

## Los modelos de predicción de la progresión en la enfermedad renal crónica

### Prediction Models for Progression in Chronic Kidney Disease

Dania Castillo Deprés<sup>1</sup> <https://orcid.org/0000-0001-8109-0105>

Saymara Castillo Deprés<sup>1</sup> <https://orcid.org/0000-0002-5439-5891>

Ariel Delgado Ramos<sup>2</sup> <https://orcid.org/0000-0003-0174-6691>

María Josefina Vidal Ledo<sup>3</sup> <https://orcid.org/0000-0002-0293-5999>

<sup>1</sup>Hospital Militar Central Carlos J. Finlay. La Habana, Cuba.

<sup>2</sup>Universidad de Ciencias Médicas de La Habana. La Habana, Cuba.

<sup>3</sup> Universidad de Ciencias Médicas de La Habana. Escuela Nacional de Salud Pública de Cuba. La Habana, Cuba.

\*Autor para la correspondencia: [castillodania97@gmail.com](mailto:castillodania97@gmail.com)

## RESUMEN

**Introducción:** En la ERC es necesario prevenir su progresión a través de la corrección de los factores de riesgo, el diagnóstico temprano y el tratamiento adecuado. Esto ha llevado a una necesidad insatisfecha de desarrollar modelos para utilizar en la práctica clínica. La predicción precisa de la progresión de la enfermedad renal crónica (ERC) es fundamental para guiar las decisiones clínicas, optimizar la asignación de recursos y mejorar los resultados de los pacientes.

**Objetivo:** Analizar el valor de los modelos de progresión en la ERC y proporcionar evidencia de los impactos y riesgos subyacentes a su empleo.



**Posicionamiento del autor:** Los modelos predictivos de progresión de la ERC han evolucionado a lo largo de los años, a medida que se ha avanzado en la comprensión de la fisiopatología de la enfermedad y se han desarrollado nuevas tecnologías y enfoques de investigación como el uso de datos genómicos, proteómicos y metabolómicos para mejorar la predicción; sin embargo su usabilidad actual es limitada y existen barreras metodológicas y de validación externa que dificultan su implementación generalizada. Persiste, en la mayoría de las propuestas, la inconsistencia y falta de validación externa que limita su aplicabilidad y generalización.

**Conclusiones:** Se concluyó que a pesar de contar con una elevada gama de modelos predictivos con disímiles metodologías, es necesario continuar adaptando los mismos a los contextos locales teniendo en cuenta las limitaciones y condiciones concretas de los servicios.

**Palabras clave:** factores de riesgo; modelos de progresión; enfermedad renal crónica.

## ABSTRACT

**Introduction:** In CKD, it is essential to prevent progression through risk factor correction, early diagnosis, and appropriate treatment. This has led to an unmet need to develop models for use in clinical practice. Accurate prediction of chronic kidney disease (CKD) progression is critical for guiding clinical decisions, optimizing resource allocation, and improving patient outcomes.

**Objective:** To analyze the value of progression models in CKD and provide evidence of the underlying impacts and risks of their use.

**Author's position:** Predictive models of CKD progression have evolved over the years, as progress has been made in the understanding of the pathophysiology of the disease and new technologies and research approaches have been developed such as the use of genomic, proteomics and metabolomics to improve prediction, however their current usability is limited and there are methodological and external validation barriers that



hinder their widespread implementation. In most proposals, inconsistency and lack of external validation persist, limiting their applicability and generalization.

**Conclusions:** It was concluded that despite having a wide range of predictive models with dissimilar methodologies, it is necessary to continue adapting them to local contexts taking into account the limitations and specific conditions of the services.

**Keywords:** risk factors; progression models; chronic kidney disease.

Recibido: 21/07/2025

Aprobado: 06/12/2025

## Introducción

La ERC es la sexta causa de muerte de más rápido crecimiento, plantean la OMS y la OPS, y se estima que 850 millones de personas en el mundo padecen ERC por diversas causas (más del 10 % de la población mundial) la misma provoca al menos 2.4 millones de muertes al año, la prevalencia está en aumento debido al envejecimiento poblacional y al incremento de factores de riesgo como la Diabetes Mellitus y la HTA, estas entidades han reconocido la importancia de la detección temprana y seguimiento de la progresión de la ERC.<sup>(1,2)</sup>

Cuba tiene una prevalencia de ERC que coincide con los rangos internacionales, existe una tasa de 0,92 personas afectadas por cada mil habitantes, evidenciado en la población de la Isla de la Juventud, que tuvo el privilegio de haber sido objeto de un estudio epidemiológico y clínico en población total, utilizando la ERC como enfermedad trazadora, y su conexión con otras enfermedades vasculares de origen aterosclerótico,



siendo identificado como uno de los tres estudios a nivel mundial con más alta población estudiada, cerca de 80 mil personas (97,6 %) de la población, estudio ISYS, y se visualiza un incremento de la mortalidad por enfermedades renales, cuyos resultados pueden ser extrapolados a población nacional, según la Sociedad Cubana de Nefrología.<sup>(1,2)</sup>

La identificación, prevención y control de los factores de riesgo para esta enfermedad son aspectos claves para el sistema de salud de cualquier país y crucial para implementar intervenciones terapéuticas oportunas que puedan ralentizar su avance y mejorar la calidad de vida de los pacientes.<sup>(3,4)</sup>

## Desarrollo

La predicción del desarrollo y progresión de la Enfermedad Renal Crónica (ERC) es un área de gran interés clínico, ya que permite identificar pacientes en riesgo y optimizar el manejo preventivo y terapéutico. A continuación, se describen los principales modelos predictivos utilizados en la práctica clínica y la investigación.

Existen diferentes tipos de modelos predictivos empleados en la Enfermedad Renal Crónica, podemos clasificarlos: modelos estadísticos tradicionales, modelos clínicos multivariados y modelos de inteligencia artificial/aprendizaje automático.

### Modelos estadísticos tradicionales

- **Kidney Failure Risk Equation (KFRE):** Modelo ampliamente validado que utiliza variables como edad, tasa de filtración glomerular estimada (TFGe), albuminuria y sexo para predecir el riesgo de progresión a falla renal en 2 y 5 años. Ha sido recalibrado para distintas poblaciones, mejorando su precisión.<sup>(5-9)</sup>



- **Regresión de Cox:** El **modelo de Cox** o **modelo de riesgos proporcionales** es un método de análisis de supervivencia que relaciona el tiempo hasta un evento con variables predictoras. Adecuado manejo de la censura, flexibilidad con variables tiempo-dependientes y no requiere conocimiento de una línea base. Es el más utilizado, entre el 85 y 90 porciento de los modelos de progresión de ERC.
- **Regresión logística múltiple:** Utiliza factores de riesgo como enfermedades urológicas, hipertensión arterial, hiperuricemia y uso de nefrotóxicos para calcular la probabilidad de desarrollar ERC. Permite identificar combinaciones de factores con alto riesgo predictivo.<sup>(10)</sup>
- **Modelos de regresión lineal:** Empleados para predecir la progresión de la función renal a partir de variables continuas como creatinina, edad y presión arterial, aunque con menor sofisticación que los modelos multivariados modernos.<sup>(9-10)</sup>

## Modelos clínicos multivariados

- **Modelo clínico con factores de riesgo ampliados:** Incluye enfermedades urológicas, hipertensión arterial, hiperuricemia y uso de nefrotóxicos, logrando una probabilidad predictiva de hasta 99,9 % cuando se presentan todos los factores.<sup>(11)</sup>
- **Modelos con variables bioquímicas y demográficas:** Incorporan datos como edad, sexo, niveles de calcio, fósforo, bicarbonato y albúmina junto con la TFGe y la relación albúmina/creatinina, para estimar el riesgo de progresión a insuficiencia renal.<sup>(11-12)</sup>
- **Modelos de cambio de estadio renal:** Predicen la transición entre diferentes estadios de ERC (por ejemplo, de estadio 3 a 4) usando variables clínicas, de laboratorio y antecedentes médicos.<sup>(11-13)</sup>

## Modelos de inteligencia artificial y aprendizaje automático



- **Bosque aleatorio (Random Forest):** Algoritmo de aprendizaje automático que ha demostrado una precisión diagnóstica de hasta 99,75 % en la predicción de la progresión de la ERC utilizando múltiples variables clínicas y bioquímicas.<sup>(14-16)</sup>
- **Redes neuronales artificiales:** Utilizadas para predecir eventos clínicos intradialíticos y progresión de la ERC, alcanzando un poder predictivo del 96% y un área bajo la curva del estadístico C de 99,3 % en estudios prospectivos.<sup>(14-21)</sup>
- **XGBoost:** Algoritmo de boosting que ha mostrado una exactitud superior al 90 % en la predicción de desarrollo de ERC terminal, superando a otros modelos en estudios comparativos.<sup>(22)</sup>

Los modelos predictivos de progresión de la ERC han evolucionado a lo largo de los años, a medida que se ha avanzado en la comprensión de la fisiopatología de la enfermedad y se han desarrollado nuevas tecnologías y enfoques de investigación.

Desde épocas tan tempranas como finales de las décadas de 1970- 1980, del pasado siglo XX, se comenzaron a estudiar y a identificar factores de riesgos asociados con la ERC, como la HTA, la proteinuria y la Diabetes Mellitus, y se basaban en ellos para estimar riesgo de progresión de la enfermedad.<sup>(23-24)</sup> En estos modelos iniciales faltaban, la estandarización de los criterios de diagnóstico de la ERC, su clasificación y existía poca comprensión respecto a los factores de riesgo y predictores de progresión.

En la década de 1990, con el avance de la epidemiología y la estadística, se desarrollaron modelos más sofisticados, y ampliaron el número de variables clínicas, y biomarcadores, se empezaron a utilizar técnicas como el análisis de regresión y modelos de supervivencia para estimar el riesgo individual de progresión.<sup>(25)</sup> Surgieron así los primeros modelos de predicción de progresión de la Enfermedad Renal Crónica.<sup>(3,4)</sup>

Por su parte en estos modelos de los 90, existía un enfoque limitado en la evaluación de la función renal, basada fundamentalmente en la creatinina, sin evaluar otros biomarcadores, y no existía una validación externa de los datos.

En los inicios del 2000, ya en pleno auge de la era digital y de la informática, se comenzaron a emplear enfoques más avanzados, como el aprendizaje automático y la inteligencia artificial, para crear modelos más precisos e individualizados, que permitían evaluar grandes volúmenes de datos clínicos y genéticos para predecir el riesgo de progresión de la ERC.<sup>(26-28)</sup> Hacia nuestros días, los modelos continúan evolucionando, con el uso de datos genómicos, proteómicos y metabolómicos para mejorar la predicción

Otros análisis señalan que los modelos predictivos multivariados, incluyendo regresión logística y técnicas de inteligencia artificial, tienen una calidad moderada y presentan variabilidad en su desempeño para predecir mortalidad y progresión en ERC. Se destaca la necesidad de modelos explicativos reproducibles y con diseño metodológico robusto para mejorar el pronóstico.<sup>(29)</sup>

Sin embargo, se mantienen las desventajas de su implementación, ya que persiste una subestimación del riesgo cardiovascular y de mortalidad asociado a la ERC y al igual que sus predecesores carecen de biomarcadores sensibles y específicos para mejorar la predicción.

La evolución en este campo ha permitido una evaluación gradual de estas desventajas y avanzar hacia modelos más sofisticados y personalizados.

## **Algunos de los modelos de predicción más utilizados en la práctica clínica y la investigación**



1. Modelo SCORED (Chronic Kidney Disease Epidemiology Collaboration). Este modelo utiliza variables como la edad, el sexo, la raza, la presión arterial, niveles de creatinina, la presencia de Diabetes Mellitus entre otras para calcular, la probabilidad de desarrollar Enfermedad Renal Crónica en los próximos años.<sup>(30-36)</sup>
2. Modelo Chino de Riesgo de ERC (CKD- MODE), este modelo se basa en datos de la población China y utiliza variables clínicas como la edad, el sexo, la presión arterial, niveles de creatinina y presencia de Diabetes Mellitus, entre otros, este modelo ha sido validado en la población china y se utiliza como una herramienta para la detección temprana y el manejo de la ERC.<sup>(30-36)</sup>
3. Modelo australiano de riesgo de ERC (AUSSCORE), desarrollado en Australia, emplea variables clínicas y de laboratorio como la edad, sexo, raza, presión arterial, niveles de creatinina, presencia de Diabetes mellitus, albuminuria entre otros, para predecir riesgo de desarrollar ERC.<sup>(33-38)</sup>
4. Modelo de Columbia: Se basa en datos demográficos y biomarcadores para predecir la ERC, utiliza variables como la edad, el sexo, la raza, el índice de masa corporal, albuminuria, y la velocidad de filtrado glomerular para estimar progresión de la ERC.<sup>(33-38)</sup>

En países subdesarrollados y algunos países africanos, el uso de modelos predictivos, puede verse limitado debido a recursos, y capacidades limitadas en el sistema de salud, pero a pesar de ello algunos han implementado modelos adaptados a sus contextos específicos.

1. En India se ha utilizado el modelo de predicción desarrollado por la Sociedad India de Nefrología (Indian Chronic Kidney Disease Risk Equation, que emplea variables como edad, sexo, la creatinina sérica y la presión arterial.<sup>(38-40)</sup>

2. Nigeria y Kenia utilizan un modelo de predicción desarrollado por investigadores locales basado en variables clínicas y demográficas territoriales.<sup>(38-40)</sup>

Estos modelos son específicos para las áreas en las que se emplean atendiendo a las características demográficas de cada una, es por eso la gran variedad de ellos, y es que cada uno tiene sus propias fortalezas y debilidades, siendo utilizados en escenarios diferentes.

### **Modelos más utilizados por su validación externa**

Modelo de la Ecuación CKD-EPI (Chronic Kidney Disease Epidemiology Collaboration),  
Modelo de Tangri, y Nomogramas Individuales.<sup>(12,39-42)</sup>

Este modelo, está basado en la creatinina sérica, la edad, el sexo y la raza, es ampliamente utilizado para estimar la tasa de filtración glomerular (TFGe) y clasificar la ERC. Aunque no fue diseñado específicamente para predecir la progresión, su valor de TFGe basal se ha utilizado como predictor en otros modelos; dentro de sus ventajas se asume que es ampliamente disponible, estandarizado y fácil de calcular pero no incluye factores de riesgo importantes como la albuminuria, la presión arterial o la diabetes por lo que su precisión para predecir la progresión es limitada. En un estudio de 2021 publicado por Chan<sup>(4)</sup>, el uso de la TFGe CKD-EPI basal para predecir la progresión a enfermedad renal terminal (ERT) tuvo un área bajo la curva ROC (AUC) de 0.65 (IC 95%: 0.60-0.70 tiene buenas propiedades discriminativas, pero su AUC es generalmente inferior en comparación con otros modelos más completos como el de Tangri.<sup>(12,39-42)</sup>

Modelo de Tangri (Chronic Kidney Disease Cohort Consortium).

Desarrollado en Canadá en el año 2011, por Navdeep Tangri, un modelo que utiliza variables medidas de forma rutinaria, en pacientes con ERC para predecir la probabilidad de progresar a falla renal a los 2 y 5 años, clasifica el riesgo como bajo, (0-



5 %), moderado (5- 15 %), y alto (> 15 %).(5) Este modelo inicial fue desarrollado con 2 cohortes de población canadiense, incluyendo 3449 y 4942 pacientes en la cohorte de validación respectivamente. Se desarrollaron cuatro tipos de KFRE, el modelo más preciso fue el de 8 variables.<sup>(12, 39-42)</sup>

Este modelo incorpora la TFGe la albuminuria, la edad, el sexo, la raza, el historial de enfermedad cardiovascular, la diabetes y el uso de inhibidores del SRAA (Sistema renina angiotensina y aldosterona). Predice el riesgo de ERT (enfermedad renal terminal) o una disminución del 50 % en la TFGe. Tiene como ventajas que incorpora múltiples factores de riesgo importantes y que ha sido validado en diversas cohortes, pero requiere la recopilación de datos adicionales más allá de la creatinina sérica. Evaluando su rendimiento: En el estudio original de desarrollo y validación de Tangri publicado en 2011, el modelo de 8 variables tuvo un C-estadístico (equivalente al AUC) de 0,78 (IC 95 %: 0,76-0,80) para predecir el riesgo de ERT o una disminución del 50 % en la TFGe a los 5 años. Su desventaja radica es que es más complejo de calcular que la ecuación CKD-EPI y requiere la recopilación de datos adicionales.<sup>(12, 39-42)</sup>

**Nomogramas Individuales.** Es una herramienta gráfica utilizada para predecir un resultado específico basado en múltiples variables o factores de riesgo. Es un diagrama bidimensional diseñado para permitir el cálculo gráfico aproximado de una función matemática, en el caso de la investigación la regresión logística ordinal. Consiste en un conjunto de n escalas, una para cada variable de una ecuación. Conociendo los valores de n-1 variables, se puede encontrar el valor de la variable desconocida, o fijando los valores de algunas variables, se puede estudiar la relación entre las variables no fijadas. Su precisión está limitada por la precisión con la que se pueden dibujar, reproducir, ver y alinear las marcas físicas. Algunos estudios han desarrollado nomogramas personalizados para predecir la progresión en cohortes específicas de pacientes con ERC algunos han mostrado AUC superiores a 0,8.<sup>(40-43)</sup>



Los modelos estadísticos tradicionales son los más utilizados para predecir la presencia, progresión y riesgo asociado a la ERC. Su base es la aplicación de técnicas clásicas de regresión que relacionan variables clínicas y de laboratorio con la probabilidad o el riesgo de enfermedad.

### **1. Regresión de Cox ó de riesgos proporcionales<sup>(39, 42-46)</sup>**

- Es definitivamente el método más utilizado en investigación de progresión de ERC debido a la interpretabilidad clínica directa mediante Hazard Ratios, flexibilidad para manejar datos del mundo real, herramientas estadísticas maduras y válidas, capacidad para modelar relaciones complejas, es el estándar metodológico cuando se quieren comparar nuevos métodos
- Limitaciones: Supuesto de Proporcionalidad, No predice tiempos individuales y sensible a *outliers* influentes

### **2. Regresión logística múltiple<sup>(39, 42-46)</sup>**

- Es el modelo estadístico más común para predecir la probabilidad de presentar ERC en función de múltiples factores de riesgo.
- Ejemplo destacado: un modelo que incluye enfermedades urológicas, hipertensión arterial (HTA), hiperuricemia y uso de nefrotóxicos, con una asociación estadísticamente significativa para cada factor ( $p < 0,001$ ). La presencia simultánea de los cuatro factores confiere una probabilidad de ERC del 99,9 %, mientras que la combinación de enfermedad urológica y uso crónico de nefrotóxicos da una probabilidad del 92,8 %.

### **2. Modelos basados en estimación de la tasa de filtración glomerular (TFG)<sup>(39, 42-46)</sup>**



- Las ecuaciones para estimar la TFG, como Cockcroft-Gault (CG) y MDRD, son fórmulas matemáticas derivadas de técnicas de regresión que relacionan creatinina sérica con la función renal real medida.
- Estas ecuaciones permiten clasificar la ERC en estadios según la función renal residual y son ampliamente utilizadas para diagnóstico, pronóstico y seguimiento.
- La ecuación MDRD fue desarrollada con datos de 1.628 pacientes y ajustada para creatinina estandarizada, mejorando su precisión.
- Aunque no son modelos predictivos en sentido estricto, constituyen la base para la clasificación y seguimiento de la ERC en la práctica clínica.

### 3. Modelos de regresión lineal y análisis multivariado<sup>(39, 42-46)</sup>

- Utilizados para modelar la tasa de declive de la función renal a lo largo del tiempo, relacionando variables continuas como creatinina, edad, presión arterial y otros factores.
- Permiten estimar la velocidad de progresión y el riesgo de transición entre estadios de ERC.
- Aunque menos sofisticados que la regresión logística, aportan información cuantitativa sobre la dinámica de la enfermedad.

### Características generales de los modelos estadísticos tradicionales<sup>(39, 42-46)</sup>

- **Interpretabilidad:** Los coeficientes de regresión permiten entender la contribución individual de cada factor de riesgo.
- **Simplicidad:** Requieren variables clínicas y de laboratorio habitualmente disponibles, facilitando su uso en la práctica.
- **Validación:** Muchos modelos han sido validados en diferentes poblaciones, aunque la calidad y aplicabilidad pueden variar.



- **Limitaciones:** Pueden no captar interacciones complejas o no lineales entre variables, y su precisión puede ser menor que la de modelos basados en inteligencia artificial.

Todos los esfuerzos son pocos cuando se trata de mejorar la estratificación del paciente con ERC y no se describen suficientes modelos que pretendan unificar todos los parámetros involucrados en su detección precoz.

## Consideraciones finales

Los modelos predictivos de la Enfermedad Renal Crónica han evolucionado desde enfoques tradicionales basados en variables clínicas y de laboratorio hacia modelos complejos que integran inteligencia artificial y el uso de grandes bases de datos. Los modelos más robustos combinan variables demográficas, clínicas, de laboratorio y comorbilidades, tienen una alta capacidad discriminativa y utilidad potencial en la práctica clínica para estratificar el riesgo y optimizar el manejo de los pacientes, sin embargo su usabilidad actual es limitada y existen barreras metodológicas y de validación externa que dificultan su implementación generalizada, persiste, en la mayoría de las propuestas, la inconsistencia y falta de validación externa.

En la práctica, su uso, se deben adaptar a los contextos propios de cada región y a las limitaciones asociadas a los servicios.

## Referencias bibliográficas



1. International Society of Nephrology (ISN). Global Kidney Health Atlas [Internet]. Advancing Nephrology Around the World. 2017. 188 p. Disponible en:  
[https://www.researchgate.net/publication/318901883\\_Global\\_Kidney\\_Health\\_Atlas\\_GKHA](https://www.researchgate.net/publication/318901883_Global_Kidney_Health_Atlas_GKHA)
2. Herrera R, Almaguer M, Chipi JA, Pérez-Oliva JF, Landrove O, et al. Prevalence and incidence of chronic kidney disease in Cuba. Clin Nephrol. 2020 Supplement-Jan;93(1):68-71. DOI: <https://doi.org/10.5414/CNP92S111>
3. Navarrete López CA. Predicción de progresión de enfermedad renal crónica en pacientes diabéticos por la fórmula Kidney Failure Risk Equation (KFRE) en población mexicana. [Trabajo terminal especialidad en línea]. Monterrey: Instituto Tecnológico y de Estudios Superiores de Monterrey; 2020 [citado 2025, Diciembre]. Disponible en: <https://hdl.handle.net/11285/649992>
4. Lun AY, Pek S, Low S, Moh A, Ang K, et al. Association of overhydration and serum pigment epithelium-derived factor with CKD progression in diabetic kidney disease: A prospective cohort study. Diabetes Res Clin Pract. 2021;174:108754. DOI: <https://doi.org/10.1016/j.diabres.2021.108754>
5. Hernández Y, Barrio L. ¿Se puede predecir la progresión de la enfermedad renal crónica con unos datos básicos demográficos y de laboratorio? 2011;2sup(4):7-76. DOI:  
<https://doi.org/10.3265/NefrologiaSuplementoExtraordinario.pre2011.Jul.11044>
6. Bravo Zuñiga JI, Soto Becerra P, Coila Paricahua EJ, Chávez Gómez JR, et al. Recalibración del modelo KFRE de 4 variables para predecir falla renal en población adulta con enfermedad renal crónica de ESSALUD. Reporte de resultados de investigación 01-2024. Instituto de Evaluación de Tecnologías En Salud E Investigación. Disponible en:  
<https://repositorio.essalud.gob.pe/bitstream/handle/20.500.12959/5027/RRI-012024.pdf?sequence=1&isAllowed=y>

7. Van den Brand JAJG, Dijkstra TMH, Wetzels J, Stengel B, Metzger M, Blankestijn PJ, et al. Predicting kidney failure from longitudinal kidney function trajectory: A comparison of models. PLoS ONE. 2019;14(5):e0216559
8. Hallan SI, Rifkin DE, Potok OA, Katz R, Langlo KA, Bansal N, et al. Implementing the European Renal Best Practice Guidelines suggests that prediction equations work well to differentiate risk of end-stage renal disease vs. death in older patients with low estimated glomerular filtration rate. Kidney Int. septiembre de 2019;96(3):728-37.
9. Bravo-Zúñiga J, Chávez-Gómez R, Soto-Becerra P. Multicentre external validation of the prognostic model kidney failure risk equation in patients with CKD stages 3 and 4 in Peru: a retrospective cohort study. BMJ Open. 1 de enero de 2024;14(1):e076217.
10. Gallardo Vidala LS, Rodríguez Méndez AJ, Burgos Ochoac M, Martínez Martínez ML, García Solís P. Utilidad de un modelo de predicción para la enfermedad renal crónica en una unidad de primer nivel de atención. Nefrología. 2016; 36(2):89-216. DOI: <https://doi.org/10.1016/j.nefro.2015.10.010>
11. Lim DKE, Boyd JH, Thomas E, Chakera A, Tippaya S, Irish A, et al. Prediction models used in the progression of chronic kidney disease: A scoping review. PLoS ONE. 2022;17(7): e0271619. DOI: <https://doi.org/10.1371/journal.pone.0271619>
12. Tangri N, Inker LA, Hiebert B, Wong J, Naimark D, Kent D, et al. Un modelo predictivo dinámico para la progresión de la enfermedad renal crónica (ERC). Revista estadounidense de enfermedades renales: la revista oficial de la Fundación Nacional del Riñón. 2016;69(4):514–20. DOI: <http://doi.org/10.1053/j.ajkd.2016.07.030>
13. Akbari A, Tangri N, Brown PA, Biyani M, Rhodes E, Kumar T, et al. Predicción de la progresión de la enfermedad renal poliquística mediante la ecuación de riesgo de

- insuficiencia renal y parámetros ecográficos. Revista Canadiense de Salud y Enfermedad Renal. 2020;7. DOI: <http://doi.org/10.1177/2054358120911274>
14. Escalona González SO, González Milán ZC. Inteligencia artificial en la predicción de mortalidad por enfermedad renal crónica. Anales de la ACC [online]. 2022[citado 2025-05-19]2;12(3). Disponible en:  
[http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S2304-01062022000300004&lng=es&nrm=iso](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2304-01062022000300004&lng=es&nrm=iso)
15. Reddy S, Roy S, Choy KW, Sharma S, Dwyer KM. Predicting chronic kidney disease progression using small pathology datasets and explainable machine learning models. Computer Methods and Programs in Biomedicine. 2024. Update 6/2024. 100160. DOI: <https://doi.org/10.1016/j.cmpbup.2024.100160>
16. T. Ferguson, P. Ravani, M.M. Sood, A. Clarke, P. Komenda, C. Rigatto, et al., Development and external validation of a machine learning model for progression of CKD, Kidney Int Rep.2022; 7(8): 1772–1781.
17. Olczak J, Pavlopoulos J, Prijs J, Ijpma FFA, Doornberg JN, Lundstrom C, et al. Presenting artificial intelligence, deep learning, and machine learning studies to clinicians and healthcare stakeholders: an introductory reference with a guideline and a Clinical AI Research (CAIR) checklist proposal, Acta Orthop. 2021;92(5):513–525.
18. Reddy S, Fox J, Purohit MP. Artificial intelligence-enabled healthcare delivery, J. R. Soc. Med. 2019;112(1):22–28.
19. Reddy S. Explainability and artificial intelligence in medicine. Lancet Digit Health. 2022;4(4):e214–e2e5.
20. Ebbehøj A, Thunbo M, Andersen OE, Glindtvad MV, Hulman A. Transfer learning for non-image data in clinical research: a scoping review. PLOS Digit Health.2022;1(2):e0000014.

21. Chan L, Nadkarni GN, Fleming F, McCullough JR, Connolly P, Mosoyan G, et al. Derivation and validation of a machine learning risk score using biomarker and electronic patient data to predict progression of diabetic kidney disease, *Diabetologia*. 2021;64(7):1504–15.
22. Jialin Liu, Jinfa Wu, Siru Liu, Mengdie Li, Kunchang Hu, Ke Li. Predicting mortality of patients with acute kidney injury in the ICU using XGBoost model. *PLoS One* 4 de febrero de 2021;16(2):e0246306. DOI: <https://doi.org/10.1371/journal.pone.0246306>
23. Soares CMB, Oliveira EA, Diniz JSS, Lima EM, Vasconcelos MM. Predictive factors of progression of chronic renal insufficiency: a multivariate analysis. *Pediatr Nephrol*. 2003;18: 371–377. DOI: <https://doi.org/10.1007/s00467-003-1115-3>
24. Demirjian S, Lane B, Derweesh I, Takagi T, Fergany A. Chronic Kidney Disease Due to Surgical Removal of Nephrons: Relative Rates of Progression and Survival. *Journal of Urology* [Internet]. 2014 Oct 1;192(4):1057–63. Disponible en: <https://doi.org/10.1016/j.juro.2014.04.016>
25. Chaurasia Dr, Vikas and Pal, Saurabh and Tiwari BB. Chronic Kidney Disease: A Predictive Model Using Decision Tree. *International Journal of Engineering Research and Technology*. 2018;11(11):1781-1794 Disponible en: <https://ssrn.com/abstract=3298343>
26. Dalrymple LS, Katz R, Kestenbaum B. Chronic Kidney Disease and the Risk of End-Stage Renal Disease versus Death. *J GEN INTERN MED*. 2011;26:379–385. DOI: <https://doi.org/10.1007/s11606-010-1511-x>
27. Isaza M, Yomayusa M, González C, Alvarado C, De Oro F, García JA. Predicting chronic kidney disease progression with artificial intelligence. *BMC Nephrol*. 2024 Apr 26;25:148. Disponible en: DOI: [10.1186/s12882-024-03545-7](https://doi.org/10.1186/s12882-024-03545-7)

28. Zhu Y, Bi D, Saunders M, Ji Y. Prediction of chronic kidney disease progression using recurrent neural network and electronic health records. *Sci Rep* 2023; 13: 22091. DOI: <https://doi.org/10.1038/s41598-023-49271-2>
29. Giraldo-Castrillón Y, Arango C, Molina CF, Segura A. Aplicabilidad de modelos predictivos de falla renal en enfermedad renal crónica: una revisión de alcance. *Rev Ces Med*, 2022; 36(3): 69-85. DOI: <https://dx.doi.org/10.21615/cesmedicina.6987>
30. Pérez-Oliva Díaz JF, Herrera Valdés R, Almaguer López M. ¿Como mejorar el manejo de la enfermedad renal cronica?: consideraciones y recomendaciones prácticas. *Rev haban cienc méd.* 2008 Mar;7(1). Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1729-519X2008000100009&lng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1729-519X2008000100009&lng=es).
31. Giraldo-Castrillón Y, Arango C, Molina CF, Segura A. Aplicabilidad de modelos predictivos de falla renal en enfermedad renal crónica: una revisión de alcance. *Rev Ces Med*, 2022; 36(3): 69-85. DOI: <https://dx.doi.org/10.21615/cesmedicina.6987>
32. Abdullah A, Raza A, Rasool Q, Rashid U, Minam M, Rasool S. A Literature Analysis for the Prediction of Chronic Kidney Diseases. JCBI [Internet]. 2024; Vol.7(02). Disponible en: <https://jcbi.org/index.php/Main/article/view/586>
33. Iftikhar H, Hashem AF, Qureshi M, Rodrigues PC. Clinical Application of Machine Learning Models for Early-Stage Chronic Kidney Disease Detection. *Diagnostics* 2025;15: 2610. DOI: <https://doi.org/10.3390/diagnostics15202610>
34. Pan Q, Tong M. Artificial intelligence in predicting chronic kidney disease prognosis. A systematic review and meta-analysis. *Renal FailuRe* 2024, 46(2): 2435483. DOI: <https://doi.org/10.1080/0886022X.2024.2435483>
35. Debal DA, Sitote TM. Chronic kidney disease prediction using machine learning techniques. *Journal of Big Data* 2022; 9(109):2-19. Disponible en: <https://doi.org/10.1186/s40537-022-00657-5>



36. Vásquez G, Martínez S, Moreno P, Recio J. Explainable Prediction for chronic renal in the colombian population. *IEEE Access*. 2019; 7(1):152900-152910. DOI: <https://doi.org/10.1109/ACCESS.2019.2948430>.
37. Fitzmaurice GM. A new predictive model for progression of chronic kidney disease. *Kidney int.* 2021;99(3):675-684. Disponible en: DOI: <https://doi:10.1016/j.kint.2020.11.027>
38. Ascencio E, Aparcana D, Carrillo R. Chronic kidney disease in Low- and Middle-Income Countries: Protocol for a systematic review of diagnostic and prognostic models. *medRxiv* 2021.04.24.21256041; DOI: <https://doi.org/10.1101/2021.04.24.21256041>
39. Tangri N, Kitsios GD, Inker LA, Griffith J, Naimark D. Risk prediction models for patients with chronic kidney disease in China: a systematic review. *Ann Intern Med*. 2013 Apr 16;158(8):596-603. DOI: <https://doi.org/10.7326/0003-4819-158-8-201304160-00004>
40. Tangri N, Stevens PE, Griffith J, Tighiouart H, Djurdjev O. A Predictive model for progression of chronic kidney disease: development and validation. *JAMA*. 2011 Apr 20;305(15):1553-9. Disponible en: DOI: [10.1001/jama.2011.451](https://doi.org/10.1001/jama.2011.451)
41. Martínez D, Beltrán A, Beloqui O, Huerta A. El índice neutrófilo/linfocito como marcador de disfunción sistémica endotelial en sujetos asintomáticos. *Nefrología* 2016;36(4):397–403 Disponible en: DOI: [10.1016/j.nefro.2015.10.018](https://doi.org/10.1016/j.nefro.2015.10.018)
42. Tangri N, Kitsios GD, Inker LA, Griffith J, Naimark DM. Risk prediction models for patients with chronic kidney disease: a systematic review. *Annals of internal medicine*. 2013;158(8): 596-603. Disponible en: <https://doi.org/10.7326/0003-4819-158-8-201304160-00004>
43. Echouffo-Tcheugui JB, Kengne AP. Risk models to predict chronic kidney disease and its progression: a systematic review. *PLoS medicine*. 2012;9(11):e1001344. DOI: <https://doi.org/10.1371/journal.pmed.1001344>

44. Jiang W, Wang J, Shen X, Lu W, Wang Y. Establishment and Validation of a Risk Prediction Model for Early Diabetic Kidney Disease Based on a Systematic Review and Meta-Analysis of 20 Cohorts. *Diabetes Care* 1 April 2020; 43 (4): 925–933. DOI: <https://doi.org/10.2337/dc19-1897>
45. Feng Y, Wang AY, Jun M. Characterization of Risk Prediction Models for Acute Kidney Injury: A Systematic Review and Meta-analysis. *JAMA Netw Open*. 2023;6(5):e2313359. DOI: <https://doi:10.1001/jamanetworkopen.2023.13359>
46. Lei N, Zhang X, Wei M. Machine learning algorithms' accuracy in predicting kidney disease progression: a systematic review and meta-analysis. *BMC Med Inform Decis Mak.* 2022; 22: 205. DOI: <https://doi.org/10.1186/s12911-022-01951-1>

