



<https://doi.org/10.24245/mim.v41iAbril.10389>

Modelo de red neuronal para predecir diálisis a 14 días en pacientes con insuficiencia renal aguda

Neural network model to predict 14-day dialysis in patients with acute renal failure.

Alberto Guevara Tirado

Resumen

OBJETIVOS: Desarrollar y evaluar un modelo de red neuronal tipo perceptrón multicapa para predecir la necesidad de diálisis a 14 días en pacientes hospitalizados con insuficiencia renal aguda.

MATERIALES Y MÉTODOS: Estudio analítico, longitudinal, que utilizó una base de datos secundaria de alcance internacional, disponible en el repositorio de datos científicos y médicos Dryad (<https://datadryad.org>) de pacientes con insuficiencia renal aguda. Se incluyeron 42 variables clínicas y de laboratorio. La base se dividió en adiestramiento (69.2%) y prueba (30.8%). Se adiestró una red neuronal artificial con una capa oculta de 9 neuronas (tangente hiperbólica) y una salida con función Softmax. Se utilizó entropía cruzada como función de pérdida. El desempeño del modelo se evaluó mediante precisión, área bajo la curva (AUC) y métricas de clasificación.

RESULTADOS: Se incluyeron 4985 pacientes. El modelo tuvo un error de entropía cruzada de 64,582 (adiestramiento) y 60,260 (prueba), con tasas de error del 0.7 y 1%. Las neuronas decisivas fueron: H1:2, H1:3, H1:6 y H1:7; destacó H1:3 (diálisis previa, SOFA, creatinina). El AUC fue de 0.995, con precisión del 99.3% (adiestramiento) y 99% (prueba). La distribución de pseudoprobabilidad mostró alta confianza en la clasificación, y la curva de ganancias identificó casi el 100% de los casos positivos en el 10% de mayor riesgo.

CONCLUSIONES: La red tipo perceptrón multicapa mostró alta precisión en la predicción de diálisis en pacientes con insuficiencia renal aguda, lo que apoya la toma de decisiones clínicas. Se recomienda la validación en cohortes externas.

PALABRAS CLAVE: Insuficiencia renal; diálisis; nefrología; red neural.

Abstract

OBJECTIVES: To develop and evaluate a multilayer perceptron neural network model to predict the need for 14-day dialysis in hospitalized patients with acute renal failure.

MATERIALS AND METHODS: Analytical, longitudinal study using an international secondary database available in the Dryad scientific and medical data repository (<https://datadryad.org>) of patients with acute kidney failure; 42 clinical and laboratory variables were included. The database was divided into training (69.20%) and test (30.8%). An artificial neuronal network was trained with a hidden layer of 9 neurons (hyperbolic tangent) and output with Softmax function, using cross entropy as loss function. Model performance was evaluated by accuracy, area under the curve (AUC) and classification metrics.

RESULTS: There were included 4985 patients. The model had a cross-entropy error of 64,582 (training) and 60,260 (testing), with error rates of 0.7% and 1.0%. The key neurons were H1:2, H1:3, H1:6, and H1:7, with H1:3 (previous dialysis, SOFA, creatinine) standing out. The AUC was 0.995, with accuracy of 99.30% (training) and 99% (testing). The pseudo-probability distribution showed high confidence in classification, and the gain curve identified almost 100% of positive cases in the 10% of highest risk.

Médico cirujano. Maestro en Medicina, Universidad Científica del Sur, Lima, Perú.

<https://orcid.org/0000-0001-7536-7884>

Recibido: 22 de febrero 2025

Aceptado: 13 de marzo 2025

Correspondencia

Alberto Guevara Tirado
albertoguevara1986@gmail.com

Este artículo debe citarse como:

Guevara-Tirado A. Modelo de red neuronal para predecir diálisis a 14 días en pacientes con insuficiencia renal aguda.
Med Int Méx 2025; 41 (4): 219-233.

CONCLUSIONS: The multilayer perceptron network showed high accuracy in dialysis prediction in acute renal failure patients, supporting clinical decision making. Validation in external cohorts is recommended.

KEYWORDS: Acute renal failure; Dialysis; Nephrology; Neural networks.

ANTECEDENTES

La insuficiencia renal aguda es una complicación frecuente en pacientes hospitalizados,¹ caracterizada por una disminución rápida y sostenida de la función renal, que implica mayor riesgo de mortalidad, estancia hospitalaria prolongada y eventos adversos.² Su tratamiento adecuado es fundamental porque en los casos más severos puede evolucionar a insuficiencia renal grave con requerimiento de terapia de reemplazo renal,³ lo que implica un pronóstico desfavorable y un incremento significativo en la carga asistencial y de los costos hospitalarios.

La necesidad de diálisis en pacientes con insuficiencia renal aguda se asocia con peor estado clínico basal, mayor gravedad de la enfermedad subyacente y disfunción multiorgánica.⁴ Sin embargo, su indicación no siempre es inmediata y puede estar influida por múltiples factores clínicos y bioquímicos. La estratificación temprana del riesgo de requerir terapia de reemplazo renal permite optimizar la toma de decisiones, evitar retrasos en la intervención y mejorar el pronóstico del paciente.

Los modelos de predicción convencionales, basados en regresión logística y puntajes clínicos, han sido útiles en la identificación de pacientes con alto riesgo de evolución.⁵ Sin embargo, su capacidad para capturar la complejidad de la fisiopatología de la insuficiencia renal aguda

es limitada, especialmente cuando se analizan múltiples interacciones no lineales entre variables. Las redes neuronales artificiales surgieron como una herramienta prometedora en este contexto, permitiendo un análisis más profundo de datos clínicos y de laboratorio para mejorar la precisión en la predicción del deterioro renal.⁶

El objetivo de este estudio fue: desarrollar y evaluar una red neuronal artificial para predecir la necesidad de diálisis en 14 días en pacientes hospitalizados con insuficiencia renal aguda. Se utilizó un conjunto de 42 variables clínicas y de laboratorio. Se buscó determinar la aplicabilidad de este modelo en la práctica clínica y su potencial para guiar decisiones terapéuticas oportunas en el tratamiento de la insuficiencia renal aguda.

MATERIALES Y METODO

Estudio analítico, longitudinal, que utilizó una base de datos secundaria de alcance internacional, disponible en el repositorio de datos científicos y médicos Dryad (<https://datadryad.org>) de pacientes con insuficiencia renal aguda. La base de datos proviene del estudio “Automated, medication-targeted alerts for acute kidney injury – A randomized trial” (“Alertas automatizadas y dirigidas a medicamentos para tratar la lesión renal aguda: ensayo aleatorizado”),⁷ efectuado en 2023. El objetivo de ese estudio fue: evaluar la repercusión de un sistema automatizado de apoyo a las decisiones clínicas en la suspensión



de medicamentos nefrotóxicos y en la evolución de pacientes con insuficiencia renal aguda.⁸

La población total de la base de datos incluyó a 5060 pacientes adultos hospitalizados, con diagnóstico de insuficiencia renal aguda, definida según los criterios de las *Kidney Disease: Improving Global Outcomes* (KDIGO): incremento $\geq 50\%$ en la creatinina en 7 días o aumento de 0.3 mg/dL en 48 horas.⁹ Para este análisis se seleccionaron intencionalmente los pacientes con valores disponibles en las variables de interés ($n = 2920$); se excluyeron 2140 casos debido a la falta de datos completos para el estudio.

En el procesamiento de datos se incluyeron 4985 casos válidos para el análisis, de los que 3449 (69.2%) se utilizaron para el adiestramiento del modelo y 1536 (30.8%) para pruebas. Se excluyeron 75 casos debido a datos faltantes o inconsistencias. El **Cuadro 1** resume el procesamiento de casos, la arquitectura de la red neuronal y su desempeño en la predicción de la necesidad de diálisis a 14 días en pacientes con insuficiencia renal aguda.

Este estudio se desarrolló siguiendo las recomendaciones establecidas en la guía RECORD (*Reporting of studies Conducted using Observational Routinely collected health Data*),¹⁰ a fin de garantizar la transparencia y calidad en el uso de datos observacionales recopilados de forma rutinaria.

Variables y mediciones

Se analizaron diversas variables clínicas y de laboratorio para evaluar su asociación con la necesidad de diálisis a 14 días en pacientes con insuficiencia renal aguda.

La variable dependiente fue la necesidad de diálisis a 14 días, definida como la iniciación del tratamiento de diálisis 14 días, o menos, después

de la hospitalización, determinada por criterios clínicos y bioquímicos.

Las variables independientes incluyeron: datos demográficos: edad (años) y sexo (masculino o femenino). Se consideró la cantidad total de días de hospitalización y la mortalidad intra-hospitalaria (sí o no). Entre las características clínicas se evaluó el avance de la insuficiencia renal aguda (sí o no), la duración del episodio de insuficiencia renal aguda (días) y la coexistencia de insuficiencia renal aguda durante el estudio (sí o no). Se registró si el paciente había tenido consulta en nefrología en los 14 días previos (sí o no) y en las 72 horas previas (sí o no).

Las variables de laboratorio incluyeron: concentraciones de creatinina en distintos momentos: creatinina al ingreso (mg/dL), creatinina mínima en las 48 horas previas (mg/dL) y mínima en los 7 días previos (mg/dL). Además, se midieron parámetros bioquímicos: anión gap, bicarbonato (mEq/L), nitrógeno ureico en sangre (mg/dL), cloruro (mEq/L) y tasa de filtrado glomerular estimada (mL/min/1.73 m²). También se incluyeron valores hematológicos: hemoglobina (g/dL) y recuento plaquetario ($10^3/\mu\text{L}$).

Para la evaluación de la gravedad clínica se utilizó la puntuación SOFA (*Sequential Organ Failure Assessment*). Asimismo, se incluyeron antecedentes de comorbilidades: diabetes mellitus tipo 2, enfermedad pulmonar crónica, insuficiencia cardiaca, cáncer, enfermedad hepática y enfermedad renal crónica.

Se analizaron los tratamientos recibidos: diálisis durante la hospitalización, inhibidores de la enzima convertidora de angiotensina, antiinflamatorios no esteroideos e inhibidores de la bomba de protones.

Todas las variables se registraron y procesaron según los criterios estandarizados, lo que ga-

Cuadro 1. Estadísticas descriptivas de las variables continuas y distribución de las variables categóricas (continúa en la siguiente página)

Variables continuas				
Variable	Mínimo	Máximo	Media	Desviación estándar
Edad (años)	18	90	68.25	15.5
Días de hospitalización	0.01	309.72	9.99	15.83
Duración de la insuficiencia renal aguda (días)	0	350.30	3.02	13.50
Creatinina (mg/dL)	0.14	10.65	1.64	0.77
Creatinina mínima 48 h previas (mg/dL)	0.06	9.01	1.18	0.68
Creatinina mínima 7 días previos (mg/dL)	0.06	6.66	1.12	0.64
Creatinina al ingreso (mg/dL)	0.06	7.91	1.34	0.72
Creatinina definida como insuficiencia renal aguda (mg/dL)	0.06	6.66	1.13	0.66
Anión gap (mEq/L)	-5	40	12.01	3.87
Bicarbonato (mEq/L)	5	48	23.42	4.92
Nitrógeno ureico en sangre (mg/dL)	1	155	33.24	19.39
Cloruro (mEq/L)	78	162	102.35	6.22
Tasa de filtrado glomerular (mL/min/1.73 m ²)	7.43	202.22	63.49	30.21
Hemoglobina (g/dL)	4.70	21.30	10.77	2.43
Plaquetas (10 ³ /μL)	3	1236	227.33	115.4
Potasio (mEq/L)	2.30	7.80	4.23	0.62
Sodio (mEq/L)	111	173	137.74	5.3
Leucocitos (10 ³ /μL)	0.10	1106	11.32	17.23
Presión arterial sistólica (mmHg)	50	262	120.57	22.25
Presión arterial diastólica (mmHg)	0	137	67.74	13.04
Pulso (latidos/min)	0	171	82.49	18.99
Frecuencia respiratoria (resp/min)	0	66	19.35	4.32
Saturación de oxígeno (%)	0	100	93.01	10.31
Temperatura (°C)	23	41	37	1.23
Hemoglobina mínima 14 días posteriores (g/dL)	2.10	16.60	8.97	2.25
Distribución de las variables categóricas				
Variable	Categoría	Frecuencia	Porcentaje	
Sexo	Masculino	2607	51.5	
	Femenino	2453	48.5	
Diálisis 14 días posteriores	No	4810	95.1	
	Sí	250	4.9	
Muerte en hospitalización	No	4339	85.8	
	Sí	721	14.2	
Dializado en hospitalización	No	4772	94.3	
	Sí	288	5.7	

**Cuadro 1.** Estadísticas descriptivas de las variables continuas y distribución de las variables categóricas (continuación)

Distribución de las variables categóricas				
Variable	Categoría	Frecuencia	Porcentaje	
Consulta con nefrología 72 h previas	No	3777	74.6	
	Sí	1283	25.4	
Hipertensión arterial	No	1624	32.1	
	Sí	3436	67.9	
Diabetes mellitus tipo 2	No	3165	62.5	
	Sí	1895	37.5	
Enfermedad pulmonar crónica	No	3522	69.6	
	Sí	1538	30.4	
Insuficiencia cardiaca	No	3449	68.2	
	Sí	1611	31.8	
Cáncer	No	3948	78	
	Sí	1112	22	
Enfermedad hepática	No	4391	86.8	
	Sí	669	13.2	
Enfermedad renal crónica	No	3773	74.6	
	Sí	1287	25.4	
Índice SOFA	0	508	10	
	1	1017	20.1	
	2	1092	21.6	
	3	1003	19.8	
	4	568	11.2	
	5	327	6.5	
	6	232	4.6	
	7	138	2.7	
	8	86	1.7	
	9	45	0.9	
	10	27	0.5	
	11	10	0.2	
	12	6	0.1	
	13	1	0	
Consumo inhibidores de la enzima convertidora de angiotensina	No	2381	47.1	
	Sí	2679	52.9	
Consumo antiinflamatorios no esteroideos	No	3507	69.3	
	Sí	1553	30.7	
Consumo inhibidores de la bomba de protones	No	1762	34.8	
	Sí	3298	65.2	
Total		5060	100	

rantiza la validez y confiabilidad de los datos usados en el análisis.

Análisis estadístico

Para la predicción de la necesidad de diálisis a 14 días en pacientes con insuficiencia renal aguda se usó un modelo de red neuronal artificial, un sistema de cómputo inspirado en el cerebro humano que aprende patrones a partir de datos.¹¹ Se incluyeron 42 covariables de la base de datos, que contó con 4985 casos válidos, divididos en un conjunto de adiestramiento (69.2%) y otro de prueba (30.8%). Se excluyeron 75 casos debido a datos faltantes o inconsistencias.

El modelo se estructuró con una arquitectura de perceptrón multicapa, un tipo de red neuronal artificial con múltiples capas de procesamiento que permiten capturar relaciones complejas.¹² Estuvo conformado por una capa de entrada, una capa oculta con 9 unidades y una capa de salida. En la capa oculta se utilizó la función de activación tangente hiperbólica, que facilita la modelización de relaciones no lineales entre las variables, mientras que en la capa de salida se usó la función SoftMax, que transforma los valores en probabilidades para la clasificación binaria ("sí" o "no" para la necesidad de diálisis). La función de error utilizada fue la entropía cruzada, una medida que evalúa la diferencia entre las predicciones y los valores reales.

El adiestramiento del modelo se hizo con un criterio de parada basado en una iteración sin disminución del error. Se obtuvo un error de entropía cruzada de 64.582 en adiestramiento y de 60.260 en prueba, con un porcentaje de predicciones incorrectas del 0.70 y 1%, respectivamente. Además, se evaluó la capacidad discriminativa del modelo mediante el área bajo la curva (AUC), un indicador que mide la capacidad del modelo para distinguir entre clases.

Para la interpretación de los pesos sinápticos, que representan la importancia de cada variable en la predicción, se analizaron los coeficientes de la capa oculta y su repercusión en la salida del modelo. Por último, la distribución de las pseudoprobabilidades pronosticadas por la red neuronal artificial permitió evaluar la separación entre los grupos de pacientes según su clasificación en la necesidad o no de diálisis. Estas pseudoprobabilidades reflejan distintos grados de certeza en la predicción, lo que permite diferenciar los casos con mayor confianza de aquellos con una clasificación más ambigua.

Se evaluó el desempeño del modelo mediante la curva de ganancias, un gráfico que muestra la efectividad del modelo respecto al azar, la matriz de clasificación de pronósticos correctos, que resume los aciertos y errores del modelo, y las pruebas de sensibilidad, especificidad, valor predictivo positivo y valor predictivo negativo, que miden la capacidad del modelo para identificar correctamente los casos positivos y negativos. El desarrollo y análisis se hicieron con el programa SPSS 25™.

Consideraciones éticas

Los autores depositaron la base de datos en el repositorio de acceso abierto Dryad (<https://datadryad.org/>) bajo la licencia *Creative Commons* (CC0), lo que permite su uso, distribución y reutilización sin restricciones. La información contenida en la base de datos se desidentificó y codificó numéricamente, a fin de garantizar la confidencialidad de los participantes y el cumplimiento de los principios éticos establecidos en la declaración de Helsinki para investigaciones con seres humanos. Este procedimiento asegura que los datos puedan utilizarse para futuras investigaciones sin poner en riesgo la privacidad de los sujetos. La base de datos está disponible para su consulta en: <https://datadryad.org/stash/dataset/doi:10.5061/dryad.kh189327p#citations>.



RESULTADOS

El análisis descriptivo mostró las características clínicas y demográficas de los pacientes incluidos en el estudio. En las variables continuas, la edad promedio fue de 68.25 ± 15.5 años, con límites de 18 y 90 años. La hospitalización tuvo una duración media de 9.99 ± 15.83 días.

En cuanto a la función renal, la creatinina mostró un valor medio de 1.64 ± 0.77 mg/dL y la tasa de filtrado glomerular promedio fue de 63.49 ± 30.21 mL/min/1.73m². Signos vitales: presión arterial sistólica media de 120.57 ± 22.25 mmHg, frecuencia cardíaca de 82.49 ± 18.99 latidos por minuto y saturación de oxígeno del $93 \pm 10.3\%$.

En las variables categóricas, el 51.5% de los pacientes eran hombres. Un 67.9% tuvo diagnóstico de hipertensión arterial y el 37.5% manifestó diabetes mellitus tipo 2. Durante la hospitalización, el 14.2% falleció y el 5.7% requirió diálisis. En cuanto a la administración de fármacos, el 52.9% recibió inhibidores de la enzima convertidora de angiotensina, el 30.7% antiinflamatorios no esteroideos y el 65.2% inhibidores de la bomba de protones. Estos datos permitieron caracterizar a la población de estudio y analizar posibles factores asociados con la evolución clínica. **Cuadro 1**

Respecto del procesamiento de casos, la arquitectura de la red neuronal y su desempeño en la predicción de la necesidad de diálisis a 14 días en pacientes con insuficiencia renal aguda, se analizaron 4985 casos válidos, con 69.2% para adiestramiento y el 30.8% para pruebas. Se excluyeron 75 por datos faltantes o inconsistencias. El modelo, basado en una red neuronal artificial tipo perceptrón multicapa, incluyó 42 covariables, una capa oculta de 9 unidades con activación tangente hiperbólica y una capa de salida con dos unidades; se usó SoftMax y entropía cruzada. El error de entropía cruzada fue de 64.582 en adiestramiento y 60.260 en prueba,

con un porcentaje de predicciones incorrectas del 0.7 y 1%, respectivamente. El adiestramiento duró, aproximadamente, 0.2 segundos; se detuvo tras una iteración sin reducción del error.

Cuadro 2

Respecto de la estructura de los coeficientes del perceptrón multicapa desarrollado para predecir la necesidad de diálisis a 14 días en pacientes con insuficiencia renal aguda, la capa de entrada incluyó 42 variables clínicas y de laboratorio, además de un nodo de sesgo para optimizar el ajuste del modelo. La capa oculta estuvo conformada por nueve neuronas (H1:1 a H1:9) y utilizó la función de activación tangente hiperbólica para modelar relaciones no lineales.

El análisis de los coeficientes sinápticos permitió identificar a las neuronas H1:2, H1:3, H1:6 y H1:7 como las más relevantes en la predicción de diálisis a 14 días. La neurona H1:3 tuvo el mayor efecto, con un coeficiente de 0.905 para necesidad de diálisis y -1.54 sin necesidad de diálisis, influida principalmente por diálisis previa, índice SOFA y creatinina mínima 7 días previos. La neurona H1:2 también mostró un peso significativo (0.835) y se activó en respuesta a la insuficiencia renal aguda, nitrógeno ureico en sangre elevado y tasa de filtrado glomerular.

La neurona H1:6 captó información decisiva de la evolución de la insuficiencia renal, la creatinina y el antecedente de diálisis, mientras que H1:7 estuvo influida por la creatinina mínima a 48 horas previas, el índice SOFA y diálisis en hospitalización, que la consolida como otro nodo fundamental en la red neuronal. En la capa de salida, dos nodos representaron las categorías "diálisis sí" y "diálisis no". Se utilizó la activación SoftMax para convertir las salidas en probabilidades e interpretarlas clínicamente. La entropía cruzada se aplicó como función de pérdida y se optimizó mediante retropropagación. Estos hallazgos sugieren que el modelo no siguió un patrón lineal simple, sino que combinó múltiples

Cuadro 2. Resumen del procesamiento de casos, información de la red y desempeño del modelo

Procesamiento de casos				
Categoría	n	Porcentaje		
Adiestramiento	3449	69.2		
Pruebas	1536	30.8		
Válido	4985	100		
Excluido	75	-		
Total	5060	-		
Estructura de la red neuronal				
Característica	Descripción			
Capa de entrada	42 covariables (estandarizadas)			
Capas ocultas	1 capa oculta, 9 unidades			
Función de activación	Tangente hiperbólica			
Capa de salida	2 unidades (sí-no diálisis en 14 días)			
Función de activación	SoftMax			
Función de error	Entropía cruzada			
Desempeño del modelo				
Fase	Error de entropía cruzada	Porcentaje de pronósticos incorrectos	Regla de parada utilizada	Tiempo de adiestramiento
Adiestramiento	64.582	0.7	1 paso sin disminución del error	00:00.2
Pruebas	60.260	1	-	-

factores clínicos y bioquímicos: diálisis previa, evolución de la insuficiencia renal, índice SOFA, nitrógeno ureico en sangre y creatinina como variables decisivas en la evaluación del riesgo de diálisis. **Cuadro 3**

El modelo alcanzó un área bajo la curva (AUC) de 0.995, lo que indica una excelente precisión y capacidad discriminatoria. Este resultado sugiere que el modelo es sumamente efectivo para diferenciar entre los pacientes que necesitarán diálisis a los 14 días y los que no lo harán. Con una AUC cercana a 1, el modelo ha mostrado un rendimiento sobresaliente, minimiza los falsos positivos y los falsos negativos, lo que lo convierte en

una herramienta potencialmente confiable para la predicción temprana de la necesidad de diálisis en pacientes con insuficiencia renal aguda. **Figura 1**

La distribución de la pseudoprobabilidad pronosticada por el perceptrón multicapa para la predicción de diálisis a 14 días mostró valores entre 0 y 1 en el eje vertical, mientras que el eje horizontal representó la variable objetivo con las categorías "Sí" y "No". Los puntos y cajas azules indicaron predicciones correctas de diálisis, y los rojos, de ausencia de diálisis, además de errores de clasificación. La mayoría de los pacientes clasificados como "Sí" tuvieron valores cercanos a 1 y los clasificados como



Cuadro 3. Coeficientes de la red neuronal para la predicción de diálisis a 14 días en pacientes con insuficiencia renal aguda (continúa en la siguiente página)

Predictor	Capa oculta								
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)
Sesgo	-0.431	-0.425	-1.391	0.337	0.46	-0.106	-0.43	0.62	0.78
Edad	-0.175	-0.3	0.152	0.476	0.129	0.065	-0.178	-0.287	-0.051
Sexo	0.284	0.281	-0.022	-0.338	-0.024	-0.101	-0.23	-0.392	-0.007
Días de hospitalización	-0.006	-0.416	-0.287	-0.451	0.019	0.444	-0.778	-0.312	0.186
Insuficiencia renal aguda: evolución mayor									
Muerte en hospitalización	-0.022	-0.24	-0.335	-0.126	0.418	0.047	0.12	-0.008	-0.203
Insuficiencia renal aguda: días de duración	0.51	0.3	-0.23	-0.408	-0.145	-0.28	-0.2	0.329	-0.323
Insuficiencia renal aguda durante estudio	0.24	0.536	-0.199	-0.409	0.317	-0.452	0.238	-0.342	0.061
Consulta renal 14 días previos	0.328	-0.036	-0.41	-0.421	0.094	0.158	-0.316	0.003	-0.254
Consulta a nefrología 72 horas previas	-0.226	0.417	-0.113	0.326	-0.049	0.024	-0.204	0.235	-0.376
Creatinina	-0.207	0.049	0.28	0.19	-0.354	0.271	-0.336	-0.334	-0.399
Creatinina mínima 48 horas previas	0.324	-0.018	-0.429	0.21	0.212	0.226	0.273	-0.282	-0.288
Creatinina mínima 7 días previos	0.481	0.278	0.398	0.11	-0.313	0.201	-0.052	0.174	0.133
Creatinina al ingreso	-0.277	0.079	-0.112	0.2	0.411	-0.493	0.465	0.258	0.167
Creatinina definida como insuficiencia renal aguda	0.425	-0.383	-0.314	-0.454	0.098	0.272	-0.29	-0.151	0.2
Anión gap	0.509	0.537	-0.048	0.065	-0.369	-0.431	-0.278	0.114	0.261
Bicarbonato	-0.048	0.16	0.052	0.382	-0.213	-0.397	0.393	0.178	0.322
Nitrógeno ureico en sangre	0.090	0.409	-0.246	0.168	-0.090	-0.447	-0.338	-0.285	-0.378
Cloruro	0.373	-0.348	0.009	-0.006	-0.021	0.212	-0.124	-0.283	0.359
Tasa de filtrado glomerular	-0.476	0.046	0.156	0.412	0.209	0.278	0.046	0.032	0.169
Hemoglobina	-0.056	0.099	0.260	0.482	0.255	0.435	-0.045	-0.036	-0.258
Plaquetas	0.207	-0.047	0.129	-0.120	0.154	0.450	0.023	0.266	-0.051
SOFA	-0.104	0.211	0.490	0.231	0.267	0.250	-0.308	-0.382	-0.479
Diabetes mellitus tipo 2	0.527	0.316	-0.202	0.117	-0.520	0.134	-0.256	-0.284	0.10
Enfermedad pulmonar crónica	-0.078	0.299	0.035	-0.031	0.224	0.351	0.197	0.385	0.321
Insuficiencia cardíaca	-0.341	0.097	0.049	-0.036	-0.198	-0.354	0.219	0.369	-0.342

Cuadro 3. Coeficientes de la red neuronal para la predicción de diálisis a 14 días en pacientes con insuficiencia renal aguda (continuación)

Predictor	Capa oculta									H(1:8)	H(1:9)
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)		
Cáncer	-0.070	-0.002	0.019	0.003	0.240	-0.111	-0.273	-0.280	-0.302		
Enfermedad hepática	-0.170	0.155	-0.079	-0.381	-0.429	0.310	-0.019	0.112	-0.142		
Enfermedad renal crónica	0.374	0.026	-0.059	0.508	-0.405	-0.149	-0.380	-0.061	0.023		
Dializado en hospitalización	0.077	0.664	1.163	-0.352	-0.448	0.437	0.588	-0.773	-0.125		
Inhibidor de la enzima convertidora de angiotensina	0.035	-0.117	0.011	0.143	-0.075	-0.153	0.001	-0.026	-0.205		
Recibe antiinflamatorios no esteroideos	-0.028	0.310	-0.004	-0.459	0.340	-0.249	-0.064	0.452	-0.095		
Recibe inhibidor de la bomba de protones	0.288	0.321	-0.015	-0.411	0.307	-0.149	0.309	0.038	0.179		
Capa de salida											
Predictor	Diálisis 14 días después = s]	Diálisis 14 días después = no									
Sexo	-1.651	2.45									
H(1:1)	0.436	-0.386									
H(1:2)	0.835	-0.123									
H(1:3)	0.905	-1.54									
H(1:4)	-0.474	0.382									
H(1:5)	-0.301	0.707									
H(1:6)	0.615	-0.224									
H(1:7)	0.494	-0.396									
H(1:8)	-0.407	0.515									
H(1:9)	-0.933	0.088									

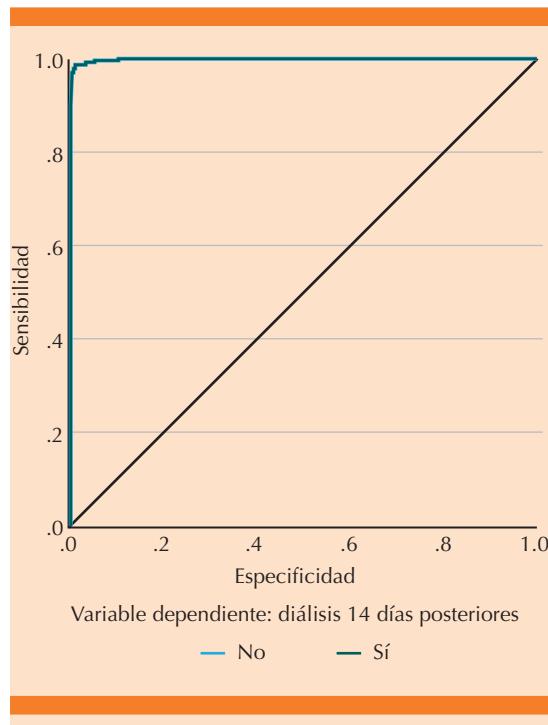


Figura 1. Desempeño discriminatorio de la perceptrón multicapa para la predicción de diálisis a 14 días en pacientes con insuficiencia renal aguda.

“No” tuvieron valores cercanos a 0, lo que refleja una diferenciación efectiva, aunque con algunas imprecisiones. **Figura 2**

La curva de ganancias evidenció el desempeño del modelo en la identificación de pacientes que requirieron diálisis. En el eje X se representó el porcentaje de la población evaluada según la probabilidad pronosticada, y en el eje Y, la ganancia acumulada de casos positivos correctamente identificados. La línea diagonal negra reflejó un modelo aleatorio, mientras que la curva azul mostró que, al evaluar el 10% de los pacientes con mayor probabilidad pronosticada, se identificó casi el 100% de los casos positivos, lo que indica un alto poder discriminatorio. En contraste, la curva roja, correspondiente a los pacientes sin diálisis, siguió una tendencia más aleatoria. Estos hallazgos sugieren que el modelo permite priorizar a los pacientes con mayor

riesgo, lo que optimizaría la intervención clínica y el uso de recursos. **Figura 3**

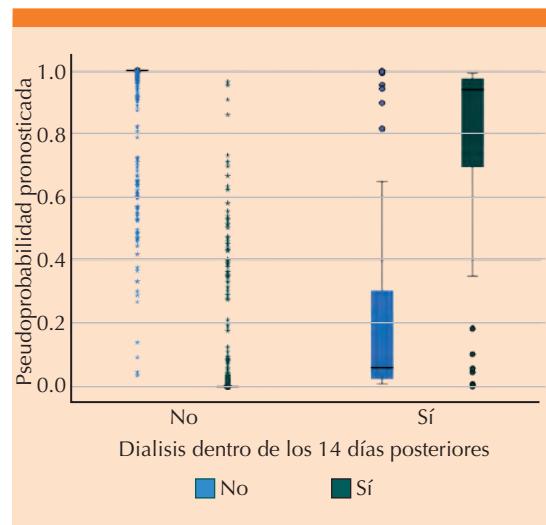


Figura 2. Distribución de la pseudoprobabilidad pronosticada en la predicción de diálisis a 14 días en pacientes hospitalizados por insuficiencia renal aguda.

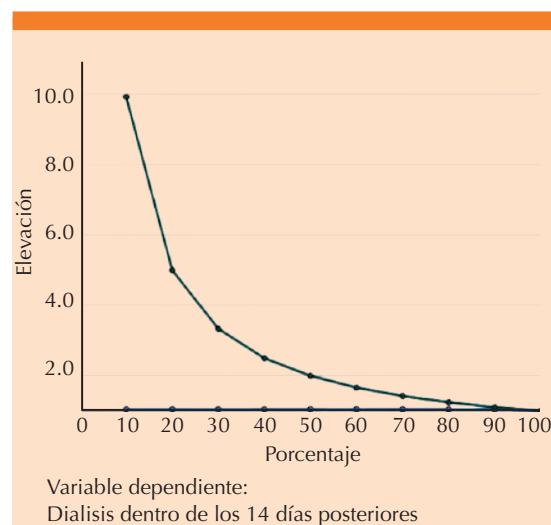


Figura 3. Curva de ganancias en la predicción de diálisis a 14 días en pacientes hospitalizados por insuficiencia renal aguda.

El modelo clasificó correctamente a 172 de 177 pacientes que requirieron diálisis en adiestramiento, con 5 falsos negativos. Entre los 3272 sin diálisis, identificó 3253 correctamente y erró 19 veces, con una precisión del 97.2% en positivos y del 99.4% en negativos, con un 99.3% global. En pruebas, detectó 57 de 63 casos positivos, con 6 falsos negativos, y clasificó correctamente a 1463 de 1473 sin diálisis, con 10 falsos positivos.

La precisión fue del 90.5% en positivos y del 99.3% en negativos, con un 99% global. La sensibilidad fue del 97.2% (IC95%: 94.7-99.6%) en adiestramiento y del 90.5% (IC95%: 83.2-97.7%) en pruebas. La especificidad se mantuvo alta: 99.4% (IC95%: 99.2-99.7%) en adiestramiento y 99.3% (IC95%: 98.9-99.7%) en pruebas. El valor predictivo positivo fue del 90.1% (IC95%: 85.8-94.3%) en adiestramiento y 85.1% (IC95%: 76.5-93.6%) en pruebas. El valor predictivo negativo alcanzó un 99.8% (IC95%: 99.7-100%) y 99.6% (IC95%: 99.3-99.9%), respectivamente. **Cuadro 4**

DISCUSIÓN

Los resultados de este estudio sugieren que el modelo de red neuronal artificial desarrollado es sumamente efectivo en la predicción de la necesidad de diálisis a 14 días en pacientes hospitalizados con insuficiencia renal aguda. En comparación con otros modelos de predicción, como los de regresión logística, la red neuronal artificial es superior significativamente en términos de sensibilidad y especificidad y tiene mayor capacidad para capturar relaciones no lineales entre las variables predictoras.¹³ En ese sentido, el uso de enfoques basados en aprendizaje profundo podría representar una alternativa más robusta en la estratificación del riesgo de diálisis en esta población.

La estructura del modelo, basada en una arquitectura de perceptrón multicapa con una capa oculta de 9 unidades y la función de activación tangente hiperbólica, permitió capturar relaciones complejas y no lineales entre las 42 covariables analizadas.

Cuadro 4. Matriz de clasificación y métricas de desempeño del modelo en la predicción de diálisis a 14 días en pacientes hospitalizados por insuficiencia renal aguda

Matriz de clasificación				
Fase	Observado	Pronosticado sí	Pronosticado no	Precisión (%)
Adiestramiento	Sí	172	5	97.2
	No	19	3253	99.4
	Porcentaje global		5.5	94.5
Pruebas	Sí	57	6	90.5
	No	10	1463	99.3
	Porcentaje global		4.4	95.6
Desempeño del modelo				
Métrica	Adiestramiento (IC95%)		Pruebas (IC95 %)	
Sensibilidad	97.2% (94.7-99.6)		90.5 (83.2-97.7)	
Especificidad	99.40% (99.2- 99.7)		99.3 (98.9-99.7)	
Valor predictivo positivo	90.1 (85.8- 94.3)		85.1 (76.5-93.6)	
Valor predictivo negativo	99.8 (99.7-100)		99.6 (99.3-99.9)	



El desempeño del modelo, evaluado mediante el error de entropía cruzada y el porcentaje de predicciones incorrectas, reflejó una alta capacidad discriminativa, con una tasa de error del 0.70% en la fase de adiestramiento y del 1% en la fase de prueba. Además, el área bajo la curva (AUC) de 0.995 sugiere que la red neuronal artificial es una herramienta sumamente confiable para la estratificación del riesgo de diálisis en pacientes con insuficiencia renal aguda, lo que podría tener implicaciones clínicas relevantes en la toma de decisiones hospitalarias.

El modelo desarrollado demostró un desempeño robusto en la predicción de la necesidad de diálisis a 14 días en pacientes con insuficiencia renal aguda, evidenciado por valores elevados de sensibilidad y especificidad en ambas fases de evaluación. La alta sensibilidad observada en la fase de adiestramiento (97.2%) y de prueba (90.5%) indica que el modelo tiene una notable capacidad para identificar correctamente a los pacientes que requerirán diálisis. Esto es decisivo en el contexto clínico porque permite la detección temprana de los sujetos en mayor riesgo y, por ende, una intervención oportuna.

La especificidad alcanzada (99.4% en adiestramiento y 99.3% en prueba) sugiere que el modelo es igualmente eficaz para descartar a los pacientes que no necesitarán diálisis, lo que minimiza el riesgo de falsos positivos y evita intervenciones innecesarias. Esto es particularmente relevante en entornos hospitalarios, donde la optimización de recursos y la reducción de procedimientos innecesarios pueden repercutir significativamente en la gestión clínica.

El análisis del valor predictivo positivo mostró que, en la fase de adiestramiento, el 90.1% de los pacientes identificados como positivos realmente necesitaron diálisis, mientras que en la fase de prueba este porcentaje fue del 85.1%. Aunque este valor es ligeramente menor en la

prueba, sigue indicando una elevada confiabilidad en la clasificación del modelo. Además, el valor predictivo negativo fue excepcionalmente alto en ambas fases (99.8% en adiestramiento y 99.6% en prueba), lo que refuerza la capacidad del modelo para identificar con precisión a los pacientes que no requerirán diálisis.

En conjunto, estos resultados confirman que la red neuronal desarrollada tiene un desempeño sumamente fiable, con excelente capacidad discriminatoria entre los pacientes con y sin necesidad de diálisis. Su implementación en la práctica clínica podría contribuir a una mejor estratificación del riesgo y optimizar la toma de decisiones médicas y la asignación de recursos hospitalarios.

Desde el análisis de los coeficientes del modelo se identificó que las neuronas H1:2, H1:3, H1:6 y H1:7 fueron las de mayor relevancia en la predicción. En particular, la neurona H1:3, que mostró el mayor efecto en la salida "sí" a la diálisis, estuvo fuertemente influida por la diálisis previa durante la hospitalización, la gravedad clínica medida por la escala SOFA y la creatinina mínima 7 días previos.

En términos fisiopatológicos, esto se explica por el hecho de que la insuficiencia renal aguda con mayor severidad, evaluada por SOFA, refleja una disfunción orgánica multisistémica que aumenta la probabilidad de requerir soporte renal.¹⁴ Además, las concentraciones bajas de creatinina en etapas previas pueden indicar una reducción en la masa muscular o una depuración ineficaz que, posteriormente, evoluciona a la necesidad de diálisis.¹⁵

El análisis de la contribución de cada variable indicó que la diálisis previa, el avance de la insuficiencia renal, el índice SOFA, el nitrógeno ureico en sangre y la creatinina fueron los predictores más influyentes en la activación de las neuronas clave. Desde el punto de vista

fisiológico, estos factores están directamente relacionados con la función renal y su deterioro. Por ejemplo, un aumento del nitrógeno ureico en sangre refleja la acumulación de productos nitrogenados debido a la disminución en la tasa de filtración glomerular,¹⁶ lo que sugiere una pérdida progresiva de la función renal. De manera similar, la elevación de la creatinina indica un deterioro del aclaramiento renal,¹⁷ un marcador decisivo en la evolución de la insuficiencia renal aguda hacia la diálisis.

El modelo desarrollado tiene varias ventajas frente a los métodos tradicionales de predicción, como la regresión logística y los índices clínicos SOFA y AKIN. Mientras que estos métodos se basan en relaciones lineales y umbrales predefinidos, la red neuronal desarrollada permite capturar interacciones complejas y no lineales entre múltiples variables. Esta capacidad mejora la clasificación de los pacientes en riesgo y ofrece un rendimiento superior en términos de sensibilidad y especificidad. En primer lugar, su capacidad para capturar interacciones complejas permite una mejor clasificación de los pacientes en riesgo, en comparación con modelos lineales convencionales. En segundo lugar, el tiempo de adiestramiento de 0.2 segundos sugiere que el modelo podría implementarse en entornos clínicos sin generar demoras en la toma de decisiones. Por último, la alta precisión del modelo podría contribuir a la optimización de recursos hospitalarios al permitir la identificación temprana de los pacientes que requerirán terapia sustitutiva renal.

Desde una perspectiva clínica, este modelo podría utilizarse para priorizar la atención de pacientes con insuficiencia renal aguda en unidades de cuidados intensivos y hospitalización general, lo que permitiría una intervención más temprana y precisa. Además, su implementación en sistemas de salud podría ayudar a optimizar la asignación de recursos hospitalarios y reducir costos asociados con la diálisis innecesaria o con su implementación tardía.

En términos de investigación, el modelo propuesto abre la puerta para el desarrollo de nuevas herramientas basadas en inteligencia artificial para la predicción y tratamiento de la insuficiencia renal, al incorporar biomarcadores avanzados y datos longitudinales para mejorar aún más su precisión. Esto podría traducirse en protocolos clínicos más personalizados y estrategias terapéuticas más eficaces en pacientes con insuficiencia renal aguda.

No obstante, el estudio tiene algunas limitaciones: se basa en una base de datos específica, lo que podría limitar su generalización a otras poblaciones. Además, aunque el modelo demostró alta precisión, es fundamental evaluar su desempeño en escenarios clínicos reales antes de su implementación definitiva. Por último, la repercusión de variables no incluidas en el modelo, como biomarcadores específicos de daño renal, podría explorarse en futuras investigaciones.

CONCLUSIONES

La red neuronal es una herramienta prometedora para la predicción temprana de la necesidad de diálisis en pacientes con insuficiencia renal aguda. Su alta capacidad predictiva facilitará la estratificación del riesgo y la toma de decisiones clínicas y contribuirá a mejorar la atención hospitalaria y la asignación de recursos en el tratamiento de pacientes con insuficiencia renal aguda.

REFERENCIAS

- Scarpioni R, Valsania T, Albertazzi V, Blanco V, et al. Acute kidney injury, a common and severe complication in hospitalized patients during the COVID-19 pandemic. *J Nephrol* 2021; 34 (4): 1019-24. <http://dx.doi.org/10.1007/s40620-021-01087-x>
- Gameiro J, Fonseca JA, Outerelo C, Lopes JA. Acute kidney injury: From diagnosis to prevention and treatment strategies. *J Clin Med* 2020; 9 (6): 1704. <http://dx.doi.org/10.3390/jcm9061704>
- Loeffler J, Hassan M, Qaqish F, Dimachkie R, et al. Predictors of renal replacement therapy requirement in cirrhotic patients with acute kidney injury. *Dig Dis Sci* 2025. <http://dx.doi.org/10.1007/s10620-025-08881-8>



4. Mas-Font S, Ros-Martinez J, Pérez-Calvo C, Villa-Díaz P, et al. Prevention of acute kidney injury in Intensive Care Units. *Med Intensiva* (Engl Ed) 2017; 41 (2): 116-26. <https://linkinghub.elsevier.com/retrieve/pii/S2173572717300395>
 5. Lai T-S, Tsao H-M, Chou Y-H, Liang S-L, et al. A competing risk predictive model for kidney failure in patients with advanced chronic kidney disease. *J Formos Med Assoc* 2024; 123 (7): 751-7. <http://dx.doi.org/10.1016/j.jfma.2023.11.010>
 6. Bajaj T, Koynier JL. Artificial intelligence in acute kidney injury prediction. *Adv Chronic Kidney Dis* 2022; 29 (5): 450-60. <http://dx.doi.org/10.1053/j.ackd.2022.07.009>
 7. Wilson F. Automated, medication-targeted alerts for Acute Kidney Injury – A randomized trial. *Dryad* 2022. <http://dx.doi.org/10.5061/DRYAD.KH189327P>
 8. Wilson FP, Yamamoto Y, Martin M, Coronel-Moreno C, Li F, Cheng C, et al. A randomized clinical trial assessing the effect of automated medication-targeted alerts on acute kidney injury outcomes. *Nat Commun* 2023; 14 (1): 1-10. <https://www.nature.com/articles/s41467-023-38532-3>
 9. Hoste EAJ, Bagshaw SM, Bellomo R, Cely CM, et al. Epidemiology of acute kidney injury in critically ill patients: the multinational AKI-EPI study. *Intensive Care Med* 2015; 41 (8): 1411-23. <http://dx.doi.org/10.1007/s00134-015-3934-7>
 10. The REporting of studies Conducted using Observational Routinely-collected health Data (RECORD) Statement. <https://www.equator-network.org/reporting-guidelines/record/>
 11. Montesinos López OA, Montesinos López A, Crossa J. Fundamentals of artificial neural networks and deep learning.
- In: Multivariate statistical machine learning methods for genomic prediction. Cham: Springer International Publishing; 2022: 379-425. http://dx.doi.org/10.1007/978-3-030-89010-0_10
12. Isabona J, Imoize AL, Ojo S, Karunwi O, Kim Y, Lee C-C, et al. Development of a multilayer perceptron neural network for optimal predictive modeling in urban microcellular radio environments. *Appl Sci (Basel)* 2022; 12 (11): 5713. <https://www.mdpi.com/2076-3417/12/11/5713>
 13. Kadnár M, Káčer P, Harničárová M, Valíček J, et al. Comparison of linear regression and artificial neural network models for the dimensional control of the welded stamped steel arms. *Machines* 2023; 11 (3): 376. <https://www.mdpi.com/2075-1702/11/3/376>
 14. Demirjian S, Chertow GM, Zhang JH, O'Connor TZ, et al. Model to predict mortality in critically ill adults with acute kidney injury. *Clin J Am Soc Nephrol* 2011; 6 (9): 2114-20. <http://dx.doi.org/10.2215/cjn.02900311>
 15. De Rosa S, Greco M, Rauseo M, Annetta MG. The good, the bad, and the serum creatinine: Exploring the effect of muscle mass and nutrition. *Blood Purif* 2023; 52 (9-10): 775-85. <http://dx.doi.org/10.1159/000533173>
 16. Du J, Zhang W, Niu J, Wang S. Association between blood urea nitrogen levels and the risk of diabetes mellitus in Chinese adults: secondary analysis based on a multicenter, retrospective cohort study. *Front Endocrinol (Lausanne)* 2024; 15. <http://dx.doi.org/10.3389/fendo.2024.1282015>
 17. Gounden V, Bhatt H, Jialal I. Renal function tests. En: *StatPearls*. Treasure Island (FL): StatPearls Publishing; 2025. <https://www.ncbi.nlm.nih.gov/books/NBK507821/>

AVISO PARA LOS AUTORES

Medicina Interna de México tiene una nueva plataforma de gestión para envío de artículos. En: www.revisionporpares.com/index.php/MIM/login podrá inscribirse en nuestra base de datos administrada por el sistema *Open Journal Systems* (OJS) que ofrece las siguientes ventajas para los autores:

- Subir sus artículos directamente al sistema.
- Conocer, en cualquier momento, el estado de los artículos enviados, es decir, si ya fueron asignados a un revisor, aceptados con o sin cambios, o rechazados.
- Participar en el proceso editorial corrigiendo y modificando sus artículos hasta su aceptación final.