es relevante destacar que los pacientes ancianos y diabéticos, al tener alterado el proceso de conducción nerviosa, pueden no percibir del mismo modo el dolor típico asociado al SCA, lo que refuerza la importancia de una evaluación completa ante sospecha que combine aspectos clínicos como los de laboratorio. [2] [39] [40]

El SCA se asocia a un riesgo significativo de muerte en un plazo de 30 días, además se reporta para el 2020 un aproximado de 1.091 millones de muertes a nivel mundial (639 469 mujeres y 452 364 hombres) representando un 23% del total respecto a todos los casos de enfermedades cardiovasculares registrados. Los países con mayor mortalidad son México (156 981), EE. UU. (112 141) y Brasil (97 170). Según los registros nacionales RENIMA-I y RENIMA-II, que se basan principalmente en datos de Lima, se observó una tasa de mortalidad intrahospitalaria después de IAM, tanto con como sin elevación del segmento ST, del 7.4% en 2008 y del 4.9% en 2013. A pesar de que el

porcentaje de mortalidad no es tan alto, el diagnóstico sigue siendo un reto debido a que se requiere de información completa que abarca desde los datos de la historia clínica del paciente hasta sus antecedentes personales y familiares, en combinación con exámenes diferenciales, como el electrocardiograma (ECG), biomarcadores, pruebas de estratificación no invasivas y la angiografía coronaria. [1] [3] [41]

En base a los datos estadísticos mencionados anteriormente, podemos decir que el SCA es una patología presente a nivel mundial, sumado a las proyecciones de aumento en los próximos 10 años, amerita un diagnóstico temprano. En tal sentido y tal como se ha descrito anteriormente, el diagnóstico del SCA muestra una alta complejidad y es por ello que se han hecho esfuerzos por realizar un diagnóstico temprano del mismo para evitar complicaciones y/o muertes asociadas al mismo, tomando la necesidad de un diagnóstico preciso y en menor tiempo, se busca métodos alternativos que ofrezcan soluciones parciales o totales con herramientas tecnológicas complementarias a las que se cuentan dentro de un centro de salud. [3]

Del mismo modo, el aumento del uso de herramientas de gestión electrónicas ha dado paso a las aplicaciones clínicas basadas en algoritmos inteligentes con la intención de reducir el tiempo de diagnóstico mejorando la precisión del mismo, brindando finalmente un servicio de calidad. Sin embargo, estas herramientas de diagnóstico no son consideradas para la toma de decisiones finales a pesar que muchos de los algoritmos desarrollados arrojan resultados muy positivos medidos mediante indicadores estadísticos adecuados que permiten evaluar la efectividad de los mismos. Debemos de entender que los algoritmos basados en inteligencia artificial (IA) se definen como aquellos algoritmos que intentan emular la inteligencia humana dentro de tareas específicas, los cuales son favorecidos por el aprendizaje y razonamiento en cierto entorno que suelen ser desconocidos en un primer momento. Estas tareas específicas son tratadas en áreas como inteligencia computacional y reconocimiento de patrones con variantes en la metodología dependientes de las aplicaciones, dentro de estas variantes podemos encontrar a las redes neuronales artificiales (ANN), computación evolutiva, lógica difusa, support vector machines (SVM), redes bayesianas, entre otras. [3] [5]

En la revisión sistemática (RS) efectuada por Sprockel et al. en el año 2017 [3], se examinaron las herramientas y enfoques basados en inteligencia artificial empleados en

el diagnóstico del SCA mediante la interpretación de señales de ECG, descartaron el diagnóstico mediante métodos de imágenes y/o procesamientos alternativos de señales; tales como perfusiones miocárdicas, tomografía, resonancia magnética nuclear o angiografía coronaria invasiva, telemetría u otros conceptos de computación ubicua. Además, se evaluaron las herramientas en términos de evaluaciones de factores de riesgo, pronóstico del SCA e intervenciones terapéuticas. Esta RS, referenciada en [3], culminó con una selección final de 35 artículos, y se llegó a la conclusión de que las redes neuronales convolucionales predominaron en su uso, demostrando un alto rendimiento (96% de precisión), superando así a los métodos tradicionales de machine learning como árboles de decisiones y support vector machines. A pesar de estos hallazgos, con alta precisión, las herramientas inteligentes no son usualmente usadas en la práctica clínica debido a que ninguna de estas herramientas logra cumplir con todas las condiciones de seguridad necesarias en el ámbito clínico. [3]

El diagnóstico del SCA sigue siendo un reto para los profesionales de salud en la actualidad y sigue pendiente una estandarización en el diagnóstico. Con este propósito, dentro del marco de la presente investigación se realizó una revisión sistemática de la literatura que se enfocará en el diagnóstico del SCA, centrándose en sistemas inteligentes y herramientas basadas en inteligencia artificial. Este enfoque permitirá explorar y evaluar críticamente las diversas metodologías que han surgido en el ámbito del diagnóstico del SCA, incluyendo globalmente técnicas de señales, y de manera destacada, métodos de imágenes. Es relevante destacar que, hasta la fecha, no se ha llevado a cabo una RS que englobe de manera exhaustiva los métodos de imágenes en el ámbito del SCA. Lo realizado por Sprockel et al. en [3] abarca solamente señales ECG, sin generalizar sobre otros métodos usados en la práctica clínica. Por lo tanto, esta RS actual representará una contribución sustancial para la comprensión general y la mejora del diagnóstico del SCA en el ámbito clínico.

II. PREGUNTA DE INVESTIGACIÓN Y OBJETIVOS

1. Pregunta de investigación

El diagnóstico del SCA sigue configurando un reto dentro del campo médico, de acuerdo a la bibliografía comentada en la sección anterior; el SCA no configura una patología con alta tasa de mortalidad pero con un riesgo significativo de llevar a la muerte en un plazo de 30 días si esta no es tratada y ante ello, el diagnóstico temprano es un concepto clave. Actualmente, dicho diagnóstico requiere de mucha información completa y documentada adecuadamente, recurriendo a exámenes diferenciales de datos clínicos, señales e imágenes y que configura no solo un reto de diagnóstico, sino que un tiempo prolongado para el mismo.

En este contexto planteamos como principal problema de investigación de la presente revisión sistemática el explorar si el empleo de las herramientas basadas en inteligencia artificial puede ayudar al diagnóstico del SCA utilizando señales y/o imágenes biomédicas. De esta forma la pregunta de investigación es: *“¿Las herramientas basadas en inteligencia artificial son capaces de realizar el diagnóstico del SCA mediante señales e imágenes biomédicas?”*

2. Objetivos

El objetivo principal y/o primario de la presente RS es poder reconocer si las herramientas basadas en inteligencia artificial presentan la capacidad de ofrecer respaldo a los profesionales de salud en conjunto con las pruebas diagnósticas del SCA; examinando su rendimiento, con el propósito de desarrollar herramientas de apoyo para los médicos.

El primer objetivo secundario es analizar el performance, esto implica medir la eficacia y precisión en la tarea de diagnóstico del SCA utilizando métricas específicas de precisión, sensibilidad y especificidad, de los modelos basados en inteligencia artificial comentando sobre la potencialidad de estos.

El segundo objetivo secundario es analizar las oportunidades de uso de las herramientas basadas en inteligencia artificial en un ámbito clínico comentando sobre la ética y normativa existente en un ámbito nacional e internacional.

III. MARCO TEÓRICO

1. Conceptos claves


1.1. Definición Operacional de Inteligencia Artificial

La inteligencia artificial se define como “la automatización de actividades que asociamos con el pensamiento humano, actividades como la toma de decisiones, la resolución de problemas, el aprendizaje, entre otras y cuya evaluación se basa en que para cada actividad realizada denominada evento (E) se puede realizar una evaluación de acuerdo a criterios de performance (P) relacionada al nivel de aciertos para cada evento o actividad realizada”. [4]

1.2. Clasificación de Inteligencia Artificial

Los modelos y algoritmos inteligentes incluyen subgrupos de técnicas y algoritmos definidos como tales como Machine Learning (ML) y Deep learning (DL), del mismo modo comparte características con el concepto de Data Science (DS) tal como podemos observar en la **Figura 1**. Ante ello, es importante poder definir adecuadamente cada uno de los subgrupos para diferenciarlos y observar las similitudes entre los mismos.

Figura 1. Clasificación de Inteligencia Artificial [6]



a. Inteligencia Artificial (IA)

Definida como la automatización de actividades que se asocian con el pensamiento humano comprende una serie de algoritmos de procesamiento automático a todo nivel incluyendo ML y DL, haciendo uso del análisis matemático y estadístico para resolver actividades como toma de decisiones, resolución de problemas, aprendizaje, etc. Siendo la herramienta matemática característica en común con el concepto *Data Science* que se definirá más adelante. [4] [5]

b. Machine Learning (ML)

El concepto de ML o aprendizaje automático está mucho más delimitado y orientado a darle la capacidad de aprendizaje experimental a una máquina asociada a la inteligencia humana, al tiempo que tiene la capacidad de aprender y mejorar sus análisis en un problema específico mediante algoritmos computacionales. Esto se logra usando grandes conjuntos de datos de entrada y salida con el objetivo de reconocer patrones y “aprender” de forma efectiva en una etapa de entrenamiento para que finalmente la máquina sea capaz de realizar recomendaciones o tomar decisiones de forma autónoma. [5]

c. Deep Learning (DL)

El concepto de aprendizaje profundo (DL) se hace específico para los algoritmos computacionales utilizados, en donde a comparación de ML, son redes más profundas haciendo uso de niveles jerárquicos para segregar y gestionar la salida final del algoritmo. El esquema general comprende una estructura de entradas que a su vez avanza hacia “capas ocultas” que responden a diferentes características de las entradas y es por ello que existe una comprensión de características individuales e indistintas, generando así que la máquina estudie varios conceptos específicos en múltiples niveles, perfeccionándose sucesivamente a medida que se generan entradas nuevas simulando al funcionamiento de un cerebro humano en donde mediante conexiones neuronales a partir de

conexiones dendríticas en distintos niveles jerárquicos en base a nuevas experiencias, se logra un aprendizaje. [5]

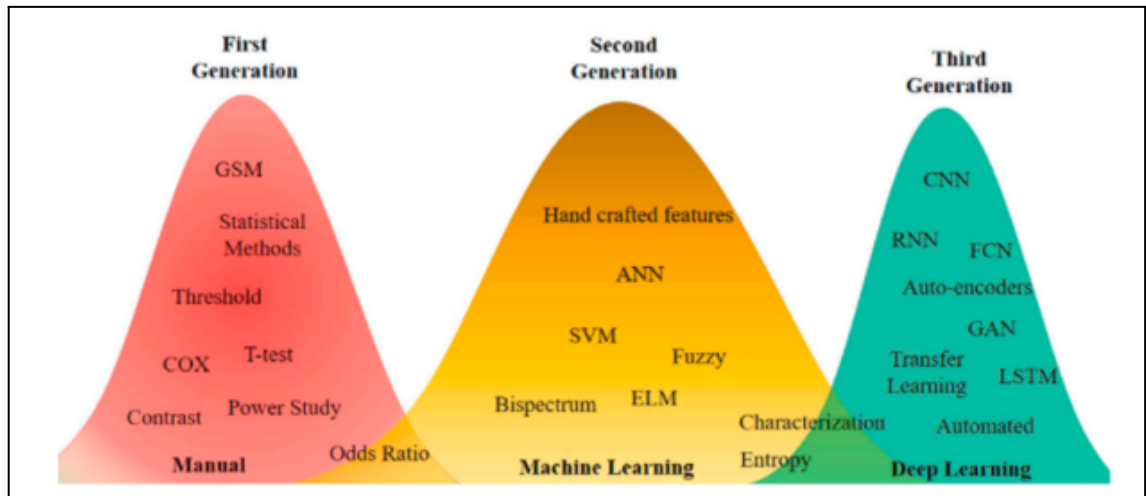
d. Data Science (DS)

Definida como un conjunto de disciplinas tales como la estadística clásica, la minería de datos, las bases de datos y los sistemas distribuidos cuya base aplicativa comprende el uso de algoritmos específicos como regresiones lineales, modelos estadísticos, agrupaciones mediante operaciones matemáticas, entre otras. Muestra características comunes con áreas como IA, ML y DL por el uso de algoritmos estadísticos, pero también muestra sus diferencias, la principal se genera debido a que DS comprende procesos de pre procesamiento, visualización y predicción de eventos mientras que la IA comprende la implementación de un modelo predictivo para un problema o tarea en específico. [6]

Del mismo modo una clasificación dilucidante de IA es la que realiza S.S. Skandha et al. y cuya perspectiva se basa en las generaciones de las arquitecturas inteligentes desarrolladas, es así que presenta un total de 3 generaciones donde la primera generación se refiere a técnicas de procesamiento manual, seguida de la segunda generación con técnicas propias de machine learning y una tercera generación con técnicas de deep learning. Dichas arquitecturas por generación se muestran en la **Figura 2** y podemos relacionar los algoritmos que se han desarrollado a través del tiempo mediante el concepto de generación.

Es así que no solo podemos realizar una definición de cada uno de los conjuntos pertenecientes a la IA, sino que también podemos saber los algoritmos específicos considerados en cada grupo de acuerdo a [7].

Figura 2. Clasificación de Algoritmos de IA por generaciones [7]



Es así que dentro de la selección de artículos, se hallaron modelos pertenecientes a la primera generación, como *"Deformable Registration Method (SCR)," "Manually Guide Point (AU)," "Contour Constrain (AO)," "Multilayer Perceptron Network (MLP),"* y *"Espacios discretos"* mediante operaciones morfológicas. Asimismo, en la segunda generación se identificaron modelos clásicos de machine learning, como *"K-Nearest Neighbors (KNN)," "Support Vector Machine (SVM)," "Random Forest (RF)," "Fuzzy Logic,"* y *"XG Boost."* Finalmente, entre los algoritmos de tercera generación se destacan *"CNN," "VGG 16," "VGG 19," "Inception V3," "YOLO," "U-Net," "ResNet," "DenseNet," "Xception," "Faster R-CNN," "AlexNet," "GoogleNet," "NasNet Large,"* y *"C-GAN."* Estas arquitecturas serán discutidas a lo largo de los resultados y la sección de discusión, según su relevancia y los resultados obtenidos en tareas como segmentación, clasificación o ambas.

1.3. Métricas importantes

Para una mejor comprensión de algunos comentarios y/o datos vistos durante el trabajo de investigación, es crucial comprender cómo evaluamos los resultados de las herramientas inteligentes para el diagnóstico. Es así que llegaremos a mencionar definiciones de métricas importantes que pueden marcar la diferencia en la concepción de una herramienta en el campo clínico y que están ligadas al nivel de rendimiento y confiabilidad de la herramienta.

a. Precisión

Medida de exactitud que indica la proporción de resultados verdaderos positivos y negativos en relación con todos los resultados de las muestras que tenemos dentro del dataset. Es por ello que se calcula como la división entre “Verdaderos positivos + Verdaderos Negativos” y “Total de resultados”. [42]

b. Sensibilidad

Representa la capacidad de identificar correctamente los casos positivos. En otras palabras, mide la proporción de resultados verdaderamente positivos con respecto al total de casos positivos presentes. Es por ello que se calcula como la división entre “*Verdaderos positivos*” y “*Total de casos positivos*”. [42]

c. Especificidad

Representa la capacidad para descartar correctamente los casos negativos. En otras palabras, mide la proporción de resultados verdaderamente negativos en relación con el total de casos negativos. Es por ello que se calcula como la división entre “*Verdaderos negativos*” y “*Total de casos negativos*”. [42]

d. Índice de Jaccard

También conocido como “coeficiente de similitud de Jaccard” es una medida estadística que evalúa la similitud entre dos conjuntos. Se calcula dividiendo el *tamaño de intersección entre dos conjuntos* y el *tamaño de la unión entre los mismos* (para nuestro caso serán las máscaras generadas por los algoritmos de segmentación). [42]

e. Índice de Dice

De forma similar al coeficiente de Jaccard, el índice de Dice, es una métrica estadística utilizada para cuantificar la similitud entre dos conjuntos pero cuya diferencia principal es el cálculo mismo del índice. Es así que el índice de Dice se calcula como la división entre “*dos veces*

el tamaño de la intersección entre dos conjuntos” y “el tamaño de la unión entre los mismos” [42]

Si bien las métricas mencionadas serán tomadas en cuenta dentro de las investigaciones escogidas, debemos de aclarar que no todos los estudios reportan dichas métricas y ante ello la comparación entre estudios distintos no serían concluyentes. Por ello, para estandarizar las comparaciones adecuadamente, se tomará la métrica en común entre los estudios a comparar y que será la precisión en su mayoría.

IV. METODOLOGÍA

En el presente punto comentaremos sobre la metodología de búsqueda bibliográfica que se realizó. La metodología a usar consta de 6 puntos específicos y cubren las tareas propias de una RS. Es así que pasaremos desde el diseño de estudio, la estrategia de búsqueda, pasando por los criterios de inclusión y exclusión, finalizando con los criterios de selección, extracción de datos y evaluación de la calidad de los estudios. A continuación se realiza una breve descripción de cada etapa.

1. Diseño del estudio

Una revisión sistemática fue realizada para evaluar la capacidad de las tecnologías basadas en inteligencia artificial para el diagnóstico del Síndrome Coronario Agudo. Este reporte siguió las recomendaciones del PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analysis) y algunas recomendaciones del Cochrane Handbook para Revisiones Sistemáticas (Tabla Suplementaria 1). El protocolo ha sido registrado en PROSPERO, número CRD #42022359094.

2. Estrategia de búsqueda

Se consultaron las siguientes bases de datos; 1) Embase, 2) Scopus, 3) Pubmed y 4) IEEE Xplore; la búsqueda se registró el día 2 de agosto del 2021 y no tuvo un límite de tiempo dentro de las bases de datos de búsqueda mencionadas (Ver tabla suplementaria 2, para mayor referencia). La condición en estudio fue el Síndrome Coronario Agudo (SCA) en sus dos grandes grupos de clasificación las cuales son: angina inestable e infarto del miocardio agudo (IAM), considerados por la guía práctica clínica de la Sociedad Europea de Cardiología 2021. [1]

3. Criterios de inclusión y exclusión

Se consideraron los siguientes criterios: 1) Diagnóstico del SCA en sus dos tipos, las cuales son: angina inestable e infarto del miocardio agudo (IAM), de acuerdo a la guía práctica de la ESC. 2) Uso de señales e imágenes. 3) Uso de procesamiento basado en inteligencia artificial. 4) Artículos escritos en español e inglés. Se excluyeron aquellos artículos científicos que presentaron: 1) Citación

doble. 2) Texto completo no disponible hasta el momento de la búsqueda. 3) Estudios que usaron solamente señales ECG y variables clínicas, ya que la presente RS tiene la intención de abarcar de forma general las estrategias asociadas dentro del diagnóstico del SCA, es decir, tanto señales como imágenes en conjunto.

4. Selección de estudios

Se procedió a la selección de los artículos que cumplieran con los criterios de inclusión inicialmente mediante la revisión de los títulos y resúmenes de los artículos, luego se evaluaron de acuerdo al contenido completo para cada artículo. Este proceso se realizó por parte del autor tomando las consideraciones de la existencia de aspectos como población, la herramienta utilizada y si el objetivo de la aplicación fue el diagnóstico del SCA. Así mismo, se extrajeron características paramétricas reportadas en cada estudio poniendo énfasis en la especificidad, sensibilidad y precisión calculada, observando el área bajo la curva ROC y el índice de Dice o Jaccard para las aplicaciones que lo requieran.

5. Extracción de datos

Se extrajeron los siguientes campos de información de los artículos incluidos en una hoja de cálculo de Microsoft Excel: Autor, año de publicación, país, base de datos, tipo de estudio, aplicación clínica, entre otras.

6. Procedimientos para evaluación de calidad de estudios científicos

La evaluación del sesgo de los estudios para esta revisión sistemática se estableció de acuerdo con la escala de New Castle-Otawa [38]. Esta escala contiene 8 ítems agrupados en 3 dominios: selección, comparabilidad y resultado. Se calculó el puntaje final para cada estudio (0-9). Un puntaje de 0-3 fue considerado muy bajo, 4-6 moderado y 7-9 alto

V. RESULTADOS

1. Búsqueda

Se identificaron un total de 3468 referencias únicas en la búsqueda de las bases de datos mencionadas anteriormente. Mediante la lectura de los títulos y abstracts de las referencias se optaron por la elección de 135 referencias para la lectura del texto completo, de los cuales se identificaron un total de 24 referencias que cumplían con los criterios de inclusión y exclusión. El proceso de selección se detalla en la **Figura X**. Las características de los estudios son descritas en la **Tabla 2**.

2. Evaluación del riesgo del sesgo

El sesgo de los estudios fue evaluado según la escala New Castle-Otawa, para los estudios de tipo cohorte fue de 4 a 7 mientras que para los estudios de tipo de estudio de casos y controles fue de 3 a 7. De forma general, tres estudios obtuvieron el puntaje más alto [11, 29, 30], seis estudios obtuvieron puntaje muy bajo [15, 16, 19, 24, 25, 27], quince obtuvieron puntaje moderado [7, 8, 9, 10, 12, 13, 14, 18, 20, 21, 22, 23, 26, 28, 30] y tres obtuvieron puntaje alto [11, 17, 29]. (**Tabla 3 y 4**)

3. Características de los estudios

Antes de mencionar las características de los estudios, debemos de precisar que cuando se habla de artículos basados en alguna tecnología en específico, se toma la referencia a que la tecnología usada en dicho artículo utiliza el principio de la técnica en específica en la que se basa, por ejemplo, si se menciona que un artículo se basa en ultrasonido, se debe de pensar en que la tecnología usada en dicho artículo, utiliza el principio de ultrasonido para generar una imagen y/o señal final.

Es así que se obtuvieron un total de siete artículos científicos basados en ultrasonido, de los cuales seis de ecocardiografía [7 - 12] y un artículo de ultrasonido intravascular [13], nueve artículos científicos basados en tomografía computarizada, dos de los cuales siguieron el procedimiento estándar de tomografía [14, 15], dos de angiografía coronaria por tomografía [16, 17], tres

por tomografía SPECT [18, 19, 20], dos por tomografía de coherencia óptica OCT [21, 22], cinco artículos basados en resonancia magnética MRI, cuatro mediante el proceso estándar [23 – 26] y uno por resonancia magnética con realce tardío MCDE [27] y tres artículos científicos basados en el vectocardiograma de donde en un estudio se añadió señales ECG [28] mientras que en los otros dos se utilizaron solamente señales vectocardiograma [29, 30].

Del mismo modo, recopilando la información según el tipo de estudio, se cuentan con un total de 19 estudios transversales, todos con grupo de casos y controles; uno de ellos se realizó en Reino Unido (U.K.), dos en Estados Unidos (EE.UU.), tres en China, uno en Korea, uno en Taiwán, uno en Turquía, dos en Suecia, uno en Bélgica, dos en Canadá, uno en España, uno en Brasil, uno en Catar, uno en Singapur y uno en Alemania. Mientras que los cinco estudios restantes fueron longitudinales del tipo cohorte, específicamente uno de ellos fue realizado en Estados Unidos, uno en Nueva Zelanda, uno en Japón y dos en China. **(Figura 3a y 3b)**

Figura 3. Distribución de estudios, por países, de acuerdo a la característica del estudio

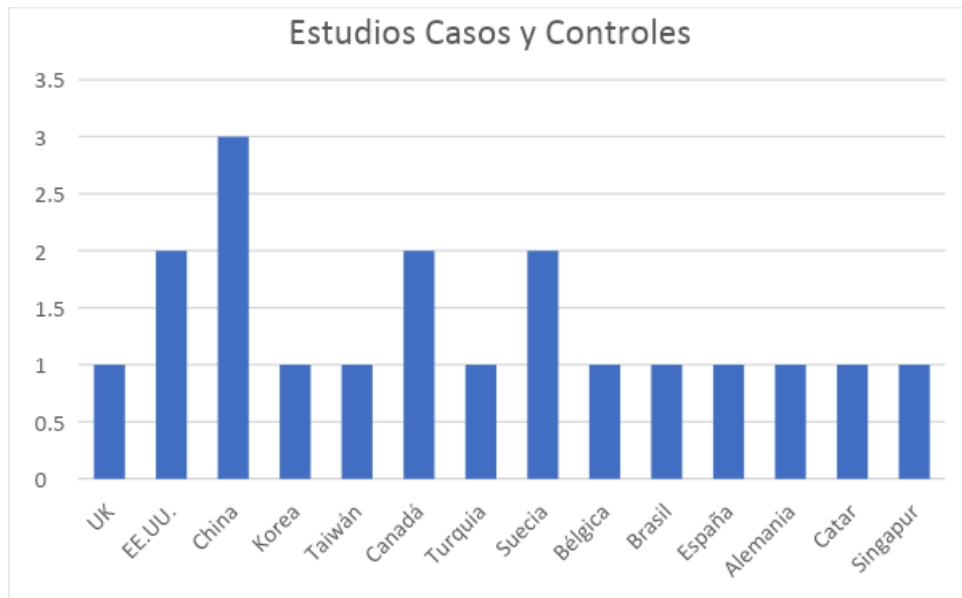


Figura 3a. Distribución de Estudio de Casos y Controles

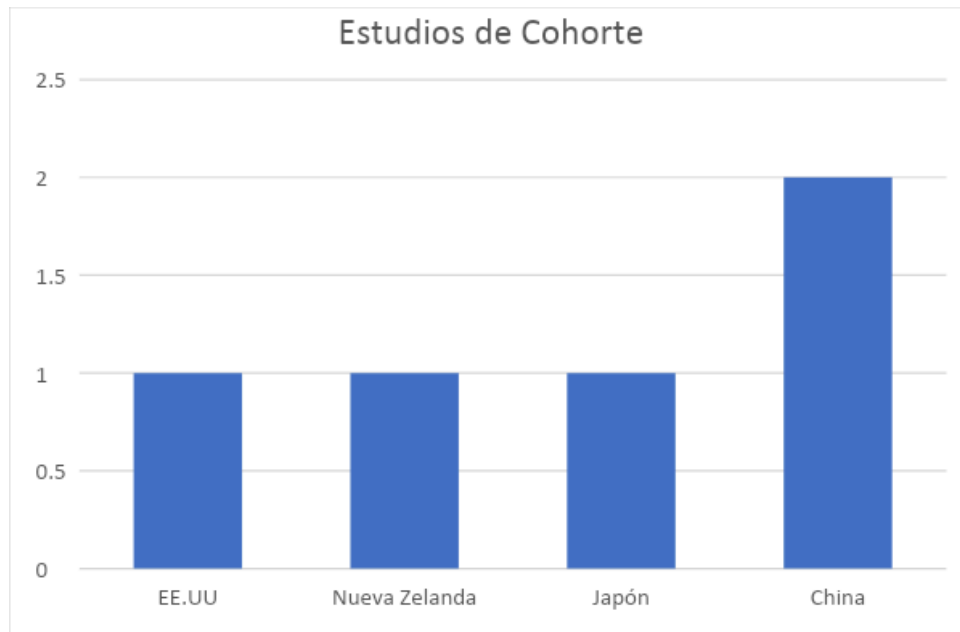


Figura 3b. Distribución de Estudio de Cohorte

Estas distribuciones por países se puede resumir y observar en la mapa presentado en la **Figura 4**, donde se representan los puntos de desarrollo de estudios en cada país, esto nos da una idea de regiones específicas donde existe un desarrollo mayor y puede ser objeto de estudio futuro orientando a prevalencia de la patología y/u otra característica relacionada a intentar realizar una explicación sobre el desarrollo de los mismos. Del mismo modo, esto puede llevar a estudiar sobre el desarrollo de normativas orientadas a desarrollo de herramientas basadas en inteligencia artificial bajo la hipótesis de desarrollo en base a las necesidades de cada región.

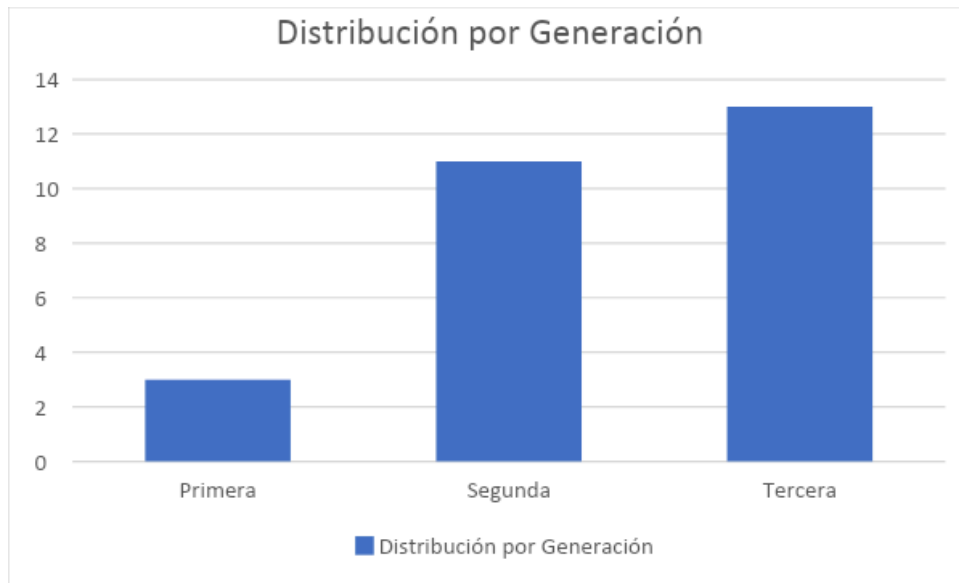
En general podemos comentar una clara prevalencia de estudios en el continente Europeo por sobre otros continentes; dentro de nuestro continente americano, existe tan solo un estudio realizado dejando abierta preguntas sobre la prevalencia de casos en zonas específicas y oportunidades de desarrollo futuro en base a experiencias externas mediante un proceso de adaptación para el contexto de cada región, esto sigue siendo una carta abierta de análisis y en que será desarrollado de forma más específica en el capítulo de discusión.

Figura 4. Mapa de distribución de estudios países



Basándonos en la clasificación por generación, expuesta por S.S. Skandha et al. en [7], se encuentran tres estudios [23, 25, 28] donde se usaron algoritmos pertenecientes a la primera generación, once estudios [7, 9, 10, 11, 12, 15, 17, 20, 27, 29, 30] con algoritmos pertenecientes a la segunda generación y trece estudios [7, 8, 12, 13, 14, 15, 16, 18, 19, 21, 22, 24, 26] con algoritmos pertenecientes a la tercera generación recalando que en [7, 12, 15] se utilizaron combinaciones de algoritmos tanto de segunda como de tercera generación (**Figura 5**). Del mismo modo en base a los algoritmos y/o arquitecturas usadas se ha notado el claro desarrollo de algoritmos basados en redes neuronales, pertenecientes a la tercera generación, por la capacidad en la resolución de problemas y tareas complejas como la segmentación automática y clasificación, siendo la arquitectura más común para la segmentación U-Net tal como se puede encontrar en [14, 26] mientras que para procesos de clasificación se usaron diversas arquitecturas como AlexNet, VGG, YOLO, Faster R-CNN, etc. con resultados por encima de 90% de precisión en la mayor parte de los casos.


Figura 5. Distribución de estudios por generación



Finalmente, en base a la **Figura 6**, comentamos los resultados de acuerdo a la tecnología usada, es así que en primer lugar tenemos seis estudios basados en ultrasonido, cinco de ellos ecocardiográficos y uno por ultrasonido intravascular. De los estudios ecocardiográficos, en [12] se realizó un proceso de segmentación de pared ventricular izquierda en base a una red convolucional con una sensibilidad del 95.72% y especificidad del 99.75% consiguiendo el mayor performance dentro de todos los estudios, así también este mismo estudio realiza un proceso de clasificación de infarto de miocardio (MI) mediante el método SVM consiguiendo una sensibilidad del 85.97% y especificidad del 74.03%, siendo este no el mejor performance para la tarea de clasificación. Por otro lado, un método utilizado en otros estudios ecocardiográficos como observamos en [9] y [10] mostraron que la performance asciende a un 99.5% luego de realizar una extracción de características. Para el caso de los estudios basados en tomografía computarizada se reportó en [18] una precisión de hasta un 100% en la clasificación y en base a los datos recogidos para las imágenes del estudio, en [15] el objetivo es la predicción de eventos cardíacos que incluyen el infarto del miocardio (IM), en [14] se realiza un proceso de segmentación mediante algoritmo de Deep Learning (DL), en [16] se buscó realizar un proceso de estratificación mediante una red convolucional, en [22] se realiza la caracterización de la arteria coronaria para determinar los casos patológicos y

culminamos los hallazgos basados en tomografía computacional con [17, 18, 19, 20, 21] donde se realiza un proceso de clasificación para el infarto del miocardio. Para los estudios basados en resonancia magnética, encontramos en [23] un procesamiento automático mediante una técnica clásica de inteligencia artificial que no supone un aprendizaje, del mismo modo en [26] y [27] se realiza un proceso de clasificación mediante un proceso de segmentación capaz de detectar infarto del miocardio culminando con [24] y [25] donde solo se realiza el proceso de segmentación con la intención de mostrar, dentro de la imagen, la zona infartada. Por último, para el caso de los estudios basados en señales electrocardiográficas y vectocardiograma, encontramos que [28, 29, 30] realizan un proceso de clasificación mediante las características extraídas de las señales comentadas encontrando un mejor performance en [28] ejemplificando la superioridad añadida por parte de las señales electrocardiográficas.

Figura 6. Distribución de acuerdo a la Tecnología usada



Una perspectiva añadida de forma resumida estará orientada bajo la referencia de temporalidad para organizar los resultados encontrados y orientar hacia la

evolución en el desarrollo de algoritmos como en los resultados generales encontrados en un nivel de avance a lo largo del tiempo. En la **Figura 7** y en la **Tabla 1.a, Tabla 1.b y Tabla 1.c** se observan todos los estudios seleccionados y los algoritmos respectivamente, en un orden de tiempo general comprendido entre 2004 y 2021 comentando en un principio hitos importantes relacionados a conceptos de conceptos de inteligencia artificial, aplicación en el campo médico y la aplicación específica sobre la patología a tratar.

Dentro de las primeras observaciones encontramos una tendencia ascendente de los estudios hacia el SCA, esto nos indica el interés por solucionar problemas asociados a dicha patología e incluso realizando tareas cada vez más complejas como lo es la segmentación sin dejar de lado el objetivo de realizar la clasificación misma, siendo este el diferenciador principal a alcanzar.

Tabla 1.a. Tabla de tiempo para algoritmos de primera generación

Modelos	Año de Referencia
Deformable Registration Method (SCR)	2014
Manually Guide Point (AU)	2014
Contour Contrain (AO)	2014
Operaciones Morfológicas (OM)	2014

Tabla 1.b Tabla de tiempo para algoritmos de segunda generación

Modelos	Año de Referencia
K-Nearest Neighbors (KNN)	2014
Support Vector Machine (SVM)	2004
Random Forest (RF)	2017
Fuzzy Logic (FL)	2015
XG-Boost	2018

Tabla 1.c Tabla de tiempo para algoritmos de tercera generación

Modelos	Año de Referencia
CNN, MLP	2019
VGG 16, VGG 19	2018 - 2019
Inception V3	2020
YOLO	2019
U-Net	2018
ResNet, DenseNet	2020 - 2019
Xception	2020
Faster R-CNN	2021
AlexNet	2021
GoogleNet	2020
NasNet Large	2020
C-GAN	2019

Figura 7. Línea de tiempo de estudios seleccionados

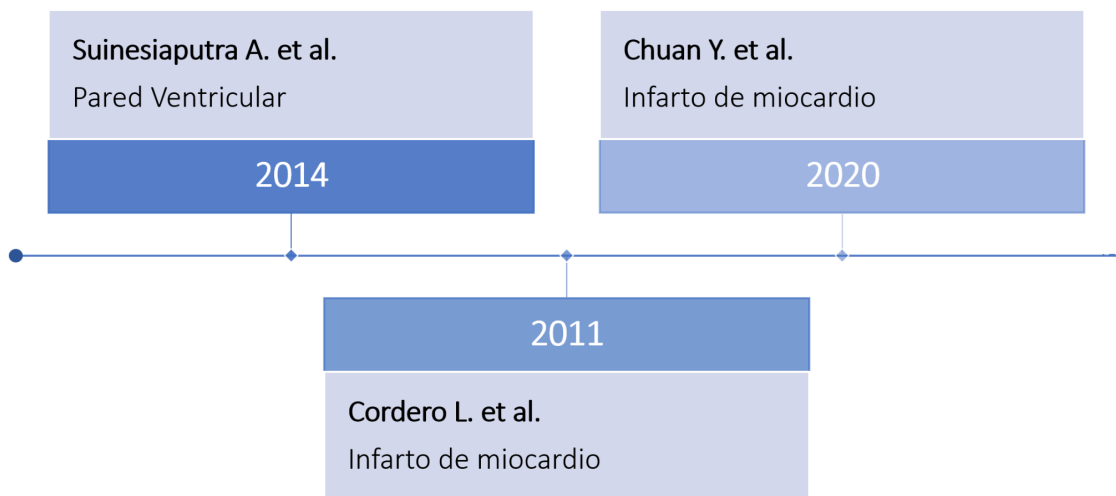


Esta vista general en principio nos da una idea de los hitos más importantes a nivel temporal dentro de los estudios seleccionados, pero si consideramos una referencia de desarrollo ligado al algoritmo, que en nuestro caso se traduce en la generación ya antes definida, podemos darnos cuenta de si los hallazgos y

abordaje de problemas se han generado desde un punto de vista de algoritmos más complejos o si se mantienen en algoritmos no tan complejos.

Es así que en la **Figura 8**, se muestran en un primer momento algoritmos pertenecientes a la primera generación desde el punto de vista temporal, el desarrollo bajo algoritmos de la primera generación nos resulta en 3 estudios. Dos de ellos están orientados al reconocimiento del infarto del miocardio como medio de diagnóstico para el SCA desarrollados en los años 2011 y 2020, mientras que el restante para el reconocimiento mediante la caracterización de la pared ventricular desarrollado el 2014. Podemos observar que aunque los algoritmos utilizados no son comentados como los más complejos, los resultados y el uso de los mismos no han sido dejados de lado, sino que sigue presentando oportunidades.

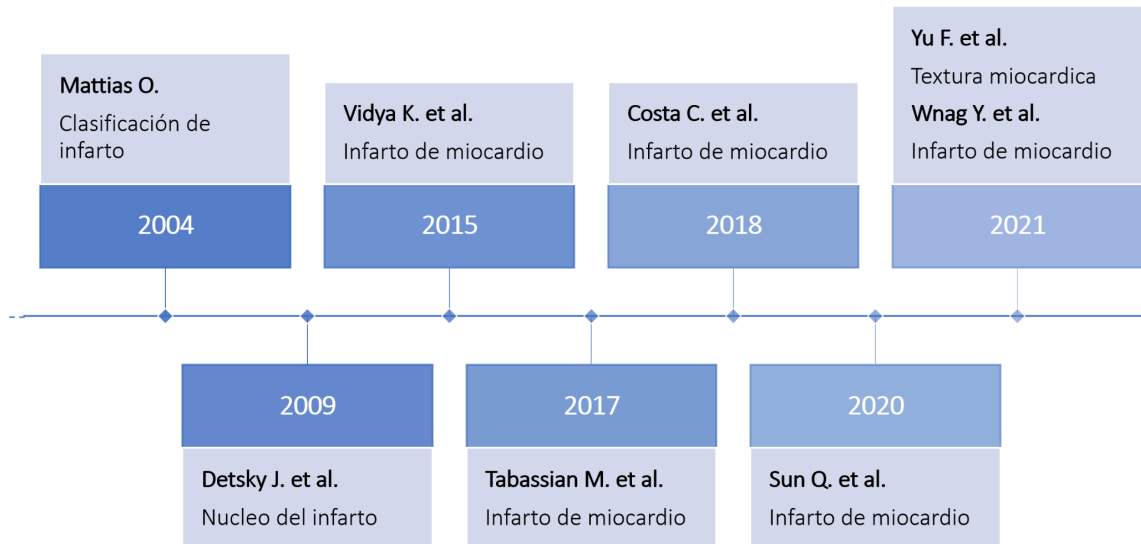
Figura 8. Línea de tiempo para algoritmos de primera generación



Siguiendo con el análisis, en la **Figura 9**, encontramos los algoritmos que pertenecen a la segunda generación desde el mismo punto de vista temporal, siendo el reconocimiento del infarto del miocardio la tarea más prevalente entre los estudios, estos se desarrollan en los años 2015, 2017, 218, 2020 y 2021 con un total de 5 estudios. Algunas otras tareas como la caracterización y/o reconocimiento de la textura miocárdica y núcleo del infarto tratadas en otros

estudios entre los años 2009 y 2021, mostrando opciones para el objetivo final de diagnóstico del SCA, mostrando una tendencia creciente respecto a los algoritmos de la primera generación.

Figura 9. Línea de tiempo para algoritmos de segunda generación



Para los trabajos pertenecientes a la tercera generación, en la **Figura 10**, tenemos como primera referencia el trabajo realizado en 2008 por parte de Lomsky et al. en [19] para el reconocimiento de isquemia, mientras que los trabajos restaurantes fueron desarrollados a partir del 2018 con la dirección a resolución de tareas como segmentación, siendo una tarea más específica que la de clasificación, dando un acercamiento al concepto de explicabilidad orientado a generar un espacio de observación que puede ser usado como herramienta de ayuda en la toma de decisiones final por parte del médico observador.

En tal sentido, una combinación de tareas como segmentación y clasificación se puede observar como una combinación de algoritmos pertenecientes a la segunda y tercera generación, esto está orientado para un algoritmo de tercera generación para una tarea de segmentación y un modelo de segunda generación para la clasificación, de esta forma se cuenta con un área de observación mientras que del mismo modo existe la referencia de clasificación. Es importante poder observar dentro de la **Figura 11** que el desarrollo de esta combinación de algoritmos se presentaron en los años 2020 y 2021 siendo los

más cercanos a la actualidad y dando una referencia del avance de los abordajes sobre el tema en cuestión.

Figura 10. Línea de tiempo para algoritmos de tercera generación

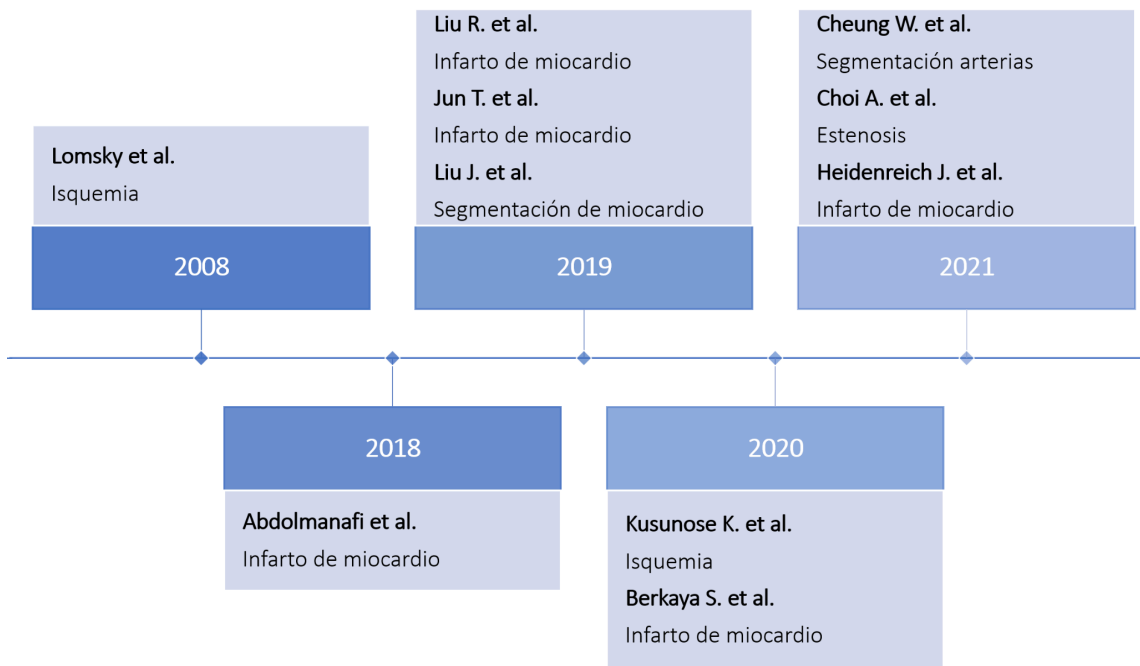
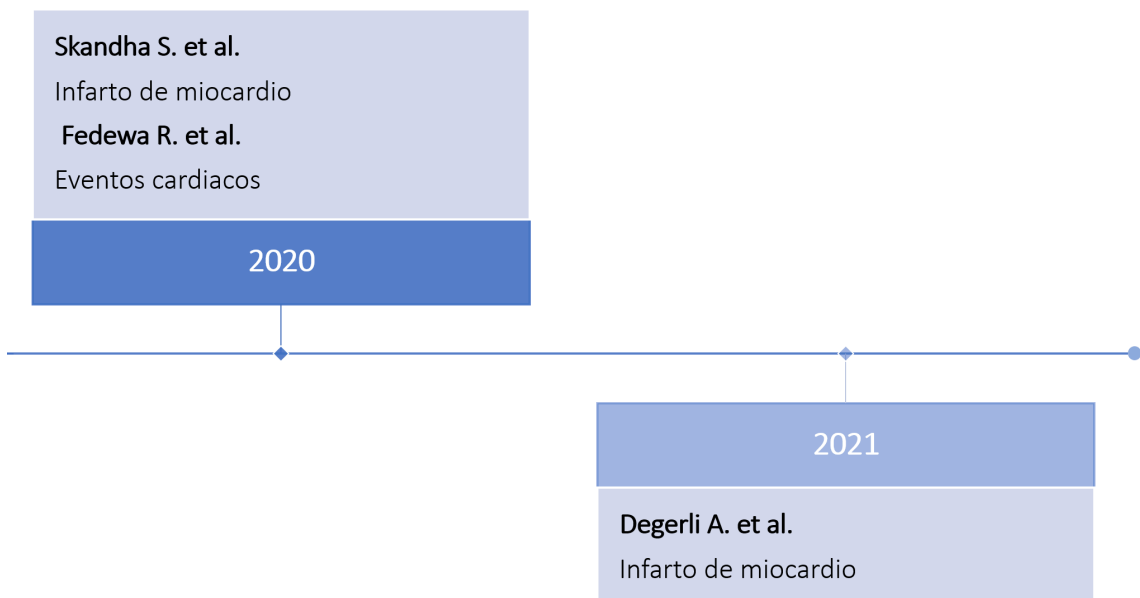


Figura 11. Línea de tiempo para algoritmos de segunda y tercera generación



Luego de realizar una visión general resumida a lo largo del tiempo, se comparte en la **Figura 12**, una infografía que reúne los mejores resultados encontrados dentro de los estudios seleccionados, con el objetivo de evaluar las hallazgos más consolidados bajo la perspectiva de tecnología utilizada y algoritmo ejecutado, se tienen 4 referencias de mejores resultados ya que estos presentan oportunidades diferentes que dependen directamente del tipo de imágenes que manejan, no se realiza una elección de mejor entre ellas debido a que la comparación no sería adecuada debido a que la naturaleza misma de las imágenes no lo son.

Figura 12. Mejores resultados obtenidos de los estudios



Finalmente, hasta este punto se comentan los resultados desde diversas perspectivas o características y que serán sujetas a comentarios para el análisis dentro de la sección de discusión para dar una mejor comprensión sobre los resultados hallados en los estudios y establecer en base al performance las potencialidades de cada método y si estos podrían ser mejorados mediante un proceso de optimización.

VI. DISCUSIÓN

En la revisión realizada se encontraron un total de 24 artículos en los que se usaron tecnologías basadas en inteligencia artificial para el diagnóstico del SCA, con una máxima precisión del 99.5% para un algoritmo de tipo Deep Learning, por encima de otros algoritmos con precisiones tanto por encima como por debajo del 90%. Con un predominio por parte de China sobre investigaciones y aplicaciones de tecnologías basadas en la IA, el país en cuestión aspira al liderazgo mundial en el campo de la Inteligencia Artificial. Así mismo, dentro de los 24 artículos se encuentran aplicaciones de algoritmos de procesamiento automático, pasando por los basados en Machine Learning y Deep Learning completando el concepto general de Inteligencia Artificial, a través de señales e imágenes médicas basadas en tecnologías como ultrasonido, tomografía, resonancia magnética y vectocardiograma.

El uso del concepto de Inteligencia Artificial ha ido evolucionando en medida de la evolución de la tecnología, es así que dicho concepto aparece por primera vez, según Malik P. et al. y Hamlet P. et al. en [31] y [32] respectivamente, el año 1956 en proporción a la relación con la ciencia e ingeniería pensándose inicialmente al desarrollo dentro del campo de la robótica. Es así que de acuerdo a Ramesh A. et al. en [33] no es hasta el año de 1976 cuando por primera vez Gunn explora la posibilidad de diagnosticar el dolor abdominal agudo a través del análisis informático y desde entonces el desarrollo ha crecido exponencialmente, comenzando con la gran acogida de las herramientas inteligentes dentro de la imagenología, específicamente en el campo de los Rayos X, Tomografía computarizada, etc. debido a que las tareas dentro de la medicina se pensaron bajo la perspectiva de realizar tareas de diagnóstico llegando finalmente a las tareas de gestión y cirugía en el área de medicina tal como lo reporta [31] desde la perspectiva de arquitecturas clásicas hasta las arquitecturas modernas como redes profundas o Deep Learning.

Para el caso del Síndrome Coronario Agudo (SCA), el primer desarrollo de una herramienta inteligente data del año 1980 con Pozen [34] despertando el interés y desarrollo bastante amplio para el uso de herramientas de IA para distintas tareas relacionadas al SCA con la consigna de implementar estrategias que

puedan mitigar las consecuencias de la patología. Las soluciones a tareas de clasificación, caracterización, segmentación, etc. mediante herramientas basadas en inteligencia artificial han mostrado un gran potencial de desarrollo. Es así que, no podemos dejar de mencionar que dentro de la definición operacional se comentó sobre la forma de evaluar la capacidad de la máquina para realizar la tarea encomendada a solucionar, esto bajo la consigna de definir el performance para cada evento. Dicha evaluación puede ser realizada a partir de diversas métricas como precisión, sensibilidad, especificidad para tareas como clasificación; índice de Jaccard o Dice para tareas como segmentación y curva ROC para consignas de estratificación. Por ello, en la discusión se reporta el performance conseguido en cada estudio seleccionado para realizar una comparación bajo las potencialidades y debilidades de cada técnica utilizada.

Siguiendo el uso de arquitecturas bajo la perspectiva de generaciones propuesta en [7] podemos comenzar con el estudio realizado por Suinesiaputra A. et al. en [23] que consigue una caracterización de la pared ventricular izquierda mediante técnicas clásicas pertenecientes a IA pero que no incluyen un componente de aprendizaje como parte del proceso para la toma de decisiones finales, se tomaron en cuenta 6 algoritmos automáticos, *Deformable registration method (SCR)*, *Layered spatio-temporal forest algorithm (INR)*, *Contour constrained optical Flow tracking (AO)*, *Block matching algorithm (DS)*, *Manually guide-point modeling assisted fitting of cardiac model (AU)* y *STAPLE algorithm*, consiguiendo una variabilidad en el índice de Jaccard para la caracterización comprendida entre 56% a 98% en el mejor de los casos para el algoritmo “STAPLE” observando una baja coincidencia en el reconocimiento de zonas de interés dentro de la pared ventricular izquierda para algunos algoritmos estudiados, pues tomando en cuenta que pertenecen a herramientas clásicas que no comprenden un componente de aprendizaje y por consiguiente un ajuste en el performance, el que se haya conseguido un porcentaje por encima del 90%, nos da a pensar que arquitecturas especializadas y más avanzadas (segunda y tercera generación) podrían llegar a un performance superior sin ningún problema y con una menor variabilidad en los resultados. Un estudio similar es el mostrado en [25] mediante un modelo probabilístico con una variabilidad similar al descrito anteriormente, específicamente para este caso, la variabilidad va desde el 61% al

92% aproximadamente permitiendo la identificación de zonas con infarto en el miocardio concluyendo en un proceso de segmentación aceptable respecto al proceso manual realizado por los médicos y que bien podría ser optimizado para lograr una mayor robustez.

Continuando con el análisis, comentaremos los estudios con métodos pertenecientes a la segunda generación sin el uso complementario de algún otro método, es así que tenemos el estudio realizado en [9] donde a partir de imágenes ecocardiográficas se extraen tres tipos de características independientes para ser introducidas en un clasificador *Support Vector Machine* (SVM). Las características fueron evaluadas independientemente y en conjunto consiguiendo para su mejor combinación una precisión del 91%, sensibilidad de 90% y en específico una sensibilidad del 80% identificando la presencia o ausencia de hipertrofia ventricular izquierda. Otro estudio similar usando imágenes ecocardiográficas y usando un clasificador SVM fue realizado por Vidya K. S. et al. en [10] donde se extrajeron características mediante la transformada discreta de wavelet (DWT), matriz de co-ocurrencia de niveles de gris (GLCM) y espectro de orden superior (HOS) consiguiendo un mejor performance de clasificación para DWT con una precisión del 99.5%, una sensibilidad del 99.75% y especificidad del 99.25% para la clasificación de infarto de miocardio siendo superior al conseguido en [9] probablemente debido a que la característica extraída demuestra una mejor caracterización para la imagen tratada. Desde el enfoque de imagen ecocardiográfica encontramos de la misma forma en [11] un estudio utilizando algoritmos del *Principal Component Analysis (PCA)* y *K Nearest Neighbors (KNN)* con un enfoque espacio – temporal, pertenecientes a la segunda generación de técnicas de IA, obtuvo una precisión en la clasificación de infarto de miocardio del 87% con una sensibilidad del 89% y especificidad del 85% siendo este menor a las métricas obtenidas en [9] y [10], en donde la similitud es que tanto en [11] como en los mencionados se trabajaron con imágenes ecocardiográficas bajo tres métodos de extracción de características diferentes con un mejor performance para la transformada discreta de Wavelet y menor para el espacio temporal observando que el cambio de características en las imágenes a nivel temporal no son características que puedan predecir de mejor manera el infarto de miocardio,

incluso luego de realizar un proceso de selección de componentes para un mejor resultado de predicción siendo el clasificador KNN que a comparación de SVM realiza un proceso de selección en base a probabilidad de pertenecer a un grupo en específico de acuerdo a un esquema de votación respecto a los árboles generados dentro del clasificador dando la referencia grupal de decisión. En [27] se presenta el uso de un método basado en *Fuzzy Logic o Lógica Difusa* siguiendo un enfoque de segmentación para imágenes de resonancia magnética con realce tardío (MCDE). Si bien dentro del estudio no se reporta una métrica en la clasificación, sí menciona la alta concordancia en la segmentación del núcleo del infarto dentro de la imagen MCDE midiendo la ubicación de la zona infartada en un paciente de forma visual. Cabe señalar que la segmentación realizada no provee una conclusión de diagnóstico, el uso de la lógica difusa comprende una relación entre los voxels de la imagen para diferenciar características únicas en zonas distintas, esta adaptación del método parece responder adecuadamente para las imágenes de resonancia. En tal sentido, encontramos un panorama distinto en [17] donde a través de cinco características extraídas de angiografía por tomografía computarizada se alcanza una precisión en clasificar el diagnóstico de infarto de miocardio bastante alta, esto asciende a un 91.8% mediante el uso de un clasificador *XG Boost*. Se puede justificar el rendimiento superior del modelo *XG Boost* ya que similar a muchos otros métodos de *gradient boosting*, estos obtienen una mejora de clasificación gracias a una retroalimentación sucesiva y secuencial de árboles de decisiones generando incluso una menor carga computacional respecto a métodos tipo SVM. Esta última característica mencionada representa una ventaja para el desarrollo de las mismas tareas en un menor tiempo; para el caso del estudio, la variable a predecir será el diagnóstico positivo de infarto de miocardio. Tal como se menciona anteriormente los métodos de *gradient boosting* han mostrado una ventaja sobre métodos clásicos en cuanto a carga computacional se refiere pero que, sin embargo, para nuestro caso general de diagnóstico del SCA; este no consigue una mejor clasificación frente a otros algoritmos, pero esta comparación no puede ser concluyente debido a que en [17] tenemos una clasificación a partir del tratamiento de imágenes de angiografía por tomografía computarizada y la cual es distinta a los estudios con

mejores resultados donde el tratamiento de datos se dieron a partir de imágenes ecocardiográficas diferenciándose notablemente en cuanto a características de imagen se refiere, del mismo modo existe una diferencia significativa en la resolución de imagen y que pueden afectar el proceso de clasificación generando una barrera para la comparación entre métodos y/o resultados. Siguiendo la misma línea, de las imágenes de resonancia magnética, en [20] se compararon arquitecturas como redes neuronales (ANN) y KNN para un proceso de segmentación y clasificación logrando una mayor precisión con la red neuronal con un 96% identificando adecuadamente el infarto de miocardio como clasificación, demostrando la superioridad de las redes neuronales sobre los algoritmos desarrollados en la misma generación y particularmente para este estudio se menciona la intención de utilizar dicha arquitectura como apoyo clínico. Los dos últimos estudios donde se usaron algoritmos de segunda generación los encontramos en [29] y [30], ambos bajo el uso de vectocardiograma y algoritmos ya mencionados; en [29] se realiza una clasificación mediante una red neuronal (ANN) con la extracción de cuatro características consiguiendo una precisión del 94% con una sensibilidad del 92% y especificidad del 96% para la identificación del infarto del miocardio mientras que el [30] se logra una precisión del 90.8% con una sensibilidad del 93.7% y especificidad del 86.8% mediante un clasificador SVM y características relacionadas al coeficiente de Lyapunov, que si bien se comenta dentro del estudio un efecto positivo mediante el coeficiente de Lyapunov para la clasificación este no supera lo conseguido en [29] sospechando nuevamente sobre la superioridad de las redes neuronales dentro de las tareas de clasificación y que fue evaluado en [20].

Dentro de las arquitecturas pertenecientes a la tercera generación, en [8] encontramos el uso de arquitecturas tipo DCNN como *ResNet*, *DenseNet*, *Inception ResNet*, *Inception* y *Xception* para la automatización del diagnóstico de isquemia miocárdica encontrando los mejores resultados con la arquitectura *ResNet* logrando un AUC de 97%, mostrando la potencialidad en la clasificación y detección de zonas infartadas de pared abdominal usando ecocardiografía; siguiendo la línea de ecocardiografía, en [13] se reporta un procesamiento de segmentación flexible y robusto por parte de una red de DCNN con una métrica

del 91.1% de AUC para la segmentación, esto se evalúa mediante el solapamiento de las imágenes (siguiendo el lineamiento de cálculo del índice de Jaccard) entre la referencia y lo desarrollado por parte de la arquitectura para determinar parámetros de función cardíaca y por consiguiente una clasificación final. Otro enfoque de segmentación se describe en [14], el cual se basa en el procesamiento de imágenes de tomografía computarizada utilizando la arquitectura *UNet*. Esta técnica de segmentación, que ha demostrado excelentes resultados en imágenes médicas, logró alcanzar un índice de Dice del 91.2% y 88.8% en la segmentación de (1) la aorta y arteria coronarias y (2) únicamente las arterias coronarias, correspondientemente. Además se destacó la eficiencia computacional lograda en comparación con otros métodos manuales, lo que subraya el potencial de aplicar esta arquitectura en un contexto clínico. Un segundo estudio para imágenes de tomografía computarizada es presentado en [21] donde a partir de una imagen de tomografía de coherencia óptica intravascular se realiza un proceso de segmentación bajo arquitecturas de redes convolucionales profundas (DCNN) para la caracterización de la placa vulnerable con un 88.46% de calidad de segmentación medido por un solapamiento entre la segmentación de referencia y la generada por la red neuronal, y que no supera a lo encontrado en [14] pero bajo la consigna de la modificación en el procedimiento de la tomografía puede que la comparación no sea concluyente sino que mostraría un potencial uso de este tipo de imágenes en trabajos futuros. Otros trabajos desarrollados para imágenes de tomografía computacional son encontrados en [16, 18, 19, 22] desarrollados con algoritmos pertenecientes a la tercera generación, en [16] y [22] se realiza bajo el concepto de caracterización de tejido consiguiendo en [22] una caracterización completa (100%) del tejido mediante una combinación de arquitecturas de *AlexNet* y *VGG 19*. Mientras que en [16] se determina mediante la segmentación del lumen y pared del bazo en imágenes de angiografía por tomografía computarizada, la estenosis coronaria que finalmente es comparable con las segmentaciones realizadas manualmente por los médicos participantes y que demuestran resultados muy similares ejemplificando la precisión de la arquitectura. En [18] y [19] existe un proceso de clasificación mediante arquitecturas de Deep Learning, en [18] en particular existe un proceso de comparación con

arquitecturas pertenecientes a la segunda generación o Machine Learning; respecto a las métricas encontradas por Deep Learning, estas ascienden al 94% de precisión, 88% de sensibilidad y 100% de especificidad comparado con un 93% de precisión, 100% de sensibilidad y 86% de especificidad (Ver **tabla 6**) encontradas por métodos de ML demostrando, al menos para esta aplicación, y dejando indicios para futuras aplicaciones de la superioridad que supone las herramientas de DL sobre las ML debido a modelos más especializados; en [19] se hace uso de una red neuronal convolucional que si bien no se especifica sobre la arquitectura, el estudio nos muestra una métrica de 90% de especificidad y 85% de sensibilidad para la clasificación de isquemia miocárdica. Finalizamos las arquitecturas de la tercera generación con el estudio desarrollado en [26] mediante imágenes de resonancia magnética y la arquitectura *UNet*, para la segmentación del miocardio del ventrículo izquierdo con un índice de Dice del 89% siendo este comparable con las segmentaciones manuales realizadas por especialistas, demostrando que la arquitectura *UNet* es adecuada para imágenes tomográficas como en resonancia dejándonos la incógnita si la segmentación es indistinta de la tecnología usada en la adquisición de la imagen pues en [14], donde se trabajó con tomografía computacional, el índice de Dice es cercano a lo encontrado en [26].

Hasta el momento se ha realizado un análisis basado en la pertenencia de las arquitecturas a una sola generación de las propuestas por S.S. Skandha et al. en [7], pero existen un total de 3 estudios compuestos por métodos secuenciales pertenecientes a la segunda y tercera generación, es así que tenemos en [7] un proceso de segmentación de la placa sintomática y asintomática provenientes de imágenes ecocardiográficas para una clasificación final de infarto de miocardio con el uso de *Inception V3* y *VGG 16* con clasificadores *KNN* y *SVM* principalmente, obteniendo un 95.66% de precisión potenciando a los modelos de Deep Learning para la clasificación luego de una segmentación siendo superior a los modelos de ML en un 7.02% en promedio. Del mismo modo dentro de las imágenes ecocardiográficas, en [12] encontramos mediante el uso secuencial de una red neuronal convolucional (E-D CNN) y un clasificador SVM para la segmentación de la pared ventricular izquierda y la clasificación de infarto de miocardio respectivamente, con unas métricas que ascienden al

86.85% de precisión con una sensibilidad del 85.97% y una especificidad del 74.03% para la clasificación, siendo esta dependiente de la segmentación dado que el modelo secuencial sugiere la extracción de características a partir de dichas imágenes segmentadas y ante ello, dentro de la segmentación se encontró una precisión medida con el índice de Dice del 95.72% superando a los índices encontrados en anteriores estudios mencionados. Terminamos de mencionar los modelos compuestos por métodos pertenecientes a la segunda y tercera generación con lo encontrado en [15] donde a partir de imágenes de tomografía computarizada se construye un modelo de predicción de eventos cardíacos, dentro de los cuales encontramos al infarto del miocardio, que aunque no se especifica el modelo usado, se menciona un proceso secuencial entre segmentación para el reconocimiento de la placa de erosión, ruptura, entre otros para descartar características y mediante un clasificador inspirado en ML se logra la predicción de los eventos. En este último estudio no se reportan métricas del modelo para la tarea de clasificación, pero nos deja el precedente del uso de modelos secuenciales para resolver tareas no solo de clasificación sino también de segmentación para resaltar las zonas dentro de una imagen que pueden ser de interés a nivel médico.

El análisis inicial se basó en la generación a la que pertenecen las herramientas inteligentes, pero otro enfoque que no podemos pasar por alto es el país en el que se desarrollaron los estudios, debido a que es claro que el área de la Inteligencia Artificial promete un desarrollo positivo dentro de muchos campos y que en específico, dentro del campo de la medicina, es vital comprender que las aplicaciones tienen un carácter de sensibilidad muy alto debido a que sus hallazgos concluyen en decisiones médicas que tienen efecto directo sobre la vida de los usuarios tomando importancia sobre el aseguramiento de calidad de las herramientas a desarrollar. Es así que comenzaremos, comentando sobre el desarrollo por país; tal como se comentó en la parte de los resultados (**Figura 3a y 3b**), de los 24 estudios comentados, 5 de ellos fueron desarrollados en China, seguido por Estados Unidos con 3 estudios, en tercer lugar, se encuentra Canadá y Suecia con 2 estudios por país finalizando con el desarrollo de 1 estudio por país para los países restantes considerados. En tal sentido, China para el 2017 lanzó un plan nacional denominado “Plan de Desarrollo de Inteligencia Artificial

de la Nueva Generación” o AIDP por sus siglas en inglés, con el objetivo de convertir a China en el líder mundial de desarrollo de herramientas inteligentes para el 2030 y es que hasta antes del 2017, políticamente el enfoque de la IA en China era muy variable y con distintos intereses sin llegar a un objetivo conjunto, el desarrollo de la AIDP muestra la primera visión unificada a nivel legislativo evaluando tres esferas importantes que son: (1) La competencia internacional, (2) El crecimiento económico y (3) La gobernanza social; y con ello se plantearon objetivos intermedios para el año 2020, 2025 y 2030 concluyendo en el crecimiento económico y desarrollo continuo de estándares y leyes capaces de adaptarse a los retos en los distintos campos de desarrollo, en esta ocasión resumimos la base legal y el debate sobre la ética digital debido a que en el campo médico el uso de datos sensibles suele ser el mayor factor para el desarrollo de herramientas inteligentes, es así que la AIDP define un total de 8 principios de gobernanza para la IA, priorizando y resaltando que todo el desarrollo debe de comenzar por mejorar el bienestar común de la humanidad, respetando los derechos humanos, la equidad y la privacidad, destacando además la importancia de la transparencia, la responsabilidad y la colaboración en la adaptación ante nuevos retos, evaluando los riesgos potenciales por el uso de una herramienta inteligente. [35]

Por otro lado, Estados Unidos se presenta como la competencia directa en el desarrollo de herramientas de IA para China, pero sin ser el único, en [36] se comenta a grandes rasgos a dos principales competidores de China para el desarrollo de las IA's, estos son EE.UU. y Reino Unido, dirigiendo al primero como competencia directa, pues si bien el número de artículos y desarrollo de herramientas inteligentes en China es mayor que en Estados Unidos, la productividad de los estudios medidas por el índice H es mayor en el país norteamericano mientras que China es desplazado a un tercer lugar por debajo del Reino Unido mostrando una valoración de importancia y predominancia momentánea representando de cierta forma la calidad de los estudios realizada por parte de EE. UU. En tal sentido la base legal en EE.UU. y Europa se han desarrollado de forma similar a lo comentado en China, en [37] se comenta particularmente que en EE. UU. para el año 2018 se desarrolló una reforma en la forma de ver a las IA's controlado por la FDA, buscando legalmente el

compromiso y total responsabilidad del fabricante mientras existe un consentimiento informado por parte del usuario para el uso particular que se quiera dar, sin tomar de forma particular algún reglamento ético para aprobar finalmente el uso clínico de dichas herramientas. El enfoque presentado por EE. UU. es muy distinto al que se viene desarrollando paralelamente en Europa donde para mayo del 2018 se vio por conveniente el desarrollo de legislación sobre los dispositivos médicos integrados con herramientas inteligentes, en particular la Unión Europea (UE) propuso la reforma en los campos de legislación basada en el Reglamento General de Protección de Datos (GRPR) y la directiva de Ciberseguridad con el objetivo de salvaguardar la seguridad de los datos, pues para la UE se debe de garantizar el conocimiento preciso de los incidentes de ciberataque para notificarlas, minimizarlas y el servicio no sea interrumpido bajo la jurisdicción de producto sanitario definido por la UE en su apartado 1 y 2 de la directiva 93/42/CEE donde considera a un producto sanitario como cualquier instrumento u otra herramienta, incluido cualquier tipo de programa informático, diseñados por el fabricante para ser utilizados por seres humanos en actividades relacionadas con el diagnóstico, prevención, seguimiento, tratamiento, o alivio de enfermedades, entre otros fines.

La preocupación general de aceptar las tecnologías inteligentes en la UE es que si realmente se puede garantizar los resultados pues muchas de las tareas desarrolladas como diagnóstico, seguimiento, etc. son desarrolladas a nivel clínico por especialistas entrenados que han sido capacitados y certificados por instituciones de alto nivel, en muchos casos con la intención que pueda garantizar la efectividad del procedimiento que desarrollan dando paso a la pregunta sobre si la tecnología inteligente necesitaría adquirir dicha certificación para de alguna manera garantizar los resultados generados sobre todo cuando la mayoría de artículos menciona la aplicación clínica como herramienta de apoyo orientada a disminuir el tiempo del procedimiento, mejorar la calidad del diagnóstico y la eficiencia de las pruebas con potencialidad para la predicción cultivando el proceso de prevención sobre el tratamiento, aunque las herramientas inteligentes no se limitan a la prevención.

Finalmente, culminamos la sección de discusión con el enfoque de las tecnologías usadas, tenemos aplicaciones basadas en ultrasonido, tomografía, resonancia magnética y vectocardiograma con la asistencia de datos electrocardiográficos en un estudio, se puede observar que nueve estudios se desarrollaron en base a la tomografía seguidas por el ultrasonido con siete estudios, en un tercer lugar tenemos a la resonancia magnética con cinco y finalmente tres con vectocardiograma. Mostrando el mejor resultado el desarrollado en [10] con ultrasonido con un 99.5% de precisión para la clasificación de infarto de miocardio, es decir para el proceso de diagnóstico, cabe la pena señalar, además, que el ecocardiograma es el examen al que más personas pueden acceder sin contraindicaciones presentadas en otros tipos de exámenes como por ejemplo, tomografía o resonancia magnética que al ser tecnologías basadas en exposición de radiación iónica no suelen ser recomendables para un proceso de seguimiento del SCA, pero que finalmente se hace necesario debido a la dificultad del diagnóstico mediante otras técnicas y esto debido a particularidades de cada caso que no se hace evidente el diagnóstico. Para el caso del vectocardiograma se puede referenciar que en los otros tres estudios considerados [28, 29, 30] la idea se basa en el diagnóstico mediante extracción de características de la señal siendo una práctica desarrollada en la electrocardiografía donde a partir de las particularidades de la señal y algunos datos clínicos se procesan una gran cantidad de datos para llegar a una tarea de diagnóstico pero que para casos particulares no es recomendable porque existen reportes de casos particulares en la señal que no dan paso a sospecha de SCA sino que por el contrario genera una interpretación equivocada y ante ello se prefiere un diagnóstico por imagen a pesar de la potencialidad que generan los algoritmos inteligentes.

VII. CONCLUSIONES

El síndrome coronario agudo o SCA es una patología con alta mortalidad a los 30 días de desarrollo de la patología. Los esfuerzos para el diagnóstico tienen grados de dificultad dependientes de las tecnologías usadas para su respectivo diagnóstico. El uso de herramientas basadas en la inteligencia artificial ha mostrado resultados prometedores para diversos campos, siendo el campo de la medicina uno de ellos. Se encontró una precisión del 99.5% para la clasificación de infarto del miocardio siendo uno de los desarrollos prometedores pues muchos de los estudios comentan propuestas a futuro de optimización de algoritmos para la determinación de mejores resultados.

En general los estudios muestran una diversa oportunidad de uso de herramientas inteligentes y las aplicaciones clínicas futuras desarrollándose para imágenes de ultrasonido, tomografía, resonancia magnética y vectocardiograma en el caso particular del SCA, el impacto es tan positivo y prometedor que en países dominantes se vienen desarrollando estrategias de regulación y normas legales bajo una perspectiva integral de acuerdo a la necesidad de cada país, todo esto para la integración de software inteligente en el área médica con el objetivo de asegurar la tecnología y lograr el impacto positivo en los usuarios. Con estas evidencias y con la continuación en las investigaciones es más que claro el futuro que le espera al área de la Inteligencia Artificial dentro del campo médico.

Respecto a las tecnologías se revelan avances prometedores en la aplicación de inteligencia artificial. En el ámbito del ultrasonido, la extracción de características a través de la transferencia discreta de Wavelet (DWT) demostró una impresionante precisión del 99.5%, sensibilidad y especificidad por encima del 99%. Asimismo, en resonancia magnética, la segmentación del miocardio utilizando la arquitectura UNet alcanzó un índice de Dice del 89%, proporcionando una herramienta eficaz para la evaluación de imágenes relacionadas con el SCA.

En el análisis del vectorcardiograma, la implementación de la arquitectura "Multilayer Perceptron Network (MLP)" exhibió una notable precisión del 99.15%, enfatizando la capacidad de las redes neuronales para interpretar señales cardíacas complejas. En el ámbito de la tomografía, la arquitectura "NasNet Large" ofreció una precisión del 94%, subrayando la eficacia de las redes neuronales avanzadas en la clasificación precisa de

imágenes tomográficas vinculadas al SCA. Estos resultados resaltan la significativa contribución de la inteligencia artificial al diagnóstico preciso del SCA.

Es así que finalmente, de acuerdo a lo encontrado en la RS, podemos decir que las herramientas basadas en IA podrían realizar la tarea de diagnóstico del SCA, pero se debe de tener cuidado con el uso en el ámbito clínico ya que la implementación comprende un grado de confiabilidad en base a métricas específicas dependientes del uso de imágenes o señales. Finalmente el desarrollo de las herramientas basadas en IA no contempla más que una herramienta de apoyo para el médico especialista que necesita ser regulado por normas específicas para asegurar la calidad y seguridad de los *stakeholders* en el ámbito clínico.

VIII. RECOMENDACIONES

En el contexto específico del diagnóstico del síndrome coronario agudo (SCA) en el Perú, se sugiere una cuidadosa consideración de los algoritmos de inteligencia artificial (IA) que se ajusten a las características y necesidades únicas de la población peruana. Dada la diversidad de factores, como la variabilidad genética y las condiciones de salud específicas, se recomienda priorizar algoritmos que hayan demostrado robustez y adaptabilidad en los entornos clínicos similares para garantizar la efectividad de los resultados.

La implementación de algoritmos basados en aprendizaje profundo como las redes neuronales (CNN) y arquitecturas avanzadas como Inception V3 o ResNet, podría ser una opción valiosa. Estos modelos han demostrado excelentes resultados en la interpretación precisa de imágenes médicas, como las utilizadas en estudios de tomografía y resonancia magnética, siendo estas herramientas fundamentales para el diagnóstico. Claramente, las aplicaciones futuras que se implementen se verán limitadas por los recursos disponibles con los que se cuentan, en específico bajo la temática de la conformación del dataset como imágenes y/o señales; en este sentido de acuerdo con los hallazgos la recomendación viene siendo una orientación a imágenes de resonancia magnética tomando en cuenta que está orientado a un diagnóstico y no una herramienta de seguimiento.

Finalmente, se sugiere explorar enfoques de aprendizaje transferido que puedan aprovechar datos previamente recopilados en otras poblaciones, adaptándose de manera a las características específicas de los pacientes peruanos. Esta estrategia podría acelerar el desarrollo de implementación de algoritmos de IA para el diagnóstico del SCA, aprovechando la experiencia acumulada en contextos clínicos similares a nivel global.

Referencias bibliográficas:

- [1].Nadarajah, R., & Gale, C. (2021). The management of acute coronary syndromes in patients presenting without persistent ST-segment elevation: key points from the ESC 2020 Clinical Practice Guidelines for the general and emergency physician. *Clinical Medicine*, 21(2), e206.
- [2]. Vidan Astiz, T. Síndrome coronario Agudo. *Tratado de Geriatria para residentes [Internet].*[citado 24 Nov 2021]; 31: 325-32.
- [3]. Sprockel, J., Tejada, M., Yate, J., Diaztagle, J., & González, E. (2018). Herramientas de sistemas inteligentes en el diagnóstico de los síndromes coronarios agudos: una revisión sistemática. *Archivos de cardiología de México*, 88(3), 178-189.
- [4]. Stuart Russell, P. N., & NORVIG, P. (2006). *Inteligencia Artificial*
- [5]. Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., ... & Ramkumar, P. N. (2020). Machine learning and artificial intelligence: definitions, applications, and future directions. *Current reviews in musculoskeletal medicine*, 13(1), 69-76
- [6]. Van Der Aalst, W. (2016). Data science in action. In *Process mining* (pp. 3-23). Springer, Berlin, Heidelberg.
- [7]. Skandha, S. S., Gupta, S. K., Saba, L., Koppula, V. K., Johri, A. M., Khanna, N. N., ... & Suri, J. S. (2020). 3-D optimized classification and characterization artificial intelligence paradigm for cardiovascular/stroke risk stratification using carotid ultrasound-based delineated plaque: Atheromatic™ 2.0. *Computers in Biology and Medicine*, 125, 103958.
- [8]. Kusunose, K., Abe, T., Haga, A., Fukuda, D., Yamada, H., Harada, M., & Sata, M. (2020). A deep learning approach for assessment of regional wall motion abnormality from echocardiographic images. *Cardiovascular Imaging*, 13(2_Part_1), 374-381.
- [9]. Yu, F., Huang, H., Yu, Q., Ma, Y., Zhang, Q., & Zhang, B. (2021). Artificial intelligence-based myocardial texture analysis in etiological differentiation of left ventricular hypertrophy. *Annals of Translational Medicine*, 9(2).
- [10]. Vidya, K. S., Ng, E. Y. K., Acharya, U. R., Chou, S. M., San Tan, R., & Ghista, D. N. (2015). Computer-aided diagnosis of myocardial infarction using ultrasound images with DWT, GLCM and HOS methods: a comparative study. *Computers in biology and medicine*, 62, 86-93.
- [11]. Tabassian, M., Alessandrini, M., Herbots, L., Mirea, O., Pagourelas, E. D., Jasaityte, R., ... & D'hooge, J. (2017). Machine learning of the spatio-temporal characteristics of echocardiographic deformation curves for infarct classification. *The international journal of cardiovascular imaging*, 33(8), 1159-1167.

- [12]. Degerli, A., Zabihi, M., Kiranyaz, S., Hamid, T., Mazhar, R., Hamila, R., & Gabbouj, M. (2021). Early Detection of Myocardial Infarction in Low-Quality Echocardiography. *IEEE Access*, 9, 34442-34453.
- [13]. Jun, T. J., Kang, S. J., Lee, J. G., Kweon, J., Na, W., Kang, D., ... & Kim, Y. H. (2019). Automated detection of vulnerable plaque in intravascular ultrasound images. *Medical & biological engineering & computing*, 57(4), 863-876.
- [14]. Cheung, W. K., Bell, R., Nair, A., Menezies, L., Patel, R., Wan, S., ... & Jacob, J. (2021). A computationally efficient approach to segmentation of the aorta and coronary arteries using deep learning. *medRxiv*.
- [15]. Fedewa, R., Puri, R., Fleischman, E., Lee, J., Prabhu, D., Wilson, D. L., ... & Fleischman, A. (2020). Artificial intelligence in intracoronary imaging. *Current Cardiology Reports*, 22, 1-15.
- [16]. Choi, A. D., Marques, H., Kumar, V., Griffin, W. F., Rahban, H., Karlsberg, R. P., ... & Earls, J. P. (2021). CT Evaluation by Artificial Intelligence For Atherosclerosis, Stenosis and Vascular Morphology (CLARIFY): A Multi-center, international study. *Journal of Cardiovascular Computed Tomography*.
- [17]. Wang, Y., Chen, H., Sun, T., Li, A., Wang, S., Zhang, J., ... & Cao, F. (2021). Risk predicting for acute coronary syndrome based on machine learning model with kinetic plaque features from serial coronary computed tomography angiography. *European Heart Journal-Cardiovascular Imaging*.
- [18]. Berkaya, S. K., Sivrikoz, I. A., & Gunal, S. (2020). Classification models for SPECT myocardial perfusion imaging. *Computers in Biology and Medicine*, 123, 103893.
- [19]. Lomsky, M., Gjertsson, P., Johansson, L., Richter, J., Ohlsson, M., Tout, D., ... & Edenbrandt, L. (2008). Evaluation of a decision support system for interpretation of myocardial perfusion gated SPECT. *European journal of nuclear medicine and molecular imaging*, 35(8), 1523-1529.
- [20]. Ohlsson, M. (2004). WeAidU—a decision support system for myocardial perfusion images using artificial neural networks. *Artificial Intelligence in Medicine*, 30(1), 49-60.
- [21]. Liu, R., Zhang, Y., Zheng, Y., Liu, Y., Zhao, Y., & Yi, L. (2019). Automated detection of vulnerable plaque for intravascular optical coherence tomography images. *Cardiovascular engineering and technology*, 10(4), 590-603.
- [22]. Abdolmanafi, A., Duong, L., Dahdah, N., Adib, I. R., & Cheriet, F. (2018). Characterization of coronary artery pathological formations from OCT imaging using deep learning. *Biomedical optics express*, 9(10), 4936-4960.
- [23]. Suinesiaputra, A., Cowan, B. R., Al-Agamy, A. O., Elattar, M. A., Ayache, N., Fahmy, A. S., ... & Young, A. A. (2014). A collaborative resource to build consensus for automated left ventricular segmentation of cardiac MR images. *Medical image analysis*, 18(1), 50-62.

- [24]. Liu, J., Xie, H., Zhang, S., & Gu, L. (2019). Multi-sequence myocardium segmentation with cross-constrained shape and neural network-based initialization. *Computerized Medical Imaging and Graphics*, 71, 49-57.
- [25]. Cordero-Grande, L., Vegas-Sánchez-Ferrero, G., Casaseca-de-la-Higuera, P., San-Román-Calvar, J. A., Revilla-Orodea, A., Martín-Fernández, M., & Alberola-López, C. (2011). Unsupervised 4D myocardium segmentation with a Markov Random Field based deformable model. *Medical image analysis*, 15(3), 283-301.
- [26]. Heidenreich, J. F., Gassenmaier, T., Ankenbrand, M. J., Bley, T. A., & Wech, T. (2021). Self-configuring nnU-net pipeline enables fully automatic infarct segmentation in late enhancement MRI after myocardial infarction. *European Journal of Radiology*, 109817.
- [27]. Detsky, J. S., Paul, G., Dick, A. J., & Wright, G. A. (2009). Reproducible classification of infarct heterogeneity using fuzzy clustering on multicontrast delayed enhancement magnetic resonance images. *IEEE transactions on medical imaging*, 28(10), 1606-1614.
- [28]. Chuang, Y. H., Huang, C. L., Chang, W. W., & Chien, J. T. (2020). Automatic classification of myocardial infarction using spline representation of single-lead derived vectorcardiography. *Sensors*, 20(24), 7246.
- [29]. Costa, C. M., Silva, I. S., de Sousa, R. D., Hortegal, R. A., & Regis, C. D. M. (2018). The association between reconstructed phase space and Artificial Neural Networks for vectorcardiographic recognition of myocardial infarction. *Journal of electrocardiology*, 51(3), 443-449.
- [30]. Sun, Q., Wang, Q., Ji, B., Wu, W., Huang, W., & Wang, C. (2020). The Cardiodynamicsgram Based Early Detection of Myocardial Ischemia Using the Lempel-Ziv Complexity. *IEEE Access*, 8, 207894-207904.
- [31]. Amisha, P. M., Pathania, M., & Rathaur, V. K. (2019). Overview of artificial intelligence in medicine. *Journal of family medicine and primary care*, 8(7), 2328.
- [32]. Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, 69, S36-S40.
- [33]. Schwartz, W. B., Patil, R. S., & Szolovits, P. (1987). Artificial intelligence in medicine.
- [34]. Sprockel, J., Tejada, M., Yate, J., Diaztagle, J., & González, E. (2018). Herramientas de sistemas inteligentes en el diagnóstico de los síndromes coronarios agudos: una revisión sistemática. *Archivos de cardiología de México*, 88(3), 178-189.
- [35]. Roberts, H., Cowls, J., Morley, J., Taddeo, M., Wang, V., & Floridi, L. (2021). The Chinese approach to artificial intelligence: an analysis of policy, ethics, and regulation. *AI & SOCIETY*, 36(1), 59-77.
- [36]. Barton, D., Woetzel, J., Seong, J., & Tian, Q. (2017). Artificial intelligence: implications for China.

- [37]. Pesapane, F., Volonté, C., Codari, M., & Sardanelli, F. (2018). Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States. *Insights into imaging*, 9(5), 745-753.
- [38]. Stang A. Critical evaluation of the Newcastle-Ottawa scale for the assessment of the quality of nonrandomized studies in meta-analyses. *Eur J Epidemiol* 2010;25:603–5. <https://doi.org/10.1007/s10654-010-9491-z>.
- [39]. Scirica, B. M. (2010). Acute coronary syndrome. *Journal of the American College of Cardiology*, 55(14), 1403–1415. <https://doi.org/10.1016/j.jacc.2009.09.071>
- [40]. DeVon, H. A., Mirzaei, S., & Zègre-Hemsey, J. (2020). Typical and atypical symptoms of acute coronary syndrome: time to retire the terms?. *Journal of the American Heart Association*, 9(7), e015539.
- [41]. Timmis, A., Kazakiewicz, D., Townsend, N., Huculeci, R., Aboyans, V., & Vardas, P. (2023). Global epidemiology of acute coronary syndromes. *Nature Reviews Cardiology*, 1-11.
- [42]. Naser, M. Z., & Alavi, A. (2020). Insights into performance fitness and error metrics for machine learning. arXiv preprint arXiv:2006.00887.

IX. ANEXOS

Tablas y Figuras

Figura 6. Diagrama de flujo para la selección de los estudios incluidos

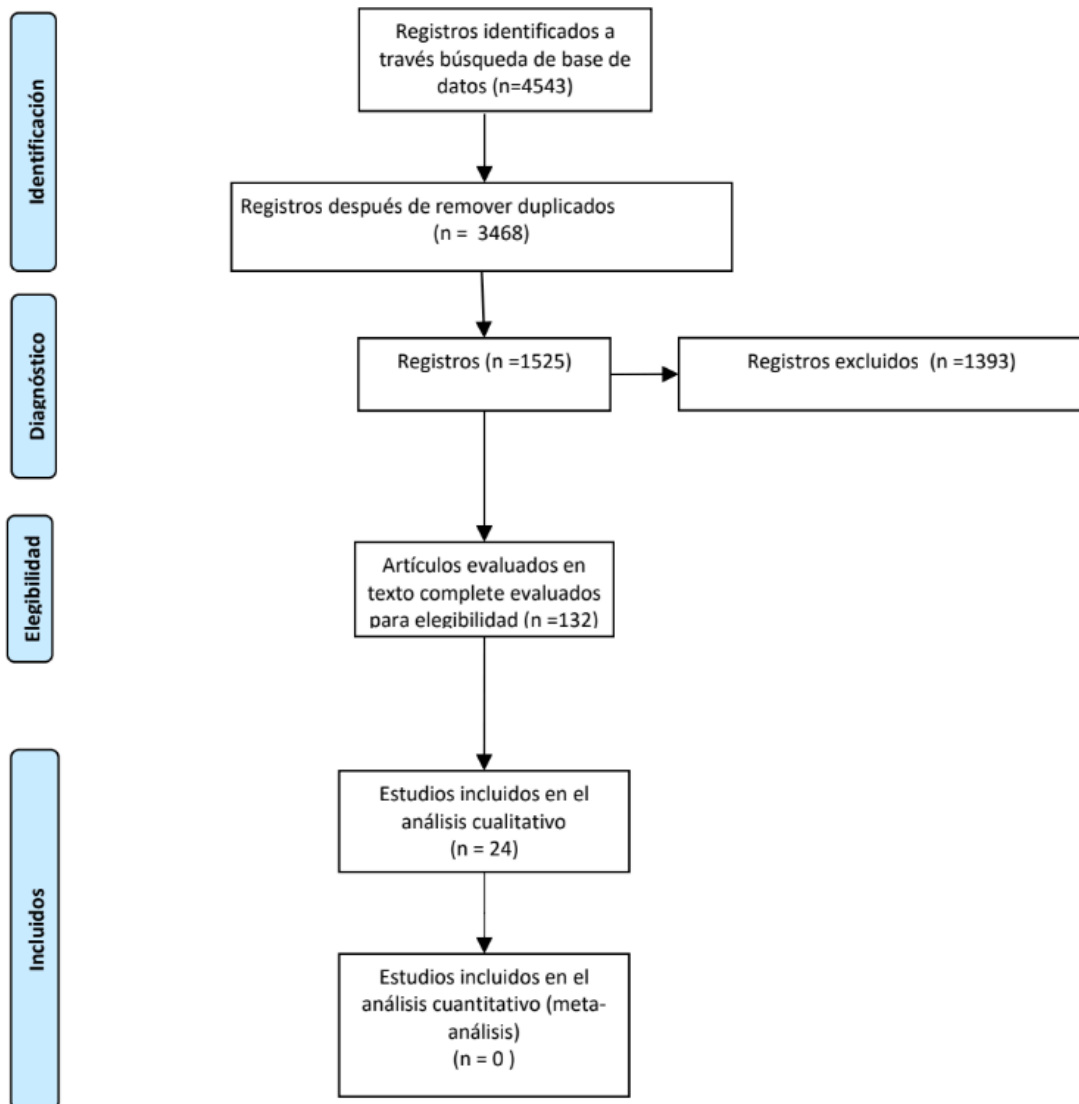


Tabla 2. Características de los estudios

N. o.	Nombre	Autores	Diseño del estudio	Aplicación del dispositivo / Aplicación clínica	Objetivos de la investigación	Instrumento de estudio	Modelo experimental	Entrenamiento	Método de evaluación	Conclusión principal
1	3-D optimized classification and characterization artificial intelligence paradigm for cardiovascular/stroke risk stratification using carotid ultrasound-based delineated plaque: Atheromatic™ 2.0	S.S. Skandha et al	Cohorte	Diagnóstico	Caracterización de los tejidos de la placa mediante la implementación de inteligencia artificial	Imágenes ecocardiográficas	Procesamiento mediante algoritmos de inteligencia artificial medido por la precisión del algoritmo	90% de la data general (346 imágenes con data aumentada)	Intercepción V3, VGG16 con pre-entrenamiento de Imagenet con Naives, KNN, SVM y DT, además DCNN (Arquitecturas de Deep Learning Neural Networks)	Se pudo caracterizar la placa sintomática y asintomática con una precisión de 95.66% mejorando un 7.01% respecto a estudios de ML y 12.05% respecto a otros estudios que no son de ML.

2	A collaborative resource to build consensus for automated left ventricular segmentation of cardiac MR images	Avian S. et al.	Cohorte	Caracterización	Consensuar la segmentación de imágenes resonancia magnética cardiaca para la caracterización del ventrículo izquierdo	Imágenes de resonancia magnética cardiaca, base de datos pública (DETERMINE: Defibrillators to reduce risk by magnetic resonance imaging evaluation)	Procesamiento automatizado (no involucra arquitectura neta de ML o DL)	100 imágenes con segmentación manual del ventrículo izquierdo	Deformable registration method (SCR), Layered spatio-temporal forest algorithm (INR), Contour constrained optical flow tracking (AO), Block matching algorithm (DS), Manually guide-point modeling assisted fitting of cardiac model (AU)	Los modelos AO, DS, AU y SCR mostraron mejores resultados frente a INR. Sin embargo se espera que el modelo sea aun mejorable en el futuro. (Las métricas no son muy altas)
---	--	-----------------	---------	-----------------	---	--	--	---	---	---

3	A computationally efficient approach to segmentation of the aorta and coronary arteries using deep learning	Wing K. et al	Estudio de casos y controles	Segmentación	Segmentación la aorta y las arterias coronarias	Imágenes CT	Procesamiento automatizado de segmentación mediante U-Net	55 imágenes equivalente al 80%	U-Net	Se demuestra que el modelo U-Net para las imágenes 2D es capaz de segmentar las arterias coronarias de manera eficiente y con buena precisión con ventajas computacionales para aplicaciones intrahospitalarias.
4	A Deep Learning Approach for Assessment of Regional Wall Motion Abnormality From Echocardiographic Images	Kenya K. et al	Cohorte	Diagnóstico	Las redes neuronales convolucionales profundas (DCNN) puede proporcionar mejor anomalías regionales	Imágenes ecocardiográficas	Procesamiento mediante algoritmos de inteligencia artificial medido por la precisión del algoritmo	320 imágenes equivalente al 80%	DCNN, ResNet, DenseNet, Inception-ResNet, Inception, and Xception	Nuestros resultados apoyan la posibilidad del uso de DCNN para el diagnóstico automatizado de la isquemia miocárdica en el campo de

					del movimiento de la pared para el diagnóstico de infarto coronario.					la ecocardiografía con un 97% de AUC.
5	Artificial Intelligence in Intracoronary Imaging	Russell F. et al	Estudio de casos y controles	Predicción	Mostrar el potencial futuro de la inteligencia artificial para la segmentación de imágenes CT*	Imágenes CT	Procesamiento de imágenes mediante algoritmos de inteligencia artificial (no se especifica la arquitectura)	No se especifica el número de imágenes de entrenamiento	No se especifica la arquitectura utilizada pero se menciona un proceso de segmentación	Se pudo reconocer el zonas características para indicios de eventos cardiacos mediante la segmentación, sin embargo se menciona que para trabajos futuros se espera reconocer diferenciadamente la placa de erosión y ruptura, etc.

6	Artificial intelligence-based myocardial texture analysis in etiological differentiation of left ventricular hypertrophy	Fei Yu et al.	Estudio de casos y controles	Clasificación	Realizar la clasificación de enfermedad cardiovascular entre el cual está el infarto al miocardio a través de la extracción de características de las imágenes ecocardiográficas	Imágenes ecocardiográficas	Procesamiento de las características extraídas de las imágenes ecocardiográficas mediante SVM	No se especifica el número de imágenes de entrenamiento, pero se menciona un total de 50 casos reunidos	SVM	Se observó la viabilidad del análisis de textura miocárdica a través de métodos de inteligencia artificial donde se encuentra mayor potencial en la extracción de características para una clasificación mediante SVM.
7	Automated Detection of Vulnerable Plaque for Intravascular Optical Coherence Tomography Images	Ran L. et al	Estudio de casos y controles	Clasificación	Detección de la placa vulnerable para la detección del síndrome coronario agudo (SCA)	IVOC (tomografía de coherencia óptica intravascular)	Procesamiento de imágenes IVOC mediante DCNN	2000 imágenes de entrenamiento y 300 de testeo	YOLO, SSD, Faster R-CNN	Se presenta un sistema de detección automática mediante combinaciones de arquitecturas DCNN

										orientado a la caracterización de la placa vulnerable mediante imágenes IVOC con una precisión del 88.46%
8	Automated detection of vulnerable plaque in intravascular ultrasound images	Jhon T. et al	Estudio de casos y controles	Clasificación	Detección de la capa fina de febroateroma en imágenes de ultrasonido intravascular (IVUS)	Imágenes IVUS (imagen de ultrasonido intravascular)	Procesamiento de imágenes mediante algoritmos de inteligencia artificial.	90% de la data general se usó como entrenamiento para el resultado más óptimo	FNN, KNN, RF y CNN	Este esquema proporciona un método de segmentación flexible y robusto que ha sido capaz de generar resultados comparables a los de las imágenes segmentadas manualmente para algunos parámetros derivados de la función cardíaca en un conjunto

										de 43 pacientes
9	Automatic Classification of Myocardial Infarction Using Spline Representation of Single-Lead Derived Vectorcardiography	Yu H. et al	Estudio de casos y controles	Clasificación	Detección de infarto de miocardio	Señales vectocardiograma + derivaciones ECG	Clasificación a partir de señales y transformación LSTM	No se especifica el número de señales tomadas para el entrenamiento pero se menciona que si realizan dicha acción (revisar)	Multilayer Perceptrón Network (MLP)	Los resultados combinados de 52 sujetos sanos y 143 pacientes con IM demuestran la validez del sistema de clasificación de IM propuesto, con una precisión del 99,15%, una sensibilidad del 99,16% y una especificidad del 99,92%
10	Characterization of coronary artery pathological formations from OCT imaging	Abdolmanafi A. et al	Estudio de casos y controles	Caracterización	Caracterización de los tejidos de las arterias coronarias	imágenes OCT	Procesamiento de imágenes mediante algoritmos de deep learning	66% de la data para el entrenamiento, 50% restante para el testeo y el	AlexNet, VGG - 19, Inception v3	Los resultados demuestran altos valores de precisión, sensibilidad y especificidad para cada

	using deep learning						(deep learning)	50% restante para la validación		tejido (hasta $0,99 \pm 0,01$).
11	Classification models for SPECT myocardial perfusion imaging	Kaplan S. et al	Estudio de casos y controles	Clasificación	Identificar las anomalías de perfusión (miocardio, isquemia y/o infarto).	imágenes SPECT	Modelos basados en arquitecturas de inteligencia artificial mediante dos modelos generales	66% para el entrenamiento, 17% de validación y 17% de testeo	AlexNet, DenseNet-201, GoogleNet, NasNet-Large, ResNet-18, VGG-16, VGG-18	Los valores máximos de precisión, sensibilidad y especificidad se calculan en un 94%, 88% y 100% para el modelo basado en DL y en un 93%, 100% y 86% para el modelo basado en machine learning, respectivamente

1 2	Computer-aided diagnosis of Myocardial Infarction using ultrasound images with DWT, GLCM and HOS methods: A comparative study	Vidya K. et al	Estudio de casos y controles	Clasificación	Clasificación de infarto de miocardio	Imágenes ecocardiográficas (extracción de características)	Extracción de características mediante transformada de wavelet y clasificación por SVM	No se especifica (revisar)	SVM	Las características extraídas de los coeficientes DWT obtuvieron una precisión del 99,5%, una sensibilidad del 99,75% y una especificidad del 99,25%; las GLCM han logrado una precisión del 85,75%, una sensibilidad del 90,25% y una especificidad del 81,25%; y HOS obtuvo una precisión del 93,0%, una sensibilidad del 94,75% y
--------	---	----------------	------------------------------	---------------	---------------------------------------	--	--	----------------------------	-----	--

										una especificidad del 91,25%. De las tres técnicas presentadas, DWT es la que ha obtenido la mayor precisión de la clasificación. Por lo tanto, el enfoque CAD propuesto puede utilizarse como herramienta complementaria para ayudar a los cardiólogos a realizar un diagnóstico más preciso
13	CT Evaluation by Artificial Intelligence For	Andrew D. et al	Estudio de casos	Estratificación	Estratificación del riesgo de	Angiografía coronaria por tomografía	Segmentación y etiquetado	No se especifica	CNN	El enfoque asistido por IA para la

	Atherosclerosis, Stenosis and Vascular Morphology (CLARIFY): A Multi-center, international study		y controles		enfermedad arterial coronaria	computarizada (ATCC)	para la determinación del lumen y la pared del vaso, la cuantificación y la caracterización de la placa			interpretación de la ACTC determina la estenosis coronaria y la categoría CAD-RADS en de acuerdo con el consenso de los lectores expertos de L3
14	Evaluation of a decision support system for interpretation of myocardial perfusion gated SPECT	Lomsky M. et al	Estudio de casos y controles	Clasificación	Sistema de apoyo para la toma de decisiones de interpretación MPS (gammagrafía de perfusión miocárdica)	MPS	Procesamiento basado en redes neuronales para la toma de decisiones de clasificación de infarto miocárdico	418 MPS de entrenamiento y 532 de testeo	Redes neuronales (No se especifica el modelo)	La red neuronal mostró una sensibilidad del 90% y una especificidad del 85% para la isquemia miocárdica, ejemplificando el uso de herramientas basadas en inteligencia artificial

15	Machine learning of the spatio-temporal characteristics of echocardiographic deformation curves for infarct classification	Tabassian M. et al	Estudio de casos y controles	Clasificación	Clasificación automática de infarto de miocardio	Imágenes ecocardiográficas	Procesamiento de imágenes a partir de imágenes ecocardiográficas mediante análisis espacio temporal	90% training y 10% de testeo	PCA, KNN, espacio temporal	Se obtuvo una precisión de clasificación media del 87%, con unas tasas de sensibilidad y especificidad correspondientes del 89% y 85%
16	Multi-sequence myocardium segmentation with cross-constrained shape and neural network-based initialization	Liu J. et al	Estudio de casos y controles	Segmentación	Reconstrucción y segmentación de miocardio	Imágenes MRI	Uso de reconstrucción C-GAN para la segmentación del miocardio	134 imágenes para el entrenamiento y generación, no evidencia algún testeo fuera de la data	C-GAN y GMM (clasificación gaussiana)	Se obtiene un prometedor coeficiente de similitud de Dice del miocardio (84,97±4,15% para T2 y 78,13±6,22% para DE CMR)
17	Reproducible Classification of Infarct Heterogeneity Using Fuzzy Clustering on Multicontrast	Jay S. et al	Estudio de casos y controles	Clasificación	Identificación de zonas infartadas y no infartadas	Imágenes de resonancia magnética con realce de contraste tardío (MCDE)	Procesamiento de imágenes mediante algoritmos de análisis y	El análisis de segmentación es mediante un proceso automatiza	Fuzzy logic	El enfoque MCDE proporciona una medida más reproducible del núcleo del

	Delayed Enhancement Magnetic Resonance Images						agrupación difusa	do de pixeles de las imágenes, no hay un entrenamiento de por medio		infarto y de las zonas grises en cualquier conjunto de datos.
18	Risk predicting for acute coronary syndrome based on machine learning model with kinetic plaque features from serial coronary computed tomography angiography	Wang Y. et al	Cohorte	Clasificación	Predicción de síndrome coronario agudo mediante características angiografía por tomografía computarizada	Características extraídas de angiografía por tomografía computarizada	Procesamiento de características extraídas de imágenes por método de IA	80% de entrenamiento y 20% de testeo	XGBoost	El modelo XGBoost que comprende las cinco características más importantes de la placa reveló una mayor capacidad de predicción (área bajo la curva 0,918, intervalo de confianza del 95%: 0,861-0,968)

19	The Association between Reconstructed Phase Space and Artificial Neural Networks for Vectorcardiographic Recognition of Myocardial Infarction	Cecilia M. et al	Estudio de casos y controles	Clasificación	Clasificación de infarto de miocardio	Vectorcardiograma	Procesamiento de características extraídas de vectocardiograma por fórmulas matemáticas	90% de entrenamiento y 10% de testeo	ANN	Con cuatro características en total un tamaño de filtro de 10 x10 se consiguió una precisión del 94% con una sensibilidad del 92% y especificidad del 96% mediante una arquitectura ANN
20	The Cardiodynamics gram Based Early Detection of Myocardial Ischemia Using the Lempel-Ziv Complexity	Sun Q. et al	Cohorte	Clasificación	Clasificación de pacientes isquémicos y no isquémicos	Vectorcardiograma	Caracterización mediante análisis matemático de las señales extraídas de CDG	314 señales para el entrenamiento y 79 de testeo	SVM y análisis matemático	Los resultados indican que la complejidad de LZ puede caracterizar con precisión caracterizar los casos que no pueden ser representados con precisión por el exponente de

										Lyapunov, y el modelo modelo es más preciso para la detección temprana de la isquemia miocárdica.
21	Unsupervised 4D myocardium segmentation with a Markov Random Field based deformable model	Cordero L. et al	Estudio de casos y controles	Segmentación	Segmentación miocárdica	Imágenes de resonancia magnética	Segmentación miocárdica en imagen de resonancia magnética	No hay fase de entrenamiento	Planteamiento probabilístico mediante espacios discretos de localizaciones	Este esquema proporciona un método de segmentación flexible y robusto que ha sido capaz de generar resultados comparables a los de las imágenes segmentadas manualmente para algunos parámetros derivados de la función cardíaca en un conjunto

										de 43 pacientes afectados en diferentes grados por un infarto agudo de miocardio
22	WeAidU—a decision support system for myocardial perfusion images using artificial neural networks	Mattias O.	Estudio de casos y controles	Clasificación	Clasificación de infarto e isquemia	Imágenes de perfusión	Segmentación e identificación de patología	920 entrenamiento y 400 de testeo	ANN, logistic discriminat ion y KNN	El rendimiento de las redes neuronales artificiales que detectan el infarto y la isquemia en diferentes partes del corazón, medido como áreas bajo las curvas de características operativas del receptor, está en el rango de 0,83 a 0,96. Estos resultados indican un

										alto potencial de la herramienta como sistema de apoyo a la decisión clínica
23	Early Detection of Myocardial Infarction in Low-Quality Echocardiography	Aysen D. et al	Estudio de casos y controles	Clasificación	Clasificación de infarto de miocardio	Imágenes ecocardiográficas	Segmentación de pared ventricular izquierda	80% de entrenamiento y 20% de testeo	E-D CNN, SVM	El enfoque propuesto ha logrado una sensibilidad del 95,72% y una especificidad del 99,58% para la segmentación de la pared del VI, y una sensibilidad del 85,97%, una especificidad del 74,03% y una precisión del 86,85% para la detección de IM en el

										conjunto de datos HMC-QU
24	Self-configuring nnU-net pipeline enables fully automatic infarct segmentation in late enhancement MRI after myocardial infarction	Julius F. et al	Estudio de casos y controles	Clasificación	Predicción de infarto de miocardio mediante segmentación y clasificación	Imágenes MRI	Segmentación del miocardio del ventrículo izquierdo	1902 entrenamiento y 96 de testeo	U-Net (nn-Unet)	La red neuronal autoconfigurable logra predicciones con una fuerte concordancia en comparación con la segmentación manual, demostrando el potencial como herramienta prometedora para proporcionar una evaluación cuantitativa totalmente automática de LGECMR.

											Índice de Dice equivalente al 89%
--	--	--	--	--	--	--	--	--	--	--	---

Tabla 3. Evaluación de la calidad de los estudios de incidencia según escala de New Castle Ottawa – Cohorte

Estudio (año)	Representatividad de la cohorte expuesta	Selección de la cohorte no expuesta	Determinación de la exposición	Demostración que el resultado de interés no estuvo presente al momento del inicio del estudio.	Comparabilidad de cohortes en la base del diseño o análisis.	Evaluación de resultados	Fue el seguimiento lo suficientemente largo para la ocurrencia del resultado.	Adecuación del seguimiento de cohortes.	Total
Skandha (2020)	1	1	1	0	1	1	0	1	6
Suinesiaputra (2014)	0	1	1	0	1	1	0	0	4
Kusunose (2020)	1	1	1	0	0	1	0	1	5
Wang (2021)	1	1	1	1	0	1	1	1	7
Sun (2020)	0	1	1	1	0	1	0	1	5

Tabla 4. Evaluación de la calidad de los estudios de incidencia según escala de New Castle Ottawa – Casos y controles

Estudio (año)	¿Es adecuada la definición del caso?	Representatividad de los casos	Selección de controles	Definición de controles	Comparabilidad de los casos y los controles sobre la base del diseño o el análisis	Determinación de la exposición	Mismo método de comprobación para los casos y los controles	Tasa de no respuesta	Total
Cheung (2021)	1	0	0	0	0	1	1	1	4
Fedewa (2020)	0	0	0	1	0	1	1	0	3
Yu (2021)	1	1	0	0	0	1	0	1	4
Liu (2019)	1	1	0	1	1	0	1	1	6
Jun (2019)	1	1	0	0	0	1	1	0	4
Chuang (2020)	1	1	0	1	1	1	1	0	6
Abdolmanafi (2018)	1	1	0	0	0	1	1	0	4
Berkaya (2020)	1	1	1	1	0	1	1	0	6
Vidya (2015)	1	1	0	1	1	1	1	0	6
Choi (2021)	1	1	0	0	0	1	0	0	3
Lomsky (2008)	0	0	0	0	1	1	1	0	3
Tabassian (2017)	1	1	0	1	1	1	1	1	7
Liu (2019)	1	0	0	0	0	1	1	0	3
Detsky (2009)	1	1	0	0	0	1	0	0	3
Costa (2018)	1	1	0	1	1	1	1	1	7
Cordero-Grande (2011)	0	1	0	1	0	1	0	0	3
Mattias (2004)	1	1	0	0	1	1	0	0	4
Degerli (2021)	1	1	0	0	1	1	1	0	5
Heidenreich (2021)	1	1	0	0	1	1	1	0	5

Tabla 5. Características de los estudios incluidos

N ^o	Nombre	Autores	País	Año de publicación	Base de datos	Revista
1	3-D optimized classification and characterization artificial intelligence paradigm for cardiovascular/stroke risk stratification using carotid ultrasound-based delineated plaque: Atheromatic™ 2.0	Skandha, S. S., Gupta, S. K., Saba, L., Koppula, V. K., Johri, A. M., Khanna et al	Estados Unidos	2020	Elseiver (Scopus)	Computers in Biology and Medicine
2	A collaborative resource to build consensus for automated left ventricular segmentation of cardiac MR images	Suinesiaputra, A., Cowan, B. R., Al-Agamy, A. O., Elattar, M. A., Ayache, N et al.	Nueva Zelanda	2014	Elseiver (Scopus)	Medical Image Analysis
3	A computationally efficient approach to segmentation of the aorta and coronary arteries using deep learning	Cheung, W. K., Bell, R., Nair, A., Menezies, L., Patel, R., Wan, S. et al	Reino Unido	2021	IEEE Xplore	medRxiv
4	A Deep Learning Approach for Assessment of Regional Wall Motion Abnormality From Echocardiographic Images	Kusunose, K., Abe, T., Haga, A., Fukuda, D., Yamada, H., Harada, M., & Sata, M.	Japón	2020	Elseiver (Scopus)	CARDIOVASCULAR IMAGING

5	Artificial Intelligence in Intracoronary Imaging	Fedewa, R., Puri, R., Fleischman, E., Lee, J., Prabhu, D., Wilson, D. L et al	Estados Unidos	2020	Pubmed	Current Cardiology Reports
6	Artificial intelligence-based myocardial texture analysis in etiological differentiation of left ventricular hypertrophy	Yu, F., Huang, H., Yu, Q., Ma, Y., Zhang, Q et al.	China	2021	Pubmed	Annals of Translational Medicine
7	Automated Detection of Vulnerable Plaque for Intravascular Optical Coherence Tomography Images	Liu, R., Zhang, Y., Zheng, Y., Liu, Y., Zhao, Y., & Yi, L.	China	2019	Pubmed	BMES (Biomedical engineering society)
8	Automated detection of vulnerable plaque in intravascular ultrasound images	Jun, T. J., Kang, S. J., Lee, J. G., Kweon, J., Na, W., Kang, D. et al	Corea	2019	Pubmed	Medical & Biological Engineering & Computing
9	Automatic Classification of Myocardial Infarction Using Spline Representation of Single-Lead Derived Vectorcardiography	Chuang, Y. H., Huang, C. L., Chang, W. W., & Chien, J. T.	República de China (Taiwán)	2020	Pubmed	Sensor

10	Characterization of coronary artery pathological formations from OCT imaging using deep learning	Abdolmanafi, A., Duong, L., Dahdah, N., Adib, I. R., & Cheriet, F.	Canadá	2018	Pubmed	Biomedical Optics Express
11	Classification models for SPECT myocardial perfusion imaging	Berkaya, S. K., Sivrikoz, I. A., & Gunal, S.	Turquía	2020	Elseiver	Computers in Biology and Medicine
12	Computer-aided diagnosis of Myocardial Infarction using ultrasound images with DWT, GLCM and HOS methods: A comparative study	Vidya, K. S., Ng, E. Y. K., Acharya, U. R., Chou, S. M., San Tan, R., & Ghista, D. N.	Singapur	2015	Elseiver	Computers in Biology and Medicine
13	CT Evaluation by Artificial Intelligence For Atherosclerosis, Stenosis and Vascular Morphology (CLARIFY): A Multi-center, international study	Choi, A. D., Marques, H., Kumar, V., Griffin, W. F., Rahban, H., Karlsberg, R. P et al	Estados Unidos	2021	Elseiver	Journal of Cardiovascular Computed Tomography
14	Evaluation of a decision support system for interpretation of myocardial perfusion gated SPECT	Lomsky, M., Gjertsson, P., Johansson, L., Richter, J., Ohlsson, M., Tout, D. et al	Suecia	2008	Springer	European Journal of nuclear medicine and molecular imaging
15	Machine learning of the spatio-temporal characteristics of	Tabassian, M., Alessandrini, M., Herbots,	Bélgica	2017	CrossMark	Int. Jorunal Cardiovascular Imaging

	echocardiographic deformation curves for infarct classification	L., Mirea, O., Pagourelas, E. D., Jasaityte, R. et al				
16	Multi-sequence myocardium segmentation with cross-constrained shape and neural network-based initialization	Liu, J., Xie, H., Zhang, S., & Gu, L.	China	2019	Elseiver	Computerized Medical Imaging and Graphics
17	Reproducible Classification of Infarct Heterogeneity Using Fuzzy Clustering on Multicontrast Delayed Enhancement Magnetic Resonance Images	Detsky, J. S., Paul, G., Dick, A. J., & Wright, G. A.	Canadá	2009	IEEE Xplore	IEEE transactions on medical imaging
18	Risk predicting for acute coronary syndrome based on machine learning model with kinetic plaque features from serial coronary computed tomography angiography	Wang, Y., Chen, H., Sun, T., Li, A., Wang, S., Zhang, J. et al	China	2021	Pubmed	European Heart Journal - Cardiovascular Imaging
19	The Association between Reconstructed Phase Space and Artificial Neural Networks for Vectorcardiographic Recognition of Myocardial Infarction	Costa, C. M., Silva, I. S., de Sousa, R. D., Hortegal, R. A., & Regis, C. D. M.	Brasil	2018	Elseiver	Journal of Electrocardiology
20	The Cardiodynamicsgram Based Early Detection of Myocardial Ischemia Using the Lempel-Ziv Complexity	Sun, Q., Wang, Q., Ji, B., Wu, W., Huang, W., & Wang, C.	China	2020	IEEE Xplore	IEEE Access

2 1	Unsupervised 4D myocardium segmentation with a Markov Random Field based deformable model	Cordero-Grande, L., Vegas-Sánchez-Ferrero, G., Casaseca-de-la-Higuera, P., San-Román-Calvar, J. A., Revilla-Orodea, A., Martín-Fernández, M., & Alberola-López, C.	España	2011	Elseiver	Medical Image Analysis
2 2	WeAidU—a decision support system for myocardial perfusion images using artificial neural networks	Mattias O.	Suecia	2004	Elseiver	Artificial Intelligent in Medicine
2 3	Early Detection of Myocardial Infarction in Low-Quality Echocardiography	Degerli, A., Zabihi, M., Kiranyaz, S., Hamid, T., Mazhar, R., Hamila, R., & Gabbouj, M.	Catar	2021	IEEE Xplore	IEEE Access
2 4	Self-configuring nnU-net pipeline enables fully automatic infarct segmentation in late enhancement MRI after myocardial infarction	Heidenreich, J. F., Gassenmaier, T., Ankenbrand, M. J., Bley, T. A., & Wech, T.	Alemania	2021	Elseiver	European Journal of Radiology

Tabla 6: Métricas según Modelo para el estudio 18

Modelo	Precisión	Sensibilidad	Especificidad
AlexNet	0.72	1	0.43
DenseNet 201	0.63	0.96	0.29
GoogLeNet	0.72	1	0.43
NASNet-Large	0.57	1	0.14
ResNet 18	0.77	0.96	0.57
VGG 16	0.86	1	0.71
VGG 19	0.84	0.96	0.71
SVM	0.57	0.96	0.17

MATERIAL SUPLEMENTARIO

Tabla suplementaria 1: PRISMA Statement for Reporting Systematic Reviews and Meta-Analyses.

SECCIÓN/ TEMA	#	ÍTEM	PÁGINA #
TÍTULO			
Título	1	Identificar la publicación como revisión sistemática, metaanálisis o ambos.	
RESUMEN			
Resúmen estructurado	2	Facilitar un resumen estructurado que incluya, según corresponda: antecedentes; objetivos; fuente de los datos; criterios de elegibilidad de los estudios, participantes e intervenciones; evaluación de los estudios y métodos de síntesis; resultados; limitaciones; conclusiones e implicaciones de los hallazgos principales; número de registro de la revisión sistemática.	
INTRODUCCIÓN			
Justificación	3	Describir la justificación de la revisión en el contexto de lo que ya se conoce sobre el tema.	
Objetivos	4	Plantear de forma explícita las preguntas que se desea contestar en relación con los participantes, las intervenciones, las comparaciones, los resultados y el diseño de los estudios (PICOS).	
MÉTODOS			
Protocolo y registro	5	Indicar si existe un protocolo de revisión al se pueda acceder (por ejemplo, dirección web) y, si está disponible, la información sobre el registro, incluyendo su número de registro.	
Criterios de elegibilidad	6	Especificar las características de los estudios (por ejemplo, PICOS, duración del seguimiento) y de las características (por ejemplo, años abarcados, idiomas o estatus de publicación) utilizadas como criterios de elegibilidad y su justificación.	
Fuentes de información	7	Describir todas las fuentes de información (por ejemplo, bases de datos y períodos de búsqueda, contacto con los autores para identificar estudios adicionales, etc.) en la búsqueda y la fecha de la última búsqueda realizada.	
Búsqueda	8	Presentar la estrategia completa de búsqueda electrónica en, al menos, una base de datos, incluyendo los límites utilizados de tal forma que pueda ser reproducible.	
Selección de los estudios	9	Especificar el proceso de selección de los estudios (por ejemplo, el cribado y la elegibilidad incluidos en la revisión sistemática y, cuando sea pertinente, incluidos en el metaanálisis).	
Proceso de recopilación de datos	10	Describir los métodos para la extracción de datos de las publicaciones (por ejemplo, formularios dirigidos, por duplicado y de forma independiente) y cualquier proceso para obtener y confirmar datos por parte de los investigadores.	
Lista de datos	11	Listar y definir todas las variables para las que se buscaron datos (por ejemplo, PICOS fuente de financiación) y cualquier asunción y simplificación que se hayan hecho.	
Riesgo de sesgo en los estudios individuales	12	Describir los métodos utilizados para evaluar el riesgo de sesgo en los estudios individuales (especificar si se realizó al nivel de los estudios o de los resultados) y cómo esta información se ha utilizado en la síntesis de datos.	
Medidas de resúmen	13	Especificar las principales medidas de resumen (por ejemplo, razón de riesgos o diferencia de medias).	

Síntesis de resultados	14	Describir los métodos para manejar los datos y combinar resultados de los estudios, si se hiciera, incluyendo medidas de consistencia (por ejemplo, I ²) para cada metaanálisis.
Riesgo de sesgo entre los estudios	15	Especificar cualquier evaluación del riesgo de sesgo que pueda afectar la evidencia acumulativa (por ejemplo, sesgo de publicación o comunicación selectiva).
Análisis adicionales	16	Describir los métodos adicionales de análisis (por ejemplo, análisis de sensibilidad o de subgrupos, metarregresión), si se hiciera, indicar cuáles fueron preespecificados.

RESULTADOS

Selección de estudios	17	Facilitar el número de estudios cribados, evaluados para su elegibilidad e incluidos en la revisión, y detallar las razones para su exclusión en cada etapa, idealmente mediante un diagrama de flujo.
Características de los estudios	18	Para cada estudio presentar las características para las que se extrajeron los datos (por ejemplo, tamaño, PICOS y duración del seguimiento) y proporcionar las citas bibliográficas.
Riesgo de sesgo en los estudios	19	Presentar datos sobre el riesgo de sesgo en cada estudio y, si está disponible, cualquier evaluación del sesgo en los resultados (ver ítem 12).
Resultados de los estudios individuales	20	Para cada resultado considerado para cada estudio (beneficios o daños), presentar: a) el dato resumen para cada grupo de intervención y b) la estimación del efecto con su intervalo de confianza, idealmente de forma gráfica mediante un diagrama de bosque (forest plot).
Síntesis de los resultados	21	Presentar resultados de todos los metaanálisis realizados, incluyendo los intervalos de confianza y las medidas de consistencia.
Riesgo de sesgo entre los estudios	22	Presentar los resultados de cualquier evaluación del riesgo de sesgo entre los estudios (ver ítem 15).
Análisis adicionales	23	Facilitar los resultados de cualquier análisis adicional, en el caso de que se hayan realizado (por ejemplo, análisis de sensibilidad o de subgrupos, metarregresión [ver ítem 16])

DISCUSIÓN

Resumen de la evidencia	24	Resumir los hallazgos principales, incluyendo la fortaleza de las evidencias para cada resultado principal; considerar su relevancia para grupos clave (por ejemplo, proveedores de cuidados, usuarios y decisores en salud).
Limitaciones	25	Discutir las limitaciones de los estudios y de los resultados (por ejemplo, riesgo de sesgo) y de la revisión (por ejemplo, obtención incompleta de los estudios identificados o comunicación selectiva).
Conclusiones	26	Proporcionar una interpretación general de los resultados en el contexto de otras evidencias, así como las implicaciones para la futura investigación.

FINANCIACIÓN

Financiamiento	27	Describir las fuentes de financiación de la revisión sistemática y otro tipo de apoyos (por ejemplo, aporte de los datos), así como el rol de los financiadores en la revisión sistemática.
----------------	----	---

Adaptado de: Liberati A, Altman DG, Tetzlaff J, Mulrow C, Gøtzsche PC, et al. The PRISMA Statement for Reporting Systematic Reviews and Meta-Analyses of Studies That Evaluate Health Care Interventions: Explanation and Elaboration. PLoS Medicine. 2009; 6(7) and Moher D, Liberati A, Tetzlaff J, Altman DG, Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. Journal of Clinical Epidemiology. 2009; 62: 1006e1012.

Tabla suplementaria 2: Estrategia de búsqueda.

		Fecha	Resultados
Pubmed	<p>((("Acute Coronary Syndrome" OR "Acute Coronary Syndromes" OR "Coronary Syndrome Acute" OR "Coronary Syndromes Acute" OR "Syndrome Acute Coronary" OR "Syndromes Acute Coronary" OR ACS OR "Infarction Myocardial" OR "Infarctions Myocardial" OR "Myocardial Infarctions" OR "cardiovascular Stroke" OR "Cardiovascular Strokes" OR "Stroke Cardiovascular" OR "Strokes Cardiovascular" OR "Myocardial Infarct" OR "Infarct Myocardial" OR "Infarcts Myocardial" OR "Myocardial Infarcts" OR "Heart Attack" OR "Heart Attacks") AND (IA OR ML OR {Artificial intelligent} OR {Neural networks} OR {Neural network} OR {Machine learning} OR {Deep learning} OR {Computational intelligent} OR {Intelligent Machine} OR {fuzzy logic} OR {<u>Unsupervised Machine Learning</u>} OR {<u>Supervised Machine Learning</u>})) OR ((("Acute Coronary Syndrome" OR "Acute Coronary Syndromes" OR "Coronary Syndrome Acute" OR "Coronary Syndromes Acute" OR "Syndrome Acute Coronary" OR "Syndromes Acute Coronary" OR ACS OR "Infarction Myocardial" OR "Infarctions Myocardial" OR "Myocardial Infarctions" OR "cardiovascular Stroke" OR "Cardiovascular Strokes" OR "Stroke Cardiovascular" OR "Strokes Cardiovascular" OR "Myocardial Infarct" OR "Infarct Myocardial" OR "Infarcts Myocardial" OR "Myocardial Infarcts" OR "Heart Attack" OR "Heart Attacks") AND (IA OR ML OR {Artificial intelligent} OR {Neural networks} OR {Neural network} OR {Machine learning} OR {Deep learning} OR {Computational intelligent} OR {Intelligent Machine} OR {fuzzy logic} OR {<u>Unsupervised Machine Learning</u>} OR {<u>Supervised Machine Learning</u>}) AND (Echocardiogram OR Echocardiograph OR Electrocardiography OR Electrocardiogram OR ECG OR EKG OR Angiographic OR Angiograph OR Angiography OR Tomography OR CT OR Topographies OR {<u>Computed Tomography Angiography</u>} OR {<u>Tomography Emission Computed</u>} OR {<u>Tomography Emission Computed Single Photon</u>} OR {<u>Positron Emission Tomography</u>} OR {CT scanning} OR Spect OR {Cat scan} OR {cardiac echography} OR {cardiac scanning} OR {cardial echography} OR cardioechography OR {echo cardiogram} OR {echo cardiography} OR {echo sounding, heart} OR {echocardiogram} OR {echocardiography} OR {echography, heart} OR {heart echo sounding} OR {heart echography} OR {heart scanning} OR {myocardium scanning} OR {scanning, heart} OR {ultrasound cardiography} OR Tomography OR CT OR Topographies OR {Computed Tomography Angiography} OR {Tomography Emission Computed} OR {Tomography Emission Computed Single Photon} OR {Positron Emission Tomography} OR {CT scanning} OR Spect OR {Cat scan} OR {elliptical tomography} OR {laminagraphy} OR {laminography} OR {narrow angle zonography} OR {planigraphy} OR {planography} OR {planygraphy} OR {polytomography} OR {radiotomography} OR {tomography} OR {transverse section imaging} OR {zonography} OR {positron emission tomography} OR {pet scan} OR {pet scanning} OR {p.e.t.' OR 'positron emission tomographic scan} OR {positron emission tomographic scanning} OR {positron emission tomography} OR {positron tomography} OR {positron-emission tomography} OR {tomography, positron} OR vectorcardiography OR vcg OR {ecg, vector} OR {electrocardiography, vector} OR {polarcardiography} OR {spatial vector cardiogram} OR {spatial vectorcardiogram} OR vectocardiogram OR vectocardiography OR {vector cardiogram} OR {vector cardiography} OR {vector ecg} OR {vector electrocardiography} OR {vectorcardiogram} OR vectorcardiography OR vectorelectrocardiography))</p>	2/08/2021	2836

Scopus	<p>#1: “Acute Coronary Syndrome” OR “Acute Coronary Syndromes” OR “Coronary Syndrome Acute” OR “Coronary Syndromes Acute” OR “Syndrome Acute Coronary” OR “Syndromes Acute Coronary” OR “Infarction Myocardial” OR “Infarctions Myocardial” OR “Myocardial Infarctions” OR “cardiovascular Stroke” OR “Cardiovascular Strokes” OR “Stroke Cardiovascular” OR “Strokes Cardiovascular” OR “Myocardial Infarct” OR “Infarct Myocardial” OR “Infarcts Myocardial” OR “Myocardial Infarcts” OR “Heart Attack” OR “Heart Attacks”</p> <p>#2: {Artificial intelligent} OR {Neural networks} OR {Neural network} OR {Machine learning} OR {Deep learning} OR {Computational intelligent} OR {Intelligent Machine} OR {fuzzy logic} OR {Unsupervised Machine Learning} OR {Supervised Machine Learning}</p> <p>#3: Echocardiogram OR Echocardiograph OR Electrocardiography OR Electrocardiogram OR ECG OR EKG OR Angiographic OR Angiograph OR Angiography OR echocardiography OR {cardiac echography} OR {cardiac scanning} OR {cardial echography} OR cardioechography OR {echo cardiogram} OR {echo cardiography} OR {echo sounding, heart} OR {echocardiogram} OR {echocardiography} OR {echography, heart} OR {heart echo sounding} OR {heart echography} OR {heart scanning} OR {myocardium scanning} OR {scanning, heart} OR {ultrasound cardiography} OR Tomography OR CT OR Topographies OR {Computed Tomography Angiography} OR {Tomography Emission Computed} OR {Tomography Emission Computed Single Photon} OR {Positron Emission Tomography} OR {CT scanning} OR Spect OR {Cat scan} OR {elliptical tomography} OR {laminagraphy} OR {laminography} OR {narrow angle zonography} OR {planigraphy} OR {planography} OR {planigraphy} OR {polytomography} OR {radiotomography} OR {tomography} OR {transverse section imaging} OR {zonography} OR {positron emission tomography} OR {pet scan} OR {pet scanning} OR {p.e.t.} OR {positron emission tomographic scan} OR {positron emission tomographic scanning} OR {positron emission tomography} OR {positron tomography} OR {positron-emission tomography} OR {tomography, positron} OR vectorcardiography OR vcg OR {ecg, vector} OR {electrocardiography, vector} OR {polarcardiography} OR {spatial vector cardiogram} OR {spatial vectorcardiogram} OR vectocardiogram OR vectocardiography OR {vector cardiogram} OR {vector cardiography} OR {vector ecg} OR {vector electrocardiography} OR {vectorcardiogram} OR vectorcardiography OR vectorelectrocardiography</p> <p>Final final (#1 AND #2 AND #3)</p>	2/08/202 1	496
Embase	(("Acute Coronary Syndrome" OR "Acute Coronary Syndromes" OR "Coronary Syndrome Acute" OR "Coronary Syndromes Acute" OR "Syndrome Acute Coronary" OR "Syndromes Acute Coronary" OR "Infarction Myocardial" OR "Infarctions Myocardial" OR "cardiovascular Stroke" OR "Cardiovascular Strokes" OR "Myocardial Infarct" OR "Infarct Myocardial" OR "Heart Attack" OR "Heart Attacks") AND ({Artificial intelligent} OR {Neural networks} OR {Neural network} OR {Machine learning} OR {Deep learning} OR {Computational intelligent} OR {Intelligent Machine} OR {fuzzy logic} OR {Unsupervised Machine Learning} OR {Supervised Machine Learning}) AND (echocardiogram OR echocardiograph OR electrocardiography OR electrocardiogram OR angiographic OR angiograph OR angiography OR tomography OR ct OR topographies OR {Computed Tomography Angiography} OR {Tomography	2/08/202 1	811

	Emission Computed} OR {CT scanning} OR {Cat scan})) AND (EXCLUDE (SRCTYPE , "k") OR EXCLUDE (SRCTYPE , "p") OR EXCLUDE (SRCTYPE , "d") OR EXCLUDE (SRCTYPE , "b")) AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "re") OR EXCLUDE (DOCTYPE , "cp") OR EXCLUDE (DOCTYPE , "ch") OR EXCLUDE (DOCTYPE , "bk") OR EXCLUDE (DOCTYPE , "ed") OR EXCLUDE (DOCTYPE , "no") OR EXCLUDE (DOCTYPE , "sh")) AND (LIMIT-TO (EXACTKEYWORD , "Human") OR LIMIT-TO (EXACTKEYWORD , "Humans") OR EXCLUDE (EXACTKEYWORD , "Nonhuman") OR EXCLUDE (EXACTKEYWORD , "Animals") OR EXCLUDE (EXACTKEYWORD , "Animal") OR EXCLUDE (EXACTKEYWORD , "Alzheimer Disease") OR EXCLUDE (EXACTKEYWORD , "Mouse"))		
IEEE Xplore	((“Acute Coronary Syndrome” OR “Acute Coronary Syndromes” OR “Coronary Syndrome Acute” OR “Coronary Syndromes Acute” OR “Syndrome Acute Coronary” OR “Syndromes Acute Coronary” OR ACS OR “Infarction Myocardial” OR “Infarctions Myocardial” OR “Myocardial Infarctions” OR “cardiovascular Stroke” OR “Cardiovascular Strokes” OR “Stroke Cardiovascular” OR “Strokes Cardiovascular” OR “Myocardial Infarct” OR “Infarct Myocardial” OR “Infarcts Myocardial” OR “Myocardial Infarcts” OR “Heart Attack” OR “Heart Attacks”) AND (IA OR ML OR {Artificial intelligent} OR {Neural networks} OR {Neural network} OR {Machine learning} OR {Deep learning} OR {Computational intelligent} OR {Intelligent Machine} OR {fuzzy logic} OR {Unsupervised Machine Learning} OR {Supervised Machine Learning}) AND (Echocardiogram OR Echocardiograph OR Electrocardiography OR Electrocardiogram OR ECG OR EKG OR Angiographic OR Angiograph OR Angiography OR Tomography OR CT OR Topographies OR {Computed Tomography Angiography} OR {Tomography Emission Computed} OR {Tomography Emission Computed Single Photon} OR {Positron Emission Tomography} OR {CT scanning} OR Spect OR {Cat scan} OR {cardiac echography} OR {cardiac scanning} OR {cardial echography} OR cardioechography OR {echo cardiogram} OR {echo cardiography} OR {echo sounding, heart} OR {echocardiogram} OR {echocardiography} OR {echography, heart} OR {heart echo sounding} OR {heart echography} OR {heart scanning} OR {myocardium scanning} OR {scanning, heart} OR {ultrasound cardiography} OR Tomography OR CT OR Topographies OR {Computed Tomography Angiography} OR {Tomography Emission Computed} OR {Tomography Emission Computed Single Photon} OR {Positron Emission Tomography} OR {CT scanning} OR Spect OR {Cat scan} OR {elliptical tomography} OR {laminagraphy} OR {laminography} OR {narrow angle zonography} OR {planigraphy} OR {planography} OR {planygraphy} OR {polytomography} OR {radiotomography} OR {tomography} OR {transverse section imaging} OR {zonography} OR {positron emission tomography} OR {pet scan} OR {pet scanning} OR {p.e.t.' OR 'positron emission tomographic scan} OR {positron emission tomographic scanning} OR {positron emission tomography} OR {positron tomography} OR {positron-emission tomography} OR {tomography, positron} OR vectorcardiography OR vcg OR {ecg, vector} OR {electrocardiography, vector} OR {polarcardiography} OR {spatial vector cardiogram} OR {spatial vectorcardiogram} OR vectocardiogram OR	2/08/2021	400

	vectocardiography OR {vector cardiogram} OR {vector cardiography} OR {vector ecg} OR {vector electrocardiography} OR {vectorcardiogram} OR vectorcardiography OR vectorelectrocardiography))		
--	--	--	--