

Estado del arte en Modelos Predictivos de Machine Learning para Eventos Cardiovasculares: Una Revisión Narrativa breve sobre las Técnicas, Variables Predictoras y Desempeño reportado en la literatura global

State of the art in Machine Learning Predictive Models for Cardiovascular Events: A brief narrative review of the techniques, predictor variables, and performance reported in the global literature

Estado da arte em modelos preditivos de aprendizado de máquina para eventos cardiovasculares: uma breve revisão narrativa das técnicas, variáveis predictoras e desempenho relatados na literatura global

Luz Melina Vázquez Cáceres¹

José Antonio Espinoza Franco¹

Víctor Manuel Melgarejo Riveros¹

¹Universidad Nacional de Caaguazú (UNCA), Facultad de Ciencias y Tecnologías

RESUMEN

La utilización de modelos predictivos de Inteligencia Artificial basados en algoritmos diseñados en Machine Learning y referenciados para su utilización como herramienta de prevención en la Medicina actual establece un progreso importante en la detección precoz de enfermedades de alto riesgo, las dolencias cardiovasculares son una de las afecciones más preocupantes entre tantas enfermedades donde el sedentarismo, el mal hábito alimenticio, el tabaquismo colaboran ampliamente en que sean la causa más frecuente de muerte. La evolución de la tecnología reúne modelos creados a partir de algoritmos que a nivel mundial y regional han mostrado grandes avances, en este artículo buscó establecer una revisión bibliográfica breve de las técnicas, variables predictoras y desempeño reportado, que fueron analizados en diferentes trabajos académicos incluyendo el establecido para el Instituto de Previsión Social (IPS) de Coronel Oviedo, Paraguay hallado en el repositorio de la Universidad Nacional de Caaguazú (Espinoza et al., 2024) p. 11. En ella se identificó y comparó el rendimiento de tres modelos de Machine Learning de aprendizaje supervisado: Regresión Logística, Árboles de Decisión y Random Forest. El estudio utilizó como base un conjunto de datos y registros, y variables de casos clínicos, el estilo de vida y otros indicadores de salud. Los resultados arrojaron que el modelo Random Forest alcanzó la mejor métrica, reportando una exactitud del 90% lo que posiciona a los modelos preferentes para la predicción de eventos cardiovasculares. Se busca establecer este trabajo como un precedente en la utilización y pruebas de campo en el sector médico paraguayo.

Palabras Clave: Machine Learning, Eventos Cardiovasculares, Random Forest, Modelo Predictivo, Revisión Sistemática.

ABSTRACT

The use of predictive models based on Artificial Intelligence, developed through Machine Learning algorithms and applied as preventive tools in modern medicine, represents a significant advance in the early detection of high-risk diseases. Cardiovascular conditions are among the most concerning worldwide, largely influenced by sedentary lifestyles, poor nutrition, and smoking, which contribute to their status as a leading cause of death.

This brief bibliographic review analyzes predictive techniques, key variables, and performance metrics reported in recent academic studies, including the model developed for the Instituto de Previsión Social (IPS) in Coronel Oviedo, Paraguay, available in the repository of the Universidad Nacional de Caaguazú (Espinoza et al., 2024). The review compares the performance of three supervised Machine Learning algorithms—Logistic Regression, Decision Trees, and Random Forest—based on clinical data, lifestyle factors, and other health indicators. The results showed that the Random Forest model achieved the best performance, with an accuracy rate of 90%, positioning it as one of the most reliable methods for predicting cardiovascular events.

This study seeks to establish a precedent for the use and future field implementation of artificial intelligence-based predictive tools in the Paraguayan healthcare sector.

Keywords: Machine Learning, Cardiovascular Events, Random Forest, Predictive Model, Systematic Review.

Recibido: 21/10/2025 Aprobado: 12/11/2025 Publicado: 12/12/2025

1. INTRODUCCIÓN

Las enfermedades cardiovasculares son principales protagonistas de muertes en el mundo, según estadísticas de la (OMS, 2021) p. 3, es la causa de mortalidad de una de cada tres defunciones globales. Estas afecciones abarcan trastornos del corazón y los vasos sanguíneos, como la cardiopatía coronaria, los accidentes cerebrovasculares y la hipertensión arterial. Una recomendación básica de la OMS subraya que la mayoría de los casos pueden prevenirse mediante el cambio de hábitos a aquellos más saludables, el control de factores de riesgo tales como el tabaquismo, la mala alimentación, la falta de actividad física y el consumo nocivo de alcohol, así como la detección y el tratamiento a tiempo. Por otro lado, subraya la necesidad de fortalecer los sistemas de salud para avalar el acceso equitativo a servicios de diagnóstico y atención temprana, a fin de reducir la mortalidad y las complicaciones asociadas a estos males.

La magnitud del problema de salud pública de los Eventos Cardiovasculares es irrefutable, siendo responsables de aproximadamente el 30% de las muertes a nivel mundial y cerca del 27% en Paraguay. “La detección tardía y la falta de un sistema de alerta temprana contribuyen a estas cifra en la fecha, se registró 82.991 consultas sobre



hipertensión esencial entre 2021 y 2024, lo que acentúa la necesidad de herramientas tecnológicas” («MSPyBS», 2013) p. 4. De ahí la importancia de investigar en la literatura académica regional los avances que se lograron en la detección temprana de enfermedades a partir de la utilización de los modelos predictivos de Machine Learning en la actualidad, buscando determinar la factibilidad de su implementación en el sector sanitario Paraguayo.

2.2. Objetivo de la Revisión

Al establecerse una revisión narrativa breve, el objetivo principal de la investigación se resume en examinar la literatura científica en referencia a los modelos predictivos de Machine Learning para Eventos Cardiovasculares, publicados a nivel regional sobre su ejecución y el beneficio de múltiples técnicas, variables apoyados en indicadores médicos y las métricas de desempeño asociadas.

3. METODOLOGÍA DE LA REVISIÓN

3.1. Estrategia de Búsqueda y Selección de Estudios

Se implementó una estrategia de búsqueda, acogiendo publicaciones científicas en español e inglés entre 2020 y 2025.

Las búsquedas se realizaron en revistas científicas indexadas tales como: Scopus, PubMed, ScienceDirect, IEEE Xplore, SciELO y Redalyc, se incluyeron repositorios institucionales nacionales como fuentes secundarias teniendo en cuenta la existencia de trabajos desarrollados en el ámbito médico local que servirán de precedente para nuevos estudios y la posterior evaluación de la adopción de la herramienta.

En relación a los criterios de inclusión fueron:

En primera instancia estudios que emplearan algoritmos de Machine Learning o Deep Learning en predicción de eventos cardiovasculares. Los reportes de estudio con métricas de desempeño (accuracy, sensibilidad o especificidad). La posibilidad del acceso al texto completo de manera a pesar la información incluida.

En cuanto a los criterios de exclusión:

Aquellas investigaciones que no se amparan en el periodo establecido de tiempo, publicaciones internacionales que no pertenezcan a la región, aquellos reportes que validan otras métricas no establecidas en este marco de investigación.

3.2. En el Marco Teórico de esta investigación de revisión se seleccionaron los siguientes artículos luego de un tamiz realizado con el sistema Prisma:

3.2.1. Desarrollo de un sistema predictivo y de apoyo clínico para enfermedades cardiovasculares mediante machine learning y deep learning: un enfoque en el infarto de miocardio

El motivo principal de este trabajo radicó en la búsqueda y combinación de algoritmos tales como redes neuronales profundas, árboles de decisión y regresión logística y su eficacia en el análisis de datos y expedientes clínicos, antecedentes de salud y métricas fisiológicas de pacientes con propensiones a insuficiencia cardíaca. Los hallazgos derivados de este estudio muestran que los modelos de deep learning como las redes neuronales multicapa consiguieron un alto grado de precisión y sensibilidad en la detección de riesgo de infarto, muy por encima de los métodos tradicionales.

“La utilización de estas tecnologías puede darse en sistemas clínicos como puntal de apoyo a la decisión, mejorando el diagnóstico rápido y temprano y reducir la mortalidad asociada a eventos cardiovasculares” (Gisbert, 2024) p.10.

3.2.2. Predicción de eventos cardiovasculares y hemorrágicos en pacientes con doble antiagregación con modelos machine learning

La predicción de eventos cardiovasculares y hemorrágicos en pacientes bajo doble terapia antiagregante, es el objeto de estudio de esta investigación en el cual se empleó variados modelos de machine learning para optimizar la evaluación del riesgo clínico.

Los indicadores utilizados fueron: demográficas, clínicas y farmacológicas para alimentar algoritmos como regresión logística, Random Forest y redes neuronales artificiales. Estos últimos modelos reportaron una mayor precisión y capacidad de discriminación que las escalas de riesgo tradicionales utilizadas. “La estratificación más personalizada y eficiente del riesgo es la clave en este estudio, apuntando a mejorar diagnósticos terapéuticos y a la mitigación de eventos adversos en pacientes tratados con antiagregantes plaquetarios” (Pérez, 2020) p. 9.

3.2.3. Diseño de una aplicación basada en técnicas de aprendizaje automático para la detección temprana de ataques cardiovasculares

En esta investigación buscó integrar regresión logística, Random Forest y redes neuronales reunidos en una plataforma interactiva que procese datos clínicos, antecedentes médicos y señales fisiológicas en tiempo real.

Este instrumento logra una precisión de alta valoración en la identificación de riesgo cardiovascular, por sobre todo cuando se combinan varios indicadores y modelos predictivos.

“Su uso radica en el funcionamiento como un sistema de alerta temprana y apoyo clínico, optimizando la prevención, el diagnóstico a tiempo y la intervención médica en pacientes con riesgo de inclinaciones y dolencias cardíacas” (Rans et al., 2025), p 15.

3.2.4. Modelo de Predicción para alerta temprana de Eventos Cardiovasculares mediante técnicas de Supervised Machine Learning en el Instituto de Previsión Social (IPS) de Coronel Oviedo, 2024

Se incluye este Proyecto Final de Grado desarrollado a nivel local, en el cual se examina una base de datos de pacientes con factores de riesgo, aplicando tres algoritmos principales analizados en este artículo buscando comparar su precisión y capacidad predictiva.

Los resultados muestran que el modelo de Random Forest obtuvo el mejor desempeño en materia de exactitud y confiabilidad, superando a los otros métodos, lo que permitiría su viabilización y su uso en el medio sanitario local.

Concluyen el trabajo estableciendo que “la inclusión de herramientas tecnológicas basadas en inteligencia artificial pueden optimizar los procesos de diagnóstico preventivo y apoyar la toma de decisiones clínicas en el sistema de salud nacional” (Espinoza et al., 2024) p. 20.

3.2.5 Impacto de la IA en la Predicción y Detección Oportuna de Enfermedades: Una Revisión Sistemática

En este material se hace énfasis del impacto positivo de la IA en la predicción de enfermedades sin embargo a la par surgen retos que deben ser saltados para que la colaboración tecnológica se pueda dar de forma amplia, el desconocimiento de su uso, la interpretación de los datos y la manipulación de la información siguen siendo materia pendiente en el área (Zepeda et al., 2024) p. 20.

3.4. Técnicas de Machine Learning Revisadas

“Las técnicas de Machine Learning estudiadas en este artículo de revisión se centran en tres modelos de aprendizaje supervisado” (Jiménez, 2022) p. 21. por su amplia aplicación, solidez metodológica y capacidad de interpretación en situaciones clínicas.

Estas técnicas muestran un equilibrio adecuado entre precisión, transparencia y facilidad de implementación en ambientes donde la finalidad principal es la predicción del riesgo cardiovascular y la comprensión de los indicadores que influyen en él.

Regresión Logística: “es un conjunto de técnicas estadísticas que tratan de explicar cómo se modifica la variable dependiente o resultado, cuando cambian una u otras variables, denominadas independientes o predictoras” (Fiuza y Rodríguez, 2000).

Es uno de los modelos estadísticos más utilizados en el área médica y epidemiológica para la estimación de probabilidades de eventos binarios es decir la presencia o ausencia de enfermedad.

“Su mayor beneficio reside en la simplicidad, interpretabilidad y capacidad para identificar la relación entre variables clínicas y el riesgo de padecer eventos cardiovasculares” (Jiménez, 2022), (p 478).

Árboles de Decisión: es un modelo de predicción cuyo objetivo principal es el aprendizaje inductivo a partir de observaciones y construcciones lógicas (Barrientos

et al., 2009). También, ofrece una estructura fácilmente interpretable por profesionales de la salud, estimando su aceptación y aplicabilidad práctica (p. 10).

Random Forest: Es un modelo de ensamble derivado de los árboles de decisión, que combina múltiples árboles para optimar la precisión y comprimir el riesgo de sobreajuste (Tejada, 2025) p. 8.

En los estudios revisados, “ha mostrado un desempeño sobresaliente en términos de exactitud y estabilidad, siendo fundamentalmente útil para examinar conjuntos de datos con numerosas variables clínicas y de estilo de vida” (Gisbert, 2024; Pérez, 2020; Espinoza et al., 2024).

4. RESULTADOS Y DISCUSIÓN

4.1. Elección y Aplicación del método PRISMA:

Para asegurar la claridad, transparencia y confiabilidad en el proceso de selección de los estudios, se persiguieron los lineamientos del método PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses).

Si bien esta revisión no se establece en una revisión sistemática exhaustiva, la utilización del método PRISMA permitió organizar y documentar de forma estructurada las etapas de búsqueda, cribado, elegibilidad e inclusión de los trabajos escogidos.

Esta orientación asevera que los resultados exhibidos se asienten en una selección rigurosa de fuentes, evadiendo sesgos y duplicidades.

Los estudios examinados concuerdan en que las técnicas de aprendizaje supervisado, fundamentalmente Random Forest y las Redes Neuronales Profundas, brindan un rendimiento superior para la predicción de las enfermedades de riesgo cardiovascular.

Las variables predictoras más comunes detectadas fueron: edad, presión arterial, colesterol, tabaquismo, diabetes, índice de masa corporal y antecedentes familiares.

El análisis PRISMA por su parte refiere (Barquero, 2022) “el proceso de identificación, cribado, elegibilidad e inclusión de los estudios analizados en la revisión sistemática sobre modelos predictivos de Machine Learning aplicados a eventos cardiovasculares” p. 25.

4.2. Proceso de identificación y selección de estudios según la metodología PRISMA

Tabla 1 Identificación y Selección según metodología Prisma

Etapa	Descripción	Cantidad (Q)	Observaciones
Identificación	Registros identificados mediante bases de datos electrónicas (Scopus, PubMed, SciELO, RedALyC, Google Scholar).	125	Búsqueda inicial mediante palabras clave relacionadas con “Machine Learning” y “Cardiovascular Events”.
	Registros adicionales identificados en otras fuentes (tesis, repositorios institucionales, congresos).	15	Incluye literatura gris y documentos locales relevantes.
Total inicial	—	140	—
Cribado	Registros después de eliminar duplicados.	85	Eliminación de repeticiones entre bases.
	Registros excluidos tras revisión de título y resumen por falta de pertinencia temática.	65	Se excluyeron artículos sin relación directa con modelos predictivos.

Etapa	Descripción	Cantidad (Q)	Observaciones
	Registros seleccionados para lectura a texto completo.	20	—
Elegibilidad	Artículos evaluados a texto completo.	20	Se analizaron metodología, métricas y calidad de datos.
	Artículos excluidos (por falta de datos cuantitativos, enfoque no predictivo o ausencia de métricas de desempeño).	16	—
Incluidos en la revisión final	Estudios incorporados en la síntesis narrativa cualitativa.	4	Gisbert (2024), Pérez (2020), Rans et al. (2025), Espinoza et al. (2024).

Elaboración propia de Autores

Descripción complementaria al método PRISMA

La transparencia del proceso, radica principalmente en la documentación de las cadenas de búsqueda aplicadas en cada base de datos (“machine learning” AND “cardiovascular events” AND “prediction models”), junto con los operadores booleanos utilizados.

Las búsquedas se realizaron de manera independiente por dos revisores, quienes evaluaron los títulos, resúmenes y textos completos de los artículos. Las discrepancias se resolvieron mediante consenso, siguiendo las recomendaciones de la guía PRISMA 2020 (Page et al., 2021).

Diagrama de flujo del proceso PRISMA adaptado

Ilustración 1 Diagrama de Flujo



Elaboración propia de Autores

De un total de 140 registros iniciales, solo 4 estudios cumplieron los criterios de inclusión: uso de modelos de Machine Learning o Deep Learning, aplicación a la predicción de eventos cardiovasculares y disponibilidad de métricas de rendimiento (Accuracy, Sensibilidad, Especificidad, etc.).

4.2. Resumen de métricas de Desempeño:

Modelo	Accuracy (%)	Sensibilidad (%)	Especificidad (%)	Fuente
Regresión Logística	84	80	82	Espinoza, 2024
Árboles de Decisión	86	83	84	Espinoza, 2024

Modelo	Accuracy (%)	Sensibilidad (%)	Especificidad (%)	Fuente
Random Forest	91	89	90	Pérez, 2020 / Espinoza, 2024
Redes Neuronales	93	91	89	Gisbert, 2024 / Rans, 2025

4.3. Desempeño Reportado

La importancia del análisis de esta revisión es la exactitud (accuracy) como indicador fundamental utilizado. Además, la tabla muestra que, de las técnicas evaluadas, resultando el modelo Random Forest es el que suministra el mayor indicador de alerta temprana con una exactitud considerable del 90%.

4.4. Síntesis narrativa de datos

Se construyó una síntesis narrativa clasificando las categorías en autor, año, objetivo, tipo de algoritmo aplicado, variables predictoras analizadas, métricas de desempeño y aportes más importantes.

También se establece la comparación cualitativa de los orientaciones, marcando propensiones comunes.

Tabla 2 Cuadro de síntesis narrativa

Autor / Año	Objetivo del estudio	Algoritmo(s) aplicado(s)	Variables predictoras principales	Métricas reportadas	Principales hallazgos y aportes
Gisbert (2024)	Desarrollar un sistema predictivo de apoyo clínico para enfermedades cardiovasculares utilizando <i>Machine Learning</i> y <i>Deep Learning</i> .	Redes Neuronales Multicapa, Árboles de Decisión, Regresión Logística.	Edad, IMC, presión arterial, frecuencia cardíaca, antecedentes médicos.	Accuracy 93%, Sensibilidad 91%, Especificidad 89%.	Las Redes Neuronales superan a los métodos tradicionales; muestran alto potencial para diagnóstico temprano.
Pérez (2020)	Predecir eventos cardiovasculares y hemorrágicos en pacientes bajo doble terapia antiagregante.	Regresión Logística, <i>Random Forest</i> , Redes Neuronales Artificiales.	Variables demográficas, clínicas y farmacológicas.	Accuracy 90%, Sensibilidad 88%.	<i>Random Forest</i> y Redes Neuronales obtuvieron mejor precisión que las escalas clínicas convencionales.
Rans et al. (2025)	Diseñar una aplicación inteligente	Regresión Logística, <i>Random</i>	Señales fisiológicas en tiempo real,	Accuracy 92%,	Propone integración de <i>Machine</i>

Autor / Año	Objetivo del estudio	Algoritmo(s) aplicado(s)	Variables predictoras principales	Métricas reportadas	Principales hallazgos y aportes
	para la detección temprana de ataques cardiovasculares.	<i>Forest</i> , Redes Neuronales.	antecedentes clínicos.	Sensibilidad 90%.	<i>Learning</i> en aplicaciones móviles de alerta temprana.
Espinoza et al. (2024)	Implementar un modelo predictivo de <i>Machine Learning</i> para riesgo cardiovascular en el IPS Coronel Oviedo.	Regresión Logística, Árboles de Decisión, <i>Random Forest</i> .	Edad, presión arterial, colesterol, hábitos de vida.	Accuracy 91%, Sensibilidad 89%.	<i>Random Forest</i> mostró el mejor rendimiento; el modelo sirve como precedente para validaciones futuras en Paraguay.

Fuente de Elaboración propia de Autores

Este cuadro se demuestra una síntesis narrativa, usando de apoyo la revisión comparativa de los estudios seleccionados, sobresalen los criterios de aplicabilidad, desempeño y relevancia. No se utilizaron técnicas estadísticas, debido a la heterogeneidad de los diseños y métricas.

4.5. Discusión: Modelo de Predicción y Estado del Arte

El análisis de los estudios revisados manifiesta una evolución muy notable en la aplicación de modelos de Machine Learning (ML) y Deep Learning (DL) para la detección y predicción de eventos cardiovasculares en la región.

La incorporación de algoritmos avanzados, como Random Forest y Redes Neuronales Profundas, logran mejorar fundamentalmente la precisión del diagnóstico en comparación a los métodos estadísticos tradicionalmente usados.

A nivel global, Gisbert (2024) expone que “los modelos basados en Deep Learning resaltan en sensibilidad y especificidad a los orientaciones clásicas, lo que defiende la propensión hacia sistemas clínicos automatizados de apoyo al diagnóstico profesional médico” p. 10.

En el ámbito regional, Pérez (2020) Revalida el potencial del machine learning en medios clínicos complejos, “fundamentalmente en pacientes bajo doble antiagregación, donde los modelos al mismo tiempo predicen el riesgo cardiovascular, y las complicaciones hemorrágicas” p. 24.

Por su parte, Rans et al. (2025), acentúan los hallazgos “sobre la integración práctica de estas tecnologías a las aplicaciones móviles e interfaces interactivas, de modo a ofrecer un monitoreo continuo y la alerta temprana, buscando por sobre todo la prevención” p. 10.

En el panorama local, el modelo desarrollado por Espinoza et al. (2024) en el Instituto de Previsión Social (IPS) de Coronel Oviedo, Paraguay, fortalece la viabilidad de aplicar modelos supervisados (Regresión Logística, Árboles de Decisión y Random Forest) con resultados auspiciosos en exactitud y confiabilidad.

Este adelanto es un paso importante hacia la transformación digital del sistema de salud paraguayo, permitiendo una detección temprana y un manejo más eficiente de los factores de riesgo cardiovascular. Este estudio sirve de precedente para su implementación en el sector sanitario local.

En definitiva, los hallazgos demuestran que la composición de tecnología, datos clínicos organizados y algoritmos inteligentes se erige como un instrumento potencial para mejorar los diagnósticos y la toma de decisiones médicas.

No obstante, aún se identifican retos relevantes, como la necesidad de bases de datos más amplias, la estandarización de variables y la validación de los modelos, personal capacitado, cobertura digital amplia y apertura profesional para la adopción, especialmente en países en desarrollo donde la infraestructura tecnológica es incipiente.

5. CONCLUSIONES

Los avances de la Inteligencia Artificial establecen un punto muy positivo en la resolución de problemáticas en muchos ámbitos, es así que los modelos de Machine Learning y Deep Learning revisados en este artículo se catalogan como instrumentos positivos para la predicción temprana de enfermedades en el área médica, beneficiando ampliamente su cobertura en razón de la precisión, rapidez y apoyo en la toma de decisiones médicas. El modelo Random Forest se erige como adecuado para el medio por su estabilidad y capacidad de generalización.



En Paraguay, la implementación de estos tipos de tecnologías resulta prometedor y desafiante, establecer una gestión preventiva en instituciones como el IPS garantiza una disminución del riesgo y por ende costos y cargos públicos.

La investigación sugiere que la combinación de enfoques predictivos, aplicaciones móviles y sistemas de alerta puede evitar muchas muertes, beneficiando de esa forma la salud pública.

Extender la investigación local, logrando la implementación como prueba piloto en la ciudad, sería el camino recomendado a seguir, encauzando la misma a las diferentes situaciones que obstaculicen su incorporación, la burocracia y la resistencia al uso de tecnologías son algunos escollos por superar.

6. REFERENCIAS BIBLIOGRÁFICAS

- Barquero, W. (2022). Análisis de Prisma Como metodología para la revisión sistemática: Una aproximación general. *Saúde em Redes*, 8(sup1), 339-360. <https://doi.org/10.18310/2446-4813.2022v8nsup1p339-360>
- Barrientos, R., Cruz, N., y Acosta, H. (2009). Árboles de decisión como herramienta en el diagnóstico médico. *Rev Med UV*, 6. https://www.uv.mx/rm/num_anteriores/revmedica_vol9_num2/articulos/arboles.pdf
- Espinoza, J., Vázquez, L., y Melgarejo, V. (2024). Modelo de Predicción para Alerta Temprana de Eventos Cardiovasculares Mediante Técnicas de Supervised Machine Learning en el Instituto de Previsión Social (IPS) de Coronel Oviedo, 2024 [Universidad Nacional De Caaguazú - Facultad de Ciencias Tecnologías]. <https://publicaciones.fctunca.edu.py/server/api/core/bitstreams/2cb42644-8a8a-4bbd-b989-4fd698b8e534/content>
- Fiuza, D., y Rodríguez, J. (2000). Regresión Logística. *Nefrología*, 20(6), 477-565. <https://www.revistanefrologia.com/es-la-regresion-logisticauna-herramienta-articulo-X0211699500035664>
- Gisbert, P. (2024). Desarrollo de un sistema predictivo y de apoyo clínico para enfermedades cardiovasculares mediante machine learning y deep learning: Un enfoque en el infarto de miocardio [Univesitat Politècnica de Valencia]. <https://riunet.upv.es/entities/publication/ca4fb881-e4cc-4ce7-ad68-297690d225cb>

- Jiménez, A. (2022). Revisión sistemática de literatura: Técnicas de aprendizaje automático (Machine Learning). *Cuaderno Activa*, 13(1), 113-121. <https://ojs.tdea.edu.co/index.php/cuadernoactiva/article/view/849>
- Ministerio de Salud Pública y Bienestar Social. (2013). Al año, unos 6.000 paraguayos mueren por enfermedades cardiovasculares. <https://www.mspbs.gov.py/portal/366/al-ano-unos-6-000-paraguayos-mueren-por-enfermedades-cardiovasculares.html>
- Organización Mundial de la Salud. (2021). Enfermedades cardiovasculares". <https://www.who.int/es/news-room/fact-sheets/detail/cardiovascular-diseases-%28cvds%29?>
- Pérez, P. (2020). Predicción de eventos cardiovasculares y hemorrágicos en pacientes con doble antiagregación con modelos machine learning [Universidad de Salamanca]. <https://gredos.usal.es/handle/10366/144568>
- Rans, N., Gamez, J., y Linero, D. (2025). Diseño de una aplicación basada en técnicas de aprendizaje automático para la detección temprana de ataques cardiovasculares [Universidad del Norte]. <https://manglar.uninorte.edu.co/handle/10584/13385#page=1>
- Tejada, D. A. (2025). Desarrollo y optimización de modelos predictivos de machine learning para pacientes con enfermedad renal crónica. *Alerta, Revista científica del Instituto Nacional de Salud*, 8(4), 354-365. <https://doi.org/10.5377/alerta.v8i4.21163>
- Zepeda, C., Insfran, A., y Arévalos, A. (2024). Impacto de la IA en la Predicción y Detección Oportuna de Enfermedades: Una Revisión Sistemática. *UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA*, 7(1), 11. <https://doi.org/10.69681/lajae.v7i1.35>