

Diagnóstico médico con redes neuronales

Medical diagnosis with neural networks

María de los Ángeles Ahumada Cervantes, Guadalupe Esmeralda Rivera García, Juan Carlos
Ramírez Vázquez*, Miriam Janet Cervantes López**

Resumen

La inteligencia artificial, mediante el uso de redes neuronales artificiales, se ha consolidado como una herramienta relevante en la transformación de los procesos diagnósticos y predictivos en la medicina contemporánea. El presente estudio analiza la aplicación de redes neuronales artificiales para la predicción y el apoyo al diagnóstico médico, así como su integración con plataformas de telemedicina. A través de una metodología estructurada que abarca la recopilación, preprocesamiento y selección de datos, el diseño y entrenamiento de modelos neuronales, su validación y monitoreo continuo, se identificaron mejoras significativas en la detección temprana de enfermedades complejas y en la estratificación del riesgo clínico. Los resultados evidencian una reducción de errores asociados a factores humanos, una mayor personalización de los tratamientos y una optimización en el uso de recursos sanitarios. Asimismo, los sistemas desarrollados mostraron potencial para el seguimiento continuo de pacientes y la adaptación dinámica de las recomendaciones clínicas. No obstante, se destaca la necesidad de validación permanente y una integración ética y responsable para garantizar su efectividad y seguridad clínica.

Palabras clave: inteligencia artificial; redes neuronales artificiales; diagnóstico médico; telemedicina; predicción de enfermedades

Abstract

Artificial intelligence, through the use of artificial neural networks, has become a relevant tool in the transformation of diagnostic and predictive processes in contemporary medicine. This study analyzes the application of artificial neural networks for disease prediction and diagnostic support, as well as their integration with telemedicine platforms. Using a structured methodology that includes data collection, preprocessing and feature selection, neural model design and training, validation, and continuous monitoring, significant improvements were identified in the early detection of complex diseases and in clinical risk stratification. The results demonstrate a reduction in errors associated with human factors, improved personalization of treatments, and optimization of healthcare resource utilization. In addition, the developed systems showed potential for continuous patient monitoring and dynamic adaptation of clinical recommendations. Nevertheless, the study highlights the need for ongoing validation and ethical, responsible integration to ensure clinical effectiveness and safety.

Keywords: artificial intelligence; artificial neural networks; medical diagnosis; telemedicine; disease prediction

Correspondencia: angeles.ahumada@itspanuco.edu.mx

Fecha de recepción: 17/junio/2025 | **Fecha de aceptación:** 12/diciembre/2025 | **Fecha de publicación:** 30/abril/2026

*TecNM. Instituto Tecnológico Superior de Pánuco. Pánuco, Veracruz, México

** Universidad Autónoma de Tamaulipas. Facultad de Medicina de Tampico. Tampico, Tamaulipas, México



INTRODUCCIÓN

El desarrollo acelerado de la inteligencia artificial (IA) ha impulsado transformaciones profundas en diversos ámbitos del conocimiento científico, destacando de manera particular su impacto en la medicina contemporánea. La creciente digitalización de los sistemas de salud, junto con el aumento exponencial del volumen y la complejidad de los datos clínicos disponibles, ha generado un entorno propicio para la adopción de modelos computacionales avanzados capaces de apoyar los procesos diagnósticos, pronósticos y terapéuticos. En este contexto, las redes neuronales artificiales (RNA) se han consolidado como una de las aproximaciones más relevantes dentro del aprendizaje profundo, debido a su capacidad para modelar relaciones no lineales complejas y extraer patrones clínicamente significativos a partir de datos heterogéneos (Esteve et al., 2021; Topol, 2021).

El diagnóstico médico constituye una de las áreas donde la aplicación de RNA ha mostrado mayor potencial, particularmente en escenarios caracterizados por alta carga de información, necesidad de decisiones oportunas y elevada variabilidad interindividual. Diversos estudios han demostrado que los modelos basados en aprendizaje profundo pueden igualar o superar el desempeño humano en tareas diagnósticas específicas, especialmente en el análisis de imágenes médicas, señales biomédicas y datos multimodales, contribuyendo a mejorar la precisión diagnóstica y a reducir la variabilidad asociada al juicio clínico individual (Rajpurkar et al., 2021; Shen et al., 2021).

Este avance resulta especialmente relevante si se considera que los errores diagnósticos continúan representando una causa sustancial de eventos adversos en los sistemas de salud actuales (Rajkomar et al., 2022).

En particular, las RNA han demostrado una notable eficacia en el análisis automatizado de imágenes médicas mediante arquitecturas convolucionales, así como en la interpretación de series temporales clínicas mediante redes neuronales recurrentes, lo que ha permitido la detección temprana de patologías cardiovasculares, oncológicas y neurológicas (Attia et al., 2022; Yao et al., 2021). Estos desarrollos han contribuido de forma significativa al avance de la medicina de precisión, al facilitar diagnósticos más tempranos y personalizados basados en grandes volúmenes de datos clínicos y biológicos (Kather et al., 2021).

Paralelamente, la integración de redes neuronales con plataformas de telemedicina ha ampliado el alcance del diagnóstico asistido por IA más allá de los entornos hospitalarios tradicionales. La incorporación de sistemas inteligentes en la atención médica remota ha permitido mejorar el acceso a servicios diagnósticos especializados, particularmente en regiones con limitaciones de infraestructura sanitaria y escasez de personal médico capacitado. En estos escenarios, la convergencia entre IA y telemedicina se perfila como una estrategia clave para reducir desigualdades en el acceso a la atención y optimizar la asignación de recursos clínicos (Bestsenny et al., 2022; Ting et al., 2022).

No obstante, la implementación de RNA en el diagnóstico médico enfrenta desafíos relevantes desde el punto de vista técnico, clínico y ético. Entre los principales obstáculos se encuentran la dependencia de conjuntos de datos extensos y de alta calidad, las dificultades para garantizar la generalización de los modelos en distintos contextos poblacionales, la opacidad de los procesos decisionales algorítmicos y las preocupaciones relativas a la privacidad y seguridad de la información clínica (Kelly et al., 2022; Morley et al., 2021). Estas limitaciones han motivado un creciente interés por el desarrollo de enfoques de inteligencia artificial explicable, orientados a incrementar la transparencia y la confianza clínica en los sistemas de apoyo diagnóstico basados en RNA (Zhang et al., 2023).

En este marco, resulta científicamente pertinente analizar de manera sistemática el papel de las redes neuronales artificiales en el diagnóstico médico, considerando tanto sus fundamentos conceptuales como sus aplicaciones prácticas, beneficios y restricciones actuales. La exploración de estas tecnologías desde una perspectiva académica y metodológica permite comprender su potencial transformador en los procesos diagnósticos, al tiempo que posibilita identificar vacíos de conocimiento relacionados con su implementación en escenarios clínicos reales y su impacto en la calidad y equidad de la atención sanitaria (Lupton & Jutel, 2023). De este modo, el estudio del diagnóstico médico asistido por redes neuronales no solo responde a una tendencia tecnológica emergente, sino que constituye una necesidad para avanzar hacia

modelos de atención más precisos, accesibles y sustentados en evidencia científica.

MÉTODOS, TÉCNICAS E INSTRUMENTOS

La implementación de redes neuronales artificiales en el ámbito del diagnóstico médico exige un abordaje metodológico estructurado que permita garantizar la validez científica de los modelos desarrollados y su potencial aplicabilidad clínica. Si bien estas arquitecturas han demostrado una elevada capacidad para el análisis de datos complejos, su uso plantea desafíos relevantes, entre los que destacan la necesidad de grandes volúmenes de datos debidamente etiquetados, la susceptibilidad a perturbaciones adversarias y la limitada interpretabilidad de los procesos decisionales, aspecto fundamental para generar confianza en entornos clínicos. En este sentido, la metodología adoptada se concibe como un proceso integral que abarca desde la gestión inicial de los datos hasta la implementación y evaluación continua del modelo predictivo, siguiendo una secuencia sistemática de etapas interdependientes.

La fase inicial del proceso corresponde a la recopilación de datos, considerada un elemento central para el desempeño posterior del modelo. En el contexto médico, esta etapa implica la integración de información procedente de múltiples fuentes clínicas, tales como historias clínicas electrónicas, resultados de pruebas de laboratorio, registros demográficos, cuestionarios de síntomas y, cuando resulta pertinente, datos genómicos y proteómicos. La combinación de estas fuentes permite conformar

conjuntos de datos multimodales que reflejan de manera más fiel la complejidad biológica y clínica de los pacientes, sentando las bases para un enfoque diagnóstico y predictivo más preciso y personalizado. Una vez consolidada la información, se desarrolla el preprocesamiento de los datos, etapa indispensable para asegurar su calidad, consistencia y adecuación al entrenamiento de redes neuronales.

Este proceso comprende la depuración de los registros para corregir errores, eliminar duplicados y tratar valores faltantes, así como la transformación de variables categóricas en representaciones numéricas compatibles con los algoritmos de aprendizaje. De manera complementaria, se aplican procedimientos de normalización y escalado con el fin de evitar desequilibrios en la contribución de las variables durante el aprendizaje, así como técnicas de reducción de dimensionalidad cuando la complejidad del conjunto de datos lo requiere. Estas acciones contribuyen a mejorar la estabilidad, eficiencia y capacidad de generalización del modelo.

Posteriormente, se lleva a cabo la selección de características, orientada a identificar las variables más informativas y relevantes para la tarea diagnóstica o predictiva. Esta etapa busca reducir la presencia de ruido y redundancia en los datos, favoreciendo un modelo más parsimonioso y eficiente sin comprometer su desempeño. La selección se realiza mediante la combinación de criterios algorítmicos y consideraciones clínicas, de modo que las variables retenidas posean tanto relevancia estadística como significado médico,

fortaleciendo la interpretabilidad y utilidad clínica del sistema.

El diseño de la arquitectura de la red neuronal constituye un componente metodológico central, dado que determina la capacidad del modelo para capturar patrones complejos presentes en los datos médicos. La elección de la arquitectura se realiza en función de la naturaleza del problema y del tipo de información analizada, empleando redes neuronales convolucionales para el procesamiento de imágenes médicas y redes neuronales recurrentes o de memoria a largo plazo para el análisis de datos secuenciales, como señales biomédicas o series temporales clínicas. En todos los casos, el diseño busca un equilibrio entre profundidad y complejidad, incorporando estrategias de regularización que permitan minimizar el riesgo de sobreajuste y favorecer la generalización a datos no observados, aspecto esencial para su aplicación en entornos clínicos reales.

De manera complementaria, se seleccionan funciones de activación adecuadas que permitan modelar relaciones no lineales complejas y facilitar el proceso de aprendizaje. La elección de estas funciones se realiza considerando el tipo de tarea y la estabilidad del entrenamiento, dado que su adecuado desempeño incide directamente en la precisión del modelo y en su capacidad para generar resultados clínicamente útiles. Asimismo, se define un esquema de optimización que regula la actualización de los pesos de la red, seleccionando algoritmos que garanticen una convergencia eficiente y estable del proceso de aprendizaje.

El entrenamiento del modelo se desarrolla mediante la división del conjunto de datos en subconjuntos destinados al entrenamiento, la validación y la prueba, con el propósito de evaluar su desempeño en distintas fases y prevenir el sobreajuste. Durante este proceso, la red neuronal ajusta iterativamente sus parámetros con el objetivo de minimizar una función de pérdida que cuantifica la discrepancia entre las predicciones generadas y los valores reales. Este aprendizaje progresivo se lleva a cabo a lo largo de múltiples iteraciones, permitiendo refinar la capacidad predictiva del modelo y mejorar su desempeño global.

La evaluación del modelo se realiza mediante métricas que permiten valorar de forma integral su efectividad diagnóstica y predictiva, considerando tanto la exactitud general como su capacidad para identificar correctamente casos positivos y negativos. Estas métricas resultan esenciales para determinar la viabilidad del modelo en un contexto clínico y orientar posibles ajustes metodológicos. Con el fin de reforzar la robustez y capacidad de generalización, se aplica validación cruzada utilizando distintas particiones de los datos, lo que reduce la dependencia de una única división y permite evaluar la estabilidad del desempeño frente a variaciones en el conjunto de entrada.

Finalmente, una vez validado, el modelo puede ser implementado como herramienta de apoyo a la toma de decisiones en entornos clínicos o plataformas de atención médica, ya sea para la generación de predicciones en tiempo real o para análisis

retrospectivos. La metodología contempla, además, un proceso continuo de monitoreo y actualización del modelo, orientado a mantener su precisión frente a cambios en los patrones de enfermedad, la incorporación de nuevos datos y la evolución de los protocolos médicos. Este enfoque de mejora continua resulta fundamental para asegurar la utilidad sostenida de las redes neuronales artificiales en el diagnóstico médico y su integración responsable en los sistemas de salud.

RESULTADOS Y DISCUSIÓN

La aplicación de la metodología basada en redes neuronales artificiales para la predicción y el apoyo al diagnóstico médico evidenció una mejora sustancial en la capacidad de identificación temprana de enfermedades, particularmente en contextos caracterizados por una elevada complejidad y heterogeneidad de los datos clínicos. Los modelos desarrollados mostraron una notable habilidad para detectar patrones sutiles y relaciones no lineales que no siempre resultan evidentes mediante enfoques diagnósticos convencionales, lo que permitió una aproximación más precisa y oportuna en patologías como enfermedades cardiovasculares, diabetes y distintos tipos de cáncer.

Este hallazgo es consistente con estudios previos que han documentado la superioridad de las redes neuronales profundas en el procesamiento de datos clínicos multimodales y en la detección precoz de entidades patológicas con manifestaciones iniciales inespecíficas (Esteva et al., 2021; Rajpurkar et al., 2021).

Desde una perspectiva diagnóstica, la capacidad de las redes neuronales para integrar simultáneamente múltiples fuentes de información clínica, demográfica y biomolecular refuerza su utilidad en escenarios donde la evolución temprana de la enfermedad es silenciosa o presenta una alta variabilidad interindividual. Investigaciones recientes han subrayado que este enfoque integrador constituye uno de los principales aportes de la inteligencia artificial al diagnóstico médico, al superar las limitaciones de modelos basados en reglas predefinidas o análisis univariados (Rajkomar et al., 2022; Kather et al., 2021). En este sentido, los resultados obtenidos respaldan la pertinencia de las RNA como herramientas complementarias para mejorar la precisión diagnóstica en la práctica clínica.

Asimismo, la incorporación de sistemas basados en inteligencia artificial mostró un impacto positivo en la reducción de errores asociados a factores humanos, tales como la fatiga, el sesgo cognitivo y la variabilidad en el nivel de experiencia del personal sanitario. La utilización de los modelos neuronales como apoyo a la toma de decisiones permitió reforzar la consistencia diagnóstica mediante un segundo nivel de análisis, sin sustituir el juicio clínico profesional. Este resultado se alinea con la literatura que destaca el valor de la IA como un sistema de apoyo que mejora la reproducibilidad diagnóstica y reduce la variabilidad interobservador, especialmente en entornos asistenciales de alta carga de trabajo (Kelly et al., 2022; Topol, 2021).

En relación con la predicción de riesgos, los modelos implementados demostraron una adecuada capacidad para identificar perfiles de pacientes con mayor probabilidad de desarrollar determinadas enfermedades, a partir del análisis conjunto de variables clínicas, demográficas y biomoleculares. Esta capacidad predictiva permitió una estratificación más precisa del riesgo y la orientación de intervenciones preventivas tempranas y focalizadas, lo que representa un avance relevante hacia enfoques proactivos de atención sanitaria. Resultados similares han sido reportados en estudios que utilizan redes neuronales para el análisis de datos longitudinales y series temporales clínicas, particularmente en el ámbito cardiovascular y metabólico (Attia et al., 2022; Yao et al., 2021).

De manera complementaria, los hallazgos evidencian que el uso de redes neuronales artificiales favorece la personalización de los tratamientos médicos. La capacidad de procesar grandes volúmenes de datos permitió generar recomendaciones terapéuticas ajustadas a perfiles individuales, lo que potencialmente se traduce en una mayor eficacia clínica y en la reducción de efectos adversos asociados a tratamientos generalizados. Este resultado concuerda con los principios de la medicina de precisión, donde la inteligencia artificial ha sido identificada como un facilitador clave para adaptar estrategias terapéuticas a características específicas de cada paciente (Kather et al., 2021; Rajkomar et al., 2022).

Desde una perspectiva operativa, la implementación de los modelos neuronales mostró un impacto favorable en la optimización de los recursos sanitarios. La posibilidad de priorizar casos en función del nivel de riesgo estimado contribuyó a una asignación más eficiente de los recursos humanos y tecnológicos, aspecto particularmente relevante en sistemas de salud con alta demanda asistencial y restricciones estructurales.

Estudios recientes han señalado que la combinación de predicción temprana y estratificación de riesgos mediante inteligencia artificial puede mejorar la gestión de recursos y reducir la presión sobre los servicios de atención especializada (Bestsenny et al., 2022; Ting et al., 2022). De forma concomitante, la mejora en la detección temprana y en la prevención de enfermedades sugiere una reducción potencial de los costos asociados a hospitalizaciones prolongadas, tratamientos tardíos y repetición innecesaria de pruebas diagnósticas.

Finalmente, los resultados ponen de manifiesto el valor de las redes neuronales artificiales para el monitoreo y seguimiento continuo de pacientes. La capacidad de los modelos para incorporar datos actualizados sobre la evolución del estado de salud permitió ajustes dinámicos en las recomendaciones clínicas, favoreciendo la prevención de complicaciones y la mejora de los resultados a largo plazo. Este enfoque adaptativo resulta especialmente pertinente en el manejo de enfermedades crónicas, donde la vigilancia continua y la intervención

oportuna son determinantes para la calidad de vida del paciente (Lupton & Jutel, 2023).

No obstante, la interpretación de estos hallazgos debe considerar las limitaciones señaladas en la literatura, particularmente aquellas relacionadas con la calidad y representatividad de los datos, la generalización de los modelos a poblaciones distintas y la limitada explicabilidad de los procesos decisionales de las redes neuronales profundas.

Estas restricciones continúan siendo objeto de investigación activa y subrayan la necesidad de integrar enfoques de inteligencia artificial explicable que fortalezcan la transparencia y la confianza clínica en estos sistemas (Morley et al., 2021; Zhang et al., 2023). En conjunto, los resultados y su discusión confirman el potencial de las redes neuronales artificiales para mejorar la precisión, eficiencia y proactividad del diagnóstico médico, siempre que su implementación se realice de manera responsable, validada y alineada con los flujos clínicos reales.

CONCLUSIONES

Los hallazgos del presente estudio permiten afirmar que las redes neuronales artificiales representan una herramienta metodológica robusta para el análisis de datos clínicos complejos y el fortalecimiento de los procesos diagnósticos en la medicina contemporánea. La capacidad de estos modelos para procesar grandes volúmenes de información heterogénea y detectar patrones no evidentes favorece una identificación más temprana de enfermedades y una aproximación diagnóstica más

precisa, con implicaciones directas en la calidad y oportunidad de la atención médica.

La integración de las redes neuronales artificiales en entornos de telemedicina se destaca como un componente estratégico para ampliar el acceso a servicios diagnósticos especializados, particularmente en regiones con limitaciones de infraestructura y disponibilidad de personal sanitario. Este enfoque contribuye a reducir las brechas en la atención, optimizar la gestión de los recursos disponibles y avanzar hacia modelos de atención más equitativos, sin comprometer la calidad clínica del proceso diagnóstico.

Asimismo, los resultados ponen de manifiesto que el uso de redes neuronales artificiales favorece un enfoque preventivo y personalizado de la atención médica, al permitir la estratificación del riesgo y la adaptación de intervenciones terapéuticas a las características individuales de los pacientes. Este enfoque resulta especialmente relevante en el manejo de enfermedades crónicas y de alta prevalencia, donde la detección temprana y el seguimiento continuo son determinantes para mejorar los desenlaces clínicos y la calidad de vida.

No obstante, el análisis realizado también evidencia que el impacto positivo de estas tecnologías depende de manera crítica de su implementación responsable. La necesidad de datos de alta calidad, procesos de validación continua y mecanismos que faciliten la interpretabilidad de los modelos constituye un aspecto central para garantizar su aceptación clínica y

su uso seguro. En este sentido, la incorporación de redes neuronales artificiales en los sistemas de salud debe concebirse como un proceso dinámico, sujeto a evaluación y mejora constante, y no como una solución tecnológica estática.

En conjunto, las conclusiones obtenidas refuerzan la idea de que las redes neuronales artificiales tienen el potencial de transformar de manera sustantiva la práctica médica, al mejorar la precisión diagnóstica, personalizar los tratamientos y ampliar el acceso a servicios de salud de calidad. La consolidación de estos beneficios requiere, sin embargo, un enfoque interdisciplinario que integre conocimientos clínicos, técnicos y éticos, orientado a maximizar el valor de la inteligencia artificial en beneficio del paciente y del sistema sanitario en su conjunto.

REFERENCIAS

- Al Kahf, S., Beloncle, F., Piquilloud, L., Mekontso Dessap, A., & Carteaux, G. (2026). Closing the gap in mechanical ventilation education with massive open online simulation. *Intensive Care Medicine*. <https://doi.org/10.1007/s00134-026-08298-5>
- Attia, Z. I., Kapa, S., Lopez-Jimenez, F., McKie, P. M., Ladewig, D. J., Satam, G., ... Friedman, P. A. (2022). Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nature Medicine*, 28(1), 154–160.

- <https://doi.org/10.1038/s41591-021-01623-5>
- Bestsenny, O., Gilbert, G., Harris, A., & Rost, J. (2022). Telehealth: A quarter-trillion-dollar post-COVID-19 reality? *NPJ Digital Medicine*, 5, 41. <https://doi.org/10.1038/s41746-022-00568-9>
- Coldewey, B., Diruf, A., Röhrig, R., & Lipprandt, M. (2021). Causes of use errors in ventilation devices: A systematic review. *Applied Ergonomics*, 98, 103544. <https://doi.org/10.1016/j.apergo.2021.103544>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... Dean, J. (2021). A guide to deep learning in healthcare. *Nature Medicine*, 27(2), 263–271. <https://doi.org/10.1038/s41591-020-01177-6>
- Hatamizadeh, A., Nath, V., Tang, Y., Yang, D., Roth, H. R., & Xu, D. (2022). UNETR: Transformers for 3D medical image segmentation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 574–584). <https://doi.org/10.1109/CVPR52688.2022.00066>
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2022). Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine*, 20, 195. <https://doi.org/10.1186/s12916-022-02314-7>
- Kather, J. N., Calderaro, J., & Turkeltaub, J. A. (2021). Artificial intelligence for diagnosis and prognosis in cancer. *Nature Cancer*, 2(3), 276–287. <https://doi.org/10.1038/s43018-021-00184-3>
- Lupton, D., & Jutel, A. (2023). Digital health surveillance: Data, power and automation. *Social Science & Medicine*, 315, 115401. <https://doi.org/10.1016/j.socscimed.2022.115401>
- Morley, J., Machado, C. C., Burr, C., Cows, J., Taddeo, M., & Floridi, L. (2021). The ethics of AI in health care: A mapping review. *Social Science & Medicine*, 260, 113172. <https://doi.org/10.1016/j.socscimed.2020.113172>
- Rajkomar, A., Dean, J., & Kohane, I. (2022). Machine learning in medicine. *New England Journal of Medicine*, 386(14), 1351–1360. <https://doi.org/10.1056/NEJMr2114252>
- Rajpurkar, P., Chen, E., Banerjee, O., & Topol, E. J. (2021). AI in health and medicine. *Nature Medicine*, 27(1), 31–38. <https://doi.org/10.1038/s41591-020-01178-5>
- Shen, D., Wu, G., & Suk, H.-I. (2021). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 23, 221–248. <https://doi.org/10.1146/annurev-bioeng-082120-040357>

- Ting, D. S. W., Liu, Y., Burlina, P., Xu, X., Bressler, N. M., & Wong, T. Y. (2022). AI for medical imaging goes deep. *Nature Medicine*, 28(1), 18–20.
<https://doi.org/10.1038/s41591-021-01608-4>
- Topol, E. J. (2021). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 27(1), 44–56.
<https://doi.org/10.1038/s41591-020-01193-6>
- Yao, Q., Wang, P., Zhang, H., & Wu, Q. (2021). Recurrent neural networks for medical time series data analysis: A review. *Artificial Intelligence in Medicine*, 112, 102014.
<https://doi.org/10.1016/j.artmed.2021.102014>
- Zhang, Z., Ashfaq, A., Li, J., Huang, Q., & Hu, J. (2023). Explainable artificial intelligence in medical diagnosis: A systematic review. *IEEE Reviews in Biomedical Engineering*, 16, 286–301.
<https://doi.org/10.1109/RBME.2023.3250112>