

Toma de posición

Toma de posición conjunta sobre ecocardiografía e inteligencia artificial

Joint opinion document on echocardiography and artificial intelligence

Guillermo Aristimuño¹, Jorge Parras¹, José Picco², Santiago Vigo³, Jesica Aranda⁴, Griselda Doxastakis⁵, Augusto José Lépori⁶. Revisión: Aldo Prado⁷; revisión y aporte de imágenes: Roberto Lang⁸ †.

Comité de Ecocardiografía. Comité de Innovación Tecnológica.

1 Presidente del Comité de Innovación Tecnológica FAC. Instituto de Cardiología de Corrientes (Corrientes, Corrientes). 2 Instituto de Cardiología y Medicina del Deporte Wolff (Mendoza, Mendoza). 3 Sanatorio Allende (Córdoba, Córdoba). 4 Sanatorio Delta (Rosario, Santa Fe). 5 Instituto de Cardiología y Cirugía Cardiovascular (Posadas, Misiones). 6 Presidente del Comité de Ecocardiografía FAC. Instituto de Cardiología y Cirugía Cardiovascular (Posadas, Misiones). 7 Centro Privado de Cardiología (San Miguel de Tucumán, Tucumán). 8 Laboratorio de Imágenes Cardíacas No Invasivas University of Chicago Medicine (Chicago, EE. UU.).

INFORMACIÓN DEL ARTÍCULO

Recibido el 25 de Marzo de 2025

Aceptado después de revisión

el 24 de Abril de 2025

www.revistafac.org.ar

Los autores declaran no tener
conflicto de intereses

Palabras clave:

Inteligencia artificial,
ecocardiografía,
aprendizaje automático,
aprendizaje profundo.

Keywords:

Artificial intelligence,
echocardiography,
machine learning,
deep learning.

ABREVIATURAS:

IA: inteligencia artificial
ML: machine learning
DL: deep learning
FE: fracción de eyección

RESUMEN

La ecocardiografía es una herramienta clave en la evaluación cardíaca, pero enfrenta desafíos como la subjetividad en la interpretación y la dependencia de la calidad de las imágenes. La IA, a través de técnicas como el machine learning y el deep learning, permite la automatización de procesos como la adquisición de imágenes, la cuantificación de parámetros (fracción de eyección, volúmenes ventriculares) y la sospecha de patologías (miocardiopatía hipertrófica, amiloidosis cardíaca). Además, la IA facilita la educación médica mediante simuladores que ofrecen retroalimentación en tiempo real. A pesar de sus ventajas, persisten desafíos como la falta de transparencia en los algoritmos ("caja negra"), la necesidad de validación externa y la dependencia de la calidad de las imágenes. En conclusión, la IA no reemplazará al ecocardiografista, pero se convertirá en una herramienta indispensable para optimizar el diagnóstico y la toma de decisiones clínicas.

Joint opinion document on echocardiography and artificial intelligence

ABSTRACT

Echocardiography is a key tool in cardiac assessment but faces challenges such as subjectivity in interpretation and dependence on image quality. AI, through techniques like machine learning and deep learning, enables the automation of processes such as image acquisition, quantification of parameters (ejection fraction, ventricular volumes), and suspicion of pathologies (hypertrophic cardiomyopathy, cardiac amyloidosis). Additionally, AI facilitates medical education through simulations that provide real-time feedback. Despite its advantages, challenges remain, including the lack of transparency in algorithms ("black box"), the need for external validation, and dependence on image quality. In conclusion, AI will not replace echocardiographers but will become an indispensable tool for optimizing diagnosis and clinical decision-making.

INTRODUCCIÓN

Día a día se generan más datos en la práctica médica: monitores de telemetría, estudios complementarios de imágenes, historias clínicas y recetas electrónicas. Sin embargo, la capacidad del cerebro para interpretar toda esta información es limitada, lo que obliga a recurrir cada vez más al apoyo de nuevas tecnologías. En este contexto, la inteligencia artificial (IA) se presenta como una herramienta esencial que, aunque su desarrollo parece avanzado, la interacción entre los seres humanos y la IA está aún en sus primeras etapas¹.

La ecocardiografía Doppler es una herramienta fundamental en la práctica clínica cardiovascular, utilizada para la evaluación estructural y funcional del corazón

TABLA 1.

Desafíos actuales. Reproducido y traducido bajo autorización de Dr. Roberto Lang. University of Chicago Medicine



FIGURA 1.

Utilidad de la IA en salud. Reproducido y traducido bajo autorización de Dr. Roberto Lang. University of Chicago Medicine

en tiempo real. Una de sus principales limitaciones es la variabilidad inter e intraobservador, la dependencia de la calidad de la imagen obtenida, así como el tiempo que demanda la realización de numerosas mediciones y cálculos (Tabla 1). En este sentido, la IA amplía la capacidad para procesar grandes volúmenes de información y se posiciona como una herramienta clave para reducir la variabilidad en la interpretación y optimizar la precisión diagnóstica de la evaluación (Figura 1).

La IA tiene diferentes ramas, siendo las principales en ecocardiografía las siguientes:

- **Machine learning (ML):** permite a las computadoras aprender de grandes volúmenes de datos, donde los expertos humanos determinan el conjunto de características para comprender las diferencias entre las entradas de datos. A través de algoritmos matemáticos, identifica pa-

trrones, reconoce tendencias y mejora su rendimiento con el tiempo, facilitando la automatización de procesos complejos, por ejemplo, la interpretación de imágenes. Los modelos de *machine learning* se dividen en tres categorías principales: ML supervisado (utiliza conjuntos de datos etiquetados para entrenar algoritmos que clasifiquen datos o predigan resultados con precisión) (Figura 3); ML no supervisado (utiliza algoritmos para analizar y agrupar conjuntos de datos no etiquetados, descubriendo patrones ocultos o agrupaciones de datos sin necesidad de intervención humana) (Figura 4); ML semisupervisado (ofrece un término medio entre el aprendizaje supervisado y el no supervisado).

- **Deep learning (DL):** es una subcategoría del ML. Se basa en redes neuronales artificiales con múltiples capas que imitan el funcionamiento del cerebro humano. Estas



FIGURA 2.

Utilidad de la IA en salud. Reproducido y traducido bajo autorización de Dr. Roberto Lang. University of Chicago Medicine.



FIGURA 3.

Modelo de aprendizaje no-supervisado. Reproducido y traducido bajo autorización de Dr. Roberto Lang. University of Chicago Medicine



FIGURA 4.
Era actual de la ecocardiografía. Reproducido y traducido bajo autorización de Dr. Roberto Lang, University of Chicago Medicine

redes permiten analizar datos de manera jerárquica y extraer características complejas. Su capacidad para detectar cambios sutiles e invisibles al ojo humano en las estructuras ha revolucionado la precisión diagnóstica en ecocardiografía.

El uso de IA en ecocardiografía puede darse en diferentes aspectos:

1. **Automatización de la adquisición de imágenes:** la IA asiste a los operadores, incluidos aquellos con poca experiencia, en la obtención de imágenes ecocardiográficas de alta calidad. En este aspecto, los algoritmos guían en tiempo real la posición y el ángulo del transductor asegurando vistas óptimas. Esto reduce la variabilidad interobservador y es especialmente útil en entornos con recursos limitados o donde no hay especialistas disponibles.
2. **Reconocimiento y clasificación de vistas ecocardiográficas:** usando diferentes algoritmos se identifican y clasifican automáticamente las diferentes vistas ecocardiográficas, agilizando el flujo de trabajo y minimizando los errores humanos.
3. **Cuantificación automática:** la IA permite la medición automática de parámetros como los volúmenes ventriculares, fracción de eyección y flujos transvalvulares, entre otros. Esto reduce el tiempo de análisis y disminuye la variabilidad inter e intraobservador. Así, se puede evaluar, por ejemplo, la función sistólica y diastólica del ventrículo izquierdo o una valvulopatía.
4. **Detección y diagnóstico de patologías:** la IA permite identificar patrones asociados con diversas enfermedades cardíacas, como la miocardiopatía hipertrófica, la amiloidosis cardíaca y la hipertensión pulmonar. Estos sistemas pueden alertar a los clínicos sobre hallazgos anormales que podrían pasar desapercibidos en evaluaciones convencionales.
5. **Educación y entrenamiento:** se han desarrollado simuladores basados en IA que permiten a los ecocardiografistas en formación practicar con una amplia variedad de casos clínicos. Los algoritmos ofrecen retroalimentación

en tiempo real sobre la calidad de las imágenes y las mediciones realizadas, lo que mejora las habilidades de adquisición e interpretación de imágenes.

A partir de los puntos anteriores, es posible entender los mecanismos mediante los cuales la IA permite mejorar la práctica actual, alcanzando una precisión comparable a la de operadores expertos en adquisición, interpretación y probabilidad de diagnósticos etiológicos de las diferentes enfermedades cardíacas (Figura 4). Estudios recientes sugieren que la IA tiene además un gran potencial en la guía y predicción de resultados en intervenciones transcatóter.

A lo largo de la toma de posición se analizará cómo la IA optimiza y seguirá optimizando la realización de estudios ecocardiográficos, mejorando la precisión diagnóstica, minimizando errores y reduciendo la variabilidad interobservador, también denominada dependencia del operador, un factor clave en este tipo de evaluación (Figura 5).

USOS DE LA IA EN ECOCARDIOGRAFÍA

Determinación de diámetros, volúmenes, fracción de eyección y strain longitudinal global.

La disfunción sistólica del ventrículo izquierdo es una alteración frecuente originada por diversas patologías. Su evaluación precisa es fundamental para el diagnóstico, manejo y pronóstico de las enfermedades cardiovasculares. La FE del ventrículo izquierdo es el parámetro más utilizado para valorar la función sistólica y guiar el tratamiento. La evaluación ecocardiográfica presenta limitaciones, como la subjetividad del análisis visual y la variabilidad intra e interobservador, influenciada principalmente por la experiencia del operador^{2,3,4}.

La tecnología actual permite automatizar las mediciones ecocardiográficas, disminuyendo la variabilidad que existe entre expertos y principiantes. Esto incrementa la eficacia y optimiza el flujo de trabajo en los laboratorios de ecocardiografía⁵. Estudios multicéntricos han evaluado softwares independientes diseñados para la detección automática del borde endomiocárdico, una técnica que puede imple-

EL FUTURO DE LA ECOCARDIOGRAFÍA?



FIGURA 5.

Futuro de la ecocardiografía. Reproducido y traducido bajo autorización de Dr. Roberto Lang, University of Chicago Medicine

mentarse sin necesidad de IA. Sin embargo, la integración de algoritmos basados en IA ha permitido optimizar este proceso, mejorando la precisión en la cuantificación de parámetros como la fracción de eyección bidimensional, los volúmenes ventriculares izquierdos y el strain longitudinal global. Estos métodos son especialmente efectivos cuando la calidad de la imagen es moderada o buena. No obstante, en imágenes de menor calidad, la correlación con los trazados manuales se reduce significativamente⁶.

Además de la detección del borde endomiocárdico, las redes de IA pueden calcular de manera precisa el strain longitudinal global, los volúmenes ventriculares, identificar vistas ecocardiográficas y realizar mediciones precisas de la masa ventricular y el espesor de la pared⁷. Esto fue demostrado en los trabajos de Salte y colaboradores, cuyo modelo basado en ML puede identificar automáticamente las tres vistas apicales tradicionales y calcular el strain longitudinal global en diversas condiciones cardíacas. Este enfoque redujo el tiempo de procesamiento a solo 15 segundos, en comparación con los 3 a 5 minutos que requiere la metodología tradicional⁸.

La IA ofrece así una herramienta poderosa para analizar imágenes ecocardiográficas con precisión y eficiencia, mejorando las capacidades diagnósticas y reduciendo el tiempo necesario para estas tareas.

EVALUACIÓN DE ALTERACIONES DE LA MOTILIDAD SEGMENTARIA EN CARDIOPATÍA ISQUÉMICA

Las alteraciones de la motilidad segmentaria son indicadores tempranos de cardiopatía isquémica y predictores independientes de eventos cardiovasculares adversos mayores^{9,10,11}. Aunque la ecocardiografía es una herramienta clave para su diagnóstico, la evaluación tradicional basada en la interpretación visual presenta limitaciones significativas, incluyendo variabilidad entre observadores y dependencia de la experiencia del operador^{12,13}. La IA puede ayudar a superar estos desafíos mediante la integración de

redes neuronales convolucionales y modelos de DL que permitan evaluarlas de manera precisa^{9,10,11}.

Varios grupos de trabajo han desarrollado modelos con buenos resultados. Huang y colaboradores desarrollaron un modelo basado en redes neuronales convolucionales en tres dimensiones que analiza videos ecocardiográficos, logrando una sensibilidad del 81,8% y una especificidad del 81,6%, demostrando su capacidad para detectar alteraciones de la motilidad segmentaria utilizando tanto información temporal como espacial⁹. El grupo de trabajo de Kusunose demostró que un modelo de DL puede tener una precisión comparable a la de expertos en cardiología, con un área bajo la curva de 0,99 para la detección de alteraciones segmentarias¹⁴. Otro grupo desarrolló una solución de IA en tiempo real que guía a operadores no especializados en adquisición de imágenes ecocardiográficas, lo que mejora la calidad diagnóstica y facilita el acceso a un ecocardiograma de calidad en diferentes contextos clínicos¹⁵. Lin y colaboradores evaluaron el desempeño de un modelo para la detección automática de anomalías en la motilidad parietal regional en pacientes con sospecha de infarto de miocardio: compararon ecocardiogramas obtenidos con equipos portátiles al pie de la cama y equipos estándar. Desarrollaron un flujo de trabajo automatizado que integró la selección de vistas, la segmentación ventricular, la detección de alteraciones de la motilidad parietal y la cuantificación de la función cardíaca. La detección de anomalías de motilidad mostró un área bajo la curva de 0,88 y 0,91 en los estudios obtenidos con equipos portátiles y estándar respectivamente¹². Otros modelos son EC3D-Net y STGA-MS, que han demostrado avances significativos en la detección automatizada de anomalías de motilidad, superando a los métodos convencionales, mejorando la precisión diagnóstica y la reproducibilidad en la evaluación de la disfunción miocárdica isquémica^{10,11}.

La ecocardiografía de estrés permite evaluar el desarrollo de anomalías segmentarias de contracción tras aplicar

un estrés ya sea físico o farmacológico. Debe existir un control de calidad en la interpretación de anomalías de motilidad parietal regional, debido a que existe una variabilidad interobservador mayor que en estudios normales¹³. Existen modelos de IA que demostraron una precisión diagnóstica alta (sensibilidad 84,4% y especificidad 92,7%) en una cohorte de validación independiente, mejorando la concordancia interobservador y la confianza diagnóstica, incrementando la sensibilidad en un 10% y alcanzando un área bajo la curva ROC de 0,93¹⁶. Si bien la tecnología no sustituye la evaluación clínica, su integración puede mejorar la eficiencia y precisión del diagnóstico de isquemia miocárdica. Se requieren estudios adicionales para evaluar su aplicabilidad en poblaciones más amplias, pero la automatización del análisis mediante IA podría optimizar la precisión diagnóstica y la reproducibilidad en la evaluación¹⁷.

EVALUACIÓN DE DISFUNCIÓN DIASTÓLICA E INSUFICIENCIA CARDIACA CON FE PRESERVADA

La disfunción diastólica del ventrículo izquierdo es un factor clave en la fisiopatología de la insuficiencia cardíaca. Sin embargo, su evaluación ecocardiográfica es compleja y requiere un enfoque multiparamétrico. No existe una única variable con precisión diagnóstica suficiente para su detección, por lo que actualmente se recomienda el uso de un algoritmo que combine múltiples mediciones¹⁸.

En los últimos años, se han desarrollado diversas investigaciones con el objetivo de evaluar la utilidad de la IA en este campo. Los esfuerzos iniciales, con sus fortalezas y limitaciones, han sido previamente analizados en detalle¹⁹. La heterogeneidad en las técnicas de IA empleadas y las diferencias metodológicas en la referencia diagnóstica (ya sea el informe ecocardiográfico final, la opinión de expertos o los algoritmos de guías clínicas) han impedido la obtención de conclusiones definitivas en estos primeros estudios.

No obstante, investigaciones más recientes han incluido un mayor número de estudios y una metodología más homogénea. En un trabajo publicado en 2021, Tromp y colaboradores demostraron que un algoritmo de DL no solo fue capaz de identificar y clasificar las vistas ecocardiográficas necesarias para evaluar la función ventricular (sistólica y diastólica), sino también de realizar mediciones automatizadas de variables clave en el diagnóstico de disfunción diastólica, como los volúmenes ventriculares y las velocidades Doppler (tanto del flujo sanguíneo como tisular)²⁰. Estas mediciones mostraron una alta concordancia con las realizadas por operadores expertos y fueron validadas en múltiples cohortes de pacientes.

Ese mismo año, Pandey y colaboradores publicaron un estudio en el que evaluaron otro algoritmo de DL diseñado para identificar subgrupos de alto y bajo riesgo de disfunción diastólica²¹. Sus hallazgos fueron validados en cohortes externas, incluidas poblaciones del estudio TOPCAT (*Spirolactone for Heart Failure with Preserved Ejection Fraction*) y RELAX-HF (*Effects of Serelaxin in Patients with Acute Heart Failure*); se observó que los pacientes clasificados como de

alto riesgo presentaban una mayor tasa de eventos adversos en el seguimiento (mortalidad y hospitalización por insuficiencia cardíaca descompensada), mayor activación neurohormonal y menor capacidad de ejercicio. Además, el modelo basado en redes neuronales predijo presiones de llenado elevadas con una mayor precisión (área bajo la curva ROC) en comparación con el algoritmo de la Sociedad Americana de Ecocardiografía de 2016.

En 2023, se publicaron dos estudios de gran escala. Chen y colaboradores analizaron 1304 estudios ecocardiográficos con el objetivo de desarrollar un modelo basado en IA capaz de identificar las vistas ecocardiográficas, detectar la presencia de disfunción diastólica y establecer su grado de severidad. La validación del modelo mediante comparación con la evaluación de expertos humanos demostró una concordancia excelente²². Por otro lado, Ackerman y colaboradores analizaron a más de 5000 pacientes empleando exclusivamente la vista apical de cuatro cámaras. Su modelo de IA mostró un desempeño diagnóstico sobresaliente, con un área bajo la curva (AUC) superior al 97% en la cohorte de derivación y al 95 % en la cohorte de validación para la identificación de disfunción diastólica²³. Posteriormente, en 2024, el mismo grupo de la Clínica Mayo publicó un estudio de seguimiento con una mediana de 3,4 años, en el cual demostraron que los pacientes identificados por el algoritmo como pacientes con probabilidad de presentar disfunción diastólica tenían un mayor riesgo de mortalidad y hospitalización por insuficiencia cardíaca a lo largo del período de observación. Estos hallazgos refuerzan la utilidad pronóstica de la IA en la estratificación del riesgo e identificación temprana de pacientes con mayor vulnerabilidad clínica²⁴.

A pesar de los avances, aún existen desafíos claves que deben resolverse antes de la implementación rutinaria de la IA en la práctica clínica. Entre ellos, se destaca la necesidad de definir cuál de los múltiples enfoques de IA es el más adecuado para este problema, la validación en grupos de población aún no estudiados, el manejo de resultados "indeterminados", la falta de validación con patrones oro más estrictos (como la medición invasiva de presiones de llenado y el tiempo de relajación ventricular, Tau), la evaluación de la reproducibilidad y, no menos importante, el impacto económico que implica la integración de estos algoritmos en los equipos de ecocardiografía.

ESTUDIO DE VALVULOPATÍAS

Si bien la ecocardiografía constituye el método de elección para el diagnóstico de valvulopatías, aún persisten casos de subdiagnóstico, en parte debido a limitaciones en el acceso y la variabilidad en la adquisición e interpretación de las imágenes. La introducción de dispositivos portátiles de ultrasonido ha mejorado la accesibilidad a esta herramienta, aunque sigue requiriendo un entrenamiento adecuado para garantizar estudios con calidad diagnóstica. En este contexto, la IA está transformando la evaluación y manejo de las valvulopatías, optimizando la adquisición

de imágenes y reduciendo la dependencia del operador. En estudios comparativos, la precisión diagnóstica de enfermeras sin experiencia previa en ecocardiografía en la evaluación de valvulopatía aórtica y mitral alcanzó valores superiores al 92 % en relación con ecocardiografistas expertos, lo que evidencia el potencial de estas tecnologías para ampliar la aplicabilidad de la ecocardiografía en distintos entornos clínicos²⁵.

En el contexto de la valoración de las valvulopatías, la IA puede brindar asistencia en:

1. **Adquisición:** la correcta visualización de cavidades, válvulas, jets y señales Doppler demanda entrenamiento, por lo que se desarrollaron algoritmos para guiar la obtención de imágenes; al comparar enfermeras nuevas vs ecocardiografistas expertos, la precisión de estas para evaluar valvulopatía aórtica o mitral fue mayor al 92%²⁵.
2. **Identificación:** al igual que con las imágenes del ventrículo izquierdo, la IA no solo permite la lectura de datos obtenidos de imágenes valvulares crudas, sino también mediciones automáticas. Esto se traducirá en acortar tiempos en el manejo de las valvulopatías debido a reducción del tiempo para establecer una probabilidad diagnóstica, disminuyendo así la variabilidad interobservador en la determinación de la severidad (actualmente aproximadamente 61% para la insuficiencia mitral). Existen algoritmos que pueden detectar con una precisión de 98% y 90% las válvulas mitral y tricúspide respectivamente; otros son capaces de identificar la señal de Doppler continuo con 98% de precisión^{26,27}. En un estudio con 256 pacientes, la IA tuvo una excelente capacidad diagnóstica comparada con mediciones realizadas por humanos en cuanto a velocidad máxima aórtica ($r=0,97$), gradiente medio ($r=0,94$), área valvular aórtica ($r=0,88$), volumen sistólico ($r=0,79$), integral tiempo-velocidad del tracto de salida del ventrículo izquierdo ($r=0,89$), integral tiempo-velocidad aórtica ($r=0,96$) y diámetro del tracto de salida del ventrículo izquierdo ($r=0,76$)^{27,28}.
3. **Segmentación:** hace referencia a reconocer una estructura en una imagen, permitiendo automatizar la evaluación de diámetros y función anular, valvular o Doppler. Existen algoritmos entrenados con imágenes de la válvula mitral, que obtuvieron una precisión variable, entre modesta a buena (0,48 -0,79), y una tasa de error cercana al 6% para la medición del perímetro y 12% del área valvular²⁹. Respecto al Doppler, en un estudio se entrenó un algoritmo con 1132 pacientes con insuficiencia mitral de leves a severas, y se lo validó con 295 pacientes, logrando una precisión cercana al 90% para cada categoría de severidad; otra publicación informó una correlación de 0,9 entre un algoritmo y un experto para la medición de velocidades, gradiente e integral tiempo-velocidad de las señales Doppler³⁰.
4. **Identificación de severidad:** se basa en reconocer datos que exceden la percepción humana. En una cohorte de 139 pacientes, se pudo identificar con una precisión ma-

yor al 99% la severidad de la insuficiencia mitral; otro estudio pudo identificar enfermedad reumática con una precisión del 77%^{31,32}. Estos algoritmos también permiten reconocer válvulas protésicas mitrales con un área bajo la curva de 98%.

No solo permite mejorar la evaluación actual sino también agregar información clínica, genética, de laboratorio o de otros exámenes complementarios, logrando tomar decisiones en mucho menos tiempo.

Existen modelos utilizando ML desarrollados para valvulopatía aórtica: un estudio de la Cleveland Clinic identificó fenotipos de aneurisma de aorta en 656 pacientes con válvula bicúspide permitiendo asociarlos con una valvulopatía predominante^{33,34,35,36}. Otros tres estudios fueron diseñados para identificar grupos de alto riesgo dentro del espectro de la estenosis aórtica:

- Casaclang-Verzosa y colaboradores describieron la progresión de estenosis leve a severa en 346 pacientes usando 79 variables clínicas y ecocardiográficas. Demostraron 2 subgrupos de estenosis aórtica moderada (uno de sexo masculino y menor FE, otro con menores velocidades, pero mayor masa del ventrículo izquierdo y volúmenes auriculares) y su respuesta tras el reemplazo valvular.
- Sengupta y colaboradores analizaron una cohorte de 1052 pacientes con estenosis aórtica leve o moderada y un grupo con estenosis aórtica severa de bajo flujo bajo gradiente. Encontraron un grupo de mayor riesgo con mayor score de calcio, mayor nivel de biomarcadores, captación de gadolinio, incidencia de reemplazo valvular y de muerte pre y post quirúrgica. El modelo de validación tuvo mejor discriminación y reclasificación que los métodos actuales.
- Por último, Kwak y colaboradores desarrollaron un modelo basado en 398 pacientes con estenosis aórtica moderada a severa, incorporando 11 variables clínicas, de laboratorio y ecocardiográficas, con el objetivo de identificar aquellos pacientes que podrían no beneficiarse de una intervención. A través del análisis de datos, identificaron tres subgrupos diferenciados, de los cuales uno presentó una elevada mortalidad cardiovascular, mientras que otro mostró una alta mortalidad total. Estos hallazgos sugieren que este último subgrupo podría requerir un enfoque terapéutico alternativo, lo que destaca el potencial de la inteligencia artificial en la estratificación del riesgo y la personalización de las estrategias de manejo.

UTILIDAD EN INTERVENCIONES TRANSCATÉTER EN CARDIOPATÍA ESTRUCTURAL

Las intervenciones transcáteter en cardiopatía estructural han crecido exponencialmente debido al envejecimiento poblacional y los avances tecnológicos, como el implante de válvula aórtica transcáteter, el cierre de orejuela auricular izquierda, el cierre de comunicación interauricular y los procedimientos sobre las válvulas auriculoventriculares. Estas intervenciones se han convertido en el tratamiento de primera línea para múltiples patologías, y la IA ha surgi-

do como una herramienta clave en la optimización de estos procedimientos, mejorando la selección de pacientes, la planificación preoperatoria, la ejecución, el monitoreo post implantación y el seguimiento, lo que contribuye a optimizar los resultados clínicos^{37,38}.

En este contexto, la IA, mediante el aprendizaje supervisado, predice resultados y facilita diagnósticos tempranos al reducir el tiempo de procesamiento de imágenes y la variabilidad inter e intraobservador mediante el análisis de grandes volúmenes de datos. A través del aprendizaje no supervisado, identifica patrones ocultos, clasifica pacientes según fenotipos y riesgos específicos, y determina diferentes pronósticos y respuestas terapéuticas³⁷.

La selección de pacientes para intervenciones cardíacas valvulares se basa en los síntomas y hallazgos ecocardiográficos, mientras que la indicación del cierre de orejuela auricular izquierda se fundamenta en el riesgo de accidente cerebrovascular o de hemorragia³⁷. A través del ML (con una técnica que se denomina cluster analysis), se pueden descubrir patrones ocultos dentro de los datos y clasificar a los pacientes en fenotipos con diferentes resultados clínicos. En la estenosis aórtica, por ejemplo, esta técnica ayuda a identificar pacientes que pueden beneficiarse del tratamiento transcatheter^{36,37,38}. Además, en fibrilación auricular, permite estimar el riesgo de accidente cerebrovascular y evaluar variabilidades anatómicas específicas de la orejuela auricular izquierda para facilitar la indicación del cierre percutáneo.

Por otro lado, el ML supervisado es una alternativa a las estadísticas convencionales para establecer una probabilidad pronóstica y así generar modelos más sólidos³⁹. No obstante, los algoritmos de IA no están exentos de sesgos, ya que dependen de la calidad, relevancia e integridad de los datos empleados en su entrenamiento.

En tomografía computada, el DL se utiliza para segmentar y cuantificar automáticamente la calcificación de la válvula aórtica, un dato clave para el diagnóstico y la predicción de mortalidad⁴⁰. En casos de estenosis aórtica severa con bajo flujo y bajo gradiente, donde los resultados ecocardiográficos pueden ser equívocos, la puntuación de calcio por ecocardiografía basada en IA ha demostrado ser útil en la toma de decisiones clínicas.

Se ha desarrollado un algoritmo basado en más de 530.000 ecocardiogramas que mejora la detección de estenosis aórtica severa, superando las limitaciones de las mediciones convencionales del tracto de salida del ventrículo izquierdo⁴¹. Sin embargo, la complejidad de los algoritmos de DL requiere una alta capacidad de procesamiento computacional, incluyendo unidades de procesamiento gráfico y computación en la nube⁴².

El ML también ha revolucionado la planificación de las intervenciones transcatheter mediante la generación de modelos tridimensionales computacionales, que permiten seleccionar dispositivos de manera más precisa y predecir su rendimiento⁴³. Esto se ha validado en procedimientos como implante de válvula aórtica transcatheter, MitraClip, cierre de orejuela auricular izquierda y reemplazo valvular

mitral transcatheter. En particular, un modelo basado en tomografía computada ha demostrado predecir con precisión la deformación y aposición del dispositivo de cierre de orejuela auricular izquierda, mejorando la planificación del procedimiento⁴⁴.

Durante la intervención, el uso de IA facilita la identificación automática de estructuras anatómicas mediante la fusión de imágenes de fluoroscopia con ecocardiografía o tomografía computada. Esta integración ha sido utilizada en implante de válvula aórtica transcatheter y cierre de orejuela auricular izquierda, reduciendo el tiempo del procedimiento y la exposición a radiación⁴⁵. Además, la planificación asistida por IA con realidad aumentada permite generar hologramas tridimensionales en tiempo real, optimizando la visualización y el posicionamiento del dispositivo⁴⁶.

En el seguimiento a corto plazo, el ML supervisado ha demostrado predecir con mayor precisión la mortalidad hospitalaria postimplante de válvula aórtica transcatheter y reemplazo valvular mitral transcatheter en comparación con modelos tradicionales⁴⁷. Asimismo, la IA ha superado los sistemas de puntuación convencionales (EuroSCORE, STS) en la predicción de supervivencia a 30 días postimplante de válvula aórtica transcatheter⁴⁸. Se describió un modelo eficaz para predecir la necesidad de implante de marcapasos posterior al implante de una válvula aórtica transcatheter, una complicación frecuente, mediante la integración de datos clínicos, electrocardiográficos y ecocardiográficos⁴⁹.

La cuantificación automatizada basada en IA también ha reducido significativamente el tiempo de análisis por paciente⁵⁰. En cuanto a la predicción del tiempo de hospitalización postimplante de válvula aórtica transcatheter, un modelo de ML ha identificado predictores novedosos, como la duración del procedimiento, la necesidad de fisioterapia y los resultados según el día de la semana en la que se realiza la intervención.

RECONOCIMIENTO DE ENFERMEDADES DEL MIOCARDIO

La clasificación y el diagnóstico de enfermedades miocárdicas en etapas tempranas, cuando los pacientes aún están asintomáticos, representan un área crítica donde la ciencia computacional puede aportar grandes beneficios. En la práctica clínica, estos pacientes pueden permanecer sin diagnóstico durante largos períodos y sólo reciben tratamiento cuando la enfermedad ha progresado a estadios avanzados. Esto tiene implicaciones no solo en el pronóstico y calidad de vida del paciente, sino también en la reducción de costos hospitalarios futuros.

La hipertrofia ventricular izquierda es un hallazgo frecuente en la práctica clínica y se asocia con eventos cardiovasculares adversos como arritmias, isquemia miocárdica, insuficiencia cardíaca y muerte súbita^{51,52}. Un estudio realizado por Zhang y cols. demostró que las redes neuronales convolucionales pueden identificar ventanas ecocardiográficas y proporcionar medidas específicas, como el grosor de las paredes y la masa del ventrículo izquierdo⁷.

Desde el punto de vista del diagnóstico etiológico, la ecocardiografía a menudo no es suficiente, y se requieren estudios más complejos para un diagnóstico preciso. Entre las principales etiologías que se presentan como hipertrofia ventricular, se encuentran la hipertensión arterial, la miocardiopatía hipertrófica, la estenosis aórtica, la insuficiencia renal crónica y la amiloidosis cardíaca. Otras etiologías menos frecuentes incluyen miocarditis, sarcoidosis y enfermedades de depósito, como la enfermedad de Fabry o Danon, además de miocardiopatías mitocondriales.

La textura miocárdica es difícil de evaluar y cuantificar mediante la simple observación del médico⁵³. En este sentido, la IA ha demostrado su capacidad para diferenciar la hipertrofia miocárdica secundaria a hipertensión arterial de la miocardiopatía hipertrófica y la miocardiopatía urémica. Se ha observado que la miocardiopatía hipertrófica presenta un patrón de distribución de valores numéricos más homogéneo en los análisis algorítmicos, lo que podría ser útil para la diferenciación etiológica⁵⁴.

En la evaluación ecocardiográfica tradicional de la amiloidosis cardíaca, si bien pueden identificarse múltiples hallazgos sugerentes, ninguno ha demostrado ser lo suficientemente específico o sensible para establecer un diagnóstico definitivo. Además, ciertas características ecográficas requieren análisis avanzados con software especializado, lo que implica mayor tiempo de procesamiento y suele aplicarse en casos con diagnóstico ya confirmado⁵⁵.

Un estudio en centros académicos utilizó un modelo basado en videos ecocardiográficos con vista de cuatro cámaras, logrando una precisión diagnóstica elevada (C-statistic de 0,96), superior a la de los expertos en la detección de amiloidosis. Se destacó que el modelo tuvo mejor desempeño en la detección de amiloidosis cardíaca por transtiretina que por cadenas livianas⁵⁶. Otro modelo de DL logró identificar cambios sutiles en la geometría ventricular, permitiendo diferenciar la amiloidosis cardíaca de la hipertrofia ventricular⁵⁷. Inclusive, la FDA (*Food and Drug Administration*) aprobó el software de inteligencia artificial EchoGo® Amyloidosis para la detección de amiloidosis cardíaca mediante ecocardiografía. Este sistema ha demostrado un alto rendimiento diagnóstico, con un área bajo la curva de hasta 0,93 y un valor predictivo negativo superior al 85%. Su sensibilidad es consistente entre los distintos tipos de amiloidosis. Además, superó el análisis convencional en pacientes mayores de 60 años con insuficiencia cardíaca y aumento del grosor de la pared del ventrículo izquierdo, con un área bajo la curva de 0,93 frente a 0,73.

En pacientes con insuficiencia cardíaca y FE preservada con predominio de síntomas de congestión derecha, el diagnóstico diferencial incluye la miocardiopatía restrictiva y pericarditis constrictiva. En este contexto, la ecocardiografía es considerada el estudio de primera línea para el diagnóstico de pericarditis constrictiva^{58,59}. No obstante, su precisión depende de la calidad del estudio y de la experiencia del operador, pudiendo requerir estudios adicio-

nales como tomografía, resonancia magnética o evaluación hemodinámica^{60,61,62}.

En 2016, Sengupta y cols realizaron un estudio piloto empleando speckle-tracking e IA mediante un clasificador de memoria asociativa para diferenciar pericarditis constrictiva de miocardiopatía restrictiva, obteniendo un área bajo la curva de 0,89, superior a las variables ecocardiográficas convencionales⁶³. Un estudio más reciente utilizó un modelo de DL para diferenciar pericarditis constrictiva de miocardiopatía restrictiva secundaria a amiloidosis, alcanzando un área bajo la curva de 0,97 con la vista de cuatro cámaras, y validación externa con área bajo la curva de 0,84⁶⁴.

El ML también ha demostrado ser útil para diferenciar el infarto agudo de miocardio del síndrome de Takotsubo. Laumer F y cols reportaron que un sistema basado en IA mostró un mejor desempeño diagnóstico (área bajo la curva 0,79 vs. 0,71) en comparación con un comité de cardiólogos expertos⁶⁵.

EDUCACIÓN EN ECOCARDIOGRAFÍA

La IA se ha convertido en una herramienta invaluable para mejorar las habilidades de adquisición e interpretación de imágenes ecocardiográficas, especialmente en ecocardiografistas en formación. Los simuladores basados en IA permiten a los estudiantes practicar con una amplia variedad de casos clínicos, desde escenarios comunes hasta situaciones complejas y raras, lo que enriquece su experiencia y preparación para la práctica real.

Uno de los avances más significativos en este campo es la capacidad de la IA para ofrecer retroalimentación en tiempo real. Los algoritmos pueden evaluar la calidad de las imágenes adquiridas por los estudiantes, guiándolos en la correcta posición y angulación del transductor para obtener vistas óptimas. Además, estos sistemas pueden proporcionar sugerencias para mejorar la técnica de adquisición y señalar errores comunes, lo que acelera el proceso de aprendizaje y reduce la dependencia de la supervisión constante de un instructor. Esta capacidad es particularmente útil en entornos con recursos limitados, donde el acceso a expertos en ecocardiografía puede ser escaso.

Otro aspecto destacado es el uso de la IA para la interpretación de imágenes. Los modelos de DL pueden analizar estudios ecocardiográficos y comparar los hallazgos del estudiante con los de expertos, ofreciendo una evaluación objetiva de su desempeño. Esto no solo mejora la precisión diagnóstica de los estudiantes, sino que también les permite familiarizarse con los estándares de calidad y las mejores prácticas en la interpretación de estudios. Además, la IA puede generar informes automatizados que sirven como material de estudio y referencia, facilitando la revisión y el aprendizaje continuo.

En resumen, la IA está revolucionando la educación en ecocardiografía al proporcionar herramientas interactivas, personalizadas y accesibles que mejoran la formación de los profesionales de la salud. A medida que estas tecnologías continúan evolucionando, se espera que desempeñen

un papel aún más importante en la preparación de ecocardiografistas altamente capacitados y en la reducción de la variabilidad en la adquisición e interpretación de imágenes.

Limitaciones

La aplicación clínica de la IA en ecocardiografía enfrenta múltiples desafíos que deben ser abordados antes de su adopción generalizada. Uno de los principales es el problema de la "caja negra" en los algoritmos, es decir, la falta de transparencia en el funcionamiento interno de modelos complejos, especialmente aquellos basados en DL, lo que dificulta la interpretación de los resultados y la comprensión de los criterios utilizados por los modelos para establecer una probabilidad diagnóstica. Esto, evidentemente, puede generar desconfianza en su uso clínico.

La calidad de las imágenes ecocardiográficas sigue siendo un factor determinante en el rendimiento de todos estos algoritmos. Así, la variabilidad en la adquisición de imágenes, influenciada tanto por la experiencia del operador como por las características técnicas del equipo, pueden afectar la precisión de los modelos. Esto resalta la necesidad de estrategias que optimicen la calidad de los datos.

Otro aspecto crítico es la falta de estandarización y validación externa de muchos modelos, lo que plantea interrogantes sobre su aplicabilidad en la práctica clínica y en diferentes poblaciones de pacientes. La mayoría de los estudios que han evaluado la IA en cardiología han sido retrospectivos y requieren validación en estudios multicéntricos de gran escala para demostrar su utilidad en escenarios clínicos reales.

Finalmente, algunos modelos, principalmente de ML, dependen de datos previamente etiquetados por médicos, lo que puede introducir sesgos inherentes y errores sistemáticos en la interpretación de los hallazgos. Esta dependencia de la clasificación humana subraya la necesidad de desarrollar estrategias para minimizar el impacto de estos sesgos en el entrenamiento de los algoritmos.

CONCLUSIONES

La IA está revolucionando el campo de la ecocardiografía, ofreciendo herramientas que mejoran la precisión diagnóstica, reducen la variabilidad interobservador y optimizan el flujo de trabajo en los laboratorios de imágenes cardíacas. Desde la cuantificación automática de parámetros como la fracción de eyección y el strain longitudinal global, hasta la evaluación de valvulopatías y la detección de alteraciones de la motilidad segmentaria en la cardiopatía isquémica, la IA ha demostrado un potencial significativo para transformar la práctica clínica. Sin embargo, persisten desafíos importantes, como la necesidad de validación externa de algoritmos, la interpretabilidad de los modelos de IA y la dependencia de la calidad de las imágenes.

El futuro de la IA en ecocardiografía dependerá de su integración efectiva en el entorno clínico, combinando automatización con supervisión humana para garantizar interpretaciones precisas y confiables. A medida que se su-

peren los desafíos técnicos y metodológicos, la IA podría transformar la ecocardiografía en una herramienta aún más poderosa, optimizando el diagnóstico cardiovascular y contribuyendo a una medicina más personalizada y eficiente.

En definitiva, la IA no reemplazará al ecocardiografista, pero se convertirá en un aliado indispensable en la toma de decisiones clínicas más precisas y personalizadas.

BIBLIOGRAFIA

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med* **2019** ; 25: 44 – 56.
2. Yamaguchi N, Kosaka Y, Haga A, et al. Artificial intelligence-assisted interpretation of systolic function by echocardiogram. *Open Heart* **2023**; 10: e002287.
3. Zhang Z, Zhu Y, Liu M, et al. Artificial Intelligence-Enhanced Echocardiography for Systolic Function Assessment. *J Clin Med* **2022**; 11: 2893.
4. Barry T, Farina JM, Chao CJ, et al. The Role of Artificial Intelligence in Echocardiography. *J Imaging* **2023**; 9: 50.
5. Thavendiranathan P, Liu S, Verhaert D, et al. Feasibility, accuracy, and reproducibility of real-time full-volume 3D transthoracic echocardiography to measure LV volumes and systolic function: a fully automated endocardial contouring algorithm in sinus rhythm and atrial fibrillation. *JACC Cardiovasc Imaging* **2012**; 5: 239 – 251.
6. Knackstedt C, Bekkers SCAM, Schummers G, et al. Fully Automated Versus Standard Tracking of Left Ventricular Ejection Fraction and Longitudinal Strain: The FAST-EFs Multicenter Study. *J Am Coll Cardiol* **2015**; 66: 1456 – 1466.
7. Zhang J, Gajjala S, Agrawal P, et al. Fully Automated Echocardiogram Interpretation in Clinical Practice. *Circulation* **2018**; 138: 1623 – 1635.
8. Salte IM, Østvik A, Smistad E, et al. Artificial Intelligence for Automatic Measurement of Left Ventricular Strain in Echocardiography. *JACC Cardiovasc Imaging* **2021**; 14: 1918 – 1928.
9. Huang MS, Wang CS, Chiang JH, et al. Automated Recognition of Regional Wall Motion Abnormalities Through Deep Neural Network Interpretation of Transthoracic Echocardiography. *Circulation* **2020**; 142: 1510 – 1520.
10. Sun S, Wang Y, Yu Q, et al. AI diagnosis model of regional wall motion abnormality based on 2D transthoracic echocardiography. *Heliyon* **2024**; 10: e23224.
11. Sanjeevi G, Gopalakrishnan U, Pathinarupothi RK, et al. Automatic Diagnostic Tool for Detection of Regional Wall Motion Abnormality from Echocardiogram. *J Med Syst* **2023**; 47: 13.
12. Lin X, Yang F, Chen Y, 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.
13. Ciampi Q, Picano E, Paterni M, et al. Quality control of regional wall motion analysis in stress Echo 2020. *Int J Cardiol* **2017**; 249: 479 – 485.
14. Kusunose K, Abe T, Haga A, et al. A Deep Learning Approach for Assessment of Regional Wall Motion Abnormality from Echocardiographic Images. *JACC Cardiovasc Imaging* **2020**; 13: 374 – 381.
15. Mor-Avi V, Khandheria B, Klempfner R, et al. Real-Time Artificial Intelligence-Based Guidance of Echocardiographic Imaging by Novices: Image Quality and Suitability for Diagnostic Interpretation and Quantitative Analysis. *Circ Cardiovasc Imaging* **2023**; 16: e015569.
16. Upton R, Mumith A, Beqiri A, et al. Automated Echocardiographic Detection of Severe Coronary Artery Disease Using Artificial Intelligence. *JACC Cardiovasc Imaging* **2022**; 15: 715 – 727.
17. Pellikka PA. Artificially Intelligent Interpretation of Stress Echocardiography: The Future Is Now. *JACC Cardiovasc Imaging* **2022**; 15: 728 – 730.
18. Nagueh SF, Smiseth OA, Appleton CP, et al. Recommendations for the Evaluation of Left Ventricular Diastolic Function by Echocardiography: An Update from the American Society of Echocardiography and the European Association of Cardiovascular Imaging. *Eur Heart J Cardiovasc Imaging* **2016**; 17: 1321 – 1360.

19. Fletcher AJ, Lapidaire W, Leeson P. Machine Learning Augmented Echocardiography for Diastolic Function Assessment. *Front Cardiovasc Med* **2021**; 8: 711611.
20. Tromp J, Seekings PJ, Hung CL, et al. Automated interpretation of systolic and diastolic function on the echocardiogram: a multicohort study. *Lancet Digit Health* **2022**; 4: e46 – e54.
21. Pandey A, Kagiya N, Yanamala N, et al. Deep-Learning Models for the Echocardiographic Assessment of Diastolic Dysfunction. *JACC Cardiovasc Imaging* **2021**; 14: 1887 – 1900.
22. Chen X, Yang F, Zhang P, et al. Artificial Intelligence-Assisted Left Ventricular Diastolic Function Assessment and Grading: Multi view Versus Single View. *J Am Soc Echocardiogr* **2023**; 36: 1064 – 1078.
23. Akerman AP, Porumb M, Scott CG, et al. Automated Echocardiographic Detection of Heart Failure with Preserved Ejection Fraction Using Artificial Intelligence. *JACC Adv* **2023**; 2: 100452.
24. Cassianni C, Huntley GD, Castrichini M, et al. Automated Echocardiographic Detection of Heart Failure with Preserved Ejection Fraction Using Artificial Intelligence Is Associated with Cardiac Mortality and Heart Failure Hospitalization. *J Am Soc Echocardiogr* **2024**; 37: 914 – 916.
25. Narang A, Bae R, Hong H, et al. Utility of a Deep-Learning Algorithm to Guide Novices to Acquire Echocardiograms for Limited Diagnostic Use. *JAMA Cardiol* **2021**; 6: 624 – 632.
26. Lang RM, Addetia K, Miyoshi T, et al. Use of Machine Learning to Improve Echocardiographic Image Interpretation Workflow: A Disruptive Paradigm Change? *J Am Soc Echocardiogr* **2021**; 34: 443 – 445.
27. Madani A, Arnaout R, Mofrad M, et al. Fast and accurate view classification of echocardiograms using deep learning. *NPJ Digit Med* **2018**; 1: 6.
28. Krishna H, Desai K, Slostad B, et al. Fully Automated Artificial Intelligence Assessment of Aortic Stenosis by Echocardiography. *J Am Soc Echocardiogr* **2023**; 36: 769 – 777.
29. Costa E, Martins N, Sultan MS, et al. Mitral Valve Leaflets Segmentation in Echocardiography using Convolutional Neural Networks. In: 2019 IEEE 6th Portuguese Meeting on Bioengineering (ENBENG) [Internet]. IEEE; **2019**. Disponible en: <https://ieeexplore.ieee.org/document/8692573/>
30. Gosling AF, Thalappillil R, Ortoleva J, et al. Automated Spectral Doppler Profile Tracing. *J Cardiothorac Vasc Anesth* **2020**; 34: 72 – 76.
31. Moghaddasi H, Nourian S. Automatic assessment of mitral regurgitation severity based on extensive textural features on 2D echocardiography videos. *Comput Biol Med* **2016**; 73: 47 – 55.
32. Martins JFBS, Nascimento ER, Nascimento BR, et al. Towards automatic diagnosis of rheumatic heart disease on echocardiographic exams through video-based deep learning. *J Am Med Inform Assoc* **2021**; 28: 1834 – 1842.
33. Wojnarski CM, Roselli EE, Idrees JJ, et al. Machine-learning phenotypic classification of bicuspid aortopathy. *J Thorac Cardiovasc Surg* **2018**; 155: 461 – 469.
34. Casaclang-Verzosa G, Shrestha S, Khalil MJ, et al. Network Tomography for Understanding Phenotypic Presentations in Aortic Stenosis. *JACC Cardiovasc Imaging* **2019**; 12: 236 – 248.
35. Sengupta PP, Shrestha S, Kagiya N, et al. A Machine-Learning Framework to Identify Distinct Phenotypes of Aortic Stenosis Severity. *JACC Cardiovasc Imaging* **2021**; 14: 1707 – 1720.
36. Kwak S, Lee Y, Ko T, et al. Unsupervised Cluster Analysis of Patients with Aortic Stenosis Reveals Distinct Population with Different Phenotypes and Outcomes. *Circ Cardiovasc Imaging* **2020**; 13: e009707.
37. Ribeiro JM, Astudillo P, de Backer O, et al. Artificial Intelligence and Transcatheter Interventions for Structural Heart Disease: A glance at the (near) future. *Trends Cardiovasc Med* **2022**; 32: 153 – 159.
38. Benjamin MM, Rabbat MG. Artificial Intelligence in Transcatheter Aortic Valve Replacement: Its Current Role and Ongoing Challenges. *Diagnostics (Basel)* **2024**; 14: 261.
39. Shameer K, Johnson KW, Glicksberg BS, et al. Machine learning in cardiovascular medicine: are we there yet? *Heart* **2018**; 104: 1156 – 1164.
40. Chang S, Kim H, Suh YJ, et al. Development of a deep learning-based algorithm for the automatic detection and quantification of aortic valve calcium. *Eur J Radiol* **2021**; 137: 109582.
41. Playford D, Bordin E, Mohamad R, et al. Enhanced Diagnosis of Severe Aortic Stenosis Using Artificial Intelligence: A Proof-of-Concept Study of 530,871 Echocardiograms. *JACC Cardiovasc Imaging* **2020**; 13: 1087 – 1090.
42. Poplin R, Varadarajan AV, Blumer K, et al. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. *Nat Biomed Eng* **2018**; 2: 158 – 164.
43. de Jaegere P, Rocatello G, Prendergast BD, et al. Patient-specific computer simulation for transcatheter cardiac interventions: what a clinician needs to know. *Heart* **2019**; 105 (Suppl 2): s21 – s27.
44. Bavo AM, Wilkins BT, Garot P, et al. Validation of a computational model aiming to optimize preprocedural planning in percutaneous left atrial appendage closure. *J Cardiovasc Comput Tomogr* **2020**; 14: 149 – 154.
45. Biaggi P, Sager DF, Külling J, et al. Potential Value of Fusion Imaging and Automated Three-Dimensional Heart Segmentation During Transcatheter Aortic Valve Replacement. *J Am Soc Echocardiogr* **2020**; 33: 516 – 517.
46. Liu J, Al'Aref et al. An augmented reality system for image guidance of transcatheter procedures for structural heart disease. *PLoS One* **2019**; 14: e0219174.
47. Hernandez-Suarez DE, Kim Y, Villablanca P, et al. Machine Learning Prediction Models for In-Hospital Mortality After Transcatheter Aortic Valve Replacement. *JACC Cardiovasc Interv* **2019**; 12: 1328 – 1338.
48. Truong VT, Beyerbach D, Mazur W, et al. Machine learning method for predicting pacemaker implantation following transcatheter aortic valve replacement. *Pacing Clin Electrophysiol* **2021**; 44: 334 – 340.
49. Evertz R, Lange T, Backhaus SJ, et al. Artificial Intelligence Enabled Fully Automated CMR Function Quantification for Optimized Risk Stratification in Patients Undergoing Transcatheter Aortic Valve Replacement. *J Interv Cardiol* **2022**; **2022**: 1368878.
50. Judson G, Luck J, Lawrence S. Predictors of Short Versus Long Length of Stay Among Transcatheter Aortic Valve Replacement Patients Using a Novel Machine Learning Algorithm. *J Am Coll Cardiol* **2023**; 81 (Suppl. S8): 2194.
51. Swamy RS, Lang RM. Echocardiographic quantification of left ventricular mass: prognostic implications. *Curr Cardiol Rep* **2010**; 12: 277 – 282.
52. Cuspidi C, Facchetti R, Bombelli M, et al. Risk of mortality in relation to an updated classification of left ventricular geometric abnormalities in a general population: the Pamela study. *J Hypertens* **2015** ; 33: 2133 – 2140.
53. Karakuş G, Değirmencioglu A, Nanda NC. Artificial intelligence in echocardiography: Review and limitations including epistemological concerns. *Echocardiography* **2022**; 39: 1044 – 1053.
54. Yu F, Huang H, Yu Q, et al. Artificial intelligence-based myocardial texture analysis in etiological differentiation of left ventricular hypertrophy. *Ann Transl Med* **2021**; 9: 108.
55. Phelan D, Collier P, Thavendiranathan P, et al. Relative apical sparing of longitudinal strain using two-dimensional speckle-tracking echocardiography is both sensitive and specific for the diagnosis of cardiac amyloidosis. *Heart* **2012**; 98: 1442 – 1448.
56. Goto S, Mahara K, Beussink-Nelson L, et al. Artificial intelligence-enabled fully automated detection of cardiac amyloidosis using electrocardiograms and echocardiograms. *Nat Commun* **2021**; 12: 2726.
57. Duffy G, Cheng PP, Yuan N, et al. High-Throughput Precision Phenotyping of Left Ventricular Hypertrophy with Cardiovascular Deep Learning. *JAMA Cardiol* **2022**; 7: 386 – 395.
58. Schwefer M, Aschenbach R, Heidemann J, et al. Constrictive pericarditis, still a diagnostic challenge: comprehensive review of clinical management. *Eur J Cardiothorac Surg* **2009**; 36: 502 – 510.
59. Welch TD, Ling LH, Espinosa RE, et al. Echocardiographic diagnosis of

- constrictive pericarditis: Mayo Clinic criteria. *Circ Cardiovasc Imaging* **2014**; 7: 526 – 534.
60. Geske JB, Anavekar NS, Nishimura RA. Differentiation of Constriction and Restriction: Complex Cardiovascular Hemodynamics. *J Am Coll Cardiol* **2016**; 68: 2329 – 2347.
 61. Jain CC, Miranda WR, El Sabbagh A, et al. A Simplified Method for the Diagnosis of Constrictive Pericarditis in the Cardiac Catheterization Laboratory. *JAMA Cardiol* **2022**; 7: 100 – 104.
 62. Talreja DR, Nishimura RA, Oh JK. Constrictive pericarditis in the modern era: novel criteria for diagnosis in the cardiac catheterization laboratory. *J Am Coll Cardiol* **2008**; 51: 315 – 319.
 63. Sengupta PP, Huang YM, Bansal M, et al. Cognitive Machine-Learning Algorithm for Cardiac Imaging: A Pilot Study for Differentiating Constrictive Pericarditis from Restrictive Cardiomyopathy. *Circ Cardiovasc Imaging* **2016**; 9: e004330.
 64. Chao CJ, Jeong J, Arsanjani R, et al. Echocardiography-Based Deep Learning Model to Differentiate Constrictive Pericarditis and Restrictive Cardiomyopathy. *JACC Cardiovasc Imaging* **2024**; 17: 349 – 360.
 65. Laumer F, Di Vece D, Cammann VL, et al. Assessment of Artificial Intelligence in Echocardiography Diagnostics in Differentiating Takotsubo Syndrome from Myocardial Infarction. *JAMA Cardiol* **2022**; 7: 494 – 503.