

Contemporary deep learning implementations in the healthcare sector: a literature review

Quispe Arque, Dario Ruben¹; Fernando Sierra-Liñan²; Moquillaza Henríquez, Santiago Domingo³
^{1,2,3}Universidad Tecnológica del Perú, Perú, U18100879@utp.edu.pe, C22334@utp.edu.pe, C29177@utp.edu.pe

Abstract– The growing saturation of healthcare systems, due to operational overload and the complexity of data management, has driven interest in more efficient technological solutions. This systematic review aimed to identify how Deep Learning models have been applied in the medical field recently. Forty scientific articles indexed in Scopus, a database recognized for its high rigor and academic prestige, were analyzed, selected using the PRISMA protocol. The results showed that the most studied anatomical areas were the respiratory system (16%), endocrine (15%), and musculoskeletal (13%). The most frequently addressed clinical tasks included classification (47.5%) and prediction (32.5%), with recurring specialties such as oncology and radiology in both categories. The most frequently used model families were CNN (32.5%), ResNet (32.5%), and specialized models (32.5%), applied primarily to medical images. A growing interest was also identified in more advanced architectures and the use of diverse clinical data. These findings provide a current overview of the field and open the way to new opportunities to develop more scalable and adaptable solutions in the healthcare sector.

Keywords-- Deep learning, Health, CNN, ResNet, Medical imaging..

Implementaciones contemporáneas de Deep Learning en el sector salud: una revisión de la literatura

Quispe Arque, Dario Ruben¹; Fernando Sierra-Liñan²; Moquillaza Henríquez, Santiago Domingo³

^{1,2,3}Universidad Tecnológica del Perú, Perú, U18100879@utp.edu.pe, C22334@utp.edu.pe, C29177@utp.edu.pe

Resumen– La creciente saturación de los sistemas de salud, debido a la sobrecarga operativa y la complejidad en el manejo de datos ha impulsado el interés por soluciones tecnológicas más eficientes. Esta revisión sistemática tuvo como objetivo identificar cómo se han aplicado los modelos de Deep Learning en el ámbito médico reciente. Se analizaron 40 artículos científicos indexados en Scopus, una base de datos reconocida por su alto rigor y prestigio académico, seleccionados mediante el protocolo PRISMA. Los resultados mostraron que las áreas anatómicas más estudiadas fueron el sistema respiratorio (16%), endocrino (15%) y músculo-esquelético (13%). Las tareas clínicas más abordadas incluyeron clasificación (47.5%) y predicción (32.5%), con especialidades recurrentes como oncología y radiología en ambas categorías. Las familias de modelos más utilizadas fueron CNN (32.5%), ResNet (32.5%) y modelos especializados (32.5%), aplicados sobre todo a imágenes médicas. También se identificó un creciente interés por arquitecturas más avanzadas y el uso de datos clínicos variados. Estos hallazgos brindan una panorámica actual del campo y abren paso a nuevas oportunidades para desarrollar soluciones más escalables y adaptables en el sector salud.

Palabras clave– Deep learning, Salud, CNN, ResNet, Imágenes médicas.

I. INTRODUCCIÓN

La pandemia de COVID-19 redujo en una década la expectativa de vida global, evidenciando profundas desigualdades y debilidades estructurales, y resaltando la urgencia de avanzar hacia la Cobertura Universal de Salud (UHC) [1]. En Europa, a pesar de contar con sistemas de salud robustos, se ha registrado un estancamiento y retroceso en indicadores clave de salud, desde la infancia hasta las enfermedades crónicas [2]. En América Latina y el Caribe, la amenaza de enfermedades infecciosas persiste, como lo demuestra el resurgimiento de fiebre amarilla en 2025 [3], la aparición de brotes de Oropouche con más de 8000 casos en el 2024 [4], y el aumento de la tuberculosis, que causó más de 30 000 muertes en 2022 [5]. Al mismo tiempo, las enfermedades no transmisibles (ENT) siguen siendo la principal causa de muerte, responsables del 74% de los decesos globales, muchas de ellas prevenibles [6]. Aunque ha habido progresos, la reducción anual de esta mortalidad, del 0.71%, aún es insuficiente [7]. Las desigualdades en salud infantil, junto con crisis sociopolíticas, migración y violencia, siguen desafiando la capacidad de respuesta del sistema sanitario [8, 9].

Ante este panorama, los sistemas de salud enfrentan presiones estructurales, como la escasez de personal y el envejecimiento poblacional y emergencias sanitarias, que

amenazan la capacidad de respuesta médica [10]. A esto se suman limitaciones tecnológicas, como la falta de sensores adecuados, la incompatibilidad de equipos y la gestión compleja de datos clínicos, dificultan la toma de decisiones [11]. Para contrarrestar estos desafíos, se vuelve prioritario adoptar estrategias de eficiencia operativa que optimicen procesos administrativos, mejoren la asignación de recursos y aceleren la transformación digital del sector [12]. Por lo tanto, la necesidad de construir sistemas resilientes para alcanzar la Cobertura Universal de Salud en 2030 resalta la urgencia de incorporar tecnologías avanzadas que fortalezcan la equidad y eficacia del sistema [13].

En este contexto, el deep learning se ha consolidado como una herramienta clave para fortalecer los sistemas de salud, al facilitar el procesamiento de datos clínicos a gran escala y optimizar la toma de decisiones médicas [14]. Su auge reciente en medicina se debe al desarrollo de arquitecturas especializadas y algoritmos avanzados, lo que lo posiciona como un componente central de la inteligencia artificial moderna [15, 16]. Este crecimiento ha sido potenciado por el uso de grandes conjuntos de datos y la capacidad de procesamiento de las GPUs [17]. Entre sus aplicaciones destacan la segmentación precisa de imágenes médicas y la detección automatizada de enfermedades, lo que permite diagnósticos más rápidos y precisos [18, 19].

Más allá de las aplicaciones actuales, el deep learning promete tener un impacto transformador en ámbitos como la medicina biológica, la bioinformática y los tratamientos personalizados [20]. Su capacidad para identificar patrones complejos en información médica permite que profesionales no especializados accedan a conocimientos clínicos avanzados [21]. Además, al emular el procesamiento cognitivo del cerebro humano, el deep learning abre paso a innovaciones orientadas al tratamiento de enfermedades crónicas, la optimización de recursos hospitalarios y la prevención de brotes sanitarios [22], consolidándose como un pilar emergente en la evolución de la inteligencia sanitaria [23].

El presente trabajo busca analizar las múltiples aplicaciones del aprendizaje profundo en el sector salud, explorando su potencial para enfrentar los desafíos actuales y futuros en la mejora de la atención y el bienestar.

II. METODOLOGÍA

Con el fin de explorar el estado actual del tema, se llevó a cabo una revisión sistemática de la literatura científica. El

proceso de búsqueda, selección y análisis de los estudios se estructuró siguiendo los principios de la declaración PRISMA [24], lo que permitió organizar la información de manera coherente y minimizar posibles sesgos. La revisión tiene un enfoque descriptivo, orientado a mapear patrones y tendencias en la producción científica existente.

A. Preguntas de investigación

Las siguientes preguntas constituyen el eje central de esta revisión y se presentan en la Tabla 1.

TABLA I
 PREGUNTAS DE INVESTIGACIÓN

Código	Pregunta
RQ1	¿Cuáles son las principales áreas anatómicas en las que se han aplicado modelos de Deep Learning en el diagnóstico o pronóstico de condiciones médicas?
RQ2	¿Qué tipos de tareas clínicas se han abordado con soluciones basadas en Deep Learning en el sector salud, y en qué áreas de aplicación se han implementado?
RQ3	¿Qué familias de modelos de Deep Learning y sus variantes arquitectónicas se han aplicado en el análisis de condiciones médicas?
RQ4	¿Qué tipos de datos médicos se han utilizado en modelos de Deep Learning y con qué condiciones clínicas están asociados?

B. Estrategias de búsqueda

La búsqueda se estructuró tomando en cuenta aspectos clave relacionados con deep learning y su aplicación en contextos médicos, diagnóstico, modelado predictivo y redes neuronales. Se combinaron sinónimos y términos afines mediante operadores booleanos para garantizar una cobertura amplia.

"deep learning" AND (("medicine" OR "healthcare" OR "clinical setting" OR "medical field") AND (("diagnosis" OR "medical diagnosis" OR "disease detection" OR "early detection") OR ("predictive modeling" OR "predictive analysis" OR "prognostic modeling") OR ("neural networks" OR "artificial neural networks" OR "deep neural networks" OR "neural architectures"))))

C. Criterios de inclusión y exclusión

Se aplicaron criterios específicos para filtrar estudios relevantes sobre deep learning en el ámbito médico y se presenta en la tabla 2.

TABLA II
 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Código	Descripción	
Inclusión	IC1	Artículos publicados entre 2024 y 2025
	IC2	Artículos publicados en idioma ingles
	IC3	Artículos con texto completo disponible
	IC4	Artículos relacionados con deep learning aplicados exclusivamente en el ámbito médico
Exclusión	EC1	Artículos publicados antes de 2024
	EC2	Artículos en idiomas distintos al inglés
	EC3	Artículos sin acceso al texto completo
	EC4	Artículos que no involucren deep learning o que lo apliquen fuera del ámbito médico

D. Fuentes de información

Todos los artículos fueron obtenidos de la base de datos Scopus, debido a su amplio alcance y reconocimiento en la comunidad científica.

E. Proceso de selección de artículos

El proceso de selección comenzó con la aplicación de la cadena de búsqueda en la base de datos Scopus, lo que arrojó un total de 19,479 documentos. Luego de aplicar los criterios de exclusión previamente definidos, el conjunto se redujo a 643 artículos. A partir de este grupo, se descartaron 603 artículos cuyo contenido no se alineaba con el enfoque específico de este estudio, ya sea por abordar tecnologías distintas, aplicaciones ajenas al ámbito médico o por un tratamiento superficial del deep learning. Como resultado, se seleccionaron 40 artículos para el análisis cualitativo. No se identificaron duplicados en el proceso.




Fig. 1 Resultados de la selección de artículos basado en PRISMA.




Fig. 2 Visualización en red de los artículos extraídos de la base de datos.

La visualización en red destaca términos clave por frecuencia y afinidad temática. “Deep learning” (azul) es el nodo más prominente, lo que refleja su centralidad en los estudios. “Female” (rojo) resalta por la atención a poblaciones específicas, mientras que “procedures” (púrpura) indica un enfoque recurrente en aspectos clínicos y técnicos.



Fig. 3 Nube de palabras.

La nube de palabras resume los términos más frecuentes en los estudios analizados. Destacan “deep learning” y “human”, reflejando el enfoque en aplicaciones biomédicas. El análisis se realizó en RStudio a partir de palabras clave extraídas de la literatura.

E. Consideraciones éticas

Este estudio se basó únicamente en artículos científicos previamente publicados en Scopus, sin involucrar datos primarios de pacientes.

III. RESULTADOS

En esta sección se presentan y analizan los resultados para responder las preguntas planteadas en la revisión.

RQ1. ¿Cuáles son las principales áreas anatómicas en las que se han aplicado modelos de Deep Learning en el ámbito médico?

Las principales áreas anatómicas en las que se han aplicado modelos de Deep Learning son el sistema respiratorio (6),

endocrino y reproductivo (6), y músculo- esquelético (5), destacando su enfoque en enfermedades como cáncer de pulmón, cáncer de próstata y tumores óseos, como se observa en la Figura 4.




Fig. 4 Distribución de áreas anatómicas en estudios con Deep Learning.

La Tabla 3 presenta las áreas anatómicas más estudiadas junto con las principales condiciones médicas tratadas en cada una.

TABLA III
CLASIFICACIÓN POR ÁREA ANATÓMICA Y CONDICIONES MÉDICAS

Área Anatómica	Condiciones Médicas	Nº de artículos	Referencias
Urinario	Cáncer de vejiga, Lesiones renales quísticas	4	[25], [31], [56], [63]
Respiratorio	Cáncer del pulmón, Neumoconiosis	6	[26], [39], [43], [58], [62], [64]
Músculo - esquelético	Escoliosis, Osteoporosis, Tumores Óseos	5	[27], [32], [38], [44], [57]
Hepatobiliar y pancreático	Atresia Biliar, Carcinoma vesícula biliar, Tumores NE pancreáticos, Adenocarcinoma ductal	4	[28], [29], [41], [54]
Gastrointestinal	Cáncer gástrico, Tumores intestinales, Cáncer colorrectal	4	[30], [48], [51], [61]
Neurológico	Alzheimer, Tumores cerebrales	2	[34], [53]
Endocrino y reproductivo	Cáncer de próstata, Cáncer de ovario epitelial, Cáncer de endometrio, Cáncer de cuello uterino	6	[35], [46], [52], [59], [60], [37]
Oftalmológico	Retinopatía diabética, Tumores de párpado	2	[33], [42]
Hematológico	Leucemia	1	[36]
Mamario	Cáncer de mama	4	[40], [47], [49], [50]
Pélvico y sacro	Tumores pélvicos y sacros	1	[45]

RQ2. ¿Qué tipos de tareas clínicas se han abordado con soluciones basadas en Deep Learning en el sector salud, y en qué áreas de aplicación se han implementado?

Se han abordado diversas tareas clínicas como clasificación, segmentación, detección, predicción, diagnóstico y medición, implementadas en múltiples áreas como oncología, radiología, neurología, pediatría y ortopedia, entre otras, demostrando la amplia aplicabilidad de estas soluciones en el sector salud, como se muestra en la Figura 5.




Fig. 5 Distribución de artículos por tareas clínicas.

La Tabla 4 identifica las tareas clínicas abordadas y sus respectivas áreas de aplicación en el ámbito médico.

TABLA IV CLASIFICACIÓN POR ÁREA ANATÓMICA Y CONDICIONES MÉDICAS			
Tarea Clínica	Áreas de Aplicación	Nº de artículos	Referencias
Clasificación	Oncología, Ortopedia, Radiología, Patología, Gastroenterología	19	[25], [27], [30], [31], [32], [35], [37], [38], [40], [41], [44], [46], [47], [48], [49], [51], [52], [54], [61]
Segmentación	Oncología, Radiología, Oftalmología	9	[26], [33], [38], [40], [42], [43], [45], [48], [49]
Detección	Oncología, Radiología, Patología	9	[29], [36], [41], [43], [45], [46], [47], [52], [54]
Predicción	Oncología, Neurología, Radiología, Genómica, Urología, Ginecología	13	[25], [34], [35], [39], [50], [53], [55], [56], [59], [60], [61], [62], [63]
Diagnóstico	Pediatría, Neumología	2	[28], [64]
Medición	Ortopedia	1	[27]

RQ3. ¿Qué familias de modelos de Deep Learning y sus variantes arquitectónicas se han aplicado en el análisis de condiciones médicas?

Se emplean diversas familias de modelos de Deep Learning, incluyendo modelos especializados que combinan técnicas híbridas y enfoques avanzados para optimizar

resultados. Además de modelos clásicos como CNN y ResNet, estas metodologías cubren un amplio espectro de aplicaciones clínicas y tipos de datos, como se muestra en la Figura 6.




Fig. 6 Distribución de artículos según familia de modelos.

La Tabla 5 presenta las familias de modelos de Deep Learning más implementadas en los artículos revisados.

TABLA V CLASIFICACIÓN POR TAREA CLÍNICA Y ÁREA DE APLICACIÓN			
Familia de Modelo	Variantes Arquitectónicas	Nº de artículos	Referencias
CNN	CNN (Convolutional Neural Networks), DeepCNN, Wavelet-CNN (WCNN), CNN-RNN híbridos, Kite-Net, KiU-Net	13	[25], [30], [31], [33], [36], [40], [43], [47], [49], [50], [51], [55], [64]
ResNet	ResNet18, ResNet34, ResNet50, ResNet101, ResNeXt50 (BlaPaSeg), Truncated ResNet (TR-MAMIL)	13	[26], [27], [28], [31], [38], [40], [46], [49], [51], [52], [54], [56], [59]
U-Net	U-Net, nnU-Net, U-Net 2.5D, Dual Attention UNet, 3D U-Net, UNet-like	10	[29], [30], [32], [35], [45], [46], [50], [60], [63]
DenseNet	DenseNet121, DenseNet-ECA	5	[36], [38], [39], [54]
MobileNet	MobileNetV2, MobileNet v3 small	3	[45], [53], [54]
Transformers	MIRAI (ResNet + Transformer), Vision Transformer, Swin Transformer, EMIT, PBTC-TransNet	5	[44], [49], [57], [62]
GNNs	GNNs (Graph Neural Networks)	1	[41]
MIL / MAML	MIL, TripletMIL, TR-MAMIL, CLAM	4	[36], [37], [52], [61]
YOLO	YOLOv4, YOLOv5	2	[36], [42]
EfficientNet	EfficientNet B3, B4, v2-B	2	[42], [44]
Modelos especializados	DeepSurv, AutoGluon, LightGBM, XGBoost, CatBoost, THAM, BLFFM, MacroVisionNet, UniVisionNet, WT-GAN, GRU, LSTM	13	[26], [34], [40], [43], [48], [49], [52], [54], [55], [56], [58], [59], [63]

RQ4. ¿Qué tipos de datos médicos se han utilizado en modelos de Deep Learning y con qué condiciones clínicas están asociados?

La mayoría de los datos empleados en modelos de Deep Learning son imágenes, destacando las imágenes anatómicas y funcionales (21) y las histológicas y patológicas (11), asociadas a diversas condiciones clínicas, como se muestra en la Figura 7.




Fig. 7 Distribución de artículos según tipos de datos.

La Tabla 6 muestra los tipos de datos identificados y sus condiciones clínicas asociadas.

TABLA VI CLASIFICACIÓN POR TIPO DE DATO Y CONDICIONES MÉDICAS			
Tipo de dato	Condiciones Médicas	Nº de artículos	Referencias
Imágenes Anatómicas y Funcionales	Cáncer de vejiga, Carcinoma de vesícula biliar, Tumores, Retinopatía diabética, Osteoporosis, Neumoconiosis, Cáncer de pulmón, Cáncer gástrico, Cáncer de ovario epitelial, Cáncer de próstata, Lesiones renales quísticas, Escoliosis	21	[25], [26], [27], [28], [29], [30], [31], [33], [38], [39], [40], [43], [44], [45], [46], [48], [53], [58], [59], [60], [63]
Imágenes Histológicas y Patológicas	Cáncer de próstata, Leucemia, Tumores neuroendocrinos pancreáticos, Cáncer gástrico, Cáncer de cuello uterino, Cáncer de mama, Cáncer colorrectal, Cáncer de endometrio,	11	[35], [36], [37], [41], [47], [51], [52], [54], [56], [61], [62]

Tipo de dato	Condiciones Médicas	Nº de artículos	Referencias
	Adenocarcinoma ductal pancreático, Cáncer de vejiga		
Imágenes Superficiales y Multiespectrales	Escoliosis, Tumores de párpado, Tumores óseos	4	[30], [32], [42], [57]
Imágenes Longitudinales y Multimodales	Alzheimer, Cáncer de mama	2	[34], [49]
Imágenes derivadas de bioseñales	Cáncer de pulmón, Cáncer de mama	2	[50], [64]

Para complementar el análisis de los artículos revisados, se consideró relevante examinar el nivel de impacto de las revistas donde se publicaron, clasificado por cuartiles. La Figura 8 muestra la proporción de artículos según el cuartil, con un predominio del cuartil Q1.




Fig. 8 Distribución de artículos según su cuartil.

TABLA VII CLASIFICACIÓN DE ARTÍCULOS POR CUARTILES		
Cuartiles	Nº de artículos	Referencias
Q1	26	[25], [26], [27], [28], [32], [34], [36], [37], [38], [41], [42], [44], [45], [48], [49], [50], [51], [52], [55], [56], [57], [58], [59], [62], [63], [64]
Q2	13	[29], [30], [31], [33], [35], [39], [40], [43], [46], [47], [53], [54], [60]
Q3	1	[61]

Adicionalmente, se realizó un análisis descriptivo cruzado para identificar relaciones entre las tareas clínicas abordadas y las familias de modelos de Deep Learning utilizadas. Los resultados, presentados en la Tabla 8, reflejan una fuerte asociación entre la tarea de clasificación y el uso de modelos CNN y ResNet, que se destacan como los más empleados en esta función específica.

TABLA VIII
ANÁLISIS DESCRIPTIVO CRUZADO

		Tareas Clínicas					
		Clasificación	Segmentación	Detección	Predicción	Diagnóstico	Medición
Familia de Modelo	CNN	[25], [30], [31], [40], [47], [49], [51]	[33], [40], [43], [49]	[36], [43], [47]	[25], [50], [55]	[64]	
	ResNet	[27], [31], [38], [40], [46], [49], [51], [52], [54]	[26], [38], [40], [49]	[46], [52], [54]	[56, 59]	[28]	[27]
	U-Net	[30], [32], [35], [46]	[45]	[29], [45], [46]	[35], [50], [60], [63]		
	MIL / MAML	[37], [52], [61]		[36], [52]	[61]		
	DenseNet	[38], [54]	[38]	[36], [54]	[39]		
	Modelos especializados	[40], [48], [49], [52], [54]	[26], [40], [43], [48], [49]	[43], [52], [54]	[34], [55], [56], [59], [63]		
	GNNs	[41]		[41]			
	Transformers	[44], [49]	[49]		[62]		
	EfficientNet	[44]	[42]				
	MobileNet	[54]	[45]	[45], [54]	[53]		
	YOLO		[42]	[36]			

IV. CONCLUSIONES

El análisis permitió identificar que las soluciones basadas en Deep Learning se aplican principalmente en el estudio de enfermedades respiratorias, endocrinas y músculo-esqueléticas, utilizando datos mayormente visuales como imágenes anatómicas, funcionales y patológicas. Las tareas clínicas más frecuentes fueron la clasificación y segmentación, debido a su utilidad en procesos de diagnósticos, destacando el uso extendido de modelos como CNN, ResNet por su desempeño en el análisis de imágenes médicas.

Aunque ya existen aplicaciones consolidadas, se evidencia una evolución hacia enfoques más complejos que integren arquitecturas avanzadas y tipos de datos más diversos. Esta línea de desarrollo podría acelerarse con la incorporación de agentes inteligentes y sistemas autónomos, capaces de interactuar con flujos clínicos en tiempo real, optimizando la toma de decisiones médicas.

También es importante señalar que el uso de deep learning en salud conlleva retos relacionados con la privacidad de los datos clínicos, la presencia de sesgos en los conjuntos de entrenamiento y la definición de responsabilidades en su aplicación práctica. Estos aspectos deben ser considerados en futuros trabajos para garantizar una adopción responsable.

REFERENCIAS

[1] World Health Organization, World Health Statistics 2024: Monitoring Health for the SDGs, Geneva: World Health Organization, 2024. [Online]. Available: <https://iris.who.int/bitstream/handle/10665/376869/9789240094703-eng.pdf>.

[2] World Health Organization, "From cradle to cane: WHO's new European Health Report warns of lifelong health crises across the Region," WHO/Europe, Feb. 25, 2025. [Online]. Available: <https://www.who.int/europe/news/item/25-02-2025-from-cradle-to-cane--who-s-new-european-health-report-warns-of-lifelong-health-crises-across-the-region>

[3] Pan American Health Organization, "Epidemiological Alert: Increase in Yellow Fever Cases in Latin America," PAHO, Feb. 4, 2025. [Online]. Available: <https://www.paho.org/en/news/4-2-2025-epidemiological-alert-increase-yellow-fever-cases-latin-america>

[4] World Health Organization, "Oropouche virus disease - Region of the Americas," Disease Outbreak News, 23-Aug-2024. [Online]. Available: <https://www.who.int/emergencies/disease-outbreak-news/item/2024-DON530>

[5] World Health Organization, "Tuberculosis resurges as top infectious disease killer," News release, 29-Oct-2024. [Online]. Available: <https://www.who.int/news/item/29-10-2024-tuberculosis-resurges-as-top-infectious-disease-killer>

[6] World Health Organization, "Boosting digital health can help prevent millions of deaths from noncommunicable diseases," WHO, Sep. 23, 2024. [Online]. Available: <https://www.who.int/news/item/23-09-2024-boosting-digital-health-can-help-prevent-millions-of-deaths-from-noncommunicable-diseases>

[7] Pan American Health Organization, NCDs at a Glance 2025: NCDs Surveillance and Monitoring – Noncommunicable Disease Mortality and Risk Factor Prevalence in the Americas, PAHO/NMH/NV/25-0002, Mar. 27, 2025. [Online]. Available: <https://iris.paho.org/handle/10665.2/65818>

[8] Pan American Health Organization, "Encouraging trends and persistent challenges: Analysis of under-five mortality and prospects in Latin America and the Caribbean," PAHO, May 14, 2024. [Online]. Available: <https://www.paho.org/en/news/14-5-2024-encouraging-trends-and-persistent-challenges-analysis-under-five-mortality-and>

[9] Pan American Health Organization, "PAHO: Regional Appeal – Region of the Americas," World Health Organization, 2023. [Online]. Available: <https://www.who.int/emergencies/funding/health-emergency-appeals/2022/2023/2023-appeals/appeal-region-paho>

[10] World Health Organization, "Health systems of the future: harnessing technology and innovation in health for everyone everywhere,"

- WHO/Europe, Feb. 21, 2025. [Online]. Available: <https://www.who.int/europe/news-room/events/item/2025/02/21/default-calendar/health-systems-of-the-future--harnessing-technology-and-innovation-in-health-for-everyone-everywhere>
- [11] S. B. Junaid et al., "Recent Advancements in Emerging Technologies for Healthcare Management Systems: A Survey," *Healthcare*, vol. 10, no. 10, p. 1940, 2022. [Online]. Available: <https://doi.org/10.3390/healthcare10101940>
 - [12] D. Luther, "How to improve operational efficiency in healthcare," *NetSuite*, Feb. 6, 2025. [Online]. Available: <https://www.netsuite.com/portal/resource/articles/financial-management/operational-efficiency-healthcare.shtml>
 - [13] K. Rasanathan, "How can health systems under stress achieve universal health coverage and health equity?" *International Journal for Equity in Health*, vol. 23, p. 244, 2024. [Online]. Available: <https://doi.org/10.1186/s12939-024-02293-2>
 - [14] K. Conger, "AI improves accuracy of skin cancer diagnoses in Stanford Medicine-led study," *Stanford Medicine News*, Apr. 11, 2024. [Online]. Available: <https://med.stanford.edu/news/all-news/2024/04/ai-skin-diagnosis.html>. [Accessed: Apr-2025].
 - [15] Y. Xie, Y. Zhai, and G. Lu, "Evolution of artificial intelligence in healthcare: a 30-year bibliometric study," *Frontiers in Medicine*, vol. 11, Art. no. 1505692, 2024. [Online]. Available: <https://doi.org/10.3389/fmed.2024.1505692>.
 - [16] I. D. Mienye and T. G. Swart, "A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications," *Information*, vol. 15, no. 12, Art. no. 755, Nov. 2024. [Online]. Available: <https://doi.org/10.3390/info15120755>.
 - [17] S. Madhavan and M. T. Jones, "Deep learning architectures: The rise of artificial intelligence," *IBM Developer*, [Online]. Available: <https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/>. [Accessed: 27-Apr-2025].
 - [18] T. Whitmarsh et al., "Quantifying the tumour vasculature environment from CD-31 immunohistochemistry images of breast cancer using deep learning based semantic segmentation," *Breast Cancer Research*, vol. 27, no. 1, Art. no. 17, Dec. 2025. [Online]. Available: <https://doi.org/10.1186/s13058-024-01950-2>.
 - [19] K. Y. J. Ayala, "Detection of breast cancer through the analysis of radiographic images using machine learning: A systematic review," *International Journal of Online and Biomedical Engineering*, vol. 20, no. 5, pp. 120–132, 2024. [Online]. Available: <https://doi.org/10.3991/ijoe.v20i05.46791>.
 - [20] I. Abdulkadar, J. R. Mohan, P. V. Bharati, S. Palit, G. S. Rao, and P. Mudholkar, "Neural Networks and Deep Learning: Innovations and Applications in Soft Computing," 7th International Conference on Contemporary Computing and Informatics (IC3I), Greater Noida, India, 18-20 Sep. 2024, doi: 10.1109/IC3I61595.2024.10829173.
 - [21] S. Thakur and S. Narad, "Deep Learning Models in Healthcare," 2nd DMIHER International Conference on Artificial Intelligence in Healthcare, Education and Industry (IDICAIEI), Wardha, India, 29-30 Nov. 2024, doi: 10.1109/IDICAIEI61867.2024.10842703.
 - [22] D.-E. M. Nisar, R. Amin, N.-U.-H. Shah, M. A. Al Ghamdi, S. H. Almotiri, and M. Alruily, "Healthcare techniques through deep learning: Issues, challenges and opportunities," *IEEE Access*, vol. 9, pp. 98523–98541, Jul. 2021. [Online]. Available: <https://doi.org/10.1109/ACCESS.2021.3095312>
 - [23] V. E. Sathishkumar, "Editorial: Utilizing big data and deep learning to improve healthcare intelligence and biomedical service delivery," *Front. Big Data*, vol. 7, Oct. 2024. [Online]. Available: <https://doi.org/10.3389/fdata.2024.1502398>
 - [24] PRISMA, "Welcome to the PRISMA website," PRISMA Statement, 2025. [Online]. Available: <https://www.prisma-statement.org/>. [Accessed: 15-May-2025].
 - [25] X. Han, J. Guan, L. Guo, Q. Jiao, K. Wang, F. Hou, S. Liu, S. Yang, C. Huang, W. Cong and H. Wang, "A CT-based interpretable deep learning signature for predicting PD-L1 expression in bladder cancer: a two-center study," *Cancer Imaging*, vol. 25, no. 1, Art. no. 27, Dec. 2025. DOI: <https://doi.org/10.1186/s40644-025-00849-1>.
 - [26] C. Liu, Y.-F. Wang, P. Gong, X.-Q. Xue, H.-Y. Zhao, H. Qian, C. Jia, and X.-F. Li, "Prediction of tumor spread through air spaces with an automatic segmentation deep learning model in peripheral stage I lung adenocarcinoma," *Respiratory Research*, vol. 26, no. 1, Art. no. 94, Dec. 2025. DOI: <https://doi.org/10.1186/s12931-025-03174-0>.
 - [27] K. Xie, S. Zhu, J. Lin, Y. Li, J. Huang, W. Lei, and Y. Yan, "A deep learning model for radiological measurement of adolescent idiopathic scoliosis using biplanar radiographs," *J Orthop Surg Res*, vol. 20, no. 1, p. 142, 2025. DOI: <https://doi.org/10.1186/s13018-025-05620-7>.
 - [28] F. He, G. Li, Z. Zhang, C. Yang, Z. Yang, H. Ding, D. Zhao, W. Sun, Y. Wang, K. Zeng, X. Li, M. Shao, J. Yin, J. Yao, B. Hong, Z. Zhang, Z. Yuan, Z. Weng, L. Zhou, M. Zhang, and L. Chen, "Transfer learning method for prenatal ultrasound diagnosis of biliary atresia," *npj Digit. Med.*, vol. 8, no. 1, p. 131, 2025. DOI: <https://doi.org/10.1038/s41746-025-01525-1>.
 - [29] Z. Jin, C. Chen, D. Zhang, M. Yang, Q. Wang, Z. Cai, S. Si, Z. Geng, and Q. Li, "Preoperative clinical radiomics model based on deep learning in prognostic assessment of patients with gallbladder carcinoma," *BMC Cancer*, vol. 25, no. 1, p. 341, 2025, DOI: <https://doi.org/10.1186/s12885-025-13711-1>.
 - [30] M. Torkaman, S. Jemaa, J. Fredrickson, A. F. Coimbra, A. De Crespigny, and R. A. D. Carano, "Comparative analysis of intestinal tumor segmentation in PET CT scans using organ based and whole body deep learning," *BMC Med. Imaging*, vol. 25, no. 1, p. 52, 2025, DOI: <https://doi.org/10.1186/s12880-025-01587-3>.
 - [31] H.-C. Kan, P.-H. Lin, I.-H. Shao, S.-C. Cheng, T.-Y. Fan, Y.-H. Chang, L.-K. Huang, Y.-C. Chu, K.-J. Yu, C.-K. Chuang, C.-T. Wu, S.-T. Pang, and S.-J. Peng, "Using deep learning to differentiate among histology renal tumor types in computed tomography scans," *BMC Med. Imaging*, vol. 25, no. 1, p. 66, 2025, DOI: <https://doi.org/10.1186/s12880-025-01606-3>.
 - [32] X. Duan, X. Ma, M. Zhu, L. Wang, D. You, L. Deng, and N. Niu, "Deep learning-assisted screening and diagnosis of scoliosis: segmentation of bare-back images via an attention-enhanced convolutional neural network," *J. Orthop. Surg. Res.*, vol. 20, no. 1, p. 161, 2025, DOI: <https://doi.org/10.1186/s13018-025-05564-y>.
 - [33] Y. Li, B. Yu, M. Si, M. Yang, W. Cui, Y. Zhou, S. Fu, H. Wang, X. Liu, and H. Zhang, "Enhancing diabetic retinopathy diagnosis: automatic segmentation of hyperreflective foci in OCT via deep learning," *Int. Ophthalmol.*, vol. 45, no. 1, p. 79, 2025, DOI: <https://doi.org/10.1007/s10792-025-03439-z>.
 - [34] S. Yang, X. Zhang, X. Du, P. Yan, J. Zhang, W. Wang, J. Wang, L. Zhang, H. Sun, Y. Liu, X. Xu, Y. Di, J. Zhong, C. Wu, J. D. Reinhardt, Y. Zheng, and T. Wu, "Prediction of cognitive conversion within the Alzheimer's disease continuum using deep learning," *Alzheimer's Res. Ther.*, vol. 17, no. 1, p. 41, 2025, DOI: <https://doi.org/10.1186/s13195-025-01686-x>.
 - [35] L. E. Marin, D. I. Zavaleta-Guzman, J. I. Gutierrez-Garcia, D. Racocanu, and F. L. Casado, "Prediction of biochemical prostate cancer recurrence from any Gleason score using robust tissue structure and clinically available information," *Discover Oncology*, vol. 16, no. 1, p. 128, 2025, DOI: <https://doi.org/10.1007/s12672-025-01896-7>.
 - [36] B.-H. Wei, X. C.-H. Tsai, K.-J. Sun, M.-Y. Lo, S.-Y. Hung, W.-C. Chou, H.-F. Tien, H.-A. Hou, and C.-Y. Chen, "Annotation-free deep learning for predicting gene mutations from whole slide images of acute myeloid leukemia," *npj Precis. Oncol.*, vol. 9, no. 1, p. 35, 2025, DOI: <https://doi.org/10.1038/s41698-025-00804-0>.
 - [37] R. Wang, G. N. Gunesli, V. E. Skingen, K.-A. F. Valen, H. Lyng, L. S. Young, and N. Rajpoot, "Deep learning for predicting prognostic consensus molecular subtypes in cervical cancer from histology images," *npj Precis. Oncol.*, vol. 9, no. 1, p. 11, 2025, DOI: <https://doi.org/10.1038/s41698-024-00778-5>.
 - [38] C. Huang, D. Wu, B. Wang, C. Hong, J. Hu, Z. Yan, J. Chen, Y. Jin, and Y. Zhang, "Application of deep learning model based on unenhanced chest CT for opportunistic screening of osteoporosis: a multicenter retrospective cohort study," *Insights Imaging*, vol. 16, no. 1, p. 10, 2025, DOI: <https://doi.org/10.1186/s13244-024-01817-2>.
 - [39] H. Dong, B. Zhu, X. Kong, X. Su, T. Liu, and X. Zhang, "Deep learning-based algorithm for classifying high-resolution computed tomography features in coal workers' pneumoconiosis," *BioMed. Eng. OnLine*, vol. 24, no. 1, p. 7, 2025, DOI: <https://doi.org/10.1186/s12938-025-01333-4>.

- [40] J. Xie, J. Wei, H. Shi, Z. Lin, J. Lu, X. Zhang, and C. Wan, "A deep learning approach for early prediction of breast cancer neoadjuvant chemotherapy response on multistage bimodal ultrasound images," *BMC Med. Imaging*, vol. 25, no. 1, p. 26, 2025, DOI: <https://doi.org/10.1186/s12880-024-01543-7>.
- [41] S. Koc, O. C. Eren, R. Esmer, F. U. Kasapoglu, B. Saka, O. C. Taskin, P. Bagci, N. V. Adsay, and C. Gunduz-Demir, "Deep Learning Enabled Scoring of Pancreatic Neuroendocrine Tumors Based on Cancer Infiltration Patterns," *Endocr. Pathol.*, vol. 36, no. 1, p. 2, 2025, DOI: <https://doi.org/10.1007/s12022-025-09846-3>.
- [42] S. Hui, J. Xie, L. Dong, L. Wei, W. Dai, and D. Li, "Deep learning-based mobile application for efficient eyelid tumor recognition in clinical images," *npj Digit. Med.*, vol. 8, no. 1, p. 185, 2025, DOI: <https://doi.org/10.1038/s41746-025-01539-9>.
- [43] M. Alsallal, H. H. Ahmed, R. Abdul Kareem, A. Yadav, S. Ganesan, A. Shankhyan, S. Gupta, K. K. Joshi, H. N. Sameer, A. Yaseen, Z. H. Athab, M. Adil, and B. Farhood, "Enhanced lung cancer subtype classification using attention-integrated DeepCNN and radiomic features from CT images: a focus on feature reproducibility," *Discover Oncology*, vol. 16, no. 1, p. 336, 2025, DOI: <https://doi.org/10.1007/s12672-025-02115-z>.
- [44] H. Wang, Y. He, L. Wan, C. Li, Z. Li, Z. Li, H. Xu, and C. Tu, "Deep learning models in classifying primary bone tumors and bone infections based on radiographs," *npj Precis. Oncol.*, vol. 9, no. 1, p. 72, 2025, DOI: <https://doi.org/10.1038/s41698-025-00855-3>.
- [45] P. Yin, W. Chen, Q. Fan, R. Yu, X. Liu, T. Liu, D. Wang, and N. Hong, "Development and evaluation of a deep learning framework for pelvic and sacral tumor segmentation from multi-sequence MRI: a retrospective study," *Cancer Imaging*, vol. 25, no. 1, p. 34, 2025, DOI: <https://doi.org/10.1186/s40644-025-00850-8>.
- [46] S. Nayak et al., "Deep Learning-Based Tumor Segmentation of Murine Magnetic Resonance Images of Prostate Cancer Patient-Derived Xenografts," *Tomography*, vol. 11, no. 3, p. 21, 2025, DOI: <https://doi.org/10.3390/tomography11030021>.
- [47] A. Das y M. N. Mohanty, "Wavelet-Convolutional Neural Network: An Improved Deep Learning Model for Breast Cancer Detection from Histopathology Images," *Archives of Breast Cancer*, vol. 12, no. 1, pp. 73-84, 2025, DOI: <https://doi.org/10.32768/abc.202512173-84>.
- [48] H. Shang et al., "Deep learning and radiomics for gastric cancer serosal invasion: automated segmentation and multi-machine learning from two centers," *Journal of Cancer Research and Clinical Oncology*, vol. 151, no. 2, p. 60, 2025, DOI: <https://doi.org/10.1007/s00432-025-06117-w>.
- [49] Z. Klanecek et al., "Longitudinal interpretability of deep learning based breast cancer risk prediction," *Physics in Medicine and Biology*, vol. 70, no. 1, p. 015001, 2025, DOI: <https://doi.org/10.1088/1361-6560/ad9db3>.
- [50] A. Munguía-Siu, I. Vergara, and J. H. Espinoza-Rodríguez, "The Use of Hybrid CNN-RNN Deep Learning Models to Discriminate Tumor Tissue in Dynamic Breast Thermography," *J. Imaging*, vol. 10, no. 12, p. 329, 2024, DOI: <https://doi.org/10.3390/jimaging10120329>.
- [51] J. Carreras, G. Roncador, and R. Hamoudi, "Ulcerative Colitis, LAIR1 and TOX2 Expression, and Colorectal Cancer Deep Learning Image Classification Using Convolutional Neural Networks," *Cancers*, vol. 16, no. 24, p. 4230, 2024, DOI: <https://doi.org/10.3390/cancers16244230>.
- [52] C.-W. Wang et al., "Deep learning for endometrial cancer subtyping and predicting tumor mutational burden from histopathological slides," *npj Precision Oncology*, vol. 8, no. 1, p. 287, 2024, DOI: <https://doi.org/10.1038/s41698-024-00766-9>.
- [53] M. Sankar et al., "Efficient brain tumor grade classification using ensemble deep learning models," *BMC Medical Imaging*, vol. 24, no. 1, p. 297, 2024, DOI: <https://doi.org/10.1186/s12880-024-01476-1>.
- [54] K. Hu et al., "Construction of a combined prognostic model for pancreatic ductal adenocarcinoma based on deep learning and digital pathology images," *BMC Gastroenterology*, vol. 24, no. 1, p. 387, 2024, DOI: <https://doi.org/10.1186/s12876-024-03469-4>.
- [55] U. Ravindran and C. Gunavathi, "Deep learning assisted cancer disease prediction from gene expression data using WT-GAN," *BMC Medical Informatics and Decision Making*, vol. 24, no. 1, p. 311, 2024, DOI: <https://doi.org/10.1186/s12911-024-02712-y>.
- [56] Q. He et al., "Integrated multicenter deep learning system for prognostic prediction in bladder cancer," *npj Precision Oncology*, vol. 8, no. 1, p. 233, 2024, DOI: <https://doi.org/10.1038/s41698-024-00731-6>.
- [57] L. Song et al., "A deep learning model to enhance the classification of primary bone tumors based on incomplete multimodal images in X-ray, CT, and MRI," *Cancer Imaging*, vol. 24, no. 1, p. 135, 2024, DOI: <https://doi.org/10.1186/s40644-024-00784-7>.
- [58] C.-Y. Liao et al., "Personalized prediction of immunotherapy response in lung cancer patients using advanced radiomics and deep learning," *Cancer Imaging*, vol. 24, no. 1, p. 129, 2024, DOI: <https://doi.org/10.1186/s40644-024-00779-4>.
- [59] X. Huang et al., "Predicting prognosis for epithelial ovarian cancer patients receiving bevacizumab treatment with CT-based deep learning," *npj Precision Oncology*, vol. 8, no. 1, p. 202, 2024, DOI: <https://doi.org/10.1038/s41698-024-00688-6>.
- [60] H. Takagi et al., "Development of deep learning-based novel auto-segmentation for the prostatic urethra on planning CT images for prostate cancer radiotherapy," *Radiological Physics and Technology*, vol. 17, no. 4, pp. 819-826, 2024, DOI: <https://doi.org/10.1007/s12194-024-00832-8>.
- [61] Z. Wang et al., "Identification of histopathological classification and establishment of prognostic indicators of gastric adenocarcinoma based on deep learning algorithm," *Medical Molecular Morphology*, vol. 57, no. 4, pp. 286-298, 2024, DOI: <https://doi.org/10.1007/s00795-024-00399-8>.
- [62] H. Shen et al., "Development of a deep learning model for cancer diagnosis by inspecting cell-free DNA end-motifs," *npj Precision Oncology*, vol. 8, no. 1, p. 160, 2024, DOI: <https://doi.org/10.1038/s41698-024-00635-5>.
- [63] Q.-H. He et al., "Deep learning system for malignancy risk prediction in cystic renal lesions: a multicenter study," *Insights into Imaging*, vol. 15, no. 1, p. 121, 2024, DOI: <https://doi.org/10.1186/s13244-024-01700-0>.
- [64] M.-R. Lee et al., "Cross-site validation of lung cancer diagnosis by electronic nose with deep learning: a multicenter prospective study," *Respiratory Research*, vol. 25, no. 1, p. 203, 2024, DOI: <https://doi.org/10.1186/s12931-024-02840-z>.