

Perceptrón multicapa aplicado a la predicción clínica de esteatosis hepática

Multilayer perceptron applied to the clinical prediction of hepatic steatosis

Alberto Guevara-Tirado^{1*}  <https://orcid.org/0000-0001-7536-7884>

¹ Universidad Científica del Sur. Lima, Perú.

* Autor para la correspondencia: albertoguevara1986@gmail.com

RESUMEN

Introducción: La esteatosis hepática es la acumulación de grasa hepática. En general, sin síntomas visibles, con posibilidad de progresar a esteatohepatitis y cirrosis. Un diagnóstico temprano es crucial para su manejo.

Objetivo: Predecir la presencia o ausencia de esteatosis hepática con la utilización de datos clínicos mediante un modelo de perceptrón multicapa.

Métodos: Estudio analítico y transversal de 912 adultos de una base de datos secundaria del repositorio Dryada. La variable dependiente fue la esteatosis hepática. Se utilizaron 11 exámenes de laboratorio y el índice de masa corporal como variables predictoras. Se empleó redes neuronales tipo perceptrón multicapa, evaluadas mediante tabla de clasificación de pronósticos correctos y capacidad predictiva del modelo.

Resultados: El área bajo la curva del modelo fue de 0,917. En el conjunto de entrenamiento, el porcentaje de pronósticos correctos para identificar la esteatosis hepática fue de 71,10 %, y para descartarla, de 92,70 %. En la fase de prueba, estos valores fueron de 70,50 % y 88,50 %, respectivamente. Al comparar la presencia o



ausencia de esteatosis hepática diagnosticada por ecografía con la clasificación obtenida mediante perceptrón multicapa, se observó una asociación moderada (coeficiente Phi = 0,612) y una concordancia aceptable (Kappa = 0,59). Los pacientes clasificados con la enfermedad por el modelo, la presentaron en ecografía 18,48 veces más frecuente que aquellos clasificados sin ella (OR = 18,48; IC 95 %: 11,4-29,5). La sensibilidad fue del 71 %, la especificidad del 89 %, y los valores predictivos positivo y negativo fueron del 71 % y 88 %, respectivamente.

Conclusiones: La red neuronal tipo perceptrón multicapa tuvo una elevada capacidad para descartar esteatosis hepática a partir de datos clínicos de laboratorio.

Palabras clave: hígado graso, ficha clínica, redes neuronales, toma de decisiones asistida por computador.

ABSTRACT

Introduction: Hepatic steatosis is the accumulation of hepatic fat; In general, without visible symptoms, and with the possibility of progressing to steatohepatitis and cirrhosis. An early diagnosis is crucial for its management.

Objective: To predict the presence or absence of hepatic steatosis using clinical data through a multilayer perceptron model.

Methods: Analytical and cross-sectional study of 912 adults from a secondary database of the Dryada repository. The dependent variable was hepatic steatosis. Eleven laboratory tests and body mass index were used as predictive variables. Multilayer perceptron neural networks were used, evaluated by means of a classification table of correct predictions and predictive capacity of the model.

Results: The area under the curve of the model was 0.917. In the training set, the percentage of correct prediction to identify hepatic steatosis was 71.10% and to rule it out, 92.70%. In the test phase, these values were 70.50% and 88.50%, respectively. When comparing the presence or absence of hepatic steatosis diagnosed by ultrasound with the classification obtained by multilayer perceptron model, a moderate association (Phi coefficient=0.612) and an acceptable concordance (Kappa=0.59) were observed. Patients classified as having the disease by the model presented it on ultrasound 18.48 times more frequently than those classified without it (OR=18.48; 95% CI: 11.4-29.5). Sensitivity was 71%, specificity 89%, and positive and negative predictive values were 71% and 88%, respectively.

Conclusions: The multilayer perceptron neural network demonstrated a high capacity to rule out hepatic steatosis from clinical laboratory data.

Key words: fatty liver, clinical record, neural networks, computer-assisted decision making.



Recibido: 30/04/2025.

Aceptado: 28/09/2025.

Revisores: Maritza Petersson-Roldán y Alberto Denis-Pérez.

INTRODUCCIÓN

La esteatosis hepática (EH) es un término que engloba un espectro de afecciones asociadas a disfunción metabólica, caracterizada por la acumulación de grasa en el hígado, y que se evidencia mediante estudios de imagen o histología. Este espectro incluye tanto causas primarias como secundarias, tales como el consumo excesivo de alcohol, el uso prolongado de fármacos hepatotóxicos o ciertos trastornos hereditarios.⁽¹⁾

Su curso es mayormente benigno, con varias fases de progresión, que incluyen esteatosis simple, esteatohepatitis, fibrosis, cirrosis y, en última instancia, podría progresar a carcinoma hepatocelular.⁽²⁾ Se estima que a nivel mundial tiene una incidencia de 47 casos por cada 1000 habitantes, y una prevalencia mundial estimada en adultos del 32 %, mayor en hombres (40 %) en comparación con las mujeres (26 %).⁽³⁾

La ecografía es uno de los métodos más utilizados para la detección de EH, con una sensibilidad aproximada del 83 % y una especificidad cercana al 81 %, incluso en casos de esteatosis leve, según estudios comparativos con la fracción de grasa hepática basada en densidad de protones mediante resonancia magnética.⁽⁴⁾

El hallazgo de EH suele ser incidental durante exámenes médicos de rutina o pruebas de imagen realizadas por otras razones.⁽⁵⁾ Debido a su curso silencioso, el diagnóstico muchas veces puede pasar desapercibido, por lo que el paciente tendrá una mayor tendencia a que progrese a fibrosis, cirrosis, e incluso cáncer hepático.

En ese sentido, el uso de redes neuronales artificiales tipo perceptrón multicapa (MLP, por sus siglas en inglés) podría ser útil para determinar o descartar la presencia de EH, a partir de datos clínicos comúnmente recopilados en atención primaria. Propuesto en la década de 1980 como una mejora del perceptrón simple, es una red con capas ocultas que permite modelar relaciones no lineales complejas, entrenada mediante algoritmos como la retropropagación. Este modelo ha sido aplicado previamente en medicina para predecir enfermedades hepáticas y metabólicas. Por ello, el objetivo de este estudio fue predecir la presencia o ausencia de EH usando un MLP basado en datos clínicos.

En el contexto de la EH, su implementación podría contribuir a reducir el número de casos no diagnosticados, optimizando, además, la indicación de ecografías solo para los casos con alta probabilidad de enfermedad según el modelo. Por ello, el objetivo de esta investigación es predecir la presencia o ausencia de EH utilizando datos clínicos mediante un modelo de perceptrón multicapa.



MÉTODOS

Estudio analítico y transversal de una base de datos secundaria del repositorio Dryada (datadryad.com), conformada por 912 adultos de entre 24 y 84 años de edad, reclutados entre personas que recibieron un programa de control médico de salud, con un cuestionario estandarizado entre los años 2004 y 2012. Según lo consignado en la base de datos de acceso abierto, los programas de control de salud que se utilizaron para la recolección de datos incluyeron las siguientes pruebas: análisis de orina, recuento de células sanguíneas, química sanguínea, mediciones del antígeno de la hepatitis B y del anticuerpo de la hepatitis C, electrocardiograma, radiografía de tórax, examen con bario del tracto gastrointestinal superior y ecografía abdominal.⁽⁶⁾

La base de datos secundaria solo incluyó a participantes que no recibían medicación, incluida terapia de reemplazo hormonal y anticonceptivos orales, y que dieron negativo a la prueba del antígeno de la hepatitis B y/o del anticuerpo de la hepatitis C, así como a mujeres embarazadas.⁽⁶⁾ Para la presente investigación, se excluyó un paciente por no tener el total de datos requeridos para el estudio de redes neuronales, por lo que se utilizó 911 datos del total de la base de datos. Las características y datos clínicos de la población estudiada se encuentran en la tabla 1.

La variable dependiente fue la presencia de EH, dicotomizada en sí y no. Según refirió el autor de la base de datos, para la evaluación del hígado graso, se hicieron ecografías abdominales, que fueron realizadas por técnicos capacitados en el manejo del dispositivo de ultrasonido Aloka SSD-650CL; un gastroenterólogo las examinó e hizo el diagnóstico de hígado graso. De los cuatro criterios conocidos (contraste de eco hepatorrenal, brillo hepático, atenuación profunda y borrosidad vascular), los participantes debían tener contraste hepatorrenal y brillo hepático para recibir un diagnóstico de hígado graso.

Las variables independientes fueron el índice de masa corporal (IMC), presión arterial diastólica (PAD), aspartato aminotransferasa (AST), alanina aminotransferasa (ALT), gamma-glutamil transpeptidasa (γGTP), glucosa basal, ácido úrico, lipoproteínas de alta densidad (HDL), lipoproteínas de baja densidad (LDL), colesterol total (CT) y triglicéridos (TG). Estas variables se hallaron consignadas en la historia clínica tras la realización de los exámenes físicos y de laboratorio.

Se utilizó estadística descriptiva con frecuencias absolutas y relativas. Para la predicción de EH, se implementó un modelo de red neuronal artificial tipo perceptrón multicapa, entrenado mediante el algoritmo de retropropagación. La arquitectura del modelo incluyó una capa de entrada con 11 neuronas correspondientes a las variables clínicas seleccionadas (IMC, PAD, AST, ALT, γGTP, glucosa basal, ácido úrico, HDL, LDL, colesterol total y triglicéridos), una capa oculta con seis unidades, y una capa de salida con dos nodos para clasificar la presencia o ausencia de EH.

La función de activación utilizada en la capa oculta fue la tangente hiperbólica, mientras que en la capa de salida se aplicó la función *Softmax*. El modelo fue ajustado automáticamente por SPSS (*Analyze > Neural Networks > Multilayer Perceptron*), utilizando validación cruzada interna con división de datos en conjunto de entrenamiento (70 %) y de prueba (30 %). La optimización de los hiperparámetros se realizó



considerando el menor error de entropía cruzada y una regla de parada por falta de mejora consecutiva.

Se basó la elección del MLP en su capacidad para modelar relaciones no lineales complejas entre múltiples variables clínicas.⁽⁷⁾ Aunque no se comparó directamente con otros algoritmos en este estudio, investigaciones previas han mostrado un rendimiento comparable o superior del MLP frente a métodos como la regresión logística o los bosques aleatorios en la predicción de enfermedades cardiometabólicas,⁽⁸⁾ lo que respalda su uso como técnica válida en este contexto.

Los resultados del perceptrón multicapa incluyeron el área bajo la curva, que determina la capacidad predictiva del modelo, donde se obtuvieron valores entre 0,6 y 0,7 como un modelo pobre, 0,7 a 0,8 como un modelo aceptable, 0,8 a 0,9 como un buen modelo, y mayor a 0,9 como un modelo sobresaliente.⁽⁹⁾ También se incluyó una tabla de clasificación de pronósticos correctos, en que se puede determinar el porcentaje de casos predichos de forma correcta para la presencia o ausencia de EA. Además, se realizaron pruebas diagnósticas de sensibilidad, especificidad, valor predictivo positivo y negativo entre el total de valores de EA predichos por el perceptrón multicapa y los valores de EA obtenidos mediante ecografía.

Los hallazgos se midieron con un valor de p significativo menor del 0,05 con un intervalo de confianza al 95 %. El análisis fue efectuado con el programa SPSS Statistics 25™.

Asimismo, la base de datos provino del repositorio de datos abierto *Dryada*, con licencia Creative Commons Zero (CC0), no requiriéndose de permisos o autorizaciones debido a que la investigación se desarrolló a partir de una base de datos secundaria. Se respetó lo establecido en las normas de Helsinki.

La base de datos está disponible en <https://datadryad.org/stash/dataset/doi:10.5061/dryad.m484p>, y las especificaciones de la base de datos en <https://bmjopen.bmj.com/content/4/10/e005413>

RESULTADOS

La población del estudio estuvo compuesta predominantemente por hombres en la mediana edad. En general, los participantes presentaron un IMC dentro de los límites normales y cifras de presión arterial adecuadas. Las enzimas hepáticas se mantuvieron dentro de rangos fisiológicos, aunque se observó una mayor variabilidad en los niveles de γ GTP.

El perfil metabólico mostró concentraciones promedio de glucosa y lípidos sin alteraciones relevantes, mientras que la función renal, evaluada mediante el filtrado glomerular estimado, se encontró conservada en la mayoría de los casos. Cabe destacar que cerca de un tercio de la muestra presentó evidencia de hígado graso, lo cual podría relacionarse con características metabólicas particulares de este grupo. (Tabla 1)



Tabla 1. Características de la población de la base de datos

Variables	Media	Desviación estándar
Edad	51,13	9,57
IMC	23,12	3,12
PAS (mmHg)	120,24	14,96
PAD (mmHg)	76,14	10,01
AST (U/mL)	20,85	8,08
ALT (U/mL)	22,69	14,29
γGTP (UI/L)	25,45	24,42
Glucosa basal (mg/dL)	98,05	14,06
Ácido úrico (mg/dL)	5,25	1,37
CT (mg/dL)	209,82	35,97
TG (mg/dL)	99,87	74,93
HDL (mg/dL)	53,53	14,59
LDL (mg/dL)	128,05	31,68
eGFR (ml/min)	70,41	12,04
Sexo	Frecuencia	Porcentaje
Hombres	591	64,90
Mujeres	320	35,10
Hígado graso		
Sí	265	29,10
No	646	70,80

PAS: presión arterial sistólica; PAD: presión arterial diastólica; ALT: alanina aminotransferasa; AST: aspartato aminotransferasa; CT: colesterol total; TG: triglicéridos; IMC: índice de masa corporal; γGTP: gamma-glutamyl transpeptidasa; eGFR: tasa de filtrado glomerular.

El entrenamiento de la red neuronal se realizó con 641 pacientes, y se obtuvo un porcentaje de pronósticos incorrectos de 13,60 %. La prueba del modelo se llevó a cabo con 270 pacientes, con un porcentaje de error del 16,70 %.

Estos resultados reflejan un desempeño aceptable del modelo, con una capacidad de clasificación adecuada en ambos subconjuntos. La baja tasa de error en la fase de prueba sugiere que el modelo puede generalizar correctamente a nuevos pacientes, lo cual es



fundamental para su aplicación en contextos reales de atención primaria. Además, la diferencia relativamente pequeña entre los errores de entrenamiento y prueba indica un buen equilibrio entre ajuste y capacidad predictiva, sin evidencia de sobreajuste. Esto respalda el potencial uso del modelo como herramienta auxiliar en la detección temprana de EH utilizando solo datos clínicos accesibles. (Tabla 2)

Tabla 2. Resumen del modelo de red neuronal para predecir EH a partir de datos clínicos

Resumen		
Entrenamiento (n = 641)	Error de entropía cruzada	193,019
	Porcentaje de pronósticos incorrectos	13,60 %
	Regla de parada utilizada	1 paso consecutivo sin disminución del error
	Tiempo de entrenamiento	0:00:00.13
Pruebas (n = 270)	Error de entropía cruzada	99,928
	Porcentaje de pronósticos incorrectos	16,70 %

La estructura de la red neuronal incluyó una capa de entrada con 11 unidades correspondientes a las variables clínicas seleccionadas, una capa oculta con seis unidades, y una capa de salida con dos unidades. Se utilizó la función de activación tangente hiperbólica en la capa oculta y la función Softmax en la capa de salida para la clasificación binaria. (Figura 1)






Fig. 1. Estructura de red neuronal tipo perceptrón multicapa.

El área bajo la curva (AUC) fue de 0,917, lo que indica una excelente capacidad discriminativa del modelo para diferenciar entre pacientes con y sin EH. Este nivel de desempeño sugiere que el modelo tiene un alto potencial para apoyar la toma de decisiones en la atención primaria, a la vez que facilita la identificación temprana de

pacientes con riesgo de EH y optimiza el uso de recursos diagnósticos como la ecografía. (Figura 2)




Fig. 2. Área a bajo la curva para predicción de EH a partir de datos clínicos.

Los porcentajes globales de pronósticos correctos en los conjuntos de entrenamiento y prueba fueron de 86,40 % y 83,30 % respectivamente, lo que indica una buena capacidad de generalización del modelo. En el conjunto de entrenamiento, el modelo identificó correctamente la presencia de EH en el 71,10 % de los casos y descartó adecuadamente la enfermedad en el 92,70 %. En el conjunto de prueba, estos porcentajes fueron de 70,50 % y 88,50 %, respectivamente.

Estos resultados muestran que el modelo es especialmente eficaz para descartar la enfermedad en pacientes sin hallazgos patológicos, lo cual es valioso en escenarios de atención primaria, donde se busca minimizar estudios innecesarios. La capacidad del modelo para identificar correctamente casos positivos también es aceptable, lo que permite una identificación temprana de pacientes con probable EH que requieren seguimiento diagnóstico con ecografía u otros métodos. (Tabla 3)

Tabla 3. Clasificación de porcentaje de pronósticos correctos entre EH obtenida con ecografía y EH obtenida mediante redes neuronales tipo perceptrón multicapa

Muestra		EH pronosticado		
		Sí	No	Porcentaje correcto (%)
Entrenamiento	Sí	133	54	71,1
	No	33	421	92,7
	Porcentaje global	25,9 %	74,1 %	86,4
Pruebas	Sí	55	23	70,5
	No	22	170	88,5
	Porcentaje global	28,5 %	71,5 %	83,3

En el conjunto de prueba, la red neuronal mostró una asociación moderada con el diagnóstico ecográfico de EH ($\Phi = 0,612$; $Kappa = 0,59$), y una *odds ratio* de 18,48 (IC 95 %: 11,4-29,5), lo que indica una asociación significativa entre la clasificación del modelo y el diagnóstico ecográfico. La sensibilidad fue de 0,71 (IC 95 %: 0,600-0,793), mientras que la especificidad alcanzó un valor alto de 0,89 (IC 95 %: 0,829-0,925), lo que sugiere que el modelo es especialmente útil para descartar la enfermedad en pacientes con bajo riesgo clínico.

Asimismo, el valor predictivo negativo fue elevado (0,88), lo que refuerza la utilidad del modelo como herramienta de tamizaje negativo y contribuye a reducir las solicitudes innecesarias de ecografía en contextos de atención primaria. El valor predictivo positivo fue de 0,71 (IC 95 %: 0,608-0,801), lo que refleja un rendimiento aceptable en la identificación de casos positivos. (Tabla 4)



Tabla 4. Medidas de asociación y pruebas diagnósticas entre EH obtenido mediante ecografía y EH obtenido mediante redes neuronales tipo perceptrón multicapa (conjunto de prueba)

Medida	Valor	IC 95 %
Coeficiente Phi	0,612	-
Coeficiente Kappa de Cohen	0,59	-
<i>Odds ratio</i>	18,48	11,4-29,5
Sensibilidad	0,71	0,600-0,793
Especificidad	0,89	0,829-0,925
Valor predictivo positivo	0,71	0,608-0,801
Valor predictivo negativo	0,88	0,827-0,920

DISCUSIÓN

El uso de redes neuronales de información para detectar EH es un campo de reciente interés en medicina, y se ha explorado en estudios que construyeron modelos de clasificación basados en métodos como el bosque aleatorio, Bayes, redes neuronales artificiales, máquinas de vectores de soporte y regresión logística, para predecir la enfermedad hepática grasa.⁽¹⁰⁻¹²⁾

Aquellos antecedentes validan la robustez de los hallazgos de esta investigación respecto a que el uso de sistemas de aprendizaje automático permite la viabilidad de la detección de EH. Sobre todo, por el alto número de pacientes de esta investigación ($n = 911$) y al uso de redes neuronales simples tipo perceptrón multicapa, las cuales son más fáciles de implementar y manejar que algoritmos de redes neuronales artificiales de mayor complejidad, con la posibilidad de extenderse rápidamente a diferentes servicios de salud públicos y privados.

Los hallazgos de este estudio subrayan la notable capacidad de las redes neuronales perceptrón multicapa para predecir EH a partir de datos clínicos como el IMC y exámenes de laboratorio solicitados frecuentemente en atención primaria. Un área bajo la curva de 0,917 indica que el modelo tiene una alta precisión y confiabilidad, lo cual es significativo, dado el desafío de diagnosticar o descartar esta condición en sus primeras etapas.

Este nivel de rendimiento, que se confirma mediante pruebas de asociación, concordancia y pruebas diagnósticas, sugiere que las redes neuronales simples tipo perceptrón multicapa pueden servir como una herramienta diagnóstica robusta en entornos clínicos, lo que facilita la identificación temprana o para descartar la presencia de EH.



La capacidad predictiva de las variables utilizadas se fundamenta en su estrecha relación con los mecanismos fisiológicos y fisiopatológicos de la EH. En el caso del IMC, un valor elevado suele asociarse con una alimentación crónicamente alta en grasas, lo que incrementa la absorción de lípidos exógenos. Esta sobrecarga lipídica favorece el aumento de ácidos grasos circulantes y su posterior depósito en el tejido hepático, y promueve así el desarrollo de esteatosis;⁽¹³⁾ se ha observado que el IMC elevado incrementa la relación entre lípidos exógenos e hígado graso.⁽¹⁴⁾

También, la elevación asintomática de enzimas, como ALT, AST y γ GTP, forman parte de las primeras manifestaciones clínicas de la EH, sobre todo ALT, hallado en mayor cantidad en el citoplasma de los hepatocitos.⁽¹⁵⁾ La glucosa basal elevada puede estimular la producción hepática de lípidos, lo que incrementa el riesgo de desarrollar EH, en cuya regulación del metabolismo hepático de glucosa y lípidos intervienen factores transcripcionales y coactivadores.⁽¹⁶⁾

El desarrollo de modelos de redes neuronales para la predicción de EH que se basan en datos clínicos obtenidos en atención primaria, podría permitir a los médicos implementar intervenciones preventivas de forma más oportuna, especialmente en pacientes con factores de riesgo como obesidad, dislipidemia o alteraciones enzimáticas. Dado que la EH puede progresar hacia estadios más graves si no se detecta a tiempo, contar con herramientas predictivas fundamentadas en inteligencia artificial resulta especialmente relevante para mejorar los desenlaces clínicos.

En ese sentido, este tipo de modelo podría integrarse en los sistemas electrónicos de historias clínicas como una herramienta de tamizaje automatizado que alerte al personal de salud sobre la probabilidad de EH al introducir datos de rutina; asimismo, podría utilizarse en campañas de prevención como una evaluación preliminar para seleccionar qué pacientes requieren una ecografía hepática, optimizar el uso de recursos y facilitar la atención temprana.

A pesar de los resultados, es importante reconocer las limitaciones del estudio. La base de datos utilizada requiere mayor diversidad para tener una adecuada representatividad de la población general, por lo que es necesario validar el modelo en cohortes más grandes y diversas. Además, futuras investigaciones deben centrarse en la integración de datos adicionales, como la hemoglobina glicosilada, para mejorar aún más la precisión y aplicabilidad del modelo.

En conclusión, las redes neuronales perceptrón multicapa poseen una alta capacidad predictiva para la detección de EH a través del empleo de datos clínicos, principalmente para el descarte de esta enfermedad. Los resultados, con un área bajo la curva de 0,917, indican una excelente precisión y confiabilidad del modelo; se destaca su potencial como herramienta diagnóstica en entornos clínicos.

La implementación de este modelo podría facilitar la identificación temprana de EH, con la posibilidad de desarrollar intervenciones preventivas y tratamientos más efectivos. Futuras investigaciones podrían centrarse en la integración de datos adicionales y la optimización del modelo para mejorar aún más su rendimiento y aplicabilidad.



REFERENCIAS BIBLIOGRÁFICAS

1. Poniachik J, Roblero JP, Urzúa A, et al. A new definition for non-alcoholic fatty liver disease. *J Hepatol.* 2021;74(4):982-3. DOI: 10.1016/j.jhep.2020.09.002.
2. Ramai D, Facciorusso A, Vigandt E, et al. Progressive liver fibrosis in non-alcoholic fatty liver disease. *Cells.* 2021;10(12):3401. DOI: 10.3390/cells10123401.
3. Teng ML, Ng CH, Huang DQ, et al. Global incidence and prevalence of nonalcoholic fatty liver disease. *Clin Mol Hepatol.* 2023;29(Suppl):S32-42. DOI: 10.3350/cmh.2022.0365.
4. Lee CM, Yoon EL, Nakajima A, et al. A reappraisal of the diagnostic performance of B-mode ultrasonography for mild liver steatosis. *Am J Gastroenterol.* 2023;118(5):840-7. DOI: 10.14309/ajg.0000000000002020.
5. Kontrick AV, VanWagner LB, Yeh C, et al. Hepatic steatosis: An incidental finding that deserves attention. *Acad Emerg Med.* 2021;28(5):578-81. DOI: 10.1111/acem.14174.
6. Fukuda T, Hamaguchi M, Kojima T, et al. Association between serum γ -glutamyltranspeptidase and atherosclerosis: a population-based cross-sectional study. *BMJ Open.* 2014;4(10):e005413. DOI: 10.1136/bmjopen-2014-005413.
7. Majidzadeh Gorjani O, Byrtus R, Dohnal J, et al. Human activity classification using multilayer perceptron. *Sensors (Basel).* 2021;21(18):6207. DOI: 10.3390/s21186207.
8. Abdullah M. Artificial intelligence-based framework for early detection of heart disease using enhanced multilayer perceptron. *Front Artif Intell.* 2025;7:1539588. DOI: 10.3389/frai.2024.1539588.
9. Nahm FS. Receiver operating characteristic curve: overview and practical use for clinicians. *Korean J Anesthesiol.* 2022;75(1):25-36. DOI: 10.4097/kja.21209.
10. Zhao Q, Lan Y, Yin X, et al. Image-based AI diagnostic performance for fatty liver: a systematic review and meta-analysis. *BMC Med Imaging.* 2023;23(1):208. DOI: 10.1186/s12880-023-01172-6.
11. Ghandian S, Thapa R, Garikipati A, et al. Machine learning to predict progression of non-alcoholic fatty liver to non-alcoholic steatohepatitis or fibrosis. *JGH Open.* 2022;6(3):196-204. DOI: 10.1002/jgh3.12716.
12. Yao Y, Zhang Z, Peng B, et al. Bio-inspired network for diagnosing liver steatosis in ultrasound images. *Bioengineering (Basel).* 2023;10(7):768. DOI: 10.3390/bioengineering10070768.



13. Lizuka K, Takao K, Yabe D. ChREBP-mediated regulation of lipid metabolism: Involvement of the gut Microbiota, liver, and adipose tissue. *Front Endocrinol (Lausanne)*. 2020;11:587189. DOI: 10.3389/fendo.2020.587189.
14. Lu S, Xie Q, Kuang M, et al. Lipid metabolism, BMI and the risk of nonalcoholic fatty liver disease in the general population: evidence from a mediation analysis. *J Transl Med*. 2023;21(1):191. DOI: 10.1186/s12967-023-04047-0.
15. Xuan Y, Wu D, Zhang Q, et al. Elevated ALT/AST ratio as a marker for NAFLD risk and severity: insights from a cross-sectional analysis in the United States. *Front Endocrinol (Lausanne)*. 2024;15:1457598. DOI: 10.3389/fendo.2024.1457598.
16. Ramatchandirin B, Pearah A, He L. Regulation of liver glucose and lipid metabolism by transcriptional factors and coactivators. *Life (Basel)*. 2023;13(2):515. DOI: 10.3390/life13020515.

CÓMO CITAR EL ARTÍCULO

Guevara-Tirado A. Perceptrón multicapa aplicado a la predicción clínica de esteatosis hepática. *Rev Méd Electrón [Internet]*. 2025 [citado: fecha de acceso];47:e6585. Disponible en:
<http://www.revmedicaelectronica.sld.cu/index.php/rme/article/view/6585/6405>

