



SECCIÓN CIENCIAS BIOMÉDICAS

Artículo original de investigación

Estimación de mortalidad en la enfermedad renal crónica basado en inteligencia artificial: sistema web de apoyo

Sergio Orlando Escalona González ^{1,2*} <https://orcid.org/0000-0003-4261-6842>
Ernesto Carlos Leonard Escariz ³ <https://orcid.org/0009-0008-2925-9864>
Yailé Caballero Mota ^{3,4} <https://orcid.org/0000-0002-6725-5812>
Yanela Rodríguez Álvarez ^{3,4} <https://orcid.org/0000-0003-2232-2260>
Zoraida Caridad González Milán ^{1,5} <https://orcid.org/0000-0002-4092-9389>

¹ Universidad de Ciencias Médicas de Las Tunas. Las Tunas, Cuba

² Academia de Ciencias de Cuba. Cuba

³ Universidad de Camagüey. Camagüey, Cuba

⁴ Academia de Ciencias de Cuba. Cuba

⁵ Hospital General Docente Dr. Ernesto Guevara de la Serna. Las Tunas, Cuba.

*Autor para la correspondencia: sernephron96@gmail.com

RESUMEN

Introducción: Los modelos predictivos basados en inteligencia artificial para la predicción del riesgo de mortalidad en pacientes con enfermedad renal crónica en hemodiálisis son robustos. El impacto real mejoraría si se traducen en herramientas accesibles en tiempo real. **Objetivo:** Desarrollar e implementar una aplicación web interactiva basada en inteligencia artificial para la predicción individualizada del riesgo de mortalidad en pacientes con enfermedad renal crónica en hemodiálisis. **Métodos:** Se desarrolló un sistema de apoyo a la decisión clínica basado en una red neuronal artificial multicapa entrenada con datos clínicos de pacientes incidentes en hemodiálisis. Para su desarrollo se implementó TensorFlow y Keras en Python, el cual se entrenó con datos clínicos y se exportó a formato TensorFlow.js para su integración en la aplicación web desarrollada. Se realizó preprocesamiento de datos, estandarización de variables y validación cruzada con 10 particiones para evaluar el rendimiento del modelo. **Resultados:** La aplicación web cuenta con un formulario interactivo donde el profesional de la salud puede ingresar datos clínicos relevantes del paciente. La herramienta mostró buena calibración y discriminación. Las métricas de la validación cruzada informaron una estimación sólida del rendimiento general del modelo. La aplicación permite generar predicciones en tiempo real y presenta una interfaz intuitiva y accesible. **Conclusiones:** La herramienta demuestra un impacto potencial significativo en el entorno clínico para la estratificación del riesgo de pacientes en hemodiálisis. Ofrece una lista de recomendaciones personalizadas y basadas en datos para la toma de decisiones rutinarias.

Palabras clave: enfermedad renal crónica; mortalidad; inteligencia artificial; modelo predictivo, aplicación web

Editor

Lisset González Navarro
Academia de Ciencias de Cuba.
La Habana, Cuba

Traductor

Darwin A. Arduengo García
Academia de Ciencias de Cuba.
La Habana, Cuba

Mortality estimation in chronic kidney disease based on artificial intelligence: a web-based support system

ABSTRACT

Introduction: Artificial intelligence-based predictive models for predicting mortality risk in patients with chronic kidney disease on hemodialysis are robust. The real impact would improve if they were translated into accessible, real-time tools. **Objective:** To develop and implement an interactive, artificial intelligence-based web application for the individualized prediction of mortality risk in patients with chronic kidney disease on hemodialysis. **Methods:** A clinical decision support system was developed based on a multilayer artificial neural network trained with clinical data from incident hemodialysis patients. TensorFlow and Keras were implemented in Python for its development. The network was trained with clinical data and exported to TensorFlow.js format for integration into the developed web application. Data preprocessing, variable standardization and cross-validation with 10 partitions were performed to evaluate model performance. **Results:** The web application features an interactive form where the healthcare professional can enter relevant clinical data. The tool showed good calibration and discrimination. Cross-validation metrics provided a robust estimate of the model's overall performance. The applications allow for real-time predictions and features an intuitive and accessible interface. **Conclusions:** The tool demonstrates a significant potential impact in the clinical setting for risk stratification of hemodialysis patients. It offers a list of personalized, data-driven recommendations for routine decision-making.

Keywords: chronic kidney disease; mortality; artificial intelligence; predictive model; web application

INTRODUCCIÓN

La enfermedad renal crónica (ERC) constituye un problema de salud pública de magnitud creciente y gran carga para los sistemas de salud. En 2017, según los análisis de la carga global de la enfermedad, aproximadamente 697,5 millones de personas padecían ERC en alguno de sus estadios, lo que representaba una prevalencia global del 9,1 %. La mortalidad asociada también es alarmante, 1,2 millones de fallecidos directamente atribuibles a la ERC en el mismo año. El incremento de la mortalidad se refleja en el aumento del 41,5 % en la tasa bruta de mortalidad entre 1990 y 2017. ⁽¹⁾

El proceso de estratificación de riesgo de mortalidad de ERC en hemodiálisis (HD) constituye un proceso clínico de complejidad. Con frecuencia el desenlace final depende de una muestra heterogénea de predictores. La existencia de múltiples predictores que abarcan desde los antecedentes y biomarcadores clínicos y de laboratorio hasta la adherencia terapéutica, tienen especial implicación en la determinación del riesgo. ⁽²⁾

Sin embargo, a pesar de la existencia de modelos predictivos (MP) desarrollados en años recientes, la mayoría presenta un riesgo global de sesgo de moderado a alto y limitaciones vinculadas a la aplicabilidad clínica, generalización y

uso rutinario para la toma de decisiones. La brecha real entre la necesidad clínica de nuevos MP y la fiabilidad de las herramientas de predicción disponibles resalta la importancia de que se obtengan sistemas de apoyo para la predicción clínica más robustos y contextualizados. ⁽³⁾

El estudio de patrones de práctica y resultados de diálisis (DOPPS, por sus siglas en inglés) es una fuente líder de datos actualizados, representativos y completos sobre la práctica de HD y los resultados de los pacientes en todo el mundo. Desde el inicio de esta gran serie, su propósito principal fue identificar prácticas que extiendan la supervivencia y mejoren la calidad de vida de los pacientes con ERC en HD. ⁽⁴⁾

El DOPPS es una gran investigación observacional prospectiva diseñada para mejorar la supervivencia en HD. La primera cohorte, que se desarrolló desde 1996 hasta 2001, incluyó 308 unidades de HD de 7 países: 145 de EE. UU; 62 de Japón y 101 centros de Francia, Alemania, Italia, España e Inglaterra. La segunda cohorte analizó 320 unidades de HD y más de 12 400 pacientes de los países citados y Australia, Bélgica, Canadá, Nueva Zelanda y Suecia durante los años 2002-2004. Las unidades de HD se eligieron mediante un procedimiento de selección aleatorio estratificado para garantizar un muestreo proporcional por región. ⁽⁵⁾

A pesar de las fortalezas del estudio DOPPS existen limitaciones metodológicas importantes a resaltar, entre ellas: sesgo de confusión por indicación clínica, variabilidad geográfica, necesidad de validaciones externas, evaluación de métricas como la calibración y discriminación y la inclusión de predictores dinámicos.

Los MP sustentados en algoritmos de la inteligencia artificial (IA) son tecnologías vanguardias. En comparación con los métodos estadísticos tradicionales, tienen mejor capacidad de aprendizaje, adaptación a tendencias complejas en los datos, mejor manejo de grandes cantidades de datos, posibilidad de organización automática, tolerancia a fallos, obtención de respuestas en tiempo real, arquitectura flexible, identificación de relaciones no lineales para tareas específicas y mayor precisión y eficacia en la identificación de patrones para la toma de decisiones clínicas.^(6,7)

Uno de los resultados más evaluados en los pacientes con ERC en HD es la mortalidad. En este contexto el uso de técnicas de la IA ha crecido con rapidez en los últimos años para estudiar la heterogeneidad que suele caracterizar la fisiopatología renal cuando se utilizan enfoques estadísticos convencionales para apoyar la toma de decisiones.⁽⁸⁾ A pesar de los beneficios y garantías de diseñar un MP basado en algoritmos de la IA, que presentan gran precisión, persisten limitaciones vinculadas a la interpretabilidad y a la desconfianza del uso rutinario de las herramientas por parte del personal clínico.

Teniendo en cuenta el incremento de la mortalidad en pacientes con ERC en HD, la heterogeneidad de los predictores y que las herramientas de pronóstico tradicionales tienen aplicabilidad, solidez y generalización limitadas, los autores consideran que se necesita un enfoque novedoso para la estratificación del riesgo de la mortalidad, por lo que el desarrollo de una herramienta basada en inteligencia artificial podría ser una solución parcial para esta problemática. El objetivo de la presente investigación fue desarrollar e implementar una aplicación web interactiva basada en IA para la predicción individualizada del riesgo de mortalidad en pacientes con ERC en HD.

MÉTODOS

Se desarrolló una aplicación, desde el 15 de septiembre al 22 de noviembre de 2024 a través de un modelo de red neuronal artificial (RNA) multicapa desarrollado en la investigación de Escalona-González SO et al.⁽⁹⁾ A través de TensorFlow en Python, se entrenó el modelo con datos clínicos que fueron tomados al iniciar la hemodiálisis y se exportó a formato TensorFlow.js para su uso en una aplicación web.^(10,11) La aplicación web, desarrollada con React y Vite, posee un formulario

interactivo donde el personal médico puede ingresar datos clínicos relevantes del paciente.^(12,13) Los datos ingresados son enviados al modelo RNA, que procesa la información y retorna una predicción sobre la probabilidad de mortalidad del paciente. El resultado se muestra de manera clara e intuitiva dentro de la interfaz de la aplicación.

Los predictores incluidos en la aplicación fue evaluada por un grupo de 10 nefrólogos entre diciembre de 2024 y enero de 2025, como parte de un estudio Delphi que constituyó un resultado parcial de una tesis doctoral. El 80 % eran doctores en ciencias, 100 % profesores auxiliares o titulares, 90 % especialistas en segundo grado en nefrología y el 80 % tenía categoría de investigador auxiliar o titular.

El algoritmo implementado se basó en un modelo RNA multicapa, se utilizó TensorFlow y Keras.⁽¹⁴⁾ A continuación, se detalla cada paso del proceso:

- Carga y preprocesamiento del dataset:
 - Carga de datos: el dataset se cargó desde un archivo CSV y se utilizó la biblioteca Pandas.⁽¹⁵⁾
 - Limpieza de datos: se reemplazaron los puntos de miles y las comas decimales en las columnas que contenían datos numéricos en formato de texto. Esto se realizó para asegurar que todos los datos sean interpretados de forma correcta como números flotantes.
 - 3. Preparación de Datos:
 - Separación de características y etiquetas: se asumió que la última columna del dataset corresponde a la etiqueta (variable objetivo) y las restantes son las características (predictores).
 - División en conjuntos de entrenamiento y prueba: el dataset se dividió en conjuntos de entrenamiento (70 %) y prueba (30 %), se utilizó `train_test_split` de scikit-learn.⁽¹⁶⁾ Este paso permitió evaluar el rendimiento del modelo en datos no vistos durante el entrenamiento.
 - Estandarización de datos:
 - Escalado: se aplicaron técnicas de estandarización a las características, se aplicó `StandardScaler` para normalizar los datos y mejorar el rendimiento del modelo.⁽¹⁶⁾ Los datos de entrenamiento y prueba se escalan y se usó el mismo transformador.
 - Codificación de etiquetas:
 - Conversión de etiquetas: las etiquetas se convirtieron en formato categórico y se utilizó `pd.get_dummies`, lo cual transforma las etiquetas en un formato adecuado para la clasificación multiplaje (one-hot encoding).

La arquitectura del modelo se construyó de RNA secuencial con la siguiente estructura:⁽⁹⁾

Capa de entrada: acepta entradas con la misma cantidad de características que el conjunto de datos de entrenamiento.

Primera capa oculta: capa densa con 5 neuronas y función de activación tanh, seguida de una capa de Dropout con una tasa del 50 % para prevenir el sobreajuste.

Segunda capa oculta: otra capa densa con 5 neuronas y función de activación tanh, también seguida de una capa de Dropout con una tasa del 50 %.

Capa de salida: capa densa con 2 neuronas (una para cada clase) y función de activación softmax, adecuada para problemas de clasificación multiclase.

Se utilizó el optimizador SGD (Stochastic Gradient Descent) con una tasa de aprendizaje de 0,001 y un momento de 0,9.⁽¹⁷⁾ La función de pérdida fue categorical_cross-entropy, adecuada para problemas de clasificación multiclase.⁽¹⁸⁾ Se utilizó la precisión como métrica para evaluar el rendimiento del modelo. Se empleó KerasClassifier para integrar el modelo con scikit-learn y realizar una validación cruzada con 10 particiones.⁽¹⁶⁾ Se ejecutó la validación cruzada para evaluar el modelo en múltiples particiones del conjunto de datos de entrenamiento, así se proporciona una estimación robusta del rendimiento general del modelo.

Las librerías y frameworks utilizados fueron React, TensorFlow.js, Formik, Yup, TailwindCSS.^(19,20,21) Durante el progreso de la aplicación web desarrollada, se cumplió con las recomendaciones brindadas en los consensos metodológicos TRIPOD-AI y PROBAST-AI.⁽²²⁾ La investigación se desarrolló a partir del uso secundario de datos clínicos que estaban registrados previamente, con fines exclusivamente investigativos. La información utilizada fue anonimizada antes del análisis, por lo que se garantizó la confidencialidad y protección de los datos personales de los pacientes, alineado a los principios éticos de la Declaración de Helsinki. Además, la investigación fue aprobada por el Comité de ética de la institución. Finalmente, la herramienta no sustituye el juicio clínico de los expertos médicos, sirve de sistema de apoyo en las decisiones.

RESULTADOS

El software es gratuito y tiene un alcance nacional e internacional, se puede descargar a través de PC o teléfonos androide, desde el sitio: <https://renal-predict-app.vercel.app/landing>. La aplicación cuenta con un formulario que permite a los usuarios ingresar datos de importancia sobre el paciente, como características clínicas y parámetros de salud. Los campos del formulario están diseñados para capturar la información necesaria para realizar la predicción de manera precisa. Incluye validaciones para asegurar que los datos ingresados sean válidos y estén en el formato correcto. Esto incluye la verificación de campos obligatorios y el formato de datos numéricos (figura 1).

Predicción del modelo

Una vez que el usuario completa el formulario y envía los datos, la aplicación utiliza el modelo de RNA multicapa entrenado para generar una predicción sobre la probabilidad de mortalidad del paciente. El modelo, exportado y cargado en TensorFlow.js realiza las predicciones directamente en el navegador, propicia una experiencia interactiva, sin necesidad de conexión al servidor (figura 2).

Una vez que se han completado todos los datos del formulario se muestra una pestaña auxiliar donde se presenta el resumen de los datos rellenados por el usuario y existe una casilla que sugiere revisar cuidadosamente todos los datos antes de continuar. Una vez confirmado, al presionar la casilla "confirmar y enviar" se procede a la predicción del riesgo renal.

Después de la predicción se muestra un modal con el resultado de la predicción. El modal incluye la probabilidad de mortalidad estimada y una interpretación de la predicción, si se ha implementado un enfoque de interpretabilidad (figura 3).

Interactividad y experiencia del usuario

La aplicación está diseñada para ser accesible desde dispositivos móviles y de escritorio, asegura una experiencia de usuario consistente en diferentes plataformas. La interfaz responde de manera dinámica a las interacciones del usuario, como la entrada de datos y la visualización de resultados, para mejorar la fluidez y la usabilidad de la aplicación.

La aplicación maneja errores y proporciona mensajes claros en caso de que ocurran problemas durante el procesamiento de los datos o la generación de la predicción. Esto incluye errores en la entrada de datos y problemas técnicos con el modelo.

Para garantizar una estimación robusta del rendimiento general del modelo, se ejecutó la validación cruzada, de forma tal que se evalúa el modelo predictivo en múltiples particiones del conjunto de datos de entrenamiento. Los resultados se presentan como la precisión media y la desviación estándar. Además, se analizó la capacidad de discriminación, mediante la interpretación del área bajo la curva ROC (figura 4).

Después de presentar el resultado de la predicción, estimado en porcentaje, se estratifica el riesgo del paciente en: bajo, moderado o alto. Luego, en dependencia del riesgo identificado, se muestra una lista de recomendaciones médicas personalizadas para cada paciente (figura 5). Las recomendaciones sugeridas se basan en la guía de práctica clínica Enfermedad Renal: Mejorando los Resultados Globales, (KDIGO, por sus siglas en inglés), en su última versión del año 2024.⁽²³⁾ Esta guía es una referencia integral para las prácticas basadas en la evidencia para la evaluación y el manejo de la ERC.




Fig. 1. Interfaz de usuario

DISCUSIÓN

La presente investigación describió el desarrollo e implementación de una aplicación web interactiva basada en RNA para la predicción del riesgo de mortalidad en pacientes con ERC en HD. Este resultado constituye una materialización importante hacia la integración de modelos predictivos inteligentes en el ámbito clínico rutinario.

El enfoque traslacional de la investigación revela el aporte práctico, científico y tecnológico. Resalta el uso clínico de un MP que fue previamente validado en una herramienta pronóstica de apoyo a la decisión médica. La propuesta no se centró exclusivamente en el rendimiento algorítmico ya que fue prioridad la accesibilidad y aplicabilidad, elementos importantes para la implementación real de algoritmos de la IA en escenarios médico-asistenciales.

Las RNA son un modelo matemático prometedor, un método de IA destacado en la modelación de funciones objetivas complejas. La adaptabilidad de este algoritmo, permite la aplicación en casos en que es imposible crear un modelo matemático estricto, pero donde existe un conjunto representativo de muestras.⁽²⁴⁾

El uso explosivo de un paradigma de modelado novedoso y que goza de popularidad aceptación crecientes, genera interrogantes acerca de qué tan bien funcionan estos modelos, la solidez de su metodología y si son aplicables en escenarios clínicos.⁽²⁵⁾ En este caso, al introducir datos de pacientes con ERC incidentes en HD, el modelo aprende a identificar a los pacientes con mayor riesgo de mortalidad según rasgos o características específicas. Luego de ciclos de aprendizaje, sería capaz de discriminar el riesgo de mortalidad con solamente introducir nuevos datos de los registros médicos.

The figure displays four sequential screenshots of the RenalPredict web application, illustrating the steps of a renal risk assessment process.

Step 1: Evaluación de Riesgo Renal (Paso 1 de 5)
 - **Progreso:** Paso 1 de 5
 - **Datos de Prueba:** (Link)
 - **Información Personal:**
 - Sexo: Masculino
 - Edad (años): Ej: 45
 - Navigation: Anterior, Continuar

Step 2: Evaluación de Riesgo Renal (Paso 2 de 5)
 - **Progreso:** Paso 2 de 5
 - **Datos de Prueba:** (Link)
 - **Signos Vitales:**
 - Tensión Arterial Sistólica (mmHg): Ej: 120
 - Tensión Arterial Diastólica (mmHg): Ej: 80
 - Frecuencia Cardíaca (lpm): Ej: 72
 - Navigation: Anterior, Continuar

Step 3: Evaluación de Riesgo Renal (Paso 3 de 5)
 - **Progreso:** Paso 3 de 5
 - **Datos de Prueba:** (Link)
 - **Antecedentes y Comorbilidades:**
 - Enfermedad Cardiovascular
 - Hipertensión Arterial
 - Complicaciones Cardiovasculares
 - Diabetes Mellitus
 - Obesidad
 - Dislipidemia
 - Glomerulopatía
 - ERPAD
 - Navigation: Anterior, Continuar

Step 4: Evaluación de Riesgo Renal (Paso 4 de 5)
 - **Progreso:** Paso 4 de 5
 - **Datos de Prueba:** (Link)
 - **Resultados de Laboratorio:**
 - Hemoglobina (g/dL): 11
 - Albúmina (g/dL): 30
 - Urea (mg/dL): 15
 - Creatinina (mg/dL): 1.0
 - Filtrado Glomerular (mL/min): 6
 - Navigation: Anterior, Continuar

Fig. 2. Predicción del modelo predictivo.

La estabilidad en el rendimiento del MP, observada en la validación cruzada, resalta la robustez interna del modelo y la utilidad potencial en la estratificación del riesgo de mortalidad. Las variables identificadas en el modelo fueron: edad menor que 65 años, enfermedad cardiovascular, dislipidemia, hemoglobina < 10 g/L, albúmina < 30 g/L, urea > 15 mmol/L, filtrado glomerular < 8 mL/min/1,73m², potasio $> 5,5$ mmol/L, inicio tardío de hemodiálisis, catéter venoso central, ganancia de peso interdialítica excesiva y sepsis.

Estos predictores tienen amplia evidencia científica en relación con el riesgo de mortalidad en los pacientes con ERC en HD. Son fáciles de evaluar y están accesibles en la mayo-

ría de los departamentos de nefrología en Cuba y pueden ser considerados en la toma de decisiones médicas en el ámbito clínico actual. Los autores resaltan que los enfoques de IA para el análisis de supervivencia pueden permitir una selección más eficiente de los factores de riesgo, incluso cuando se dispone de un gran número de posibles predictores para una población relativamente pequeña o en escenarios donde existen más predictores que eventos en la muestra de estudio.

Un aspecto de gran importancia de la herramienta desarrollada y que supera a otros MP de riesgo de mortalidad en la ERC, en cuestiones de interoperabilidad, explicabilidad, escalabilidad, uso responsable de la IA y actualización, es la



Fig. 3. Visualización del resultado.

incorporación de recomendaciones médicas personalizadas con adherencia a las guías KDIGO, lo que respalda la medicina de precisión y el beneficio clínico-organizacional. Además, se favorece el análisis dinámico y visual con potenciales mejoras en la atención médica basada en manejo de datos y evidencia, optimización de recursos sanitarios con disminución de complicaciones y hospitalizaciones prolongadas.

La investigación constituye un referente en innovación en Salud, un llamado especial que ha realizado durante los últimos años el Ministerio de Salud Pública en el que la ciencia e innovación son pilares fundamentales de la gestión gubernamental en Cuba en todos los ámbitos.⁽²⁶⁾ Con posibilidades reales en la contribución de políticas públicas en materia de salud. Se menciona como limitación que la validación externa




Fig. 4. Evaluación de la validación cruzada y área bajo la curva COR.




Fig. 5. Lista de recomendaciones médicas personalizadas (ejemplo)

en poblaciones independientes no fue abordada, por lo que los resultados son exclusivos para pacientes con ERC en HD periódica.

Para cumplir con el concepto de automatización, actualización y mejora continua, se prevé el desarrollo de una versión más actualizada de la herramienta en futuras investigaciones. El abordaje propuesto en la presente investigación tiene la ventaja de que permite diferenciar el riesgo de mortalidad en los pacientes con ERC que inician tratamiento en HD y proporciona al especialista un mecanismo predictivo de la supervivencia del paciente teniendo en cuenta variables accesibles de las historias clínicas. Además, despliega una lista de recomendaciones médicas basadas en la guía clínica KDIGO, por lo que tiene aplicación práctica.

Conclusiones

Se concluye que la herramienta demuestra un impacto potencial significativo en el entorno clínico para la estratificación del riesgo de pacientes con ERC en HD. Ofrece una lista de recomendaciones personalizadas y basadas en datos para la toma de decisiones rutinarias.

REFERENCIAS BIBLIOGRÁFICAS

1. GBD Chronic Kidney Disease Collaboration. Global, regional, and national burden of chronic kidney disease, 1990-2017: a systematic analysis for the Global Burden of Disease Study 2017. [Inter-

- net]. 2020 [consultado 10 nov 2025];395(10225):709-33. Disponible en: [https://doi.org/10.1016/S0140-6736\(20\)30045-3](https://doi.org/10.1016/S0140-6736(20)30045-3)
2. Jarrar F, Pasternak M, Harrison T, James M, Quinn R, Lam N, et al. Mortality Risk Prediction Models for People With Kidney Failure A Systematic Review. JAMA Network Open. [Internet]. 2025 [consultado 10 nov 2025];8(1):e2453190. Disponible en: <https://doi.org/10.1001/jamanetworkopen.2024.53190>
3. Liu P, Sawhney S, Jorgensen U, Quinn R, Jensen S, Mclean A, et al. Predicting the risks of kidney failure and deaths in adults with moderate to severe chronic kidney disease: multinational, longitudinal, population based, cohort study. BMJ. [Internet]. 2024 [consultado 10 nov 2025];385(1):e078063. Disponible en: <https://dx.doi.org/10.1136/bmj-2023-078063>
4. Gorke A. Dialysis Outcomes and Practice Patterns Study (DOPPS). Dialyse aktuell. [Internet]. 2016 [consultado 10 nov 2025];20(6):274-5. Disponible en: <https://doi.org/10.1055/s-0042-110411>
5. Pisoni R, Gillespie B, Dickinson D, Chen K, Kutner M, Wolfe R. The Dialysis Outcomes and Practice Patterns Study (DOPPS): design, data elements, and methodology. American Journal of Kidney Disease. [Internet]. 2004 [consultado 10 nov 2025];44(5):7-15. Disponible en: <https://doi.org/10.1053/j.ajkd.2004.08.005>
6. Ye Z, An S, Gao Y, Xie E, Zhao X, Guo Z, et al. The prediction of in-hospital mortality in chronic kidney disease patients with coronary artery disease using machine learning models. European Journal of Medical Research. [Internet]. 2023 [consultado 10 nov 2025];28(1):33. Disponible en: <https://doi.org/10.1186/s40001-023-00995-x>
7. Kumar Y, Koul A, Singla R, Ijaz M. Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. Journal of ambient intelligence

- and humanized computing. [Internet]. 2023 [consultado 10 nov 2025];14(7):8459-6. Disponible en: <https://doi.org/10.1007/s12652-021-03612-z>
8. Díez-Sanmartín C, Sarasa Cabezuelo A, Belmonte AA. A new approach to predicting mortality in dialysis patients using sociodemographic features based on artificial intelligence. *Artificial Intelligence in Medicine*. [Internet]. 2023 [consultado 10 nov 2025];136(1):102478. Disponible en: <https://doi.org/10.1016/j.artmed.2022.102478>
 9. Escalona-González SO, Caballero-Mota Y, Rodríguez-Alvarez Y, León-Acebo M, González-Milán ZC, Ricardo-Páez B, et al. Red neuronal artificial para la predicción de mortalidad de pacientes con enfermedad renal crónica. *Revista Cubana de Medicina Militar*. [Internet]. 2024 [consultado 10 nov 2025];53(3):e024038408. Disponible en: <https://revmedmilitar.sld.cu/index.php/mil/article/view/38408>
 10. He M. Performance and accuracy of Python distributed neural network training frameworks: Spark vs. TensorFlow in big data modeling and prediction. *Applied and Computational Engineering*. [Internet]. 2024 [consultado 10 nov 2025];92:52-8. Disponible en: <https://doi.org/10.54254/2755-2721/92/20241729>
 11. Usman A, Abdul R, Uzair S, Majid H, Samraiz Z. A Privacy-Preserving System for Skin Disease Using a Lightweight CNN and TensorFlow.js for Client-Side Inference. *Advance Social Science Archive Journal*. [Internet]. 2025 [consultado 10 nov 2025];4(2):1785-97. Disponible en: <https://doi.org/10.5281/zenodo.17656620>
 12. Meta Platforms, Inc. React: A JavaScript library for building user interfaces [Internet]. [consultado 10 nov 2025]. Disponible en: <https://react.dev/>
 13. Vite.js. Vite: Next generation fronted tooling [Internet]. [consultado 10 nov 2025]. Disponible en: <https://vitejs.dev/>
 14. Chollet. Keras. GitHub repository [Internet]. 2015-2025 [consultado 10 nov 2025]. Disponible en: <https://github.com/keras-team/keras>
 15. Addepali L, Lokhande G, Sakinam S, Hussain S, Mookerjee J, Vamsi U, et al. Assessing the performance of Python data visualization libraries: a review. *International Journal of Computer Engineering in Research Trends*. [Internet]. 2023 [consultado 10 nov 2025]; 10(1):28-39. Disponible en: <https://doi.org/10.22363/ijcert/2023/v10/i01/v10i0104>
 16. Bichri H, Chergui A, Hain M. Investigating the impact of train/test split ratio on the performance of pre-trained models with custom datasets. *International Journal of Advanced Computer Science and Applications*. [Internet]. 2024 [consultado 10 nov 2025]; 15(2):331-9. Disponible en: <https://doi.org/10.14569/ijac-sa.2024.0150235>
 17. Sclocchi A, Wyart M. On the different regimes of stochastic gradient descent. *Computer Sciences*. [Internet]. 2024 [consultado 10 nov 2025];121(9):e2316301121. Disponible en: <https://doi.org/10.1073/pnas.2316301121>
 18. Brochet T, Lapuyade-Lahorque J, Huat A, Thureau S, Pasquier D, Gardin I, et al. A quantitative comparison between Shannon and Tsallis-Havrda-Charvat entropies applied to cancer outcome prediction. *Entropy*. [Internet]. 2022 [consultado 10 nov 2025];24:436. Disponible en: <https://doi.org/10.3390/e24040436>
 19. Formik. Build forms in React, without the tears [Internet]. Formik; c2017-2025 [consultado 10 nov 2025]. Disponible en: <https://formik.org/>
 20. Yup. Dead simple object schema validation [Internet]. Yup; c2016-2025 [consultado 10 nov 2025]. Disponible en: <https://github.com/jquense/yup>
 21. Tailwind Labs, Inc. Tailwind CSS: A utility-first CSS framework [Internet]. San Francisco (CA): Tailwind Labs, Inc.; c2029-2025 [consultado 10 nov 2025]. Disponible en: <https://tailwindcss.com/>
 22. Collins GS, Dhiman P, Andaur Navarro CL, Ma J, Hooft L, Reitsma JB, et al. Protocol for development of a reporting guideline (TRIPOD-AI) and risk of bias tool (PROBAST-AI) for diagnostic and prognostic prediction model studies based on artificial intelligence. *BMJ Open*. [internet]. 2021 [consultado 10 nov 2025];11:e048008. Disponible en: <https://doi.org/10.1136/bmjopen-2020-048008>
 23. Kidney Disease: Improving Global Outcomes (KDIGO) CKD Work Group. KDIGO 2024 Clinical Practice Guideline for the Evaluation and Management of Chronic Kidney Disease. *Kidney Int*. [internet]. 2024 [consultado 10 nov 2025];105(4S): S117-S314. Disponible en: <https://doi.org/10.1016/j.kint.2023.10.018>
 24. Almási AD, Wozniak S, Cristea V, Leblebici Y, Engbersen T. Review of advances in neural networks: Neural design technology stack. *Neurocomputing*. [Internet]. 2016 [consultado 10 nov 2025];174(1):31-41. Disponible en: <https://doi.org/10.1016/j.neucom.2015.02.092>
 25. Escalona González SO, González Milán ZC. Inteligencia artificial en la predicción de mortalidad por enfermedad renal crónica. *An Acad Cienc Cuba*. [Internet]. 2022 [consultado 10 nov 2025];12(3):e1292. Disponible en: <http://www.revistaccuba.cu/index.php/revacc/article/view/1292>
 26. Díaz-Canel Bermúdez M. Gestión de gobierno basada en ciencia e innovación: avances y desafíos. *An Acad Cienc Cuba*. [Internet]. 2022 [consultado 10 nov 2025];12(2):e1235. Disponible en: <http://www.revistaccuba.cu/index.php/revacc/article/view/1235>

Recibido: 14/03/2026

Aprobado: 28/05/2026

Conflictos de intereses

Los autores declaran que no existen conflictos de intereses entre ellos, ni con la investigación presentada, ni con la institución que representa.

Contribuciones de los autores

- Conceptualización: Sergio Orlando Escalona González, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez, Zoraida Caridad González Milán
- Curación de datos: Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez, Zoraida Caridad González Milán
- Investigación: Sergio Orlando Escalona González, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez, Zoraida Caridad González Milán
- Metodología: Sergio Orlando Escalona González, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez
- Validación: Sergio Orlando Escalona González, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez
- Visualización: Sergio Orlando Escalona González, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez, Zoraida Caridad González Milán
- Redacción - borrador original: Sergio Orlando Escalona González

lez, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez, Zoraida Caridad González Milán

- Redacción – revisión y edición: Sergio Orlando Escalona González, Ernesto Carlos Leonard Escariz, Yailé Caballero Mota, Yanela Rodríguez Álvarez, Zoraida Caridad González Milán

Financiamientos

Los autores no recibieron ningún tipo de apoyo financiero para la investigación, redacción ni publicación de este artículo.

Cómo citar este artículo

Escalona González SO, Leonard Escariz EC, Caballero Mota Y, Rodríguez Álvarez Y, González Milán ZC. Estimación de mortalidad en la enfermedad renal crónica basado en inteligencia artificial: sistema

web de apoyo. An Acad Cienc Cuba [Internet] 2026 [citado en día, mes y año];16:e3249. Disponible en: <http://www.revistaccuba.cu/index.php/revacc/article/view/3249>

El artículo se difunde en acceso abierto según los términos de una licencia Creative Commons de Atribución/Reconocimiento-NoComercial 4.0 Internacional (CC BY-NC-SA 4.0), que le atribuye la libertad de copiar, compartir, distribuir, exhibir o implementar sin permiso, salvo con las siguientes condiciones: reconocer a sus autores (atribución), indicar los cambios que haya realizado y no usar el material con fines comerciales (no comercial).

© Los autores, 2026.

