

Diagnóstico de cardiopatías congénitas usando aprendizaje profundo en radiografías torácicas pediátricas: prueba de concepto

Diagnosis of congenital heart disease using Deep Learning in pediatric chest X-rays: A proof of concept

Óscar Andrés Ramírez-Terán^{1a}, Eduardo Tomás-Alvarado^{1b}, Salvador Ruiz-Correa^{2c}, Héctor Segura-Quintanilla^{3d}, Rubén López-Revilla^{2e}, Cesaré Moisés Ovando-Vázquez^{2f}, Rubicel Trujillo-Acatitla^{2g}

Resumen

Introducción: en México, las cardiopatías congénitas (CC) constituyen las malformaciones más frecuentes al nacimiento. A pesar de su letalidad, una proporción considerable no se detecta oportunamente en el primer nivel de atención. Si bien el ecocardiograma es el estándar diagnóstico, su disponibilidad es limitada. La radiografía de tórax, pese a su interpretación subjetiva, es un estudio económico y accesible, cuyo análisis mediante inteligencia artificial (IA) podría apoyar el diagnóstico presuntivo de CC.

Objetivo: crear una base de datos de radiografías torácicas pediátricas y desarrollar una prueba de concepto que evalúe la viabilidad de aplicar algoritmos de IA para la detección presuntiva de CC a partir de dichas imágenes.

Material y métodos: estudio transversal retrospectivo basado en el análisis de imágenes de radiografía de tórax mediante una red neuronal convolucional profunda, bajo la arquitectura *Residual Network*.

Resultados: se generó una base de datos de 656 radiografías de tórax, de las cuales 426 correspondieron a pacientes con CC. Un algoritmo de aprendizaje profundo de clasificación binaria aplicado a este conjunto alcanzó una precisión diagnóstica del 75%.

Conclusiones: la base de datos generada constituye, según los registros disponibles, la colección más amplia de radiografías torácicas de pacientes pediátricos mexicanos con CC confirmada por expertos clínicos. Este recurso permitió entrenar un algoritmo de inteligencia artificial con una precisión diagnóstica que respalda su utilidad como herramienta presuntiva en entornos con acceso limitado a subespecialistas.

Abstract

Background: In Mexico, congenital heart diseases (CHD) are the most common birth defects. Despite their high mortality rate, many CHD are not detected early by general practitioners and pediatricians at the primary care level. Echocardiography, the diagnostic standard for CHD, is only available at tertiary care facilities with specialized equipment and personnel. In contrast, chest X-rays are an inexpensive and accessible test, and their analysis using artificial intelligence (AI) could allow for the presumptive diagnosis of CHD.

Objective: Create a database of pediatric chest X-rays and develop a proof of concept that evaluates the feasibility of applying AI algorithms for the presumptive detection of CHD from these images.

Material and methods: A retrospective cross-sectional study was conducted based on the analysis of pediatric chest X-ray images using a deep convolutional neural network implemented under a Residual Network (ResNet) architecture.

Results: Among the radiographs included in the study, 426 (65%) corresponded to patients with CC and 230 (35%) to patients without CC. A deep learning algorithm for binary classification (Healthy/Cardiopath) applied to this set achieved a diagnostic precision of 75%.

Conclusions: According to available records, this database represents the largest collection of chest X-rays from Mexican pediatric patients with CHD confirmed by clinical experts. This resource enabled the training of an AI-based model with sufficient diagnostic performance to support its potential utility as a presumptive screening tool in health-care settings with limited access to pediatric cardiology subspecialists.

¹Instituto Mexicano del Seguro Social, Hospital General Regional No. 17, Servicio de Cardiología Pediátrica. Cancún, Quintana Roo, México

²Instituto Potosino de Investigación Científica y Tecnológica, Centro Nacional de Supercómputo, Grupo de Ciencia e Ingeniería Computacionales. San Luis Potosí, San Luis Potosí, México

³Instituto Tecnológico y de Estudios Superiores de Monterrey, Escuela de Ingeniería, Maestría en Inteligencia Artificial Aplicada. Monterrey, Nuevo León, México

ORCID: 0000-0003-3841-2003^a, 0000-0001-5474-3481^b, 0000-0002-2918-6780^c, 0009-0008-3579-3094^d, 0000-0002-3216-8057^e, 0000-0002-0201-695X^f, 0000-0002-4775-0090^g

Palabras clave

Cardiopatías Congénitas
Inteligencia Artificial
Radiografía Torácica
Red Neuronal Convolucional
Medicina de Precisión

Keywords

Heart Defects, Congenital
Artificial Intelligence
Radiography, Thoracic
Convolutional Neural Network
Precision Medicine

Fecha de recibido: 06/11/2025

Fecha de aceptado: 14/01/2026

Comunicación con:

Eduardo Tomás Alvarado

acteck333@gmail.com

99 8267 8542, extensión 3032

Cómo citar este artículo: Ramírez-Terán OA, Tomás-Alvarado E, Ruiz-Correa S *et al.* Diagnóstico de cardiopatías congénitas usando aprendizaje profundo en radiografías torácicas pediátricas: prueba de concepto. Rev Med Inst Mex Seguro Soc. 2026;64(4):e6971. doi: 10.5281/zenodo.19076180

Introducción

Las cardiopatías congénitas (CC) representan la forma más frecuente de malformaciones presentes al nacimiento.¹ El tamiz cardíaco neonatal en México permite detectar CC críticas;² sin embargo, las dos entidades con mayor mortalidad en el país —la persistencia del conducto arterioso (PCA) y la comunicación interventricular (CIV)— no son identificadas mediante la estrategia actual de tamizaje.³

El ecocardiograma es el método de referencia para el diagnóstico de las CC. No obstante, las guías clínicas reconocen la utilidad de la radiografía de tórax (RxTx) como herramienta inicial en el abordaje de pacientes con sospecha de CC,^{4,5} especialmente en contextos con acceso limitado a cardiólogos y a estudios especializados como el ecocardiograma, el cateterismo cardíaco o la resonancia magnética.⁶

La RxTx presenta ventajas importantes, como su amplia disponibilidad y bajo costo para los sistemas de salud. Sin embargo, su interpretación es altamente subjetiva; por ello, el diagnóstico presuntivo de CC basado únicamente en imágenes radiográficas, incluso por cardiólogos y radiólogos experimentados, alcanza una sensibilidad aproximada del 78% y una especificidad del 80%.⁷

La estructuración de bases de datos de pacientes mexicanos con CC es fundamental para adaptar la atención médica y la investigación a las necesidades de la población, mejorar la calidad asistencial y fomentar la innovación clínica y científica. El análisis sistemático de datos clínicos generados en la práctica médica permite identificar patrones epidemiológicos y características propias que contribuyen a una mejor interpretación diagnóstica y a la personalización de los tratamientos.⁸ Asimismo, la fisiología de la población pediátrica difiere considerablemente de la de los adultos, pero el análisis riguroso de los datos permite abordar preguntas relevantes y detectar necesidades no cubiertas.⁹

La inteligencia artificial (IA) ha demostrado mejorar la precisión diagnóstica, ya sea superando el desempeño humano en ciertas tareas específicas o complementando la labor médica como herramienta de apoyo diagnóstico.⁹ Para el desarrollo de estos algoritmos es indispensable contar con bases de datos estructuradas y adecuadamente etiquetadas, que permitan entrenar modelos robustos y reproducibles, capaces de reducir errores humanos, optimizar tiempos de atención y disminuir la carga asistencial.

El objetivo principal de este trabajo fue crear una base de datos de RxTx de niños mexicanos sanos y con CC, a fin de explorar, en un entorno de prueba de concepto, qué algoritmos de aprendizaje profundo podrían ser utilizados eficaz-

mente por médicos generales y pediatras para el diagnóstico presuntivo de CC a partir de imágenes radiográficas.

Material y métodos

Con la aprobación de los comités de Bioseguridad, Ética e Investigación en Salud (registro R-2025-785-053), se realizó un estudio transversal y retrospectivo para analizar RxTx de pacientes pediátricos atendidos consecutivamente en el servicio de Cardiología Pediátrica del Hospital General Regional No. 17 del Instituto Mexicano del Seguro Social en Cancún, Quintana Roo, entre el 16 de marzo de 2020 y el 31 de diciembre de 2024.


Se incluyeron radiografías de pacientes de ambos sexos, desde el nacimiento hasta los 18 años, sin restricciones en cuanto al sitio de referencia o diagnóstico de envío. Los criterios de inclusión adicionales fueron: ausencia de cirugía cardíaca previa al momento de la toma de la RxTx, disponibilidad de RxTx frontal en el sistema local de estudios de imágenes (HisWeb) y expediente clínico electrónico completo que permitiera corroborar la información clínica y diagnóstica.

Los criterios de exclusión fueron: RxTx de pacientes sin diagnóstico definitivo de CC (por complejidad del caso o protocolo diagnóstico incompleto), así como aquellas radiografías en proyección lateral.

En todos los casos se identificó el diagnóstico definitivo tras completar el protocolo habitual del servicio (exploración física, ecocardiograma y, en caso necesario, angiografía, resonancia magnética y/o cateterismo cardíaco), clasificando a los pacientes como sanos o con CC, y especificando el tipo de cardiopatía. Las RxTx sin alteraciones cardiovasculares se etiquetaron como paciente “*SANO*”. El tamaño de la muestra se determinó por conveniencia, incluyendo de forma consecutiva a todos los pacientes atendidos en el servicio de Cardiología Pediátrica durante el periodo de estudio. Para facilitar su uso e identificación la base de datos estructurada fue denominada XRAY-C5.

Las RxTx se obtuvieron como parte del protocolo clínico habitual. La selección y edición de las imágenes aptas para incluirse en la base de datos fueron realizadas por cardiólogos pediatras mediante: 1) eliminación de imágenes que no incluyeran escápulas y ambos campos pulmonares completos (área de interés); 2) eliminación de radiografías duplicadas; 3) recorte digital para contener exclusivamente el área de interés; 4) etiquetado como “*SANO*” o “*CARDIÓPATA*” según el diagnóstico; y 5) anonimización completa de los datos del paciente (eliminación de nombre, número de seguridad social, fecha, etc.) (figura 1).

Figura 1 Radiografía de la base de datos XRAY-C5



Se muestra un ejemplo de la edición de radiografías contenidas en la base de datos XRAY-C5, recorte digital para establecer el área de interés y eliminación de datos personales, dejando la imagen lista para su integración

Las imágenes se almacenaron en formato JPEG y se registraron de forma anónima mediante un folio (por ejemplo: A011, A012, B023), seguido de la etiqueta diagnóstica (por ejemplo: A011-CIV, A012-PCA, B023-SANO). El resguardo de las imágenes se realizó en un servidor seguro del Centro de Salud Móvil del Instituto Potosino de Investigación Científica y Tecnológica (IPYCYT). El acceso fue restringido mediante protocolos de autenticación autorizados por los investigadores principales.

Para el análisis, las imágenes fueron procesadas mediante una red neuronal convolucional profunda (RNCP) basada en la arquitectura *Residual Network* (ResNet). Previamente, se convirtieron a formato RGB, se redimensionaron a 200×200 píxeles y se normalizaron con base en parámetros de modelos preentrenados en ImageNet.

Se empleó una variante de ResNet-152 con pesos iniciales preentrenados, adaptada mediante *transfer learning* para clasificación binaria en dos categorías ("SANO" y "CARDIÓPATA"). La capa final se sustituyó por una capa *fully connected* con activación *softmax* para dos salidas. El conjunto de datos se dividió en entrenamiento (70%), validación (15%) y prueba (15%), asegurando el balance entre clases.

Durante el entrenamiento se aplicaron técnicas de aumento de datos (*data augmentation*), incluyendo rotación, traslación horizontal, escalado y ajuste de brillo, para mejorar la capacidad de generalización del modelo. La optimización se realizó con el algoritmo Adam, con una tasa de aprendizaje inicial de 1×10^{-4} , función de pérdida *categorical cross-entropy* y un máximo de 100 épocas, con parada temprana basada en la pérdida de validación.

El desempeño del modelo se evaluó mediante métricas estándar de clasificación: *accuracy*, *precision*, *recall* y *F1-score*. Este análisis se planteó como una prueba de concepto para determinar si, a partir de una base de datos estructurada de RxTx pediátricas, es posible entrenar algoritmos de aprendizaje profundo capaces de detectar CC con una precisión diagnóstica comparable a la de médicos especialistas.

Resultados

Se generó una base de datos con 656 imágenes de radiografías, de las cuales 230 corresponden a sujetos sanos y 426 a pacientes con CC, de acuerdo con los diagnósticos incluidos en el **cuadro I**.

Las imágenes de RxTx integradas a la base XRAY-C5 incluyen el área de interés y su respectiva etiqueta de identificación (**figura 2**).

Para facilitar el entrenamiento de algoritmos de clasificación y permitir la incorporación progresiva de nuevas radiografías en la base de datos, se implementó una estructura de carpetas contenedoras (**figura 3**), organizadas según la clasificación clínica comúnmente utilizada por cardiólogos pediatras. Esta organización considera la similitud en la fisiopatología y la presentación clínica de diversas CC, lo que mejora la trazabilidad diagnóstica, optimiza el etiquetado supervisado y favorece la interoperabilidad del conjunto de datos en futuros desarrollos de IA.

El modelo basado en la arquitectura ResNet mostró un desempeño diagnóstico moderado en la prueba piloto de clasificación de las RxTx (**cuadro II**). La evaluación se realizó con 70 imágenes no utilizadas previamente en el entrenamiento del modelo, distribuidas equitativamente en 35 casos positivos ("CARDIÓPATA") y 35 negativos ("SANO").

La precisión (*precision*) alcanzó el 75%, lo que refleja una proporción adecuada de verdaderos positivos entre las predicciones positivas del modelo. Asimismo, la especificidad evidenció una buena capacidad para identificar correctamente los casos negativos.

En conjunto, estas métricas demuestran que, incluso en esta etapa inicial, el modelo de aprendizaje profundo es capaz de identificar patrones radiográficos asociados a CC con un desempeño clínicamente relevante, cumpliendo el objetivo del estudio como prueba de concepto: una base de datos estructurada de RxTx puede ser utilizada eficazmente por algoritmos de aprendizaje profundo para la detección de CC.

Cuadro I Tipos de cardiopatías contenidos en la base de datos XRAY-C5

Identificador de carpeta contenedora	Tipo de cardiopatía congénita	Número de RxTx
SANOS	Sin CC	230
CIV	Comunicación Interventricular	95
CIA	Comunicación Interauricular	55
PCA	Conducto Arterioso	40
CAV	Canal auriculoventricular	13
TGA	Transposición de grandes arterias	5
CIA-CIV	Comunicación Interauricular con Comunicación Interventricular	2
CIA-PCA	Comunicación Interauricular con Conducto Arterioso	12
CIV-PCA	Comunicación Interventricular con Conducto Arterioso	11
CAVP	Conexión anómala de venas pulmonares	18
DVSVD	Doble vía de salida de ventrículo derecho	9
EBST	Anomalia de Ebstein	4
AP	Atresia pulmonar	33
AT	Atresia tricúspide	15
T4F	Tetralogía Fallot	26
COAO	Coartación Aórtica	18
EST PUL	Estenosis pulmonar	15
EST AO	Estenosis aórtica	7
INSUF AO	Insuficiencia aórtica	6
DOB AO	Doble lesión aórtica	2
MIO	Miocardopatías	15
UNI	Fisiología univentricular	25

RxTx: radiografía de tórax

Figura 2 Radiografías etiquetadas dentro de la base

CIV-B213




CATVP-B373



Radiografías de pacientes con diagnóstico de cardiopatía congénita. Se aprecian las etiquetas CIV que corresponde a comunicación interventricular y CATVP que corresponde a conexión anómala de venas pulmonares, así como su folio de identificación dentro de la base XRAY-C5

Figura 3 Estructura organizacional de la base de datos XRAY-C5



Se muestra la distribución de las carpetas contenedoras dentro de la base de datos XRAY-C5

Cuadro II Resultados del modelo con datos no observados durante el entrenamiento

Métrica	Valor	Interpretación clínica/operativa
Exactitud global (accuracy)	70%	Porcentaje de casos que clasifican correctamente (sanos y cardiopatas)
Precisión (PPV) – CARDIÓPATA	75%	De los predichos como cardiopatas, solo 75% son cardiopatas
Sensibilidad (recall) – CARDIÓPATA	60%	60% de los cardiopatas fueron detectados
Especificidad (specificity) – SANO	80%	80% de los casos sanos fueron detectados
F1 – CARDIÓPATA	0.66	Media armónica de la precisión y la sensibilidad
Soporte (n) SANOS, CARDIÓPATAS	(70) 35, 35	Total de los datos prueba

PPV: Valor predictivo positivo

Discusión

Desarrollo prospectivo de herramientas inteligentes para la clasificación radio-gráfica de cardiopatías congénitas

La base de datos desarrollada demuestra la factibilidad de implementar herramientas de IA para la clasificación automatizada de RxTx en el diagnóstico presuntivo de CC en población pediátrica mexicana. Asimismo, sienta las bases para el diseño de modelos de clasificación binaria y algoritmos de subclasificación específicos, en concordancia con avances reportados en China por Han,¹⁰ Chen¹¹ y Zhixin.¹²

Es factible desarrollar modelos de clasificación binaria capaces de distinguir entre RxTx de sujetos sanos y pacientes con CC mediante técnicas de aprendizaje profundo, como las RNC, que han demostrado alta precisión en tareas similares de clasificación.¹³

Se espera que el modelo alcance métricas superiores al

90% en precisión y sensibilidad, siguiendo estándares establecidos en estudios previos de clasificación médica supervisada.¹⁴ El crecimiento interinstitucional de esta base y el desarrollo de aplicaciones móviles de apoyo clínico podrían mejorar la referencia, el tratamiento y el seguimiento oportuno de pacientes pediátricos con CC en México.

Subclasificación: cardiopatías tipo CIV, CIA y PCA

Dada la heterogeneidad de las CC, es factible desarrollar algoritmos de clasificación orientados a identificar las entidades más prevalentes en México, como la comunicación interventricular (CIV) y la persistencia del conducto arterioso (PCA).¹⁵ Experiencias internacionales respaldan este enfoque, en China se han desarrollado modelos para detectar CIA, CIV y PCA,¹² así como sistemas que clasifican las CC según el tipo de flujo pulmonar;¹¹ en Japón han empleado RxTx para estimar el balance de flujo pulmonar en comparación con el cateterismo.¹⁶

Para garantizar la validez y aplicabilidad de los algoritmos en el contexto nacional, es fundamental contar con bases de datos propias que reflejen las características clínicas, demográficas y técnicas de la población. Esto permite reducir la discrepancia de dominio, mejorar la generalización del modelo y aumentar su precisión diagnóstica.¹⁷ La base XRAY-C5 tiene el potencial de ampliarse para incluir cardiopatías complejas como atresia pulmonar, tetralogía de Fallot o ventrículo único, considerando la variabilidad fenotípica de estas entidades.¹⁸

Asimismo, se contempla el establecimiento de colaboraciones con instituciones médicas nacionales para incorporar radiografías externas al repositorio alojado en el Centro de Salud Móvil del Instituto Potosino de Investigación Científica y Tecnológica. Esta estrategia incrementaría la diversidad del conjunto de datos y fortalecería la generalización de los modelos.¹⁹ La creación de grupos colaborativos de investigación enfocados en problemas prioritarios de salud nacional incrementa las posibilidades de traducir los resultados en aplicaciones clínicas reales,²⁰ y la mejora de la interoperabilidad de los datos médicos entre instituciones ha sido validada como una estrategia efectiva para fortalecer los sistemas de IA en salud.²¹

En el ámbito clínico, existen aplicaciones móviles basadas en IA, como *Face2Gene*, que permite generar diagnósticos presuntivos a partir de una fotografía facial,²² y *PMcardio*, que han demostrado utilidad para emitir diagnósticos presuntivos basados en imágenes fotográficas de electrocardiogramas impresos.²³ De manera complementaria, otras herramientas móviles para el análisis de imágenes médicas han mostrado resultados comparables a los sistemas de escritorio.²⁴ En este contexto, el desarrollo futuro de una aplicación capaz de clasificar radiografías a partir de fotografías tomadas con dispositivos móviles podría ampliar el acceso al diagnóstico presuntivo en entornos con recursos limitados, particularmente en regiones sin cardiólogos pediatras.

El uso de estas tecnologías no se limita únicamente a la detección y clasificación de enfermedades. Garrido Pino *et al.*²⁵ demostraron su utilidad como herramientas de tamizaje y apoyo a la toma de decisiones clínicas cuando se emplean de forma adecuada por profesionales de la salud,

favoreciendo además la participación del paciente.²⁶

Las aplicaciones móviles integradas con IA deben entenderse como tecnologías médicas, cuyo uso apropiado incrementa el rendimiento clínico y, en consecuencia, mejora los resultados en los pacientes,²⁷ siempre bajo los principios fundamentales para la implementación ética de la inteligencia artificial en salud, que incluyen la gobernanza de datos y la aplicación clínica responsable de los productos generados.²⁸

Conclusiones

La base de datos estructurada de RxTx constituye, hasta donde se tiene registro, una de las colecciones más amplias de estudios radiográficos de pacientes pediátricos mexicanos con CC. Su diseño incluye tanto RxTx de sujetos sanos como de pacientes con diversos tipos de CC, y establece las bases para el desarrollo y entrenamiento de algoritmos de IA orientados al apoyo diagnóstico, particularmente en entornos con acceso limitado a subespecialistas, fortaleciendo la capacidad resolutoria de los distintos niveles de atención.

Para incrementar su utilidad y alcance, será necesario ampliar progresivamente la base de datos mediante la integración de estudios provenientes de otros centros hospitalarios. La consolidación de una base nacional permitirá desarrollar herramientas diagnósticas más robustas, precisas y con mayor validez externa, favoreciendo su integración efectiva en la práctica médica cotidiana.

Agradecimientos

Agradecemos al equipo docente del Diplomado en Inteligencia Artificial para Informática de la Salud del Instituto Potosino de Investigación Científica y Tecnológica por su apoyo y orientación durante la planeación y ejecución de este proyecto de investigación.

Declaración de conflicto de interés: las autoras han completado y enviado la forma traducida al español de la declaración de conflictos potenciales de interés del Comité Internacional de Editores de Revistas Médicas, y no fue reportado alguno relacionado con este artículo.

Referencias

1. Liu Y, Chen S, Zühlke L, et al. Global birth prevalence of congenital heart defects 1970–2017: updated systematic review and meta-analysis of 260 studies. *Int J Epidemiol.* 2019;48(2):455–63. doi: 10.1093/ije/dyz009.
2. Instituto Mexicano del Seguro Social. Lineamiento técnico médico para la realización del tamiz neonatal cardiaco. Ciudad de México: IMSS; 2022. Disponible en: https://www.gob.mx/cms/uploads/attachment/file/802995/Lineamiento_tamiz_neonatal_cardiaco_Aportaciones_Comite___2022_.pdf
3. Torres-Cosme JL, Rolón-Porras C, Aguinaga-Ríos M, et al. Mortality from congenital heart disease in Mexico: a problem on the rise. *PLoS One.* 2016;11(3):e0150422. doi: 10.1371/journal.pone.0150422.
4. CENETEC. Diagnóstico y Tratamiento de Los Defectos de

Los Tabiques Interauricular e Interventricular En Menores de 18 Años En Segundo y Tercer Nivel de Atención. Guía de Evidencias y Recomendaciones: Guía de Práctica Clínica, 2018.

5. Baumgartner H, De Backer J, Babu-Narayan SV, et al. 2020 ESC guidelines for the management of adult congenital heart disease. *Eur Heart J*. 2021;42(6):563–645. doi: 10.1093/eurheartj/ehaa554.
6. Murni IK, Wirawan MT, Patmasari L, et al. Delayed diagnosis in children with congenital heart disease: a mixed-method study. *BMC Pediatr*. 2021;21(1):191. doi: 10.1186/s12887-021-02667-3.
7. Siregar MHR, Daulay ER, Hasan R. Role of chest radiograph in diagnosis of acyanotic congenital heart disease. *J Soc Med*. 2022;1(3):81–86. doi: <https://doi.org/10.47353/jsocmed.v1i3.12>
8. Sarioğlu T, Ereğ E, Yalçınbaş YK. Why national databases are necessary for pediatric and congenital heart surgery practice? *Türk Gogus Kalp Damar Cerrahisi Derg*. 2019;27(3):418–22. doi:10.5606/tgkdc.dergisi.2019.17945.
9. Markham JL, Hall M, Stephens JR, et al. A pediatric hospital medicine primer for performing research using administrative data. *Hosp Pediatr*. 2022;12(9):e319–25. doi: 10.1542/hpeds.2022-006691.
10. Han PL, Jiang L, Cheng JL, et al. Artificial intelligence-assisted diagnosis of congenital heart disease and associated pulmonary arterial hypertension from chest radiographs: a multi-reader multi-case study. *Eur J Radiol*. 2024;171:111277. doi: 10.1016/j.ejrad.2023.111277.
11. Chen R, Wu X, Chung T, et al. Using deep learning to detect pediatric congenital heart disease by chest radiography [preprint]. 2021. doi: 10.21203/rs.3.rs-491844/v1.
12. Zhixin L, Gang L, Zhixian J, et al. CHD-CXR: a de-identified publicly available dataset of chest x-ray for congenital heart disease. *Front Cardiovasc Med*. 2024;11:1351965. doi: 10.3389/fcvm.2024.1351965.
13. Rajpurkar P, Irvin J, Zhu K, et al. CheXNet: radiologist-level pneumonia detection on chest X-rays with deep learning [preprint]. arXiv:1711.05225. 2017 [citado 2025 Sep 25]. Disponible en: <https://arxiv.org/abs/1711.05225>.
14. Giełczyk A, Marciniak A, Tarczewska M, et al. Pre-processing methods in chest X-ray image classification. *PLoS One*. 2022; 17(4):e0265949. doi: 10.1371/journal.pone.0265949.
15. Tomás-Alvarado E, Ramírez-Terán OA. Descripción epidemiológica de niños con cardiopatías congénitas en Quintana Roo, México. *Rev Mex Pediatr*. 2024;91(2):64–7. doi: 10.35366/119128.
16. Toba S, Mitani Y, Yodoya N, et al. Prediction of pulmonary to systemic flow ratio in patients with congenital heart disease using deep learning-based analysis of chest radiographs. *JAMA Cardiol*. 2020;5(4):449–57. doi:10.1001/jamacardio.2019.5620.
17. Luo L, Yu L, Chen H, et al. Deep mining external imperfect data for chest X-ray disease screening. *IEEE Trans Med Imaging*. 2020;39(11):3583–94. doi: 10.1109/TMI.2020.3000949.
18. Rao PS. Diagnosis and management of ventricular septal defects. *Rev Cardiovasc Med*. 2024;25(11):411. doi: 10.31083/j.rcm2511411.
19. Schiavone WA, Majdalany DS. Chest radiography pearls in select adult congenital heart disease. *J Pers Med*. 2024;14(4):397. doi: 10.3390/jpm14040397.
20. Contreras-Hernández I, Bonifaz-Alfonzo LC. Redes transversales de investigación en salud: estrategia para la medicina traslacional. *Rev Med Inst Mex Seguro Soc*. 2022;60(Suppl 2): S110–8.
21. Jiang F, Jiang Y, Zhi H, et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol*. 2017;2(4):230–43. doi: 10.1136/svn-2017-000101.
22. Yahya D, Stoyanova M, Hachmeriyan M, et al. The application of the facial analysis program Face2Gene in a single genetic counseling center: a retrospective study. *Egypt Pediatr Assoc Gaz*. 2025;73:1. doi: 10.1186/s43054-025-00344-z.
23. Shroyer S, Mehta S, Thukral N, et al. Accuracy of cath lab activation decisions for STEMI-equivalent and mimic ECGs: physicians vs AI (Queen of Hearts by PMcardio). *Am J Emerg Med*. 2025;97:193–9. doi: 10.1016/j.ajem.2025.07.061.
24. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med*. 2019;25(1):24–9. doi: 10.1038/s41591-018-0316-z.
25. Garrido-Pino CA, López-Montero LM, López-Lozano L, et al. Edema macular en fotografías de fondo de ojo mediante un algoritmo computacional. *Rev Med Inst Mex Seguro Soc*. 2024;62(2):e5701. doi: 10.5281/zenodo.10711610.
26. Sharma M, Savage C, Nair M, et al. Artificial Intelligence Applications in Health Care Practice: Scoping Review. *J Med Internet Res*. 2022;24(10):e40238. doi: 10.2196/40238.
27. Alowais SA, Alghamdi SS, Alsuhbeyany N, Alqahtani T, Alshaya AI, Almohareb SN, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC Med Educ*. 2023;23(1):689. doi: 10.1186/s12909-023-04698-z.
28. Chávez-Martínez O, Ragacini LA. Educación médica e inteligencia artificial: perspectivas y desafíos éticos. *Rev Med Inst Mex Seguro Soc*. 2025;63(5):e6736. doi: 10.5281/zenodo.16748310.