

Revisión sistemática de la Literatura

Inteligencia artificial en el diagnóstico imagenológico de las alteraciones cardíacas estructurales: Una revisión sistemática.

Artificial intelligence in the imaging diagnosis of structural cardiac alterations: A systematic review.

Valentina Botía-Arciniegas^{1,a}, Laura Margarita Calvo-Saavedra^{1,a}

1. Estudiante de Medicina.

a. Facultad de Ciencias de la Salud, Pontificia Universidad Javeriana Cali (Colombia).

CORRESPONDENCIA

Valentina Botía Arciniegas

ORCID ID <https://orcid.org/0009-0002-1793-5470>

Pontificia Universidad Javeriana Cali (Colombia)

E-mail: valenbotiaar@javerianacali.edu.co

CONFLICTO DE INTERESES

Las autoras del artículo hacen constar que no existe, de manera directa o indirecta, ningún tipo de conflicto de intereses que pueda poner en peligro la validez de lo comunicado.

RECIBIDO: 29 de mayo de 2024.

ACEPTADO: 14 de diciembre de 2024.

RESUMEN

Introducción: La IA se ha implementado cada vez más en las ciencias biomédicas, con una relevante aplicación en cardiología. Esta revisión tuvo como objetivo determinar si el uso de la IA en técnicas imagenológicas en cardiología mejora el diagnóstico y manejo terapéutico de alteraciones cardíacas estructurales no congénitas. **Materiales y métodos:** La búsqueda se realizó en las bases de datos Pubmed, Scopus y Embase, mediante el uso de las palabras claves y términos MeSH: “Artificial Intelligence”, “Heart Diseases”, “Structural heart diseases”, “Heart Valve Diseases”, “Cardiac Imaging Techniques” y “Machine learning”, que fueron combinados con los conectores booleanos AND y OR. Se incluyeron estudios publicados entre 2004-2024 en idiomas inglés o español, realizados en humanos, sin límite de edad y/o sexo. **Resultados:** En total fueron seleccionados 2,407 artículos, de los cuales fueron escogidos para la revisión sistemática 22, de estos 2 fueron cohortes, 10 ensayos clínicos, 10 estudios transversales. De los modelos de IA, 10 fueron de DL, 10 de ML y 2 no fueron especificados. El rango de edad de los participantes fue de 30-70 años, con mayoría del sexo masculino. Un total de 15 artículos reportaron sensibilidad y especificidad, 7 usaron otras métricas de eficacia y precisión. **Conclusiones:** El apoyo de la IA en técnicas imagenológicas ha logrado una mejora en la detección de alteraciones cardíacas estructurales no congénitas. Sin embargo, los estudios revisados demuestran una aplicación limitada y una eficacia que no alcanza las expectativas previstas.

Palabras clave: Inteligencia artificial, enfermedades cardíacas, técnicas de imagenología cardíaca, aprendizaje automatizado, aprendizaje profundo, cardiología, enfermedades cardíacas estructurales.

ABSTRACT

Introduction: AI has been increasingly implemented in biomedical sciences, particularly in cardiology. This review aims to determine whether the use of AI in imaging techniques improves the diagnosis and therapeutic management of non-congenital structural cardiac alterations. **Materials and methods:** The search was conducted in the PubMed, Scopus, and Embase databases using keywords and MeSH terms, including “Artificial Intelligence”, “Heart Diseases”, “Structural Heart Diseases”, “Heart Valve Diseases”, “Cardiac Imaging Techniques”, and “Machine Learning”. These terms were combined with Boolean connectors AND and OR, resulting in the identification of 2,407 articles. Studies published between 2004 and 2024 in English or Spanish languages, conducted on humans, with no age and/or gender restrictions, were included. **Results:** In total, 2,407 articles were selected, of which 22 were chosen for the systematic review. Among these, 2 were cohorts, 10 were clinical trials, and 10 were cross-sectional studies. Regarding the AI models, 10 were DL, 10 were ML, and 2 were not specified. The age range of the participants was 30-70 years, with a majority being male. A total of 15 articles reported sensitivity and specificity, while 7 used other metrics of efficacy and precision. **Conclusions:** The integration of AI into imaging techniques has led to improvements in the detection of non-congenital structural cardiac alterations. However, the reviewed studies revealed limited application and efficacy that falls short of expectations.

Key words: Artificial intelligence, heart diseases, cardiac imaging techniques, machine learning, deep learning, cardiology, structural heart diseases.

Botía-Arciniegas V, Calvo-Saavedra LM. Inteligencia artificial en el diagnóstico imagenológico de las alteraciones cardíacas estructurales: Una revisión sistemática. *Salutem Scientia Spiritus* 2025; 11(1):36-50.



La Revista *Salutem Scientia Spiritus* usa la licencia Creative Commons de Atribución - No comercial - Sin derivar:

Los textos de la revista son posibles de ser descargados en versión PDF siempre que sea reconocida la autoría y el texto no tenga modificaciones de ningún tipo.

INTRODUCCIÓN

La Inteligencia artificial (IA) es un campo de la ciencia e ingeniería, relacionada con la creación de artefactos y la comprensión del comportamiento inteligente, que permite representar e interpretar mejor datos complejos, sobre todo de tareas clásicamente humano-dependientes,^{1,2} como las realizadas en las ciencias biomédicas. Allí la IA se ha expandido significativamente con el propósito de mejorar la eficacia diagnóstica, terapéutica y de predicción, así como la gestión médica, educativa e investigativa.^{3,4} La IA comprende dos subcampos principales: *Machine Learning* (ML) o aprendizaje automatizado, y *Deep learning* (DL) o aprendizaje profundo; ambos con diferentes elementos, niveles de supervisión y redes implicadas en su diseño, con el propósito de aumentar la complejidad y eficacia de los modelos.⁵ La IA ha evolucionado especialmente en el apoyo de áreas como las técnicas imagenológicas, las cuales permiten la representación gráfica de diferentes tejidos y órganos del cuerpo humano, para la descripción y diagnóstico de alteraciones estructurales y funcionales.⁶

Una de las disciplinas médicas donde la IA, en conjunto con las técnicas imagenológicas, ha presentado importantes desarrollos es la cardiología, facilitando la evolución hacia una medicina cardiovascular de precisión, especialmente en la discriminación de alteraciones cardíacas estructurales frecuentes⁷ como la enfermedad de arterias coronarias (EAC),^{8,9} alteraciones del sistema eléctrico cardíaco,^{10,11} predicción de muerte cardíaca en escenarios concretos,¹² o incluso para la identificación de pacientes con resultados beneficiosos ante diversas terapias o intervenciones, como es la resincronización cardíaca.¹³ Si bien las tecnologías asistidas por computadora facilitan la detección rápida de síntomas clínicos de interés (p. e., benignos y malignos) en función de las características de la imagen (p. e., tono y borde),¹⁴ la tecnología de IA con propósitos médicos no ha sido acogida con entusiasmo por el sector salud o al menos no en una población general.¹ Además, existen pocos estudios prospectivos de aprendizaje profundo y ensayos aleatorios en imágenes médicas,¹⁵ y la interpretación de datos aún parece ser un reto significativo para la IA.¹⁴ Ante una limitada síntesis de la utilización de la IA en el diagnóstico de alteraciones cardíacas estructurales no congénitas en cardiología mediante técnicas imagenológicas clásicas como resonancia magnética (RM), Tomografía computarizada (TC) o Ecocardiografía (ECG),¹⁶ el objetivo de este artículo fue determinar si el uso de la IA en técnicas imagenológicas en cardiología mejora el diagnóstico y con ello, el manejo terapéutico de las alteraciones estructurales cardíacas no congénitas.

MATERIALES Y MÉTODOS

Se realizó una revisión sistemática de la literatura mediante una búsqueda en las bases de datos: Pubmed, Scopus y Embase, me-

dante el uso de las palabras claves y términos MeSH: “*Artificial Intelligence*”, “*Heart Diseases*”, “*Structural heart diseases*”, “*Heart Valve Diseases*”, “*Cardiac Imaging Techniques*” y “*Machine learning*”, que fueron combinados con los conectores booleanos *AND* y *OR*, identificando 2,407 artículos. Se seleccionaron estudios tipo ensayos clínicos, meta-análisis, revisiones sistemáticas y estudios observacionales, publicados entre 2004-2024 en idiomas inglés o español, realizados en humanos, sin límite de edad y/o sexo; y que abordaran el tema de la IA como apoyo para el diagnóstico imagenológico de las alteraciones cardíacas estructurales de *novo*, ya sean del miocardio, de las válvulas cardíacas u otras anomalías relacionadas. Se excluyeron revisiones narrativas, editoriales, artículos en los cuales no fue posible acceder, estudios con enfoque en alteraciones cardíacas estructurales de etiología congénita, o cuyo abordaje no describió la eficacia diagnóstica en una intervención en relación con la sensibilidad; una medida que representa la capacidad para identificar correctamente a las personas con una condición dentro de todas las personas con esta, y la especificidad, entendida como la capacidad de la prueba para identificar correctamente a las personas sin enfermedad dentro de todas las personas libres de esta. Finalmente fueron incluidos en la revisión 22 artículos (Figura 1, Tabla 1).

RESULTADOS Y DISCUSIÓN

Inteligencia artificial y su aplicación en la cardiología

La IA es un campo de la informática con amplia aplicación en el diagnóstico, tratamiento, pronóstico y predicción de muchas condiciones en medicina, mediante el uso de algoritmos autónomos de análisis estadístico con subcampos como el DL y ML, que actúan como un apoyo a las herramientas biomédicas,¹⁶ con el propósito de reducir el error humano en especialidades médicas como la cardiología¹⁷ (Figura 2).

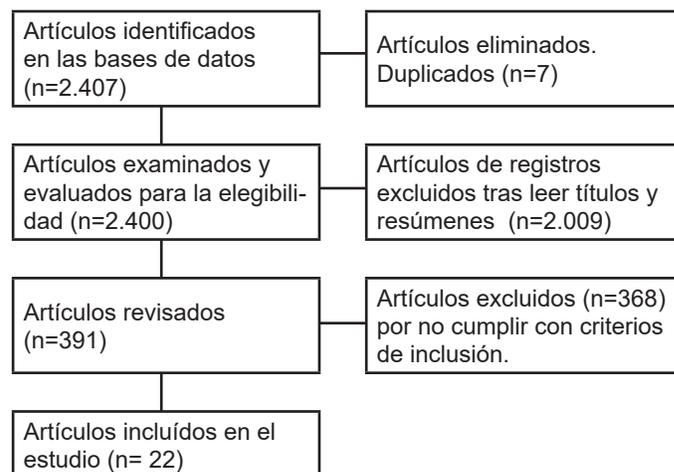


Figura 1. Flujograma de la búsqueda sistematizada.

Tabla 1. Estudios relacionados al uso de IA en el diagnóstico imagenológico de alteraciones cardíacas estructurales no congénitas.

Autor	Tipo de estudio	País	Tamaño de muestra (n=)	Características de la población (edad, sexo, etc.)	Ayuda diagnóstica e IA	Resultados principales
Miocardiopatías						
Cau R, <i>et al</i> (2024).	Estudio transversal, retrospectivo	Italia	107 participantes: 49 pacientes con Miocardiopatía isquémica y 58 pacientes con Miocardiopatía no isquémica. Entrenamiento: 172. Prueba: 1	Edad media: 60± 9. Miocardiopatía isquémica: 34 hombres. Miocardiopatía no isquémica: 38 hombres.	RMN y ML (GB-GAM y Gini <i>Impurity Reduction</i>)	S=72% E=68%
Togo R, <i>et al</i> (2019).	Estudio transversal, retrospectivo	Japón	85 participantes. Entrenamiento: 84 pacientes. Prueba: NR	>20 años. 45 hombres y 40 mujeres.	Tomografía por emisión de positrones con flúor-18-fluorodeoxiglucosa y DL	S=83,9% E=87%
Davies R, <i>et al</i> (2022).	Estudio transversal, multicéntrico, prospectivo.	Reino Unido	1.923 pacientes con múltiples enfermedades (no especificadas). Entrenamiento y prueba: NR	NR	RMC y redes neuronales convolucionales (DL) - (modelo SAX, modelo 2Ch y 4Ch)	Análisis del ML: 20 seg por paciente. Tasa de segmentación errónea: 1 en 479 imágenes.
Salehi M, <i>et al</i> (2024).	Ensayo clínico no aleatorizado, prospectivo.	Reino Unido y Hungría	Entrenamiento: 539 participantes, 611 estudios RMC. Prueba: 462 participantes con 462 estudios RMC.	En este estudio también se incluyeron patologías congénitas como la Tetralogía de Fallot. Hombres: 62% Edad media 57 años	RMC e IA	Contornos automatizados en <90s.
Corianò M, <i>et al</i> (2024)	Estudio cohorte.	Italia	154 participantes. Entrenamiento: 108 participantes. Prueba: 46 participantes.	Hombres: 108 Mujeres: 46 Edad: 38-58 años Peso: 79kg	RMC y DP (DARP-D)	DARP-D logró un IC 95% en los índices de concordancia de Harrell (c-index) de 0,12 - 0,68.
Lin X, <i>et al</i> (2022)	Ensayo clínico no aleatorizado, prospectivo.	China	6.953 exámenes Entrenamiento: 2.274. Prueba interna: 1.868 participantes. Prueba externa: 2.811 participantes	NR	ECG y DL (Xception Net neural network model).	S=85,4% versus 85,2% y una E=83,2% versus 78,2% equipos estándar versus de cabecera. Conjunto de datos de la prueba externa: S=81,6% estándar versus 78,3% cabecera y E=83,7% estándar versus 78,1% cabecera.
Barbieri A, <i>et al</i> (2023)	Estudio transversal, retrospectivo	Italia	1.349 participantes. Entrenamiento y prueba: NR	Edad: mediana de 49 años.	ECG y ML	Diferencia entre adultos sanos y miocardiopatía hipertrófica: S=75,9%, E=77,8% y AUC=0.814. Diferencia entre adultos sanos y amiloidosis cardíaca: S=87%, E=100% y AUC=0,959

Tabla 1. Estudios relacionados al uso de IA en el diagnóstico imagenológico de alteraciones cardíacas estructurales no congénitas (Continuación).

Autor	Tipo de estudio	País	Tamaño de muestra (n=)	Características de la población (edad, sexo, etc.)	Ayuda diagnóstica e IA	Resultados principales
Miocardiopatías						
Tabassian, <i>et al</i> (2018)	Estudio transversal, prospectivo.	Reino Unido e Italia	100 participantes: Entrenamiento: 64 participantes. Prueba: 16 participantes.	43 hombres y 57 mujeres con edad de 69 ± 7 años.	ECG y ML	S= 86% E= 82%
Spielvogel C, <i>et al</i> (2024)	Estudio transversal, retrospectivo, internacional	Austria, Reino Unido, China e Italia	16.241 pacientes 19.401 exploraciones. Entrenamiento y prueba: NR.	Edad media: 62,6 años (DE 16). Mujeres: 9.493 (58%). Hombres: 6.748	Gammagrafía e IA	Cohorte Austriaca: S=95,8% E=99,9%
Valvulopatías						
Chandra V, <i>et al</i> (2020)	Estudio transversal, controlado, retrospectivo.	India	40 videos. 2.400 imágenes: 1.800 para entrenamiento. 600 de prueba	Pacientes sin enfermedad de base o con enfermedad reumática cardíaca. 16-65 años. India. NR sexo biológico.	ECG y DL (<i>Yolo3</i> y <i>MobileNet</i>)	Precisión del 98% mAP de 88,4
Lang RM, <i>et al</i> (2021)	Estudio transversal, controlado, retrospectivo.	Alemania y Estados Unidos	2.000 sujetos: 1.800 de entrenamiento y 200 de prueba.	NR	ECG y ML.	Variabilidad interobservador de interpretación asistida por ML de 3 ± 16. Interpretación automatizada de ML vs interpretación convencional de 14 ± 11. Precisión: 90% para imágenes bidimensionales. 94% para las imágenes Doppler.
Enfermedad de arterias coronarias.						
Upton R, <i>et al</i> (2022)	Estudio Transversal, controlado retrospectivo.	Reino Unido	Entrenamiento: 578 participantes 154 de prueba	Entrenamiento: Edad: 64,5 ± 11,5 IMC: 29,9 ± 6,2 54,3% hombres Prueba: Edad: 61,0 ± 10,7 IMC: 30,1 ± 7,9 50% hombres	ECG tipo estrés y ML.	E= 85,7% (95% CI: 82,7%-88,9%) S= 86,7% (95% CI: 80,2%-94.3%)
Guo Y, <i>et al</i> (2023)	Ensayo clínico aleatorio controlado.	China	818 participantes (80% de entrenamiento y 20% de prueba). Validación: 115 participantes	Pacientes con sospecha de EAC. Edad media: 64,1 ± 9,7 años. Sexo: 515 hombres y 303 mujeres.	ECG y ML	S= 95,2% E=69,1%.
Kuo HC, <i>et al</i> (2023)	Estudio transversal, retrospectivo.	Taiwán	1283 imágenes. (70% para entrenamiento, 20% para validación y 10% para probar el modelo).	Niños con diagnóstico de Enfermedad de Kawasaki. NR edad ni otros datos.	ECG y DL	Scaled-YOLOv4-HarDNet: mAP de 72,63%. Scaled-YOLOv4: mAP 70,05%. YOLOv5: mAP 69,79%

Tabla 1. Estudios relacionados al uso de IA en el diagnóstico imagenológico de alteraciones cardíacas estructurales no congénitas (continuación).

Autor	Tipo de estudio	País	Tamaño de muestra (n=)	Características de la población (edad, sexo, etc.)	Ayuda diagnóstica e IA	Resultados principales
Enfermedad de arterias coronarias.						
Laumer F, <i>et al</i> (2022)	Estudio de Cohorte. Retrospectivo.	Suiza	448 pacientes. Entrenamiento: 228 (50% de cada patología) Prueba: 220 (50% de cada patología)	Síndrome de Takot-subo: Edad media: 68,4 años. 90,4% mujeres Infarto agudo al miocardio: Edad media: 69,1 años. 90,4% mujeres.	ECG y DL	Precisión general del modelo: 74,8% Precisión general de los Cardiólogos: 64,4%
Stuckey D, <i>et al</i> (2018)	Ensayo clínico aleatorio controlado, multicéntrico, prospectivo.	Estados Unidos	606 participantes. Entrenamiento: 339. Prueba: 117 más Verificación: 94	40% mujeres >21 años.	Tomografía espacial de fase cardíaca y ML	S= 92% IC 95%: 74-100% E= 62% IC 95%: 51-74%
Dey D, <i>et al</i> (2018)	Ensayo clínico multicéntrico.	Dinamarca y Estados Unidos	254 participantes. NR grupo entrenamiento ni prueba.	Edad media: 64 años (31-84 años) . 64% hombres, IMC 26 ± 3 kg/m2	Angiografía con TC y ML.	S= 73% E= 80%.
Tang CX, <i>et al</i> (2019)	Ensayo clínico, aleatorio controlado, multicéntrico, retrospectivo.	China	183 vasos de 136 pacientes. NR grupo entrenamiento ni prueba.	Edad media: 60,6 ± 8,6 años 73,5% de hombres	Angiografía con TC derivada de la medición de la reserva de flujo fraccional y ML. vs CTA coronaria.	Por persona: CT-FFR - ML S= 86%, E=92% PPV=90% CTA coronaria: S= 95%, E=33% , PPV=56% Por vaso: CT-FFR - ML S= 84%, E=94% , PPV=90% CTA coronaria: S= 95%, E=28% , PPV=47%
Lipkin I, <i>et al</i> (2022)	Estudio retrospectivo basado en los datos del Ensayo clínico CREDESCENCE.	Estados Unidos	301 participantes NR grupo entrenamiento ni prueba.	Edad media: 64,4 ± DS 10.2SD. 88 mujeres 213 hombres	Angiografía con TC y DL vs imagen de perfusión miocárdica	IA-CTQ (Estenosis >50%) S= 95%, E= 63%, PPV=75% (Estenosis >75%) S= 95%, E= 81%, PPV=67% IPM, (Estenosis >50%) S= 74%, E= 43%, PPV=61% (Estenosis >75%) S= 91%, E= 44%, PPV=39%
Cho H, <i>et al</i> (2021)	Ensayo clínico aleatorizado controlado, retrospectivo.	Corea del Sur	598 pacientes con 137.989 imágenes. Entrenamiento: 498 pacientes; 113.746 ecografías. Prueba: 100 pacientes; 24.243 ecografías.	Edad media: 62,6 ± 9,8 años Hombres: 71% Mujeres: 29%	Ecografía coronaria y DL	S= 85% ± 7 E= 94% ± 2 PPV 82% ± 5 Precisión: 98%

Tabla 1. Estudios relacionados al uso de IA en el diagnóstico imagenológico de alteraciones cardíacas estructurales no congénitas (continuación).

Autor	Tipo de estudio	País	Tamaño de muestra (n=)	Características de la población (edad, sexo, etc.)	Ayuda diagnóstica e IA	Resultados principales
Enfermedad de arterias coronarias.						
Li Y, <i>et al</i> (2019)	Ensayo clínico aleatorizado controlado, comparativo, prospectivo.	China	86 participantes. NR grupo entrenamiento ni prueba.	Pacientes con angina estable o síntomas equivalentes sin infarto agudo al miocardio previo. Edad media: 67±12 años. 67 hombres.	Imagen de perfusión miocárdica y CT vs Angiografía con TC derivada de la medición de la reserva de flujo fraccional y ML (cFFR, version 3.0; <i>Siemens Healthineers</i>).	Por vaso arterial: TC dinámica con imagen de perfusión miocárdica. S= 81%, E= 63%, PPV= 67% Precisión=72%. TC derivada de la medición de la reserva de flujo fraccional con ML S= 88%, E= 68%, PPV= 72% Precisión=79%. Por paciente: TC dinámica con imagen de perfusión miocárdica. S= 94%, E= 61%, PPV= 79% Precisión= 81%. TC derivada de la medición de la reserva de flujo fraccional con ML S= 77%, E= 94%, PPV= 95% Precisión=84%
D'Ancona, <i>et al</i> (2023)	Ensayo clínico aleatorizado controlado, retrospectivo.	Italia	7.728 participantes Entrenamiento: 70%; 5454. Ajuste del modelo: 10%; 773. Prueba: 20%; 1501.	Edad media: 74±12 años. Hombres: 5.429 (70.3 %) IMC: 26±4	Radiografía y DL.	DL solo: S=90% E=32% DL + Score de Diamond Forrester. S=90% E=35%

NR: No reporta, DL: deep learning, ML: machine learning, S: sensibilidad, E: especificidad. RMC: resonancia magnética cardiovascular. RMN: resonancia magnética. ECG: ecocardiograma. TC: tomografía computarizada.

Machine learning/aprendizaje automatizado:

El ML en cardiología y así como en otras especialidades, desarrolla modelos basados en training data, es decir, datos que entrenan algoritmos para la clasificación y predicción de resultados de interés,¹⁷ con subtipos como ML supervisado, no supervisado y reforzado. La aplicación de ML en la salud cardiovascular abarca condiciones como enfermedades de las arterias coronarias (32,09%), seguida de insuficiencia cardíaca (19,07%) y trastornos eléctricos del corazón (9,3%); siendo el resto de condiciones el 39,75%, según los reportes de literatura científica hasta el año 2020.¹⁶ También, el ML se ha utilizado con propósitos específicos en la electrofisiología cardíaca con el diagnóstico y la predicción de arritmias,^{18,19} en eventos cardiovasculares *de novo* o exacer-

bación,^{20,21} en respuesta a terapias como la resincronización cardíaca,^{13,22} el abordaje en trasplante de corazón,²³ entre otros.

Deep learning (DL)/aprendizaje profundo:

El concepto de redes neuronales artificiales (ANN) fue propuesto como un modelo matemático de una neurona artificial en 1943 mientras que, en el 2006 se introdujo el concepto de DL como un modelo ANN que tiene mayor capacidad de aprendizaje.²⁴

En los últimos años, los modelos DL en medicina se han utilizado en el análisis de imágenes médicas mediante la detección de anomalías, prognosis, diagnóstico, clasificación, tratamiento y manejo clínico de enfermedades,²⁴⁻²⁶ como señala Panjiyar BK

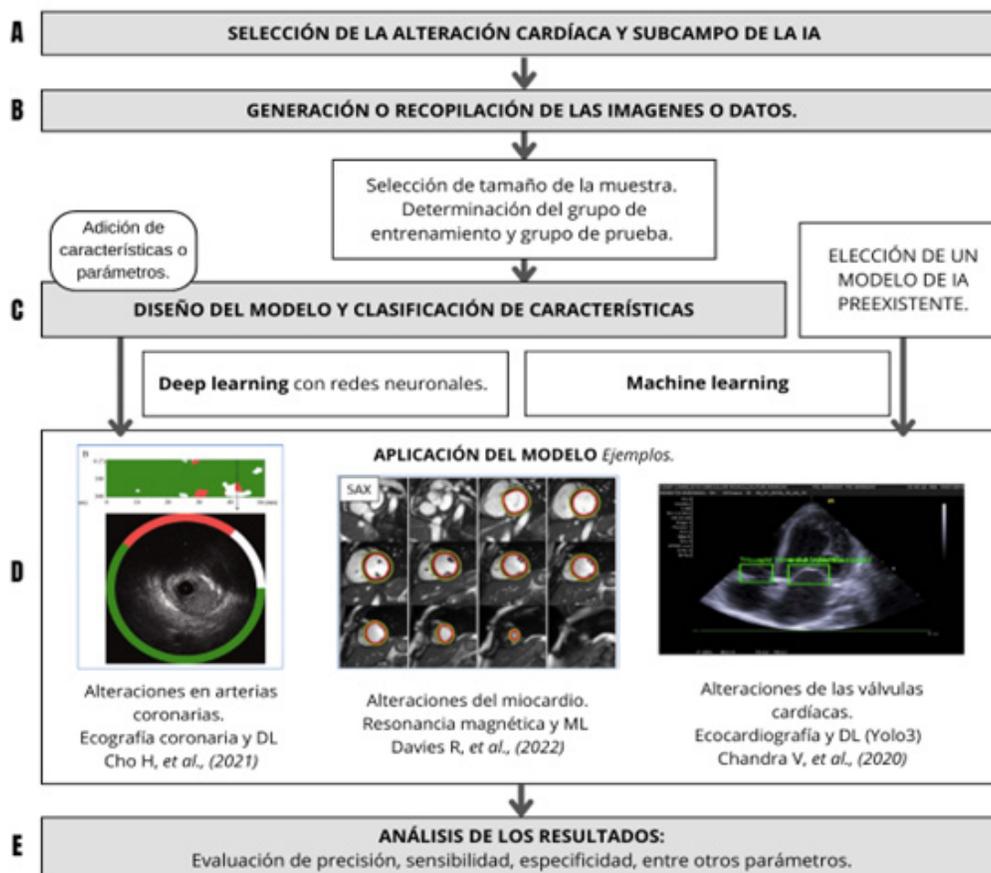


Figura 2. Pasos para el desarrollo de modelos de IA para imagenología cardíaca A. Selección de la alteración cardíaca a estudiar y del subcampo de la IA, además de otros aspectos de diseño propios de cualquier investigación original, así como los criterios de inclusión y exclusión de la muestra. B. Generación o recopilación de las imágenes o datos para la posterior determinación de la muestra, la cual usualmente se dividirá en los grupos de participantes o datos que serán sometidos para entrenar y/o probarlo en el algoritmo. Las imágenes pueden ser evaluadas por expertos (con n= variable), cuya interpretación podría utilizarse como referencia o comparación de la precisión del modelo. C. Diseño del modelo o elección de uno preexistente. Está la posibilidad de adicionar parámetros que apoyen el alcance de los objetivos propios del estudio. El diseño varía según el subcampo de la IA: Deep Learning con redes neuronales como la red neuronal convolucional profunda, y el Machine learning. D. Aplicación del modelo usando el grupo de datos y poniendo en práctica los diferentes parámetros de interés. Aquí se plantean tres ejemplos de aplicaciones de modelos sobre diferentes alteraciones cardíacas.^{29,38,51} E. Análisis de los resultados, se evalúan métricas como sensibilidad, especificidad, mAP, precisión diagnóstica, etc., del modelo, con posibilidad de comparación con la interpretación humana u otros algoritmos de IA. IA: Inteligencia artificial, mAP: Mean Average Precision.

et al,²⁷ cuya investigación destaca el uso de DL para prevenir, estratificar el riesgo y tratar eficazmente a los pacientes con EAC.

Soporte de la IA en la imagenología cardíaca en anomalías estructurales y su eficacia diagnóstica: Aplicación diagnóstica en alteraciones del miocardio

Las enfermedades cardiovasculares son la causa de mortalidad más importante a nivel mundial (17,9 millones de casos/año), dentro de las principales se encuentran las alteraciones del mio-

cardio, también llamadas miocardiopatías; cuya prevalencia en el 2019 fue de 3,73 millones de casos globalmente.^{28,29} Por esta razón, la IA se ha utilizado extensivamente en la interpretación de técnicas imagenológicas y datos de los pacientes, para la detección de miocardiopatías.³⁰

Resonancia magnética (RM):

La RM es el gold standard para la obtención de imágenes cardíacas debido a su excelente contraste de tejidos blandos, fina resolución espacial y capacidad para reconocer el miocardio desde la

observación y segmentación, realizar seguimiento del movimiento cardíaco local, cuantificar y reportar parámetros funcionales clínicamente relevantes; como el volumen ventricular derecho e izquierdo, la fracción de eyección, el espesor de la pared del miocardio y la masa.³¹

Davies RH *et al*,³² desarrollaron un algoritmo de ML capaz de analizar volumétricamente la RM cardiovascular (RMC) con una mayor precisión que los médicos. El algoritmo de ML fue entrenado con 1.923 exploraciones y usado para segmentar el volumen sanguíneo del ventrículo izquierdo y del miocardio. El rendimiento se cuantificó midiendo la precisión de un conjunto de datos con múltiples localizaciones y patologías de 109 pacientes escaneados dos veces. Además, se adicionaron 1.277 pacientes que fueron escaneados rutinariamente en la atención clínica de rutina, mejorando la capacidad de generalización del modelo de ML al identificar errores en la segmentación. Los resultados fueron comparados con tres médicos y una herramienta comercial (cvi42), concluyendo que el análisis del ML fue más rápido (20 segundos por paciente) que el humano (13 minutos por paciente) y la tasa de segmentación errónea fue de uno en 479 imágenes, en patologías que no fueron añadidas en el entrenamiento. Este estudio no reportó las medidas de sensibilidad o especificidad.

En un estudio retrospectivo realizado por Cau R *et al*,³³ se utilizó el modelo GB-GAM de ML con el objetivo de diferenciar la miocardiopatía isquémica de la miocardiopatía no isquémica mediante el uso de RMC sin contraste. En este estudio participaron 107 pacientes, 49 participantes con miocardiopatía isquémica y previo diagnóstico de etiología isquémica como consecuencia de una estenosis $\geq 50\%$, antecedente de infarto agudo al miocardio o revascularización. En total 58 participantes fueron clasificados con miocardiopatía no isquémica con presencia de disfunción del ventrículo izquierdo (fracción de eyección $< 50\%$) y ausencia de antecedente de infarto agudo al miocardio o arteriografía coronaria con estenosis obstructiva. El modelo GB-GAM alcanzó una precisión diagnóstica competitiva (AUC=0,82) con una sensibilidad de 72% y una especificidad de 68%, al discriminar entre miocardiopatía isquémica y miocardiopatía no isquémica.

Salehi M *et al*,³⁴ estudiaron la utilidad clínica de la IA para medir volúmenes cardíacos con RMC. El estudio incluyó 462 pacientes, con una RMC por paciente, la edad media de los pacientes fue 57 años; con los siguientes criterios de inclusión: enfermedad estructural conocida, paciente sintomático con evaluación de función cardíaca, falla cardíaca y enfermedad vascular. Las imágenes de RMC de eje corto fueron segmentadas individualmente de manera manual y por la IA, para obtener el volumen, la masa y medidas de fracción de eyección para ambos ventrículos. Se concluyó que no hubo diferencias significativas entre medidas manuales con medidas automatizadas ($p > 0,05$) y los contornos automatizados se evaluaron visualmente en 251 casos con acuerdo o desacuerdo

menor en 229 casos (91,2%), con segmentación fallida en un caso (0,4%). Por otro lado, la herramienta de IA proporcionó contornos automatizados en < 90 segundos, y el análisis *Bland-Altman* y el coeficiente de correlación intraclase demostró una excelente concordancia en las medidas. Este estudio no reportó sensibilidad o especificidad.

Coriano M *et al*,³⁵ realizaron un estudio cuya finalidad era rastrear y predecir la curva de riesgo que tenían los pacientes para desarrollar eventos arrítmicos mayores, para esto, utilizaron datos recolectados de RMC y construyeron un algoritmo de DL denominado DARP-D, cuyo rendimiento fue evaluado con el índice de concordancia de Harrell (*c-index*). La muestra fue de 154 participantes con disminución en la función sistólica de la fracción de eyección del ventrículo izquierdo ($< 50\%$), ausencia de EAC con limitación del flujo y ausencia de hipertensión. Dentro de los resultados, DARP-D alcanzó en los índices de concordancia de Harrell (*c-index*) un IC del 95% de 0,12 - 0,68 demostrando ser capaz de predecir el riesgo de eventos arrítmicos en cardiomiopatía dilatada, al analizar el movimiento cardíaco, las características del tejido y las variables iniciales. Sin embargo, se requieren más investigaciones para mejorar, estabilizar y validar el rendimiento de DARP-D para su uso diario.

Tomografía computarizada (TC):

Desde su introducción en 1970 la TC ha sido un pilar de las ayudas imagenológicas, facilitando la visualización y reconstrucción de la anatomía, permitiendo la identificación y cuantificación de procesos patológicos.³¹

Togo R *et al*,³⁶ realizaron un estudio para determinar si las características de *deep convolutional neural network* (DCNN) podían identificar las diferencias entre sarcoidosis cardíaca y la sarcoidosis no cardíaca a partir de los mapas polares de TC por emisión de positrones con F18-fluorodesoxiglucosa. Para esto desarrollaron un algoritmo denominado *ReliefF*, utilizando una muestra de 85 pacientes (33 pacientes con sarcoidosis cardíaca y 52 con sarcoidosis no cardíaca), mayores de 20 años y sin consumo cardíaco. El algoritmo *ReliefF* alcanzó una sensibilidad del 83,9% y una especificidad de 87%, con una media armónica de 85,4%. El 78,8% de los pacientes con sarcoidosis cardíaca fueron correctamente clasificados y el 90% de los pacientes con sarcoidosis no cardíaca fueron correctamente clasificados. En contraste, al no utilizar el algoritmo *ReliefF*, sino el valor de captación estandarizado y el coeficiente de varianza, la sensibilidad, especificidad y media armónica fueron menores: 80%, 83,6% y 81,8% respectivamente.

Ecocardiografía:

Lin X *et al*,³⁷ llevaron a cabo un estudio cuyo principal objetivo fue comparar el rendimiento de un sistema DL para la detección automática de anomalías regionales en el movimiento de la pared

cardíaca en pacientes con sospecha de infarto agudo al miocardio por medio de ecocardiogramas de cabecera versus el equipamiento estándar. Para el entrenamiento del modelo se recopilieron 6.953 exámenes con los siguientes criterios de inclusión: diagnóstico de hipertensión arterial, hiperlipidemia, diabetes, insuficiencia renal y antecedente de accidente cerebrovascular. En el procesamiento de datos se utilizó el algoritmo de DL denominado *Xception Net neural network* con la finalidad de reconocer las tres vistas apicales del corazón, segmentar el ventrículo izquierdo, medir el tamaño de las cámaras cardíacas y determinar la fracción de eyección del ventrículo izquierdo. Finalmente, el modelo aplicó las tres vistas apicales con una exactitud del 90%, promedio Dice 0,89 y el índice de Youden mostró una sensibilidad de 85,4% versus 85,2% y una especificidad de 83,2% versus 78,2% para equipos estándar versus de cabecera. El conjunto de datos de la prueba interna detectó anomalías regionales del movimiento de la pared con AUC de 0,91 (estándar) y 0,88 (ultrasonido de cabecera). En el conjunto de datos de la prueba externa el AUC fue de 0,90 (estándar) y 0,85 (ultrasonido de cabecera) con sensibilidad de 81,6% versus 78,3% y una especificidad de 83,7% versus 78,1% respectivamente. Además, las mediciones automáticas de la función cardíaca coincidieron con los valores del informe ecocardiográfico.

Barbieri A *et al*,³⁸ desarrollaron un estudio que evaluó la fracción de contracción miocárdica (MCF) utilizando medidas de la cámara del ventrículo izquierdo basadas en ML, y de manera tridimensional automatizada, con el propósito de discriminar diferentes fenotipos hipertróficos del ventrículo izquierdo. El modelo de ML fue denominado DHM (modelo dinámico del corazón) y la muestra fue de 1.349 participantes divididos en 4 grupos: pacientes sanos, pacientes con hipertensión aislada, pacientes con miocardiopatía hipertrófica y pacientes con amiloidosis cardíaca. Se incluyeron participantes ≥ 18 años con evaluación ecocardiográfica 2D y 3D completa en reposo, y FE $\geq 50\%$. Al compararse con los controles, los valores media de la fracción de contracción miocárdica redujeron de manera significativa en sujetos con miocardiopatía hipertrófica (48,55%) y amiloidosis cardíaca (40,92%) pero no en hipertensión aislada (59,35%). Además, la fracción de contracción miocárdica mostró una correlación baja con la fracción de eyección en la cohorte general ($R^2=0,136$) y los cuatro grupos de estudio (sanos $R^2=0,039$; hipertensión aislada $R^2=0,089$; miocardiopatía hipertrófica $R^2=0,225$; amiloidosis cardíaca $R^2=0,102$). La curva ROC mostró que la fracción de contracción miocárdica lograba diferenciar entre adultos sanos y miocardiopatía hipertrófica (sensibilidad de 75,9%, especificidad de 77,8% y un AUC de 0,814) con adultos sanos y amiloidosis cardíaca (sensibilidad de 87%, especificidad de 100% y AUC de 0,959).

Tabassian M *et al*,³⁹ realizaron un estudio cuyo objetivo era investigar durante el ciclo cardíaco en reposo y estrés, si el análisis exhaustivo de la sincronización, amplitud del movimiento y defor-

mación del miocardio del eje largo del ventrículo izquierdo, lograba proporcionar criterios con mayor información para cuantificar la reserva funcional del ventrículo izquierdo, en comparación con las mediciones estándar. Se utilizó un algoritmo de ML entrenado con características STRE (*spatiotemporal-rest-exercise*) que evaluó la tasa de velocidad, deformación y tasa de deformación de 18 segmentos del ventrículo izquierdo, por medio de imágenes ecocardiográficas de velocidad del miocardio en reposo y durante el ejercicio. Se reclutaron 100 participantes con edad de 69 ± 7 años y se distribuyeron en cuatro grupos: sujetos con falla cardíaca con fracción de eyección preservada, función sistólica global del ventrículo izquierdo conservada y disfunción diastólica del ventrículo izquierdo; sujetos control sin aliento, sujetos control y sujetos control con hipertensión asintomática. Finalmente, los parámetros de velocidad de deformación aprendidos por el modelo de IA generaron mayor precisión para asignar los sujetos en los cuatro grupos (un 57% en general y 81% en falla cardíaca con fracción de eyección preservada) y en dos clases (asintomáticos versus sintomáticos) con AUC 0,89; precisión 85%, sensibilidad 86% y especificidad 82%.

Gammagrafía:

Spielvogel C *et al*,⁴⁰ desarrollaron un sistema de IA para la detección de captación sugestiva de amiloidosis cardíaca con el objetivo de evaluar su valor pronóstico, utilizando una base de datos multinacional de Gammagrafía con 99Tc. Fueron incluidos 16.241 pacientes con una edad media de 62,6 años originarios de Austria, Reino Unido, China e Italia. Se incluyeron todos los pacientes que tuvieran gammagrafía con 99Tc. En los resultados se encontró que la cohorte Austriaca tuvo un AUC de 1,000 (intervalo de confianza 95% 0,924-0,967), exactitud de 99,9%, sensibilidad de 95,8%, especificidad de 99,9%, valor de predicción positivo de 0,951 y valor de predicción negativo de 0,999. Los registros de Reino Unido e Italia consiguieron un AUC de 0,997 (0,993 - 0,999) y 1,000 (0,999 - 1,000) respectivamente, seguido de China con AUC de 0,925 (0,871 - 0,971). Además, cinco médicos estuvieron en desacuerdo con los resultados en 22 casos de 200 (*Fleiss' Kappa* 0,89) con AUC medio de 0,946 (IC 95% 0,924 - 0,967) que fue inferior a IA (AUC 0,997 [0,991 - 1,000], $p=0,0040$). En general, las predicciones de la IA fueron pronósticos independientes de la mortalidad general con un Hazard Ratio ajustado de 144 (intervalo de confianza 95% 1,19-1,74) y $p<0,0001$.

Aplicación diagnóstica en valvulopatías

Las enfermedades valvulares del corazón (EVC) o valvulopatías representan tan solo el 2,78% de las alteraciones cardíacas abordadas con IA en la literatura biomédica hasta el 2021,¹⁶ lo que dificultó su búsqueda en comparación con otros tipos de alteraciones.

Chandra V *et al*,⁴¹ mediante los algoritmos de DL llamados

Yolo3 y *MobileNet* buscaron reducir la subjetividad y mejorar el diagnóstico ecocardiográfico de alteraciones de la válvula mitral. En su estudio se incluyeron pacientes sin patología de base o que tuvieran enfermedad reumática cardíaca, entre los 16 a 65 años; de los que se recolectaron 40 vídeos, con un total de 2.400 imágenes, de las cuales 1.800 fueron para entrenamiento del modelo y 600 para prueba. También, la interpretación propuesta por el algoritmo fue comparada con notas de ecocardiografistas experimentados. Se encontró que el modelo localizó las valvas de interés con una precisión del 98% y un mAP (*Mean Average Precision* o Precisión media promedio) de 88,4. Sin embargo, este estudio no reportó sensibilidad ni especificidad, sino métricas como mAP que evalúan la precisión de modelos de detección de objetos como *Yolo3* y *MobileNet*.⁴² Según los resultados, el modelo propuesto alcanzó una alta precisión y rapidez en la identificación de las valvas alteradas.

Lang RM *et al*,⁴³ desarrollaron un algoritmo de tres protocolos para la clasificación de imágenes de ECG en 2.000 sujetos (1.800 de entrenamiento y 200 de prueba), para la identificación de 16 parámetros en toda la imagen cardíaca, entre ellos alteraciones de la válvula mitral. Los datos fueron revisados por un ecocardiografista experimentado. En la identificación de las alteraciones en esta válvula, obtuvieron una variabilidad interobservador de la interpretación asistida por ML de 3 ± 16 e interpretación automatizada por ML vs interpretación convencional de 14 ± 11 . También alcanzaron una precisión del 90% para las imágenes bidimensionales y del 94% para las imágenes Doppler, ambos de manera general en la imagen cardíaca. Sin embargo, la precisión sobre los datos individuales de parámetros como las EVC no fueron discriminados, lo que dificultó la comprensión del impacto del ML sobre el diagnóstico de alteraciones más específicas. Adicionalmente, no se reportó especificidad ni sensibilidad del modelo, en cambio la métrica consistió en medir la precisión general diferenciada en la asistencia o no del modelo de ML.

Aplicación diagnóstica en enfermedades de arterias coronarias

Las enfermedades de las arterias coronarias (EAC) son alteraciones cardíacas estructurales caracterizadas tanto por su alta morbimortalidad a nivel mundial, como por ser objeto mayoritariamente de aplicación en los modelos de IA, con un 32,09% según la literatura hasta 2021.¹⁶ Las ayudas diagnósticas imagenológicas que se usan para su estudio son múltiples, como se expone a continuación.

Ecocardiografía:

Upton R *et al*,⁴⁴ evaluaron la utilidad del ML en la interpretación ECG en EAC por medio de una serie de imágenes de ECG tipo estrés obtenidas del estudio EVAREST. El modelo se entrenó con datos de 578 pacientes y 154 de prueba; las interpretaciones

soportadas por ML fueron evaluadas por cuatro ecocardiografistas con al menos dos años de experiencia y con alrededor de 350 lecturas de ECG tipo estrés por año. Reportaron que el modelo tuvo especificidad de 85,7% (IC 95%: 82,7 - 88,9%) y sensibilidad de 86,7% (95% CI: 80,2 - 94,3%), con un aumento del 10% en el número de lecturas seguras y un decrecimiento del 29% de las lecturas no seguras a diferencia de las interpretaciones no asistidas con IA.

Guo Y *et al*,⁴⁵ en un estudio prospectivo analizaron los resultados ecocardiográficos previos a la angiografía coronaria para la confirmación de EAC. Se incluyeron 818 pacientes, 80% del grupo de entrenamiento y el resto de prueba; y se adicionaron 115 pacientes para la validación del modelo. Además, el algoritmo fue optimizado con el establecimiento de 59 características ecocardiográficas. El modelo obtuvo una sensibilidad del 95,2%, con una especificidad de 69,1%, lo que supuso un riesgo de falsos positivos con mayor ocurrencia de eventos cardiovasculares en este grupo (21,6%) a diferencia de otros, como los verdaderos positivos (19,7%).

Kuo HC *et al*,⁴⁶ realizaron un estudio usando ECG en apoyo de *Scaled-YOLOv4-HarDNet*, un modelo de DL para la identificación de alteraciones de las arterias coronarias en pacientes con enfermedad de Kawasaki, debido al riesgo elevado de muerte por infarto agudo al miocardio en esta población. Se incluyeron 1.283 imágenes, en cuya revisión inicial por ecocardiografistas pediátricos se halló brillo ("*Brightness*" como criterio de Enfermedad de Kawasaki incompleto) en 295 de las imágenes y, dilatación en 475, ambas en la arteria coronaria izquierda. Mientras en la coronaria derecha se hallaron 174 con brillo y 242 con dilatación. El 70% de las imágenes se usaron para entrenamiento y 20% para validación, el resto se usó para probar el desempeño del modelo, el cual obtuvo un mAP de 72,63%. *Scaled-YOLOv4-HarDNet* fue comparado con otros algoritmos como *Scaled-YOLOv4* (mAP 70,05%) y *YOLOv5* (mAP 69,79%), mostrando superior precisión diagnóstica. Los autores resaltaron la capacidad del modelo para identificar lesiones pequeñas en las arterias como dilataciones, brillo u otros cambios que no fueron fácilmente detectables por otros modelos como *Scaled-YOLOv4*, *YOLOv5* o por el ecocardiografista.

Laumer F *et al*,⁴⁷ evaluaron el uso de DL y ECG para diferenciar entre el Síndrome de Takotsubo y el infarto agudo al miocardio. Se usaron imágenes de ECG apicales de dos y cuatro cámaras, también revisadas por un comité de cardiólogos. Se incluyeron 448 pacientes, 228 para entrenamiento del modelo; y 220 participantes como datos independientes para evaluar el algoritmo; cada uno de los grupos con 50% para cada condición. Los participantes con Síndrome de Takotsubo tuvieron una edad media de 68,4 años, el 90,4% eran mujeres, mientras aquellos con infarto agudo al miocardio tuvieron una edad media de 69,1 años e igualmente,

con un 90,4% de mujeres. El enfoque logró una precisión general del 74,8% en la diferenciación entre el síndrome de Takotsubo y el infarto agudo al miocardio, con valores superiores al de los cardiólogos, quienes lograron una precisión del 64,4%.

Actualmente está siendo desarrollado el proyecto PROTEUS⁴⁸ propuesto en el 2021. Este es un estudio multicéntrico, aleatorizado de alrededor de 2.500 participantes para evaluar el uso de *Echo-Go Pro*, un algoritmo de ML y ECG en la identificación de EAC severa. Este proyecto empezó su reclutamiento de participantes en septiembre del 2021 y según su protocolo de investigación, debió terminar en diciembre del 2023. Sin embargo, para la fecha actual de abril del 2024, no han sido publicados sus resultados.

Tomografía computarizada (TC):

Stuckey T *et al*,⁴⁹ quienes realizaron un estudio prospectivo usando TC espacial de fase cardíaca y ML en 606 pacientes sin patología cardíaca conocida, remitidos por dolor de pecho a angiografía coronaria no urgente, desarrollaron un algoritmo utilizando señales de fase pareadas de 512 datos de resultados clínicos (339 de entrenamiento y 117 de validación), y 94 participantes para verificación. Se realizó una comparación de este modelo con los resultados de angiografía coronaria, donde el 30% tuvo lesiones obstructivas. El modelo logró una sensibilidad del 92% (IC 95%: 74-100 %) y una especificidad del 62% (IC 95%: 51-74%). Por consiguiente, el modelo logró una mejoría sustancial en la identificación de EAC a diferencia ECG tipo estrés sin IA.

Dey D *et al*,⁵⁰ estudiaron la detección de lesiones coronarias y riesgo de isquemia usando una puntuación mediada por ML. Un modelo aplicado en 254 participantes con sospecha de EAC estable, que se sometieron a angiografía por TC con medición de la reserva de flujo fraccional. Las imágenes fueron evaluadas por dos lectores con experiencia, cuya especialidad no fue especificada. Se consideraron factores como volumen total, longitud, calcificación, entre otras características de la placa de ateroma y de la estenosis de las arterias. Se encontró que el 31% de los pacientes que habían presentado lesión coronaria también presentaron isquemia, con una área bajo la curva más alta implementando el ML, en comparación con una medición estándar solo visual. El modelo de ML mejoró la comprensión de la magnitud hemodinámica de las lesiones con una sensibilidad del 73% y especificidad del 80%.

Tang C *et al*,⁵¹ en un estudio multicéntrico retrospectivo evaluaron el rendimiento de la angiografía con TC derivada de la medición de la reserva de flujo fraccional asistida por ML en pacientes con EAC. Se incluyeron 183 arterias de 136 pacientes que fueron sometidos a angiografía con TC, con una edad media de 60,6 ± 8,6 años y una población de 73,5% de hombres. Se desarrolló un prototipo de ML en conjunto con datos de angiografía con TC de rutina, el cual fue entrenado para la identificación de los valores de la reserva de flujo fraccional y la extracción de las ca-

racterísticas cuantitativas de la anatomía coronaria. No obstante, no se indicó la cantidad de datos usados para el entrenamiento y prueba del modelo, u otras características acerca de este proceso. La gravedad de las lesiones identificadas en las arterias coronarias fueron estrechamiento de la luz del vaso arterial en un 20-90%, alrededor de 12 vasos (8.8%) con estenosis <50% y 124 vasos (91,2%) con estenosis ≥50%. Se encontró que por paciente el modelo logró una sensibilidad de 86%, especificidad 92% y un valor predictivo positivo (PPV) del 90%, mientras que la angiografía por TC sola, tuvo un 95%, 33% y 56% respectivamente. También se evaluó la precisión del modelo por vaso arterial, alcanzando una sensibilidad de 84%, especificidad de 94% y PPV 90%. En la utilización del modelo, se logró un 95%, 28% y 47% respectivamente. Con ello se demostró que el modelo de IA tuvo una mayor precisión diagnóstica de EAC en comparación con la lectura de la angiografía por TC.

Lipkin I *et al*,⁵² mediante un análisis de la base de datos del estudio CREDENCE, evaluaron el desempeño de las imágenes de perfusión miocárdica, y la angiografía con TC coronaria con IA cuantitativa, para la detección de EAC obstructiva. Incluyeron una muestra de 301 pacientes, 88 mujeres y 213 hombres, con edad media de 64,4 ± 10,2 años. Las imágenes de perfusión miocárdica fueron evaluadas por uno de tres cardiólogos con 10-15 años de experiencia y los resultados del modelo con IA por uno de cuatro cardiólogos experimentados. Se obtuvo que en la EAC de tipo obstructivo (estenosis ≥ 50%) el modelo de angiografía con TC coronaria con IA cuantitativa tuvo una sensibilidad de 95%, especificidad de 63% y PPV de 75% contra un 74%, 43% y 61% respectivamente en las imágenes de perfusión miocárdica. En la lesión obstructiva severa (estenosis ≥ 70%) el modelo tuvo una sensibilidad de 95%, especificidad de 81% y PPV de 67% en comparación con 91%, 44% y 39% de la imagen de perfusión miocárdica. Por lo que, la angiografía con TC coronaria e IA cuantitativa tuvo un mejor desempeño diagnóstico en la detección de EAC obstructiva (severa y no severa) en angiografía coronaria a diferencia de la imagen de perfusión miocárdica.

Li Y *et al*,⁵³ realizaron una comparación entre el desempeño de la TC dinámica con imagen de perfusión miocárdica y angiografía con TC derivada de la medición de la reserva de flujo fraccional con ML, para evaluar estenosis en arterias coronarias. El modelo fue entrenado con una extensa base de datos de anatomía coronaria, no obstante no se especificó la cantidad de imágenes para el entrenamiento ni prueba del algoritmo. Se incluyeron 86 participantes con sintomatología relacionada a angina o similares, sin historia de revascularización o infarto agudo al miocardio; con una edad media de 67 ± 12 años y alrededor del 78% de ellos fueron hombres, evaluándose un total de 157 vasos arteriales. Los resultados fueron revisados por dos cardiólogos intervencionistas con más de 20 años de experiencia. Al evaluar el desempeño en el diagnóstico de estenosis de las arterias coronarias, se encon-

tró que por vaso arterial, la sensibilidad de la TC dinámica con imagen de perfusión miocárdica en el estudio del diámetro de la estenosis arterial fue de 81%, con una especificidad de 63%, PPV de 67% y precisión 72%, mientras que la TC derivada de la medición de la reserva de flujo fraccional con ML fue de 88%, 68%, 72% y 78% respectivamente. En el análisis por paciente se halló una sensibilidad sin ML de 94%, especificidad de 61%, PPV de 79% y precisión de 81%, mientras con el modelo fue de 77%, 94%, 95% y 84%. Por lo tanto, la precisión diagnóstica en la evaluación de lesiones en las arterias coronarias que causan isquemia resultó mayor en la TC sin uso de ML que en la TC basada en este modelo.

Cho H *et al*,⁵⁴ desarrollaron algoritmos de DL para el apoyo de la ecografía coronaria para la caracterización de las placas calcificadas y atenuación del flujo sanguíneo de las arterias coronarias. Para este estudio se incluyeron 598 pacientes (137.989 imágenes), en cuyas lesiones se escogieron aquellas con mayor grado de estenosis. Y si bien los grupos para el entrenamiento (498 pacientes con 113.746 ecografías) y prueba del modelo (100 pacientes con 24.243 ecografías) fueron escogidos de manera aleatoria, estos también se dividieron en una clasificación de 5 grupos para la validación cruzada, y presentaron una edad promedio de 62,6 ± 9,8 años, un 71% de los cuales eran hombres. En promedio el modelo de DL y ecografía coronaria tuvo una sensibilidad de 0,85 ± 0,07, especificidad de 0,94 ± 0,02, PPV de 0,82 ± 0,05 y una precisión del 98% para la clasificación y caracterización de las lesiones coronarias, de manera rápida y precisa.

Radiografía (Rx):

Corresponde a una ayuda diagnóstica no usada comúnmente para el diagnóstico de EAC, sin embargo hay autores que resaltan su posible utilidad. D'Ancona G *et al*,⁵⁵ realizaron un estudio retrospectivo en 7.728 pacientes con angina que fueron sometidos a Rx de tórax y posterior angiografía coronaria, cuyos reportes se usaron como referencia para confirmar los hallazgos. Se utilizó un algoritmo de DL con base en una red neuronal convolucional profunda que fue entrenada para la clasificación de ausencia o presencia de EAC, con un grupo de entrenamiento del 70% (5.454 participantes), ajuste del modelo de 10% (n=773) y prueba de este del 20% (n=1.501). El desempeño del algoritmo se evaluó bajo distintos escenarios, partiendo desde el uso solo de la clasificación de riesgo *Diamond Forrester* con una sensibilidad del 94% y especificidad del 22%, mientras el uso del algoritmo obtuvo una sensibilidad del 90% y especificidad del 32 % para la identificación de EAC significativa; ambos en combinación conservaron una sensibilidad del 90% pero con un leve aumento de la especificidad a 35%. Por lo cual, la Rx de tórax en uso de este modelo de DL e incluso también apoyada por clasificaciones de riesgo, puede ser una ayuda inicial útil, fácil de usar y económica para la detección de EAC severo en muchos escenarios, sin olvidar su baja especificidad.

CONCLUSIONES:

El aumento en la precisión diagnóstica, sensibilidad y especificidad del algoritmo es un elemento común en la mayoría de los resultados, con pocas excepciones, en las cuales el modelo no tuvo una precisión diagnóstica significativamente alta o que en cambio, requirió elementos adicionales para alcanzarla. Dentro de los estudios revisados es destacable el interés por probar modelos de IA en poblaciones con antecedentes patológicos variados, ya sean sanos o con patologías estructurales específicas como el síndrome de Takotsubo o incluso con condiciones reumatológicas. También hubo una gran variedad de ayudas diagnósticas, algunas comúnmente usadas en ciertas alteraciones cardíacas y otras que se buscaban usar en escenarios atípicos proporcionando así información novedosa.

En esta revisión se encontraron limitaciones tales como poblaciones altamente homogéneas en edad y sexo biológico, siendo variables que en la salud cardiovascular suponen cambios y factores de riesgo sustanciales. Además, hubo estudios donde la caracterización del proceso de creación del modelo fue descrita de manera insuficiente, al igual que el tipo de IA utilizada y sus resultados, con métricas muy heterogéneas, dificultando la comparación entre modelos. Si bien, al mencionar el uso de la IA en una investigación se esperaría que los resultados de sensibilidad y especificidad contaran con porcentajes muy altos, la realidad fue diferente. En gran parte de los estudios revisados los valores fueron bajos con respecto a lo esperado, evidenciando la necesidad de más desarrollo en este campo tecnológico y biomédico. Sobre las alteraciones cardíacas, los estudios revisados abordaron principalmente afecciones como EAC o miocardiopatías, con una aplicación escasa sobre las valvulopatías, a pesar de su alta prevalencia e impacto en la morbimortalidad global. Desafortunadamente no se encontraron estudios de autores latinoamericanos que aborden la IA en técnicas imagenológicas en dicha población, siendo la mayoría de los estudios revisados de China, Estados Unidos y países de Europa como Italia y Alemania. Lo cual resalta la necesidad de cubrir esta brecha de conocimiento en países latinoamericanos y del continente africano.

RECOMENDACIONES

De acuerdo a esta revisión, la RMC fue la técnica diagnóstica asistida por IA más utilizada en el estudio de miocardiopatías, sin embargo, sus resultados fueron poco específicos en comparación con la gammagrafía la cuál mostró mayor sensibilidad y especificidad en los artículos. Por esta razón, se recomienda que futuras investigaciones relacionadas a IA, se tenga un enfoque más amplio hacia esta técnica imagenológica. También, son necesarias investigaciones que abarquen diversas poblaciones (sexo, edad y otras características), alteraciones y modelos, debido a su limitada variedad reportada en la literatura revisada. Además,

sería ideal brindar herramientas adicionales al personal de salud para comprender e interpretar la IA de manera adecuada, ya que una comprensión insuficiente podría conllevar a una aplicación carente de precisión y con ello, resultados deficientes.

AGRADECIMIENTOS

Este trabajo fue desarrollado en gran medida usando los recursos bibliográficos cuyo acceso fue facilitado por la Pontificia Universidad Javeriana de Cali. Las autoras agradecen al docente José Guillermo Ortega, de la Facultad de Ciencias de la Salud de esta misma institución, por su valioso apoyo durante la elaboración de este artículo.

REFERENCIAS

- Ramesh AN, Kambhampati C, Monson JRT, Drew PJ. Artificial intelligence in medicine. *Ann R Coll Surg Engl.* 2004; 86(5):334-8. DOI: 10.1308/147870804290
- Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer.* 2018; 18(8):500-10. DOI: 10.1038/s41568-018-0016-5
- Liu PR, Lu L, Zhang JY, Huo TT, Liu SX, Ye ZW. Application of Artificial Intelligence in Medicine: An Overview. *Curr Med Sci.* 2021; 41(6):1105-15. DOI: 10.1007/s11596-021-2474-3
- Johnson KW, Torres Soto J, Glicksberg BS, Shameer K, Miotto R, Ali M, *et al.* Artificial Intelligence in Cardiology. *J Am Coll Cardiol.* 2018; 71(23):2668-79. DOI: 10.1016/j.jacc.2018.03.521
- Gupta R, Srivastava D, Sahu M, Tiwari S, Ambasta RK, Kumar P. Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Mol Divers.* 2021; 25(3):1315-60. DOI: 10.1007/s11030-021-10217-3
- Hussain S, Mubeen I, Ullah N, Shah SSUD, Khan BA, Zahoor M, *et al.* Modern Diagnostic Imaging Technique Applications and Risk Factors in the Medical Field: A Review. *Biomed Res Int.* 2022; 2022:5164970. DOI: 10.1155/2022/5164970
- Krittana Wong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial Intelligence in Precision Cardiovascular Medicine. *J Am Coll Cardiol.* 2017; 69(21):2657-64. DOI: 10.1016/j.jacc.2017.03.571
- Iannattone PA, Zhao X, VanHouten J, Garg A, Huynh T. Artificial Intelligence for Diagnosis of Acute Coronary Syndromes: A Meta-analysis of Machine Learning Approaches. *Can J Cardiol.* 2020; 36(4):577-83. DOI: 10.1016/j.cjca.2019.09.013
- Lin A, van Diemen PA, Motwani M, McElhinney P, Otaki Y, Han D, *et al.* Machine Learning From Quantitative Coronary Computed Tomography Angiography Predicts Fractional Flow Reserve-Defined Ischemia and Impaired Myocardial Blood Flow. *Circ Cardiovasc Imaging.* 2022; 15(10):e014369. DOI: 10.1161/CIRCIMAGING.122.014369
- Singh S, Chaudhary R, Bliden KP, Tantry US, Gurbel PA, Visweswaran S, *et al.* Meta-Analysis of the Performance of AI-Driven ECG Interpretation in the Diagnosis of Valvular Heart Diseases. *Am J Cardiol.* 2024; 213:126-31. DOI: 10.1016/j.amjcard.2023.12.015
- Gruwez H, Barthels M, Haemers P, Verbrugge FH, Dhont S, Meekers E, *et al.* Detecting Paroxysmal Atrial Fibrillation From an Electrocardiogram in Sinus Rhythm: External Validation of the AI Approach. *JACC Clin Electrophysiol.* 2023; 9(8 Pt 3):1771-82. DOI: 10.1016/j.jacep.2023.04.008
- Barker J, Li X, Khavandi S, Koeckerling D, Mavilakandy A, Pepper C, *et al.* Machine learning in sudden cardiac death risk prediction: a systematic review. *Europace.* 2022; 24(11):1777-87. DOI: 10.1093/europace/euac135
- Cikes M, Sanchez-Martinez S, Claggett B, Duchateau N, Piella G, Butakoff C, *et al.* Machine learning-based phenotyping in heart failure to identify responders to cardiac resynchronization therapy. *Eur J Heart Fail.* 2019; 21(1):74-85. DOI: 10.1002/ejhf.1333
- Shen J, Zhang CJP, Jiang B, Chen J, Song J, Liu Z, *et al.* Artificial Intelligence Versus Clinicians in Disease Diagnosis: Systematic Review. *JMIR Med Inform.* 2019; 7(3):e10010. DOI: 10.2196/10010
- Nagendran M, Chen Y, Lovejoy CA, Gordon AC, Komorowski M, Harvey H, *et al.* Artificial intelligence versus clinicians: systematic review of design, reporting standards, and claims of deep learning studies. *BMJ.* 2020; 368:m689. DOI: 10.1136/bmj.m689
- Friedrich S, Groß S, König IR, Engelhardt S, Bahls M, Heinz J, *et al.* Applications of artificial intelligence/machine learning approaches in cardiovascular medicine: a systematic review with recommendations. *Eur Heart J Digit Health.* 2021; 2(3):424-36. DOI: 10.1093/ehjdh/ztab054
- Krajcer Z. Artificial Intelligence in Cardiovascular Medicine: Historical Overview, Current Status, and Future Directions. *Tex Heart Inst J.* 2022; 49(2). DOI: 10.14503/THIJ-20-7527
- Kolk MZH, Deb B, Ruipérez-Campillo S, Bhatia NK, Clopton P, Wilde AAM, *et al.* Machine learning of electrophysiological signals for the prediction of ventricular arrhythmias: systematic review and examination of heterogeneity between studies. *EBioMedicine.* 2023 Mar;89:104462. DOI: 10.1016/j.ebiom.2023.104462
- Manetas-Stavarakakis N, Sotiropoulou IM, Paraskevas T, Maneta Stavarakaki S, Bampatsias D, Xanthopoulos A, *et al.* Accuracy of Artificial Intelligence-Based Technologies for the Diagnosis of Atrial Fibrillation: A Systematic Review and Meta-Analysis. *J Clin Med Res.* 2023; 12(20). DOI: 10.3390/jcm12206576
- Ambale-Venkatesh B, Yang X, Wu CO, Liu K, Hundley WG, McClelland R, *et al.* Cardiovascular Event Prediction by Machine Learning: The Multi-Ethnic Study of Atherosclerosis. *Circ Res.* 2017; 121(9):1092-101. DOI: 10.1161/CIRCRESAHA.117.311312
- Popat A, Yadav S, Patel SK, Baddevelu S, Adusumilli S, Rao Dasari N, *et al.* Artificial Intelligence in the Early Prediction of Cardiogenic Shock in Acute Heart Failure or Myocardial Infarction Patients: A Systematic Review and Meta-Analysis. *Cureus.* 2023; 15(12):e50395. DOI: 10.7759/cureus.50395
- Nazar W, Szymanowicz S, Nazar K, Kaufmann D, Wabich E, Braun-Dullaes R, *et al.* Artificial intelligence models in prediction

- of response to cardiac resynchronization therapy: a systematic review. *Heart Fail Rev.* 2024; 29(1):133-50. DOI: 10.1007/s10741-023-10357-8
23. Palmieri V, Montisci A, Vietri MT, Colombo PC, Sala S, Maiello C, *et al.* Artificial intelligence, big data and heart transplantation: Actualities. *Int J Med Inform.* 2023; 176:105110. DOI: 10.1016/j.ijmedinf.2023.105110
 24. Talaei Khoei T, Ould Slimane H, Kaabouch N. Deep learning: systematic review, models, challenges, and research directions. *Neural Comput Appl.* 2023, DOI: 10.1007/s00521-023-08957-4
 25. Egger J, Gsaxner C, Pepe A, Pomykala KL, Jonske F, Kurz M, *et al.* Medical deep learning-A systematic meta-review. *Comput Methods Programs Biomed.* 2022; 221:106874. DOI: 10.1016/j.cmpb.2022.106874
 26. Umar U, Nayab S, Irfan R, Khan MA, Umer A. E-Cardiac care: A comprehensive systematic literature review. *Sensors [Internet].* 2022; 22(20). DOI: 10.3390/s22208073
 27. Panjiyar BK, Davydov G, Nashat H, Ghali S, Afifi S, Suryadevara V, *et al.* A Systematic Review: Do the Use of Machine Learning, Deep Learning, and Artificial Intelligence Improve Patient Outcomes in Acute Myocardial Ischemia Compared to Clinician-Only Approaches? *Cureus.* 2023; 15(8):e43003. DOI: 10.7759/cureus.43003
 28. Cheng S, Han Y, Jiang L, Lan Z, Guo J. National, regional, and global cardiomyopathy burden from 1990 to 2019. *Front Cardiovasc Med.* 2022; 9:1042448. DOI: 10.1186/s12916-023-02925-4
 29. World Health Organization. World health statistics 2023: monitoring health for the SDGs, Sustainable Development Goals. World Health Organization; 2023. 130 p.
 30. Ahsan MM, Siddique Z. Machine learning-based heart disease diagnosis: A systematic literature review. *Artif Intell Med.* 2022; 128:102289. DOI: 10.1016/j.artmed.2022.102289
 31. De Cecco CN, van Assen M, Leiner T, editors. Artificial intelligence in cardiothoracic imaging. 1st ed. Cham, Switzerland: Springer Nature; 2022. 595 p. (Contemporary Medical Imaging).
 32. Davies RH, Augusto JB, Bhuva A, Xue H, Treibel TA, Ye Y, *et al.* Precision measurement of cardiac structure and function in cardiovascular magnetic resonance using machine learning. *J Cardiovasc Magn Reson.* 2022; 24(1):16. DOI: 10.1186/s12968-022-00846-4
 33. Cau R, Pisu F, Pintus A, Palmisano V, Montisci R, Suri JS, *et al.* Cine-cardiac magnetic resonance to distinguish between ischemic and non-ischemic cardiomyopathies: a machine learning approach. *Eur Radiol.* 2024. DOI: 10.1007/s00330-024-10640-8
 34. Salehi M, Maiter A, Strickland S, Aldabbagh Z, Karunasaagarar K, Thomas R, *et al.* Clinical assessment of an AI tool for measuring biventricular parameters on cardiac MR. *Front Cardiovasc Med.* 2024; 11:1279298. DOI: 10.3389/fcvm.2024.1279298
 35. Corianò M, Lanera C, De Michieli L, Perazzolo Marra M, Iliceto S, Gregori D, *et al.* Deep learning-based prediction of major arrhythmic events in dilated cardiomyopathy: A proof of concept study. *PLoS One.* 2024; 19(2):e0297793. DOI: 10.1371/journal.pone.0297793
 36. Togo R, Hirata K, Manabe O, Ohira H, Tsujino I, Magota K, *et al.* Cardiac sarcoidosis classification with deep convolutional neural network-based features using polar maps. *Comput Biol Med.* 2019; 104:81-6. DOI: 10.1016/j.compbimed.2018.11.008
 37. Lin X, Yang F, Chen Y, Chen X, Wang W, Chen X, *et al.* Echocardiography-based AI detection of regional wall motion abnormalities and quantification of cardiac function in myocardial infarction. *Front Cardiovasc Med.* 2022; 9:903660. DOI: 10.3389/fcvm.2022.903660
 38. Barbieri A, Imberti JF, Bartolomei M, Bonini N, Laus V, Torlai Triglia L, *et al.* Quantification of Myocardial Contraction Fraction with Three-Dimensional Automated, Machine-Learning-Based Left-Heart-Chamber Metrics: Diagnostic Utility in Hypertrophic Phenotypes and Normal Ejection Fraction. *J Clin Med Res.* 2023; 12(17). DOI: 0.3390/jcm12175525
 39. Tabassian M, Sunderji I, Erdei T, Sanchez-Martinez S, Degiovanni A, Marino P, *et al.* Diagnosis of Heart Failure With Preserved Ejection Fraction: Machine Learning of Spatiotemporal Variations in Left Ventricular Deformation. *J Am Soc Echocardiogr.* 2018; 31(12):1272-84.e9. DOI: 10.1016/j.echo.2018.07.013
 40. Spielvogel CP, Haberl D, Mascherbauer K, Ning J, Kluge K, Traub-Weidinger T, *et al.* Diagnosis and prognosis of abnormal cardiac scintigraphy uptake suggestive of cardiac amyloidosis using artificial intelligence: a retrospective, international, multicentre, cross-tracer development and validation study. *Lancet Digit Health.* 2024; 6(4):e251-60. DOI: 10.1016/S2589-7500(23)00265-0
 41. Chandra V, Sarkar PG, Singh V. Mitral valve leaflet tracking in echocardiography using custom Yolo3. *Procedia Comput Sci.* 2020; 171:820-8.
 42. Li K, Huang Z, Cheng YC, Lee CH. A maximal figure-of-merit learning approach to maximizing mean average precision with deep neural network based classifiers. In: 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) [Internet]. IEEE; 2014. Disponible en: <http://ieeexplore.ieee.org/document/6854454/>
 43. Lang RM, Addetia K, Miyoshi T, Kebed K, Blitz A, Schreckenberg M, *et al.* Use of Machine Learning to Improve Echocardiographic Image Interpretation Workflow: A Disruptive Paradigm Change? *J Am Soc Echocardiogr.* 2021; 34(4):443-5. DOI: 10.1016/j.echo.2020.11.017
 44. Upton R, Mumith A, Beqiri A, Parker A, Hawkes W, Gao S, *et al.* Automated Echocardiographic Detection of Severe Coronary Artery Disease Using Artificial Intelligence. *JACC Cardiovasc Imaging.* 2022; 15(5):715-27.
 45. Guo Y, Xia C, Zhong Y, Wei Y, Zhu H, Ma J, *et al.* Machine learning-enhanced echocardiography for screening coronary artery disease. *Biomed Eng Online.* 2023; 22(1):44. DOI: 10.1186/s12938-023-01106-x
 46. Kuo HC, Chen SH, Chen YH, Lin YC, Chang CY, Wu YC, *et al.* Detection of coronary lesions in Kawasaki disease by Scaled-YOLOv4 with HarDNet backbone. *Front Cardiovasc Med.* 2022;

- 9:1000374.
47. Laumer F, Di Vece D, Cammann VL, Würdinger M, Petkova V, Schönberger M, *et al.* Assessment of Artificial Intelligence in Echocardiography Diagnostics in Differentiating Takotsubo Syndrome From Myocardial Infarction. *JAMA Cardiol.* 2022; 7(5):494-503. DOI: 10.1001/jamacardio.2022.0183
 48. Woodward G, Bajre M, Bhattacharyya S, Breen M, Chiocchia V, Dawes H, *et al.* PROTEUS Study: A Prospective Randomized Controlled Trial Evaluating the Use of Artificial Intelligence in Stress Echocardiography. *Am Heart J.* 2023; 263:123-32. DOI: 10.1016/j.ahj.2023.05.003
 49. Stuckey TD, Gammon RS, Goswami R, Depta JP, Steuter JA, Meine FJ 3rd, *et al.* Cardiac Phase Space Tomography: A novel method of assessing coronary artery disease utilizing machine learning. *PLoS One.* 2018; 13(8):e0198603. DOI: 10.1371/journal.pone.0198603
 50. Dey D, Gaur S, Ovrehus KA, Slomka PJ, Betancur J, Goeller M, *et al.* Integrated prediction of lesion-specific ischaemia from quantitative coronary CT angiography using machine learning: a multicentre study. *Eur Radiol.* 2018; 28(6):2655-64. DOI: 10.1007/s00330-017-5223-z
 51. Tang CX, Wang YN, Zhou F, Schoepf UJ, van Assen M, Stroud RE, *et al.* Diagnostic performance of fractional flow reserve derived from coronary CT angiography for detection of lesion-specific ischemia: A multi-center study and meta-analysis. *Eur J Radiol.* 2019; 116:90-7. DOI: 10.1016/j.ejrad.2019.04.011
 52. Lipkin I, Telluri A, Kim Y, Sidahmed A, Krepp JM, Choi BG, *et al.* Coronary CTA With AI-QCT Interpretation: Comparison With Myocardial Perfusion Imaging for Detection of Obstructive Stenosis Using Invasive Angiography as Reference Standard. *AJR Am J Roentgenol.* 2022; 219(3):407-19. DOI: 10.2214/AJR.21.27289
 53. Li Y, Yu M, Dai X, Lu Z, Shen C, Wang Y, *et al.* Detection of Hemodynamically Significant Coronary Stenosis: CT Myocardial Perfusion versus Machine Learning CT Fractional Flow Reserve. *Radiology.* 2019; 293(2):305-14. DOI: 10.1148/radiol.2019190098
 54. Cho H, Kang SJ, Min HS, Lee JG, Kim WJ, Kang SH, *et al.* Intravascular ultrasound-based deep learning for plaque characterization in coronary artery disease. *Atherosclerosis.* 2021; 324:69-75. DOI: 10.1148/radiol.2019190098
 55. D'Ancona G, Massussi M, Savardi M, Signoroni A, Di Bacco L, Farina D, *et al.* Deep learning to detect significant coronary artery disease from plain chest radiographs AI4CAD. *Int J Cardiol.* 2023; 370:435-41. DOI: 10.1016/j.ijcard.2022.10.154