

Aplicación del aprendizaje automático para la identificación de riesgo y diagnóstico de insuficiencia cardíaca

DOI: 10.5377/alerta.v8i1.17760

Paolo Antoine Vigne Cuellar¹, Daniel Ernesto Morales Maza², José Miguel Gutiérrez Mendoza³, Emilio Jacobo Abullarade Navarrete^{4*}.

1-4. Facultad de Ciencias de la Salud Dr. Luis Edmundo Vásquez, Universidad Dr. José Matías Delgado, Antiguo Cuscatlán, La Libertad, El Salvador.

*Correspondencia

✉ paolovigne@hotmail.com

1.  0000-0002-2433-2566

3.  0009-0000-9085-4584

2.  0009-0000-9101-0092

4.  0000-0003-4898-032X

Resumen

La insuficiencia cardíaca congestiva se ha vuelto un problema de salud pública que aumenta cada año. La reducción del alto costo que esta conlleva se ve limitada por su desarrollo silente durante años antes del diagnóstico, especialmente en personas con alto riesgo cardiovascular y sin control de los factores de riesgo. Nuevos avances tecnológicos como la inteligencia artificial ofrecen soluciones a estas situaciones. Por tanto, en esta revisión narrativa se propone determinar la aplicación del aprendizaje automático para la identificación de riesgo y diagnóstico de insuficiencia cardíaca. La búsqueda se efectuó en inglés y español en las bases de datos PubMed, HINARI, Google Académico y Elsevier con los siguientes términos MeSH: «Artificial intelligence», «Machine Learning», «Algorithm», «Cardiology», «Heart Failure», «Heart Failure/diagnosis», y «Heart Failure/prevention and control». Se incluyeron artículos de revisión bibliográfica, casos y controles, artículos originales, revisiones sistemáticas con metaanálisis de 2018 a 2024, en los idiomas inglés y español. No se utilizó inteligencia artificial en la elaboración de este documento. La inteligencia artificial permite estratificar el riesgo de insuficiencia cardíaca y facilita su diagnóstico oportuno a través del análisis de técnicas de imagen cardíaca.

Palabras clave

Aprendizaje Automático, Insuficiencia Cardíaca, Técnicas de Imagen Cardíaca, Inteligencia Artificial, Aprendizaje Profundo.

Abstract

Congestive heart failure has become a growing public health problem. Reducing the high cost of congestive heart failure is challenging, as it progresses silently for years before diagnosis, especially in people with high cardiovascular risk and who do not control predisposing factors. New technological advances such as artificial intelligence offer solutions to these problems. Therefore, in this narrative review we determine the application of machine learning for risk identification and diagnosis of heart failure. The search was carried out in English and Spanish in the databases PubMed, HINARI, Google Scholar and Elsevier with the following MeSH terms: «Artificial intelligence», «Machine Learning», «Algorithm», «Cardiology», «Heart Failure», «Heart Failure/diagnosis», and «Heart Failure/prevention and control». We considered original articles, meta-analyses, literature reviews, and systematic reviews, including both cases and controls, published within the last seven years. No artificial intelligence was used in the preparation of this document. Artificial intelligence allows for risk assessment of heart failure and facilitates its timely diagnosis through the analysis of cardiac imaging techniques.

Keywords

Machine Learning, Heart Failure, Cardiac Imaging Techniques, Artificial Intelligence, Deep Learning.

Introducción

La insuficiencia cardíaca congestiva (ICC) se ha convertido en un problema de salud pública significativo, ya que el retraso en la

implementación de un tratamiento oportuno puede conducir a un aumento en la morbilidad evitable. Este problema afecta a cerca de 64 millones de personas a nivel mundial y no se limita a una región geográfica específica.



ACCESO ABIERTO

Machine learning for risk assessment and diagnosis of heart failure

Citación recomendada:

Vigne Cuellar PA, Morales Maza DE, Gutiérrez Mendoza JM, Abullarade Navarrete EJ. Aplicación del aprendizaje automático para la identificación de riesgo y diagnóstico de insuficiencia cardíaca. Alerta. 2025;8(1): 113-121. DOI: 10.5377/alerta.v8i1.17760

Editor:

Nadia Rodríguez.

Recibido:

9 de septiembre de 2024.

Aceptado:

7 de enero de 2025.

Publicado:

22 de enero de 2025.

Contribución de autoría:

PAVC¹: búsqueda bibliográfica, manejo de datos o software y recolección de datos. DEMM²: concepción del estudio, búsqueda bibliográfica y redacción, revisión y edición. JMGM³: diseño del manuscrito oncepción del estudio, búsqueda bibliográfica y redacción, revisión y edición. EJAN⁴: Redacción, revisión y edición.

Conflicto de intereses:

Los autores declaran no tener conflicto de intereses.



© 2025 por los autores. Este es un artículo de acceso abierto distribuido bajo los términos y condiciones de la licencia Creative Commons Attribution (CC BY) (<https://creativecommons.org/licenses/by/4.0/>).

No obstante, su impacto es particularmente grave en los países desarrollados, donde el envejecimiento, el aumento de factores de riesgo cardiovascular y la mejora en la supervivencia de enfermedades como el infarto de miocardio han aumentado la prevalencia de ICC. Este incremento en la supervivencia se debe a avances terapéuticos, como la intervención coronaria percutánea y el uso de betabloqueantes. En estos países, la incidencia de la ICC se estima entre el 1-2 % en la población generalⁱⁱ.

Un ejemplo específico es Estados Unidos, en donde según Van Nuys, *et al.*, la prevalencia de personas de 65-70 años con ICC aumentará de 4,3 % en el 2012 a 8,5 % en el 2030ⁱⁱⁱ. La ICC conlleva un elevado costo económico debido a que 83,7 % de las consultas de emergencia terminan en ingresos hospitalarios^{iv}. En el 2012, el costo estimado fue de 30,7 mil millones de dólares americanos. Este incrementará para el 2030 a 69,8 mil millones de dólares americanos^v.

La reducción del costo económico y social de esta enfermedad se ve limitada por el progreso de la disfunción cardíaca durante años antes del diagnóstico de ICC^{vi}. Esto se puede observar en el *National Health Service* del Reino Unido, donde el 80 % de los casos son diagnosticados en hospitales, a pesar de que el 40 % de los pacientes tienen síntomas que deberían haberse explorado en una evaluación temprana^{vii}.

Actualmente, los métodos para la detección temprana de exacerbaciones y deterioro de la función cardíaca se basan en algoritmos diagnósticos y modelos predictivos. Estos se emplean en el monitoreo ambulatorio de parámetros clínicos, tanto de forma continua como intermitente. Estos algoritmos se basan en parámetros fisiológicos como presión arterial, saturación de oxígeno, frecuencia cardíaca y peso. Entre estos, muy pocos logran alcanzar una sensibilidad y especificidad superior al 80 %^{viii}. Teniendo esto en cuenta, existen tecnologías emergentes que buscan mejorar estas estadísticas.

La inteligencia artificial (IA) permite el análisis de grandes bases de datos y mejora la eficiencia con la que se interpretan patrones^{ix,x}. El aprendizaje automático investiga cómo las computadoras pueden aprender a partir de datos. Este es una subrama de la inteligencia artificial, que a su vez es una rama de la ciencia computacional^{xii,xiii}. Estas tecnologías se utilizan en diferentes métodos de análisis. En el caso de métodos descriptivos se utiliza el aprendizaje automático no supervisado, mientras que los métodos predictivos se asocian al uso de aprendizaje automático supervisado^{xiii,xiv}.

Desde 1960 se han estudiado algoritmos para el diagnóstico de cardiopatías congénitas^{xv}. En esta línea de investigación, el aprendizaje automático se ha utilizado para la creación de calculadoras de riesgo cardiovascular, la lectura de estudios imagenológicos y para identificar eventos isquémicos agudos^{xvi,xvii}. Además, este ha facilitado la interpretación de múltiples hallazgos clínicos^{xviii}.

Existe una gran variedad de estudios sobre el tema, sobre todo en cardiología. Quer, *et al.*, evidencian el creciente interés que el aprendizaje automático ha tenido. Se han publicado más de 3000 artículos combinados en PubMed, arXiv y bioRxiv (servidores de preimpresión de acceso abierto) durante 2015-2020. Además, en 2020, una de cada mil publicaciones en PubMed se relacionaba con la inteligencia artificial y/o aprendizaje automático en cardiología^{xix}.

El estudio de las cardiopatías, en particular de la insuficiencia cardíaca, se han beneficiado enormemente de estas tecnologías. Estas se pueden aplicar en todos los niveles de atención y permiten identificar alteraciones en el gasto cardíaco incluso antes que el diagnóstico ecocardiográfico convencional^{xx}.

Se realizó una revisión bibliográfica sobre la utilización del aprendizaje automático en insuficiencia cardíaca, para esto fueron incluidos estudios originales y artículos de revisión cuya fecha de publicación no excediera los 7 años. No se utilizó inteligencia artificial en la elaboración de este documento. La búsqueda se efectuó en inglés y español en las bases de datos, PubMed, HINARI, Google Académico y Elsevier con los términos MeSH: «Artificial intelligence», «Machine Learning», «Algorithm», «Cardiology», «Heart Failure», «Heart Failure/diagnosis», y «Heart Failure/prevention and control». El objetivo fue determinar la aplicación del aprendizaje automático para la identificación de riesgo y diagnóstico de insuficiencia cardíaca.

Discusión

Generalidades del aprendizaje automático y su uso en cardiología

El aprendizaje automático, una rama de la inteligencia artificial, busca imitar e incluso superar la capacidad cognitiva humana para reconocer patrones y tendencias en una serie de datos. Esto se logra mediante sistemas que aprenden de manera autónoma a través de la exposición repetida a datos.

Recientemente, la aplicación de esta tecnología en cardiología ha demostrado potencial en aplicaciones clínicas como el

diagnóstico precoz de ICC, la predicción de riesgo, pronóstico, lectura acertada de estudios electrofisiológicos e imágenes cardiológicas, optimización de atención, tratamiento y monitoreo de pacientes^{xxi}.

El aprendizaje automático se puede subdividir en aprendizaje supervisado y no supervisado, según la presencia o ausencia de etiquetas en los datos utilizados para entrenar el modelo, es decir, si se conoce (supervisado) o no (no supervisado) las variables predictoras y de resultado. Los modelos no supervisados, a su vez se clasifican en modelos de reducción de dimensionalidad como el Análisis de Componentes Principales (ACP) y modelos de clasificación, como el clustering o agrupamiento.

El clustering, consiste en agrupar datos en categorías o clústeres, de modo que los elementos dentro de un mismo grupo sean más similares entre sí que con los de otros grupos, permitiendo la detección de subgrupos de pacientes con características comunes, fenómenos genéticos o patrones epidemiológicos similares. En contraste, los modelos supervisados, se clasifican en modelos de regresión y clasificación. Los modelos de regresión, como la regresión lineal, se utilizan cuando la variable objetivo es continua, mientras que los modelos de clasificación, como la regresión logística, los árboles de decisión (decisión tres) y los bosques aleatorios (random forest), se emplean cuando la variable objetivo es categórica. Ambos tipos de modelos aprenden a partir de datos etiquetados para predecir o clasificar eventos, estableciendo relaciones entre las variables predictoras y la variable de resultado^{xxii}.

La utilización de un modelo u otro dependerá de la complejidad del problema a resolver o la necesidad de mayor precisión.

Otra rama del aprendizaje automático es el aprendizaje profundo que utiliza múltiples redes neuronales para encontrar patrones más complejos en datos más extensos. Se inspira en la neurobiología humana y tiene la habilidad de aprender a través de diversas experiencias. La mayoría de los estudios que se basan en el uso de aprendizaje automático utilizan estos modelos para integrar información y crear algoritmos que se analizan según los objetivos del estudio.

El funcionamiento básico de una red neuronal se observa en la Figura 1 y consiste de una capa de entrada que representa las variables a estudiar, una o más capas ocultas, que analizan dichas variables, cuyo número tanto de capas como de neuronas a utilizar, depende de la complejidad del análisis, y una capa de salida que produce el resultado final del análisis^{xxiii}.

Actualmente existe controversia sobre el uso de herramientas potenciadas por inteligencia artificial debido a los problemas ético-legales que la recopilación de información personal sin regulaciones produce^{xxiv}.

Sin embargo, la reducción de la mortalidad de enfermedades cardiovasculares ha sido uno de los principales objetivos en las últimas décadas por lo cual la integración de estas tecnologías ha despertado mucho interés.

Entre los usos con mayor interés se encuentra la capacidad de interpretar estudios de imágenes cardiológicas de alta complejidad^{xxv}. Por ejemplo, Narula, *et al.*, utilizaron bases de datos de un estudio tipo cohorte con 62 casos verificados de cardiopatía hipertrófica (HCM) y 77 casos verificados de corazón fisiológicamente hipertrófico en atletas de alto rendimiento (ATH).

Describen un modelo combinado de redes neuronales, bosque aleatorio y aprendizaje no supervisado capaz de dife-




Figura 1: Funcionamiento básico de una red neuronal

reñciar ATH y HCM según parámetros ecocardiográficos con sensibilidad de 96 % y especificidad de 77 %, superiores o iguales a la relación entre la velocidad transmitral diastólica temprana y tardía (sensibilidad = 79 %, especificidad = 77 %; $p < 0,01$)^{xxvi}. La velocidad transmitral diastólica temprana y tardía son medidas clave en la ecocardiografía para evaluar la función diastólica del corazón, es decir, cómo se relaja y llena de sangre el ventrículo izquierdo entre latidos. De igual forma, se han comparado modelos para diferenciar entre pericarditis constrictiva y cardiomiopatía restrictiva donde se observó una curva positiva de aprendizaje en todos los modelos supervisados utilizados, teniendo una exactitud diagnóstica promedio de hasta 93,7 %^{xxvii}.

Además, el aprendizaje automático ha mostrado su utilidad en lecturas complejas de estudios nucleares. Otaki, *et al.*, utilizaron un modelo de aprendizaje profundo investigando la predicción de arteriopatía coronaria obstructiva mediante el uso de tomografía computarizada por emisión de fotón único de perfusión miocárdica (SPECT, por sus siglas en inglés) en 3578 pacientes. El modelo se comparó con el déficit de perfusión total (DPT) y la opinión de un experto. El modelo de aprendizaje profundo tuvo un área bajo la curva (AUC) superior (AUC 0,83; IC 95 % 0,82-0,85) que el DPT (AUC 0,78; IC 95 % 0,77-0,80) o el lector experto (AUC 0,71; IC 95 % 0,69-0,72; $p < 0,01$ para ambos) para la detección de arteriopatías coronarias obstructivas^{xxviii}.

Adicionalmente, llama la atención el uso de estas tecnologías en la electrofisiología. Actualmente es posible acoplar sistemas de electrocardiograma (ECG) portátiles con sistemas de aprendizaje automático en teléfonos inteligentes para el manejo ambulatorio de fibrilaciones auriculares^{xxix}. Además, se puede utilizar para la identificación de disfunción ventricular izquierda en el ECG. Attia, *et al.*, utilizaron métodos de aprendizaje profundo y analizaron ECG de 52 870 pacientes posterior al entrenamiento del modelo. Este modelo proporcionó un alto grado de discriminación entre fracción de eyección ≤ 35 % con una AUC de 0,93, al examinar únicamente el ECG^{xxx}.

El aprendizaje automático permite realizar el diagnóstico, y facilita la agrupación de pacientes por fenotipos basados en biomarcadores moleculares para la creación de calculadoras inteligentes^{xxxi}. Ambale-Venkatesh, *et al.*, demuestran que la predicción de eventos cardiovasculares mediante técnicas de bosques de supervivencia aleatorios (RSF) que incluyen biomarcadores y medidas de enfermedad subclínica, es superior

a las escalas de AHA/ASCVD y Framingham con índices de concordancia más altos (0,80 vs 0,73 vs 0,73, respectivamente) y puntajes de Brier más bajos (0,079 vs 0,11 vs 0,089, respectivamente). La implementación de estas calculadoras, tiene el objetivo de optimizar algoritmos de tratamiento para brindar cuidados altamente precisos, de calidad e individualizados^{xxxii}.

Aprendizaje automático y riesgo de insuficiencia cardíaca

El aprendizaje automático y la inteligencia artificial pueden utilizarse para analizar datos y, a partir de ellos, hacer predicciones o inferencias sobre características, comportamientos o tendencias de una población completa, basándose en una muestra de esos datos. Dichos sistemas pueden ser altamente útiles en distintos campos de la medicina. Un campo en donde se ha observado un creciente desarrollo es la cardiología, especialmente en patologías como la insuficiencia cardíaca, en donde dichos modelos se están utilizando para la determinación del riesgo y de complicaciones^{xxxiii}.

La insuficiencia cardíaca al ser una enfermedad multifactorial puede estudiarse desde dos perspectivas. La perspectiva clínica, la cual abarca bases de datos de dispositivos usables, historias clínicas, imagenología y electrocardiografía. Y la perspectiva genética, la cual se centra en el análisis de transcriptomas, genómica y proteómica. En ambas pueden ser de utilidad algoritmos de aprendizaje automático^{xxxiv,xxxv}.

Debido a la complejidad que supone la insuficiencia cardíaca, los clínicos se encuentran ante la necesidad de herramientas que faciliten la toma de decisiones. Angraal, *et al.*, utilizaron data del ensayo TOPCAT (*treatment of preserved ejection cardiac function with an aldosterone antagonist*) en donde se utilizaron cuatro modelos de aprendizaje automático y uno de regresión logística. Estos modelos fueron entrenados para evaluar la mortalidad y hospitalización de pacientes con insuficiencia cardíaca con fracción de eyección preservada. El modelo con mejor rendimiento para la predicción de hospitalización fue el de bosques aleatorios con una AUC de 0,72 para mortalidad y de 0,76 para hospitalización. Esto muestra una alta fidelidad al estratificar datos como modelos de predicción probabilística^{xxxvi}.

Mortazavi, *et al.*, utilizaron modelos similares para analizar la readmisión de pacientes con insuficiencia cardíaca a través de datos de telemedicina. Se comparó la predicción de readmisión mediante la evaluación por ecocardiografía de la fracción de eyección

con un modelo de análisis de datos con aprendizaje automático. Se evidenció que, al utilizar algoritmos de aprendizaje automático, hubo un mayor valor predictivo en el modelo de bosques aleatorios (AUC 0,628 frente a 0,533) y en el modelo de regresión logística (AUC 0,678 en contraste a 0,543)^{xxxvii}.

Además, Banerjee, *et al.*, realizaron un estudio en donde se recolectaron datos del sistema de salud del Reino Unido. Se conformaron cinco grupos para el análisis predictivo del desarrollo de insuficiencia cardíaca y mortalidad en un año, dichos grupos eran: de inicio temprano, de inicio tardío, relacionado a fibrilación atrial, metabólico y cardiometabólico.

Se utilizó un modelo de bosques aleatorios supervisado utilizando variables continuas que se traslapan entre las agrupaciones. Este modelo mostró un buen valor predictivo de mortalidad en un año para aquellos pacientes con insuficiencia cardíaca de inicio temprano (estadística- c 0,68; IC 95 % 0,65-0,71), pacientes con patologías metabólicas (AUC 0,71, IC 95 % 0,70-0,73) y pacientes con patologías cardiometabólicas (AUC 0,68; IC 95 % 0,65-0,70)^{xxxviii}.

Estos datos pueden ser comparados al modelo creado por Kwon, *et al.*, el cual consiste en un algoritmo de aprendizaje profundo. El objetivo de este era predecir la mortalidad de pacientes con insuficiencia cardíaca. Durante los test de rendimiento, dicho algoritmo logró una AUC de 0,88 para predecir mortalidad intrahospitalaria. Además, logró predecir pacientes con alto riesgo, en cuanto supervivencia posterior al alta ($p < 0,001$)^{ixl}.

El análisis transcripcional y genómico de la insuficiencia cardíaca es otro campo en donde se ha aplicado el aprendizaje automático. Venkat *et al.*, utilizaron secuenciación de ARN y un algoritmo de maximización de expectativa para identificar transcritomas de novo. A partir de estos datos se realizó un análisis de regresión a través de un modelo de bosque aleatorio. Luego se integraron los datos de expresión génica a un algoritmo con capacidades de diagnóstico clínico. Usando este algoritmo se logró establecer una relación proporcional entre el desarrollo de insuficiencia cardíaca y edad ($R = 0,8$), género ($R = 0,14$) y raza ($R = 0,06$). A partir de estos datos se realizó una correlación genómica en la cual se identificó que el gen NR3 α 2 tenía un alto valor predictivo (0,52)^{xli}.

Por otro lado, Yang, *et al.*, utilizaron herramientas de mapeo genético para identificar los polimorfismos de nucleótido único (PNUs) que tenían un mayor valor predictivo para el desarrollo de insuficiencia cardíaca.

En este estudio se utilizaron tres algoritmos supervisados para identificar PNU específicos. Usando aprendizaje automático se identificaron 20 PNUs que se repetían frecuentemente. Usando tres algoritmos de aprendizaje automático se determinó que el algoritmo de máquinas de vectores de soporte tenía el mejor rendimiento a la hora de determinar si un paciente estaba en estadio A o B de insuficiencia cardíaca (AUC 0,931 y tasa de rendimiento de 0,899)^{xli}.

Aprendizaje automático para diagnóstico de insuficiencia cardíaca

Uno de los pilares del diagnóstico de la insuficiencia cardíaca es la evaluación de la fracción de eyección mediante ecocardiografía. Sin embargo, determinar la fracción de eyección mediante un trazado manual toma tiempo y es dependiente del operador. Asimismo, la evaluación visual de esta es inherentemente subjetiva, por lo cual nuevas iniciativas han buscado utilizar el aprendizaje automático. Ouyang *et al.*, crearon EchoNet-Dynamic un algoritmo basado en aprendizaje profundo que permite calcular la fracción de eyección a partir de videos de ecocardiogramas. En una base de datos a la cual no se le había expuesto durante su entrenamiento el algoritmo logró clasificar la insuficiencia cardíaca con fracción de eyección reducida (AUC de 0,97)^{xlii}.

No obstante, la interpretación automatizada se extiende más allá de parámetros ecocardiográficos de rutina. Actualmente se busca identificar características ligadas a diferentes cardiopatías, las cuales son sutiles y difíciles de identificar. Zhang, *et al.*, crearon un modelo *black-box* basado en aprendizaje profundo para identificar tres enfermedades (cardiomiopatía hipertrófica, amiloidosis cardíaca e hipertensión arterial) a través de hallazgos ecocardiográficos. Se utilizó una cohorte de pacientes con cardiomiopatía hipertrófica y controles para evaluar este modelo. La inteligencia artificial logró identificar a pacientes con cardiomiopatía hipertrófica con un AUC de 0,93 (95 % IC, 0,91-0,94)^{xliii}. Debido a que en los modelos *black-box* el proceso de derivación y selección de variables es manejado completamente por el algoritmo de entrenamiento, un análisis posterior es necesario para entender su funcionamiento. En el caso de la cardiomiopatía hipertrófica dos características fueron asociadas al proceso patológico por la inteligencia artificial. Estas fueron una mayor masa auricular izquierda ($p = 0,01$) y una mayor masa ventricular izquierda ($p = 0,001$)^{xliiv}.

Otra de las funciones de la ecocardiografía es determinar la función diastólica. Con los algoritmos actuales, muchos pacientes son clasificados con función diastólica indeterminada, es decir, su función cardíaca no puede definirse como normal o anormal debido a falta de información o medidas contradictorias. Esto limita la utilidad clínica de los resultados para la toma de decisiones^{xiv}.

Pandey *et al.*, crearon una inteligencia artificial con el fin de evaluar la función diastólica a través de parámetros ecocardiográficos. Esta se utilizó en una cohorte de pacientes sometidos tanto a ecocardiografía como a mediciones invasivas de la presión de llenado del ventrículo izquierdo. El modelo logró predecir una elevada presión de llenado del ventrículo izquierdo mejor que las guías clínicas de la Asociación Americana de Ecocardiografía (AUC 0,88 vs 0,67). Además, separó a dichos pacientes en dos grupos (alto y bajo riesgo)^{xvi}.

Por otro lado, el aprendizaje automatizado se ha utilizado para valorar la función del ventrículo derecho. Beecy *et al.*, crearon una inteligencia artificial capaz de medir la circunferencia del anillo tricuspídeo a través de ecografía 2D. Este modelo identificó de manera consistente la insuficiencia cardíaca derecha definida por resonancia magnética cardíaca a través de índices como el desplazamiento lineal del anillo tricuspídeo (AUC 0,69, IC 95 % 0,63-0,76). Este rendimiento es similar al de los índices ecográficos convencionales de insuficiencia cardíaca como desplazamiento sistólico del anillo tricuspídeo (TAPSE) (AUC 0,80, IC 95 % 0,73-0,86) y S' (AUC 0,78, IC 95 % 0,71-0,85)^{xvii}.

Este tipo de modelos también se ha aplicado a ecografía 3D. Genovese *et al.*, probaron una inteligencia artificial capaz de valorar la función y tamaño del ventrículo derecho. Se evaluó su uso en 56 pacientes referidos por indicación clínica a resonancia magnética cardíaca. El modelo requirió de edición del contorno endocárdico post procesamiento en 68 % de los pacientes, lo cual prolongó el tiempo de análisis de un promedio de 15 segundos a 114 segundos. Con estos ajustes, el volumen del ventrículo derecho y las mediciones de la fracción de eyección fueron precisas en comparación con la resonancia magnética cardíaca de referencia (fracción de eyección de ventrículo derecho, sesgo-3,3 % +/- 5,2 %)^{xviii}.

Otra de las modalidades de imagen beneficiada es la resonancia magnética cardíaca (RMC) que permite evaluar la función ventricular y caracterizar el tejidoⁱⁱ. La segmentación en RMC es un proceso tedioso que se ha intentado automatizar con inteligencia artificial.

Davis *et al.*, crearon un modelo entrenado en 1923 resonancias. Este realizó el proceso de segmentación en 20 segundos a comparación de los 13 minutos que le tomó a los médicos. Se encontraron errores en la segmentación automatizada de 72 imágenes de una base de datos de 34 486. Estos errores ocurrieron en patologías raras no encontradas en el entrenamiento de la inteligencia artificialⁱ.

Una de las ventajas de la RMC es la caracterización del tejido. Actualmente, esta se realiza mediante la captación tardía de gadolinio. Zhang *et al.* usaron inteligencia artificial para crear «Virtual native enhancement images» (VNE) a partir de mapeos T1 pre-contraste e imágenes cine.

Operadores experimentados evaluaron la calidad de imagen, la concordancia visoespacial y la cuantificación de la lesión miocárdica de imágenes obtenidas con captación tardía de gadolinio y VNE. Los operadores consideraron que la calidad de imagen fue significativamente mejor con VNE (n = 345 conjuntos de datos; p < 0,001 [prueba de Wilcoxon]). Además, la concordancia entre estos dos métodos para la extensión de la fibrosis miocárdica fue alta (r = 0,77-0,79 para lesiones hiperintensas, r = 0,70-0,76 para lesiones de intensidad intermedia)^{li}.

Conclusión

El aprendizaje automático representa una herramienta con un gran potencial en el manejo de la insuficiencia cardíaca, particularmente en la identificación de riesgos y el diagnóstico temprano mediante el análisis avanzado de datos clínicos e imagenológicos. Los estudios revisados evidencian su capacidad para mejorar la precisión diagnóstica y optimizar los modelos predictivos, lo que puede contribuir a una atención más eficiente y a la detección oportuna de complicaciones.

Sin embargo, su implementación en la práctica clínica enfrenta importantes retos, como la disponibilidad de bases de datos representativas, el entrenamiento adecuado de los modelos y la necesidad de validaciones externas para garantizar su aplicabilidad en diversos contextos. Además, cuestiones éticas y regulatorias deben abordarse para asegurar el uso responsable de estas tecnologías en beneficio de los pacientes.

En síntesis, aunque los avances descritos son alentadores, es necesario seguir investigando y evaluando el aprendizaje automático en escenarios clínicos reales, con el objetivo de establecer su rol definitivo como complemento en la atención de la insuficiencia cardíaca.

Agradecimientos

A la Universidad Dr. José Matías Delgado por su apoyo académico durante la elaboración del manuscrito.

Financiamiento

No se recibieron recursos directa o indirectamente para realizar el trabajo de investigación.

Referencias bibliográficas

- i. Groenewegen A, Rutten FH, Mosterd A, Hoes AW. Epidemiology of heart failure. *Eur J Heart Fail.* 2020;22:1342-1356. DOI: [10.1002/ehf.1858](https://doi.org/10.1002/ehf.1858)
- ii. Riccardi M, Sammartino AM, Piepoli M, Adamo M, Pagnesi M, Rosano G, *et al.* Heart failure: an update from the last years and a look at the near future. *ESC Heart Fail.* 2022;9:3667-3693. DOI: [10.1002/ehf2.14257](https://doi.org/10.1002/ehf2.14257)
- iii. Roger VL. Epidemiology of Heart Failure. *Circ Res.* 2021;128:1421-1434. DOI: [10.1161/CIRCRESAHA.121.318172](https://doi.org/10.1161/CIRCRESAHA.121.318172)
- iv. Urbich M, Globe G, Pantiri K, Heisen M, Bennisson C, Wirtz HS, *et al.* A Systematic Review of Medical Costs Associated with Heart Failure in the USA (2014-2020). *PharmacoEconomics.* 2020;38:1219-1236. DOI: [10.1007/s40273-020-00952-0](https://doi.org/10.1007/s40273-020-00952-0)
- v. Savarese G, Moritz Becher P, Lund LH, Seferovic P, Rosano GMC, Coats AJS. Global burden of heart failure: a comprehensive and updated review of epidemiology. *Cardiovascular Research.* 2022;118,17:3272-3287. DOI: [10.1093/cvr/cvac013](https://doi.org/10.1093/cvr/cvac013)
- vi. Cleland JGF, Pellicori P, González A. A novel treatment for heart failure targets myocardial fibrosis. *Nat Med.* 2021;27:1343-1344. DOI: [10.1038/s41591-021-01457-9](https://doi.org/10.1038/s41591-021-01457-9)
- vii. Bottle A, Kim D, Aylin P, Cowie MR, Majeed A, Hayhoe B. Routes to diagnosis of heart failure: observational study using linked data in England. *Heart Br Card Soc.* 2018;104(7):600-5. DOI: [10.1136/heartjnl-2017-312183](https://doi.org/10.1136/heartjnl-2017-312183)
- viii. Gálvez-Barrón C, Pérez-López C, Villar-Álvarez F, Ribas J, Formiga F, Chivite D, *et al.* Machine learning for the development of diagnostic models of decompensated heart failure or exacerbation of chronic obstructive pulmonary disease. *Sci Rep.* 2023;13:12709. DOI: [10.1038/s41598-023-39329-6](https://doi.org/10.1038/s41598-023-39329-6)
- ix. Liu P, Lu L, Zhang J, Huo T, Liu S, Ye Z. Application of Artificial Intelligence in Medicine: An Overview. *Curr Med Sci.* 2021;41:1105-1115. DOI: [10.1007/s11596-021-2474-3](https://doi.org/10.1007/s11596-021-2474-3)
- x. Manickam P, Mariappan S, Murugesan S, Hansda S, Kaushik A, Shinde R, *et al.* Artificial Intelligence (AI) and Internet of Medical Things (IoMT) Assisted Biomedical Systems for Intelligent Healthcare. *Biosensors.* 2022;12:562. DOI: [10.3390/bios12080562](https://doi.org/10.3390/bios12080562)
- xi. Sarker IH. Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *Sn Comput Sci.* 2021;2:420. DOI: [10.1007/s42979-021-00815-1](https://doi.org/10.1007/s42979-021-00815-1)
- xii. Sarker IH. AI-Based Modeling: Techniques, Applications and Research Issues Towards Automation, Intelligent and Smart Systems. *Sn Comput Sci.* 2022;3. DOI: [10.1007/s42979-022-01043-x](https://doi.org/10.1007/s42979-022-01043-x)
- xiii. Jiang T, Gradus JL, Rosellini AJ. Supervised machine learning: A brief primer. *Behav Ther.* 2020;51:675-687. DOI: [10.1016/j.beth.2020.05.002](https://doi.org/10.1016/j.beth.2020.05.002)
- xiv. Eckhardt CM, Madjarova SJ, Williams RJ, Ollivier M, Karlsson J, Pareek A, Nwachukwu BU. Unsupervised machine learning methods and emerging applications in healthcare. *Knee Surg Sports Traumatol Arthrosc.* 2023;31:376-381. DOI: [10.1007/s00167-022-07233-7](https://doi.org/10.1007/s00167-022-07233-7)
- xv. Toronto AF, Veasy LG, Warner HR. Evaluation of a computer program for diagnosis of congenital heart disease. *Prog Cardiovasc Dis.* 1963;5:362-377. DOI: [10.1016/S0033-0620\(63\)80005-5](https://doi.org/10.1016/S0033-0620(63)80005-5)
- xvi. You J, Guo Y, Kang J-J, Wang H-F, Yang M, Feng J-F, *et al.* Development of machine learning-based models to predict 10-year risk of cardiovascular disease: a prospective cohort study. *Stroke Vasc Neurol.* 2023;8. DOI: [10.1136/svn-2023-002332](https://doi.org/10.1136/svn-2023-002332)
- xvii. Doudesis D, Lee KK, Boeddinghaus J, Bularga A, Ferry AV, Tuck C, *et al.* Machine learning for diagnosis of myocardial infarction using cardiac troponin concentrations. *Nat Med.* 2023;29:1201-1210. DOI: [10.1038/s41591-023-02325-4](https://doi.org/10.1038/s41591-023-02325-4)
- xviii. Jayatilake SMDAC, Ganegoda GU. Involvement of Machine Learning Tools in Healthcare Decision Making. *J Healthc Eng.* 2021;2021:6679512. DOI: [10.1155/2021/6679512](https://doi.org/10.1155/2021/6679512)
- xix. Quer G, Arnaout R, Henne M, Arnaout R. Machine Learning and the Future of Cardiovascular Care: JACC State-of-the-Art Review. *J Am Coll Cardiol.* 2021;77:300-313. DOI: [10.1016/j.jacc.2020.11.030](https://doi.org/10.1016/j.jacc.2020.11.030)
- xx. Rushlow DR, Croghan IT, Inselman JW, Thacher TD, Friedman PA, Yao X, *et al.* Clinician Adoption of an Artificial Intelligence Algorithm to Detect Left Ventricular Systolic Dysfunction in Primary Care. *Mayo Clin Proc.* 2022;97:2076-2085. DOI: [10.1016/j.jmayocp.2022.04.008](https://doi.org/10.1016/j.jmayocp.2022.04.008)
- xxi. Komuro J, Kusumoto D, Hashimoto H, Yuasa S. Machine learning in cardiology: Clinical application and basic research. *Journal of Cardiology.* 2023;82(2):128-33. DOI: [10.1016/j.jjcc.2023.04.020](https://doi.org/10.1016/j.jjcc.2023.04.020)

- xxii. Bradley AJ, Ghawanmeh M, Govi AM, Covas P, Panjath G, Choi AD. Emerging Roles for Artificial Intelligence in Heart Failure Imaging. *Heart Fail Clin*. 2023;19:531-543. DOI: [10.1016/j.hfc.2023.03.005](https://doi.org/10.1016/j.hfc.2023.03.005)
- xxiii. Lopez-Jimenez F, Attia Z, Arruda-Olson AM, Carter R, Chareonthaitawee P, Jouni H, *et al*. Artificial Intelligence in Cardiology: Present and Future. *Mayo Clin Proc*. 2020;95:1015-1039. DOI: [10.1016/j.mayocp.2020.01.038](https://doi.org/10.1016/j.mayocp.2020.01.038)
- xxiv. Sung J. Artificial intelligence in medicine: Ethical, social and legal perspectives. *Annals of the Academy of Medicine, Singapore*. el 28 de diciembre de 2023;52(12). DOI: [10.47102/annals-acadmedsg.2023103](https://doi.org/10.47102/annals-acadmedsg.2023103)
- xxv. Bluemke DA, Kawel-Boehm N. Artificial Intelligence: Evaluating All Imaging for Cardiovascular Disease. *J Am Heart Assoc*. 2021;10:e021540. DOI: [10.1161/JAHA.121.021540](https://doi.org/10.1161/JAHA.121.021540)
- xxvi. Narula S, Shameer K, Salem Omar AM, Dudley JT, Sengupta PP. Machine-Learning Algorithms to Automate Morphological and Functional Assessments in 2D Echocardiography. *J Am Coll Cardiol*. 2016;68:2287-2295. DOI: [10.1016/j.jacc.2016.08.062](https://doi.org/10.1016/j.jacc.2016.08.062)
- xxvii. Sengupta PP, Huang Y-M, Bansal M, Ashrafi A, Fisher M, Shameer K, *et al*. A Cognitive Machine Learning Algorithm for Cardiac Imaging: A Pilot Study for Differentiating Constrictive Pericarditis from Restrictive Cardiomyopathy. *Circ Cardiovasc Imaging*. 2016;9:e004330. DOI: [10.1161/CIRCIMAGING.115.004330](https://doi.org/10.1161/CIRCIMAGING.115.004330)
- xxviii. Otaki Y, Singh A, Kavanagh P, Miller RJH, Parekh T, Tamarappoo BK, *et al*. Clinical Deployment of Explainable Artificial Intelligence of SPECT for Diagnosis of Coronary Artery Disease. *JACC Cardiovasc Imaging*. 2022;15:1091-1102. DOI: [10.1016/j.jcmg.2021.04.030](https://doi.org/10.1016/j.jcmg.2021.04.030)
- xxix. Shao M, Zhou Z, Bin G, Bai Y, Wu S. A Wearable Electrocardiogram Telemonitoring System for Atrial Fibrillation Detection. *Sensors*. 2020;20:606. DOI: [10.3390/s20030606](https://doi.org/10.3390/s20030606)
- xxx. Attia ZI, Kapa S, Lopez-Jimenez F, McKie PM, Ladewig DJ, Satam G, Pellikka PA, *et al*. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nat Med*. 2019;25:70-74. DOI: [10.1038/s41591-018-0240-2](https://doi.org/10.1038/s41591-018-0240-2)
- xxxi. Johnson KW, Shameer K, Glicksberg BS, Readhead B, Sengupta PP, Björkegren JLM, *et al*. Enabling Precision Cardiology Through Multiscale Biology and Systems Medicine. *JACC Basic Transl Sci*. 2017;2:311-327. DOI: [10.1016/j.jacbts.2016.11.010](https://doi.org/10.1016/j.jacbts.2016.11.010)
- xxxii. Ambale-Venkatesh B, Yang X, Wu CO, Liu K, Hundley WG, McClelland R, *et al*. Cardiovascular Event Prediction by Machine Learning. *Circ Res*. 2017;121:1092-1101. DOI: [10.1161/CIRCRESAHA.117.311312](https://doi.org/10.1161/CIRCRESAHA.117.311312)
- xxxiii. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to Machine Learning, Neural Networks, and Deep Learning. *Transl Vis Sci Technol*. 2020; 9:14. Disponible en: <https://pmc.ncbi.nlm.nih.gov/articles/PMC7347027/pdf/tvst-9-2-14.pdf>
- xxxiv. Fu Y, Eisen HJ. Genetics of Dilated Cardiomyopathy. *Curr Cardiol Rep*. 2018;20:121. DOI: [10.1007/s11886-018-1061-0](https://doi.org/10.1007/s11886-018-1061-0)
- xxxv. Lanzer JD, Leuschner F, Kramann R, Levinson RT, Saez-Rodriguez J. Big Data Approaches in Heart Failure Research. *Curr Heart Fail Rep*. 2020;17:213-224. DOI: [10.1007/s11897-020-00469-9](https://doi.org/10.1007/s11897-020-00469-9)
- xxxvi. Angraal S, Mortazavi BJ, Gupta A, Khera R, Ahmad T, Desai NR, *et al*. Machine Learning Prediction of Mortality and Hospitalization in Heart Failure With Preserved Ejection Fraction. *JACC Heart Fail*. 2020;8:12-21. DOI: [10.1016/j.jchf.2019.06.013](https://doi.org/10.1016/j.jchf.2019.06.013)
- xxxvii. Mortazavi BJ, Downing NS, Bucholz EM, Dharmarajan K, Manhapra A, Li S-X, *et al*. Analysis of Machine Learning Techniques for Heart Failure Readmissions. *Circ Cardiovasc Qual Outcomes*. 2016;9:629-640. DOI: [10.1161/CIRCOUTCOMES.116.003039](https://doi.org/10.1161/CIRCOUTCOMES.116.003039)
- xxxviii. Banerjee A, Dashtban A, Chen S, Pasea L, Thygesen JH, Fatemifar G, *et al*. Identifying subtypes of heart failure from three electronic health record sources with machine learning: an external, prognostic, and genetic validation study. *The Lancet Digital Health*. 2023;5(6):e370-9. DOI: [10.1016/S2589-7500\(23\)00065-1](https://doi.org/10.1016/S2589-7500(23)00065-1)
- xxxix. Kwon J myoung, Kim KH, Jeon KH, Lee SE, Lee HY, Cho HJ, *et al*. Artificial intelligence algorithm for predicting mortality of patients with acute heart failure. *Abete P, editor. PLoS ONE*. 2019;14(7):e0219302. DOI: [10.1371/journal.pone.0219302](https://doi.org/10.1371/journal.pone.0219302)
- xl. Venkat V, Abdelhalim H, DeGroat W, Zeeshan S, Ahmed Z. Investigating genes associated with heart failure, atrial fibrillation, and other cardiovascular diseases, and predicting disease using machine learning techniques for translational research and precision medicine. *Genomics*. 2023;115:110584. DOI: [10.1016/j.ygeno.2023.110584](https://doi.org/10.1016/j.ygeno.2023.110584)
- xli. Yang NI, Yeh CH, Tsai TH, Chou YJ, Hsu PWC, Li CH, *et al*. Artificial Intelligence-Assisted Identification of Genetic Factors Predisposing High-Risk Individuals to Asymptomatic Heart Failure. *Cells*. 2021;10(9):2430. DOI: [10.3390/cells10092430](https://doi.org/10.3390/cells10092430)
- xlii. Ouyang D, He B, Ghorbani A, Yuan N, Ebinger J, Langlotz CP, *et al*. Video-based AI for beat-to-beat assessment of cardiac function. *Nature*. 2020;580:252-256. DOI: [10.1038/s41586-020-2145-8](https://doi.org/10.1038/s41586-020-2145-8)
- xliii. Zhang J, Gajjala S, Agrawal P, Tison GH, Hallock LA, Beussink-Nelson L, *et al*. Fully automated echocardiogram interpretation in clinical practice: Feasibility and diagnostic accuracy. *Circulation*. 2018;138(16):1623-35. DOI: [10.1161/CIRCULATIONAHA.118.034338](https://doi.org/10.1161/CIRCULATIONAHA.118.034338)

- xliv. Tokodi M, Shrestha S, Bianco C, Kagiyama N, Casaclang-Verzosa G, Narula J, Sengupta PP. Interpatient Similarities in Cardiac Function: A Platform for Personalized Cardiovascular Medicine. *JACC Cardiovasc Imaging*. 2020;13:1119-1132. DOI: [10.1016/j.jcmg.2019.12.018](https://doi.org/10.1016/j.jcmg.2019.12.018).
- xlv. Lancaster MC, Salem Omar AM, Narula S, Kulkarni H, Narula J, Sengupta PP. Phenotypic Clustering of Left Ventricular Diastolic Function Parameters: Patterns and Prognostic Relevance. *JACC Cardiovasc Imaging*. 2019;12:1149-1161. DOI: [10.1016/j.jcmg.2018.02.005](https://doi.org/10.1016/j.jcmg.2018.02.005).
- xlvi. Pandey A, Kagiyama N, Yanamala N, Segar MW, Cho JS, Tokodi M, *et al*. Deep-Learning Models for the Echocardiographic Assessment of Diastolic Dysfunction. *JACC Cardiovasc Imaging*. 2021;14:1887-1900. DOI: [10.1016/j.jcmg.2021.04.010](https://doi.org/10.1016/j.jcmg.2021.04.010).
- xlvii. Beecy AN, Bratt A, Yum B, Sultana R, Das M, Sherifi I, *et al*. Development of novel machine learning model for right ventricular quantification on echocardiography—A multimodality validation study. *Echocardiography*. 2020;37:688-697. DOI: [10.1111/echo.14674](https://doi.org/10.1111/echo.14674).
- xlviii. Genovese D, Rashedi N, Weinert L, Narang A, Addetia K, Patel AR, *et al*. Machine learning-based three-dimensional echocardiographic quantification of right ventricular size and function: Validation against cardiac magnetic resonance. *J Am Soc Echocardiogr*. 2019;32(8):969-77. DOI: [10.1016/j.echo.2019.04.001](https://doi.org/10.1016/j.echo.2019.04.001).
- xlix. Heidenreich PA, Bozkurt B, Aguilar D, Allen LA, Byun JJ, Colvin MM, *et al*. 2022 AHA/ACC/HFSA guideline for the Management of Heart Failure: A report of the American College of Cardiology/American Heart Association joint committee on clinical practice guidelines. *Circulation*. 2022;145(18):e895-e1032. DOI: [10.1161/CIR.0000000000001063](https://doi.org/10.1161/CIR.0000000000001063).
- i. Davies RH, Augusto JB, Bhuvu 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;24:16. DOI: [10.1186/s12968-022-00846-4](https://doi.org/10.1186/s12968-022-00846-4).
- ii. Zhang Q, Burrage MK, Lukaschuk E, Shanmuganathan M, Popescu IA, Nikolaidou C, *et al*. Toward Replacing Late Gadolinium Enhancement With Artificial Intelligence Virtual Native Enhancement for Gadolinium-Free Cardiovascular Magnetic Resonance Tissue Characterization in Hypertrophic Cardiomyopathy. *Circulation*. 2021;144:589-599. DOI: [10.1161/CIRCULATIONAHA.121.054432](https://doi.org/10.1161/CIRCULATIONAHA.121.054432).