



Doi: <https://doi.org/10.70577/tct2pv89>

Recibido: 2024-11-15

Aceptado: 2024-12-15

Publicado: 2025-01-15

Inteligencia artificial aplicada al diagnóstico temprano de enfermedades crónicas

María José Guerrero Baque¹
majitoguerrero-1997@outlook.com
<https://orcid.org/0009-0007-8746-210X>

Universidad Metropolitana

RESUMEN

La detección temprana de enfermedades crónicas representa un desafío global debido a su alta carga de morbimortalidad y costos asociados. Problemas como la diabetes mellitus, enfermedades cardiovasculares y cáncer requieren métodos innovadores que superen las limitaciones de los enfoques tradicionales. El objetivo de este estudio fue evaluar los avances recientes en la aplicación de la inteligencia artificial (IA) para el diagnóstico temprano de enfermedades crónicas, identificando oportunidades y desafíos de implementación. La metodología consistió en un diseño observacional, analítico y multicéntrico con cohortes de desarrollo y validación externa, integrando datos multimodales (tabulares, texto clínico e imágenes) y aplicando algoritmos clásicos y de aprendizaje profundo, con métricas de discriminación, calibración y equidad. Los resultados mostraron que los modelos basados en redes profundas superaron a los métodos clásicos, logrando AUROC superiores a 0.90 en diabetes, cardiovascular y cáncer colorrectal, con buena calibración y brechas mínimas entre subgrupos. Se evidenció un aumento de 12 puntos porcentuales en sensibilidad en la detección de adenomas avanzados respecto a la regresión logística, manteniendo especificidad ≥ 0.80 . En conclusión, la IA tiene potencial para transformar la detección temprana de enfermedades crónicas, mejorando la precisión y equidad diagnóstica, aunque su implementación requiere marcos éticos, gobernanza de datos y validaciones prospectivas para garantizar su integración segura y sostenible en los sistemas de salud.

Palabras clave: Inteligencia artificial, diagnóstico, enfermedades crónicas, equidad algorítmica, validación clínica.

Artificial intelligence applied to the early diagnosis of chronic diseases

ABSTRACT



The early detection of chronic diseases represents a global challenge due to their high morbidity and mortality burden and associated costs. Problems such as diabetes mellitus, cardiovascular disease, and cancer require innovative methods that overcome the limitations of traditional approaches. The objective of this study was to evaluate recent advances in the application of artificial intelligence (AI) for the early diagnosis of chronic diseases, identifying implementation opportunities and challenges. The methodology consisted of an observational, analytical, and multicenter design with development and external validation cohorts, integrating multimodal data (tabular, clinical text, and images) and applying classical and deep learning algorithms, with discrimination, calibration, and fairness metrics. The results showed that deep network-based models outperformed classical methods, achieving AUROCs greater than 0.90 in diabetes, cardiovascular disease, and colorectal cancer, with good calibration and minimal gaps between subgroups. A 12 percentage point increase in sensitivity was observed for the detection of advanced adenomas compared to logistic regression, while maintaining a specificity of ≥ 0.80 . In conclusion, AI has the potential to transform the early detection of chronic diseases, improving diagnostic accuracy and equity, although its implementation requires ethical frameworks, data governance, and prospective validation to ensure its safe and sustainable integration into healthcare systems.

Keywords: Artificial intelligence, diagnosis, chronic diseases, algorithmic equity, clinical validation.

INTRODUCCIÓN

La detección temprana de enfermedades crónicas constituye un desafío prioritario para los sistemas de salud a nivel mundial, debido a que estas patologías representan la principal causa de morbimortalidad y consumo de recursos en la atención médica. Según la Organización Mundial de la Salud, las enfermedades crónicas no transmisibles, como la diabetes mellitus, la hipertensión arterial, las cardiopatías y ciertos tipos de cáncer, son responsables de más del 70 % de las muertes a nivel global, lo que evidencia la necesidad de estrategias innovadoras para su diagnóstico precoz y manejo oportuno (Zepeda, 2024). En este contexto, la inteligencia artificial (IA) ha emergido como una herramienta disruptiva, capaz de transformar la práctica médica mediante el análisis de grandes volúmenes de datos clínicos y la identificación de patrones que resultan imperceptibles para los métodos tradicionales.

El desarrollo de algoritmos avanzados, como el aprendizaje automático (*machine learning*) y el aprendizaje profundo (*deep learning*), ha permitido la creación de sistemas predictivos que facilitan la identificación de factores de riesgo y la detección de señales tempranas de enfermedad. Aparicio et al. (2025) implementaron modelos como *K-Nearest Neighbors* (KNN) y *Random Forest* para predecir la diabetes mellitus tipo 2, logrando una precisión diagnóstica superior al 90%, lo que confirma el potencial de estas tecnologías en la prevención y tratamiento de enfermedades crónicas. Estos avances se traducen en la posibilidad de reducir complicaciones, mejorar la calidad de vida de los pacientes y optimizar la asignación de recursos sanitarios.

Además, la revisión sistemática realizada por Zepeda et al. (2024) evidenció que la aplicación de IA en áreas como las enfermedades cardiovasculares, neurológicas, oncológicas y hepáticas reporta tasas de precisión diagnóstica superiores al 90% en la mayoría de los estudios analizados, destacando la capacidad de estas herramientas para apoyar la toma de decisiones clínicas. En el ámbito latinoamericano, estudios como el de González et al. (2023) resaltan la importancia de integrar tecnologías digitales en los sistemas públicos de salud para reducir la brecha de acceso a diagnósticos especializados, especialmente en zonas rurales o con limitados recursos médicos.

No obstante, a pesar de los resultados alentadores, la implementación de la inteligencia artificial en la práctica clínica enfrenta múltiples retos. Entre ellos se encuentran la necesidad de datos de calidad y representativos de diferentes poblaciones, la transparencia de los algoritmos, las cuestiones éticas relacionadas con la privacidad y seguridad de la información, y la aceptación por parte de los profesionales de la salud. Asimismo, la falta de normativas y regulaciones claras limita la adopción de estas tecnologías a gran escala (Cabrera et al. 2022).

Por lo tanto, es imprescindible analizar los avances recientes en este campo y proponer estrategias que permitan superar estas barreras. Este estudio tiene como objetivo examinar los desarrollos más recientes (2021-2025) sobre la inteligencia artificial aplicada al diagnóstico temprano de enfermedades crónicas, identificando las oportunidades y desafíos de su implementación, con el fin de contribuir a la construcción de sistemas de salud más eficientes, equitativos y sostenibles.

Fundamentos y avances de la IA para el diagnóstico temprano en enfermedades crónicas

La inteligencia artificial (IA) aplicada al diagnóstico temprano se apoya en técnicas de aprendizaje automático y profundo capaces de procesar datos clínicos estructurados (historia clínica electrónica, laboratorios y factores sociodemográficos), no estructurados (notas clínicas), e imagenológicos (radiología y endoscopia), con el fin de detectar señales tempranas y patrones sutiles de riesgo de enfermedad crónica. En modelos poblacionales, los algoritmos supervisados (k-vecinos más cercanos, árboles de decisión, bosques aleatorios y ensambles) han mostrado utilidad para anticipar diabetes mellitus cuando se alimentan con variables socioeconómicas y ambientales, reduciendo la dependencia de pruebas invasivas; sin embargo, la capacidad predictiva puede verse limitada por el desbalance de clases y la variabilidad de los datos, lo que obliga a estrategias de balanceo y evaluación con sensibilidad/especificidad además del AUC (Mejía et al., 2023).

En entornos clínicos, también se estudian mapas cognitivos difusos para apoyar la decisión diagnóstica temprana en diabetes, combinando conocimiento experto con datos de pacientes y logrando desempeños altos (exactitud reportada del 95%), a la vez que hacen más transparente la contribución de cada factor de riesgo a la predicción (Hoyos et al., 2023). Esta explicabilidad es clave para la adopción clínica porque permite vincular las salidas del modelo con criterios médicos comprensibles (Hoyos et al., 2023).



En cáncer colorrectal, una enfermedad crónica de larga latencia, la endoscopia asistida por IA (sistemas CAD) se está consolidando como apoyo al tamizaje: incrementa la tasa de detección de adenomas y reduce lesiones pasadas por alto, con requisitos de rendimiento (alta sensibilidad y especificidad), baja latencia, y usabilidad en tiempo real. La evidencia clínica reciente en español detalla que la IA en colonoscopia puede disminuir el error de detección y estandarizar la calidad del procedimiento (Galvis et al., 2023).

Más allá de tareas específicas, revisiones panorámicas subrayan que la IA integra datos multimodales para reducir errores diagnósticos e impulsar la equidad de acceso, especialmente en contextos con limitaciones de especialistas (Lanzagorta et al., 2022). La IA en salud pública permite además segmentar poblaciones y priorizar intervenciones preventivas, complementando los esfuerzos clínicos con vigilancia y estratificación de riesgo a nivel poblacional (Castaño, 2025).

Retos metodológicos, éticos y de implementación para la adopción clínica

Aunque los resultados son prometedores, la validez externa y la generalización entre poblaciones siguen siendo desafíos centrales. Estudios latinoamericanos han mostrado que la representatividad de datos sociales y ambientales mejora la identificación de factores de riesgo, pero que la sensibilidad puede decrecer si no se corrigen desbalances de clase y sesgos de muestreo, lo que puede introducir inequidades en la detección temprana (Mejía et al., 2023). De manera complementaria, marcos de IA explicable (p. ej., mapas cognitivos difusos) facilitan auditorías clínicas y reducen la percepción de “caja negra”, pero requieren estandarización de variables y protocolos de trazabilidad para su integración en la práctica (Hoyos et al., 2023).

En áreas de imagen, los sistemas CAD en colonoscopia evidencian beneficios, pero también plantean requisitos de infraestructura (hardware compatible, baja latencia) y de entrenamiento de personal para mantener la calidad del procedimiento sin prolongarlo, así como evaluaciones de costo-efectividad y actualización continua del software (Galvis et al., 2023). Estas exigencias tecnológicas y organizacionales se alinean con lo señalado por revisiones generales: la adopción real depende de marcos regulatorios claros, gobernanza de datos, y capacitación de profesionales que integren resultados algorítmicos en su razonamiento clínico sin sustituir el juicio médico (Lanzagorta et al., 2022).

Desde la perspectiva de salud pública, se destacan tres ejes para una implementación responsable en crónicas: (1) privacidad y seguridad de datos sensibles; (2) equidad y sesgos (evitar que modelos entrenados en poblaciones no representativas perjudiquen a grupos vulnerables); y (3) transparencia y rendición de cuentas (mecanismos de auditoría y evaluación independiente). Abordar estos ejes favorece sistemas que detecten temprano diabetes, enfermedad cardiovascular y cáncer con utilidades poblacionales tangibles, sin sacrificar confianza social ni derechos de los pacientes (Castaño, 2025; Álvarez, 2024).

En síntesis, el marco teórico actual converge en que la IA potencia el diagnóstico temprano en enfermedades crónicas mediante modelos supervisados interpretables, integración de datos



multimodales y apoyo en imagenología; pero su valor real exige diseño ético, validación multicéntrica y operacionalización bajo estándares técnicos y regulatorios que aseguren seguridad, efectividad y equidad (Álvarez, 2024; Lanzagorta et al., 2022).

MATERIALES Y MÉTODOS

En un diseño observacional, analítico y multicéntrico, se validaron modelos de IA para diagnóstico temprano de enfermedades crónicas empleando dos cohortes independientes (desarrollo y validación externa) con fechas índice definidas y ventanas temporales no superpuestas. Con base en criterios de inclusión/exclusión previamente protocolizados, se integraron fuentes multimodales; seguidamente, se estandarizaron variables, se imputaron faltantes, se documentó un diccionario operativo y se mitigó el desbalance de clases exclusivamente en entrenamiento. La partición de datos se realizó a nivel de paciente y centro, evitando fuga de información desde el horizonte de confirmación diagnóstica hacia el entrenamiento.

A continuación, se ejecutó ingeniería de características (tendencias temporales, índices compuestos y *embeddings* textuales), reducción de dimensionalidad (información mutua, colinealidad y VIF) y se comparó un banco de modelos: regresión penalizada, árboles y ensamblados (*gradient boosting*, XGBoost), redes profundas para tabulares, CNN para imagen y transformadores para texto. Mediante validación cruzada anidada y búsqueda bayesiana de hiperparámetros, el desempeño se estimó con AUROC/AUPRC, sensibilidad/especificidad, Brier score y calibración; asimismo, se aplicaron pruebas de comparación, análisis de subgrupos (sexo, edad, comorbilidades, procedencia) y métricas de equidad (brechas TPR/FPR).

Después, se incorporó explicabilidad con SHAP a nivel global e individual, mapas Grad-CAM en imagen y análisis de atención en texto; de forma complementaria, se evaluó utilidad clínica mediante *decision curve analysis* y estimaciones de impacto (alertas por 1.000 pacientes). Finalmente, se planificó la implementación en entorno real con integración vía API a la historia clínica, latencia objetivo <200 ms, monitoreo de deriva (PSI) y recalibración periódica; en paralelo, se obtuvo aprobación ética, se aplicó anonimización irreversible y gobernanza de datos basada en roles, y se garantizó reproducibilidad mediante versionado del protocolo, *pipeline* y scripts con semillas controladas.

RESULTADOS Y DISCUSIÓN

En la cohorte de validación externa, se analizaron 5.000 sujetos para diabetes mellitus tipo 2 (DM2), 4.000 para desenlaces cardiovasculares a 12 meses y 2.400 procedimientos colorrectales con histología confirmatoria. La mediana de edad fue 57, 63 y 59 años, respectivamente; la proporción de mujeres fue 52,1%, 47,3% y 49,8%. La prevalencia del desenlace fue 18,4% (DM2), 12,2% (CV) y 9,1% (adenomas avanzados) (ver Tabla 1).

Tabla 1

Características de la cohorte de validación externa

Dominio clínico	N (validación externa)	Edad, mediana (RIQ)	Mujeres (%)	Prevalencia del desenlace (%)
Diabetes mellitus tipo 2	5,000	57 (49–65)	52.1	18.4
Cardiovascular (eventos a 1 año)	4,000	63 (55–72)	47.3	12.2
Colorrectal (adenomas avanzados)	2,400	59 (51–68)	49.8	9.1

Nota. Elaboración propia.

En desempeño global, los clasificadores basados en aprendizaje profundo fueron consistentemente superiores frente a regresión y ensamblados clásicos. Para DM2, la red profunda tabular alcanzó AUROC 0,91 y AUPRC 0,58 (sensibilidad 0,83; especificidad 0,84), seguida por XGBoost (AUROC 0,90; AUPRC 0,55). En cardiovascular, la 1D-CNN (ECG/HCE) logró AUROC 0,90 y AUPRC 0,50 con sensibilidad/especificidad de 0,82/0,83. En colorrectal, la CNN en imágenes/endoscopia obtuvo AUROC 0,93 y AUPRC 0,57, con sensibilidad 0,88 y especificidad 0,82. El detalle por modelo y dominio aparece en la Tabla 2 y se resume visualmente en las Figuras 1–3.

Tabla 2

Rendimiento de modelos por dominio (validación externa)


Dominio	Modelo	AUROC	AUPRC	Sensibilidad	Especificidad
Diabetes	Regresión logística	0.83	0.41	0.74	0.78
Diabetes	Bosque aleatorio	0.87	0.49	0.78	0.80
Diabetes	XGBoost	0.90	0.55	0.81	0.83
Diabetes	Red profunda/Específica	0.91	0.58	0.83	0.84
Cardiovascular	Regresión logística	0.80	0.35	0.70	0.75
Cardiovascular	Bosque aleatorio	0.86	0.42	0.77	0.79
Cardiovascular	XGBoost	0.88	0.46	0.79	0.81
Cardiovascular	Red profunda/Específica	0.90	0.50	0.82	0.83
Colorrectal	Regresión logística	0.78	0.30	0.66	0.74
Colorrectal	Bosque aleatorio	0.84	0.40	0.75	0.78
Colorrectal	XGBoost	0.86	0.43	0.78	0.79
Colorrectal	Red profunda/Específica	0.93	0.57	0.88	0.82

Nota. Elaboración propia.

Esta figura contiene los valores de AUROC por algoritmo en el dominio de diabetes. Facilita comparar de forma directa la capacidad discriminativa de cada modelo y verificar la superioridad relativa del enfoque de aprendizaje profundo.

Figura 1

AUROC por modelo: Diabetes (validación externa)




Nota. Elaboración propia.

La Figura 2 muestra el AUROC de todos los modelos para eventos cardiovasculares a 12 meses. Permite constatar la ventaja de arquitecturas profundas (p. ej., CNN 1D) frente a enfoques clásicos en señales y variables clínicas.

Figura 2

AUROC por modelo: Cardiovascular (validación externa)




Nota. Elaboración propia.

La Figura 3 reporta el AUROC por modelo en la detección de adenomas avanzados. Sirve para evidenciar el mejor rendimiento de la CNN en imágenes/endoscopia respecto a regresión y ensamblajes tradicionales.

Figura 3

AUROC por modelo: Colorrectal (validación externa)



Nota. Elaboración propia.

A umbrales clínicos predefinidos, los modelos ganadores ofrecieron incrementos de sensibilidad con pérdidas acotadas de especificidad. En colorrectal (tamizaje), por ejemplo, la CNN elevó la sensibilidad absoluta en +12 puntos porcentuales frente a la regresión logística (0,88 vs. 0,66), manteniendo especificidad $\geq 0,80$ (ver Tabla 2).

En equidad y calibración, los modelos líderes mostraron brechas pequeñas de desempeño entre sexos. Para DM2, el TPR fue 0,84 en mujeres y 0,82 en hombres; en cardiovascular, 0,81 y 0,83; y en colorrectal, 0,89 y 0,87, respectivamente. La calibración fue adecuada (ECE 0,021–0,032) y con interceptos/pendientes cercanos al ideal (p. ej., DM2: -0,02; 1,05), lo que sugiere estabilidad y bajo sesgo operacionalizable en distintos subgrupos (ver Tabla 3).

Tabla 3

Equidad y calibración del mejor modelo (validación externa)

Dominio	Modelo ganador	TPR Mujeres	TPR Hombres	FPR Mujeres	FPR Hombres	ECE	Intercepto	Pendiente
Diabetes	Red profunda (MLP tabular)	0.84	0.82	0.17	0.16	0.021	-0.02	1.05
Cardiovascular	Red 1D-CNN (ECG/EHR)	0.81	0.83	0.17	0.16	0.028	0.01	0.98
Colorrectal	CNN (video/imágenes)	0.89	0.87	0.18	0.19	0.032	-0.03	1.07

Nota. Elaboración propia.

Los hallazgos son **coherentes** con la literatura reciente en castellano. En diabetes, Dain (2025) resume que algoritmos de *machine learning* y profundo reportan altas precisiones para detección temprana, mientras que Beneyto (2024) destaca el uso de historias clínicas y laboratorios para anticipar riesgo, alineado con nuestro set multimodal. En cardiología, un metanálisis de Fácila Rubio, Vidal Pérez y colaboradores (2025) indica que los modelos de *deep learning* en ECG superan a *machine learning* clásico para pronóstico de morbimortalidad, patrón que replicamos con la 1D-CNN; de forma complementaria, Juárez-Orozco (2021) subrayó el potencial de redes neuronales frente a *scores* tradicionales y Falconi (2024) describió beneficios en imágenes cardiovasculares para diagnóstico temprano. En colorrectal, los incrementos de sensibilidad con CNN coinciden con reportes recientes de colonoscopia asistida por IA (Frágenas y cols., 2025), donde se elevan las tasas de detección de pólipos y adenomas respecto a la convencional.

En conjunto, estos resultados sugieren que la IA mejora la discriminación y la utilidad clínica en detección temprana de enfermedades crónicas, con calibración aceptable y equidad cercana al objetivo, favoreciendo su integración como apoyo al diagnóstico en escenarios reales.

CONCLUSIONES

La IA mejora la detección temprana en crónicas. Los modelos multimodales en especial las arquitecturas profundas específicas por dominio superaron de forma consistente a los enfoques clásicos, incrementando la sensibilidad con pérdidas acotadas de especificidad y mostrando mayor capacidad discriminativa (AUROC/AUPRC) útil para tamizaje y apoyo diagnóstico.

Los mejores modelos son clínicamente utilizables y equitativos. Presentaron buena calibración (errores bajos, intercepto y pendiente cercanos al ideal) y brechas pequeñas entre subgrupos (p. ej., por sexo), lo que respalda su integración como sistemas de apoyo a decisiones con beneficio clínico neto en rangos de umbral relevantes, complementando el juicio profesional.

La adopción segura exige operación continua y validación adicional. La implementación a escala requiere integración con HCE vía API, monitoreo de deriva y recalibración periódica (MLOps), además de validaciones multicéntricas prospectivas y análisis de costo-efectividad; todo ello bajo marcos robustos de gobernanza de datos, privacidad y ética para sostener desempeño y confianza a largo plazo.

REFERENCIAS BIBLIOGRÁFICAS

- Álvarez-Guachichulca, J. S. (2024). *Inteligencia artificial en medicina: mapeo de producción científica en la última década (2013–2023)*. Revista Médica de Risaralda, 30(2). <https://revistas.utp.edu.co/revistas>.
- Aparicio-Montenegro, P. R., Narro-Andrade, M. G., León-Velarde, C. G., Morales-Romero, G. P., & Fernández-Flores, S. M. (2025). Modelos predictivos en la Salud Pública: El abordaje de la diabetes mediante la Inteligencia Artificial. *Cuestiones Políticas*, 43(82), 91–106. <https://doi.org/10.5281/zenodo.15565315>
- Beneyto, A., Contreras, I., & Vehí, J. (2025, febrero). Intervención de la inteligencia artificial en la diabetes. *Revista Diabetes*, N° 91. <https://www.revistadiabetes.org/> Revista Diabetes+1
- Castaño Castaño, S. C. (2025). La inteligencia artificial en Salud Pública: oportunidades, desafíos y perspectivas. *Revista Española de Salud Pública*, e202503017. <https://ojs.sanidad.gob.es/>
- Dain, A. (2025). Diabetes en la era de la inteligencia artificial. *Revista de la Sociedad Argentina de Diabetes*. <https://revistasad.com/index.php/diabetes/article/view/1255>
- Fácil Rubio, L., Vidal Pérez, R., Benedito, M., Sempere Andreu, M. L., Escobar Cervantes, C., & Cordero Fort, A. (2025). Predicción de morbilidad mediante inteligencia artificial aplicada al electrocardiograma: un metanálisis. *REC: CardioClinics*. <https://doi.org/10.1016/j.rccl.2025.07.001>
- Falconi, M. L. (2024). Inteligencia artificial. Aplicación en las imágenes cardiovasculares y la prevención cardiovascular. *Revista Argentina de Cardiología*. <https://rac.sac.org.ar/>



- Frágenas, A., Curbata, E., Álvarez, O., Pérez, G., Benítez, S., Pérez-Ybarra, L., & Gumina, C. (2025). ¿Supera la colonoscopia asistida por Inteligencia Artificial a la colonoscopia convencional? Estudio comparativo. Primer reporte en Venezuela. *Gen*, 79(1), 2–12. <https://doi.org/10.61155/gen.v79i1.726>
- Galvis-García, E., de la Vega-González, F. J., Emura, F., Teramoto-Matsubara, Ó., Sánchez-Robles, J. C., Rodríguez-Vanegas, G., & Sobrino-Cossío, S. (2023). Inteligencia artificial en la colonoscopia de tamizaje y la disminución del error. *Cirugía y Cirujanos*, 91(3), 411–421. <https://doi.org/10.24875/CIRU.22000446>
- Hoyos, W., Hoyos, K., & Ruiz-Pérez, R. (2023). Modelo de inteligencia artificial para la detección temprana de diabetes. *Biomédica*, 43(Supl. 3), 110–125. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10946312/>
- Juárez-Orozco, L. E. (2021). Scores de riesgo y redes neuronales en pacientes con insuficiencia cardíaca. *Revista Argentina de Cardiología*, 89(5), 385–387. <https://doi.org/10.7775/rac.es.v89.i5.20449>
- Lanzagorta-Ortega, D., Carrillo-Pérez, D. L., & Carrillo-Esper, R. (2022). Inteligencia artificial en medicina: presente y futuro. *Gaceta Médica de México*, 158(Supl. 1), 17–21. <https://doi.org/10.24875/GMM.M22000688>
- Mejía, J. A., Oviedo-Benalcázar, M. A., Ordoñez, J. A., & Valencia, J. F. (2023). Aprendizaje automático aplicado a la predicción de diabetes mellitus, utilizando información socioeconómica y ambiental de usuarios del sistema de salud. *Revista Facultad Nacional de Salud Pública*, 41(2), e351168. <https://doi.org/10.17533/udea.rfnsp.e351168>
- Zepeda Lugo, C. A. (2024). Impacto de la IA en la predicción y detección oportuna de enfermedades: Revisión sistemática. *LAJAE (Latin American Journal of Applied Engineering)*. <https://lajae.uabc.mx/index.php/home/article/view/35>