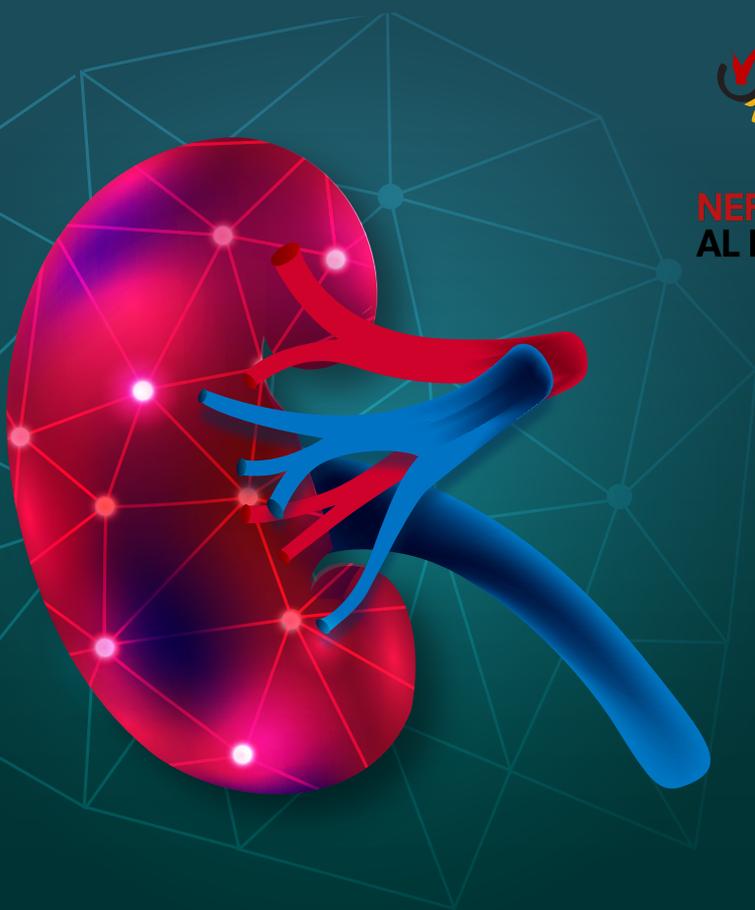


**Ángel L. Martín de Francisco**

Catedrático de Nefrología Universidad de Cantabria

# MEDICINA RENAL INTELIGENTE

El futuro de la nefrología clínica con inteligencia artificial



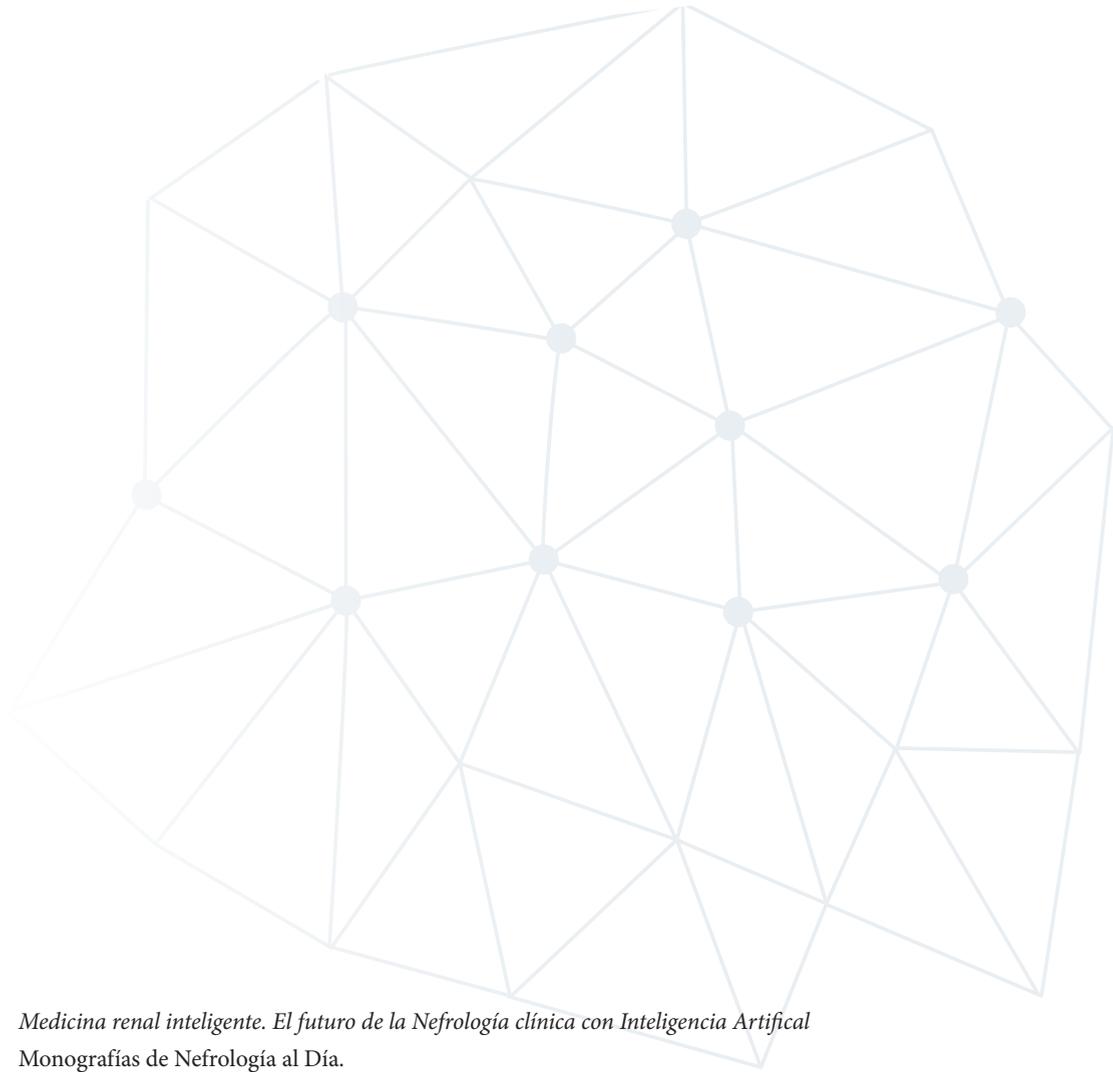
**NEFROLOGÍA  
AL DÍA**

**Víctor Lorenzo Sellares**  
**Juan Manuel López Gómez**  
**Miquel Blasco Pelicano**  
Editores Nefrología al Día



## MEDICINA RENAL INTELIGENTE

*El futuro de la Nefrología clínica con Inteligencia Artificial*



*Medicina renal inteligente. El futuro de la Nefrología clínica con Inteligencia Artificial*

Monografías de Nefrología al Día.

Grupo Editorial de la Sociedad Española de Nefrología. Edición 2025.

ISBN 978-84-129769-3-9

**EDITOR**

Ángel Luis Martín de Francisco

Catedrático de Nefrología Universidad de Cantabria

# ÍNDICE

---

Agradecimientos .....	1
Presentación .....	3
Introducción .....	5

## 1.

<b>Subcategorías De la Inteligencia Artificial .....</b>	<b>9</b>
1.1 Modelos de Aprendizaje Automático (Machine Learning ML) .....	9
1.2 Modelos de Aprendizaje Profundo (Deep Learning): Redes Neuronales Artificiales .....	11
1.3 Diferencias entre aprendizaje automático (ML) y profundo (DL) .....	12
1.4 Inteligencia Artificial Generativa (IA Gen) .....	12
1.5 Inteligencia Artificial multimodal .....	13

## 2.

<b>IA en la interpretación de imágenes en Nefrología .....</b>	<b>15</b>
2.1 Análisis de imágenes médicas .....	15
2.1.1 Radiómica .....	15
2.1.2 Aprendizaje Profundo (DL) .....	17
2.2 Evaluación no invasiva de la función renal y detección precoz de la ERC con imágenes médicas .....	17
2.2.1 Ecografía .....	17
2.2.2 Resonancia magnética (RM) .....	18
2.2.3 Tomografía Computarizada (TC) .....	18
2.2.4 Imágenes de retina .....	18
2.3 Aplicación de redes neuronales en el análisis de biopsias renales .....	19
2.4 Modelos de IA para el diagnóstico de tumores renales .....	19
2.5 Modelos de IA para la evolución en la poliquistosis renal autosómica dominante (ADPKD) del volumen quístico total (VKT) .....	20

## 3.

<b>IA en la detección y manejo de la Insuficiencia Renal Aguda (LRA- AKI) .....</b>	<b>23</b>
3.1 Predicción temprana de LRA .....	23
3.1.1 Factores a evaluar al buscar una predicción de LRA .....	24
3.1.2 importancia de nuevos marcadores en la predicción de LRA .....	24
3.2 Alertas electrónicas («E-Alerts») .....	24
3.3 Clasificación en fenotipos .....	25

## 4.

<b>IA en el diagnóstico de la biopsia renal .....</b>	<b>29</b>
4.1 Fases del desarrollo de IA para el análisis de biopsias renales .....	29
4.2 Estudios de análisis de imágenes en patología renal mediante IA .....	31
4.3 Aplicaciones de IA en la patología del trasplante renal .....	33
4.4 Modelos predictivos de la IA en patología renal .....	33
4.5 Combinación IA: datos histológicos y datos clínicos .....	33
4.6 Dificultades para la aplicación de la IA en la patología renal .....	34

<b>5.</b>	
<b>IA en la Enfermedad Renal Crónica (ERC)</b> .....	<b>37</b>
5.1 Categorías de aprendizaje automático en el manejo de la enfermedad renal crónica.....	37
5.2 IA en la predicción de la progresión y complicaciones de la Enfermedad Renal Crónica.....	37
5.3 IA aplicada al diagnóstico por imágenes y análisis de biopsias en la ERC.....	39
5.4 IA en el tratamiento y manejo de la ERC.....	40
5.4.1 Optimización de tratamientos farmacológicos personalizados.....	40
5.4.2 Chatbots para educación y seguimiento de pacientes con ERC.....	40
<b>6.</b>	
<b>Inteligencia artificial en diálisis</b> .....	<b>43</b>
6.1 Aplicaciones de la IA en hemodiálisis.....	43
6.1.1 Predicción de hipotensión intradiálisis.....	43
6.1.2 Optimización del manejo de la anemia.....	46
6.1.3 Monitorización del acceso vascular.....	47
6.1.4 Adecuación de la diálisis y planificación del servicio.....	48
6.1.5 Optimización de la dosis de diálisis y estabilidad hemodinámica.....	48
6.2. Aplicaciones de la IA en diálisis peritoneal.....	49
6.2.1 Pronóstico de pacientes y técnica.....	50
6.2.2 Predicción de peritonitis.....	51
6.2.3 Control a distancia y adherencia en DP domiciliaria.....	52
6.2.4 Chatbots para pacientes en DP.....	52
6.3 Desafíos y consideraciones éticas de la implementación de la IA en diálisis.....	53
<b>7.</b>	
<b>Aplicación de la inteligencia artificial en el trasplante renal</b> .....	<b>57</b>
7.1 Diagnóstico asistido por IA en el trasplante renal (detección de rechazo).....	57
7.1.1 Análisis histopatológico asistido por ML para mejorar la evaluación de biopsias.....	58
7.1.2 Análisis de expresiones génicas o proteómicas en biopsias o muestras sanguíneas.....	58
7.1.3 Evaluación radiológica avanzada (p. ej. resonancia magnética por difusión) con sistemas de diagnóstico asistido por computadora.....	59
7.2 Predicción temprana del rechazo agudo mediante modelos de IA.....	59
7.3 Pronóstico postrasplante a mediano y largo plazo (supervivencia del injerto y del paciente).....	60
7.4 Aplicaciones visuales de IA en la evaluación del injerto renal: imágenes médicas y análisis de tejidos.....	62
7.4.1 Imagen médica y segmentación renal asistidas por IA.....	62
7.4.2 Realidad aumentada y visión artificial.....	63
7.4.3 Patología digital renal y análisis de tejidos con IA.....	63
7.5 IA en la selección de donantes y receptores.....	65
7.5.1 Emparejamiento óptimo donante-receptor.....	65
7.5.2. IA y decisión de aceptar o rechazar un órgano ofrecido.....	65
7.5.3 IA y optimización de la logística y gestión de listas de espera.....	66
7.5.4 Análisis de datos y modelos predictivos en compatibilidad y resultados postrasplante.....	66
7.6 Impacto de la IA en la optimización de recursos y la atención al paciente con trasplante renal.....	68

<b>8.</b>	
<b>Aplicación de la IA en enfermedades glomerulares</b>	<b>73</b>
8.1 Flujo de trabajo con IA para evaluación automática de glomerulos	73
8.2 Diagnóstico de nefropatías	74
8.3 Pronóstico y manejo personalizado de las glomerulopatías	75
<b>9.</b>	
<b>Aplicación de la IA en Onconeurología</b>	<b>77</b>
9.1 Predicción de nefrotoxicidad inducida por tratamientos oncológicos	77
9.2 Manejo del daño renal ya establecido en pacientes con cáncer	78
9.3 Diagnóstico y clasificación	79
<b>10.</b>	
<b>Aplicación de la IA en hipertensión arterial</b>	<b>81</b>
10.1 Monitorización y seguimiento de la tensión arterial (TA)	81
10.2 Optimización del tratamiento antihipertensivo mediante IA	82
10.3 Predicción de la hipertensión de nueva aparición	82
10.4 Riesgo de mal control de la TA	82
10.5 Predicción de complicaciones	83
<b>11.</b>	
<b>Aplicación de la Inteligencia Artificial en la medicina cardiorrenal</b>	<b>85</b>
11.1 Predicción de riesgos y estratificación	86
11.2 Diagnóstico y detección temprana	86
11.3 Apoyo al tratamiento y decisiones terapéuticas	86
11.4 Planificación colaborativa y soporte clínico	87
11.5 Desafíos de la IA en la medicina cardiorrenal	87
11.6 Tendencias futuras y áreas de investigación en desarrollo de la IA en la medicina cardiorrenal	88
<b>12.</b>	
<b>Medicina personalizada en Nefrología: Integración de biomarcadores, datos clínicos e Inteligencia Artificial</b>	<b>91</b>
12.1 Biomarcadores y precisión en el daño renal	91
12.2 La IA: del Big Data a la acción clínica	92
12.2.1 Aplicaciones actuales de la IA en Nefrología	92
12.2.2 Retos en la implementación de IA	92
<b>13.</b>	
<b>IA Generativa (Gen AI): Educación médica [Nefrología]</b>	<b>95</b>
13.1 Principales programas de IA generativa	95
13.2 Aplicaciones de la IA generativa para educadores y profesionales	95
13.3 Ventajas de la IA en la estructuración de texto	97
13.4 Resumen clínico en consulta en tiempo real	97
13.5 Ensayos clínicos	98
13.6 IA y educación médica	98
13.7 IA generativa comparada con médicos	99
13.8 Ventajas y dificultades de la IA en la formación médica	99

<b>14.</b>	
<b>Razones para que los especialistas en Nefrología se impliquen en la IA</b>	<b>103</b>
<b>15.</b>	
<b>Desafíos actuales que enfrenta la implementación de la IA en la práctica clínica</b>	<b>105</b>
<b>16.</b>	
<b>El paciente renal y su participación en la IA en Nefrología</b>	<b>109</b>
<b>16.1</b> Contribución de los pacientes al desarrollo de la IA en Nefrología	109
<b>16.2</b> Beneficios y desafíos de la participación de los pacientes	109
<b>17.</b>	
<b>Diseño práctico de un estudio con inteligencia artificial en enfermedad renal crónica (ERC - CKD)</b>	<b>111</b>
<b>17.1</b> Variables clave para la predicción de la evolución de la ERC	111
<b>17.2</b> Pasos para diseñar el modelo de IA (Tabla 19)	112
<b>17.3</b> Implementación práctica del modelo	112
<b>17.4</b> Conclusión y aplicaciones	113
<b>18.</b>	
<b>El futuro prometedor de la IA en la Nefrología española: Grupo de Trabajo BIGSEN</b>	<b>115</b>
<b>18.1</b> Plan estratégico del grupo BIGSEN de la Sociedad Española de Nefrología (S.E.N.)	115
<b>18.2</b> El futuro de la IA en la Nefrología española	116
<b>19.</b>	
<b>Más allá del algoritmo</b>	<b>119</b>

## **AGRADECIMIENTOS**

---

En la elaboración de este trabajo se ha utilizado la herramienta de inteligencia artificial ChatGPT-4o (OpenAI) y Gemini 2.0 (Google) para la generación de ideas, revisión de estilo y apoyo en la redacción de ciertos apartados. No obstante, la validación y selección de contenidos han sido realizadas por el autor, basándose en literatura científica actualizada.



## PRESENTACIÓN

---

Tras el primer libro, *ARTIFICIAL: La Nueva Inteligencia y su Aplicación en Nefrología* [1] nos complace presentar esta segunda obra: *Medicina Renal: Inteligente. El futuro de la Nefrología Clínica con Inteligencia Artificial*. Si en nuestro primer trabajo exploramos los fundamentos y el potencial de la inteligencia artificial (IA) en el campo de la Nefrología, en este segundo volumen damos un paso más allá, centrándonos en su implementación real en la práctica clínica.

La IA ha dejado de ser una mera promesa para convertirse en una herramienta con aplicaciones concretas en la toma de decisiones médicas, la optimización del diagnóstico y el tratamiento personalizado. Por ello, este libro analiza los avances más recientes en la aplicación de la IA en distintas áreas de la Nefrología, incluyendo Imágenes, Biopsia renal, Enfermedades glomerulares, Insuficiencia renal aguda, Enfermedad renal crónica, Diálisis, Trasplante renal, Hipertensión arterial, Medicina cardiorenal y Onconefrología.

A lo largo de sus capítulos, presentamos estudios que muestran cómo los algoritmos de aprendizaje automático están mejorando la detección precoz de enfermedades renales, permitiendo una mayor precisión en la clasificación de biopsias renales y facilitando modelos predictivos para evaluar la progresión de la enfermedad renal crónica o la evolución del trasplante renal. También exploramos la integración de la IA en la monitorización remota de pacientes y su impacto en la personalización de tratamientos en hemodiálisis y diálisis peritoneal.

Un aspecto clave de este libro es la discusión sobre los desafíos actuales que enfrenta la implementación de la IA en la práctica clínica. Nos preguntamos: ¿Cuáles son los límites de la tecnología en el contexto de la toma de decisiones médicas? ¿Cómo se pueden garantizar la ética y la equidad en el uso de estos sistemas? ¿Qué papel desempeñan la regulación y las normativas en la adopción de la IA en Nefrología? En un campo donde la seguridad del paciente es prioritaria, es fundamental abordar estos interrogantes para avanzar hacia un uso responsable y eficaz de la inteligencia artificial.

Miramos también al futuro, analizando nuevas líneas de desarrollo como el uso de modelos de lenguaje para la asistencia en la interpretación de informes clínicos, la IA generativa en la educación médica y la aplicación de redes neuronales para la identificación de biomarcadores en enfermedades renales.

En definitiva, este libro es una guía para médicos, investigadores y profesionales de la salud interesados en comprender cómo la inteligencia artificial está transformando la práctica de la medicina renal en 2025. Queremos ofrecer una visión equilibrada, basada en evidencia y con

un enfoque crítico, que permita a la comunidad médica no solo adoptar estas herramientas, sino también participar activamente en su evolución y regulación.

Esperamos que esta obra contribuya a enriquecer el debate y a impulsar nuevas aplicaciones que mejoren la calidad de vida de los pacientes con enfermedad renal.



Ángel Luis Martín de Francisco

*Catedrático de Nefrología. Universidad de Cantabria  
Servicio de Nefrología. HU Valdecilla Santander Cantabria*

#### REFERENCIAS

- 1 De Francisco ALM. Artificial. La Nueva Inteligencia y su Aplicación en Nefrología. En Lorenzo V, López Gómez JM (Eds) Nefrología al Día ISBN 978-84-127624-1-9.

## INTRODUCCIÓN

---

La inteligencia artificial (IA) ha emergido como una herramienta revolucionaria en la medicina, transformando la manera en que se diagnostican, tratan y previenen enfermedades. Con el desarrollo de técnicas avanzadas como el aprendizaje automático y el aprendizaje profundo [1], la IA ha permitido el análisis de grandes volúmenes de datos clínicos, optimizando la toma de decisiones médicas y mejorando la precisión diagnóstica. Su impacto abarca diversas áreas, desde la Radiología y la Oncología hasta la Cardiología y la neurología, con aplicaciones que van desde la interpretación de imágenes médicas hasta la personalización de tratamientos en función de modelos predictivos.

El número de aplicaciones clínicas de IA aprobadas ha aumentado drásticamente en los últimos años. Casi mil nuevos productos habilitados con inteligencia artificial han sido aprobados por la FDA a finales de 2024 [2]. La Radiología lidera ampliamente las aprobaciones, representando más del 70 % de todas las autorizaciones con 758 y con 35 nuevos productos añadidos desde agosto 2024. Cardiología ocupa el segundo lugar con 101 aprobaciones, además de otras 60 que también se incluyen dentro de la categoría de Radiología. Neurología está en un distante tercer lugar, con 35 aprobaciones registradas. Dentro de esta transformación, la Nefrología ha sido un

campo que ha experimentado un crecimiento significativo en el uso de la IA si bien a una distancia importante respecto a Radiología o Cardiología. La enfermedad renal, debido a su complejidad y alta prevalencia, requiere enfoques innovadores para su detección temprana, tratamiento y manejo a largo plazo y la IA ha demostrado ser particularmente útil en la identificación de patrones en enfermedades renales, la predicción de progresión de la enfermedad y la optimización de tratamientos como la diálisis y el trasplante renal.

Un análisis de la literatura en MEDLINE hasta noviembre de 2022 [3] identificó 1687 artículos, de los cuales 342 se centraban en IA en Nefrología, con un notable aumento después de 2010. Estos estudios fueron clasificados en diversos dominios: hemodiálisis (HD), diálisis peritoneal (DP), trasplante renal (TR), lesión renal aguda (LRA), enfermedad renal crónica (ERC), cuidados críticos, enfermedad glomerular, nutrición y otros (Tabla 1).

Un análisis bibliométrico más reciente [4] ha demostrado el crecimiento exponencial del uso de la IA en la Nefrología. Según un estudio basado en la recopilación de artículos publicados entre 2012 y 2023 en la Web of Science, se identificaron 631 publicaciones relevantes en este campo. El estudio reveló que las revistas más influyentes en esta área incluyen *Nephrology Dialysis Transplantation*, *American Journal*

**TABLA 1.** Revisión de la literatura en cada dominio de IA en Nefrología (hasta Nov 2022) [3]

TEMA	PUBLICACIONES (N)	OBJETIVOS
Hemodiálisis (HD)	65	<ul style="list-style-type: none"> <li>- Predicción de la adecuación de la diálisis y planificación del servicio</li> <li>- Evaluación del acceso arteriovenoso</li> <li>- Predicción de la mortalidad</li> <li>- Predicción de eventos de enfermedad cardiovascular (ECV)</li> <li>- Sistema de apoyo a la decisión clínica (CDSS) para la anemia</li> <li>- CDSS para el manejo de la enfermedad ósea y mineral en la enfermedad renal crónica (ERC-MBD)</li> <li>- Predicción del peso seco</li> <li>- Predicción de eventos adversos intradialíticos</li> <li>- Predicción de la función cognitiva</li> </ul>
Diálisis Peritoneal (DP)	5	<ul style="list-style-type: none"> <li>- Predicción de la prueba de equilibrio peritoneal (PET)</li> <li>- Predicción de la mortalidad</li> <li>- Predicción del fracaso del tratamiento</li> <li>- Predicción de eventos de enfermedad cardiovascular (ECV)</li> <li>- Identificación de respuestas inflamatorias específicas de patógenos</li> </ul>
Trasplante Renal (TR)	29	<ul style="list-style-type: none"> <li>- Priorización para la asignación de órganos</li> <li>- Predicción del tiempo en lista de espera</li> <li>- Predicción de la supervivencia renal</li> <li>- Predicción de la función del injerto</li> <li>- Predicción del porcentaje de fibrosis intersticial y atrofia tubular (%FIAT)</li> <li>- Predicción del nivel de tacrolimus</li> </ul>
Lesión Renal Aguda (LRA)	71	<ul style="list-style-type: none"> <li>- Predicción de eventos/gravedad de la LRA en diversas operaciones, incluyendo CABG, reparación de TAA, trasplante cardíaco, PCI, TKA, quemaduras</li> <li>- Predicción de eventos de LRA en pacientes con ECV</li> <li>- Predicción de la nefropatía inducida por contraste</li> <li>- Predicción de la mortalidad post-LRA</li> <li>- Identificación de nuevos biomarcadores</li> </ul>
Enfermedad Renal Crónica (ERC)	72	<ul style="list-style-type: none"> <li>- Predicción del inicio de la terapia de reemplazo renal (TRR)</li> <li>- Predicción de la progresión de la nefropatía diabética (ND)</li> <li>- Predicción de la progresión de la poliquistosis renal autosómica dominante (PQRAD)</li> <li>- Predicción de la progresión de otras ERC</li> <li>- Identificación de biomarcadores/genética potencial para la ERC</li> <li>- CDSS para el manejo de la anemia</li> <li>- CDSS para el manejo de la ERC-MBD</li> </ul>
Cuidados Críticos	16	<ul style="list-style-type: none"> <li>- Predicción de la recuperación renal</li> <li>- Predicción de la dependencia de la TRR</li> <li>- Predicción de LRA grave en UCI</li> <li>- Predicción de la respuesta al volumen en pacientes oligúricos</li> <li>- Predicción de la tendencia del nivel de nitrógeno ureico en sangre</li> </ul>

Abreviaturas: CDSS (sistemas de apoyo a la decisión clínica), CKD-MBD (enfermedad renal crónica con trastorno mineral óseo), PET (prueba de equilibrio peritoneal), CVD (enfermedad cardiovascular), IFTA (fibrosis intersticial y atrofia tubular), CABG (injerto de derivación de arteria coronaria o bypass coronario), TAA (aneurisma de aorta torácica), PCI (intervención coronaria percutánea), TKA (artroplastia total de rodilla), RRT (terapia de reemplazo renal), ND (nefropatía diabética), ADPKD (enfermedad renal poliquística autosómica dominante), SLE (lupus eritematoso sistémico), IgAN (nefropatía por IgA), MN (nefropatía membranosa), AIN (nefritis intersticial aguda).

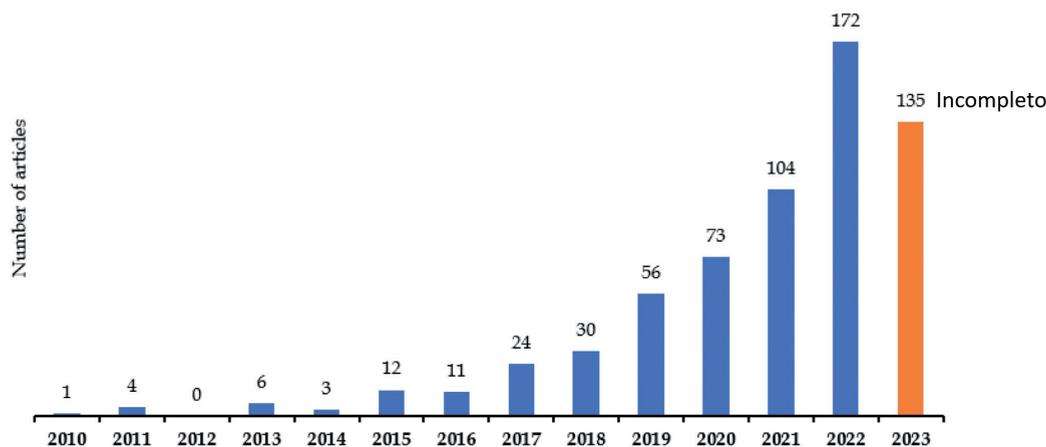
of Transplantation y Scientific Reports. Los países con mayor producción científica en este ámbito fueron Estados Unidos (25,99 %), China (24,72 %) e India (9,83 %), mientras que la Clínica Mayo, la Universidad de Harvard y la Universidad Sun Yat-Sen destacaron como las instituciones con más contribuciones (Figura 1).

Estos hallazgos reflejan cómo la IA se está consolidando como una herramienta esencial en la Nefrología, permitiendo avances significativos en la comprensión de la enfermedad

renal y en la mejora de su tratamiento. La creciente colaboración internacional y el desarrollo de nuevas tecnologías basadas en IA sugieren un futuro prometedor, en el que la inteligencia artificial desempeñará un papel fundamental en la optimización del cuidado renal y la personalización de terapias.

Este artículo tiene como objetivo explorar en profundidad cómo la IA está siendo aplicada en la práctica clínica nefrológica, destacando sus beneficios, avances y desafíos.

**FIGURA 1.** Número de publicaciones anuales sobre la aplicación de la IA en el ámbito de las enfermedades renales [4]



Wu CC, et al Diagnostics 2024 Feb 12;14(4):397.

#### REFERENCIAS

- 1 De Francisco ALM. Artificial. La Nueva Inteligencia y su Aplicación en Nefrología. En Lorenzo V, López Gómez JM (Eds) Nefrología al Día ISBN 978-84-127624-1-9.
- 2 U.S. Food and Drug Administration. Artificial Intelligence and Machine Learning (AI/ML)-Enabled Medical Devices [Internet]. Silver Spring, MD: FDA; updated Dec 2024 Available from: <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-aiml-enabled-medical-devices>
- 3 Boonvisuth, N, Tiranathanagul, K. Artificial Intelligence in Nephrology: Advancements, Opportunities, and Concerns in Hemodialysis. Journal of the Nephrology Society of Thailand, 2024; 30(3), 168–184. <https://he01.tci-thaijo.org/index.php/JNST/article/view/271559>
- 4 Wu CC, Islam MM, Poly TN, Weng YC. Artificial Intelligence in Kidney Disease: A Comprehensive Study and Directions for Future Research. Diagnostics (Basel). 2024, 12;14(4):397.



# 1.

## SUBCATEGORÍAS DE LA INTELIGENCIA ARTIFICIAL

---

Antes de avanzar en la aplicación de la IA en Nefrología vamos a recordar algunos aspectos básicos del funcionamiento de la IA en general que están extraídos de *ARTIFICIAL: La Nueva Inteligencia y su Aplicación en Nefrología* [1]. La inteligencia artificial (IA) es un conjunto de tecnologías que permiten a las máquinas simular la inteligencia humana para realizar tareas como el reconocimiento de voz, la toma de decisiones, el procesamiento del lenguaje natural y la visión por computadora. Funciona a través de algoritmos y modelos de aprendizaje que procesan grandes cantidades de datos para identificar patrones y hacer predicciones o tomar decisiones. Los sistemas de IA «aprenden» a través de numerosas repeticiones y el correspondiente *feedback* (entrenamiento) cómo alcanzar mejor una solución predeterminada (por ejemplo, diagnóstico, pronóstico de una enfermedad), lo que permite que el resultado sea más preciso y los procedimientos más eficientes. La IA funciona mediante algoritmos y modelos matemáticos que procesan datos para identificar patrones y tomar decisiones. Hay varias ramas y técnicas dentro de la IA, pero las más relevantes incluyen:

### 1.1 MODELOS DE APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING ML)

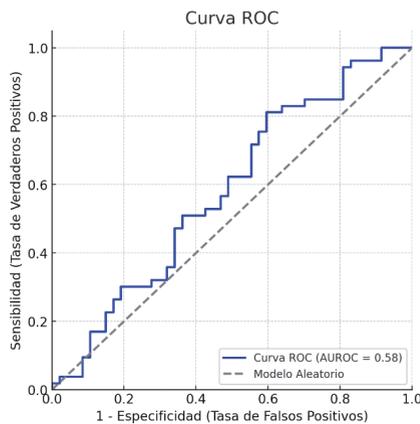
El ML permite desarrollar algoritmos que aprenden de manera automática a partir de los datos suministrados. El algoritmo no cuenta con un código que le brinde todas las opciones posibles, sino que se le instruye, se le entrena por el hombre para que detecte e identifique patrones y relaciones en los datos de manera automática con distintas finalidades: para clasificar, agrupar o predecir. Emplean redes neuronales simples, a lo sumo con una o dos capas computacionales.

Para poder adaptar tempranamente el tratamiento de una enfermedad (por ejemplo, la lesión renal aguda LRA) o incluso prevenir su aparición, es fundamental identificar lo antes posible a los pacientes con un alto riesgo. Mientras que para predicciones a corto plazo se ha establecido el uso de la regresión logística, en el caso de grandes volúmenes de datos y análisis complejos se recomienda cada vez más el uso de inteligencia artificial (IA). Cada algoritmo de IA tiene una sensibilidad y especificidad determinadas. Gráficamente, esto se representa en la Figura 2 en un diagrama donde el eje x corresponde a (1 - especificidad) es decir la tasa

de falsos positivos y el eje y a la sensibilidad que representa la tasa de verdaderos positivos. El «área bajo la curva de la característica operativa del receptor» (AUROC) se utiliza para evaluar el rendimiento del modelo. Cuanto mayor sea la AUROC, mejor distinguirá el modelo: valores por debajo de 0.7 suelen ser poco informativos y valores superiores a 0.9 se consideran excelentes.

Se utilizan distintos modelos de aprendizaje automático utilizados en clasificación y regresión, con diferentes enfoques funcionales tales como: regresión logística, Naive Bayes, máquina de vectores de soporte, árboles de decisión, modelo aditivo generalizado, *random forest*, etc.

**FIGURA 2.** Área bajo la curva de la característica operativa del receptor (AUROC)



Existen tres modelos de aprendizaje automático (ML):

- **Aprendizaje supervisado:** en este modelo, el algoritmo aprende a partir de datos etiquetados, es decir, ejemplos en los que la respuesta correcta ya es conocida. Se usa

principalmente para tareas de clasificación (por ejemplo, diagnóstico de enfermedades a partir de imágenes médicas) y regresión (como predecir la progresión de la enfermedad renal crónica). La IA ajusta su modelo en función de los datos de entrenamiento para hacer predicciones precisas en nuevos casos.

- **Aprendizaje no supervisado:** aquí, el modelo trabaja con datos sin etiquetas y busca patrones o estructuras ocultas sin intervención humana. Se emplea en tareas como la agrupación (*clustering*), donde se identifican subconjuntos en los datos (por ejemplo, diferentes fenotipos en enfermedades glomerulares).
- **Aprendizaje por refuerzo:** este modelo se basa en un agente que aprende a tomar decisiones mediante prueba y error, recibiendo recompensas o penalizaciones según sus acciones. Se usa en aplicaciones como la optimización del tratamiento en hemodiálisis, donde el sistema ajusta parámetros para mejorar los resultados del paciente a largo plazo.

En la Figura 3 puede verse como el aprendizaje supervisado utiliza datos etiquetados para entrenar modelos de inteligencia artificial que reconocen patrones y realizan predicciones. Ejemplos de aprendizaje supervisado en el contexto de la enfermedad renal crónica (ERC), por ejemplo, incluyen el diagnóstico de la ERC únicamente a partir de ecografías renales o imágenes del fondo de ojo, la predicción de la progresión de la enfermedad renal, la mortalidad y los niveles de hemoglobina en pacientes en hemodiálisis que reciben agentes estimulantes de la eritropoyesis (ESA), así como la identificación del tratamiento óptimo para los pacientes.

Por otro lado, el aprendizaje no supervisado utiliza datos no etiquetados para identificar

**FIGURA 3.** Representación de las dos categorías de aprendizaje automático en la gestión de la enfermedad renal crónica [2]



Krisanapan P, J Clin Med. 2023

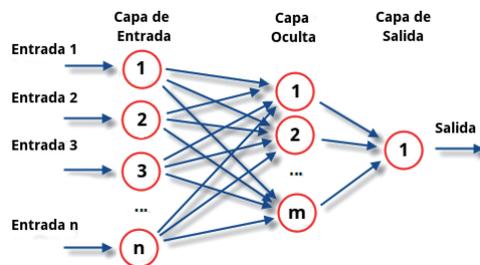
patrones o agrupar casos sin conocimiento previo del resultado. Ejemplos de aprendizaje no supervisado en la ERC incluyen la agrupación de pacientes según características clínicas y demográficas similares o el descubrimiento de biomarcadores desconocidos o subtipos de la enfermedad[2].

### 1.2 MODELOS DE APRENDIZAJE PROFUNDO (DEEP LEARNING): REDES NEURONALES ARTIFICIALES

El aprendizaje profundo (DL) es una rama de la inteligencia artificial que utiliza redes neuronales para imitar la forma en que el cerebro humano aprende y procesa información [1]. El aprendizaje profundo es un tipo de Machine Learning supervisado, donde el modelo aprende patrones a partir de grandes volúmenes de datos etiquetados, es decir, se le proporciona tanto la entrada como la salida esperada. Por ejemplo, para entrenar una red neuronal a reconocer cáncer de pulmón en imágenes, se le muestran miles de fotos de entrada, junto con la etiqueta correspondiente (cáncer sí, o cáncer no) como salida. Con el tiempo, la red aprende a identificar cáncer de pulmón por sí sola en nuevas imágenes.

Estas redes están formadas por múltiples «neuronas», organizadas en diferentes capas: entrada (recibe los datos iniciales); capas ocultas (procesan y transforman la información) y capa de salida (genera el resultado final del modelo) (Figura 4).

**FIGURA 4.** Red neuronal artificial



Cada neurona dentro de la red contiene funciones matemáticas que determinan cómo se procesan los datos. En la capa oculta, una neurona recibe información de otras neuronas, asigna pesos a estas entradas, realiza cálculos y transmite los resultados a otras neuronas en la misma capa o en capas posteriores. Durante el entrenamiento, los pesos de las conexiones

entre neuronas se ajustan repetidamente hasta que los resultados del modelo coinciden con la solución esperada. Una vez entrenadas, estas redes se aplican a datos reales o pacientes, permitiendo la identificación y predicción de condiciones médicas.

### 1.3 DIFERENCIAS ENTRE APRENDIZAJE AUTOMÁTICO (ML) Y PROFUNDO (DL)

En la Tabla 2 pueden observarse las diferencias entre aprendizaje automático (ML) y profundo (DL).

### 1.4 INTELIGENCIA ARTIFICIAL GENERATIVA (IA GEN)

Es un tipo de inteligencia artificial diseñada para crear contenido nuevo en lugar de simplemente analizar datos existentes. Se basa en modelos avanzados de aprendizaje automático, especialmente redes neuronales profundas, que pueden generar texto, imágenes, audio, código, y otros tipos de contenido a partir de patrones aprendidos en grandes conjuntos de

datos. Su funcionamiento se basa en técnicas como **redes neuronales generativas (GANs)** y **modelos de aprendizaje profundo** como los **Transformers** (el modelo asigna pesos a diferentes palabras dentro de una oración y puede capturar en paralelo relaciones entre palabras aunque estén muy separadas) que permiten la generación de contenido de alta calidad y realismo.

Es pues una rama de la IA enfocada en la creación de contenido nuevo y original.

- Texto: Creación de documentos, respuestas automáticas (ej.: ChatGPT, Gemini, Copilot, DeepSeek, Claude...)
- Imágenes: Generación de arte o imágenes sintéticas (ej.: DALL-E 3, Midjourney)
- Música: Composición automática en diferentes estilos (ej.: Suno, Amper Music)
- Vídeos: Creación de animaciones o simulaciones (ej.: Sora, Runway ML)
- Datos sintéticos: Generación de datos para entrenar modelos (ej.: SDV o MOSTLY AI)

**TABLA 2.** Diferencias entre aprendizaje automático y profundo

CARACTERÍSTICA	APRENDIZAJE AUTOMÁTICO (ML)	APRENDIZAJE PROFUNDO (DL)
Complejidad de los algoritmos	Algoritmos simples y más fáciles de interpretar.	Algoritmos complejos y menos interpretables.
Consumo de recursos	Bajo consumo energético y computacional.	Alto consumo de energía y recursos computacionales.
Arquitectura de la red	Redes neuronales simples (1-2 capas).	Redes neuronales profundas (3 o más capas, hasta miles).
Procesamiento	Puede ejecutarse eficientemente con una CPU.	Requiere GPU para un procesamiento ágil y eficiente.
Cantidad de datos necesarios	Se adapta a conjuntos de datos pequeños o medianos.	Necesita grandes volúmenes de datos para alcanzar buen rendimiento.

CPU: Unidad Central de Procesamiento; GPU: Unidad de Procesamiento gráfico.

### 1.5 INTELIGENCIA ARTIFICIAL MULTIMODAL

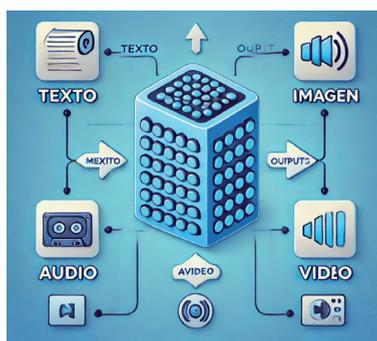
Es un tipo de inteligencia artificial generativa capaz de procesar y combinar diferentes tipos de datos, como texto, imágenes, audio y video, para generar respuestas más completas y sofisticadas. A diferencia de los modelos tradicionales, que se enfocan en un solo tipo de entrada (por ejemplo, solo texto o solo imágenes), los modelos multimodales integran múltiples fuentes de información para mejorar

su comprensión y generación de contenido (Figura 5).

Las ventajas de la IA multimodal son que puede interpretar imágenes y texto al mismo tiempo, y permite la comunicación con texto, voz e imágenes. La IA multimodal representa un gran avance en la inteligencia artificial, ya que permite una comprensión más parecida a la humana de la información.

En la Tabla 3 pueden verse algunos ejemplos de IA multimodal.

**FIGURA 5.** Modelo de IA Generativa multimodal



**TABLA 3.** Ejemplos de IA multimodal

NOMBRE	DESCRIPCIÓN	TIPOS DE DATOS QUE PROCESA
GPT-4Turbo (Multimodal)	Modelo avanzado de OpenAI que puede interpretar imágenes y texto en la misma conversación.	Texto + Imágenes
Gemini1.5 (Google DeepMind)	IA de Google que integra texto, imágenes, audio, código y video en un mismo modelo.	Texto + Imágenes + Audio + Video + Código
Claude3 (Anthropic)	Procesa texto y puede analizar imágenes para generar respuestas más completas.	Texto + Imágenes
DeepSeek-Vision	IA china multimodal que comprende imágenes y texto para análisis más detallados.	Texto + Imágenes
Runway Gen-2	Genera videos a partir de texto e imágenes con IA avanzada.	Texto + Imágenes + Video

(Continúa)

(Continuación)

NOMBRE	DESCRIPCIÓN	TIPOS DE DATOS QUE PROCESA
Meta ImageBind	Modelo de Meta que asocia y entiende múltiples tipos de datos sin necesidad de etiquetarlos previamente.	Texto + Imágenes + Audio + Sensores 3D + Movimiento
OpenAI Whisper	Reconoce y traduce audio a texto, facilitando la transcripción y comprensión de múltiples idiomas.	Audio + Texto
DALL-E 3	Generador de imágenes que convierte descripciones textuales en imágenes realistas.	Texto + Imágenes
MusicLM (Google)	Convierte descripciones en lenguaje natural en música original.	Texto + Audio

#### REFERENCIAS

- 1 De Francisco ALM. Artificial. La Nueva Inteligencia y su Aplicación en Nefrología. En Lorenzo V, López Gómez JM (Eds) Nefrología al Día ISBN 978-84-127624-1-9
- 2 Krisanapan P, Tangpanithandee S, Thongprayoon C, Pattharanitima P, Cheungpasitporn W. Revolutionizing Chronic Kidney Disease Management with Machine Learning and Artificial Intelligence. J Clin Med. 2023, 21;12(8):3018.

## 2.

# IA EN LA INTERPRETACIÓN DE IMÁGENES EN NEFROLOGÍA

---

La inteligencia artificial (IA) está transformando el análisis de imágenes médicas, y la Nefrología no es una excepción. Gracias a técnicas avanzadas como el aprendizaje profundo, hoy es posible automatizar la detección de alteraciones renales en estudios como ecografías, tomografías y biopsias digitalizadas. Estas herramientas no solo aumentan la precisión diagnóstica, sino que también reducen el tiempo de interpretación y facilitan la identificación de patrones sutiles que pueden pasar desapercibidos al ojo humano. La IA representa, así, un aliado prometedor para los nefrólogos, con el potencial de mejorar el seguimiento clínico, optimizar recursos y ofrecer una medicina más personalizada [1]. A continuación, revisamos la aportación de la IA en imágenes en Nefrología.

### 2.1 ANÁLISIS DE IMÁGENES MÉDICAS

En el análisis de imágenes médicas, el uso de la IA se divide ampliamente en dos categorías: Radiómica y Aprendizaje Profundo (Deep Learning)

#### 2.1.1 Radiómica

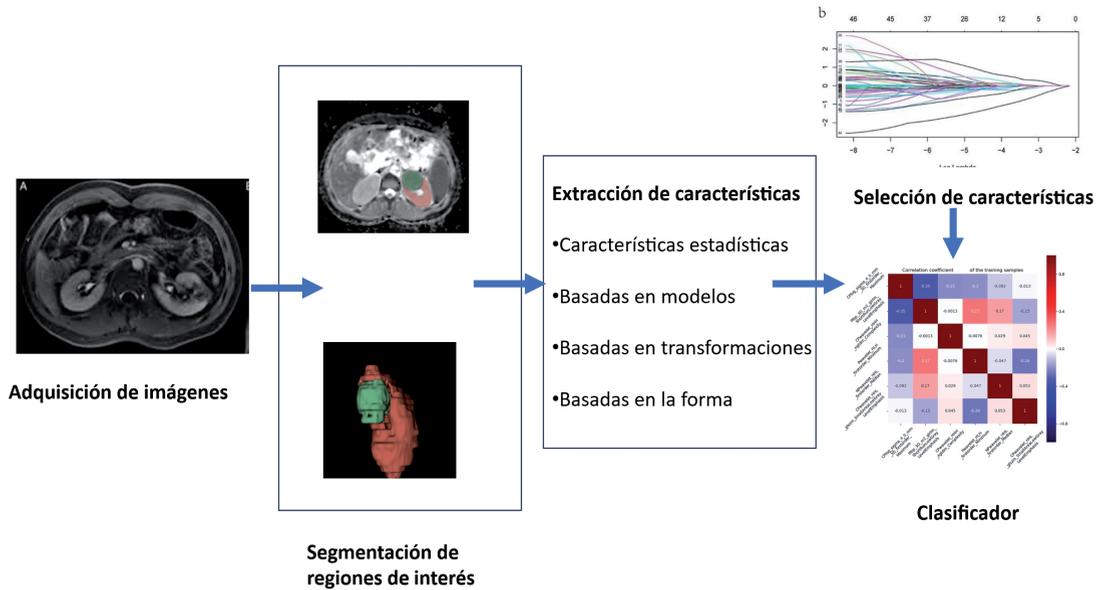
La radiómica permite analizar características invisibles al ojo humano en una imagen médica, como la textura, la forma o los patrones de los tejidos. Estas características

pueden ayudar a los médicos a detectar enfermedades más temprano, predecir su evolución y personalizar los tratamientos. La radiómica se refiere a la aplicación de métodos matemáticos para extraer características cuantitativas de imágenes médicas. Se pueden diseñar algoritmos de aprendizaje para identificar patrones en la heterogeneidad y la distribución espacial de píxeles dentro de regiones predefinidas de imágenes seleccionadas por el usuario, que han demostrado reflejar diferentes estados de enfermedad. De una forma más sencilla pudiéramos decir que la radiómica es una tecnología que usa inteligencia artificial y análisis de datos avanzados para extraer información detallada de imágenes médicas, como tomografías computarizadas (TC), resonancias magnéticas (RM) y ecografías.

Por ejemplo, en Nefrología, la radiómica podría ayudar a evaluar la estructura del riñón y detectar signos tempranos de enfermedad renal crónica o cáncer renal sin necesidad de una biopsia. Al combinar estas imágenes con algoritmos de inteligencia artificial, se pueden hacer diagnósticos más precisos y tomar mejores decisiones clínicas [2] (Figura 6).

El flujo del trabajo radiómico tiene los siguientes pasos (Tabla 4): comienza con la adquisición de imágenes médicas (TC, RM,

**FIGURA 6.** Flujo de trabajo radiómico [2]



**TABLA 4.** Flujo de trabajo radiómico

ETAPA	DESCRIPCIÓN
1. Adquisición de imágenes	Obtención de imágenes médicas (TC, RM, ecografía) con protocolos estandarizados para garantizar calidad y comparabilidad.
2. Preprocesamiento y segmentación	Mejora de la imagen (reducción de ruido, normalización) y segmentación de la región de interés mediante métodos manuales o IA.
3. Extracción de características	Extracción de datos cuantificables de la imagen (forma, textura, intensidad) que revelan información clínica no visible al ojo humano.
4. Análisis de datos y modelado predictivo	Uso de Machine Learning y Deep Learning para analizar patrones en los datos y crear modelos predictivos sobre diagnóstico y evolución de enfermedades.
5. Interpretación y aplicación clínica	Integración de los resultados en la toma de decisiones médicas, combinando información radiómica con datos clínicos del paciente.
6. Validación y retroalimentación	Validación del modelo con datos adicionales, ajuste y mejora continua para asegurar su precisión y utilidad clínica.

ecografía), asegurando una calidad y estandarización adecuadas. Luego, en la fase de preprocesamiento y segmentación, se mejora la imagen y se identifica la región de interés. A continuación, se realiza la extracción de características radiómicas, analizando aspectos como la forma, textura e intensidad de los tejidos. Estos datos se procesan mediante modelos de inteligencia artificial, que buscan patrones y generan predicciones sobre diagnóstico, evolución de la enfermedad y respuesta al tratamiento. Finalmente, los resultados se integran en la práctica clínica, combinándolos con información del paciente para mejorar la toma de decisiones. Este proceso es continuo, con validación y mejora de los modelos mediante nuevos datos y estudios.

### 2.1.2 Aprendizaje Profundo (DL)

Dentro del aprendizaje profundo DL, las redes neuronales convolucionales (CNN) son especialmente útiles para analizar imágenes médicas, ya que pueden extraer automáticamente características sin necesidad de intervención humana. Funcionan imitando la forma en que vemos, identificando primero formas simples como líneas o bordes, y luego combinándolas para reconocer objetos más complejos, sin necesidad de que un humano le diga qué buscar. La red aprende sola a partir de muchos ejemplos, haciéndola muy precisa para reconocer patrones visuales. Esto las hace más eficientes que los métodos tradicionales de radiómica, donde las características de la imagen se extraen manualmente y luego se analizan con modelos estadísticos o de aprendizaje automático.

Una diferencia clave entre la radiómica tradicional y el aprendizaje profundo es que este último trabaja de forma más automatizada, usando la imagen completa como entrada y generando resultados directamente

a través de la red neuronal. Sin embargo, las CNN son en su mayoría modelos de «caja negra», lo que significa que es difícil interpretar exactamente cómo toman sus decisiones.

Un desafío en el uso del DL en Nefrología es la falta de grandes volúmenes de datos de imágenes renales. Para solucionar este problema, se usa el aprendizaje por transferencia (TL), una técnica que permite entrenar un modelo con un gran conjunto de datos en una tarea similar y luego adaptarlo a la detección de enfermedades renales con menos imágenes.

El aprendizaje profundo ha modernizado la radiómica, haciendo que la segmentación de imágenes y la extracción de características sean más automáticas. Estudios recientes han demostrado que combinar TL con técnicas tradicionales mejora la precisión en el análisis de imágenes renales, como la clasificación de ecografías [3].

## 2.2 EVALUACIÓN NO INVASIVA DE LA FUNCIÓN RENAL Y DETECCIÓN PRECOZ DE LA ERC CON IMÁGENES MÉDICAS

La detección regular de la función renal en pacientes en riesgo de enfermedad renal crónica se recomienda en las guías [4]. En la actualidad, la creatinina sérica y la albuminuria son los biomarcadores más comúnmente aceptados para la detección de la ERC, pero ninguno proporciona una evaluación precisa de la integridad estructural renal. El análisis de imágenes médicas basado en IA puede utilizar la TFGe o la creatinina sérica como referencias de verdad fundamental para el desarrollo de modelos para la evaluación no invasiva de la función renal.

### 2.2.1 Ecografía

Kuo y cols. [5] desarrollaron un modelo de inteligencia artificial (IA) basado en aprendizaje profundo que predice automáticamente la tasa de filtración glomerular estimada (TFGe)

y el estado de la ERC. Se utilizó la técnica de aprendizaje por transferencia, integrando la red neuronal ResNet, previamente entrenada en un conjunto de datos de imágenes médicas (ImageNet). El modelo fue entrenado con 4505 ecografías renales etiquetadas con valores de TFGe obtenidos de concentraciones de creatinina sérica. Los resultados mostraron una alta correlación (0,741) entre las estimaciones de TFGe obtenidas por IA y los valores reales de creatinina, así como una precisión del 85,6 % en la clasificación del estado de ERC. Este modelo abre la posibilidad de usar ecografías como herramienta de detección remota y en tiempo real para evaluar la función renal de manera no invasiva.

#### 2.2.2 Resonancia magnética (RM)

La resonancia magnética es una herramienta clave para evaluar la función renal y la enfermedad renal crónica (ERC) debido a su alta resolución y ausencia de radiación. La resonancia magnética avanzada, combinada con IA y radiómica, está revolucionando la evaluación de la ERC, permitiendo diagnósticos más precisos y la predicción de su progresión. Investigaciones recientes han demostrado que las características radiómicas extraídas de imágenes T2WI pueden correlacionarse con la creatinina sérica y la tasa de filtración glomerular estimada (TFGe), mejorando la predicción de la progresión de la ERC [6].

Además, la resonancia magnética funcional (fMRI) es una técnica de neuroimagen que mide la actividad cerebral detectando cambios en el flujo sanguíneo y se usa para estudiar funciones cerebrales y mapear áreas activas durante tareas cognitivas. La fMRI ofrece un análisis más detallado de los cambios fisiopatológicos en los riñones, al medir variaciones en el flujo sanguíneo y la oxigenación tisular. Esto ayuda a detectar disfunciones renales en etapas tempranas, evaluar la perfusión y analizar

respuestas a tratamientos sin necesidad de contrastes agresivos. Estudios han demostrado que los parámetros cuantitativos de fMRI están significativamente relacionados con marcadores de función renal como la albuminuria y la TFGe. El uso de inteligencia artificial (IA) en el análisis de imágenes de fMRI ha mejorado la capacidad para identificar la ERC con alta sensibilidad y especificidad [7].

#### 2.2.3 Tomografía Computarizada (TC)

La evaluación de la función renal mediante tomografía computarizada (TC) asistida por inteligencia artificial (IA) ha sido poco estudiada. Sin embargo, debido a la exposición a la radiación ionizante, su aplicación se limita a casos específicos en lugar de monitorización continua de la función renal. Se han desarrollado y probado modelos de aprendizaje profundo en diversas áreas de la nefropatología, por ejemplo, la predicción de la progresión de la enfermedad renal o el diagnóstico de enfermedades basadas en imágenes y datos clínicos. La fibrosis tisular es una alteración clave en la progresión de la ERC hacia la insuficiencia renal terminal. Aunque inicialmente la IA se ha aplicado en el diagnóstico de fibrosis hepática, estudios recientes han desarrollado modelos de redes neuronales convolucionales (CNN) que analizan imágenes de tomografía computarizada (CT) para distinguir distintos grados de fibrosis renal con una precisión superior al 85 % [8]. Estos avances abren nuevas posibilidades para el diagnóstico no invasivo de la fibrosis renal mediante IA.

#### 2.2.4 Imágenes de retina

Por otro lado, la evaluación renal basada en imágenes de retina ha cobrado interés debido a las similitudes en los cambios microvasculares que ocurren tanto en la retina como en los riñones, especialmente en pacientes con diabetes tipo 2. Estudios han demostrado que

ciertos patrones en las imágenes de retina están fuertemente asociados con la disfunción renal. Mayor calibre de las vénulas en las zonas central y media, así como un menor calibre de las arteriolas en la zona central, se asociaron con enfermedad renal. Además, un aumento en la tortuosidad de las arteriolas se asoció con ERC y varias medidas de textura de imagen también mostraron una asociación significativa con la ERC. Otros modelos de redes neuronales convolucionales (CNN) han logrado una alta precisión en la detección de ERC, con valores de áreas bajo la curva (AUC) entre 0,911 y 0,733 en diferentes cohortes. Esta estrategia sugiere que la integración del cribado de la ERC en exámenes de retina puede mejorar la detección temprana y la rentabilidad del diagnóstico en poblaciones de alto riesgo [9].

### 2.3 APLICACIÓN DE REDES NEURONALES EN EL ANÁLISIS DE BIOPSIAS RENALES.

Las redes neuronales han revolucionado el análisis de biopsias renales, permitiendo una evaluación más rápida y precisa de enfermedades como la nefropatía diabética o la glomerulonefritis. Estos modelos de aprendizaje profundo pueden detectar patrones microscópicos en imágenes histológicas, identificando anomalías con una precisión comparable a la de los patólogos expertos. Gracias a la segmentación de tejidos y la clasificación automática, es posible cuantificar el daño renal, evaluar la fibrosis y predecir la progresión de la enfermedad [10].

Veremos más adelante (capítulo 4. IA en el diagnóstico de la biopsia renal) cómo la segmentación de imágenes es clave para el diagnóstico asistido por IA. La segmentación de imágenes es el proceso mediante el cual un algoritmo identifica y delimita estructuras específicas dentro de una imagen histológica digital, como los glomérulos, túbulos, intersticio o vasos.

Muchos estudios ya han hecho importantes contribuciones, en particular a la automatización de la cuantificación de algunas lesiones histopatológicas en el trasplante renal. Es probable que esto pueda ampliarse para cuantificar automáticamente todas las lesiones relevantes para un trasplante de riñón, como las lesiones de Banff. Existen importantes limitaciones y retos en la recopilación de conjuntos de datos representativos y las actualizaciones de la clasificación de Banff, lo que dificulta la realización de estudios a gran escala. Los resultados del estudio, que ya son positivos, hacen que parezca probable un futuro apoyo de la IA en la patología del trasplante renal [11].

A pesar de su prometedor potencial, siguen existiendo retos que dificultan una adopción más amplia, por ejemplo, la falta de pruebas prospectivas y de pruebas en escenarios del mundo real. El potencial del aprendizaje profundo en nefropatología está solo en sus inicios y podemos esperar mucho más por venir.

### 2.4 MODELOS DE IA PARA EL DIAGNÓSTICO DE TUMORES RENALES

Los tumores renales incluyen el carcinoma de células renales (CCR), los oncocitomas y los angiomiolipomas. La tomografía computarizada (TC) y la resonancia magnética (RM) son los principales métodos diagnósticos, pero la interpretación subjetiva de las imágenes puede generar errores.

El aprendizaje automático (ML) y el aprendizaje profundo (DL), en particular las redes neuronales convolucionales (CNN) en el reconocimiento de imágenes médicas, permiten diagnosticar y tratar tumores con precisión. Estas tecnologías analizan patrones complejos de imágenes médicas, mejorando la precisión y la eficiencia. Los sistemas de IA, al aprender de vastos conjuntos de datos, revelan características ocultas, ofreciendo diagnósticos fiables y planes de tratamiento personalizados.

La detección precoz es crucial para tumores como el carcinoma de células renales el cáncer de vejiga y el cáncer de próstata. La IA, junto con el análisis de datos, mejora la detección precoz y reduce las tasas de diagnósticos erróneos, mejorando la precisión del tratamiento. La aplicación de la IA en tumores urológicos es un foco de investigación, que promete un papel vital en la Cirugía Urológica con mejores resultados para los pacientes [12].

### 2.5 MODELOS DE IA PARA LA EVOLUCIÓN EN LA POLIQUISTOSIS RENAL AUTOSÓMICA DOMINANTE (ADPKD) DEL VOLUMEN QUISTICO TOTAL (VKT)

El volumen total del riñón es un biomarcador de imagen importante para evaluar la gravedad y progresión de la enfermedad renal poliquística autosómica dominante (ADPKD). Sin embargo, el cálculo del VKT es un desafío debido a la alta variabilidad causada por el crecimiento anómalo de los riñones poliquísticos. A pesar de su alta precisión, el cálculo tradicional del VKT depende del seguimiento manual de los límites del riñón, lo que resulta en un proceso laborioso y susceptible a variabilidad inter e intraoperador. Los estudios longitudinales del Consorcio para Estudios de Imágenes Radiológicas identificaron que antes de la disminución de la función renal, el VKT aumenta y predice una tasa de filtración glomerular estimada <60 ml/min por 1,73 m<sup>2</sup>. PKD [13]. Debido a que ahora existe un tratamiento eficaz para retardar la progresión de la enfermedad, Tolvaptán, la identificación oportuna de los pacientes en riesgo de progresión rápida a insuficiencia renal es vital para optimizar y personalizar la atención al paciente. Al aprender de las imágenes de entrada, las redes de DL pueden discriminar con precisión entre el parénquima renal y los quistes patológicos, sin necesidad de seguimiento manual,

produciendo estimaciones comparables a las de la segmentación renal automatizada para el cálculo del VKT.

Estudios recientes han aplicado algoritmos de DL a modalidades de imagen como ultrasonido (US), tomografía computarizada (CT) y resonancia magnética (MRI) para calcular el VKT en pacientes con ADPKD, logrando niveles de precisión similares a los métodos manuales [14,15]. Sobre la base de una segmentación precisa del parénquima renal y los quistes, se pueden realizar análisis adicionales de intensidad de señal o textura de los quistes para identificar estructuras complejas, lo que contribuye a la clasificación de la enfermedad [16].

### REFERENCIAS

- 1 Huo Y, Deng R, Liu Q, Fogo AB, Yang H. AI applications in renal pathology. *Kidney Int.* 2021;99(6):1309-1320.
- 2 Cellina M, Irmici G, Pepa GD, Ce M, Chiarpelleno V, Ali M, Papa S, Carrafiello G. Radiomics and Artificial Intelligence in Renal Lesion Assessment. *Crit Rev Oncog.* 2024;29(2):65-75.
- 3 Zheng Q, Warner S, Tasian G, Fan Y. A Dynamic Graph Cuts Method with Integrated Multiple Feature Maps for Segmenting Kidneys in 2D Ultrasound Images. *Acad Radiol.* 2018;25(9):1136-1145.
- 4 KDIGO 2024 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.* 2024;105(4S):S117-S314.
- 5 Kuo CC, Chang CM, Liu KT, Lin WK, Chiang HY, Chung CW, Ho MR, Sun PR, Yang RL, Chen KT. Automation of the kidney function prediction and classification through ultrasound-based kidney imaging using Deep Learning . *NPJ Digit Med.* 2019; 26:2:29.

- 6 Kline TL, Korfiatis P, Edwards ME, Bae KT, Yu A, Chapman AB, Mrug M, Grantham JJ, Landsittel D, Bennett WM, King BF, Harris PC, Torres VE, Erickson BJ; CRISP Investigators. Image texture features predict renal function decline in patients with autosomal dominant polycystic kidney disease. *Kidney Int.* 2017;92(5):1206-1216.
- 7 Li LP, Leidner AS, Wilt E, Mikheev A, Rusinek H, Sprague SM, Kohn OF, Srivastava A, Prasad PV. Radiomics-Based Image Phenotyping of Kidney Apparent Diffusion Coefficient Maps: Preliminary Feasibility & Efficacy. *J Clin Med.* 2022;11(7):1972.
- 8 Chantaduly C, Troutt HR, Perez Reyes KA, Zuckerman JE, Chang PD, Lau WL. Artificial Intelligence Assessment of Renal Scarring (AIRS Study). *Kidney360.* 2021;3(1):83-90.
- 9 Park HW, Kim HR, Nam KY, Kim BJ, Kang T. Predicting renal function using fundus photography: role of confounders. *Korean J Intern Med.* 2025 Mar;40(2):310-320.
- 10 Pilva P, Bülow R, Boor P. Deep Learning applications for kidney histology analysis. *Curr Opin Nephrol Hypertens.* 2024;33(3):291-297.
- 11 Bülow RD, Lan YC, Amann K, Boor P. Künstliche Intelligenz in der Nierentransplantationspathologie [Artificial intelligence in kidney transplant pathology]. *Pathologie (Heidelb).* 2024;45(4):277-283.
- 12 Zhu M, Gu Z, Chen F, Chen X, Wang Y, Zhao G. Application of artificial intelligence in the diagnosis and treatment of urinary tumors. *Front Oncol.* 2024;14:1440626.
- 13 Bae, K (2022). Consortium for Radiologic Imaging Studies of Polycystic Kidney Disease (CRISP) (Version 9) [Dataset] NIDDK Central Repository. <https://doi.org/10.58020/956q-m463>
- 14 Van Gastel MDA, Edwards ME, Torres VE, et al. Automatic measurement of kidney and liver volumes from MR images of patients affected by autosomal dominant polycystic kidney disease. *J Am Soc Nephrol* 2019;30(8):1514–22.
- 15 Kim Y, Tao C, Kim H, Oh GY, Ko J, Bae KT. A Deep Learning Approach for Automated Segmentation of Kidneys and Exophytic Cysts in Individuals with Autosomal Dominant Polycystic Kidney Disease. *J Am Soc Nephrol.* 2022;33(8):1581-1589.
- 16 Taylor J, Thomas R, Metherall P, van Gastel M, Cornec-Le Gall E, Caroli A, Furlano M, Demoulin N, Devuyst O, Winterbottom J, Torra R, Perico N, Le Meur Y, Schoenherr S, Forer L, Gansevoort RT, Simms RJ, Ong ACM. An Artificial Intelligence Generated Automated Algorithm to Measure Total Kidney Volume in ADPKD. *Kidney Int Rep.* 2023;9(2):249-256.



## 3.

### IA EN LA DETECCIÓN Y MANEJO DE LA INSUFICIENCIA RENAL AGUDA (LRA- AKI)

La lesión renal aguda (LRA) representa un desafío significativo en la medicina, especialmente en pacientes críticamente enfermos, debido a su alta incidencia y su asociación con una mayor morbilidad y mortalidad. En este contexto, la inteligencia artificial (IA) ofrece oportunidades prometedoras para mejorar el diagnóstico, la predicción y la gestión de esta condición.

#### 3.1 PREDICCIÓN TEMPRANA DE LRA

Una de las aplicaciones más interesantes de la IA en la LRA es la predicción temprana. Los modelos de IA permiten identificar pacientes con alto riesgo de desarrollar LRA antes de que se manifieste clínicamente. Estos modelos, basados en aprendizaje automático (ML) y aprendizaje profundo (DL), pueden analizar grandes volúmenes de datos para calcular la probabilidad de LRA con horas o incluso días de anticipación.

Para entrenar modelos de IA destinados a la predicción o clasificación de LRA, se utilizan grandes conjuntos de datos que incluyen diversos desarrollos de la enfermedad. Los pacientes se categorizan según criterios predefinidos en «LRA ocurrió» y «LRA no ocurrió».

Como ya definimos anteriormente cada uno de los algoritmos de IA tiene una sensibilidad y especificidad propias y cuanto mayor

sea el valor de AUROC, mejor podrá el modelo distinguir entre «LRA» y «sin LRA». Ya hemos visto que valores inferiores a 0,7 se consideran poco significativos, mientras que valores superiores a 0,9 se califican como excelentes. Hasta ahora, para la predicción de LRA se han utilizado diferentes algoritmos de IA con diversos mecanismos de funcionamiento y resultados (Tabla 5) [1].

**TABLA 5.** Métodos para predecir la lesión renal aguda (AKI) en la literatura (según KDIGO, durante la hospitalización) [1]

MÉTODO	AUROC
Regresión logística	0,686–0,930
Naive Bayes	0,687–0,819
Máquina de vectores de soporte	0,720–0,900
Árboles de decisión	0,637–0,781
Modelo aditivo generalizado	0,858
Random forest	0,709–0,911
Adaptive boost M1	0,751
Gradient boosting	0,741–0,900
Vecino más cercano	0,664–0,920
Red neuronal artificial	0,720–0,921

### 3.1.1 Factores a evaluar al buscar una predicción de LRA

Al interpretar los resultados de los estudios con IA sobre predicción de LRA, es crucial considerar las condiciones específicas en las que se realizaron los estudios:

- Bases de datos utilizadas con modelos diferentes que ofrecen resultados diversos. En un metaanálisis de 24 estudios con un total de 82 modelos de ML diferentes se encontraron diferencias. Los modelos de aprendizaje automático (ML) mostraron un rendimiento comparable al de la regresión logística (LR); sin embargo, presentaron una variabilidad significativa, con algunos modelos de ML. Esta variabilidad en la predicción de la lesión renal aguda (AKI) mediante ML puede atribuirse, en parte, al tipo específico de modelo utilizado, a la selección y procesamiento de variables, a las características del estudio y de los pacientes, así como a las etapas de entrenamiento, validación, prueba y calibración del modelo [2].
- Parámetros incluidos en los análisis: frecuentemente, solo se tienen en cuenta los marcadores estándar (creatinina, volumen de orina, factores de riesgo), que presentan limitaciones conocidas.
- La definición de LRA: también parece tener un gran impacto en los resultados y es un factor relevante en la heterogeneidad de los mismos. Dependiendo de si se utilizaron los criterios de Kidney Disease Improving Global Outcomes (KDIGO) [3] o los criterios de Acute Kidney Injury Network (AKIN) [4] se observaron diferencias en sensibilidad y especificidad. En general, se ha observado que los resultados de predicción de LRA basados en los criterios KDIGO tienen mayor precisión

en comparación con los basados en los criterios AKIN.

- Período de pronóstico, es decir, cuánto tiempo en el futuro se intenta realizar la predicción. Algunos modelos logran una predicción muy precisa para el estadio II de KDIGO dentro de 24 horas (AUROC: 0,900), pero la capacidad predictiva disminuye a medida que aumenta el intervalo de tiempo [5].

### 3.1.2 importancia de nuevos marcadores en la predicción de LRA

La mayoría de los estudios utilizaron creatinina (en sangre u orina) como marcador principal para la predicción. La incorporación de nuevos biomarcadores podría mejorar significativamente las predicciones. Por ejemplo, un modelo K-nearest-neighbour que incluyó NGAL logró un AUROC de 0,92 [6]. Aunque biomarcadores como Cistatina C, «kidney injury molecule» (KIM) 1, NGAL, y «tissue inhibitor of metalloproteinase» (TIMP) 2/, «insulin-like growth factor binding protein» (IGFBP) 7 han sido estudiados para la detección temprana de LRA, aún faltan conjuntos de datos suficientemente grandes que incluyan estos parámetros para entrenar modelos de ML [7,8,9].

### 3.2 ALERTAS ELECTRÓNICAS («E-ALERTS»)

Los sistemas basados en IA pueden generar alertas tempranas para advertir a los clínicos sobre un riesgo inminente de LRA. Aunque estas alertas tienen el potencial de mejorar la respuesta clínica, su efectividad sigue siendo un tema de debate debido a problemas como las falsas alarmas y la «fatiga por alertas».

Como dato esperanzador un sistema de alertas basado en IA utilizó no solo creatinina sérica, sino también volumen urinario y

parámetros clínicos adicionales (como urea, leucocitos y plaquetas). Este modelo de aprendizaje profundo (DL) predijo el 88 % de los casos de LRA en pacientes de cuidados intensivos con más de 12 horas de anticipación. De seis pacientes clasificados con alto riesgo, cinco desarrollaron episodios de LRA, mientras que solo el 18 % de los pacientes sin riesgo predicho presentó LRA [10]. Esto sugiere que los modelos de IA podrían generar alertas más precisas que los algoritmos simples. Sin embargo, los efectos clínicos de estos sistemas, que podrían integrarse en sistemas electrónicos de gestión de pacientes para predecir LRA con hasta 24 horas de antelación, aún no se han evaluado sistemáticamente.

### 3.3 CLASIFICACIÓN EN FENOTIPOS

La lesión renal aguda (LRA) es un síndrome clínico heterogéneo que presenta múltiples etiologías, una patogenia variable y resultados diversos. Sin embargo, estas heterogeneidades no se reflejan en los enfoques actuales del diagnóstico y, hasta cierto punto, del tratamiento de la LRA. A menudo se sigue considerando que la LRA es una entidad clínica homogénea, lo que implica una patogenia uniforme y un pronóstico bien definido. En consecuencia, los esfuerzos por encontrar tratamientos eficaces para la LRA se han visto obstaculizados por la falta de clasificaciones clínicas claras para los distintos tipos de LRA. Además, la subclasificación de la LRA en fenotipos subclínicos (por ejemplo, sobre la base de biomarcadores proteicos y otros diagnósticos *in vitro* que tengan en cuenta la etiología de la enfermedad y la patogenia subyacente) podría ser necesaria para desarrollar enfoques terapéuticos que aborden eficazmente los muy diversos fisiopatológicos de la LRA [11].

Los avances en DL han permitido dividir la LRA en estos diferentes fenotipos según las características del daño renal, el riesgo de complicaciones o la necesidad de terapia de reemplazo renal. Esta clasificación tiene el potencial de avanzar hacia una medicina más personalizada. Mediante aprendizaje profundo, ya es posible clasificar distintos fenotipos de LRA e identificar, entre pacientes críticamente enfermos [12] y postoperatorios [13], aquellos con mayor riesgo de mortalidad. Además, en pacientes sépticos, se pudieron clasificar grupos con riesgo bajo, moderado y alto de necesitar diálisis [14]. Sin embargo, son pocos los estudios que han analizado el impacto de la fenotipificación en el tratamiento.

En la Tabla 6 pueden observarse fenotipos subclínicos en la lesión renal aguda [15]. Esta clasificación ofrece una visión más precisa del daño renal y su pronóstico.

Podemos concluir en relación con la IA en la LRA que el creciente volumen de datos, impulsado por los registros electrónicos de pacientes y su integración en grandes bases de datos, permite entrenar modelos de aprendizaje automático (ML) para el estudio y evaluación temprana de la LRA de manera más rápida y con información actualizada. Sin embargo, la dependencia exclusiva de la creatinina y el volumen de orina, indicadores insuficientes para reflejar con precisión la función renal, sigue siendo una limitación. Así que para que la IA tenga un impacto significativo en la práctica clínica, será esencial:

- Implementar biomarcadores innovadores en los modelos de IA.
- Superar problemas como las falsas alarmas y la dependencia de datos antiguos.
- Diseñar modelos que combinen precisión técnica con relevancia clínica y facilidad de uso.

**TABLA 6.** Fenotipos subclínicos en la Lesión Renal Aguda (AKI)

FENOTIPO	DESCRIPCIÓN	BIOMARCADORES ASOCIADOS	IMPLICACIONES CLÍNICAS
<b>Fenotipo subclínico AKI</b>	Elevación de biomarcadores sin aumento de creatinina ni oliguria	NGAL, TIMP-2, IGFBP7, KIM-1, IL-18	Indica daño renal estructural sin disfunción aparente. Riesgo elevado de AKI clínico.
<b>Fenotipo funcional (hemodinámico)</b>	Disminución de la función renal sin biomarcadores de daño	Aumento de creatinina, sin biomarcadores elevados	Puede reflejar hipoperfusión reversible o prerrenal. Pronóstico generalmente más favorable.
<b>Fenotipo mixto</b>	Elevación de creatinina y biomarcadores	Creatinina + NGAL, TIMP-2, etc.	Mayor riesgo de progresión a AKI grave y mayor mortalidad.
<b>Fenotipo resistente</b>	Exposición a factores de riesgo sin desarrollar AKI ni daño detectable	Biomarcadores normales	Puede indicar resiliencia renal. Potencial valor predictivo para terapias protectoras.
<b>Fenotipo recuperado</b>	Daño previo evidenciado por biomarcadores, pero función renal ya recuperada	Disminución progresiva de biomarcadores	Importante en seguimiento post-AKI. Riesgo de enfermedad renal crónica (ERC) persistente.

**REFERENCIAS**

- 1 Perschinka F, Peer A, Joannidis M. Künstliche Intelligenz und akute Nierenschädigung [Artificial intelligence and acute kidney injury]. *Med Klin Intensivmed Notfmed.* 2024;119(3):199-207.
- 2 Song X, Liu X, Liu F, Wang C. Comparison of Machine Learning and logistic regression models in predicting acute kidney injury: a systematic review and meta-analysis. *Int J Med Inform.* 2021; 151:104484.
- 3 KDIGO AKI Work Group: KDIGO clinical practice guideline for acute kidney injury. *Kidney Int Suppl.* 2012, 2: 1-138.
- 4 Mehta RL, Kellum JA, Shah SV, Molitoris BA, Ronco C, Warnock DG, et al. Acute kidney injury network: report of an initiative to improve outcomes in acute kidney injury. *Crit Care.* 2007;11(2):R31.
- 5 Tomašev N, Glorot X, Rae JW, Zielinski M, Askham H, Saraiva A, et al. A clinically applicable approach to continuous prediction of future acute kidney injury. *Nature.* 2019;572(7767):116–119.
- 6 Tran NK, Sen S, Palmieri TL, Lima K, Falwell S, Wajda J, et al. Artificial intelligence and Machine Learning for predicting acute kidney injury in severely burned patients: a proof of concept. *Burns.* 2019;45(6):1350–1358.
- 7 Flechet M, Güiza F, Schetz M, Wouters P, Vanhorebeek I, Derese I, et al. AKIpredictor, an online prognostic calculator for acute kidney injury in adult critically ill patients: development, validation and comparison to serum neutrophil gelatinase-associated lipocalin. *Intensive Care Med.* 2017;43(6):764–773.
- 8 Wang JJ, Chi NH, Huang TM, Connolly R, Chen LW, Chueh SJ, et al. Urinary biomarkers predict advanced acute kidney injury after cardiovascular surgery. *Crit Care.* 2018;22(1):108.

- 9 Villa P, Jiménez M, Soriano MC, Manzanares J, Casasnovas P. Serum cystatin C concentration as a marker of acute renal dysfunction in critically ill patients. *Crit Care*. 2005;9(2): R139–43.
- 10 Alfieri F, Ancona A, Tripepi G, Rubeis A, Arjoldi N, Finazzi S, Cauda V, Fagugli RM. Continuous and early prediction of future moderate and severe Acute Kidney Injury in critically ill patients: Development and multi-centric, multi-national external validation of a machine-learning model. *PLoS One*. 2023;18(7).
- 11 Kellum JA, Prowle JR. Paradigms of acute kidney injury in the intensive care setting. *Nat Rev Nephrol*. 2018;14(4):217-230.
- 12 Smith TD, Soriano VO, Neyra JA, Chen J. Identifying KDIGO trajectory phenotypes associated with increased inpatient mortality. *IEEE Int Conf Healthc Inform*. 2019. <https://doi.org/10.1109/ichi.2019.8904739>
- 13 Andrew BY, Pieper CE, Cherry AD, Pendergast JF, Privratsky JR, Mathew JP, et al. Identification of trajectory-based acute kidney injury phenotypes among cardiac surgery patients. *Ann Thorac Surg*. 2022;114(6):2235–2243.
- 14 Chaudhary K, Vaid A, Duffy Á, Paranjpe I, Jaladanki S, Paranjpe M, et al. Utilization of Deep Learning for subphenotype identification in sepsis-associated acute kidney injury. *Clin J Am Soc Nephrol*. 2020;15(11):1557–1565.
- 15 Ostermann M, Legrand M, Meersch M, Srisawat N, Zarbock A, Kellum JA. Biomarkers in acute kidney injury. *Ann Intensive Care*. 2024;15;14(1):145



## 4.

### IA EN EL DIAGNÓSTICO DE LA BIOPSIA RENAL

---

La mayor parte del tiempo (80 %) de los patólogos se pasa observando campos normales donde no hay nada que ver. Se toman grandes cantidades de muestras de tejido de la mama, el colon y el cuello uterino como consecuencia de los programas de detección poblacional, y durante la Cirugía se resecan un gran número de ganglios linfáticos por paciente, lo que da lugar a que los patólogos revisen un gran número de preparaciones en su mayoría negativas. Es decir hay un inmenso trabajo que en general se carga en un personal laboral insuficiente considerando que la evaluación patológica implica tanto el diagnóstico del tejido como la evaluación pronóstica, basada en la arquitectura del tejido y la morfología de las células. En estas situaciones, los algoritmos de IA pueden marcar regiones o áreas sospechosas para su inspección y en el futuro, evaluar casos de manera autónoma.

Inicialmente, los avances tecnológicos estaban limitados a la garantía de calidad y a ciertas aplicaciones de investigación. Por lo tanto, el desarrollo de herramientas de IA capaces de diagnosticar enfermedades con precisión representa un gran avance. La inteligencia artificial se puede aplicar para detectar y contar células, por ejemplo, en eventos mitóticos que pueden ser relevantes en células cancerosas. También puede utilizarse para la

segmentación y clasificación de tejidos como sanos o enfermos.

Los nefropatólogos examinan las biopsias renales mediante microscopía óptica (ML), inmunofluorescencia (IF) y microscopía electrónica (ME) para realizar diagnósticos, a menudo descriptivos, de diversas enfermedades glomerulares. La digitalización de imágenes de portaobjetos completos (WSI) ha permitido la aplicación de herramientas informáticas, desde el análisis clásico de imágenes hasta los métodos más recientes de aprendizaje profundo (DL), para facilitar la asistencia informática al diagnóstico por biopsia.

#### 4.1 FASES DEL DESARROLLO DE IA PARA EL ANÁLISIS DE BIOPSIAS RENALES

En la Tabla 7 se muestran los pasos que se suelen seguir en el desarrollo de tecnologías de inteligencia artificial (IA) aplicadas al análisis de biopsias renales, tanto en la fase de entrenamiento como en la de despliegue. El desarrollo de IA para el análisis de biopsias renales comienza con la recopilación de imágenes y datos clínicos, seguido de su preprocesamiento y anotación por expertos. Luego, los datos se dividen en conjuntos de entrenamiento, validación y prueba para entrenar un modelo basado en redes neuronales, cuya precisión se evalúa y ajusta. En la fase de despliegue, el

**TABLA 7.** Fases del desarrollo de IA para el análisis de biopsias renales

FASE	PASO	DESCRIPCIÓN
Entrenamiento	Adquisición de datos	Recopilación de imágenes de biopsias renales y datos clínicos asociados.
	Preprocesamiento de imágenes	Normalización, segmentación y mejora de calidad de las imágenes.
	Anotación de expertos	Patólogos identifican y marcan estructuras y patologías en las imágenes.
	División de datos	Separación en conjuntos de entrenamiento, validación y prueba.
	Entrenamiento del modelo	Uso de algoritmos de IA (redes neuronales, aprendizaje profundo) para entrenar el modelo.
	Validación y evaluación	Medición de métricas de rendimiento y ajuste de hiperparámetros.
Despliegue	Integración en el entorno clínico	Implementación del modelo en hospitales y centros de diagnóstico.
	Interfaz de usuario	Desarrollo de una plataforma intuitiva para la visualización de resultados.
	Monitoreo y retroalimentación	Supervisión del rendimiento del modelo con datos reales y mejora continua.
	Mantenimiento y actualización	Reentrenamiento periódico del modelo con nuevos datos y control de calidad.

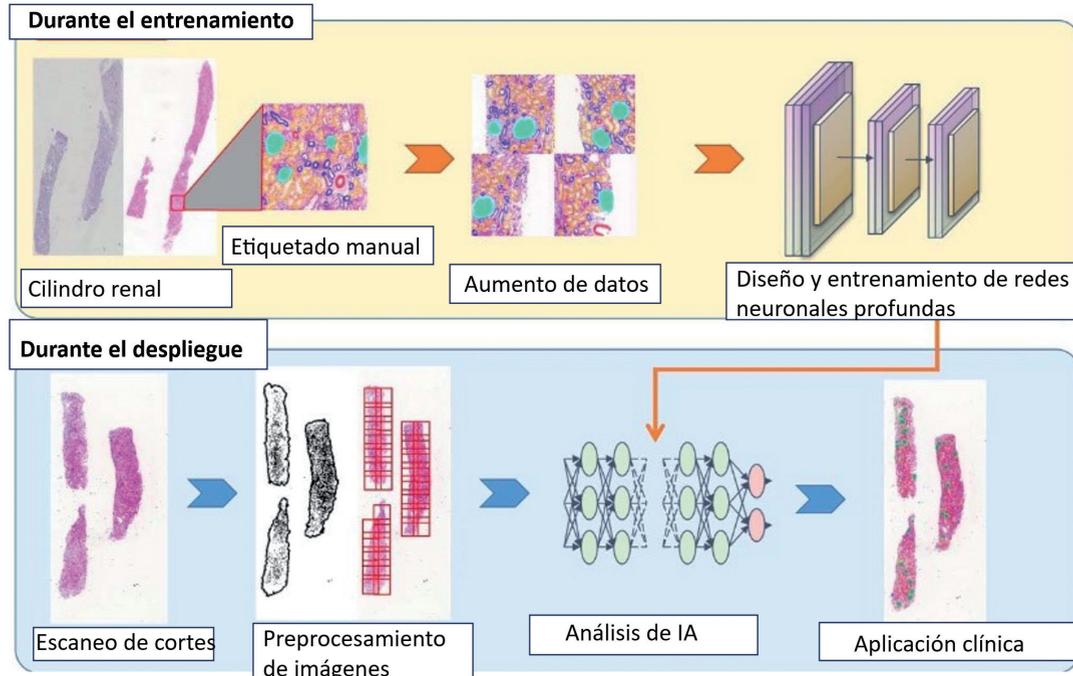
modelo se integra en hospitales mediante una interfaz intuitiva, permitiendo su monitorización continua y actualización con nuevos datos para mejorar su rendimiento y fiabilidad.

La Figura 7 muestra la segmentación de imágenes patológicas basada en aprendizaje profundo (DL) durante el entrenamiento y durante el despliegue en el trabajo práctico. Ahí vemos la preparación de datos, preprocesamiento de imágenes (normalización y aumento de imágenes), selección y construcción del modelo (selección del software y fase de entrenamiento del modelo), postprocesamiento, extracción de características y aplicación clínica [1].

La segmentación de imágenes es clave para el diagnóstico asistido por IA en biopsias renales por varias razones:

- a) Precisión diagnóstica: la segmentación permite al algoritmo enfocar su análisis en las estructuras relevantes, evitando el «ruido» del resto de la imagen. Por ejemplo, puede detectar con precisión glomérulos esclerosados, inflamación intersticial o fibrosis tubular.
- b) Cuantificación objetiva: automatiza la medición de parámetros clínicamente relevantes (porcentaje de fibrosis, número de glomérulos, áreas de necrosis, etc.),

**FIGURA 7.** Segmentación de imágenes patológicas basada en aprendizaje profundo (DL) durante el entrenamiento y durante el despliegue en el trabajo práctico [1]



Modificada de Feng C., Biomol Biomed. 2023

- reduciendo la variabilidad interobservador entre patólogos.
- c) Entrenamiento eficiente del modelo: la segmentación mejora el aprendizaje del modelo, ya que le proporciona regiones bien definidas donde se encuentran las lesiones clave, lo que reduce errores y mejora el rendimiento predictivo.
  - d) Interpretabilidad y validación: los modelos basados en segmentación pueden generar mapas de calor o visualizaciones que permiten a los médicos validar visualmente qué zonas del tejido están contribuyendo al diagnóstico automatizado.
  - e) Aplicabilidad clínica: facilita el desarrollo de sistemas de ayuda al diagnóstico que pueden integrarse en la rutina clínica, ayudando al patólogo a revisar grandes volúmenes de biopsias con mayor rapidez y consistencia.

#### 4.2 ESTUDIOS DE ANÁLISIS DE IMÁGENES EN PATOLOGÍA RENAL MEDIANTE IA

En la patología de biopsias renales, se utilizan múltiples métodos de tinción, lo que requiere una evaluación compleja. El análisis morfológico depende de la calidad de los cortes, la experiencia del patólogo y el uso de indicadores cuantitativos para evaluar el daño

tisular. La implementación de herramientas de análisis de imágenes automatizadas puede facilitar la evaluación cuantitativa de las biopsias renales, mejorando la identificación de estructuras histológicas y la predicción del pronóstico de enfermedades renales. Las herramientas de segmentación basadas en DL permiten extraer características visuales y subvisuales (como forma y textura), optimizando el diagnóstico y la toma de decisiones clínicas. Las características gráficas y morfológicas extraídas mediante herramientas de segmentación de aprendizaje profundo (DL) están directamente relacionadas con el diagnóstico y los resultados clínicos.

En los últimos años, se han acumulado numerosos estudios que aplican DL en el diagnóstico de Nefropatología. Inicialmente, estos estudios se centraron en el glomérulo, comenzando con modelos para distinguir entre glomérulos esclerosados y no esclerosados. Estos métodos automatizados han demostrado reducir la variabilidad en la evaluación, mejorar la eficiencia del análisis y disminuir la carga de trabajo de los patólogos. En la Tabla 8 puede verse un resumen de algunos estudios sobre Nefropatología.

Estos estudios han demostrado que la segmentación automatizada basada en aprendizaje profundo (DL) no solo puede mejorar la precisión del diagnóstico, sino también facilitar la cuantificación objetiva de estructuras renales en biopsias. Permiten un diagnóstico más integral de la patología renal, combinando imágenes de inmunofluorescencia y microscopía óptica en el análisis automatizado con IA. Estas investigaciones han sentado las bases para un diagnóstico patológico automatizado, reduciendo la carga de trabajo de los patólogos y la variabilidad en la evaluación entre diferentes especialistas, mejorando la eficiencia del diagnóstico, reduciendo la variabilidad interobservador y facilitando el análisis de grandes volúmenes de datos.

**TABLA 8.** Resumen de estudios sobre IA en Nefropatología

AUTOR	ESTUDIO BASADO EN DL
Barros et al. [2]	Clasificación de lesiones glomerulares proliferativas.
Chagas et al. [3]	Refinamiento de la clasificación de la hiper celularidad glomerular (mesangial, endocapilar y combinada).
Sheehan et al. [4,5]	Segmentación glomerular, cuantificación de proliferación mesangial, núcleos y penacho glomerular.
Hermesen et al. [6]	Segmentación multicategoría de glomérulos, túbulos e intersticio con validación usando la clasificación Banff.
Jayapandian et al. [7]	Segmentación tisular de la corteza renal en diferentes tinciones; PAS mostró mayor consistencia DL-patólogos.
Ginley et al. [8]	Detección automatizada de fibrosis intersticial, atrofia tubular y glomeruloesclerosis.
Uchino et al. [9]	Clasificación de siete manifestaciones glomerulares (esclerosis global y segmentaria, proliferaciones, etc.).
Zeng et al. [10]	Localización y clasificación de lesiones glomerulares; puntuación automatizada de hiper celularidad mesangial en IgAN.
Bouteldja et al. [11]	Segmentación multicategoría en modelos experimentales animales de patología renal.
Marechal [12]	Segmentación automática de componentes histológicos pronósticos como volumen glomerular, fibrosis, atrofia, etc.
Yi [13]	Detección y cuantificación de infiltrado intersticial, tubular y leucocitario en biopsias de trasplante.
Weis et al. [14]	Reconocimiento automatizado de cambios morfológicos glomerulares comunes (ej.: amiloidosis, esclerosis, etc.).
Theilig et al. [15]	Clasificación de túbulos renales normales vs anormales para un entendimiento integral de la estructura renal.

#### 4.3 APLICACIONES DE IA EN LA PATOLOGÍA DEL TRASPLANTE RENAL

La patología del trasplante renal abarca la evaluación del riñón del donante antes del trasplante y el seguimiento del receptor después del trasplante. La biopsia preimplante es crucial para determinar la viabilidad del órgano en situaciones urgentes, evaluando el daño glomerular a partir del porcentaje de glomérulos esclerosados, lo que ayuda en la decisión de asignación o descarte del órgano [16]. El uso de plataformas web e inteligencia artificial (IA) ha sentado las bases para la creación de nuevos algoritmos diagnósticos en trasplantes, con el objetivo de mejorar la precisión en la evaluación del órgano y optimizar su valor predictivo en el pronóstico postrasplante [17].

En la evaluación postrasplante, es fundamental la detección de rechazo y las alteraciones funcionales del injerto, siguiendo los criterios de Banff, que requieren formación especializada. La mayoría de los estudios que han aplicado algoritmos automatizados a biopsias renales se han centrado en la cuantificación de elementos inflamatorios y fibrosis intersticial, indicadores clave en la evaluación del rechazo renal [18,19].

La implementación de IA en este campo puede mejorar la precisión diagnóstica, reducir la variabilidad inter observador y optimizar la gestión clínica de los trasplantes renales.

#### 4.4 MODELOS PREDICTIVOS DE LA IA EN PATOLOGÍA RENAL

Los modelos predictivos impulsados por inteligencia artificial (IA) no solo realizan tareas básicas como la detección y segmentación de imágenes, sino que también tienen la capacidad de predecir el riesgo y evaluar la respuesta al tratamiento. Más allá de clasificar imágenes, la IA puede identificar fenotipos agresivos con base en similitudes moleculares, lo que permite combinar avances en biología

molecular e imagenología para mejorar la comprensión de la patología renal y descubrir nuevas oportunidades terapéuticas.

Mariani y cols. evidenciaron que el análisis de fibrosis intersticial en imágenes WSI de biopsias renales tiene valor pronóstico en glomerulopatías proteinúricas, ya que su grado de afectación se relaciona con una disminución de la tasa de filtración glomerular estimada y con la activación de genes inflamatorios y fibróticos, lo que puede ayudar a predecir la evolución de la enfermedad [20]. Por otro lado, Chen y cols. desarrollaron y validaron el Sistema de Estratificación de Riesgo de IgAN de Nanjing, aplicando un enfoque basado en *gradient tree boosting* (múltiples árboles de decisión). A partir de 36 variables candidatas, identificaron las 10 más relevantes y construyeron un modelo de puntuación mediante análisis de regresión de Cox. Este sistema, que integra aprendizaje automático y análisis de supervivencia, permite una estratificación precisa del riesgo de progresión en pacientes con nefropatía por IgA (IgAN), facilitando un tratamiento más personalizado [21].

Los algoritmos de IA proporcionan una evaluación clínica precisa, objetiva y eficiente, lo que los convierte en herramientas valiosas para ensayos clínicos. Si un modelo puede prever con mayor precisión la expectativa de vida de un paciente en comparación con los sistemas tradicionales de estratificación de riesgo, su implementación podría generalizarse. A medida que la IA sigue evolucionando, los modelos predictivos para el pronóstico continúan perfeccionándose, impulsando avances en la medicina personalizada y mejorando la toma de decisiones en la práctica clínica.

#### 4.5 COMBINACIÓN IA: DATOS HISTOLÓGICOS Y DATOS CLÍNICOS

La inteligencia artificial (IA) en patología renal no solo se centra en el análisis visual de

imágenes histopatológicas, sino que también puede integrar datos clínicos, como información demográfica, historial médico y resultados de laboratorio. La incorporación del procesamiento de lenguaje natural (NLP) permite extraer hallazgos relevantes de registros médicos, facilitando la toma de decisiones clínicas. Además, la IA puede descubrir conexiones complejas y sutiles entre imágenes y datos clínicos, proporcionando un análisis de alta dimensionalidad más allá de la capacidad humana [22].

El desarrollo de métodos computacionales, como la combinación de patología con datos ómicos (genómica, epigenómica, proteómica y metabolómica), puede mejorar la detección de enfermedades con características moleculares específicas. La IA tiene el potencial de identificar señales subvisuales, permitiendo diagnósticos más precisos y clínicamente relevantes. Un ejemplo sería un paciente que tiene función renal aparentemente normal en los exámenes de rutina, pero un sistema de IA, al analizar sus datos genéticos y bioquímicos, detecta un patrón asociado con daño renal temprano.

#### 4.6 DIFICULTADES PARA LA APLICACIÓN DE LA IA EN LA PATOLOGÍA RENAL

Entre ellas se encuentra la limitación de datos, ya que la mayoría de los estudios utilizan conjuntos reducidos y de una sola institución, lo que puede generar sobreajuste en los algoritmos. Otro reto es la falta de interpretabilidad de los modelos de IA, lo que dificulta evaluar si las decisiones generadas son razonables. Este problema de «caja negra» es especialmente relevante en medicina, donde se requiere transparencia en el diagnóstico. Además, la implementación de IA en la patología renal debe adaptarse a las regulaciones éticas y de seguridad, garantizando la privacidad de los datos y su protección. Actualmente, no existe un consenso internacional sobre el uso de

IA en medicina, lo que requiere un marco regulador claro.

A pesar de estos desafíos, la IA en patología renal sigue en expansión, con una creciente capacidad para reconocer patrones y combinar información de manera que los humanos no pueden. Su integración en la medicina de precisión tiene un gran potencial para mejorar el diagnóstico, la clasificación de enfermedades y la personalización de tratamientos, impulsando así el futuro de la Nefropatología.

#### REFERENCIAS

- 1 Feng C, Liu F. Artificial intelligence in renal pathology: Current status and future. *Biomol Biomed.* 2023;23(2):225-234.
- 2 38. Barros GO, Navarro B, Duarte A, dos-Santos WLC. PathoSpotter-K: a computational tool for the automatic identification of glomerular lesions in histological images of kidneys. *Sci Rep* 2017;7(1):46769.
- 3 Chagas P, Souza L, Araújo I, Aldeman N, Duarte A, Angelo M, Dos-Santos WLC, Oliveira L. Classification of glomerular hypercellularity using convolutional features and support vector machine. *Artif Intell Med.* 2020; 103:101808.
- 4 Sheehan SM, Korstanje R. Automatic glomerular identification and quantification of histological phenotypes using image analysis and Machine Learning. *Am J Physiol Renal Physiol* 2018;315(6): F1644–51.
- 5 Sheehan S, Mawe S, Cianciolo RE, Korstanje R, Mahoney JM. Detection and classification of novel renal histologic phenotypes using deep neural networks. *Am J Pathol* 2019;189(9): 1786–96.
- 6 Hermsen M, de Bel T, den Boer M, Steenbergen EJ, Kers J, Florquin S, Roelofs JJTH, Stegall MD, Alexander MP, Smith BH, Smeets B, Hilbrands LB, van der Laak JAWM. Deep Learning -Based Histopathologic Assessment of Kidney Tissue. *J Am Soc Nephrol.* 2019;30(10):1968-1979.

- 7 Jayapandian CP, Chen Y, Janowczyk AR, Palmer MB, Cassol CA, Sekulic M, et al. Development and evaluation of Deep Learning -based segmentation of histologic structures in the kidney cortex with multiple histologic stains. *Kidney Int* 2021;99(1):86–101.
- 8 Ginley B, Jen K-Y, Han SS, Rodrigues L, Jain S, Fogo AB, et al. Automated computational detection of interstitial fibrosis, tubular atrophy, and glomerulosclerosis. *J Am Soc Nephrol* 2021;32(4):837–50.
- 9 Uchino E, Suzuki K, Sato N, Kojima R, Tamada Y, Hiragi S, et al. Classification of glomerular pathological findings using Deep Learning and nephrologist–AI collective intelligence approach. *Int J Med Inform.* 2020;141:104231.
- 10 Zeng C, Nan Y, Xu F, Lei Q, Li F, Chen T, et al. Identification of glomerular lesions and intrinsic glomerular cell types in kidney diseases via Deep Learning . *J Pathol* 2020;252(1):53–64.
- 11 Bouteldja N, Klinkhammer BM, Bülow RD, Droste P, Otten SW, Freifrau von Stillfried S, et al. Deep Learning -based segmentation and quantification in experimental kidney histopathology. *J Am Soc Nephrol* 2021;32(1):52–68.
- 12 Marechal E, Jaugey A, Tarris G, Paindavoine M, Seibel J, Martin L, et al. Automatic evaluation of histological prognostic factors using two consecutive convolutional neural networks on kidney samples. *Clin J Am Soc Nephrol* 2022;17(2):260–70.
- 13 Yi Z, Salem F, Menon MC, Keung K, Xi C, Hultin S, et al. Deep Learning identified pathological abnormalities predictive of graft loss in kidney transplant biopsies. *Kidney Int* 2022;101(2):288–98.
- 14 Weis C-A, Bindzus JN, Voigt J, Runz M, Hertjens S, Gaida MM, et al. Assessment of glomerular morphological patterns by Deep Learning algorithms. *J Nephrol* 2022;35(2):417–27.
- 15 Theilig F, Hara S, Haneda E, Kawakami M, Morita K, Nishioka R, et al. Evaluating tubulointerstitial compartments in renal biopsy specimens using a Deep Learning -based approach for classifying normal and abnormal tubules. *PLoS One* 2022;17(7):e0271161
- 16 Girolami I, Pantanowitz L, Marletta S, Hermsen M, van derLaak J, Munari E, et al. Artificial intelligence applications for pre-implantation kidney biopsy pathology practice: a systematic review. *J Nephrol* 2022;35(7):1801–08.
- 17 Neri F, Eccher A, Rigotti P, Girolami I, Zaza G, Gambaro G, et al. Advantages of using a web-based digital platform for kidney preimplantation biopsies. *J Pathol Inform* 2021;12(1):41.
- 18 Girolami I, Marletta S, Eccher A. Commentary: the digital fate of glomeruli in renal biopsy. *J Pathol Inform* 2021;12(1):14.
- 19 Nankivell BJ, Shingde M, Keung KL, Fung CLS, Borrows RJ, O’Connell PJ, et al. The causes, significance and consequences of inflammatory fibrosis in kidney transplantation: the Banff i-IFTA lesion. *Am J Transplant* 2018;18(2):364–76.
- 20 Mariani LH, Martini S, Barisoni L, Canetta PA, Troost JP, Hodgins JB, et al. Interstitial fibrosis scored on whole-slide digital imaging of kidney biopsies is a predictor of outcome in proteinuric glomerulopathies. *Nephrol Dial Transplant* 2018;33(2):310–18.
- 21 Chen T, Li X, Li Y, Xia E, Qin Y, Liang S, et al. Prediction and risk stratification of kidney outcomes in IgA nephropathy. *Am J Kidney Dis* 2019;74(3):300–09.
- 22 Xie G, Chen T, Li Y, Chen T, Li X, Liu Z. Artificial intelligence in nephrology: how can artificial intelligence augment nephrologists’ intelligence? *Kidney Dis* 2020;6(1):1–6.



## 5.

### IA EN LA ENFERMEDAD RENAL CRÓNICA (ERC)

---

La enfermedad renal crónica (ERC) es una patología progresiva que afecta a millones de personas en todo el mundo (10-15 %) y se asocia con un aumento significativo en el riesgo de insuficiencia renal avanzada, eventos cardiovasculares y mortalidad. Tradicionalmente, la ERC se evalúa mediante la tasa de filtración glomerular estimada (TFGe) y la presencia de albuminuria [1] pero estos indicadores no siempre reflejan la complejidad de la progresión de la enfermedad ni permiten identificar con precisión a los pacientes con mayor riesgo. Dada la multitud de factores de riesgo y pruebas diagnósticas involucradas, diagnosticar con precisión, predecir el pronóstico y manejar de manera óptima la ERC puede ser un desafío para los médicos. En respuesta a este complejo problema, se ha introducido la inteligencia artificial (IA) como una posible solución en la predicción y el manejo de la ERC, proporcionando modelos avanzados que permiten un análisis más preciso y personalizado.

#### 5.1 CATEGORÍAS DE APRENDIZAJE AUTOMÁTICO EN EL MANEJO DE LA ENFERMEDAD RENAL CRÓNICA

Como ya conocemos las dos categorías principales de aprendizaje automático son el aprendizaje supervisado y no supervisado [2].

El aprendizaje supervisado utiliza datos etiquetados para entrenar modelos de aprendizaje automático para reconocer patrones y hacer predicciones. Los ejemplos de aprendizaje supervisado en el contexto de la ERC incluyen el diagnóstico de ERC únicamente a partir de la ecografía renal o la obtención de imágenes del fondo de ojo, la predicción de la progresión renal, la mortalidad y el nivel de hemoglobina en pacientes de hemodiálisis que reciben agentes estimulantes de la eritropoyetina (AEE), así como la identificación del tratamiento óptimo para los pacientes.

Por otra parte, el aprendizaje no supervisado utiliza datos no etiquetados para identificar patrones o grupos sin conocimiento previo del resultado. Algunos ejemplos de aprendizaje no supervisado en la enfermedad renal crónica incluyen la agrupación de pacientes en función de características clínicas y demográficas similares o el descubrimiento de biomarcadores o subtipos desconocidos de la enfermedad [3].

#### 5.2 IA EN LA PREDICCIÓN DE LA PROGRESIÓN Y COMPLICACIONES DE LA ENFERMEDAD RENAL CRÓNICA

Desde 2015, se han aprobado al menos cuatro fármacos de dos clases (inhibidores del cotransportador de sodio-glucosa 2 y antagonistas del receptor de mineralocorticoides)

para retardar la progresión de la ERC y reducir los eventos cardiovasculares en pacientes en casi todas las etapas de la ERC [1]. Aunque estos fármacos, cuando se añaden a los inhibidores de renina-angiotensina-aldosterona, tienen beneficios clínicamente significativos en los eventos adversos renales y cardiovasculares importantes, el beneficio clínico y la rentabilidad probablemente sean mayores en pacientes con riesgo alto o intermedio de progresión de la enfermedad renal. En estos pacientes, es probable que el número necesario a tratar para prevenir resultados adversos sea bajo. Cuando se utilizan al principio del curso de la enfermedad, estas terapias pueden ayudar potencialmente a los pacientes a evitar la diálisis de por vida en lugar de simplemente retrasarla entre 1 y 2 años [4] como podemos ver en la Figura 8.

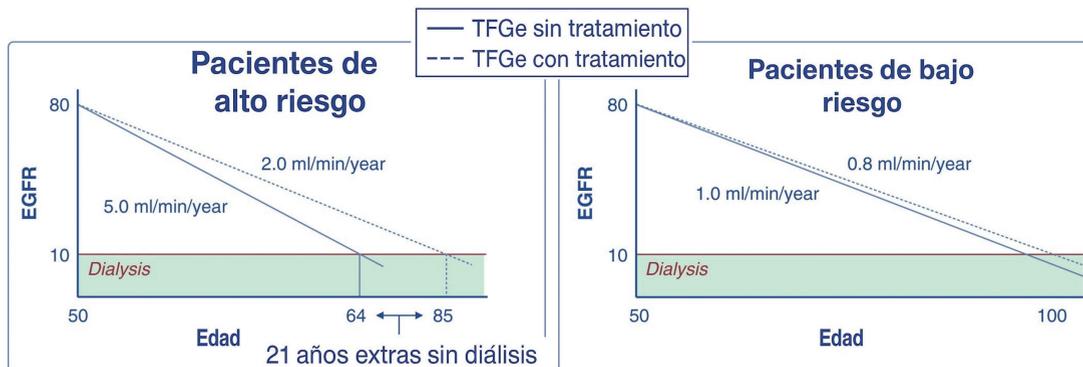
Uno de los mayores desafíos en la ERC es la dificultad para predecir qué pacientes progresarán a estadios más avanzados o desarrollarán complicaciones graves. Mientras que los modelos tradicionales de predicción, como la ecuación de riesgo de insuficiencia renal (KFRE) [5] o la regresión de Cox, han

sido útiles, tienen limitaciones en la identificación de patrones complejos dentro de grandes volúmenes de datos clínicos.

Los modelos de Machine Learning (ML) y Deep Learning (DL) han mostrado resultados prometedores al analizar múltiples variables de manera simultánea, permitiendo una mayor precisión en la predicción de la progresión de la CKD. Por ejemplo, un modelo basado en redes bayesianas y máquinas de soporte vectorial (SVM es un algoritmo de inteligencia artificial que encuentra la mejor frontera para separar datos en diferentes categorías) logró identificar factores de riesgo en pacientes mediante datos obtenidos en chequeos médicos, permitiendo visualizar la probabilidad de progresión de CKD en un mapa de calor [6]. Además, se ha desarrollado un sistema de IA para predecir el riesgo de mortalidad en pacientes en diálisis, logrando una precisión AUROC de 0,948, superior a la obtenida con modelos tradicionales [7,8].

Nuevas organizaciones están utilizando inteligencia artificial para mejorar el manejo de la enfermedad renal crónica. Un ejemplo es pulseData, que en 2021 obtuvo una patente

**FIGURA 8.** Retraso de la progresión que proporcionan los nuevos tratamientos en pacientes con ERC [4]



para sistemas de aprendizaje automático que calculan puntuaciones de riesgo basadas en diversos datos clínicos y demográficos. Sus algoritmos utilizan biomarcadores como eTFG, creatinina sérica y endostatina, entre otros muchos, para evaluar el riesgo renal. Los modelos han mostrado alta precisión, con AUC >0,90 para predecir insuficiencia renal a un año. Para la ERC incidente, la precisión fue de 0,84 a un año, 0,81 a dos y 0,79 a cinco años [9]. Otro de los proyectos IA en ERC es Renalytix AI desarrolló KidneyIntelX, un modelo de aprendizaje automático para ayudar en el tratamiento de la enfermedad renal diabética mediante datos de registros médicos electrónicos y biomarcadores. Utiliza el receptor TNF 1 y 2 (TNFR1/2) y la molécula plasma kidney injury molecule-1 (KIM-1) con una precisión predictiva moderada (AUCC de 0,77). Requiere más de 100 características clínicas y ha mostrado limitaciones, como la falta de validación externa y problemas de calibración. Su análisis económico puede ser optimista, al sugerir que retrasaría 5000 inicios de diálisis en una cohorte de 100.000 pacientes. Se necesita más validación antes de su implementación clínica [10,11].

En lo que respecta a las complicaciones cardiovasculares de la ERC CALIBRA (Cardiovascular, Literature-Based, Risk Algorithm), es un modelo basado en *naïve bayes* que predice el riesgo anual de hospitalizaciones cardiovasculares en pacientes con ERC. CALIBRA utiliza 31 variables, combinando factores de riesgo tradicionales y específicos de la ERC. Se validó en dos cohortes independientes: EuCliD (FMC NephroCare) y el estudio prospectivo GCKD (German Chronic Kidney Disease). Su rendimiento se evaluó mediante estadísticos C (AUC) y gráficos de calibración, comparándolo con tres modelos existentes: Framingham, ASCVD y INDANA, CALIBRA mostró buena capacidad discriminativa en

EuCliD® (AUC 0,79) y GCKD (AUC 0,73), superando significativamente a los modelos tradicionales en ambas cohortes [12].

La solución ideal sería un modelo validado externamente, aplicable a todas las etapas de la ERC, basado en valores de laboratorio rutinarios accesibles desde cualquier sistema convencional. Esto evitaría la dependencia de ensayos específicos y costosos, facilitando su escalabilidad. Además, la integración con los sistemas de registros médicos electrónicos permitiría comunicar información basada en el riesgo de manera eficiente. Es fundamental que los modelos permitan la actualización de la calibración según los avances en tratamientos y mantengan una validación externa en diversas poblaciones [4].

### 5.3 IA APLICADA AL DIAGNÓSTICO POR IMÁGENES Y ANÁLISIS DE BIOPSIAS EN LA ERC

Ya hemos comentado como el diagnóstico por imágenes ha sido otro campo donde la IA ha demostrado ser altamente efectiva. Algoritmos de redes neuronales convolucionales (CNN) han sido entrenados para analizar ecografías renales y biopsias, logrando una segmentación precisa de los tejidos renales y permitiendo la detección temprana de alteraciones estructurales. Conocemos el estudio realizado por Kuo y cols. [13], donde se utilizó un modelo de aprendizaje profundo para la clasificación y estimación de la función renal a partir de ecografía y los resultados indicaron una precisión del 85,6 %, con una especificidad del 92,1 % y una sensibilidad del 60,7 %, superando las evaluaciones de cuatro nefrólogos experimentados (60,3 %-80,1 %) lo que representa un avance significativo en la evaluación no invasiva de la función renal.

Por otro lado, recordemos que la IA ha sido utilizada para evaluar biopsias renales, logrando una clasificación más rápida y precisa

de las lesiones, lo que facilita la identificación de patrones asociados a enfermedades renales y en el trasplante renal [14]. Esto no solo optimiza el diagnóstico, sino que también ayuda a estandarizar la interpretación de las biopsias, reduciendo la variabilidad entre patólogos.

#### 5.4 IA EN EL TRATAMIENTO Y MANEJO DE LA ERC

La inteligencia artificial (IA) ha emergido como una herramienta prometedora para mejorar el manejo de la ERC, apoyando la toma de decisiones médicas mediante el análisis avanzado de datos clínicos. Dejando aparte aquello relacionado con su aplicación en diálisis estudiaremos: la optimización de tratamientos farmacológicos personalizados, y los asistentes virtuales y chatbots para educación y seguimiento de pacientes.

##### 5.4.1 Optimización de tratamientos farmacológicos personalizados

El tratamiento de la ERC suele requerir regímenes farmacológicos complejos (antihipertensivos, hipoglucemiantes, diuréticos, agentes nefroprotectores, etc.), y la respuesta a estas terapias varía entre individuos. La IA, en particular el aprendizaje automático, ofrece la posibilidad de personalizar los tratamientos farmacológicos analizando grandes volúmenes de datos clínicos de pacientes para encontrar patrones de respuesta. Por ejemplo, se ha propuesto usar aprendizaje automático para identificar qué pacientes con ERC se benefician más de intervenciones específicas como inhibidores SGLT2, bloqueadores del sistema renina-angiotensina, agonistas GLP-1 o antagonistas de receptor mineralocorticoide, optimizando así la selección terapéutica para maximizar el beneficio. Los algoritmos de Machine Learning pueden analizar múltiples características del paciente, como biomarcadores, datos demográficos y comorbilidades,

para correlacionarlas con resultados clínicos y permitir tratamientos más personalizados [15]. Un estudio reciente mostró que la inteligencia artificial, combinada con un modelo biomatemático, mejoró las decisiones terapéuticas en el trastorno mineral óseo en la enfermedad renal crónica. En simulaciones, la IA superó a expertos humanos ajustando dinámicamente las dosis de medicamentos para mantener los parámetros bioquímicos en rangos óptimos [16]. Además, modelos supervisados han predicho con éxito la respuesta a tratamientos estándar, como los niveles de hemoglobina en pacientes en hemodiálisis tratados con eritropoyetina, lo que facilita un ajuste más preciso de las dosis [15]. Estas aplicaciones de IA permiten una medicina de precisión en Nefrología, adaptando las terapias farmacológicas al perfil del paciente y mejorando los resultados clínicos. Sin embargo, su implementación requiere validación clínica, integración con los flujos de trabajo médicos y consideraciones éticas en la automatización de decisiones.

##### 5.4.2 Chatbots para educación y seguimiento de pacientes con ERC

La inteligencia artificial está transformando la educación y el seguimiento de los pacientes con enfermedad renal crónica (ERC) mediante asistentes virtuales y chatbots. Estas herramientas, basadas en procesamiento de lenguaje natural y Machine Learning, pueden proporcionar información comprensible sobre la enfermedad, medicación, dieta y cuidados, respondiendo preguntas en tiempo real y en varios idiomas. Diferentes estudios han evaluado chatbots entrenados con guías clínicas como KDIGO y KDOQI, demostrando que modelos avanzados de lenguaje, como ChatGPT, ofrecen respuestas alineadas con las recomendaciones médicas [17].

Una ventaja clave de estos asistentes es su disponibilidad continua, lo que permite

reforzar la educación fuera de la consulta y mejorar el autocuidado. En un estudio con pacientes de ERC de mediana edad, el uso de chatbots durante tres meses incrementó el conocimiento sobre la enfermedad, la dieta y la medicación en comparación con la línea basal y combinaciones de chatbots con notificaciones automatizadas han demostrado ser viables y satisfactorias, promoviendo el involucramiento activo del paciente en su tratamiento [18].

Estos asistentes no solo educan, sino que también facilitan el seguimiento al registrar síntomas diarios, recordar medicaciones y alertar al equipo médico ante datos preocupantes. Un modelo como ChatGPT podría mejorar la comunicación entre pacientes y nefrólogos, aclarando dudas antes o después de la consulta y proporcionando información accesible y actualizada sobre ERC [15]. Aunque estas herramientas no reemplazan la evaluación médica, pueden complementar la atención tradicional al reducir la carga asistencial y fomentar la adherencia a las recomendaciones. Sin embargo, es crucial garantizar la fiabilidad de la información proporcionada por chatbots mediante validaciones basadas en guías clínicas y supervisión de especialistas, ya que se han identificado casos de respuestas erróneas o inconsistentes. Con la mejora continua de la IA y un adecuado control de calidad, los asistentes virtuales tienen el potencial de integrarse cada vez más en la Nefrología, optimizando la educación, la autogestión de la ERC y el monitoreo remoto de los pacientes.

Simeri y cols. ofrecen una revisión amplia sobre el uso de técnicas de Machine Learning y Deep Learning, aplicadas a datos clínicos, bioimágenes e incluso fotografías del fondo de ojo para predecir ERC y diabetes tipo 2. Exploran los modelos más relevantes, sus ventajas sobre los enfoques clásicos y su potencial en la medicina personalizada [19].

## REFERENCIAS

- 1 KDIGO 2024 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.* 2024;105(4S):S117-S314.
- 2 De Francisco ALM. Artificial. La Nueva Inteligencia y su Aplicación en Nefrología. En Lorenzo V, López Gómez JM (Eds) *Nefrología al Día* ISBN 978-84-127624-1-9.
- 3 Ferguson T, Ravani P, Sood MM, Clarke A, Komenda P, Rigatto C, Tangri N. Development and External Validation of a Machine Learning Model for Progression of CKD. *Kidney Int Rep.* 2022;7(8):1772-1781.
- 4 Tangri N, Ferguson TW. Artificial Intelligence in the Identification, Management, and Follow-Up of CKD. *Kidney360.* 2022;3(3):554-556.
- 5 The kidney failure risk equation <https://kidney-failurerisk.com/>
- 6 Kanda E, Kanno Y, Katsukawa F. Identifying progressive CKD from healthy population using Bayesian network and artificial intelligence: A worksite-based cohort study. *Sci Rep.* 2019;9(1):5082.
- 7 Kanda E, Epureanu BI, Adachi T, et al. Application of explainable ensemble artificial intelligence model to categorization of hemodialysis-patient and treatment using nationwide-real-world data in Japan. *PLOS ONE.* 2020;15(5): e0233491.
- 8 Kanda E. Development of Artificial Intelligence Systems for Chronic Kidney Disease. *JMA J.* 2025 Jan 15;8(1):48-56.
- 9 Cha T, Son HP, Kipers C, Fielding O, Son JH, Lee E. Machine Learning Systems and Methods for Predicting Risk of Renal Function Decline. United States Patent and Trademark Office. 2021.
- 10 Chan L, Nadkarni GN, Fleming F, McCullough JR, Connolly P, Mosoyan G, El Salem F, Kattan MW, Vassalotti JA, Murphy B, Donovan MJ, Coca SG, Damrauer SM: 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: 1504–1515.
- 11 Datar M, Burchenal W, Donovan MJ, Coca SG, Wang E, Goss TF: Payer budget impact of an artificial intelligence in vitro diagnostic to modify diabetic kidney disease progression. *J Med Econ* 24: 972–982, 2021.
  - 12 Neri L, Lonati C, Titapiccolo JI, Nadal J, Meiselbach H, Schmid M, Baerthlein B, Tschulena U, Schneider MP, Schultheiss UT, Barbieri C, Moore C, Steppan S, Eckardt KU, Stuard S, Bellocchio F. The Cardiovascular Literature-Based Risk Algorithm (CALIBRA): Predicting Cardiovascular Events in Patients with Non-Dialysis Dependent Chronic Kidney Disease. *Front Nephrol.* 2022 Jul 12;2: 922251.
  - 13 Kuo CC, Chang CM, Liu KT, Lin WK, Chiang HY, Chung CW, Ho MR, Sun PR, Yang RL, Chen KT. Automation of the kidney function prediction and classification through ultrasound-based kidney imaging using Deep Learning . *NPJ Digit Med.* 2019; 26;2:29.
  - 14 Farris AB, Vizcarra J, Amgad M, Cooper LAD, Gutman D, Hogan J. Artificial intelligence and algorithmic computational pathology: an introduction with renal allograft examples. *Histopathology.* 2021;78(6):791-804.
  - 15 Krisanapan P, Tangpanithandee S, Thongprayoon C, Pattharanitima P, Cheungpasitporn W. Revolutionizing Chronic Kidney Disease. Management with Machine Learning and Artificial Intelligence. *J Clin Med.* 2023, 21;12(8):3018.
  - 16 Gaweda AE, Lederer ED, Brier ME. Artificial intelligence-guided precision treatment of chronic kidney disease-mineral bone disorder. *CPT Pharmacometrics Syst Pharmacol.* 2022;(10):1305-1315.
  - 17 Acharya PC, Alba R, Krisanapan P, Acharya CM, Suppadungsuk S, Csongradi E, Mao MA, Craici IM, Miao J, Thongprayoon C, Cheungpasitporn W. AI-Driven Patient Education in Chronic Kidney Disease: Evaluating Chatbot Responses against Clinical Guidelines. *Diseases.* 2024;12(8):185.
  - 18 Chen NJ, Huang CM, Fan CC, Lu LT, Lin FH, Liao JY, Guo JL. User Evaluation of a Chat-Based Instant Messaging Support Health Education Program for Patients with Chronic Kidney Disease: Preliminary Findings of a Formative Study. *JMIR Form Res.* 2023 Sep 19;7:e45484.
  - 19 Simeri A, Pezzi G, Arena R, Papalia G, Szili-Torok T, Greco R, Veltri P, Greco G, Pezzi V, Provenzano M, Zaza G. Artificial intelligence in chronic kidney diseases: methodology and potential applications. *Int Urol Nephrol.* 2025;57(1):159-168.

## 6.

### INTELIGENCIA ARTIFICIAL EN DIÁLISIS

---

La ERC en etapa terminal requiere tratamientos de sustitución renal como la hemodiálisis (HD) o la diálisis peritoneal (DP). Ambas modalidades tienen ventajas y desventajas, pero también están asociadas a complicaciones frecuentes que afectan la calidad de vida y el pronóstico de los pacientes. La IA ha emergido como una herramienta prometedora en el ámbito de la diálisis, con el potencial de optimizar el tratamiento, mejorar la monitorización de los pacientes y prevenir eventos adversos.

El desarrollo de algoritmos de Machine Learning (ML) y Deep Learning (DL) ha permitido analizar grandes volúmenes de datos clínicos, provenientes tanto de los registros de los pacientes como de las máquinas de diálisis. Esto ha llevado a la creación de modelos predictivos capaces de identificar patrones ocultos que escapan al análisis convencional, lo que facilita la toma de decisiones clínicas más informadas y personalizadas [1].

#### 6.1 APLICACIONES DE LA IA EN HEMODIÁLISIS

La prestación de hemodiálisis es un proceso altamente estandarizado y, especialmente, la hemodiálisis en centros se realiza en un entorno supervisado. Este procedimiento genera una gran cantidad de datos relacionados con los pacientes, lo cual resulta

particularmente atractivo desde la perspectiva del aprendizaje automático (Machine Learning, ML). En hemodiálisis (HD), la IA ha impulsado el desarrollo de modelos en ocho subcategorías, ayudando a los nefrólogos a comprender su impacto en la práctica clínica. Los modelos de IA procesan seis tipos de datos clave: demográficos, de laboratorio, de series temporales (como presión arterial), de prescripción médica, relacionados con diálisis (tipo de dializador, acceso vascular) y de imágenes (fístulas arteriovenosas, biopsias renales). Esta categorización busca proporcionar una visión clara de cómo la IA puede mejorar la atención renal mediante el análisis automatizado y en tiempo real de múltiples parámetros clínicos [1] (Tabla 9).

##### 6.1.1 Predicción de hipotensión intradiálisis

La hipotensión intradiálisis (HID) es una de las complicaciones más frecuentes en HD y está asociada a síntomas como mareos, náuseas y síncope, además de contribuir a la hipoperfusión de órganos y a un mayor riesgo de eventos cardiovasculares y mortalidad. Predecir estos episodios con suficiente antelación permitiría tomar medidas preventivas como ajustar la ultrafiltración o administrar fluidos de manera proactiva [2].

Modelos de Machine Learning han demostrado ser eficaces para anticipar la HID. En

**TABLA 9.** Subcategorías de la IA en hemodiálisis [1]

SUBCATEGORÍA DE IA EN HD	TIPOS DE DATOS PROCESADOS	APLICACIONES CLÍNICAS
<b>Predicción de eventos adversos intradialíticos</b>	Datos demográficos, series temporales (presión arterial, frecuencia cardíaca, presión venosa), datos de prescripción (flujo sanguíneo, volumen de ultrafiltración)	Predicción de hipotensión intradialítica, calambres y episodios de hipertensión intradialíticos.
<b>Gestión de anemia</b>	Datos de laboratorio (hemoglobina, hematocrito, ferritina), datos de prescripción (dosis de hierro, eritropoyetina)	Optimizar dosis de eritropoyetina para mejorar calidad de vida y evitar efectos adversos.
<b>Evaluación del acceso vascular</b>	Datos de imagen (fistulas arteriovenosas, panning video)	Clasificación de aneurismas y predicción de falla de la fistula.
<b>Predicción de insuficiencia cardíaca</b>	Datos de series temporales (presión arterial, peso, variabilidad de volumen)	Identificación de pacientes con riesgo de insuficiencia cardíaca.
<b>Predicción de mortalidad en HD</b>	Datos demográficos (edad, comorbilidades), datos de laboratorio (albumina, creatinina)	Identificación temprana de pacientes con alto riesgo de muerte.
<b>Monitoreo de función cognitiva en HD</b>	Datos de imagen (resonancia magnética funcional)	Evaluación de deterioro cognitivo en pacientes en hemodiálisis.
<b>Manejo de desórdenes minerales y óseos</b>	Datos de laboratorio (calcio, fósforo, hormona paratiroidea)	Predicción de niveles fuera de rango de PTH y optimización del tratamiento.
<b>Predicción de peso seco en HD</b>	Datos de series temporales (presión arterial post diálisis, bioimpedancia)	Ajuste individualizado del peso seco para reducir complicaciones.

particular, un estudio realizado por Lee y cols. desarrolló un modelo basado en redes neuronales recurrentes (RNN) que logró predecir la caída de la presión arterial sistólica por debajo de 90 mmHg con hasta una hora de anticipación, con una excelente capacidad discriminativa AUROC  $\approx 0,94$  [3]. En un estudio posterior utilizando datos de 2.007 pacientes y 943.220 sesiones de HD en siete hospitales universitarios, los investigadores desarrollaron un modelo de inteligencia artificial basado en Deep Learning para predecir HID a partir de características prediálisis. Compararon su acierto con modelos tradicionales de Machine Learning (regresión logística, random forest

y XGBoost). Los resultados mostraron que la HID ocurrió en el 5,39 % de las sesiones y que factores como la presión arterial prediálisis baja, una mayor tasa de ultrafiltración y el aumento de peso interdialítico fueron predictores clave. Inicialmente, los modelos de Machine Learning y Deep Learning tuvieron un rendimiento similar, pero al incorporar datos de las tres sesiones previas, el modelo de Deep Learning mejoró significativamente y superó a los demás en precisión predictiva. Las variables más importantes para la predicción fueron la presión arterial sistólica previa, la tasa de ultrafiltración y antecedentes de HID en sesiones anteriores [4].

Una más reciente revisión sistemática [2] analiza la literatura existente sobre el uso de modelos de inteligencia artificial (IA) y aprendizaje automático (ML) para predecir la HID. Se identificaron cinco estudios que emplearon diversos algoritmos, como redes neuronales artificiales, árboles de decisión, máquinas de soporte vectorial, XGBoost, random forests y Light Gradient

Boosting Machine (Tabla 10). Estos modelos utilizaron datos demográficos, clínicos, de laboratorio y parámetros de diálisis, mostrando resultados prometedores con altas precisiones de predicción. Sin embargo, las limitaciones incluyen la variabilidad en las poblaciones estudiadas, el diseño retrospectivo de los estudios y la necesidad de validación prospectiva.

**TABLA 10.** Resumen de los estudios incluidos en la revisión sistemática [2] sobre hipotensión intradiálisis (HID)

AUTOR	ENFOQUE DEL ESTUDIO	PARÁMETROS DE HEMODIÁLISIS	MODELO DE IA/ML	DIVISIÓN DE DATOS	DESEMPEÑO DEL MODELO	CONCLUSIONES PRINCIPALES
Barbieri et al. [5] (2019)	Predicción de múltiples parámetros en hemodiálisis.	60 variables: características del paciente, reacciones históricas, datos prediálisis, prescripciones	Red neuronal multicapa (ANN)	70 % entrenamiento, 10 % validación, 20 % prueba	Precisión aceptable para peso postdiálisis, Kt/V, presión arterial mínima, frecuencia cardíaca postdiálisis	El modelo puede anticipar reacciones hemodinámicas y guiar ajustes de prescripción.
Gómez-Pulido et al. [6] (2021)	Predicción de hipotensión durante hemodiálisis.	22 variables: demografía, ganancia de peso interdialítica, aclaramiento de urea, flujo sanguíneo, presión arterial	Árbol de decisión (DT) y Máquina de Soporte Vectorial (SVM)	70–95 % entrenamiento, 5–30 % prueba	DT: precisión 75–81 %, especificidad >90 %; SVM: precisión 74–80 %	Los modelos pueden ayudar a prevenir eventos cardiovasculares durante la hemodiálisis.
Zhang et al. [7] (2023)	Predicción en tiempo real de la hipotensión intradiálisis.	99 variables: datos demográficos, clínicos, parámetros del tratamiento, datos de laboratorio	XGBoost	80 % entrenamiento, 20 % prueba	AUROC = 0.89; Sensibilidad = 0.65, Especificidad = 0.90	La predicción en tiempo real de IDH es factible con buen rendimiento.
Hong et al. [8] (2023)	Predicción temprana de IDH antes de la diálisis.	Datos demográficos, clínicos y de laboratorio (Hb, albúmina, calcio, fósforo, sodio, potasio, PTH, ferritina)	18 algoritmos de ML (incluyendo Regresión Logística, XGBoost, Random Forest)	80 % entrenamiento, 20 % prueba	Precisión 74,0 %, AUROC = 81,2 %	El sistema de alerta temprana puede predecir IDH antes de iniciar la diálisis.
Dong et al. [9] (2023)	Predicción de IDH usando dos modelos.	Género, edad, tiempo de tratamiento, medidas de presión arterial, tasa de ultrafiltración	LightGBM, LDA, MLP, XGB, SVM	70 % entrenamiento, 20 % prueba, 10 % validación	LightGBM tuvo el mejor desempeño (AUROC = 0,82).	Los modelos ofrecen predicción complementaria del riesgo de IDH.

Se recomienda que futuras investigaciones se centren en estudios multicéntricos prospectivos, evalúen la utilidad clínica de estos modelos e integren sistemas de IA interpretables en la toma de decisiones médicas. No obstante, estos avances han llevado a la implementación de sistemas de alerta temprana en algunas máquinas de diálisis, permitiendo ajustes automáticos en la tasa de ultrafiltración para prevenir caídas bruscas de la presión arterial.

Más recientemente Yang y cols. [10] desarrollaron modelos de inteligencia artificial (IA) para predecir la HID considerando datos en tiempo real y de sesiones previas. Se probaron ocho algoritmos de aprendizaje automático, siendo el modelo XGBoost el más preciso (AUC: 0,936). Este modelo se integró en un panel digital que muestra en tiempo real el riesgo de HID para cada paciente, ayudando al equipo clínico a intervenir de forma preventiva. Tras su implementación, se observó una reducción significativa en la tasa de HID.

#### 6.1.2 Optimización del manejo de la anemia

La optimización del manejo de la anemia en hemodiálisis (HD) es un desafío clínico importante, ya que la anemia refractaria es una complicación frecuente en pacientes renales en diálisis. El tratamiento convencional con agentes estimulantes de eritropoyesis (AEEs) y hierro intravenoso requiere un ajuste preciso de las dosis, dado que tanto la infra como la sobrecorrección de la hemoglobina pueden generar riesgos como fatiga, necesidad de transfusiones o eventos cardiovasculares graves [11].

La inteligencia artificial (IA) ha sido utilizada para personalizar la terapia de la anemia, permitiendo ajustes más precisos mediante el análisis de múltiples datos del paciente, como niveles de hemoglobina (Hb), dosis previas de AEEs, respuesta individual y valores de ferritina. En 2003, un grupo de la Universidad

de Valencia utilizó el aprendizaje automático (ML) para identificar asociaciones ocultas en los datos [12]. Desde entonces, se han desarrollado numerosos modelos de ML que han mejorado la precisión de estas predicciones. Un estudio europeo desarrolló un modelo de red neuronal artificial con una precisión superior al 90 % en la predicción de la Hb futura, superando los métodos convencionales. Este modelo fue posteriormente validado en un estudio multicéntrico observacional con 752 pacientes en HD seguidos durante 24 meses, donde su integración en un sistema de apoyo a la decisión clínica demostró mejoras sustanciales en el control de la anemia [13, 14].

Bucalo y cols. utilizaron ACM que es un software concebido como una herramienta de ayuda al clínico en la toma de decisiones en la prescripción de AEE y hierro para el tratamiento de la anemia renal en los pacientes en hemodiálisis. El uso de IA permitió reducir la dosis total de AEEs administrada, al tiempo que aumentó el porcentaje de pacientes con hemoglobina dentro del rango objetivo y con menor variabilidad de Hb. Además, se observaron una disminución en la necesidad de transfusiones, hospitalizaciones y eventos cardiovasculares asociados a la anemia, lo que respalda el impacto clínico positivo de esta tecnología [15].

Kang y cols. utilizaron un módulo basado en atención con unidades recurrentes con compuertas (GAM que combina redes neuronales recurrentes con mecanismos de atención) para optimizar el manejo de la anemia en pacientes en diálisis crónica que opera en dos fases principales: (1) predicción de los niveles de Hb y recomendación de dosis de ESA y (2) un marco de alerta para transfusiones. El modelo GAM mejoró la gestión de la anemia en pacientes con ERC avanzada al optimizar las dosis de ESA y proporcionar alertas oportunas (99 %) para transfusión [16].

Actualmente, algunos proveedores están integrando estos sistemas en plataformas de diálisis para apoyar a los nefrólogos en la titulación de AEEs de manera más dinámica y basada en datos, con el objetivo de optimizar la terapia y mejorar los resultados clínicos de los pacientes en HD. El CDSS (Sistema de Apoyo a la Decisión Clínica) es un sistema basado en inteligencia artificial o en reglas predefinidas que ayuda a los profesionales de la salud a tomar decisiones médicas basadas en datos, mejorando la precisión de los diagnósticos, la planificación del tratamiento y la gestión de los pacientes). La implementación de algoritmos de ML en el CDSS se perfila como una estrategia clave en la toma de decisiones clínicas. Estos modelos permiten un enfoque más preciso en la prescripción de tratamientos, disminuyen la incidencia de efectos adversos en los pacientes, optimizan el proceso de prescripción para los médicos y mejoran la rentabilidad para las instituciones sanitarias. Se espera que, en el futuro, el uso de estos CDSS basados en IA sea cada vez más común entre los nefrólogos, dado que la capacidad de estos sistemas para procesar grandes volúmenes de datos, adaptarse a nueva información e identificar correlaciones complejas los convierte en un recurso valioso para la atención médica [17].

### 6.1.3 Monitorización del acceso vascular

El acceso vascular es un componente crítico en pacientes en hemodiálisis (HD), ya que permite la realización del tratamiento de manera efectiva. Sin embargo, las fístulas arteriovenosas (FAV) y los injertos pueden desarrollar estenosis y trombosis, lo que compromete la continuidad del tratamiento. La inteligencia artificial (IA) ha sido aplicada para mejorar la vigilancia de la FAV y predecir fallos antes de que ocurran complicaciones graves.

Un estudio del Renal Research Institute demostró que el uso de algoritmos de aprendizaje automático (ML) puede mejorar la clasificación de imágenes de AVF/AVG en tres etapas de aneurisma/pseudoaneurisma, cada una con diferentes niveles de riesgo de ruptura del acceso vascular, una complicación grave que puede causar morbilidad y mortalidad. Este modelo de ML mostró una precisión del 93 % en la predicción de estos estadios a partir de imágenes tomadas con un teléfono inteligente. Esto permite a los pacientes enviar fotografías de su AVF para evaluación durante los días interdialíticos sin necesidad de acudir a una consulta presencial, facilitando una gestión proactiva y reduciendo la carga asistencial para los pacientes [18].

Un modelo de Machine Learning basado en XGBoost, desarrollado por Peralta y cols. [19] se entrenó con datos de más de 13.000 pacientes, utilizando información de rutina como presiones dinámicas, flujos y recirculación. Este modelo alcanzó un rendimiento predictivo elevado ( $AUC \approx 0,80$ ) y demostró ser capaz de anticipar el riesgo de fallo de la fístula en los siguientes tres meses, identificando variables clave como antecedentes de complicaciones, grado de recirculación y patrones en la dosis de diálisis y presiones vasculares. Su integración en la práctica clínica permite un seguimiento personalizado, facilitando la derivación temprana de pacientes de alto riesgo a estudios de ecografía o angiografía, mientras que aquellos con bajo riesgo pueden evitar procedimientos innecesarios. De hecho, la detección de estenosis mediante IA podría reducir procedimientos no indicados: actualmente, la vigilancia con medición de flujos o presiones en FAV tiene alto índice de falsos positivos que llevan a angioplastias preventivas posiblemente no requeridas [1].

Heindel y cols. desarrollaron una herramienta predictiva del número de intervenciones

necesarias en fístulas arteriovenosas radiocefálicas (AVF) y recopilaron datos clínicos (como demografía, comorbilidades, antecedentes de accesos vasculares y características anatómicas), así como mediciones ecográficas posoperatorias a las 4–6 y 12 semanas, con el fin de predecir las intervenciones necesarias en el año posterior a la Cirugía. Construyeron varios modelos predictivos, incluyendo modelos de supervivencia de Cox, random survival forest, regresión logística agrupada y elastic net, combinando variables basales y ecográficas. El modelo de random survival forest, basado únicamente en las características iniciales, mostró el mejor desempeño con un área bajo la curva (AUROC) de 0,75. Desarrollaron una aplicación web interactiva (<https://predict-avf.com>), que ofrece predicciones personalizadas en línea con las guías KDOQI, proporcionando así una herramienta útil para la planificación centrada en el paciente con enfermedad renal terminal [20].

Además, el uso de sensores de fotopleti-mografía (PPG) ha sido explorado en Taiwán como una herramienta portátil para la evaluación del AVF. Este estudio, de prueba de concepto, desarrolló un modelo de ML que convierte la señal de PPG en una velocidad comparable a la obtenida con ultrasonido Doppler. El modelo fue capaz de clasificar AVF con anomalías con una precisión del 89 %. Esta tecnología se perfila como una alternativa prometedora al examen clínico tradicional, al permitir una evaluación más cómoda, no invasiva y precisa del AVF [21].

Por tanto, la aplicación de la IA en la vigilancia del acceso vascular en HD ha mostrado resultados prometedores, tanto en la predicción de fallos en la FAVI mediante ML como en el uso de visión por computadora para la detección temprana de anomalías estructurales. Estas tecnologías tienen el potencial de optimizar el seguimiento clínico, reducir

intervenciones innecesarias y mejorar la seguridad del paciente, lo que justifica su validación y futura integración en la práctica nefrológica.

#### 6.1.4 Adecuación de la diálisis y planificación del servicio

El uso de la inteligencia artificial (IA) en la gestión de unidades de diálisis ha demostrado ser un recurso valioso debido a la gran cantidad de datos recopilados durante las sesiones de diálisis. Mediante la IA como un sistema de auditoría, es posible resumir estas sesiones desde una perspectiva de calidad clínica, evaluando factores como la probabilidad de coagulación, la interrupción de sesiones o la adecuación del tratamiento de diálisis.

Esta aplicación de la IA ha sido objeto de diferentes estudios. La mayoría de estos estudios utilizan una amplia variedad de datos de entrada, incluyendo datos demográficos, datos de laboratorio, series temporales y datos específicos de la diálisis, con el fin de construir un perfil de riesgo para cada paciente. Este perfil de riesgo puede ser utilizado para priorizar la gestión de la vigilancia en clínicas con recursos limitados, mejorando así los resultados de los pacientes y optimizando la toma de decisiones clínicas [22].

#### 6.1.5 Optimización de la dosis de diálisis y estabilidad hemodinámica

La inteligencia artificial ha demostrado ser una herramienta prometedora en la optimización de la dosis de diálisis y otros parámetros en hemodiálisis. Como ya hemos comentado, los pacientes con inestabilidad hemodinámica no toleran bien la diálisis intermitente, lo que resalta la necesidad de dispositivos más avanzados. La inteligencia artificial y el aprendizaje automático (ML) pueden contribuir a mejorar la diálisis mediante el análisis en tiempo real de parámetros clínicos y alarmas de los equipos, facilitando respuestas automatizadas.

La medicina de precisión busca tratamientos individualizados basados en el análisis de grandes volúmenes de datos generados por los pacientes en diálisis. Aunque la Nefrología aún avanza lentamente en este campo, la integración de la ciencia de datos puede mejorar la toma de decisiones médicas y evaluar la efectividad de los tratamientos actuales mediante ensayos clínicos pragmáticos.

Una de sus aplicaciones es la adecuación dialítica mediante modelos predictivos que permiten ajustar los parámetros de la máquina según las características individuales del paciente, con el objetivo de alcanzar un Kt/V óptimo [1]. La determinación del peso seco (PS) en pacientes sometidos a hemodiálisis sigue siendo un desafío clínico, con múltiples métodos empleados para evaluar el PS óptimo. Ante la incertidumbre en la determinación exacta del PS, algunos modelos han optado por predecir sus consecuencias en lugar del peso en sí. La predicción de eventos adversos intradialíticos, como la hipotensión intradialítica (HID) y los calambres, ha sido explorada a través de dos enfoques principales.

El primer enfoque consiste en modelos predictivos que utilizan parámetros de entrada estáticos antes de la sesión de diálisis. Estos modelos han sido implementados en estudios piloto y emplean una variedad de datos, incluyendo datos demográficos (edad, sexo, estatura), resultados de laboratorio (sodio, calcio, etc.), condiciones médicas subyacentes (diabetes, hipertensión, etc.), datos de series temporales (presión arterial sistólica y diastólica antes de la sesión de diálisis) y datos específicos de la diálisis (tipo de dializador, tiempo en diálisis, etc.) [23]. Sin embargo, los modelos que incorporan parámetros no estáticos, es decir, aquellos que analizan cambios en los datos de series temporales durante la sesión de hemodiálisis (como la presión arterial sistólica, presión arterial diastólica, frecuencia cardíaca

y frecuencia respiratoria), han demostrado ser más efectivos en la mitigación proactiva de eventos adversos. Diversos estudios han reportado un rendimiento excelente de estos modelos en términos de área bajo la curva (AUC) para la predicción de eventos adversos, con valores entre 0,83 y 0,90 [24, 25].

El uso de estas herramientas de asistencia permite a los profesionales de la salud reducir su carga de trabajo y mejorar la monitorización de eventos adversos intradialíticos de manera más eficiente. Se espera que la implementación de estos modelos en la práctica clínica contribuya significativamente a la seguridad y el bienestar de los pacientes en tratamiento de hemodiálisis. Además, existen iniciativas piloto para la gestión integrada de la volemia y la presión arterial a través de IA. Un ejemplo destacado es el modelo multivariable desarrollado por Barbieri y cols. diseñado para sugerir ajustes en el perfil de ultrafiltración, la ingesta interdialítica de líquidos y la dosis de diálisis, con el propósito de mantener al paciente euvolémico y con una presión arterial controlada [5].

Las tecnologías emergentes basadas en inteligencia artificial, aprendizaje automático, electrónica y robótica representan una gran oportunidad para mejorar la diálisis, aunque aún se requiere mucha innovación para desarrollar una máquina inteligente capaz de interpretar y adaptarse en tiempo real a los cambios en la homeostasis del paciente [26, 27].

## 6.2. APLICACIONES DE LA IA EN DIÁLISIS PERITONEAL

La inteligencia artificial (IA) ha encontrado múltiples aplicaciones en la diálisis peritoneal (DP), una modalidad de terapia renal domiciliar que otorga mayor autonomía a los pacientes, pero cuya efectividad depende de la monitorización continua, la adherencia al tratamiento y la prevención de complicaciones

como la peritonitis. El uso de IA en DP se centra en la predicción de riesgos, la optimización del seguimiento remoto y la identificación de patrones que permitan mejorar la continuidad del tratamiento [28].

### 6.2.1 Pronóstico de pacientes y técnica

Diferentes estudios han empleado técnicas de Machine Learning (ML) para estratificar el pronóstico de los pacientes en DP. Uno de los trabajos más destacados es el de Noh y cols. [29] que aplicó modelos de ML a una cohorte prospectiva de 1.730 pacientes para predecir la mortalidad a cinco años. Comparando métodos tradicionales como la regresión de Cox con enfoques basados en árboles de decisión y redes neuronales, se encontró que el modelo basado en árboles de decisión (*survival tree*) tuvo mayor capacidad predictiva (índice de concordancia 0,769 vs. 0,745). Además, al incluir datos longitudinales de seguimiento, un modelo de red neuronal profunda mejoró el AUC de predicción de mortalidad de 0,804 (modelo logístico) a 0,841, reflejando una mejora significativa en la precisión. Estos modelos identificaron factores de riesgo clave, como la edad avanzada y la puntuación de comorbilidad de Charlson modificada, evidenciando que un paciente mayor de 70 años con una carga de comorbilidades alta (Charlson >4) tiene un riesgo de muerte 4,6 veces superior al promedio. Estas herramientas pueden ser fundamentales para los nefrólogos al momento de identificar pacientes con mal pronóstico, permitiendo intervenciones oportunas como un seguimiento más intensivo o la planificación de un trasplante renal antes de que la condición del paciente se deteriore demasiado.

Un estudio de Xu y cols. [30] tuvo como objetivo desarrollar un modelo predictivo para insuficiencia cardíaca (IC) y mortalidad por cualquier causa en pacientes en diálisis

peritoneal (DP) utilizando algoritmos de aprendizaje automático (ML). Se incluyeron retrospectivamente 1006 pacientes que iniciaron DP entre 2010 y 2016. Se entrenaron modelos con XGBoost, random forest (RF) y AdaBoost para evaluar el riesgo de hospitalización por IC y mortalidad a 1 y 5 años, y su rendimiento se validó mediante validación cruzada de cinco pliegues. El algoritmo más preciso se utilizó para construir los modelos predictivos. Durante un seguimiento mediano de 49 meses, 298 pacientes presentaron IC que requirió hospitalización y 199 fallecieron. El modelo RF (AUC = 0,853) fue el más eficaz para predecir hospitalización por IC, mientras que el modelo XGBoost (AUC = 0,871) tuvo la mejor precisión para predecir mortalidad. En todos los casos, los modelos de ML demostraron una capacidad de discriminación superior a la del modelo de regresión de Cox. En conclusión, se desarrolló y validó un nuevo enfoque predictivo que integra variables clínicas, de laboratorio y electrocardiográficas fácilmente disponibles para predecir el riesgo de IC y mortalidad en pacientes con DP.

Otro aspecto relevante es la predicción del fallo de la técnica de DP, que ocurre cuando un paciente debe abandonar esta modalidad debido a complicaciones, siendo la peritonitis bacteriana una de las principales causas. Un estudio utilizó una base de datos amplia, de alta calidad y recolectada prospectivamente del *United Kingdom Renal Registry* entre 1999 y 2004. Se incluyeron 3.269 pacientes y se creó un modelo de red neuronal artificial (RNA) para predecir la supervivencia de la técnica de diálisis peritoneal (DP). Se construyeron y entrenaron redes neuronales artificiales multicapa tipo *perceptron*, con arquitecturas de nodos 73-80-1, utilizando el enfoque de retropropagación (*backpropagation*). Se encontró que el centro de DP influye significativamente en la supervivencia de la técnica. La mayoría

de las características del examen físico, los datos de laboratorio y las comorbilidades no tuvieron un efecto significativo en la probabilidad de fallo de la técnica en pacientes en DP. Además, el modelo basado en RNA tuvo un resultado razonablemente bueno para predecir el fallo temprano de la técnica en pacientes incidentes en DP. La RNA tuvo un rendimiento significativamente mejor que un modelo tradicional de predicción basado en regresión logística [31,32].

Investigadores chinos desarrollaron modelos de ML para prever si un episodio de peritonitis llevaría al fracaso de la terapia. Un estudio de Zang et al. [33] analizó 508 episodios de peritonitis retrospectivamente, evaluando cinco algoritmos distintos (*random forest*, regresión LASSO, árboles de decisión, k-NN y regresión logística). El modelo de *random forest* obtuvo la mayor precisión, con un AUC de 0,916 y una exactitud del 93,7 % para predecir el fracaso de la técnica tras un episodio infeccioso. Este modelo mostró una sensibilidad del 97 % en la identificación de los casos que terminarían en fallo de la técnica, lo que lo convierte en una herramienta útil para la toma de decisiones clínicas, permitiendo anticipar qué pacientes con peritonitis severa tienen peor pronóstico y deben ser evaluados tempranamente para un cambio a hemodiálisis. Además, se están explorando modelos capaces de identificar peritonitis recurrentes o refractarias, considerando factores en la historia clínica del paciente y en su respuesta inflamatoria inicial.

### 6.2.2 Predicción de peritonitis

La peritonitis es una complicación frecuente de la diálisis peritoneal (DP) y sigue siendo una causa importante de abandono temprano de la técnica y de mortalidad. Aunque el recuento elevado de leucocitos con una proporción superior al 50 % de granulocitos

en el efluente peritoneal se utiliza como indicador de peritonitis, el diagnóstico basado en cultivos es lento y poco satisfactorio. Por ello, el tratamiento de la peritonitis continúa siendo en gran medida empírico.

Xu y cols. [34] desarrollaron un modelo de predicción del riesgo de episodios frecuentes de peritonitis en pacientes en DP. Para la construcción del modelo predictivo se utilizó regresión logística binaria. Incluyeron 371 pacientes con PDAP, de los cuales 235 presentaron un solo episodio y 136 episodios frecuentes. Los pacientes fueron asignados aleatoriamente a un conjunto de entrenamiento (296 pacientes) y a un conjunto de prueba (75 pacientes), en una proporción de 8:2. En el análisis del conjunto de entrenamiento, se identificaron varios factores de riesgo independientes significativamente asociados con episodios frecuentes, entre ellos: diabetes mellitus, niveles de hemoglobina, albúmina sérica, lactato deshidrogenasa, potasio sérico, NT-proBNP y el recuento de leucocitos en el líquido peritoneal en el primer día. El modelo predictivo construido mostró un buen rendimiento, con un área bajo la curva (AUC) de 0,75 en el conjunto de entrenamiento y de 0,76 en el conjunto de prueba. Además, se desarrolló un nomograma más intuitivo para facilitar la evaluación del riesgo clínico. No obstante, los autores señalan la necesidad de realizar estudios multicéntricos con muestras más amplias para validar el modelo y confirmar su aplicabilidad en distintos entornos clínicos.

Se ha demostrado que las técnicas de aprendizaje automático (ML) pueden identificar variedades específicas de biomarcadores asociadas a organismos Gram negativos, Gram positivos y a episodios con cultivo negativo de etiología incierta. Un estudio empleó un enfoque sistemático para caracterizar la respuesta a infecciones microbiológicamente bien definidas en un total de 83 pacientes en

DP, evaluados el mismo día de la presentación clínica con peritonitis aguda. Se aplicaron distintos modelos de ML, incluidos máquinas de vectores de soporte (SVM), redes neuronales (NN) y bosques aleatorios (RF), a conjuntos de datos biomédicos complejos, identificando rutas clave implicadas en respuestas inmunitarias específicas según el patógeno en el sitio de la infección. Este estudio demostró el poder de los modelos matemáticos avanzados para analizar datos biomédicos complejos, resaltar rutas críticas en la respuesta inflamatoria específica del patógeno y aportar implicaciones tanto diagnósticas como pronósticas, ayudando a orientar el tratamiento del paciente [35].

### 6.2.3 Control a distancia y adherencia en DP domiciliaria

Una de las ventajas de la DP es la posibilidad de telemonitorización, ya que las cicladoras de DP automatizada pueden transmitir datos detallados de cada sesión, incluyendo volúmenes ultrafiltrados, alarmas del equipo y cumplimiento de la prescripción médica. La IA puede procesar estos datos para detectar anomalías que sugieran problemas incipientes. Se han desarrollado algoritmos capaces de identificar reducciones sutiles en el ultrafiltrado o aumentos en la frecuencia de alarmas, lo que podría indicar el inicio de una disfunción del peritoneo o problemas de adherencia antes de que se presenten complicaciones graves como sobrecarga de volumen o peritonitis.

Además, la combinación de datos clínicos mensuales (peso, niveles de albúmina, historial de infecciones) con registros de adherencia, como retrasos en la solicitud de componentes o desconexiones prematuras del ciclador, permite predecir qué pacientes tienen mayor riesgo de abandonar la DP. En este sentido, Fresenius ha desarrollado la herramienta PD Drop Risk [36], basada en IA,

que analiza información clínica y de adherencia para identificar pacientes en riesgo de suspender la terapia peritoneal y pasar a hemodiálisis. Este modelo considera múltiples factores, incluyendo resultados de laboratorio, infecciones previas, hospitalizaciones recientes y cumplimiento del tratamiento. Al anticipar la posibilidad de abandono, los equipos médicos pueden intervenir oportunamente, reforzando la educación domiciliaria, ajustando regímenes de DP o solucionando barreras logísticas y sociales para mejorar la adherencia al tratamiento. Actualmente, esta herramienta se encuentra en fase piloto en diversos centros, con la expectativa de que su uso generalizado ayude a prolongar el tiempo que los pacientes permanecen en DP de manera segura, lo que trae beneficios tanto clínicos como económicos.

### 6.2.4 Chatbots para pacientes en DP

Otro desarrollo interesante es el uso de chatbots inteligentes en la educación y soporte de pacientes con DP domiciliaria. En Taiwán, un chatbot basado en procesamiento de lenguaje natural fue implementado en 2021 para guiar a los pacientes en su autocuidado y prevenir errores que podrían derivar en infecciones [37]. Estas herramientas pueden ofrecer recomendaciones personalizadas y resolver dudas en tiempo real, contribuyendo a mejorar la seguridad y la adherencia a la terapia.

Podemos concluir que la IA en diálisis peritoneal abarca múltiples frentes, desde la predicción de riesgos y la optimización del seguimiento hasta el soporte educativo automatizado. Su capacidad para analizar grandes volúmenes de datos en tiempo real permite identificar patrones que pueden mejorar la seguridad y la eficacia de esta modalidad terapéutica, contribuyendo a una mejor calidad de vida para los pacientes y una gestión más eficiente de los recursos sanitarios.

### 6.3 DESAFÍOS Y CONSIDERACIONES ÉTICAS DE LA IMPLEMENTACIÓN DE LA IA EN DIÁLISIS

A pesar de sus ventajas, la implementación de la IA en diálisis presenta varios desafíos. Uno de los principales desafíos éticos es la transparencia y explicabilidad de los algoritmos. Muchos modelos de IA, especialmente aquellos basados en aprendizaje profundo, son considerados «cajas negras» debido a la dificultad para comprender cómo se generan sus predicciones [38]. En el contexto de la diálisis, donde las decisiones pueden influir directamente en la supervivencia y calidad de vida del paciente, resulta fundamental que tanto los profesionales sanitarios como los pacientes puedan entender los criterios utilizados por el sistema para emitir recomendaciones.

Otro aspecto crítico es la privacidad y protección de datos. La IA en diálisis se alimenta de grandes volúmenes de información clínica, incluyendo datos de laboratorio, historiales médicos, imágenes, y registros de tratamiento. La recolección, almacenamiento y procesamiento de estos datos deben cumplir con estrictos principios de confidencialidad y regulaciones como el Reglamento General de Protección de Datos (GDPR) en Europa o la HIPAA en Estados Unidos [39]. La reidentificación de datos anónimos mediante algoritmos sofisticados representa un riesgo real, y debe contemplarse en los sistemas de gobernanza.

La equidad y la ausencia de sesgos son también cuestiones clave. Los algoritmos pueden reproducir y amplificar desigualdades preexistentes si son entrenados con datos no representativos o sesgados. Por ejemplo, si un sistema predictivo de riesgo de hospitalización en pacientes en hemodiálisis se entrena mayoritariamente con datos de poblaciones blancas urbanas, podría tener un peor desempeño en comunidades rurales o en minorías

étnicas [40]. Esto podría derivar en decisiones clínicas injustas o en una distribución desigual de recursos.

La autonomía del paciente también se ve afectada. Si bien la IA puede facilitar la toma de decisiones compartidas mediante recomendaciones personalizadas, también existe el riesgo de que el criterio automatizado sustituya o condicione excesivamente el juicio clínico humano. Esto podría debilitar la relación médico-paciente y afectar la participación activa del paciente en su tratamiento [41].

Otro desafío importante es la responsabilidad profesional. Si una decisión tomada con apoyo de un sistema de IA resulta en un daño al paciente, ¿quién es responsable? Este es un tema particularmente delicado en diálisis, donde las condiciones de los pacientes pueden cambiar rápidamente y las decisiones deben tomarse con rapidez. La IA debe considerarse como una herramienta de apoyo, no como un reemplazo del juicio clínico. Por ello, es necesario desarrollar marcos legales y éticos que delimiten claramente las responsabilidades.

La implementación sostenible y justa de la IA en diálisis también requiere atención. No todos los centros de salud cuentan con los recursos tecnológicos ni con el personal capacitado para adoptar estas herramientas, lo que podría ampliar la brecha entre centros urbanos y rurales, o entre países desarrollados y en desarrollo. La equidad en el acceso a la innovación debe ser un principio rector.

Finalmente, la IA también plantea la necesidad de repensar la formación de los profesionales sanitarios. Es fundamental que nefrólogos, enfermeras y otros integrantes del equipo de diálisis comprendan los fundamentos de los sistemas de IA, sus ventajas y limitaciones, para poder usarlos de forma crítica y responsable [42].

**REFERENCIAS**

- 1 Burlacu A, Iftene A, Jugrin D, Popa IV, Lupu PM, Vlad C, Covic A. Using Artificial Intelligence Resources in Dialysis and Kidney Transplant Patients: A Literature Review. *Biomed Res Int.* 2020;2020:9867872.
- 2 Chaudhry TZ, Yadav M, Bokhari SFH, Fatimah SR, Rehman A, Kamran M, Asim A, Elhefyan M, Yousif O. Artificial Intelligence and Machine Learning in Predicting Intradialytic Hypotension in Hemodialysis Patients: A Systematic Review. *Cureus.* 2024;16(7):e65334.
- 3 Lee H, Yun D, Yoo J et al. Deep Learning model for real-time prediction of intradialytic hypotension. *Clin J Am Soc Nephrol* 2021;16:396–406.
- 4 Lee H, Moon SJ, Kim SW, Min JW, Park HS, Yoon HE, Kim YS, Kim HW, Yang CW, Chung S, Koh ES, Chung BH. Prediction of intradialytic hypotension using pre-dialysis features-a Deep Learning -based artificial intelligence model. *Nephrol Dial Transplant.* 2023 Sep 29;38(10):2310-2320.
- 5 Barbieri C, Cattinelli I, Neri L, Mari F, Ramos R, Brancaccio D, Canaud B, Stuard S. Development of an Artificial Intelligence Model to Guide the Management of Blood Pressure, Fluid Volume, and Dialysis Dose in End-Stage Kidney Disease Patients: Proof of Concept and First Clinical Assessment. *Kidney Dis (Basel).* 2019;5(1):28-33.
- 6 Gómez-Pulido JA, Gómez-Pulido JM, Rodríguez-Puyol D, Polo-Luque ML, Vargas-Lombardo M. Predicting the Appearance of Hypotension During Hemodialysis Sessions Using Machine Learning Classifiers. *Int J Environ Res Public Health.* 2021;18(5):2364.
- 7 Zhang H, Wang LC, Chaudhuri S, Pickering A, Usvyat L, Larkin J, Waguespack P, Kuang Z, Kooman JP, Maddux FW, Kotanko P. Real-time prediction of intradialytic hypotension using Machine Learning and cloud computing infrastructure. *Nephrol Dial Transplant.* 2023;38(7):1761-1769.
- 8 Hong D, Chang H, He X, Zhan Y, Tong R, Wu X, Li G. Construction of an Early Alert System for Intradialytic Hypotension before Initiating Hemodialysis Based on Machine Learning. *Kidney Dis (Basel).* 2023;9(5):433-442.
- 9 Dong J, Wang K, He J, Guo Q, Min H, Tang D, Zhang Z, Zhang C, Zheng F, Li Y, Xu H, Wang G, Luan S, Yin L, Zhang X, Dai Y. Machine Learning-based intradialytic hypotension prediction of patients undergoing hemodialysis: A multicenter retrospective study. *Comput Methods Programs Biomed.* 2023;240:107698.
- 10 Yang IN, Liu CF, Chien CC, Wang HY, Wang JJ, Shen YT, Chen CC. Personalized prediction of intradialytic hypotension in clinical practice: Development and evaluation of a novel AI dashboard incorporating risk factors from previous and current dialysis sessions. *Int J Med Inform.* 2024; 190:105538.
- 11 Yuan Q, Zhang H, Deng T, Tang S, Yuan X, Tang W, Xie Y, Ge H, Wang X, Zhou Q, Xiao X. Role of Artificial Intelligence in Kidney Disease. *Int J Med Sci* 2020; 17(7):970-984.
- 12 Martin-Guerrero JD, Camps-Valls G, Soria-Olivas E, Serrano-Lopez AJ, Perez-Ruixo JJ, Jimenez-Torres NV. Dosage individualization of erythropoietin using a profile-dependent support vector regression. *IEEE Trans Biomed Eng.* 2003;50(10):1136-42.
- 13 Gaweda AE, Jacobs AA, Aronoff GR, Brier ME. Model predictive control of erythropoietin administration in the anemia of ESRD. *Am J Kidney Dis.* 2008; 51:71-9.
- 14 Barbieri C, Molina M, Ponce P, Tothova M, Cattinelli I, Ion Titapiccolo J. et al. An international observational study suggests that artificial intelligence for clinical decision support optimizes anemia management in hemodialysis patients. *Kidney Int.* 2016;90:422-9.
- 15 Bucalo ML, Barbieri C, Roca S, Ion Titapiccolo J, Ros Romero MS, Ramos R. et al. The anaemia control model: Does it help nephrologists in therapeutic decision-making in the management of anaemia? *Nefrologia.* 2018;38:491-502.
- 16 Kang C, Han J, Son S, Lee S, Baek H, Hwang DD, Park JI. Optimizing anemia management using artificial intelligence for patients undergoing hemodialysis. *Sci Rep.* 2024;14(1):26739.

- 17 Hak F, Guimarães T, Santos M. Towards effective clinical decision support systems: A systematic review. *PLoS One*. 2022 Aug 15;17(8): e0272846.
- 18 Krackov W, Sor M, Razdan R, Zheng H, Kotanko P. Artificial Intelligence Methods for Rapid Vascular Access Aneurysm Classification in Remote or In-Person Settings. *Blood Purif*.2021;50(4-5):636-41.
- 19 Peralta R, Garbelli M, Bellocchio F, Ponce P, Stuard S, Lodigiani M, Fazendeiro Matos J, Ribeiro R, Nikam M, Botler M, Schumacher E, Brancaccio D, Neri L. Development and Validation of a Machine Learning Model Predicting Arteriovenous Fistula Failure in a Large Network of Dialysis Clinics. *Int J Environ Res Public Health*. 2021;18(23):12355.
- 20 Heindel P, Dey T, Fitzgibbon JJ, Mamdani M, Hentschel DM, Belkin M, Ozaki CK, Hussain MA. Predicting recurrent interventions after radiocephalic arteriovenous fistula creation with Machine Learning and the PREDICT-AVF web app. *J Vasc Access*. 2025;26(1):202-210.
- 21 Chao PC, Chiang PY, Kao YH, Tu TY, Yang CY, Tarng DC, et al. A Portable, Wireless Photoplethysmography Sensor for Assessing Health of Arteriovenous Fistula Using Class-Weighted Support Vector Machine. *Sensors (Basel)*. 2018;18(11):3854.
- 22 Chan L, Beers K, Yau AA, Chauhan K, Duffy Á, Chaudhary K, Debnath N, Saha A, Pattharanitima P, Cho J, Kotanko P, Federman A, Coca SG, Van Vleck T, Nadkarni GN. Natural language processing of electronic health records is superior to billing codes to identify symptom burden in hemodialysis patients. *Kidney Int*. 2020;97(2):383-392.
- 23 Ren Z, Zhang M, Wang P, Chen K, Wang J, Wu L, Hong Y, Qu Y, Luo Q, Cai K. Research on the development of an intelligent prediction model for blood pressure variability during hemodialysis. *BMC Nephrol*. 2025;26(1):82.
- 24 Liu YS, Yang CY, Chiu PF, Lin HC, Lo CC, Lai AS, et al. Machine Learning Analysis of Time-Dependent Features for Predicting Adverse Events During Hemodialysis Therapy: Model Development and Validation Study. *J Med Internet Res*. 2021;23(9): e27098.
- 25 Thakur SS, Abdul SS, Chiu HS, Roy RB, Huang PY, Malwade S, et al. Artificial-Intelligence-Based Prediction of Clinical Events among Hemodialysis Patients Using Non-Contact Sensor Data. *Sensors (Basel)*. 2018;18(9):2833.
- 26 Hueso M, Navarro E, Sandoval D, Cruzado JM. Progress in the Development and Challenges for the Use of Artificial Kidneys and Wearable Dialysis Devices. *Kidney Dis (Basel)*. 2019;5(1):3-10.
- 27 Scherer L, Kuss M, Nahm W. Review of Artificial Intelligence-Based Signal Processing in Dialysis: Challenges for Machine-Embedded and Complementary Applications. *Adv Kidney Dis Health*. 2023;30(1):40-46.
- 28 Bai Q, Tang W. Artificial intelligence in peritoneal dialysis: general overview. *Ren Fail*. 2022;44(1):682-687.
- 29 Noh J, Yoo KD, Bae W, Lee JS, Kim K, Cho JH, Lee H, Kim DK, Lim CS, Kang SW, Kim YL, Kim YS, Kim G, Lee JP. Prediction of the Mortality Risk in Peritoneal Dialysis Patients using Machine Learning Models: A Nationwide Prospective Cohort in Korea. *Sci Rep*. 2020;10(1):7470.
- 30 Xu L, Cao F, Wang L, Liu W, Gao M, Zhang L, Hong F, Lin M. Machine Learning model and nomogram to predict the risk of heart failure hospitalization in peritoneal dialysis patients. *Ren Fail*. 2024;46(1):2324071.
- 31 Tangri N, Ansell D, Naimark D. Predicting technique survival in peritoneal dialysis patients: comparing artificial neural networks and logistic regression. *Nephrol Dial Transplant*. 2008;23(9):2972–2981.
- 32 Tangri N, Ansell D, Naimark D. Determining factors that predict technique survival on peritoneal dialysis: application of regression and artificial neural network methods. *Nephron Clin Pract*. 2011;118(2):c93–c100.
- 33 Zang Z, Xu Q, Zhou X, Ma N, Pu L, Tang Y, Li Z. Random forest can accurately predict the technique failure of peritoneal dialysis asso-

- ciated peritonitis patients. *Front Med (Lausanne)* 2024;10:1335232.
- 34 Xu QJ, Zang ZY, Zhou XL, Ma NY, Pu L, Li Z. Unveiling risk factors: a prognostic model of frequent peritonitis in peritoneal dialysis patients. *Front Med (Lausanne)*. 2025;12:1456857.
- 35 Zhang J, Friberg IM, Kift-Morgan A, et al. Machine-learning algorithms define pathogen-specific local immune fingerprints in peritoneal dialysis patients with bacterial infections. *Kidney Int*. 2017;92(1):179–191.
- 36 PD Drop Risk <https://freseniusmedicalcare.com/en-us/insights/articles/5-ways-artificial-intelligence-ai-impacting-kidney-disease/>
- 37 Woan-Jean Lin, Ching-I Cheng, Juei-Hsin Hsu, Hui-Ting Liu, Yi-Tingchen, Yu-Hsiang Chou, Chih-Kang Chiang, #4729 Innovative artificial intelligence education tool in peritoneal dialysis patients, *Nephrology Dialysis Transplantation*. 2023;38(1).
- 38 Topol, E. (2019). *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books.
- 39 Price WN 2nd, Cohen IG. Privacy in the age of medical big data. *Nat Med*. 2019;25(1):37-43.
- 40 Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science*. 2019;366(6464):447-453.
- 41 Morley J, Floridi L, Kinsey L, Elhalal A. From What to How: An Initial Review of Publicly Available AI Ethics Tools, Methods and Research to Translate Principles into Practices. *Sci Eng Ethics*. 2020(4):2141-2168.
- 42 Amann J, Blasimme A, Vayena E, Frey D, Madai VI; Precise4Q consortium. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC Med Inform Decis Mak*. 2020;20(1):310.

## 7.

# APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL TRASPLANTE RENAL

---

El trasplante renal es el tratamiento de elección para la enfermedad renal terminal, ofreciendo mejor calidad de vida y supervivencia que la diálisis. Sin embargo, este campo enfrenta desafíos importantes, como la escasez de órganos disponibles y las complicaciones postrasplante (rechazo agudo, disfunción del injerto a largo plazo, toxicidad de fármacos inmunosupresores, etc).

La inteligencia artificial (IA), incluyendo técnicas de Machine Learning (ML o aprendizaje automático) y Deep Learning (aprendizaje profundo), ha emergido como una herramienta prometedora para abordar estas dificultades en medicina. En trasplante renal, la IA permite analizar grandes volúmenes de datos clínicos, moleculares e imágenes, descubriendo patrones complejos que escapan al análisis tradicional [1]. Esto abre posibilidades para mejorar el diagnóstico de complicaciones, predecir rechazos y pronosticar la evolución del injerto con mayor precisión, así como optimizar la selección de donantes y receptores [2].

Las técnicas de ML y DL se han aplicado en múltiples facetas del trasplante renal. Resaltamos tres áreas clave: el diagnóstico asistido por IA (particularmente en la detección de rechazo), la predicción temprana de episodios de rechazo agudo, y el pronóstico postrasplante

a mediano y largo plazo (supervivencia del injerto y del paciente). Estas aplicaciones aprovechan diversos tipos de datos: desde análisis histopatológicos y moleculares hasta parámetros clínicos del donante y receptor.

### 7.1 DIAGNÓSTICO ASISTIDO POR IA EN EL TRASPLANTE RENAL (DETECCIÓN DE RECHAZO)

El diagnóstico de rechazo del injerto renal típicamente se basa en la biopsia renal, un procedimiento invasivo con criterios complejos y sujeto a variabilidad entre patólogos [3]. En años recientes se han investigado métodos complementarios de diagnóstico apoyados por IA para mejorar la precisión y reducir la subjetividad. Estos esfuerzos se agrupan en tres categorías principales:

- (a) análisis histopatológico asistido por ML para mejorar la evaluación de biopsias.
- (b) análisis de expresiones génicas o proteómicas en biopsias o muestras sanguíneas, con desarrollo de clasificadores diagnósticos,
- (c) evaluación radiológica avanzada (p. ej. resonancia magnética por difusión) con sistemas de diagnóstico asistido por computadora

### 7.1.1 Análisis histopatológico asistido por ML para mejorar la evaluación de biopsias

En el ámbito de la patología, los algoritmos de DL han demostrado capacidad para identificar signos de rechazo en imágenes digitales de biopsias renales. Por ejemplo, un estudio entrenó redes neuronales convolucionales (CNNs) con 5.844 imágenes de biopsias para clasificarlas como normales, con rechazo o con otras patologías. Las CNN alcanzaron AUROC de hasta 0,87 para clasificar como normal o con enfermedad, y 0,75 al distinguir entre rechazo y otras enfermedades. Las técnicas de visualización identificaron áreas relevantes para el diagnóstico de rechazo, logrando un resultado fiable tanto en validación interna como externa [4]. Otro estudio de DL multicéntrico con 906 imágenes (WSIs) de 302 biopsias tomadas entre 2015 y 2023, clasificadas por dos patólogos expertos en biopsias de trasplante renal, mostró que la clasificación automática de biopsias podía apoyar el diagnóstico de rechazo de aloinjerto renal, identificando con éxito el rechazo, subtipificarlo (rechazo mediado por células T o anticuerpos) y predecir su pronóstico. El modelo, llamado RRAIM, logró un AUC de 0,798 en la clasificación de las categorías. Además, los modelos pronósticos predijeron con precisión la pérdida del injerto al año (AUC 0,936) y la respuesta al tratamiento (AUC 0,756) [5]. Estos modelos alcanzaron una precisión comparable a la de expertos, y además fueron capaces de resaltar regiones histológicas relevantes (como el área túbulo-intersticial) asociadas al rechazo. Esto sugiere que la IA puede estandarizar la interpretación de biopsias y reducir la variabilidad entre observadores, sirviendo como soporte al patólogo y evitando errores en la clasificación [3].

### 7.1.2 Análisis de expresiones génicas o proteómicas en biopsias o muestras sanguíneas

Se están explorando métodos no invasivos apoyados en IA para diagnóstico de rechazo y disfunción del injerto. Un enfoque es analizar parámetros clínicos de rutina con algoritmos inteligentes: Fritsche y cols. desarrollaron un modelo que detecta rechazo agudo basándose únicamente en los patrones de cambio de creatinina sérica, entrenado con historiales de pacientes trasplantados. Este algoritmo logró 78 % de acierto, superando significativamente la precisión de nefrólogos expertos (69 %) en identificar a tiempo un episodio de rechazo [6].

Modelos de ML basados en perfiles transcriptómicos de las biopsias (conocidos como «microscopio molecular») se están empleando para complementar el diagnóstico histológico tradicional, especialmente cuando los hallazgos morfológicos son ambiguos. Un ejemplo es el uso de biomarcadores proteómicos en tejido de biopsia: Fang y cols. realizaron un análisis proteómico cuantitativo sin marcaje en biopsias fijadas en formol e incluidas en parafina (FFPE) de pacientes trasplantados renales, 5 con rechazo mediado por células T (TCMR), 5 con nefropatía por poliomavirus BKyVN, y 5 con función renal estable. Se identificaron proteínas diferencialmente expresadas (DEP) y se entrenaron tres algoritmos de Machine Learning para construir un modelo diagnóstico molecular. Cuantificaron entre 800 y 1350 proteínas por muestra y se identificaron 329 y 467 DEP en TCMR frente a tejido estable y BKPyVN, respectivamente. Comparando estos datos con un estudio previo usando otra técnica, se construyó un modelo diagnóstico basado en *random forest* (RF), que alcanzó una precisión del 80 % para TCMR y 100 % para controles estables en un test ciego. Aplicado a conjuntos de datos transcriptómicos públicos, obtuvo una sensibilidad del 78–83 % y

especificidad del 59–64 %. Concluyeron que el análisis proteómico cuantitativo sin marcaje combinado con Machine Learning es una alternativa prometedora, precisa y económica (menos de 10 USD por prueba) para el diagnóstico del rechazo renal en biopsias FFPE [7].

De forma similar, se han utilizado perfiles de *omics*: un estudio empleó espectrometría de masas de péptidos en orina para detectar rechazo subclínico tipo T, obteniendo un área bajo la curva (AUC) de 0,91 y clasificando correctamente la mayoría de casos antes de que fueran clínicamente aparentes [8]. Otro trabajo analizó la firma de expresión génica en sangre periférica mediante secuenciación de RNA e identificó 102 genes (codificantes y no codificantes) asociados con distintos fenotipos de rechazo (mediado por anticuerpos vs. celular), aportando potenciales biomarcadores para pruebas diagnósticas no invasivas [9].

Aunque varias de estas tecnologías están en fase de investigación, ilustran el potencial de la IA para complementar o incluso reemplazar en el futuro a la biopsia en ciertas situaciones (por ejemplo, cuando está contraindicada), usando combinaciones de biomarcadores en sangre, orina o imágenes avanzadas. La IA está pues enriqueciendo el arsenal diagnóstico del trasplante renal, permitiendo un enfoque más integral donde datos histológicos, moleculares y clínicos se integran para identificar el rechazo con mayor prontitud y exactitud.

### 7.1.3 Evaluación radiológica avanzada (p. ej. resonancia magnética por difusión) con sistemas de diagnóstico asistido por computadora

La evaluación avanzada mediante resonancia magnética por difusión (DWI) combinada con sistemas de diagnóstico asistido por computadora (CAD) ha mostrado resultados prometedores en la detección temprana del rechazo en trasplantes renales. En un estudio

prospectivo reciente, Zhang y colaboradores evaluaron la utilidad diagnóstica de la resonancia magnética con imagen por tensor de difusión (DTI) para identificar disfunción del injerto renal en pacientes con rechazo agudo (AR) y nefropatía crónica del injerto (CAN). El estudio incluyó 77 receptores de trasplante renal, divididos en tres grupos: función estable, rechazo agudo y nefropatía crónica. Los autores observaron que los valores de anisotropía fraccional (FA) cortical y medular eran significativamente más bajos en los pacientes con AR y CAN en comparación con los controles, siendo la FA cortical útil para diferenciar entre ambos tipos de rechazo. El rendimiento diagnóstico de la FA cortical, medido por el área bajo la curva (AUC), fue particularmente alto para distinguir CAN de aloinjertos normales (AUC = 0,907), y mostró una capacidad razonable para diferenciar entre AR y CAN (AUC = 0,728). Estos hallazgos respaldan el potencial de la DTI como una herramienta no invasiva y cuantitativa para evaluar el estado del injerto renal, complementando la biopsia en el diagnóstico del rechazo [10].

### 7.2 PREDICCIÓN TEMPRANA DEL RECHAZO AGUDO MEDIANTE MODELOS DE IA

Anticipar qué pacientes presentarán rechazo agudo (RA) tras un trasplante renal es fundamental para guiar la inmunosupresión y el seguimiento. Tradicionalmente, los factores de riesgo de rechazo incluyen incompatibilidades HLA, niveles altos de anticuerpos preformados (PRA), ciertos antecedentes del receptor (retrasplantes, mala adherencia, etc.) y características del donante. La IA permite crear modelos predictivos multivariados más precisos incorporando multitud de variables clínicas, inmunológicas y hasta genómicas de donante y receptor [1].

Diversos estudios han entrenado algoritmos de ML en bases de datos de trasplantes para estimar la probabilidad de rechazo. En general, estos modelos suelen identificar como variables importantes la edad tanto del donante como del receptor, el grado de incompatibilidad HLA, la presencia de anticuerpos donante-específicos, la duración de la diálisis pretrasplante y factores como la diabetes o la hipertensión en el receptor [11].

Un área de gran interés es la detección precoz de rechazo antes de que cause daño irreversible. Ya mencionamos algoritmos que analizan creatinina o biomarcadores urinarios para señalar rechazo inminente [6]. Adicionalmente, algunos grupos han aplicado aprendizaje automático a datos de seguimiento rutinario (laboratorio, constantes vitales, niveles de fármacos) para pronosticar episodios de rechazo incipientes. Por ejemplo, Pineda *et al.* combinaron perfiles transcriptómicos en biopsias de protocolo con ML para predecir qué pacientes desarrollarían rechazo mediado por anticuerpos, lo que ayuda a identificar a quienes podrían beneficiarse de vigilancia estrecha o terapias preventivas [9]. Aunque todavía no existe un estándar clínico de predicción de rechazo basado en IA, los resultados de estos estudios son prometedores: algunos modelos alcanzan AUC por encima de 0,8 en la estratificación de riesgo de rechazo [8].

En el futuro, la integración de estos modelos en la práctica podría permitir un abordaje personalizado: por ejemplo, ajustar la inmunosupresión de mantenimiento en pacientes que el modelo identifica con alto riesgo, o planificar biopsias tempranas dirigidas en casos sospechosos (biopsias virtuales apoyadas por algoritmos) [12].

### 7.3 PRONÓSTICO POSTRASPLANTE A MEDIANO Y LARGO PLAZO (SUPERVIVENCIA DEL INJERTO Y DEL PACIENTE)

Además del rechazo agudo, la IA se está utilizando para predecir otros resultados clave tras el trasplante renal, como la función del injerto a corto plazo (p. ej. función retrasada o DGF), la supervivencia del injerto a 1, 5 o 10 años, y la supervivencia del paciente. Un modelo tradicional de pronóstico, es el índice de riesgo del donante (KDRI) [13] que se basa únicamente en las características del donante y se normaliza en una puntuación percentil. El KDPI es una transformación del KDRI a un porcentaje, que permite interpretar más fácilmente la calidad del riñón donado y se expresa como un porcentaje del 0 al 100 %. Los órganos con un KDPI  $\geq 85$  %, también conocidos como órganos con «KDPI alto», se asocian a una menor supervivencia a 5 años y a un mayor riesgo de fracaso del injerto en comparación con los riñones con KDPI  $< 85$  %. La puntuación de supervivencia postrasplante (EPTS), es una medida numérica que combina cuatro parámetros del receptor (edad y tiempo en diálisis del candidato, diagnóstico actual de diabetes y trasplantes previos de órganos sólidos) para predecir la supervivencia tras el trasplante y ayudar a la asignación de riñones de donantes [14]. Tanto el KDPI como el EPTS fueron implementados como parte del Sistema de Asignación de Riñones (KAS) en 2014 por la Red Unida para la Compartición de Órganos (UNOS) [15].

Los enfoques de ML pueden incorporar decenas de variables de donante, receptor y del procedimiento, capturando mejor la complejidad que determina el éxito del trasplante. Por ejemplo, se han desarrollado modelos basados

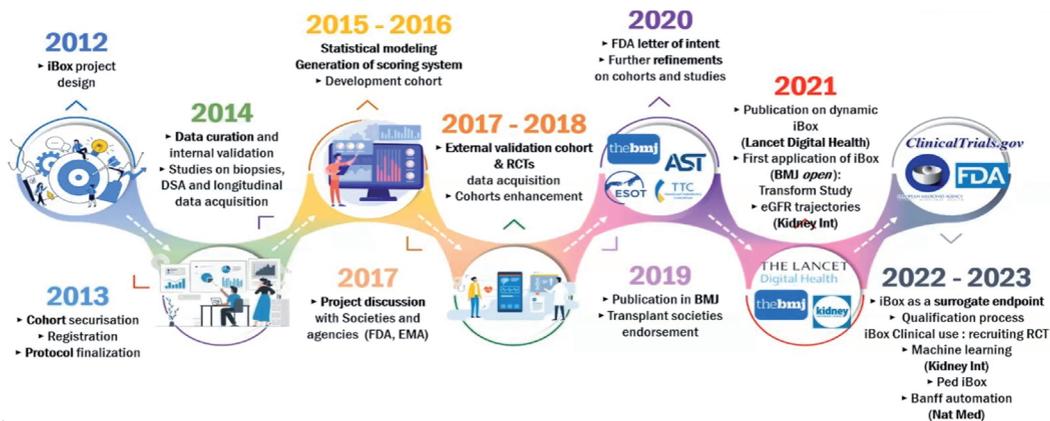
en *random forests*, *gradient boosting* y redes neuronales que pronostican la supervivencia del injerto a 5 años con mayor exactitud que el sistema de puntuación convencional. Un estudio de Mark y cols. combinó múltiples algoritmos (*ensemble*) y logró un índice de concordancia de 0,724 en predicción de supervivencia a cinco años, superando al 0,697 obtenido con la puntuación EPTS de UNOS [11]. De manera similar, Ramalhete y cols. reportaron que algoritmos de ML pueden conectar factores clínicos con resultados en trasplante de forma más robusta, proporcionando a clínicos y pacientes estimaciones individualizadas de pronóstico y ayudando a identificar la pareja donante-receptor óptima [16].

El iBox es una herramienta predictiva desarrollada para estimar con precisión el riesgo de fallo del injerto renal a largo plazo en pacientes trasplantados. Este sistema combina múltiples variables clínicas, histológicas e inmunológicas para ofrecer una evaluación

detallada del pronóstico del injerto. El iBox fue desarrollado a partir de una cohorte de 4.000 receptores de trasplante renal en Francia entre 2005 y 2014. Posteriormente, se validó en dos cohortes adicionales: una europea con 2.129 pacientes y otra norteamericana con 1.428 pacientes, reclutados entre 2002 y 2014. Además, su eficacia se confirmó en tres ensayos clínicos aleatorizados [17, 18].

El proyecto iBox comenzó en 2012 con el diseño inicial del sistema (Figura 9). En 2013 se aseguraron las cohortes, se realizó el registro y se finalizó el protocolo de estudio. Durante 2014, se llevó a cabo la depuración de datos y la validación interna, además de estudios sobre biopsias, anticuerpos donante-específicos (DSA) y adquisición de datos longitudinales. Entre 2015 y 2016, se desarrolló el modelo estadístico y se generó el sistema de puntuación utilizando la cohorte de desarrollo. En los años 2017 y 2018, el sistema se validó externamente mediante cohortes y ensayos clínicos

**FIGURA 9.** Desarrollo del sistema de predicción iBox para el riesgo de pérdida del aloinjerto en pacientes que reciben trasplantes de riñón



ATI Research Day 2023 Keynote - Alexandre Loupy

aleatorizados (RCTs), al tiempo que se fortalecieron las cohortes. Durante este período también se iniciaron discusiones del proyecto con sociedades científicas y agencias regulatorias como la FDA y la EMA. En 2019, se publicó el iBox en el *British Medical Journal* [17] y obtuvo el respaldo de sociedades de trasplante. En 2020, la FDA emitió una carta de intención para su evaluación, y se realizaron mejoras adicionales en cohortes y estudios. Entre 2022 y 2023, el iBox fue utilizado como criterio de valoración sustituto (*surrogate endpoint*) y se inició su proceso de calificación. Se incorporó en ensayos clínicos reclutados, con aplicaciones que incluyen aprendizaje automático, la versión pediátrica y la automatización del sistema Banff.

Un resultado temprano crítico es la función retrasada del injerto (DGF), definida convencionalmente por la necesidad de diálisis en la primera semana postrasplante. La DGF se asocia a mayor riesgo de rechazo y menor supervivencia del injerto, además de prolongar la hospitalización y costos. Predecir qué trasplantes tendrán DGF permite tomar medidas para mitigarlo. La IA ha sido aplicada en este ámbito desde hace décadas: ya en 1998, Shoskes y cols. entrenaron una red neuronal en datos de 100 trasplantes cadavéricos para anticipar la DGF, logrando 80 % de precisión, y sugirieron que tal modelo podría apoyar decisiones al considerar órganos de donantes marginales o receptores de alto riesgo [19]. En un análisis, un modelo XGBoost, Kotsifa y cols. identificaron variables del cuidado del donante (diuresis, presión arterial, dosis de vasopresores, etc.) fuertemente asociadas a DGF, alcanzando AUC 0,78; con ello podría señalar qué riñones se beneficiarían de intervenciones como perfusión máquina para mejorar resultados [2].

Sin embargo, no todos los estudios encuentran superioridad clara de ML sobre métodos estadísticos tradicionales y, de hecho,

en algunas cohortes, algoritmos de ML no superaron sustancialmente al análisis multivariado convencional en predecir rechazo o falla del injerto. Esto sugiere que la calidad de los datos y la selección de variables son determinantes. En cualquier caso, la tendencia apunta a que los modelos predictivos híbridos (clínico+IA) se integren a las plataformas de trasplante para estratificar riesgos: quién tiene más probabilidad de perder el injerto en ciertos plazos, quién podría tener complicaciones, etc., de forma que se personalice el seguimiento y eventualmente se mejore la supervivencia a largo plazo del trasplante.

#### 7.4 APLICACIONES VISUALES DE IA EN LA EVALUACIÓN DEL INJERTO RENAL: IMÁGENES MÉDICAS Y ANÁLISIS DE TEJIDOS

La IA aplicada a datos visuales (imágenes médicas y de patología) está revolucionando la evaluación del injerto renal tanto antes como después del trasplante. Por un lado, las técnicas de visión por computador permiten analizar estudios de imagen (ecografías, tomografías, resonancias) para extraer información cuantitativa sobre la anatomía y función del riñón trasplantado. Por otro lado, la patología digital asistida por Deep Learning facilita la interpretación de biopsias renales y otras muestras de tejido, identificando lesiones microscópicas con alta precisión. A continuación, se detallan algunas aplicaciones visuales destacadas:

##### 7.4.1 Imagen médica y segmentación renal asistidas por IA

En el contexto de trasplante renal, las imágenes diagnósticas (ultrasonido, TAC, RM) son fundamentales para monitorear la posición del injerto, perfusión vascular y descartar complicaciones (trombosis, estenosis, colecciones líquidas, etc.). La IA está potenciando este campo a través de algoritmos de segmentación

y detección de anomalías. Por ejemplo, redes neuronales convolucionales entrenadas en ecografías pueden segmentar automáticamente el parénquima renal trasplantado y medir su volumen, permitiendo un seguimiento objetivo de cambios en la talla del injerto o la aparición de edema. De igual modo, en resonancia magnética se han desarrollado modelos que analizan imágenes de difusión para detectar patrones sutiles asociados al rechazo: un estudio incorporó imágenes por difusión en un sistema de diagnóstico asistido por computador que apoyó la identificación de rechazo sin necesidad de biopsia, sirviendo como alarma temprana en pacientes con contraindicación para biopsia [3].

#### 7.4.2 Realidad aumentada y visión artificial

Otra aplicación innovadora es el uso de realidad aumentada (AR) y visión artificial en el acto quirúrgico. Durante la Cirugía de trasplante, técnicas de imagen intraoperatoria asistidas por IA pueden guiar al cirujano. Por ejemplo, sistemas de AR proyectan una representación tridimensional de los vasos sanguíneos del receptor y la posición óptima del injerto obtenida del TAC preoperatorio, ayudando a planificar anastomosis con mayor precisión. Algoritmos de visión identifican estructuras críticas en tiempo real y podrían señalar sitios ideales de incisión o alertar sobre posibles colisiones anatómicas [20,21]. Además, en el periodo postoperatorio inmediato, la IA puede monitorizar las imágenes de perfusión del injerto; por ejemplo, evaluando por ultrasonido doppler el flujo en la arteria renal y detectando si hay signos de trombosis incipiente mejor que la inspección visual humana. Aunque estas herramientas están en desarrollo, apuntan a reducir errores y acelerar la detección de complicaciones.

En la fase de preservación de órganos, se está utilizando visión artificial para evaluar

riñones ex vivo antes del implante. Un avance notable es la combinación de imagen hiperespectral (HSI) con ML durante la perfusión máquina del riñón donado. La HSI capta información en un espectro amplio de longitudes de onda (incluyendo infrarrojo y ultravioleta), revelando detalles sobre la fisiología y composición tisular que no son visibles a simple vista [22]. Dado que HSI genera enormes cantidades de datos, se emplean CNNs para interpretarlos. Markgraf y cols. entrenaron modelos de visión profunda para clasificar riñones perfundidos en tres categorías de función (no funcional, función limitada o funcional) basándose en la dinámica de excreción de inulina durante la perfusión. En sus pruebas, el modelo alcanzó una exactitud entre 84 % y 96 % en validación interna, y entre 62 % y 100 % en conjuntos de prueba, dependiendo de la categoría [23] y concluyeron que la combinación de HSI con algoritmos de IA permite valorar objetivamente la calidad pre-trasplante de riñón y respaldar la decisión de aceptar o descartar un órgano [24]. Esto es particularmente valioso para riñones de donantes marginales, donde la aceptación del órgano es incierta; la IA podría predecir si el injerto recuperará función adecuada, optimizando así el uso de órganos disponibles.

#### 7.4.3 Patología digital renal y análisis de tejidos con IA

La patología digital es otra área de gran impacto visual. En trasplante renal, las biopsias del injerto (ya sean protocolarias o indicadas por disfunción) deben ser examinadas minuciosamente para diagnosticar rechazo agudo (ya sea mediado por células T o por anticuerpos), nefropatía crónica del trasplante, recurrencia de la enfermedad primaria o toxicidad farmacológica, entre otros diagnósticos. La IA, mediante algoritmos de Deep Learning, ha demostrado mejorar la consistencia y rapidez en este análisis (Tabla 11).

**TABLA 11.** Patología digital renal en trasplante renal

AUTOR(ES)	MODELO DESARROLLADO	OBJETIVOS
Kers et al. [4]	Modelo de Deep Learning para clasificación de biopsias renales.	Clasificar biopsias en rechazo vs. no rechazo con alta concordancia y priorizar las sospechosas para revisión.
Ye et al. [5]	Renal Rejection Artificial Intelligence Model (RRAIM)	Subtipificar el rechazo en biopsias teñidas con H&E y predecir la evolución del rechazo con AUC >0.9.
Hermesen et al. [25]	Análisis de infiltrados celulares con CNNs e inmunohistoquímica (CD45)	Cuantificar infiltrados celulares en el rechazo del injerto, mejorando la evaluación inmunitaria con CNNs.
Yi et al. [26]	Kidney Donor Quality Score basado en Deep Learning	Predecir la evolución del injerto mediante análisis multimodal y mejorar la asignación de órganos con menor descarte.

Como se mencionó en secciones previas, CNNs entrenadas con miles de imágenes de biopsias pueden aprender a reconocer patrones morfológicos complejos. Kers y cols. reportaron que un modelo de Deep Learning podía clasificar biopsias en rechazo vs. no rechazo con alta concordancia, y subrayaron que tales sistemas podrían servir como herramienta de triaje digital, identificando las biopsias sospechosas de rechazo para revisión prioritaria por el patólogo [4]. Más recientemente, Ye y cols. desarrollaron un modelo denominado Renal Rejection Artificial Intelligence Model (RRAIM) para subtipificar el rechazo en biopsias teñidas con H&E. Este modelo, basado en aprendizaje por instancias múltiples, diferenciaba rechazo mediado por células T, rechazo mediado por anticuerpos y otras lesiones con un AUC global de 0,80, superando el diagnóstico de patólogos experimentados en condiciones de evaluación de rutina [5]. Además, construyeron modelos adicionales que, usando la información de la biopsia digitalizada, lograron predecir la evolución del rechazo: por ejemplo, podían estimar con AUC >0,9 qué pacientes con rechazo agudo perderían el injerto en el año siguiente a pesar

del tratamiento, algo invaluable para guiar terapias más agresivas cuando se identifica un rechazo de mal pronóstico. Estos resultados ejemplifican cómo la patología computacional va más allá del diagnóstico estático y se adentra en el terreno del pronóstico y la medicina personalizada, al cuantificar la severidad de lesiones (inflamación, fibrosis, daño vascular) de manera reproducible.

Otra ventaja de la IA en patología es la capacidad de detectar características que pueden pasar inadvertidas. Por ejemplo, algoritmos pueden cuantificar con precisión el porcentaje de esclerosis glomerular o de fibrosis intersticial en una biopsia, datos que correlacionan con la vida media del injerto. También se han utilizado redes neuronales para analizar preparaciones especiales: Hermesen y cols. emplearon coloraciones inmunohistoquímicas (CD45) con herramientas de análisis de imágenes para cuantificar infiltrados celulares, demostrando que las CNN pueden mejorar la evaluación de la infiltración inmunitaria en el rechazo [25]. De igual forma, la IA puede integrar hallazgos morfológicos con datos moleculares de la misma biopsia (técnica conocida como análisis multimodal),

ofreciendo un diagnóstico más completo. Un estudio de Yi y cols. analizó biopsias de preimplante (congeladas durante la procuración del órgano) mediante Deep Learning para predecir la evolución del injerto: el modelo identificó lesiones como fibrosis arterial e intersticial y las correlacionó con datos de seguimiento, derivando un índice de calidad del donante (Kidney Donor Quality Score). Dicho índice mostró mejorar la predicción de supervivencia del injerto y podría ayudar a reducir descartes innecesarios de órganos [26].

En resumen, las aplicaciones visuales de IA en trasplante renal abarcan desde el quirófano (guía quirúrgica y perfusión de órganos) hasta el laboratorio de patología. La segmentación automatizada y análisis de imágenes médicas mejoran la vigilancia posoperatoria, mientras que la patología digital con IA aporta diagnósticos más rápidos y estandarizados, e incluso información pronóstica del injerto. Estas herramientas, tras validación clínica adecuada, tienen el potencial de integrarse al flujo de trabajo del trasplante para asistir en la toma de decisiones en tiempo real y mejorar los resultados.

### 7.5 IA EN LA SELECCIÓN DE DONANTES Y RECEPTORES

Dada la escasez de órganos, asignar el riñón correcto al paciente indicado es crítico. Tradicionalmente, como vimos anteriormente, los sistemas de asignación de riñones (como el Kidney Allocation System, en EE.UU.) utilizan reglas basadas en puntuaciones como el KDPI (índice de perfil del donante) y el EPTS (estimación de supervivencia postrasplante) para emparejar donantes y receptores [13]. Si bien estas herramientas objetivas han mejorado la equidad, aún presentan limitaciones, pues se basan en un conjunto limitado de variables y no capturan plenamente la complejidad de cada caso. La IA se postula para revolucionar

la asignación mediante algoritmos inteligentes que analicen múltiples criterios simultáneamente y aprendan de datos históricos qué combinaciones donante-receptor conllevan mejores resultados.

#### 7.5.1 Emparejamiento óptimo donante-receptor

Usando ML, Paquette y cols. desarrollaron un sistema de apoyo a decisiones para trasplante renal que, alimentado con datos de múltiples centros, evalúa la probabilidad de éxito de distintas combinaciones donante-receptor en tiempo real. Empleando modelos de supervivencia de aprendizaje profundo (p. ej. DeepSurv), estiman las probabilidades de supervivencia del injerto para cada posible emparejamiento, superando en calibración y poder predictivo a métodos tradicionales como la regresión de Cox [27]. Esto permite que, cuando hay un órgano disponible, el algoritmo sugiera el receptor en lista cuya supervivencia proyectada con ese órgano sería máxima, mejorando la precisión del *matching* y aprovechando al máximo la donación. En EE.UU. ya se han comenzado a incorporar algoritmos de ML en el sistema de asignación, especialmente para donantes fallecidos donde el tiempo apremia y una decisión informada es crucial. De este modo, la IA puede considerar en pocos segundos factores como: compatibilidad HLA, tamaño del donante vs receptor, tiempo de isquemia fría, urgencia del receptor, calidad estimada del órgano, distancia geográfica, etc., optimizando el equilibrio entre utilidad (maximizar años de vida del injerto) y equidad (distribución justa).

#### 7.5.2. IA y decisión de aceptar o rechazar un órgano ofrecido

No todos los riñones ofertados terminan en trasplante; un porcentaje se descarta por criterios de calidad. Modelos inteligentes pueden guiar estas decisiones de manera más

precisa que las reglas estáticas. Por ejemplo, un algoritmo entrenado con datos de seguimiento predijo con alta exactitud qué riñones inicialmente considerados de “criterios expandidos” aún proporcionarían supervivencias aceptables [28]. Así, se evitaría descartar órganos que, aunque de mayor riesgo, podrían beneficiar a ciertos receptores de alto perfil inmunológico o mayores de edad. Como se mencionó anteriormente, la evaluación automatizada de biopsias de donante con Deep Learning (identificando esclerosis glomerular, fibrosis arterial, etc.) llevó al desarrollo de un puntaje de calidad de órgano que correlaciona con la supervivencia real postrasplante. Ese Kidney Donor Quality Score podría integrarse en las decisiones de oferta: un riñón con puntuación alta debería aprovecharse, asignándolo al receptor adecuado, mientras que uno con puntuación muy baja tal vez convenga desecharlo para no exponer a un paciente a un injerto de mal pronóstico.

### 7.5.3 IA y optimización de la logística y gestión de listas de espera

Algoritmos de priorización inteligentes, como el sistema Smart Match, prometen minimizar la mortalidad en lista de espera y mejorar el bienestar del paciente al agilizar la asignación óptima de órganos. Estos sistemas aprenden de experiencias pasadas identificando patrones de qué pacientes se benefician más de ciertos órganos, e incluso pueden simular escenarios de asignación futuros. Un estudio reciente propuso la plataforma «Nephron», un sistema basado en ML que probó múltiples clasificadores (árboles de decisión, *random forest*, redes neuronales, etc.) para seleccionar el receptor ideal para un donante dado. Su mejor modelo (*gradient boosting*) alcanzó una sorprendente precisión del 98 % en la concordancia de emparejamientos simulados,

superando métodos de similitud convencionales, y demostró ser flexible para adaptarse a criterios de distintas regiones [29]. Si bien este resultado debe validarse prospectivamente, ilustra el potencial de la IA para hacer más eficiente y justa la distribución de órganos. A medida que estas técnicas maduren, es esperable que los sistemas de asignación incorporen componentes de IA que consideren más variables y optimicen objetivos múltiples (maximizar supervivencia del injerto, minimizar tiempo en diálisis, reducir transporte de órganos, etc.)

Por tanto, al aprender de decenas de miles de trasplantes previos, estos algoritmos pueden sugerir decisiones de aceptación y asignación más informadas, con el potencial de aumentar la utilidad global del trasplante renal (más años de vida del injerto acumulados) y reducir al mismo tiempo inequidades. No obstante, es importante garantizar la transparencia y equidad de estos modelos, evitando sesgos aprendidos de datos históricos que pudieran perpetuar desigualdades en el acceso al trasplante.

### 7.5.4 Análisis de datos y modelos predictivos en compatibilidad y resultados postrasplante

La compatibilidad inmunológica entre donante y receptor es uno de los pilares para el éxito del trasplante renal. Tradicionalmente, esta compatibilidad se evalúa mediante grupo sanguíneo ABO, tipificación de antígenos HLA y detección de anticuerpos del receptor contra los HLA del donante (*crossmatch*). No obstante, el sistema inmunológico presenta matices que pueden escapar a estos parámetros convencionales. La IA ofrece herramientas para analizar bases de datos complejas de incompatibilidades y resultados, con el fin de descubrir patrones que asocien ciertos emparejamientos con riesgo alto o bajo de complicaciones inmunológicas.

- Un ejemplo es la predicción de la formación de anticuerpos de novo postrasplante (donor-specific antibodies, DSA). Investigadores han aplicado ML a datos pre-trasplante de pacientes para identificar qué factores predisponen a desarrollar DSA, los cuales a su vez pueden causar rechazo mediado por anticuerpos. Variables como la carga inmunogénica de los epítomos HLA (diferencias finas entre las moléculas HLA del donante y receptor), el perfil genético del receptor o marcadores de activación inmunitaria podrían integrarse en modelos predictivos. Un estudio utilizó aprendizaje automático para examinar factores pretrasplante asociados al desarrollo de DSA y logró identificar subconjuntos de pacientes de alto riesgo, proporcionando una estratificación más refinada que la mera cantidad de incompatibilidades HLA [30]. Aunque este campo está en desarrollo, sugiere que la IA podría mejorar la evaluación de compatibilidad funcional más allá del conteo de *mismatches*, prediciendo qué incompatibilidades son clínicamente relevantes.
- Asimismo, la IA ha sido empleada para reevaluar los índices de riesgo tradicionales. Por ejemplo, investigadores compararon algoritmos de ML versus modelos convencionales para predecir diversos desenlaces a partir de datos de registro nacional de trasplantes [31]. En algunos casos, ML demostró ser más útil cuando la relación entre variables y desenlace no es lineal o es altamente interactiva. Por el contrario, cuando los datos son completos y las relaciones relativamente sencillas, los métodos tradicionales pueden desempeñarse de forma similar (lo cual refuerza la importancia de seleccionar cuidadosamente la aplicación de ML a problemas donde aporte valor añadido real).
- Un área donde los modelos predictivos avanzados sí han mostrado clara utilidad es en la supervivencia del injerto condicionada a la compatibilidad. Como se mencionó, algoritmos de aprendizaje han incorporado variables como número específico de incompatibilidades HLA-A, B, DR, presencia de determinados anticuerpos, edades del donante y receptor, etc., para proyectar la longevidad esperada del injerto en diferentes escenarios de compatibilidad [1]. Por ejemplo, un modelo podría indicar que un receptor joven con PRA elevado tendría mayor supervivencia esperada si espera un donante con 0 incompatibilidades HLA-DR, mientras que para otro receptor de menor PRA la ganancia es marginal. Este tipo de análisis de datos a gran escala puede informar políticas de asignación más granulares (priorizar compatibilidad máxima para quienes más se benefician de ella).

En cuanto a resultados postrasplante, los modelos predictivos ya están ayudando a evaluar pronósticos individualizados. Herramientas en línea, algunas impulsadas por ML, permiten ingresar las características de un donante y un receptor y obtener la probabilidad estimada de supervivencia del injerto a X años. Esto apoya la toma de decisiones clínicas complejas, como aceptar un órgano de mayor riesgo para un receptor que quizás no sobreviva mucho más en diálisis, versus esperar un órgano ideal. Un caso práctico es la implementación de modelos de pronóstico en programas de trasplante para guiar la lista de espera: pacientes con baja probabilidad de beneficio neto podrían enfocarse en tratamientos alternativos, mientras que otros con alto beneficio proyectado se priorizan para ciertos órganos. La IA facilita simular estos escenarios con más precisión que antes [32].

Cabe destacar que los análisis masivos de datos de trasplante han corroborado muchos factores clásicos de riesgo, pero también han revelado algunos sorprendentes. En un amplio estudio de aprendizaje automático, además de las variables conocidas (edad, incompatibilidades, tiempo en diálisis), emergieron factores como la hipertensión del donante repetidamente incluidos en la mayoría de algoritmos exitosos, señalando su importancia subestimada en el desenlace del injerto [1]. Este hallazgo, coherente en distintos modelos, sugiere que la historia médica del donante (por ejemplo, si tuvo hipertensión, diabetes, hábito de fumar) influye más de lo que se reflejaba en los índices tradicionales. Del mismo modo, el análisis de interacciones complejas ha planteado hipótesis, como que ciertos pares de incompatibilidades HLA concretas disparan riesgo de rechazo mucho más que otras, algo que podría orientar futuras estrategias de emparejamiento virtual óptimo.

La IA aplicada al análisis de compatibilidad y resultados está afinando nuestra comprensión de qué hace exitoso un trasplante. Los modelos predictivos integrales pueden servir tanto a nivel micro (decisiones para un paciente específico) como macro (políticas de asignación y manejo de la lista de espera), siempre con el objetivo de mejorar los resultados postrasplantes. A medida que se disponga de más datos (por ejemplo, integración de datos *-ómicos* e históricos de cada trasplante), estos modelos serán aún más potentes para guiar la práctica clínica basada en evidencia real.

#### 7.6 IMPACTO DE LA IA EN LA OPTIMIZACIÓN DE RECURSOS Y LA ATENCIÓN AL PACIENTE CON TRASPLANTE RENAL

La incorporación de la inteligencia artificial en trasplante renal conlleva también beneficios en términos de eficiencia del sistema

de salud y mejora de la atención al paciente. En primer lugar, al afinar las predicciones y diagnósticos, la IA permite una toma de decisiones más precisa, lo que evita intervenciones innecesarias y focaliza los recursos donde más se necesitan. Por ejemplo, un modelo fiable que prediga rechazo agudo podría ahorrar biopsias de descarte en pacientes de bajo riesgo y, a la vez, recomendar intervenciones tempranas en pacientes de alto riesgo, previniendo hospitalizaciones por rechazos severos. De hecho, en el ejemplo citado de detección de rechazo vía creatinina, el algoritmo superó a clínicos en identificar rechazos incipientes, lo que supone tratar antes al paciente y potencialmente evitar daño mayor al injerto [6].

En el ámbito de la asignación de órganos, la IA contribuye a una utilización óptima de la escasa oferta de donantes. Herramientas como *Smart Match* pretenden minimizar la mortalidad en lista de espera, priorizando inteligentemente a los pacientes y asignando los órganos de forma que se maximice el beneficio global [32]. Esto podría traducirse en más pacientes trasplantados exitosamente y menos tiempo promedio en diálisis (con las consiguientes reducciones de costos dialíticos y mejoras en calidad de vida). Asimismo, al reducir descartes innecesarios de órganos viables (gracias a evaluaciones más certeras de calidad por IA), se aumenta el número de trasplantes realizados sin incrementar los riesgos. Un órgano marginal que antes se hubiera descartado por incertidumbre, ahora con apoyo de IA puede asignarse a un receptor apropiado con expectativas realistas de resultado.

Otro punto de impacto es la optimización de los tratamientos. La IA permite personalizar la inmunosupresión: modelos que predicen niveles óptimos de fármacos como tacrolimus o ciclosporina en base a factores farmacogenómicos y clínicos pueden evitar tanto la infra-inmunosupresión (riesgo de

rechazo) como la sobreexposición (riesgo de nefrotoxicidad e infecciones) [33]. Igualmente se han usado redes neuronales para predecir concentraciones sanguíneas de ciclosporina con notable exactitud considerando enzimas hepáticas, edad del paciente, interacciones medicamentosas, etc., lo que guía al clínico en la dosis más segura y efectiva [34].

En el entorno hospitalario, la IA puede agilizar flujos de trabajo. En quirófano, por ejemplo, sistemas de apoyo quirúrgico con IA monitorizan constantes y progresión de la Cirugía, pudiendo predecir la duración restante del procedimiento y necesidades de recursos en tiempo real. Esto permite planificar mejor el quirófano y el personal, reduciendo tiempos ociosos y aumentando la productividad. Asimismo, como ya hemos comentado, robots quirúrgicos con IA mejoran la estabilidad y precisión en las anastomosis vasculares, lo que puede reducir complicaciones postoperatorias (como sangrados o estenosis) y acortar la estancia hospitalaria [20,21]. En el área formativa, simuladores inteligentes entrenan a cirujanos en técnicas de trasplante, acelerando la curva de aprendizaje de manera segura y estandarizada [35].

Desde la perspectiva del paciente trasplantado, contar con IA significa potencialmente mejor seguimiento y empoderamiento. Por ejemplo, aplicaciones móviles con algoritmos de IA podrían alertar al paciente y al equipo médico si ciertos datos (tensión arterial, peso, creatinina domiciliaria) sugieren un problema, permitiendo intervención precoz. Ya existen chatbots y asistentes virtuales que educan al paciente en autocuidado postrasplante y promueven adherencia a medicamentos, usando procesamiento de lenguaje natural para interactuar de forma personalizada [2]. Todo ello redundará en pacientes más informados, menos incidencias por descuidos y, en última instancia, mayor supervivencia del injerto.

Es importante mencionar que, si bien el impacto positivo de la IA es evidente, su implementación debe hacerse con precaución. Persisten retos como la necesidad de datos de alta calidad y representatividad para entrenar los modelos, evitando sesgos que reproduzcan inequidades. También se requieren infraestructuras adecuadas y capacitación de los profesionales de la salud para interpretar y confiar en las recomendaciones de la IA. Aproximadamente una cuarta parte de los médicos expresa inquietud sobre las dificultades técnicas al integrar IA en su práctica, lo que subraya la importancia de involucrar a los clínicos en el diseño e implementación de estas herramientas. Con abordajes interdisciplinarios y validaciones rigurosas, la IA podrá integrarse de forma segura, actuando como un refuerzo y no un reemplazo de la experticia humana en el cuidado del trasplante.

La visión a futuro es la de un ecosistema de trasplante renal apoyado por IA en cada fase –desde la procuración del órgano hasta el seguimiento a largo plazo–, logrando resultados que antes no eran posibles y llevando la atención del paciente a un nuevo nivel de precisión y eficacia [36].

## REFERENCIAS

- 1 Mizera J, Pondel M, Kepinska M, Jerzak P, Banasik M. Advancements in Artificial Intelligence for Kidney Transplantology: A Comprehensive Review of Current Applications and Predictive Models. *J Clin Med.* 2025;14(3):975.
- 2 Kotsifa E, Mavroeidis VK. Present and Future Applications of Artificial Intelligence in Kidney Transplantation. *J Clin Med.* 2024;13(19):5939.
- 3 Belčič Mikič T, Arnol M. The Use of Machine Learning in the Diagnosis of Kidney Allograft Rejection: Current Knowledge and Applications. *Diagnostics (Basel).* 2024;14(22):2482.

- 4 Kers J., Bülow R.D., Klinkhammer B.M., Breimer G.E., Fontana F., Abiola A.A., Hofstraat R., Corthals G.L., Peters-Sengers H., Djudjaj S., et al. Deep Learning -Based Classification of Kidney Transplant Pathology: A Retrospective, Multicentre, Proof-of-Concept Study. *Lancet Digit. Health.* 2022;4:e18–e26.
- 5 Ye Y, Xia L, Yang S, Luo Y, Tang Z, Li Y, Han L, Xie H, Ren Y, Na N. Deep Learning -enabled classification of kidney allograft rejection on whole slide histopathologic images. *Front Immunol.* 2024;15: 1438247.
- 6 Fritsche L., Schlaefer A., Budde K., Schroeter K., Neumayer H.H. Recognition of critical situations from time series of laboratory results by case-based reasoning. *J. Am. Med. Inform. Assoc.* 2002; 9:520–528.
- 7 Fang F, Liu P, Song L, Wagner P, Bartlett D, Ma L, Li X, Rahimian MA, Tseng G, Randhawa P, Xiao K. Diagnosis of T-cell-mediated kidney rejection by biopsy-based proteomic biomarkers and Machine Learning. *Front Immunol.* 2023;14:1090373.
- 8 Metzger J., Chatzikyrkou C., Broecker V., Schiffer E., Jaensch L., Iphoefer A., Mengel M., Mullen W., Mischak H., Haller H., et al. Diagnosis of subclinical and clinical acute T-cell-mediated rejection in renal transplant patients by urinary proteome analysis. *Proteom. Clin. Appl.* 2011;5:322–333.
- 9 Pineda S, Sur S, Sigdel T, Nguyen M, Crespo E, Torija A, Meneghini M, Gomà M, Sirota M, Bestard O, Sarwal MM. Peripheral Blood RNA Sequencing Unravels a Differential Signature of Coding and Noncoding Genes by Types of Kidney Allograft Rejection. *Kidney Int Rep.* 2020;5(10):1706-1721.
- 10 Zhang JL, Ma Y, Liu JY, et al. Evaluation of diffusion tensor imaging for detecting acute rejection and chronic allograft nephropathy in renal transplant patients: A prospective study. *J Magn Reson Imaging.* 2024;59(1):111–121.
- 11 Mark E., Goldsman D., Gurbaxani B., Keskinocak P., Sokol J. Using Machine Learning and an Ensemble of Methods to Predict Kidney Transplant Survival. *PLoS ONE.* 2019;14:e0209068.
- 12 Yoo D., Divard G., Raynaud M., Cohen A., Mone T.D., Rosenthal J.T., Bentall A.J., Stegall M.D., Naesens M., Zhang H., et al. A Machine Learning-Driven Virtual Biopsy System for Kidney Transplant Patients. *Nat. Commun.* 2024;15:554.
- 13 Rao P.S., Schaubel D.E., Guidinger M.K., Andreoni K.A., Wolfe R.A., Merion R.M., Port F.K., Sung R.S. A comprehensive risk quantification score for deceased donor kidneys: The kidney donor risk index. *Transplantation.* 2009;88:231–236.
- 14 Clayton P.A., McDonald S.P., Snyder J.J., Salkowski N., Chadban S.J. External validation of the estimated posttransplant survival score for allocation of deceased donor kidneys in the United States. *Am. J. Transplant.* 2014;14:1922–1926.
- 15 Stegall, M.D.; Stock, P.G.; Andreoni, K.; Friedewald, J.J.; Leichtman, A.B. Why do we have the kidney allocation system we have today? A history of the 2014 kidney allocation system. *Hum. Immunol.* 2017, 78, 4–8.
- 16 Ramalhete L., Almeida P., Ferreira R., Abade O., Teixeira C., Araújo R. Revolutionizing Kidney Transplantation: Connecting Machine Learning and Artificial Intelligence with Next-Generation Healthcare—From Algorithms to Allografts. *BioMedInformatics.* 2024; 4:673–689.
- 17 Loupy A, Aubert O, Orandi BJ, Naesens M, Bouatou Y, Raynaud M, Divard G, et al. Prediction system for risk of allograft loss in patients receiving kidney transplants: international derivation and validation study. *BMJ.* 2019;366:l4923.
- 18 Rampersad C, Bau JT, Orchanian-Cheff A, Kim SJ. iBox as a Predictor of Kidney Allograft Failure: A Systematic Review. *Am J Kidney Dis.* 2025;S0272-6386(25)00702-4.
- 19 Shoskes D.A., Ty R., Barba L., Sender M. Prediction of early graft function in renal transplantation using a computer neural network. *Transplant. Proc.* 1998;30: 1316–1317.
- 20 De Backer P, Van Praet C., Simoens J., Peraire Lores M., Creemers H., Mestdagh K., Allaeyns C., Vermijs S., Piazza P, Mottaran A., et al.

- Improving Augmented Reality Through Deep Learning: Real-time Instrument Delineation in Robotic Renal Surgery. *Eur. Urol.* 2023;84:86–91. <https://doi.org/10.1016/j.eururo.2023.02.024>
- 21 Piana A., Gallioli A., Amparore D., Diana P., Territo A., Campi R., Gaya J.M., Guirado L., Checcucci E., Bellin A., et al. Three-dimensional Augmented Reality-guided Robotic-assisted Kidney Transplantation: Breaking the Limit of Atheromatic Plaques. *Eur. Urol.* 2022;82:419–426.
  - 22 Lu G., Fei B. Medical hyperspectral imaging: A review. *J. Biomed. Opt.* 2014;19:10901.
  - 23 Markgraf W., Malberg H. Preoperative Function Assessment of Ex Vivo Kidneys with Supervised Machine Learning Based on Blood and Urine Markers Measured during Normothermic Machine Perfusion. *Biomedicines.* 2022; 10:3055.
  - 24 Sommer F., Sun B., Fischer J., Goldammer M., Thiele C., Malberg H., Markgraf W. Hyperspectral Imaging during Normothermic Machine Perfusion-A Functional Classification of Ex Vivo Kidneys Based on Convolutional Neural Networks. *Biomedicines.* 2022;10:397.
  - 25 Hermesen M., Ciompi F., Adefidipe A., Denic A., Dendooven A., Smith B.H., van Midden D., Brasen J.H., Kers J., Stegall M.D., et al. Convolutional Neural Networks for the Evaluation of Chronic and Inflammatory Lesions in Kidney Transplant Biopsies. *Am. J. Pathol.* 2022;192:1418–1432.
  - 26 Yi Z., Xi C., Menon M.C., Cravedi P., Tedla F., Soto A., Sun Z., Liu K., Zhang J., Wei C., et al. A Large-Scale Retrospective Study Enabled Deep-Learning Based Pathological Assessment of Frozen Procurement Kidney Biopsies to Predict Graft Loss and Guide Organ Utilization. *Kidney Int.* 2024;105:281–292.
  - 27 Paquette F.X., Ghassemi A., Bukhtiyarova O., Cisse M., Gagnon N., Della Vecchia A., Rabearivelo H.A., Loudiyi Y. Machine Learning Support for Decision-Making in Kidney Transplantation: Step-by-Step Development of a Technological Solution. *JMIR Med. Inform.* 2022; 10:e34554.
  - 28 Schwantes I.R., Axelrod D.A. Technology-Enabled Care and Artificial Intelligence in Kidney Transplantation. *Curr. Transplant. Rep.* 2021; 8:235–240.
  - 29 Alowidi N, Ali R, Sadaqah M, Naemi FMA. Advancing Kidney Transplantation: A Machine Learning Approach to Enhance Donor-Recipient Matching. *Diagnostics (Basel).* 2024;14(19):2119.
  - 30 Rothwell A, Nita G, Howse M, y cols Using Machine Learning to Examine Pre-Transplant Factors Influencing De novo HLA-Specific Antibody Development Post-Kidney Transplant medRxiv 2024.10.28.24315920.
  - 31 Bae S, Massie AB, Caffo BS, Jackson KR, Segev DL. Machine Learning to predict transplant outcomes: helpful or hype? A national cohort study. *Transpl Int.* 2020;33(11):1472-1480.
  - 32 Deshpande R Smart match: revolutionizing organ allocation through artificial intelligence *Front. Artif. Intell.* 2024;7.
  - 33 Zhang Q., Tian X., Chen G., Yu Z., Zhang X., Lu J., Zhang J., Wang P., Hao X., Huang Y., et al. A Prediction Model for Tacrolimus Daily Dose in Kidney Transplant Recipients with Machine Learning and Deep Learning Techniques. *Front. Med.* 2022;9:813117.
  - 34 Gören S., Karahoca A., Onat F.Y., Gören M.Z. Prediction of Cyclosporine A Blood Levels: An Application of the Adaptive-Network-Based Fuzzy Inference System (ANFIS) in Assisting Drug Therapy. *Eur. J. Clin. Pharmacol.* 2008; 64:807–814.
  - 35 Vedula S.S., Ishii M., Hager G.D. Objective Assessment of Surgical Technical Skill and Competency in the Operating Room. *Annu. Rev. Biomed. Eng.* 2017;19:301–325.
  - 36 He YJ, Liu PL, Wei T, Liu T, Li YF, Yang J, Fan WX. Artificial intelligence in kidney transplantation: a 30-year bibliometric analysis of research trends, innovations, and future directions. *Ren Fail.* 202;47(1):2458754.



## 8.

### APLICACIÓN DE LA IA EN ENFERMEDADES GLOMERULARES

---

Las enfermedades glomerulares comprenden un amplio espectro de glomerulopatías (p. ej., nefropatía IgA, glomeruloesclerosis focal y segmentaria, membranosa, lupus eritematoso sistémico con nefritis, entre otras) que a menudo requieren biopsia renal para un diagnóstico preciso. La interpretación de biopsias es un proceso laborioso y sujeto a variabilidad entre patólogos. En este contexto, la IA está emergiendo como un asistente valioso para mejorar tanto la precisión diagnóstica como la reproducibilidad en la nefropatología. Por ejemplo, se han desarrollado algoritmos de *Deep Learning* capaces de analizar imágenes digitalizadas de biopsias renales y detectar automáticamente lesiones glomerulares.

#### 8.1 FLUJO DE TRABAJO CON IA PARA EVALUACIÓN AUTOMÁTICA DE GLOMÉRULOS

Veamos un sistema de inteligencia artificial basado en aprendizaje profundo (*Deep Learning*) diseñado para localizar y clasificar glomérulos en imágenes escaneadas de biopsias renales (WSI - Whole Slide Images).

- Reducción de resolución (*Downsampling*): Las imágenes de biopsia escaneadas tienen una resolución muy alta. El primer

paso consiste en reducir su tamaño para facilitar un análisis preliminar más eficiente.

- Localización de glomérulos (módulo de localización): Una vez reducida la imagen, se utiliza un modelo de IA para detectar de forma aproximada la ubicación de los glomérulos en la imagen. Esta etapa produce localizaciones generales, no detalladas.
- Recorte de parches glomerulares: Con base en las ubicaciones obtenidas en la etapa anterior, se extraen fragmentos (parches) de alta resolución que contienen los glomérulos completos desde la imagen original.
- Clasificación del glomérulo (módulo de clasificación): Los parches glomerulares se analizan utilizando un modelo de clasificación, como VGG16, que determina el estado de cada glomérulo: normal, esclerótico, incompleto, entre otros.

Este sistema permite automatizar el análisis de biopsias renales, facilitando un diagnóstico más objetivo, rápido y reproducible. Puede ser utilizado como apoyo en estudios clínicos, seguimiento de enfermedades glomerulares y enseñanza médica.

### 8.2 DIAGNÓSTICO DE NEFROPATÍAS

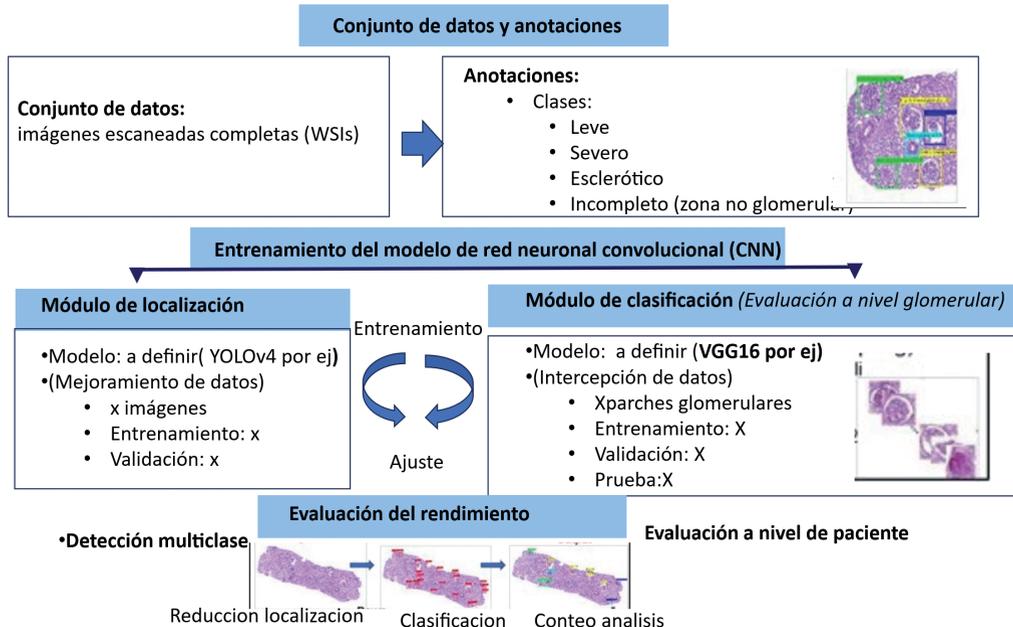
En el caso de la nefritis lúpica, un modelo de redes neuronales convolucionales (CNN) fue entrenado con cientos de biopsias para reconocer distintos grados de daño glomerular; dicho sistema logró una exactitud del 95 % en la clasificación de lesiones glomerulares y un índice Kappa de 0,93, indicando concordancia casi perfecta con el estándar experto [1]. Este nivel de rendimiento sugiere que la IA puede disminuir significativamente la variabilidad interobservador en la interpretación de biopsias. Para comprender mejor la metodología de este trabajo y cómo se usa un sistema de inteligencia artificial para identificar y clasificar glomérulos dentro de imágenes de biopsias renales escaneadas digitalmente a alta resolución, WSI (Whole Slide Images) se

incluyen los siguientes pasos que nos servirán para entender el flujo en la Figura 10 [1].

Otro estudio más reciente enfocó la IA en distinguir dos glomerulopatías de presentación histológica similar: la nefropatía por IgA versus la nefropatía diabética. Utilizando imágenes con tinción de Masson, un modelo automático alcanzó una exactitud global de alrededor del 73 % para diferenciar IgA vs. diabética, con capacidad de identificar prácticamente todos los glomérulos en las muestras (omisión <1,5 %) [2].

Aunque el rendimiento diagnóstico aún es modesto en comparación con un patólogo experto, estos sistemas demostraron trabajar con gran velocidad y consistencia, apuntando a un papel complementario de la IA como asistente del patólogo en un futuro cercano.

**FIGURA 10.** Sistema de IA basado en Deep Learning para la evaluación automática de glomérulos



Zheng Z. 2021

### 8.3 PRONÓSTICO Y MANEJO PERSONALIZADO DE LAS GLOMERULOPATÍAS

Las enfermedades glomerulares suelen tener cursos clínicos variables y es crucial identificar tempranamente qué pacientes están en riesgo de progresión a enfermedad renal crónica avanzada. En este sentido, los modelos de aprendizaje automático han mostrado ser útiles al integrar numerosas variables clínicas, de laboratorio e incluso hallazgos patológicos en predicciones de evolución. Un ejemplo notable es la nefropatía IgA, la glomerulonefritis primaria más común a nivel mundial. Múltiples grupos han aplicado algoritmos de ML para predecir resultados en nefropatía IgA (como el deterioro de la función renal o la remisión de la proteinuria) y recientemente se evaluó toda esta evidencia en una revisión sistemática con metaanálisis. Dicho análisis incorporó 47 estudios con más de 50 mil pacientes, encontrando que los modelos basados en ML alcanzaron en conjunto un índice C promedio de 0,90 para el diagnóstico asistido de nefropatía IgA, y de aproximadamente 0,84 para predicción de pronóstico (p. ej., riesgo de progresión a etapa terminal) [3]. Estas cifras de discriminación son comparables a las obtenidas con métodos estadísticos tradicionales (incluso, la regresión de Cox mostró un desempeño equiparable o superior en algunos análisis), lo que sugiere que la IA logra al menos igualar la capacidad predictiva convencional en este contexto. Sin embargo, un hallazgo interesante fue que los modelos más complejos (redes neuronales, *random forest*, máquinas de soporte vectorial, etc.) no superaron drásticamente a métodos más simples o a la estadística clínica tradicional en esta enfermedad, indicando que todavía hay margen de mejora y necesidad de refinar qué datos se incluyen en los algoritmos. Los autores de la revisión señalaron que futuras investigaciones deberían incorporar variables

más sensibles de daño glomerular (por ejemplo, dinámica de la albuminuria) y enfocarse en mejorar la predicción en pacientes de riesgo intermedio, para traducir estas herramientas en beneficios clínicos tangibles.

Por otro lado, en glomerulopatías específicas se han desarrollado modelos de IA para estratificación de riesgo personalizado. En la nefropatía membranosa idiopática, por ejemplo, un estudio reciente construyó un modelo predictivo utilizando *gradient boosting* (LightGBM) entrenado con datos de 418 pacientes, integrando hasta 59 características clínicas y patológicas por individuo [4]. El modelo logró excelente rendimiento para predecir eventos adversos (como progresión a insuficiencia renal terminal o recaídas), con un AUC de 0,89 en la cohorte de validación, superando a los puntajes de riesgo tradicionales. Además de su precisión, este enfoque permitió identificar qué variables tenían mayor peso en el pronóstico mediante técnicas de interpretabilidad (SHAP values). De manera concordante con el conocimiento nefrológico actual, los principales factores pronósticos resultaron ser el título de anticuerpos anti-PLA2R (elevado) y la intensidad de depósitos de IgG4 en biopsia (reducida), junto con marcadores de actividad y severidad como niveles de D-dímero, proteinuria, albúmina sérica baja, entre otros. Esta capacidad de la IA para descubrir y cuantificar la relevancia de múltiples factores simultáneamente puede guiar al clínico en el manejo: por ejemplo, un paciente con nefropatía membranosa con anti-PLA2R muy alto podría beneficiarse de terapia inmunosupresora temprana y más intensiva, según su perfil de riesgo predicho por el modelo.

Por tanto, en las enfermedades glomerulares la IA está encontrando áreas de aplicación tanto en el diagnóstico —mediante la lectura automatizada de biopsias y la mejora de la

precisión en identificar patrones histológicos– como en la fase pronóstica y de decisión terapéutica, al estratificar riesgos de forma individualizada. A pesar de que muchas de estas herramientas aún se encuentran en etapas de investigación o validación inicial, los resultados obtenidos hasta ahora demuestran que pueden complementar la práctica clínica: agilizando el diagnóstico de glomerulopatías, reduciendo la

subjetividad en la interpretación de biopsias, e informando decisiones clínicas (inicio de tratamientos agresivos, seguimiento estrecho) basadas en modelos predictivos robustos y basados en evidencia [5]. El reto siguiente será integrar estas soluciones de IA en los flujos de trabajo reales de patólogos y nefrólogos, validando su impacto en resultados clínicos y asegurando que su uso sea seguro y confiable.

#### REFERENCIAS

- 1 Zheng Z, Zhang X, Ding J, Zhang D, Cui J, Fu X, Han J, Zhu P. Deep Learning -Based Artificial Intelligence System for Automatic Assessment of Glomerular Pathological Findings in Lupus Nephritis. *Diagnostics (Basel)*. 2021;11(11):1983.
- 2 Fan Z, Yang Q, Xia H, Zhang P, Sun K, Yang M, Yin R, Zhao D, Ma H, Shen Y, Fan J. Artificial intelligence can accurately distinguish IgA nephropathy from diabetic nephropathy under Masson staining and becomes an important assistant for renal pathologists. *Front Med (Lausanne)*. 2023;10:1066125.
- 3 Zhuang K, Wang W, Xu C, Guo X, Ren X, Liang Y, Duan Z, Song Y, Zhang Y, Cai G. Machine Learning-based diagnosis and prognosis of IgAN: A systematic review and meta-analysis. *Heliyon*. 2024;10(12):e33090.
- 4 Liu Y, Lu Y, Li W, Wang Y, Zhang Z, Yang X, Yang Y, Li R, Zhou X. Prognostic prediction of idiopathic membranous nephropathy using interpretable Machine Learning. *Ren Fail*. 2023;45(2):2251597.
- 5 Basso MN, Barua M, Meyer J, John R, Khademi A. Machine Learning in renal pathology. *Front Nephrol*. 2022;2:1007002.

## 9.

### APLICACIÓN DE LA IA EN ONCONEFROLOGÍA

---

La Onconefrología es la subespecialidad que aborda las alteraciones renales en el paciente con cáncer. Incluye problemas como la lesión renal aguda por quimioterapia o inmunoterapia, las glomerulopatías paraneoplásicas, las complicaciones renales de trasplantes de médula ósea y el manejo de pacientes con enfermedad renal crónica que desarrollan neoplasias. Debido a la complejidad clínica de estos casos –donde convergen dos ámbitos altamente demandantes, la Oncología y la Nefrología–, la IA se vislumbra como un apoyo importante para detectar de forma precoz el daño renal incipiente, guiar el manejo óptimo de la función renal durante el tratamiento oncológico y eventualmente contribuir a personalizar los tratamientos para minimizar toxicidades sin comprometer la efectividad contra el cáncer [1].

#### 9.1 PREDICCIÓN DE NEFROTOXICIDAD INDUCIDA POR TRATAMIENTOS ONCOLÓGICOS

Muchos quimioterápicos (como los derivados de platino, ciertos antiangiogénicos, inmunoterapias, etc.) pueden producir efectos adversos renales [2]. Identificar con anticipación qué pacientes tienen mayor riesgo permitiría tomar medidas preventivas o indicar esquemas terapéuticos alternativos. En este sentido, se han aplicado algoritmos de *Machine*

*Learning* sobre datos clínicos y genómicos para pronosticar la lesión renal aguda asociada a quimioterapia. Un ejemplo destacado es un modelo de *random forest* desarrollado para predecir nefrotoxicidad por cisplatino en pacientes con cáncer testicular [3]. En este estudio se recopiló información de 433 pacientes tratados con cisplatino, incluyendo no sólo variables clínicas (dosis, función renal basal, comorbilidades) sino también datos genéticos de cada individuo. El modelo de ML integrado (clínica + genómica) logró identificar a los pacientes de alto riesgo de nefrotoxicidad con mayor precisión que los métodos tradicionales: su capacidad predictiva (AUC del ROC) aumentó de 0,63 (usando sólo factores clínicos) a 0,73 al incorporar marcadores genéticos relevantes. En particular, el algoritmo encontró asociaciones novedosas entre ciertas variantes genéticas (localizadas en genes como *NAT1*, *NAT2*, *CNTN6/CNTN4*) y la susceptibilidad a daño renal por cisplatino, complementando factores conocidos (polimorfismos en *ERCC1/2* y *SLC22A2*). Este tipo de modelo predictivo podría usarse antes de iniciar la quimioterapia para estratificar pacientes: aquellos identificados con alto riesgo podrían recibir esquemas menos agresivos (p. ej., ajustar la dosis de cisplatino o elegir un régimen alternativo) o medidas profilácticas intensificadas (hidratación vigorosa, control más frecuente

de creatinina), personalizando el tratamiento oncológico según el perfil de riesgo renal.

Las inmunoterapias con inhibidores de puntos de control inmunitario (ICPi, como los anti-PD-1, anti-PD-L1 o anti-CTLA-4) han revolucionado el pronóstico de muchos cánceres refractarios. No obstante, también conllevan efectos adversos autoinmunes, incluyendo nefritis intersticial y glomerulopatías, que causan lesión renal aguda en una proporción de pacientes [4]. Aquí nuevamente la IA ha demostrado utilidad para detectar tempranamente el daño renal asociado al cáncer. Investigadores en China desarrollaron un modelo de ML retrospectivo con datos de 1.600 pacientes tratados con ICPi, con el fin de predecir qué pacientes desarrollarían lesión renal aguda inmunomediada durante el tratamiento [5]. Empleando ocho algoritmos de ML diferentes y múltiples variables clínicas (medicaciones concomitantes, resultados de laboratorio periódicos, características demográficas, etc.), identificaron un modelo óptimo con un resultado notable: el algoritmo logró un AUC de hasta 0,82 en la predicción de AKI relacionada a ICPi. Esto significa que el modelo puede distinguir con buena precisión aquellos pacientes con alto riesgo de nefrotoxicidad inmunitaria. Los autores enfatizan que herramientas así, integradas a la práctica, permitirían intervenciones más oportunas –por ejemplo, control más estrecho de la función renal y suspensión temprana del fármaco inmunitario ante las primeras alteraciones– y en general mejorarían la seguridad del tratamiento oncológico. De hecho, el estudio concluye que los modelos de decisión clínica impulsados por IA pueden mejorar la predicción de AKI en pacientes oncológicos bajo ICPi, sirviendo como apoyo para la identificación precoz de pacientes en alto riesgo y facilitando intervenciones preventivas o terapéuticas antes de que el daño renal sea irreversible.

## 9.2 MANEJO DEL DAÑO RENAL YA ESTABLECIDO EN PACIENTES CON CÁNCER

Aquí la IA también puede ayudar de forma importante. Por ejemplo, una vez que un paciente oncológico desarrolla lesión renal aguda, algoritmos de aprendizaje automático podrían ayudar a diferenciar la causa principal del daño (progresión de enfermedad vs. nefrotoxicidad farmacológica vs. sepsis u otras causas) analizando patrones en los datos del paciente, lo cual guiaría decisiones clínicas (como continuar o no con cierta quimioterapia). Asimismo, se ha planteado que la IA podría optimizar la dosificación de quimioterápicos en pacientes con insuficiencia renal crónica, basándose en experiencias previas y simulaciones, para lograr un balance adecuado entre eficacia oncológica y seguridad renal. Aunque estas aplicaciones están menos desarrolladas, conceptualmente encajan en la noción de medicina personalizada asistida por IA: utilizando las características individuales (función renal basal, genética, comorbilidades) para adaptar el tratamiento del cáncer. De igual modo, en el ámbito de las glomerulopatías paraneoplásicas –situaciones en que un cáncer desencadena indirectamente una enfermedad glomerular, como la nefropatía membranosa asociada a tumores sólidos–, herramientas de IA podrían en el futuro correlacionar datos genómicos tumorales y renales para predecir qué pacientes oncológicos desarrollarán este tipo de complicaciones renales y así vigilar signos de enfermedad glomerular de manera anticipada.

Por tanto, la Onconeurología se beneficia de la IA principalmente a través de la predicción y prevención de la lesión renal asociada a tratamientos oncológicos y en la toma de decisiones terapéuticas complejas donde el riesgo renal es un factor crítico. Los estudios iniciales demuestran que los algoritmos pueden mejorar la identificación de pacientes en riesgo

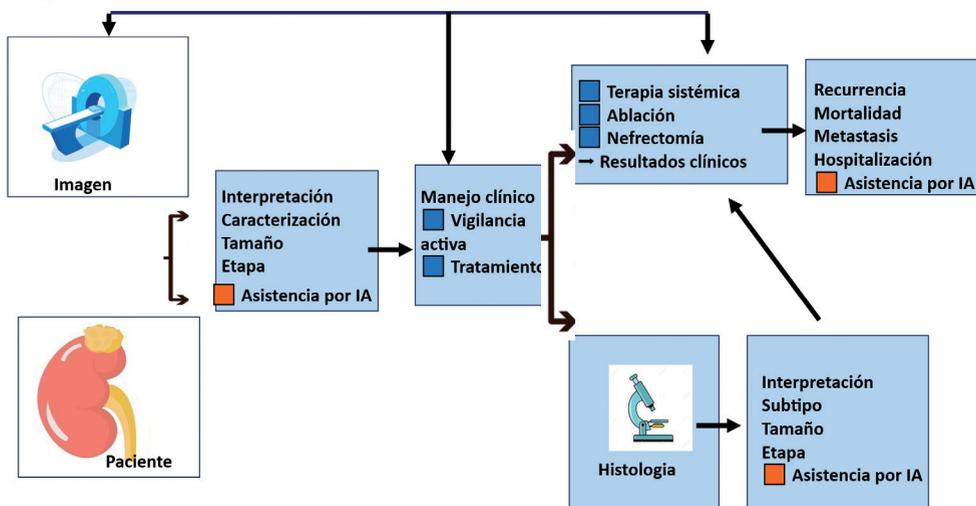
de nefrotoxicidad (tanto por quimioterapia convencional como por inmunoterapia) comparado con las evaluaciones clínicas habituales [3]. Esto redundaría en un manejo proactivo: ajustar dosis, elegir fármacos menos nefrotóxicos o implementar medidas de protección renal de forma dirigida. A futuro, con la consolidación de estas herramientas, es esperable que los oncólogos y nefrólogos cuenten con sistemas de apoyo basados en IA integrados a las historias clínicas electrónicas, que les alerten sobre riesgo renal inminente o les sugieran opciones de tratamiento oncológico mejor adaptadas al paciente con enfermedad renal. Todo ello con el objetivo final de mejorar los resultados: que el paciente con cáncer pueda recibir el tratamiento más efectivo contra su tumor con el menor impacto posible en su función renal, gracias a la planificación informada por predicciones de IA.

imágenes médicas, como tomografías computarizadas (TC) y resonancias magnéticas (RM), para distinguir entre tumores renales benignos y malignos. Los algoritmos de IA también pueden analizar imágenes histológicas para clasificar los subtipos de carcinoma de células renales (CCR) y determinar el grado del tumor con alta precisión. Se han reportado áreas bajo la curva (AUC) superiores a 0.93 en la clasificación de subtipos de CCR utilizando modelos de aprendizaje profundo. Además, la IA puede ayudar a cuantificar marcadores celulares y moleculares en el CCR, mejorando la exactitud y la reproducibilidad del diagnóstico. Incluso en la ecografía renal, la IA se está utilizando para la segmentación automática del riñón y el diagnóstico de enfermedades renales [6]. Existen múltiples oportunidades dentro del flujo de trabajo clínico del tratamiento del cáncer de riñón para la utilización de algoritmos de IA para predecir y mejorar los resultados (Figura 11).

### 9.3 DIAGNÓSTICO Y CLASIFICACIÓN

En el ámbito del diagnóstico, la IA ha demostrado ser eficaz en el análisis de

**FIGURA 11.** Flujo del trabajo clínico en el manejo del cáncer renal [6]



Modificado de Rasmussen R 2022

Las redes neuronales profundas que han impulsado los rápidos avances en la visión artificial y el procesamiento del lenguaje natural se basan en pasos de optimización masivos y paralelos que permiten que la red neuronal aprenda una función que asigna una entrada (p. ej., una imagen) a un resultado (p. ej., cáncer vs. no cáncer). Durante el entrenamiento, se actualizan millones de pesos en la red neuronal para minimizar la frecuencia de predicción de un resultado incorrecto [7]. Suponiendo que la red neuronal se entrena adecuadamente, una entrada dada debería poder asignarse a una salida dada con cierto grado de confianza. De esta manera, las redes neuronales tienen la capacidad de aproximarse a cualquier función (es decir, asignar cualquier entrada a cualquier salida) si se les proporcionan suficientes datos y una arquitectura adecuada [8].

#### REFERENCIAS

- 1 de Francisco ALM, Macia Heras Manuel, Alonso Fabiola, et al. Onconeurología Cancer y enfermedad renal. En: Lorenzo V., López Gómez JM (Eds). Nefrología al día. ISSN: 2659-2606. Disponible en: <https://www.nefrologiaaldia.org/202>
- 2 de Francisco ALM, Efectos renales adversos del tratamiento del cáncer. En: Lorenzo V., López Gómez JM (Eds). Nefrología al día. ISSN: 2659-2606. Disponible en: <https://www.nefrologiaaldia.org/402>
- 3 Garcia SL, Lauritsen J, Zhang Z, Bandak M, Dalgaard MD, Nielsen RL, Daugaard G, Gupta R. Prediction of Nephrotoxicity Associated with Cisplatin-Based Chemotherapy in Testicular Cancer Patients. JNCI Cancer Spectr. 2020;4(3):pkaa032.
- 4 de Francisco ALM, Alonso García F, García García P y cols Efectos Renales Adversos de la Inmunoterapia. En: Lorenzo V., López Gómez JM (Eds). Nefrología al día. ISSN: 2659-2606. Disponible en: <https://www.nefrologiaaldia.org/506>
- 5 Yu X, Wu R, Ji Y, Huang M, Feng Z. Identifying Patients at Risk of Acute Kidney Injury among Patients Receiving Immune Checkpoint Inhibitors: A Machine Learning Approach. Diagnostics (Basel). 2022;12(12):3157.
- 6 Rasmussen R, Sanford T, Parwani AV, Pedrosa I. Artificial Intelligence in Kidney Cancer. Am Soc Clin Oncol Educ Book. 2022;42:1-11.
- 7 LeCun Y, Bengio Y, Hinton G. Deep Learning. Nature. 2015;521:436-444.
- 8 Hornik K. Multilayer feedforward networks are universal approximators. Neural Netw. 1989; 2:359-366.

## 10.

### APLICACIÓN DE LA IA EN HIPERTENSIÓN ARTERIAL

---

La hipertensión arterial (HTA) es uno de los factores de riesgo cardiovascular más prevalentes, cuya óptima detección y control representa un desafío de salud pública. La gestión de la hipertensión genera una enorme cantidad de datos longitudinales (lecturas de presión arterial en consultorio, control de 24 horas, registros domiciliarios, etc.), así como información clínica asociada (hábitos de vida, parámetros antropométricos, exámenes de laboratorio, comorbilidades). Esto brinda un campo fértil para la aplicación de la IA, que puede aprovechar dichos datos para predecir eventos futuros, mejorar el control en tiempo real y optimizar las estrategias terapéuticas de control tensional de forma individualizada.

#### 10.1 MONITORIZACIÓN Y SEGUIMIENTO DE LA TENSIÓN ARTERIAL (TA)

Tradicionalmente, el control de la HTA dependía de mediciones esporádicas en la consulta, las cuales pueden no reflejar plenamente el perfil tensional real del paciente (fenómeno de *bata blanca*, HTA enmascarada, variabilidad circadiana). Hoy en día, con la proliferación de dispositivos portables y de monitores ambulatorios inteligentes, es posible obtener mediciones de presión casi continuas, generando series de tiempo voluminosas que requieren análisis avanzado. Aquí, algoritmos de IA pueden filtrar el ruido de datos y

extraer información accionable. Por ejemplo, se han desarrollado métodos basados en redes neuronales para estimar la presión arterial de forma no invasiva a partir de señales de fotoplethismografía (PPG) obtenidas por sensores ópticos en pulseras o relojes inteligentes [1,2].

Estos algoritmos aprenden la relación compleja entre las características de la onda de pulso (forma, velocidad de propagación, etc.) y la presión arterial sistólica/diastólica, permitiendo calcular valores de PA en tiempo real sin necesidad de un esfigmomanómetro tradicional. Diversas aproximaciones de Machine Learning –desde regresión multivariada hasta modelos de ensamblajes y redes neuronales profundas– se han aplicado a este problema para lidiar con la naturaleza no lineal de la señal y las variaciones interindividuales. Si bien todavía se afinan aspectos técnicos (eliminación de artefactos de movimiento, calibraciones personalizadas), estos sistemas de IA prometen monitorización continua de la PA en la vida diaria del paciente, detectando episodios hipertensivos en tiempo real. La integración de estos datos mediante plataformas de salud digital podría alertar automáticamente al médico o al paciente cuando la presión supera ciertos umbrales, o incluso ajustar algoritmos de dosificación de medicamentos antihipertensivos en dispositivos inteligentes. Así, la IA facilita un control mucho más dinámico y

preciso de la hipertensión, en contraposición al modelo estático de visitas periódicas.

### 10.2 OPTIMIZACIÓN DEL TRATAMIENTO ANTIHIPERTENSIVO MEDIANTE IA

La elección y ajuste de medicamentos para la HTA suele ser un proceso de prueba y error, dado que la respuesta a fármacos varía ampliamente entre individuos. Actualmente, las guías clínicas ofrecen recomendaciones generales (diuréticos tiazídicos, bloqueadores del sistema renina-angiotensina, calcioantagonistas, betabloqueantes como pilares terapéuticos), pero no existe una fórmula infalible para qué fármaco funcionará mejor en cada paciente. Aquí, la IA puede aportar medicina de precisión analizando grandes bases de datos clínicos para encontrar patrones de respuesta farmacológica. Un avance reciente en este campo fue el desarrollo de un algoritmo de ML en el Boston Medical Center que, a partir de datos de 42.752 pacientes hipertensos, aprendió a predecir cuál sería el régimen terapéutico óptimo para controlar la PA de cada paciente [3].

### 10.3 PREDICCIÓN DE LA HIPERTENSIÓN DE NUEVA APARICIÓN

Uno de los usos prominentes de la IA en HTA es la predicción de la hipertensión de nueva aparición en individuos aún normotensos o prehipertensos. Identificar tempranamente a personas con alto riesgo de desarrollar HTA permite implementar intervenciones preventivas (cambios en el estilo de vida, control de peso, etc.) antes de que la hipertensión se establezca y cause daño orgánico. En este sentido, los modelos de Machine Learning han mostrado ser superiores a los modelos estadísticos tradicionales para manejar múltiples factores de riesgo simultáneamente. Por ejemplo, un estudio en población etíope utilizó datos de encuestas de salud para entrenar cuatro

algoritmos (regresión logística, red neuronal, random forest y XGBoost) en la predicción de incidencia de HTA [4]. La mejor predicción la obtuvo el modelo basado en *extreme gradient boosting* (XGBoost), alcanzando una exactitud del 89 % y un área bajo la curva (AUC) de 0,894 en el conjunto de prueba. Mediante técnicas de explicación (SHAP), mide cuánto contribuye cada característica (variable) a una predicción específica, el modelo identificó los principales factores asociados al desarrollo de hipertensión en esa cohorte: la edad, el peso corporal y la obesidad (por porcentaje de grasa), los antecedentes familiares de HTA, la presencia de diabetes y la ingesta elevada de sal, entre otros. Muchos de estos coinciden con los factores de riesgo conocidos epidemiológicamente, lo cual valida el enfoque; pero la IA aporta la cuantificación precisa del riesgo individual combinando todos esos factores. Los autores concluyeron que este tipo de herramienta puede servir para estratificar a la población y ayudar a focalizar recursos preventivos en quienes más probablemente se volverán hipertensos.

### 10.4 RIESGO DE MAL CONTROL DE LA TA

Los modelos de Machine Learning han demostrado su utilidad en la predicción del mal control tensional y de complicaciones en pacientes hipertensos. Nguyen y cols. [5] desarrollaron y validaron modelos para predecir la hipertensión no controlada y crisis hipertensivas a partir de historias clínicas electrónicas, empleando regresión logística, perceptrón multicapa, *gradient boosting* y *random forest*. En validación interna, lograron una precisión moderada con un C-statistic de 0,72 para hipertensión sostenida y 0,81 para crisis hipertensivas, mostrando mejor predicción en elevaciones tensionales severas, aunque con margen de mejora en la predicción del control deficiente sostenido. Por su

parte, Mroz y col. [6] aplicaron ML a datos de 350.000 pacientes en Cleveland Clinic para predecir la posibilidad de control de la presión arterial en los siguientes 12 meses. Utilizando variables como medicamentos, laboratorio, constantes vitales y comorbilidades, su modelo alcanzó un AUC de 0,76, con especificidad del 76 % y sensibilidad del 62 %. Aunque sus resultados fueron prometedores, los autores sugieren perfeccionar el modelo antes de su implementación clínica. Hung y cols. [7] abordaron la identificación de hipertensión enmascarada en pacientes hipertensos utilizando datos de una única consulta. Analizaron 970 pacientes en validación interna y 416 en validación externa, logrando un rendimiento destacado con un modelo de *random forest* que alcanzó AUC 0,85 en validación interna y 0,84 en externa, con alta sensibilidad (95–100 %) y elevado valor predictivo negativo. Esto resalta la capacidad de ML para detectar casos de hipertensión no controlada en pacientes con mediciones aparentemente normales en consulta.

### 10.5 PREDICCIÓN DE COMPLICACIONES

En cuanto a la predicción de complicaciones, Wu y cols. [8] aplicaron *extreme gradient boosting* para estratificar el riesgo de eventos cardiovasculares en jóvenes hipertensos. Analizando 508 pacientes seguidos durante 33 meses, su modelo alcanzó un C-statistic de 0,757, superando modelos tradicionales como la regresión de Cox (0,723) y la puntuación de riesgo de Framingham recalibrada (0,529). Yang y cols. [9] se enfocaron en la predicción del riesgo de ictus en hipertensos a 3 años, utilizando big data de 250.000 pacientes en Shenzhen, China. Identificaron 9.421 casos de ictus y desarrollaron un modelo basado en XGBoost, que alcanzó una AUC de 0,92, superando las escalas de riesgo convencionales como Framingham. Incorporar características

temporales fue clave para mejorar la precisión del modelo. Zhong y cols. [10] abordaron la predicción de deterioro cognitivo temprano en hipertensos, analizando 733 pacientes, de los cuales el 17 % presentaba deterioro cognitivo leve. Utilizando técnicas de selección como LASSO, seleccionaron variables clave como edad, educación y actividad física, entrenando un modelo de XGBoost que alcanzó una AUC de 0,88, con sensibilidad del 84 % y especificidad del 80 %.

En conjunto, estos estudios demuestran que los modelos de ML pueden mejorar la predicción del mal control tensional y de diversas complicaciones en hipertensión. La integración de múltiples variables clínicas y la incorporación de datos longitudinales permiten mejorar la precisión de las predicciones en comparación con los métodos tradicionales. Modelos como random forest y XGBoost han mostrado alta precisión, y el uso de características temporales mejora significativamente su capacidad predictiva. Sin embargo, la validación en entornos clínicos reales sigue siendo un desafío clave. A pesar de estos avances, se requiere más investigación para asegurar que estas herramientas sean aplicables de manera efectiva en la práctica clínica.

### REFERENCIAS

- 1 Visco V, Izzo C, Mancusi C, Rispoli A, Tedeschi M, Virtuoso N, Giano A, Gioia R, Melfi A, Serio B, Rusciano MR, Di Pietro P, Bramanti A, Galasso G, D'Angelo G, Carrizzo A, Vecchione C, Ciccarelli M. Artificial Intelligence in Hypertension Management: An Ace up Your Sleeve. *J Cardiovasc Dev Dis.* 2023;10(2):74.
- 2 Elgendi M., Fletcher R., Liang Y., Howard N., Lovell N.H., Abbott D., Lim K., Ward R. The use of photoplethysmography for assessing hypertension. *NPJ Digit. Med.* 2019;2:60. <https://doi.org/10.1038/s41746-019-0136-7>

- 3 Hu, Y., Huerta, J., Cordella, N. et al. Personalized hypertension treatment recommendations by a data-driven model. *BMC Med Inform Decis Mak.* 2023;23:44.
- 4 Islam MM, Alam MJ, Maniruzzaman M, Ahmed NAME, Ali MS, Rahman MJ, Roy DC. Predicting the risk of hypertension using Machine Learning algorithms: A Cross sectional study in Ethiopia. *PLoS One.* 2023;18(8): e0289613.
- 5 Nguyen HM, Anderson W, Chou SH, McWilliams A, Zhao J, Pajewski N, Taylor Y. Predictive Models for Sustained, Uncontrolled Hypertension and Hypertensive Crisis Based on Electronic Health Record Data: Algorithm Development and Validation. *JMIR Med Inform.* 2024;12:e58732.
- 6 Mroz T, Griffin M, Cartabuke R, Laffin L, Russo-Alvarez G, Thomas G, Smedira N, Meese T, Shost M, Habboub G. Predicting hypertension control using Machine Learning. *PLoS One.* 2024;19(3):e0299932.
- 7 Hung MH, Shih LC, Wang YC, Leu HB, Huang PH, Wu TC, Lin SJ, Pan WH, Chen JW, Huang CC. Prediction of Masked Hypertension and Masked Uncontrolled Hypertension Using Machine Learning. *Front Cardiovasc Med.* 2021;8:778306.
- 8 Wu X, Yuan X, Wang W, Liu K, Qin Y, Sun X, Ma W, Zou Y, Zhang H, Zhou X, Wu H, Jiang X, Cai J, Chang W, Zhou S, Song L. Value of a Machine Learning Approach for Predicting Clinical Outcomes in Young Patients with Hypertension. *Hypertension.* 2020;75(5):1271-1278.
- 9 Yang Y, Zheng J, Du Z, Li Y, Cai Y Accurate Prediction of Stroke for Hypertensive Patients Based on Medical Big Data and Machine Learning Algorithms: Retrospective Study
- 10 Zhong X, Yu J, Jiang F, Chen H, Wang Z, Teng J, Jiao H. A risk prediction model based on Machine Learning for early cognitive impairment in hypertension: Development and validation study. *Front Public Health.* 2023;11:1143019.

## 11.

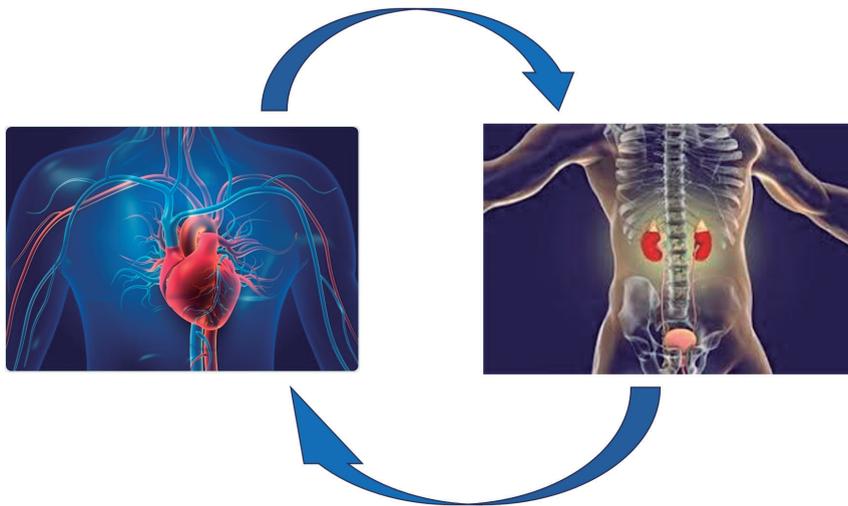
### APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN LA MEDICINA CARDIORRENAL

---

La medicina cardiorrenal aborda la compleja interacción entre el corazón y los riñones, donde la disfunción de uno puede precipitar problemas en el otro. Un ejemplo clásico es el síndrome cardiorrenal, en el que la insuficiencia cardíaca aguda puede causar lesión renal aguda (LRA o AKI, por sus siglas en inglés) y viceversa (Figura 12). Estas interdependencias generan grandes volúmenes de datos clínicos (signos vitales, laboratorio, imágenes, historias) cuyo análisis rebasa la capacidad humana

convencional. En este contexto, la inteligencia artificial (IA) está emergiendo como una aliada prometedora para descifrar patrones ocultos y apoyar la toma de decisiones clínicas. Técnicas avanzadas de IA, como el Machine Learning (aprendizaje automático) y el Deep Learning (aprendizaje profundo), permiten comprender mejor la fisiopatología combinada de corazón y riñón, personalizar cuidados en tiempo real y potencialmente mejorar los desenlaces en pacientes cardíacos con afectación renal.

**FIGURA 12.** Síndrome cardiorrenal



La IA en el campo cardiorrenal tiene aplicaciones emergentes a lo largo de todo el espectro asistencial:

### 11.1 PREDICCIÓN DE RIESGOS Y ESTRATIFICACIÓN

Una de las contribuciones más potentes de la IA es anticipar efectos adversos. Modelos de Machine Learning ya predicen con fiabilidad qué pacientes con insuficiencia cardíaca desarrollarán lesión renal aguda durante la hospitalización, permitiendo vigilarlos más de cerca e implementar medidas preventivas [1,2]. Del mismo modo, se han construido nomogramas y modelos ML que predicen la mortalidad a 1 año en síndrome cardiorrenal por sepsis, incorporando variables como edad, puntuación SOFA, niveles de mioglobina, necesidad de vasopresores y ventilación mecánica [3]. Estas herramientas identifican pacientes de alto riesgo para intervenciones tempranas. También se ha aplicado IA para predecir AKI post-Cirugía cardíaca mejorando la identificación preoperatoria de pacientes vulnerables a fallo renal agudo tras bypass o reemplazo valvular [4].

### 11.2 DIAGNÓSTICO Y DETECCIÓN TEMPRANA

Aunque el diagnóstico de los síndromes cardiorrenales se basa en la presentación clínica, la IA puede detectar señales sutiles de descompensación antes de que sean evidentes. Por ejemplo, algoritmos aplicados a historiales electrónicos pueden analizar tendencias de creatinina, diuresis, peso y presión venosa central para alertar sobre un posible empeoramiento renal en un paciente cardíaco incluso antes de que cumpla criterios formales de AKI. En Cardiología, la IA ya se usa para identificar arritmias ocultas en ECG o disfunción ventricular en ecocardiogramas [5]. Un estudio de Mayo Clinic demostró que la

IA aplicada a ECG estándar puede detectar de manera confiable la disfunción ventricular izquierda asintomática, una condición que precede a la insuficiencia cardíaca [6]. Otro estudio publicado en Revista Española de Cardiología destaca 19 ejemplos donde la IA ha mostrado mejoras diagnósticas y terapéuticas en diferentes áreas de la Cardiología, incluyendo la evaluación de la función ventricular izquierda [7]. Integrandos estos hallazgos con marcadores renales, es posible diagnosticar precozmente un síndrome cardiorrenal incipiente. Un desarrollo innovador ha sido el uso de IA en aplicaciones móviles para pacientes con insuficiencia cardíaca: por ejemplo, análisis de voz con IA que detecta congestión pulmonar incipiente (a través de cambios sutiles en la voz) y ha logrado predecir exacerbaciones de insuficiencia cardíaca con >75 % de acierto [8]. Tales soluciones de diagnóstico temprano ofrecen una ventana de actuación preventiva.

### 11.3 APOYO AL TRATAMIENTO Y DECISIONES TERAPÉUTICAS

La IA también contribuye a guiar tratamientos. En pacientes hospitalizados con fallo cardíaco y deterioro renal, los algoritmos pueden ayudar a ajustar el manejo de líquidos y diuréticos equilibrando la perfusión renal y la congestión pulmonar. Por ejemplo, sistemas de apoyo a la decisión clínica basados en ML podrían recomendar reducir o aumentar dosis de diuréticos según patrones de respuesta de creatinina y diuresis previas, optimizando el tratamiento minuto a minuto [9]. Adicionalmente, la IA de imágenes médicas puede cuantificar congestión en radiografías de tórax o ecografías pulmonares de forma objetiva, aportando datos para decidir iniciar ultrafiltración o diálisis en un síndrome cardiorrenal refractario [10]. En escenarios críticos como la sepsis, la IA ha demostrado utilidad

sugiriendo intervenciones tempranas para prevenir AKI asociado a sepsis, integrando múltiples variables en tiempo real [11]. En cuanto al tratamiento crónico, sistemas de telemedicina con IA están ayudando a seguir de cerca a pacientes dados de alta: programas de monitoreo remoto combinando sensores (peso, presión arterial, creatinina vía análisis domiciliario) y algoritmos predictivos han logrado reducir hasta un 50 % las readmisiones a 30 días por insuficiencia cardíaca, al detectar descompensaciones antes de que se vuelvan graves [12]. Esto resalta cómo la IA, junto con la supervisión médica, puede mejorar la continuidad asistencial y resultados clínicos en pacientes cardiorrenales frágiles.

#### 11.4 PLANIFICACIÓN COLABORATIVA Y SOPORTE CLÍNICO

Otra aplicación relevante es facilitar la colaboración entre especialistas. Dada la necesidad de un abordaje multidisciplinario (cardiólogos, nefrólogos, intensivistas), se están desarrollando

plataformas de IA que integran las perspectivas de distintas especialidades. Por ejemplo, paneles de control inteligentes que muestran en tiempo real indicadores cardíacos y renales clave, con alertas y sugerencias basadas en guías, ayudan al equipo a coordinar estrategias (como cuándo derivar a diálisis o cuándo indicar terapia inotrópica) [9]. Incluso se explora el uso de modelos de lenguaje (tipo ChatGPT entrenado en documentos médicos para responder preguntas clínicas complejas, servir de «segunda opinión» instantánea y revisar interacciones fármaco-renales, lo que podría agilizar decisiones en la cabecera del paciente [13]).

#### 11.5 DESAFÍOS DE LA IA EN LA MEDICINA CARDIORRENAL

En la Tabla 12 se resumen los principales desafíos a la implementación de la IA en Cardiología y Nefrología, así como la necesidad de estrategias interdisciplinarias para superarlos. En realidad, son comunes a la aplicación de la IA en medicina.

**TABLA 12.** Obstáculos en la implementación de la IA en Cardiología y Nefrología

OBSTÁCULO	DESCRIPCIÓN
Calidad y disponibilidad de datos	Los modelos de IA necesitan grandes volúmenes de datos representativos y bien integrados de los ámbitos de Cardiología y Nefrología. Sin embargo, los registros clínicos suelen estar fragmentados entre distintos servicios o pueden contener datos incompletos y no estructurados, lo que compromete la fiabilidad de las predicciones.
Cuestiones éticas y sesgos	Los algoritmos de IA pueden reflejar sesgos inherentes a los datos de entrenamiento. Si el conjunto de datos proviene de poblaciones específicas, los modelos pueden no generalizar bien a otros grupos, lo que podría afectar la equidad en la atención médica.
Privacidad y seguridad de los datos	La aplicación de IA en salud requiere un manejo cuidadoso de la información del paciente para garantizar la protección de datos y cumplir con regulaciones como el GDPR. La seguridad es fundamental para evitar el acceso no autorizado y el uso indebido de la información.
Interpretabilidad de los modelos	Muchos modelos de Deep Learning funcionan como «cajas negras», lo que dificulta la comprensión del proceso de toma de decisiones. Sin una explicación clara del razonamiento del algoritmo, los profesionales de la salud pueden mostrarse reacios a confiar en las recomendaciones de la IA.

(Continúa)

(Continuación)

OBSTÁCULO	DESCRIPCIÓN
Validación clínica	Antes de su implementación generalizada, los algoritmos de IA deben ser sometidos a ensayos rigurosos y validaciones externas para demostrar su eficacia en entornos reales. Sin esta verificación, el riesgo de errores o inexactitudes podría limitar su aplicabilidad clínica.
Resistencia al cambio y capacitación del personal	La integración de IA en la práctica clínica implica una adaptación de los flujos de trabajo y capacitación de los profesionales sanitarios. La resistencia al cambio dentro de las instituciones puede dificultar la adopción de estas tecnologías.
Necesidad de un enfoque multidisciplinario	Superar estos desafíos requiere la colaboración entre ingenieros, científicos de datos, cardiólogos y nefrólogos. Además, es fundamental contar con marcos éticos y regulaciones adaptadas para garantizar un uso responsable de la IA en salud.

### 11.6 TENDENCIAS FUTURAS Y ÁREAS DE INVESTIGACIÓN EN DESARROLLO DE LA IA EN LA MEDICINA CARDIORRENAL

Mirando hacia el futuro, la aplicación de IA en la medicina cardiorrenal se perfila como un campo dinámico. Una tendencia clara es la evolución hacia un cuidado más proactivo y en tiempo real. Se están desarrollando sistemas de monitorización continua que combinan dispositivos portables y sensores domiciliarios con algoritmos de IA para vigilar a los pacientes 24h [14]. Imaginemos un paciente con insuficiencia cardíaca avanzada: su reloj inteligente envía constantemente datos de frecuencia cardíaca, presión arterial y actividad física; a esto se suman mediciones periódicas de creatinina o peso vía dispositivos conectados. La IA integrará esos datos múltiples, detectando desviaciones sutiles que anuncien un desequilibrio cardiorrenal, de modo que el equipo médico pueda actuar antes de una crisis (Figura 13). Algunos hospitales ya experimentan con estas plataformas y reportan disminuciones significativas en rehospitalizaciones.

FIGURA 13. Monitorización inteligente del paciente con insuficiencia cardíaca avanzada



## REFERENCIAS

- 1 Cheungpasitporn W, Thongprayoon C, Kashani KB. Artificial Intelligence in Heart Failure and Acute Kidney Injury: Emerging Concepts and Controversial Dimensions. *Cardiorenal Med.* 2024;14(1):147-159 [ Liu WT. et al. Using a Machine Learning model to predict the development of acute kidney injury in patients with heart failure. *Front Cardiovasc Med.* 2022;9:911987.
- 2 Liu WT, Liu XQ, Jiang TT, Wang MY, Huang Y, Huang YL, Jin FY, Zhao Q, Wu QY, Liu BC, Ruan XZ, Ma KL. Using a Machine Learning model to predict the development of acute kidney injury in patients with heart failure. *Front Cardiovasc Med.* 2022;9:911987.
- 3 Liu Y, Zhang Y, Zhang X, Liu X, Zhou Y, Jin Y, Yu C. Nomogram and Machine Learning Models Predict 1-Year Mortality Risk in Patients with Sepsis-Induced Cardiorenal Syndrome. *Front Med (Lausanne).* 2022;9:792238.
- 4 Thongprayoon C, Hansrivijit P, Bathini T, Vallabhajosyula S, Mekkarakakit P, Kaewput W, Cheungpasitporn W. Predicting Acute Kidney Injury after Cardiac Surgery by Machine Learning Approaches. *J Clin Med.* 2020;9(6):1767.
- 5 Bocanegra-Pérez AJ, Piella G, Sebastian R, Jimenez-Perez G, Falasconi G, Saglietto A, Soto-Iglesias D, Berruezo A, Penela D, Camara O. Automatic and interpretable prediction of the site of origin in outflow tract ventricular arrhythmias: Machine Learning integrating electrocardiograms and clinical data. *Front Cardiovasc Med.* 2024;11:1353096.
- 6 Attia ZI, Kapa S, Lopez-Jimenez F, McKie PM, Ladewig DJ, Satam G, Pellikka PA, Enriquez-Sarano M, Noseworthy PA, Munger TM, Asirvatham SJ, Scott CG, Carter RE, Friedman PA. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nat Med.* 2019;25(1):70-74.
- 7 Dorado-Díaz PI, Sampredo-Gómez J, Vicente-Palacios V, Sánchez PL. Applications of Artificial Intelligence in Cardiology. The Future is Already Here. *Rev Esp Cardiol (Engl Ed).* 2019;72(12):1065-1075.
- 8 Amir O, Abraham WT, Azzam ZS, Berger G, Anker SD, Pinney SP, Burkhoff D, Shalloom ID, Lotan C, Edelman ER. Remote Speech Analysis in the Evaluation of Hospitalized Patients with Acute Decompensated Heart Failure. *JACC Heart Fail.* 2022;10(1):41-49.
- 9 Martínez Bernabé, E., Paluzie-Ávila, G., Terre Ohme, S., Ruiz Poza, D., Parada Aradilla, M. A., González Martínez, J., Albertí Valmaña, R., & Castellvi Gordo, M. Sistemas de soporte a la toma de decisiones clínicas en insuficiencia renal. *Farmacia Hospitalaria*, 2014.38(3), 245-254.
- 10 García-García, F., & Argüeso, M. Inteligencia artificial en Radiología torácica. ¿Un reto en tiempos de pandemia? *Radiología*, 2020;62(6), 481-487.
- 11 Yue S, Li S, Huang X, Liu J, Hou X, Zhao Y, Niu D, Wang Y, Tan W, Wu J. Machine Learning for the prediction of acute kidney injury in patients with sepsis. *J Transl Med.* 2022;20(1):215.
- 12 Comín-Colet J, Enjuanes C, Verdú-Rotellar JM, Linas A, Ruiz-Rodríguez P, González-Robledo G, Farré N, Moliner-Borja P, Ruiz-Bustillo S, Bruguera J. Impact on clinical events and healthcare costs of adding telemedicine to multidisciplinary disease management programmes for heart failure: Results of a randomized controlled trial. *J Telemed Telecare.* 2016;22(5):282-95.
- 13 Li Y, Li Z, Zhang K, Dan R, Jiang S, Zhang Y. ChatDoctor: A Medical Chat Model Fine-Tuned on a Large Language Model Meta-AI (LLaMA) Using Medical Domain Knowledge. *Cureus.* 2023;15(6): e40895.
- 14 Liao Y, Thompson C, Peterson S, Mandrola J, Beg MS. The Future of Wearable Technologies and Remote Monitoring in Health Care. *Am Soc Clin Oncol Educ Book.* 2019;39:115-121.



## 12.

# MEDICINA PERSONALIZADA EN NEFROLOGÍA: INTEGRACIÓN DE BIOMARCADORES, DATOS CLÍNICOS E INTELIGENCIA ARTIFICIAL

---

La medicina personalizada ha emergido como un enfoque transformador en el ámbito de la salud, orientado a adaptar las estrategias diagnósticas, terapéuticas y preventivas a las características individuales de cada paciente. En el caso de la Nefrología, esta aproximación está experimentando un desarrollo acelerado gracias al avance en el conocimiento de biomarcadores específicos, la disponibilidad de grandes volúmenes de datos clínicos y la irrupción de tecnologías como la inteligencia artificial.

Tradicionalmente, la práctica nefrológica se ha basado en parámetros bioquímicos generales como la creatinina sérica y la tasa de filtrado glomerular estimada (eGFR). Sin embargo, estos indicadores presentan limitaciones, particularmente en la detección precoz de daño renal o en poblaciones con características especiales. La medicina personalizada permite superar estas limitaciones mediante la integración de múltiples capas de información, incluyendo biomarcadores moleculares, datos clínicos estructurados, imágenes médicas y análisis predictivos basados en IA [1].

### 12.1 BIOMARCADORES Y PRECISIÓN EN EL DAÑO RENAL

El concepto de biomarcador se refiere a cualquier sustancia, estructura o proceso que

pueda medirse en el organismo y que refleje un estado fisiológico o patológico. En Nefrología, los biomarcadores sanguíneos permiten detectar alteraciones en la función renal, identificar tipos específicos de daño y predecir la evolución de diversas enfermedades [2].

Entre los marcadores tradicionales, la creatinina sigue siendo el biomarcador más utilizado para estimar la función renal. No obstante, su concentración sérica depende del metabolismo muscular y puede no reflejar con precisión el filtrado glomerular en todos los pacientes. Por ello, se han propuesto marcadores alternativos como la cistatina C, una proteína de bajo peso molecular producida por todas las células nucleadas, que se filtra libremente en el glomérulo y no se ve afectada por la masa muscular.

Entre los biomarcadores emergentes destacaremos:

- NGAL (Neutrophil Gelatinase-Associated Lipocalin): aumenta precozmente en la orina y en el plasma ante una lesión tubular aguda. Se ha validado como un marcador sensible de lesión renal aguda (LRA) en distintos escenarios clínicos como Cirugía Cardíaca, sepsis y trasplante renal [3].

- KIM-1 (Kidney Injury Molecule-1): se expresa en células epiteliales tubulares tras una lesión y es útil para el diagnóstico y el pronóstico tanto de la LRA como de la enfermedad renal crónica (ERC) [4].
- IL-18: una citoquina inflamatoria relacionada con daño tubular y la respuesta inmune, también ha demostrado utilidad en la predicción de la LRA [5].
- $\beta$ 2-microglobulina y cadenas ligeras libres (FLC): relevantes en contextos específicos como la nefropatía por mieloma múltiple u otras enfermedades hematológicas con afectación renal [6].

La utilidad clínica de estos biomarcadores radica en su capacidad para proporcionar información sobre el tipo, la localización y la severidad del daño renal, así como para identificar a pacientes con riesgo elevado de progresión o de complicaciones. Si bien los biomarcadores aportan datos moleculares fundamentales, no deben interpretarse de forma aislada. Es imprescindible considerar el contexto clínico del paciente, incluyendo historia médica, comorbilidades, tratamientos, parámetros hemodinámicos y resultados de estudios de imagen. Este análisis permite segmentar mejor a los pacientes y mejorar la precisión diagnóstica. En la práctica, muchos casos de enfermedad renal son multifactoriales, y el cruce de información molecular y clínica es esencial para una evaluación personalizada.

### 12.2 LA IA: DEL BIG DATA A LA ACCIÓN CLÍNICA

La medicina personalizada en Nefrología no sería viable sin herramientas capaces de procesar e interpretar el enorme volumen de información generado. La inteligencia artificial permite descubrir patrones ocultos en los datos, hacer predicciones clínicas precisas y

apoyar la toma de decisiones en tiempo real. La conjunción de biomarcadores moleculares, datos clínicos detallados y análisis avanzados con IA está configurando una Nefrología de precisión, capaz de ofrecer cuidados individualizados (Tabla 13). Este enfoque permite diagnósticos más precisos, tratamientos dirigidos, la predicción de la progresión de la ERC, detección precoz de LRA, fenotipado de pacientes y prevención secundaria.

#### 12.2.1 Aplicaciones actuales de la IA en Nefrología

En capítulos anteriores ya hemos comentado estas aplicaciones:

- Predicción de la progresión de la ERC: mediante modelos de aprendizaje automático que combinan variables clínicas, analíticas y biomarcadores.
- Detección precoz de LRA: a partir de la monitorización continua de pacientes hospitalizados, se pueden generar alertas basadas en el análisis de parámetros clínicos en tiempo real.
- Fenotipado de pacientes: identificación de subgrupos con diferente evolución o respuesta al tratamiento mediante análisis de historias clínicas electrónicas.
- Optimización terapéutica: ajuste de inmunosupresores o fármacos nefrotóxicos en base al perfil metabólico y la evolución renal individual.
- Prevención secundaria: modelos predictivos que permiten actuar antes de que el daño renal se vuelva irreversible.

#### 12.2.2 Retos en la implementación de IA

Pese a su potencial, la IA enfrenta desafíos importantes como la calidad de los datos clínicos disponibles, la validación externa de los modelos predictivos, barreras regulatorias y éticas, y la necesidad de formación técnica entre los profesionales sanitarios.

**TABLA 13.** Medicina personalizada en Nefrología

ELEMENTO CLAVE	EJEMPLOS Y DETALLES	UTILIDAD CLÍNICA
Biomarcadores tradicionales	Creatinina, Cistatina C	Estimación de función renal
Biomarcadores emergentes	NGAL, KIM-1, IL-18, $\beta$ 2-microglobulina, FLC	Detección temprana de LRA, pronóstico en ERC
Datos clínicos	Historia médica, tratamientos, imagen médica	Contextualización y personalización del riesgo
Inteligencia Artificial	Machine Learning, XGBoost, redes neuronales	Predicción de LRA/ERC, ajuste de tratamientos
Aplicaciones clínicas	Trasplante renal, ERC diabética, hipertensión	Individualización del tratamiento
Retos éticos y técnicos	Privacidad, formación, interoperabilidad	Implementación segura y equitativa

#### REFERENCIAS

- 1 Topol EJ. “High-performance medicine: the convergence of human and artificial intelligence.” *Nature Medicine*. 2019;25(1):44-56.
- 2 Pan HC, Yang SY, Chiou TT, Shiao CC, Wu CH, Huang CT, Wang TJ, Chen JY, Liao HW, Chen SY, Huang TM, Yang YF, Lin HY, Chan MJ, Sun CY, Chen YT, Chen YC, Wu VC. Comparative accuracy of biomarkers for the prediction of hospital-acquired acute kidney injury: a systematic review and meta-analysis. *Crit Care*. 2022;26(1):349.
- 3 Romejko K, Markowska M, Niemczyk S. The Review of Current Knowledge on Neutrophil Gelatinase-Associated Lipocalin (NGAL). *Int J Mol Sci*. 2023;24(13):10470.
- 4 Coca SG, Nadkarni GN, Huang Y, Moledina DG, et al. Plasma Biomarkers and Kidney Function Decline in Early and Established Diabetic Kidney Disease. *J Am Soc Nephrol*. 2017;28(9):2786-2793.
- 5 Qin Z, Li H, Jiao P, Jiang L, Geng J, Yang Q, Liao R, Su B. The value of urinary interleukin-18 in predicting acute kidney injury: a systematic review and meta-analysis. *Ren Fail*. 2022;44(1):1717-1731.
- 6 Snyder L, Chawla LS, Goldstein SL. “Use of biomarkers and artificial intelligence in acute kidney injury risk prediction.” *Nature Reviews Nephrology*. 2020;16(7):415-430.



## 13.

### IA GENERATIVA (GEN AI): EDUCACIÓN MÉDICA [NEFROLOGÍA]

---

La inteligencia artificial generativa es una rama de la IA que se especializa en la creación de contenido nuevo y original, ya sea texto, imágenes, audio o videos, basándose en los datos con los que ha sido entrenada. A diferencia de los métodos tradicionales de aprendizaje automático, que se centran principalmente en la predicción o la clasificación, la IA generativa tiene la capacidad única de producir resultados novedosos que imitan los datos del mundo real.

Entre los conceptos clave se encuentran los Modelos de Lenguaje Extenso (LLMs, por sus siglas en inglés), como ChatGPT, que han demostrado una notable capacidad para comprender y generar texto similar al humano. Estos modelos utilizan grandes cantidades de datos textuales para aprender patrones lingüísticos y, posteriormente, generar respuestas coherentes y contextualmente relevantes a diversas indicaciones.

Un aspecto fundamental para trabajar con la IA generativa es la ingeniería de prompts. Este proceso consiste en elaborar instrucciones o preguntas efectivas (prompts) para guiar a los modelos de IA y obtener los resultados deseados. La calidad del prompt tiene un impacto directo en la salida del modelo, por lo que aprender a diseñar prompts claros y específicos es

una habilidad esencial para cualquier persona que desee utilizar la IA generativa de manera eficaz.

#### 13.1 PRINCIPALES PROGRAMAS DE IA GENERATIVA

La Gen AI está en pleno desarrollo y en la Tabla 14 podemos ver las más conocidas.

#### 13.2 APLICACIONES DE LA IA GENERATIVA PARA EDUCADORES Y PROFESIONALES

La inteligencia artificial generativa (GenAI) está transformando rápidamente diversos sectores, incluyendo la atención médica y la educación. Existe un interés creciente en explorar sus posibles aplicaciones en la educación médica, donde podría revolucionar la forma en que los estudiantes aprenden y los educadores enseñan [1]. La rápida evolución y la disponibilidad casi ubicua de herramientas de GenAI como ChatGPT han hecho que esta tecnología sea accesible para educadores y estudiantes por igual.

La GenAI ofrece numerosas oportunidades para la creación de materiales de aprendizaje y la personalización de la educación médica y entre ellas la creación automática de preguntas tipo USMLE [2] como podemos ver en la Tabla 15.

**TABLA 14.** Programas de Inteligencia Artificial Generativa (Actualización: abril 2025)

NOMBRE	MODALIDAD	DESARROLLADOR	DESCRIPCIÓN BREVE
ChatGPT	Multimodal	OpenAI	Modelo de lenguaje avanzado que genera texto coherente y mantiene conversaciones naturales.
Gemini	Multimodal	Google DeepMind	Modelo capaz de procesar y generar texto, imágenes y audio; sucesor de LaMDA y PaLM 2.
Copilot	Código	Microsoft	Asistente de programación que sugiere código y funciones en tiempo real dentro de entornos de desarrollo.
DeepSeek	Texto	DeepSeek	Chatbot avanzado conocido por su eficiencia y precisión en respuestas.
Apple Intelligence	Multimodal	Apple Inc.	Sistema de IA integrado en dispositivos Apple que ofrece funcionalidades como edición de texto, generación de imágenes y mejoras en Siri.
Manus	Multimodal	Monica	Agente de IA autónomo capaz de realizar tareas complejas en línea sin supervisión humana continua.
Gemma	Texto	Google DeepMind	Colección de modelos de lenguaje de código abierto optimizados para diferentes aplicaciones.
Grok	Texto	xAI	Chatbot desarrollado por xAI, conocido por su humor y acceso a datos en tiempo real desde X (antes Twitter).
MusicLM	Música	Google	Generador de música a partir de texto, capaz de crear composiciones musicales realistas.
Riffusion	Música	Independiente	Generador de música que convierte texto en audio musical en tiempo real.
MuseNet	Música	OpenAI	Generador de música que crea composiciones en diversos géneros y estilos.
Voicemod	Voz	Voicemod	Herramienta de modificación de voz en tiempo real con más de 210 voces disponibles.
Descript	Voz/Vídeo	Descript Inc.	Plataforma de edición de audio y vídeo que permite editar contenido manipulando texto.
Sonix	Voz/Vídeo	Sonix	Herramienta de transcripción y traducción automática de audio y vídeo con alta precisión.
Sora	Vídeo	OpenAI	Modelo que genera vídeos realistas a partir de descripciones textuales.
Movie Gen	Vídeo	Meta	Generador de vídeos de hasta 16 segundos en 1080p a partir de texto.
DeepBrain AI	Vídeo	DeepBrain	Plataforma que crea vídeos a partir de texto utilizando avatares realistas.
Lumen5	Vídeo	Lumen5	Herramienta que transforma contenido escrito en vídeos atractivos para redes sociales.
Clipchamp	Vídeo	Microsoft	Editor de vídeo con funciones de IA, incluyendo texto a voz y plantillas personalizables.

**TABLA 15.** Aplicaciones de la IA Generativa en medicina relevantes para los educadores

ÁREA DE APLICACIÓN	EJEMPLOS Y USOS ESPECÍFICOS
Mejora de la enseñanza y el aprendizaje	<ul style="list-style-type: none"> <li>- Simulaciones clínicas virtuales seguras y realistas.</li> <li>- Modelos anatómicos humanos en 3D.</li> <li>- Cirugías simuladas interactivas.</li> <li>- Generación de casos clínicos para diagnóstico.</li> <li>- Creación automática de preguntas tipo USMLE.</li> <li>- Personalización del aprendizaje según el estudiante.</li> </ul>
Apoyo a la investigación médica e innovación	<ul style="list-style-type: none"> <li>- Generación de estructuras moleculares para descubrimiento de fármacos.</li> <li>- Análisis avanzado de imágenes médicas.</li> <li>- Producción de datos sintéticos respetando la privacidad.</li> <li>- Automatización del análisis de literatura científica.</li> <li>- Identificación de nuevas correlaciones clínicas.</li> </ul>
Agilización de tareas administrativas	<ul style="list-style-type: none"> <li>- Redacción de notas clínicas y resúmenes automatizados.</li> <li>- Generación de códigos de facturación y reclamaciones.</li> <li>- Programación de citas y recordatorios automáticos.</li> <li>- Automatización del ingreso de datos y gestión de admisión.</li> <li>- Extracción eficiente de datos clínicos.</li> </ul>
Apoyo a la práctica clínica y educación	<ul style="list-style-type: none"> <li>- Asistencia a la toma de decisiones clínicas personalizadas.</li> <li>- Recomendaciones preventivas basadas en datos del paciente.</li> <li>- Chatbots educativos para pacientes.</li> <li>- Apoyo al diagnóstico y planificación terapéutica.</li> <li>- Exposición temprana de estudiantes a tecnologías clínicas emergentes.</li> </ul>

### 13.3 VENTAJAS DE LA IA EN LA ESTRUCTURACIÓN DE TEXTO

La capacidad de la IA generativa para procesar y estructurar texto no estructurado tiene un efecto en cascada, mejorando diversas funciones de la atención médica, desde la eficiencia en la investigación o la enseñanza [3] hasta la toma de decisiones clínicas y la participación del paciente mediante informes simplificados. Los datos no estructurados en los registros electrónicos de salud (EHRs) representan una barrera significativa para aprovechar plenamente la información del paciente, pero los modelos de lenguaje (LLMs) permiten convertirlos en formatos estructurados, facilitando su uso en análisis, investigación y aplicaciones clínicas. Esta estructuración inicial genera beneficios como una investigación más rápida,

una mejor toma de decisiones y una comunicación más eficiente [4]

### 13.4 RESUMEN CLÍNICO EN CONSULTA EN TIEMPO REAL

Los programas de voz en consulta son sistemas basados en inteligencia artificial que transcriben y resumen automáticamente la conversación entre el médico y el paciente durante una consulta. Utilizan modelos avanzados de procesamiento de lenguaje natural (NLP) para convertir el habla en texto estructurado y generar un resumen clínico en tiempo real. Estos sistemas permiten reducir la carga administrativa del personal médico, optimizando el tiempo de consulta y mejorando la calidad de la documentación en los registros electrónicos de salud. Además, facilitan la

obtención de información relevante para la toma de decisiones médicas, asegurando que los datos clínicos sean precisos y completos [5], Figura 14.

Un ejemplo de un programa validado en este ámbito es Nuance DAX (Dragon Ambient eXperience), desarrollado por Nuance (una empresa de Microsoft). Este sistema utiliza IA para capturar automáticamente las conversaciones médico-paciente, generar notas clínicas estructuradas y enviarlas directamente al historial médico electrónico, permitiendo a los médicos centrarse en la atención del paciente en lugar de en la documentación.

### 13.5 ENSAYOS CLÍNICOS

Algunas empresas ofrecen modelos que crean representaciones digitales de pacientes basadas en datos de ensayos clínicos previos y estudios observacionales. Los modelos de IA generativa predicen cómo progresaría probablemente la salud de cada participante durante el ensayo si no recibiera el tratamiento en

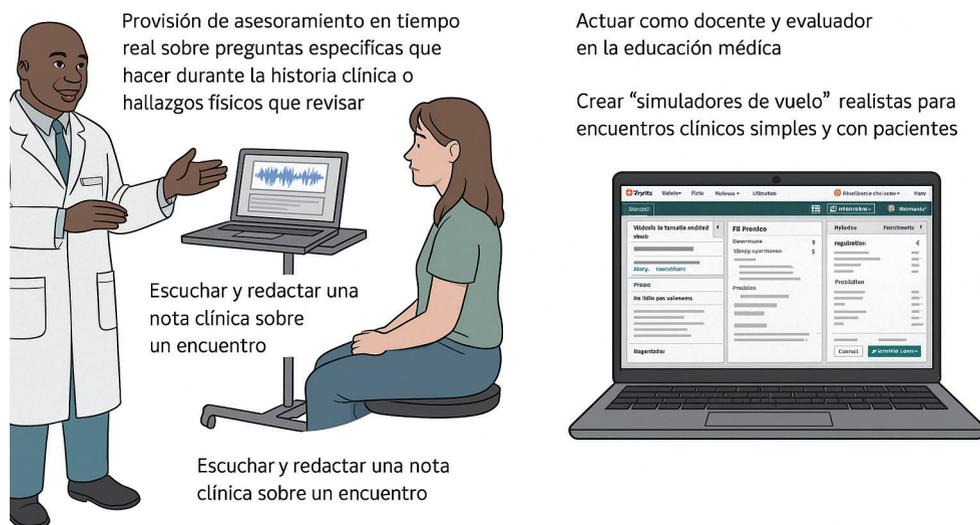
evaluación. Estas predicciones podrían aumentar la confianza en los resultados de ensayos clínicos de menor escala [6].

### 13.6 IA Y EDUCACIÓN MÉDICA

La integración de la GenAI en el diseño curricular y la evaluación puede dar lugar a un sistema de educación médica más adaptativo y receptivo, donde los objetivos de aprendizaje y los métodos de enseñanza se ajustan continuamente en función de los datos de rendimiento estudiantil y la evolución del conocimiento médico. La IA permite un análisis granular del desempeño de los estudiantes, proporcionando a los educadores información valiosa sobre las áreas en las que tienen dificultades recurrentes. Estos datos pueden utilizarse para refinar planes de estudio, adaptar métodos de enseñanza y ofrecer apoyo específico, contribuyendo a un sistema educativo más eficaz.

Asimismo, la GenAI se emplea para crear simulaciones realistas y evaluar habilidades en la educación médica. Puede generar escenarios

FIGURA 14. Programas de voz en consulta



clínicos complejos y realistas que permiten a los estudiantes practicar diagnóstico y planificación de tratamiento en entornos virtuales [7]. A través de visitas de telesalud simuladas con pacientes estandarizados generados por IA, los alumnos pueden perfeccionar sus habilidades de comunicación y clínicas [8]. Estos pacientes virtuales representan una amplia gama de perfiles humanos, superando las limitaciones de los grupos de actores y pueden proporcionar retroalimentación en tiempo real sobre las intervenciones y habilidades de comunicación de los estudiantes. Además, la IA puede evaluar las interacciones con estos pacientes virtuales y las notas de los alumnos en los registros médicos analizando patrones en sus preguntas y toma de decisiones para ofrecer retroalimentación valiosa. También se puede utilizar para calificar el trabajo estudiantil y brindar apoyo personalizado en el aprendizaje, así como para resumir evaluaciones narrativas en solicitudes de residencia, mejorando su calidad y reduciendo el tiempo requerido [9]. En el aprendizaje basado en problemas, la GenAI puede responder preguntas a lo largo de los escenarios, reflejando la evolución del conocimiento a medida que el caso avanza [10].

La IA generativa ofrece una alternativa escalable y rentable a los métodos tradicionales de simulación con actores humanos, permitiendo más oportunidades de práctica en un entorno seguro y controlado. La logística y los costos asociados con la contratación y programación de pacientes estandarizados humanos pueden ser limitaciones significativas para las escuelas de medicina, mientras que los pacientes virtuales y las simulaciones con GenAI pueden superar estas barreras [11]. Esto brinda a los estudiantes más oportunidades para practicar habilidades clínicas e interactuar con una mayor diversidad de casos, incluyendo condiciones raras o de alto riesgo.

Además, el uso de IA en la evaluación clínica permite obtener valoraciones más objetivas y estandarizadas que los métodos tradicionales, proporcionando análisis consistentes e imparciales de la competencia de los estudiantes. Al entrenar modelos en criterios específicos de evaluación, la IA puede identificar áreas de mejora y garantizar una medición más precisa del desempeño clínico.

### 13.7 IA GENERATIVA COMPARADA CON MÉDICOS

Takita y cols. en un metaanálisis revisó 83 estudios publicados entre junio de 2018 y junio de 2024 que evaluaban el rendimiento diagnóstico de modelos de inteligencia artificial generativa (IA) en comparación con médicos. La precisión diagnóstica global de los modelos de IA fue del 52,1 %. No se observaron diferencias significativas en el rendimiento entre los modelos de IA y los médicos en general ( $p = 0,10$ ), ni con médicos no expertos ( $p = 0,93$ ), aunque sí fueron significativamente inferiores a los médicos expertos ( $p = 0,007$ ). Algunos modelos como GPT-4, Claude 3 y Gemini 1.5 Pro mostraron un rendimiento comparable al de médicos no expertos, aunque sin alcanzar el nivel de expertos. La revisión también destacó una alta heterogeneidad y riesgo de sesgo en muchos estudios. Pese a sus limitaciones, los hallazgos sugieren que la IA generativa tiene potencial como herramienta complementaria en entornos con recursos limitados y en educación médica, especialmente si se implementa con comprensión crítica de sus límites [12].

### 13.8 VENTAJAS Y DIFICULTADES DE LA IA EN LA FORMACIÓN MÉDICA

En la Tabla 16 se encuentran las ventajas y las dificultades. La inteligencia artificial generativa (GenAI) ofrece un conjunto significativo de oportunidades para transformar la

**TABLA 16.** Inteligencia Artificial Generativa: ventajas y dificultades

VENTAJAS/DIFICULTADES	DESCRIPCIÓN
Materiales de aprendizaje personalizados	La GenAI puede crear guías de estudio, cuestionarios y ejercicios personalizados.
Experiencias de aprendizaje adaptativas	La GenAI puede actuar como un tutor personalizado, adaptándose a las necesidades de cada estudiante.
Simulaciones clínicas realistas	La GenAI puede generar casos clínicos complejos y pacientes virtuales para la práctica.
Evaluación automatizada	Las plataformas impulsadas por IA pueden evaluar las respuestas de los estudiantes y proporcionar retroalimentación instantánea.
Precisión y fiabilidad	El contenido generado por IA a veces puede ser incorrecto y requiere supervisión humana.
Consideraciones éticas y de privacidad	El uso de la IA plantea preocupaciones sobre la privacidad de los datos, el sesgo y la mala conducta académica.
Sesgo y diversidad	Los modelos de IA pueden contener sesgos si se entrenan con datos limitados o no representativos.
Impacto en el aprendizaje	La dependencia excesiva de la IA podría obstaculizar el desarrollo de habilidades esenciales.
Preparación del profesorado	Los educadores necesitan capacitación para integrar eficazmente la IA en sus métodos de enseñanza.
Políticas y directrices	La mayoría de las instituciones médicas carecen de políticas claras para el uso de la IA.

educación médica. Entre sus aplicaciones más destacadas se encuentra la creación de materiales de aprendizaje personalizados, como guías de estudio, ejercicios y cuestionarios adaptados al nivel y ritmo de cada estudiante. Además, permite desarrollar experiencias de aprendizaje adaptativas, actuando como un tutor virtual que responde a las necesidades individuales y ofrece apoyo en tiempo real.

Otra oportunidad clave es la posibilidad de generar simulaciones clínicas realistas, mediante la creación de casos complejos y pacientes virtuales que permiten practicar habilidades diagnósticas y terapéuticas sin riesgo para el paciente. Asimismo, la GenAI

facilita la evaluación automatizada, proporcionando retroalimentación instantánea y liberando tiempo del profesorado para tareas más analíticas y pedagógicas.

Estas capacidades, bien implementadas, pueden enriquecer significativamente la calidad del aprendizaje, aumentar la personalización de la enseñanza y fomentar una formación médica más práctica, dinámica y centrada en el estudiante.

No obstante, la integración de la IA generativa en la formación médica presenta desafíos y consideraciones importantes. La educación médica requiere información precisa y actualizada, pero el contenido generado por IA

puede contener errores (alucinaciones). Por ello, es fundamental la supervisión humana y la verificación cruzada con fuentes médicas confiables [13]. También surgen preocupaciones sobre privacidad de datos, monitorización estudiantil y el uso ético de la IA, lo que exige el cumplimiento de regulaciones. Los modelos de IA entrenados con datos limitados pueden introducir sesgos, generando contenido educativo incompleto o engañoso, por lo que es esencial utilizar conjuntos de datos diversos y de alta calidad para garantizar una educación médica integral. La facilidad de acceso a la GenAI plantea riesgos como la mala conducta académica, el engaño y problemas de atribución del contenido generado, por lo que las instituciones deben establecer políticas y programas de formación adecuados [14]. Además, una dependencia excesiva de la GenAI podría afectar el desarrollo del pensamiento crítico, la resolución de problemas y el aprendizaje independiente en los estudiantes de medicina por lo que es esencial un enfoque equilibrado en su adopción.

Para afrontar estos retos, los educadores médicos deben conocer bien las ventajas y limitaciones de la GenAI para guiar a los estudiantes de manera efectiva. Sin embargo, la mayoría de las facultades de medicina carecen actualmente de políticas y formación en GenAI para alumnos, profesores y administradores [15]. La integración de esta tecnología exige una reestructuración de los métodos tradicionales de evaluación para medir adecuadamente las habilidades de los estudiantes en un entorno impulsado por IA [16]. Además, la distribución desigual de la tecnología y los recursos de IA podría aumentar las disparidades dentro del sistema educativo. Actualmente, muchas facultades de medicina no tienen normativas claras sobre el uso de la GenAI ni planes formales para su implementación [17].

## REFERENCIAS

- 1 Science & Tech Spotlight: Generative AI in Health Care | U.S. GAO, <https://www.gao.gov/products/gao-24-107634>
- 2 Kung TH, Cheatham M, Medenilla A, Sillos C, De Leon L, Elepaño C, Madriaga M, Aggabao R, Diaz-Candido G, Maningo J, Tseng V. Performance of ChatGPT on USMLE: Potential for AI-assisted medical education using large language models. *PLOS Digit Health*. 2023;2(2):e0000198.
- 3 Biswas S. ChatGPT and the Future of Medical Writing. *Radiology*. 2023;307(2):e22331.
- 4 Gordon M, Daniel M, Ajiboye A, Uraiby H, Xu NY, Bartlett R, Hanson J, Haas M, Spadafore M, Grafton-Clarke C, Gasiea RY, Michie C, Corral J, Kwan B, Dolmans D, Thammasitboon S. A scoping review of artificial intelligence in medical education: BEME Guide No. 84. *Med Teach*. 2024;46(4):446-470.
- 5 Haug CJ, Drazen JM. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. *N Engl J Med*. 2023;388(13):1201-1208.
- 6 Harrer S, Shah P, Antony B, Hu J. Artificial Intelligence for Clinical Trial Design. *Trends Pharmacol Sci*. 2019;40(8):577-591.
- 7 Parente DJ. Generative Artificial Intelligence and Large Language Models in Primary Care Medical Education. *Fam Med*. 2024;56(9):534-540.
- 8 Karabacak M, Ozkara BB, Margetis K, Wintermark M, Bisdas S. The Advent of Generative Language Models in Medical Education. *JMIR Med Educ*. 2023;9:e48163.
- 9 Weller JM, Coomber T, Chen Y, Castanelli DJ. Key dimensions of innovations in workplace-based assessment for postgraduate medical education: a scoping review. *Br J Anaesth*. 2021;127(5):689-703.
- 10 Sauder M, Tritsch T, Rajput V, Schwartz G, Shoja MM. Exploring Generative Artificial Intelligence-Assisted Medical Education: Assessing Case-Based Learning for Medical Students. *Cureus*. 2024;16(1):e51961.
- 11 Simulaciones con GenAI <https://www.youtube.com/watch?v=Tq0kftd9zjk>

- 12 Takita, H., Kabata, D., Walston, S.L. et al. A systematic review and meta-analysis of diagnostic performance comparison between generative AI and physicians. 2025; 8:175.
- 13 Almansour M, Soliman M, Aldekhyyel R, et al. An Academic Viewpoint (2025) on the Integration of Generative Artificial Intelligence in Medical Education: Transforming Learning and Practices. *Cureus*. 2025;17(3): e81145. <https://doi.org/10.7759/cureus.81145>
- 14 Preiksaitis C, Rose C. Opportunities, Challenges, and Future Directions of Generative Artificial Intelligence in Medical Education: Scoping Review. *JMIR Med Educ*. 2023;9:e48785.
- 15 Janumpally R, Nanua S, Ngo A, Youens K. Generative artificial intelligence in graduate medical education. *Front Med (Lausanne)*. 2025;11:1525604.
- 16 Rodman A, Mark NM, Artino AR Jr, Lessing JN. Using Generative Artificial Intelligence in Medical Education. *Acad Med*. 2025;100(2):250.
- 17 Hallquist E, Gupta I, Montalbano M, Loukas M. Applications of Artificial Intelligence in Medical Education: A Systematic Review. *Cureus*. 2025;17(3):e79878.

## 14.

### RAZONES PARA QUE LOS ESPECIALISTAS EN NEFROLOGÍA SE IMPLIQUEN EN LA IA

---

Los especialistas en Nefrología deben involucrarse activamente en la inteligencia artificial porque esta tecnología no sólo está transformando la práctica médica, sino que también redefinirá el rol de los profesionales de la salud en las próximas décadas [1]. La IA no es sólo una herramienta de apoyo, sino un nuevo paradigma en la toma de decisiones clínicas, la personalización de tratamientos y la gestión del conocimiento médico. Aquellos que comprendan su funcionamiento y sus aplicaciones tendrán una ventaja significativa en su desarrollo profesional y en la calidad de la atención que brinden a sus pacientes.

Uno de los principales motivos por los cuales deben implicarse en la IA es su capacidad para mejorar la eficiencia en el trabajo clínico. Desde la automatización de tareas administrativas hasta la asistencia en diagnósticos complejos, la IA puede reducir la carga de trabajo y permitir que los médicos se concentren en lo más importante: la atención directa al paciente. Adoptar estas herramientas no sólo optimiza el tiempo en consulta, sino que también minimiza errores humanos, mejorando la seguridad del paciente [2].

Además, la IA está democratizando el acceso al conocimiento médico. Con el crecimiento de bases de datos y modelos de aprendizaje automático, los profesionales pueden acceder

a información actualizada en tiempo real, ayudando a tomar decisiones más fundamentadas. Esto es especialmente relevante en una era donde la cantidad de información médica crece exponencialmente y es imposible para un solo individuo mantenerse al día con todos los avances. La IA puede actuar como un asistente cognitivo que facilita el aprendizaje continuo y la toma de decisiones basadas en evidencia.

Otro aspecto crucial es el papel de los médicos en la supervisión ética y la implementación responsable de la IA. Si bien los avances tecnológicos pueden ser impresionantes, la medicina no puede depender exclusivamente de algoritmos sin el juicio clínico humano. Los médicos jóvenes, al estar más familiarizados con la tecnología, tienen la oportunidad de liderar el desarrollo y la validación de estas herramientas, asegurando que se utilicen de manera justa, segura y sin sesgos que puedan afectar a los pacientes.

Por último, involucrarse en la IA no sólo ofrece ventajas clínicas, sino que también abre nuevas oportunidades profesionales. La medicina del futuro no sólo necesitará clínicos expertos en enfermedades, sino también profesionales con habilidades en datos, bioinformática y desarrollo de tecnología médica. La intersección entre la IA y la medicina será un campo de innovación constante, donde los

jóvenes médicos pueden desempeñar roles clave en la creación de nuevas soluciones para los desafíos de la salud global [3].

En resumen, la inteligencia artificial no es sólo una herramienta para facilitar la práctica médica; es un cambio de paradigma que requiere la participación activa de los nuevos profesionales. Quienes se formen en esta área no solo mejorarán la calidad de su ejercicio clínico, sino que también tendrán un papel fundamental en la evolución de la medicina. La IA no reemplazará a los médicos, pero los médicos que sepan usar la IA reemplazarán a aquellos que no lo hagan. Aprender IA no es opcional, es parte de ser un buen médico en el siglo XXI.

#### REFERENCIAS

- 1 Topol EJ. "High-performance medicine: the convergence of human and artificial intelligence." *Nature Medicine*. 2019;25(1):44-56.
- 2 Jeong J, Kim S, Pan L, Hwang D, Kim D, Choi J, Kwon Y, Yi P, Jeong J, Yoo SJ. Reducing the workload of medical diagnosis through artificial intelligence: A narrative review. *Medicine (Baltimore)*. 2025 Feb 7;104(6):e41470Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J*. 2019;6(2):94-98.
- 3 Bradley SH. Forget about replacing doctors with AI-just get our computers to work. *BMJ*. 2024;385:q1171.

## 15.

### DESAFÍOS ACTUALES QUE ENFRENTA LA IMPLEMENTACIÓN DE LA IA EN LA PRÁCTICA CLÍNICA

En los capítulos precedentes hemos revisado la aplicación de la IA en Nefrología y siempre aparece una alusión a las dificultades que no hacen fácil esa aplicación al día a día del trabajo de los médicos y personal sanitario y administrativo. A pesar de los importantes beneficios de la inteligencia artificial (IA) en el ámbito clínico, su implementación enfrenta múltiples obstáculos que dificultan su integración efectiva en la práctica médica diaria. Estos desafíos no son triviales, ya que abarcan dimensiones técnicas, éticas, legales

y humanas que deben ser cuidadosamente abordadas para garantizar un uso seguro y equitativo de estas tecnologías. Pueden observarse en la Tabla 17.

Uno de los principales problemas es el sesgo en los algoritmos de IA, que puede surgir en distintas etapas del proceso, desde la recolección hasta el análisis de los datos. Estos sesgos suelen originarse en muestras de datos no representativas o reflejar desigualdades estructurales ya existentes en la atención sanitaria. Un ejemplo preocupante es el uso

**TABLA 17.** Principales desafíos en la implementación de la IA en medicina

DESAFÍO	DESCRIPCIÓN	FUENTE
Sesgo algorítmico	Introducido desde la fase de datos; puede perpetuar desigualdades en salud	1, 2
Calidad de los datos	Datos clínicos heterogéneos, no estructurados, incompletos y fragmentados	3
Caja negra	Falta de transparencia en el proceso de toma de decisiones de los algoritmos	4
Seguridad	Riesgo ante cambios de contexto clínico; sensibilidad a cambios de distribución en los datos	5
Responsabilidad legal	Falta de claridad sobre quién asume la responsabilidad en errores relacionados con decisiones de IA	6, 7
Ética y privacidad	Preocupaciones por la equidad, privacidad, participación del paciente y uso por aseguradoras	8

de ajustes en la tasa de filtración glomerular basados en raza, que puede retrasar el diagnóstico y tratamiento de la enfermedad renal en pacientes afroamericanos [1,2].

Otro obstáculo significativo es la calidad de los datos. Los datos clínicos suelen ser heterogéneos, no estandarizados y estar incrustados en notas clínicas no estructuradas. Además, se almacenan de forma local y fragmentada entre diferentes plataformas de historias clínicas electrónicas, lo que dificulta su procesamiento por parte de los modelos de aprendizaje automático. La falta de etiquetado, datos que faltan y la variabilidad entre centros agravan el problema y pueden comprometer el rendimiento y la generalización de los modelos. Una solución potencial es la integración de los modelos de IA con los registros electrónicos para recoger datos en tiempo real y preprocesarlos automáticamente, identificando valores anómalos y errores de muestreo, lo cual también reduciría la carga de trabajo humano [3].

La falta de transparencia, especialmente en los sistemas de IA tipo «caja negra», genera desconfianza entre los profesionales sanitarios. Estos sistemas no permiten comprender con claridad cómo se han procesado los datos ni cómo se ha llegado a una determinada decisión. En algunos casos, ni siquiera los desarrolladores del modelo entienden completamente su funcionamiento [4]. Esta opacidad es particularmente preocupante cuando los algoritmos participan en decisiones médicas críticas, como diagnósticos o tratamientos que afectan directamente la vida de los pacientes.

La seguridad clínica también es un tema delicado. A diferencia de los médicos, que tienden a adoptar decisiones conservadoras ante la incertidumbre diagnóstica, los modelos de IA pueden comportarse de forma arriesgada, especialmente si enfrentan un

contexto clínico diferente al utilizado durante su entrenamiento (problema de cambio de distribución). Aunque entrenar los modelos en múltiples conjuntos de datos puede mitigar este riesgo, no lo elimina completamente [5].

En cuanto a los aspectos legales, la IA médica está sujeta a regulación por parte de organismos como la Food and Drug Administration (FDA), que considera el software basado en aprendizaje automático como un dispositivo médico. En 2019, la FDA propuso un marco regulador específico para este tipo de software, similar al de los dispositivos médicos tradicionales [6]. Asimismo, la Asociación Médica Americana (AMA) ha recomendado extender la responsabilidad legal a los desarrolladores y organizaciones que promuevan el uso de IA sin considerar medidas de mitigación de riesgos [7].

Por último, no se pueden ignorar los dilemas éticos vinculados a la equidad algorítmica, la transparencia, la privacidad de los datos y la rendición de cuentas. Un área especialmente sensible es la influencia de los algoritmos en la toma de decisiones por parte de aseguradoras, lo que podría afectar la aprobación o denegación de tratamientos, socavando la autonomía médica e incluso la participación del paciente. La pregunta de quién debe asumir la responsabilidad en caso de errores médicos provocados por decisiones algorítmicas –el médico o el desarrollador– sigue siendo motivo de preocupación [8].

## REFERENCIAS

- 1 Vyas DA, Eisenstein LG, Jones DS. Hidden in plain sight reconsidering the use of race correction in clinical algorithms. *N Engl J Med.* 2020;383(9):874-882.
- 2 Eneanya ND, Boulware LE, Tsai J, et al. Health inequities and the inappropriate use of race in nephrology. *Nat Rev Nephrol.* 2022;18(2):84-94.

- 3 Loftus TJ, Shickel B, Ozrazgat-Baslanti T, et al. Artificial intelligence-enabled decision support in nephrology. *Nat Rev Nephrol.* 2022;18(7):452-465.
- 4 Rudin C, Radin J. Why are we using black box models in AI when we don't need to? A lesson from an explainable AI competition. *Harvard Data Science Review.* 2019;1(2).
- 5 Amodei D, Olah C, Steinhardt J, Christiano P, Schulman J, Mane D. Concrete problems in AI safety. *ArXiv.* 2016. abs/1606.06565).
- 6 US FDA. Good Machine Learning Practice for Medical Device Development: Guiding Principles. Accessed October 1, 2024. <https://www.fda.gov/medical-devices/software-medical-devicesamd/good-machine-learning-practice-medical-device-developmentguiding-principles>
- 7 American Medical Association. AMA issues new principles for AI development, deployment & use. <https://www.ama-assn.org/press-center/press-releases/ama-issues-new-principles-ai-development-deployment-use>
- 8 Vayena E, Blasimme A, Cohen IG. Machine Learning in medicine: addressing ethical challenges. *PLoS Med.* 2018;15(11): e1002689.



## 16.

### EL PACIENTE RENAL Y SU PARTICIPACIÓN EN LA IA EN NEFROLOGÍA

---

La participación activa de los pacientes no sólo es ética sino también fundamental para el desarrollo efectivo y centrado en el paciente de herramientas de IA en Nefrología. Al involucrar a los pacientes en el proceso, se puede asegurar que estas tecnologías aborden las necesidades y preocupaciones del mundo real de quienes viven con enfermedades renales. Los principios de la «Medicina 4P» (Preventiva, Predictiva, Personalizada y Participativa) subrayan la importancia de la participación del paciente en el desarrollo e implementación de la IA en Nefrología, asegurando que estas tecnologías se alineen con los objetivos de una atención médica proactiva, individualizada e inclusiva. Los pacientes aportan perspectivas y conocimientos únicos al desarrollo de herramientas de IA, que a menudo no son evidentes para los clínicos o desarrolladores, especialmente en lo que respecta a los desafíos prácticos y las experiencias vividas en la gestión de la enfermedad renal. Al participar activamente en la definición de las prioridades de investigación para la IA en Nefrología, los pacientes pueden ayudar a cerrar la brecha entre las capacidades técnicas de la IA y las necesidades y desafíos reales que enfrentan a diario, garantizando que los esfuerzos de desarrollo se centren en la creación de soluciones que realmente mejoren sus vidas [1].

#### 16.1 CONTRIBUCIÓN DE LOS PACIENTES AL DESARROLLO DE LA IA EN NEFROLOGÍA

En la Tabla 18 se encuentran las contribuciones, beneficios y desafíos éticos de la participación de los pacientes. Los pacientes desempeñan un papel fundamental en el desarrollo de la inteligencia artificial [2]. Su principal contribución radica en el suministro de datos clínicos, información sobre su estilo de vida y retroalimentación sobre sus experiencias, todos ellos elementos clave para entrenar y validar los modelos de IA. Además, la participación activa en estudios y ensayos clínicos permite validar estas herramientas en entornos reales, garantizando su seguridad y efectividad. Los pacientes también colaboran en el diseño de aplicaciones más intuitivas, adaptadas a sus necesidades, lo que mejora la usabilidad y la aceptación de estas tecnologías.

#### 16.2 BENEFICIOS Y DESAFÍOS DE LA PARTICIPACIÓN DE LOS PACIENTES

Su participación contribuye a una atención médica más personalizada, facilita el diagnóstico precoz y mejora la autogestión de la enfermedad renal. Asimismo, fomenta una toma de decisiones compartida con los profesionales de la salud y una mayor comprensión de su propia condición. Sin embargo,

**TABLA 18.** Contribuciones, beneficios y desafíos éticos de la participación de los pacientes en la IA de Nefrología

CATEGORÍA	DESCRIPCIÓN
Contribuciones de los pacientes	<ul style="list-style-type: none"> <li>- Proporcionan datos clínicos y de estilo de vida</li> <li>- Participan en estudios y ensayos clínicos</li> <li>- Ofrecen retroalimentación sobre herramientas IA</li> <li>- Contribuyen al diseño de interfaces amigables</li> </ul>
Beneficios de su participación	<ul style="list-style-type: none"> <li>- Atención médica personalizada</li> <li>- Diagnóstico más temprano</li> <li>- Mejora en la comprensión de la enfermedad</li> <li>- Aumento en la toma de decisiones compartida</li> </ul>
Ejemplos de aplicación	<ul style="list-style-type: none"> <li>- Preferencias en modalidades de diálisis</li> <li>- Encuestas sobre planificación anticipada de cuidados</li> <li>- Becas centradas en impacto de la ERC en la vida diaria</li> </ul>
Desafíos éticos y consideraciones	<ul style="list-style-type: none"> <li>- Protección de datos personales</li> <li>- Consentimiento informado real</li> <li>- Posibilidad de sesgo en los algoritmos</li> <li>- Preservar la relación médico-paciente</li> </ul>
Importancia de la colaboración	<ul style="list-style-type: none"> <li>- Promueve innovación responsable</li> <li>- Asegura que la IA sirva a necesidades reales</li> <li>- Potencia el papel activo del paciente en su salud</li> </ul>

esta colaboración también plantea desafíos éticos como la protección de la privacidad, el consentimiento informado y la equidad en los algoritmos, así como la necesidad de mantener la relación humano-clínico en el proceso asistencial. Por tanto, la integración ética y efectiva de los pacientes en el desarrollo de la IA resulta clave para una innovación tecnológica responsable y centrada en el ser humano en el ámbito de la Nefrología.

#### REFERENCIAS

- 1 Obermeyer Z, Topol EJ. Artificial intelligence, bias, and patients' perspectives. *Lancet*. 2021;397(10289):2038.
- 2 Plan estratégico grupo de la Sociedad Española de Nefrología (s.e.n.) big data, inteligencia artificial (BIGSEN) (2024-2027) <https://www.senefro.org/contents/work-groups/files/5/439bbbd1-4316-4013-aae5-20e35aa5c0fa.pdf>

## 17.

### DISEÑO PRÁCTICO DE UN ESTUDIO CON INTELIGENCIA ARTIFICIAL EN ENFERMEDAD RENAL CRÓNICA (ERC - CKD)

---

Vamos a ver un ejemplo de diseño de un estudio utilizando inteligencia artificial (IA) para la predicción de la evolución de la enfermedad renal crónica (ERC-CKD). Incluiremos las variables clave, los pasos metodológicos y un ejemplo práctico con una explicación accesible del proceso [1].

#### 17.1 VARIABLES CLAVE PARA LA PREDICCIÓN DE LA EVOLUCIÓN DE LA ERC

Antes de diseñar el modelo, es fundamental definir las variables que influirán en la predicción.

- Variables demográficas y clínicas:
  - » Edad
  - » Sexo
  - » IMC (Índice de Masa Corporal)
  - » Presión arterial sistólica/diastólica
  - » Historial de tabaquismo
- Biomarcadores renales y de sangre:
  - » Historial de diabetes mellitus
  - » Historial de hipertensión arterial
  - » Historial de enfermedades cardiovasculares
  - » Historial de hiperpotasemia
  - » Tasa de filtración glomerular estimada (eGFR)
  - » Creatinina sérica
  - » Proteinuria (cociente albúmina/creatinina)
  - » Niveles de potasio en sangre
  - » Niveles de fósforo en sangre
  - » Niveles de hemoglobina
  - » Bicarbonato sérico
- Tratamiento y factores de riesgo:
  - » Uso de inhibidores del SRAA
  - » Uso de diuréticos
  - » Adherencia al tratamiento
  - » Frecuencia de visitas médicas
  - » Historial de hospitalización por insuficiencia cardíaca o CKD
  - » Marcadores inflamatorios (PCR, IL-6)

## 17.2 PASOS PARA DISEÑAR EL MODELO DE IA (TABLA 19)

**TABLA 19.** Pasos clave para el desarrollo de un modelo predictivo

PASO	DESCRIPCIÓN
1. Definición del problema	Determinar si el objetivo es predecir progresión a insuficiencia renal terminal, riesgo de diálisis o mortalidad.
2. Recopilación de datos	Obtener una base de datos confiable de pacientes con ERC.
3. Análisis exploratorio de datos	Limpiar y preparar los datos: valores nulos, normalización, codificación de variables.
4. Selección de variables	Elegir las variables más relevantes mediante análisis estadístico o técnicas automáticas.
5. División de datos	Separar los datos en entrenamiento (70 %), validación (15 %) y prueba (15 %).
6. Selección del modelo	Probar diferentes algoritmos: Random Forest, XGBoost, Redes Neuronales, SVM.
7. Entrenamiento del modelo	Ajustar el modelo con los datos de entrenamiento.
8. Validación y optimización	Mejorar el rendimiento ajustando parámetros e implementando validación cruzada.
9. Interpretabilidad del modelo	Aplicar técnicas explicativas como SHAP o LIME para entender el modelo.
10. Implementación y monitorización	Integrar el modelo en una plataforma médica y evaluar su impacto clínico.

## 17.3 IMPLEMENTACIÓN PRÁCTICA DEL MODELO

Se presenta un ejemplo de cómo entrenar un modelo predictivo usando datos simulados. El modelo *random forest*, una técnica robusta y ampliamente usada en medicina, se utiliza aquí para predecir la mortalidad en pacientes con CKD a un año.

El código en Python no se espera que sea comprendido en profundidad por todos, pero permite visualizar cómo la IA puede procesar múltiples variables para realizar predicciones clínicas. Realiza los siguientes pasos:

- 1. Simulación de pacientes**  
Se generan datos ficticios de 1000 pacientes con variables clínicas relevantes como edad, sexo, eGFR, creatinina, proteinuria, etc. También se incluye una variable final que representa si el paciente falleció o no en el primer año. Esto simula una base de datos clínica real, pero con fines educativos.
- 2. Preparación de los datos**  
Los datos se dividen en dos grupos: uno para entrenar el modelo (80 %) y otro para probar su rendimiento (20 %). Esto es esencial para asegurar que el modelo pueda generalizarse a nuevos pacientes.
- 3. Entrenamiento del modelo**  
Se entrena un modelo de *random forest*, una técnica de IA que analiza patrones entre las variables clínicas para predecir qué pacientes tienen más riesgo de fallecer en un año. Es como un médico que aprende de miles de casos clínicos anteriores.
- 4. Evaluación del modelo**  
El modelo se evalúa utilizando métricas como la precisión (cuántas veces acierta) y AUROC (qué tan bien separa a pacientes con y sin riesgo). Estas métricas nos indican si el modelo puede ser útil en la práctica clínica.
- 5. Importancia de las variables**  
Se muestra un gráfico con las variables que más influyen en la predicción. Por ejemplo, si la eGFR y la proteinuria son muy relevantes, esto refuerza su valor clínico y ayuda a enfocar el seguimiento de los pacientes.

Este ejercicio demuestra cómo la IA puede ser una herramienta poderosa para apoyar la toma de decisiones clínicas. Aunque no se espera que todos los estudiantes comprendan

el código en detalle, sí es importante que comprendan su lógica y aplicaciones clínicas.

de decisiones clínicas, optimizar tratamientos y mejorar los resultados en salud.

#### **17.4 CONCLUSIÓN Y APLICACIONES**

La inteligencia artificial permite diseñar modelos predictivos útiles para mejorar la atención de pacientes con ERC - CKD. Este apartado ofrece una estructura básica para que los estudiantes comprendan cómo se aplican estas técnicas y experimenten con modelos reales. La integración futura de estos modelos en plataformas digitales puede facilitar la toma

#### **REFERENCIAS**

- 1** Liu X, Rivera SC, Moher D, Calvert MJ, Denniston AK; SPIRIT-AI and CONSORT-AI Working Group. Reporting guidelines for clinical trial protocols and reports of intervention trials involving artificial intelligence: the SPIRIT-AI and CONSORT-AI extensions. *BMJ*. 2020 Sep 9;370:m3210.



## 18.

### EL FUTURO PROMETEDOR DE LA IA EN LA NEFROLOGÍA ESPAÑOLA: GRUPO DE TRABAJO BIGSEN

---



La Nefrología española gracias al entusiasmo, generosidad y preparación de profesionales como José Ibeas, Miquel Hueso, Ignacio Revuelta y muchos otros componentes, formando parte del Grupo de Trabajo BIGSEN de la S.E.N, hace años que viene trabajando en la enseñanza y aplicación práctica de la Inteligencia Artificial en Nefrología.

#### 18.1 PLAN ESTRATÉGICO DEL GRUPO BIGSEN DE LA SOCIEDAD ESPAÑOLA DE NEFROLOGÍA (S.E.N.) [1]

La cantidad de datos generados diariamente en el ámbito de la Nefrología, diálisis y trasplante supera la capacidad cognitiva humana para su procesamiento. La inteligencia artificial (IA), mediante técnicas como el aprendizaje automático, permite identificar patrones complejos y relaciones no lineales que escapan a la estadística tradicional.

Este potencial motivó la creación del grupo BIGSEN (BIG Data, Inteligencia Artificial) dentro de la S.E.N. en 2018, con el objetivo de asesorar, formar y facilitar la implementación de tecnologías de IA en Nefrología.

En una etapa de consolidación, BIGSEN presenta un plan estratégico que busca desarrollar un ecosistema colaborativo centrado en el estudio, aplicación y difusión de la IA en la toma de decisiones clínicas. El objetivo principal es crear una red de trabajo que promueva el uso de datos y modelos predictivos como herramienta de soporte en Nefrología, diálisis y trasplante. Entre los objetivos secundarios destacan el mapeo metodológico del uso de datos, la creación de un grupo asesor multidisciplinar, el desarrollo de proyectos piloto multicéntricos, la educación continua, la colaboración con otros actores del sector salud y la participación activa de pacientes y familias.

Las acciones propuestas incluyen el envío de cuestionarios a centros sanitarios para evaluar su capacidad tecnológica, la formación de un grupo de expertos que asesore a miembros de la S.E.N. y la industria, y el impulso de proyectos conjuntos para la integración de datos sanitarios. Asimismo, se prevén actividades educativas como webinars, simposios, congresos, formación para tutores MIR (Training for Trainers) y jornadas híbridas anuales, iniciando en 2025 con sesiones básicas para todos los profesionales interesados.

También se contempla la difusión del conocimiento a través de publicaciones científicas, capítulos de libros, guías de consenso y artículos en medios de comunicación. Se promoverá la participación en revistas especializadas como *Frontiers in Nephrology*, *NEJM AI* y *Nefrología al Día*. Se impulsarán hackathones, ideathones y datathones para fomentar la innovación y el trabajo colaborativo, como ya se ha hecho en congresos anteriores de la S.E.N.

Una línea clave es el desarrollo de productos tecnológicos basados en IA que puedan ser implantados en la práctica clínica. Para ello, se atenderán los aspectos legales, éticos y de propiedad intelectual en colaboración con entidades tecnológicas, farmacéuticas y los servicios jurídicos de la S.E.N.

La visibilidad y la comunicación se potenciarán con el desarrollo de una página web del grupo BIGSEN integrada en la web de la S.E.N., así como una presencia activa en redes sociales como LinkedIn, X, Instagram, Facebook y YouTube. Se plantea la creación de contenido audiovisual, como una serie animada con el personaje “Nefr-i”, para divulgar el uso de la IA en salud entre pacientes, familiares, profesionales sanitarios y población general, incluidos niños y adolescentes.

El plan también promueve la colaboración con otras sociedades científicas, centros tecnológicos e instituciones nacionales

e internacionales. Se buscará integrar a nuevos miembros interesados en IA dentro de BIGSEN, diferenciando entre quienes desean colaborar activamente y quienes buscan una vía de información directa. El CORE del grupo mantendrá su estructura como núcleo organizativo.

El plan fue diseñado para ejecutarse inicialmente en el periodo 2021-2023, con una revisión realizada en el Congreso de la S.E.N. de noviembre de 2024. La implantación formal está ya desarrollada. Se realizará un seguimiento anual con informes de cumplimiento y se revisará cada tres años para adaptarlo a nuevas necesidades.

## 18.2 EL FUTURO DE LA IA EN LA NEFROLOGÍA ESPAÑOLA

Hemos visto, con muchas limitaciones de extensión, las posibilidades de aplicación y futuros desarrollos, de estudios basados en Machine Learning y Deep Learning en Nefrología. Nos encontramos ante una revolución silenciosa pero poderosa en el ámbito de la medicina, y en particular en la Nefrología. La irrupción de la inteligencia artificial no es una promesa lejana, sino una realidad creciente que ya está transformando la forma en que entendemos, analizamos y abordamos las enfermedades renales. Frente a un volumen de datos cada vez más inabarcable para el ser humano, la IA se convierte en un aliado imprescindible para interpretar la complejidad, anticipar riesgos, personalizar tratamientos y mejorar los resultados en salud.

Como hemos visto en el plan estratégico, durante estos últimos años, el Grupo BIGSEN de la Sociedad Española de Nefrología ha trabajado con firmeza y entusiasmo para consolidar una estructura que permita a los profesionales del ámbito renal acercarse a estas tecnologías sin miedo, con curiosidad, sentido crítico y vocación de servicio.

Hemos aprendido que no se trata de sustituir al médico, sino de ampliar sus capacidades. La IA no es el destino, sino la herramienta que puede acompañarnos y potenciarnos en la toma de decisiones clínicas, siempre bajo nuestra supervisión, juicio y ética profesional.

Gracias al esfuerzo colectivo del grupo y a la colaboración de múltiples perfiles profesionales —nefrólogos, ingenieros, estadísticos, desarrolladores, instituciones científicas, asociaciones de pacientes— podremos sentar las bases para avanzar con rigor, responsabilidad y ambición.

Los pilotos, formaciones, publicaciones, hackathones, guías, herramientas digitales y nuevas metodologías generadas por el grupo BIGSEN nos han permitido ver que la IA puede impactar positivamente en áreas tan diversas como el manejo de grandes bases de datos, la detección precoz de enfermedades renales crónicas, la predicción de complicaciones, la interpretación automatizada de pruebas diagnósticas o la mejora de la eficiencia en los sistemas de diálisis y trasplante. Todo ello se ha hecho sin perder el foco en lo más importante: el bienestar del paciente.

Pero este potencial transformador sólo se materializará si los especialistas en Nefrología deciden implicarse activamente. No podemos quedarnos al margen del cambio tecnológico. Tenemos la responsabilidad y la oportunidad de liderarlo desde el conocimiento clínico, desde la experiencia de estar al lado del paciente. Si dejamos que otros decidan por nosotros cómo y para qué se aplicará la

inteligencia artificial en nuestro campo, corremos el riesgo de que se diseñen soluciones alejadas de la realidad asistencial o incluso que aumenten las inequidades existentes.

Por eso la importancia del grupo BIGSEN no es sólo por su hoja de ruta, sino como invitación abierta a todos los profesionales de la Nefrología a participar, sumar y transformar. Es una llamada a la acción. Cualquiera que tenga interés —independientemente de su nivel técnico inicial— puede encontrar en BIGSEN un espacio para aprender, contribuir y crecer. La formación específica, el trabajo multidisciplinar, la difusión del conocimiento y el contacto directo con la innovación son los pilares sobre los que construiremos el futuro.

Y ese futuro ya está aquí. Lo que soñábamos hace apenas una década hoy empieza a ser cotidiano: algoritmos que ayudan a predecir el riesgo de progresión en la enfermedad renal crónica, sistemas que priorizan pacientes en función de sus datos en tiempo real, modelos de lenguaje natural que asisten en la elaboración de informes clínicos, asistentes virtuales para la educación de pacientes y un sinfín de nuevas herramientas que seguirán emergiendo si mantenemos la mente abierta y el compromiso firme.

#### REFERENCIAS

- 1 Plan estratégico grupo de la sociedad española de nefrología (s.e.n.) big data, inteligencia artificial (bigsen) (2024-2027) <https://www.senefro.org/contents/workgroups/files/5/439bbbd1-4316-4013-aae5-20e35aa5c0fa.pdf>



## 19.

### MÁS ALLÁ DEL ALGORITMO

---

Terminamos este segundo libro básico de IA en Nefrología con optimismo. Este libro ha sido para mí mucho más que una recopilación de avances, datos y aplicaciones. Ha sido un viaje de asombro, de preguntas y de aprendizaje. Por mi edad, he visto cambiar la medicina desde sus cimientos: desde la clínica más sencilla hasta esta nueva era donde los algoritmos se convierten en herramientas de diagnóstico, apoyo y previsión. Nunca imaginé vivir para ver la inteligencia artificial aplicarse a la Nefrología con tanta fuerza y esperanza.

Estamos sembrando algo importante. Este libro es, en parte, una manera sencilla de contribuir a ese futuro que ya empieza a germinar en los hospitales, en los centros de investigación y, sobre todo, en las mentes jóvenes que lo harán realidad.

He escrito estas páginas con la humildad de quien ha vivido muchas transformaciones, y con la emoción de saber que cada paso hacia adelante puede significar una vida mejor para un paciente, una familia menos angustiada, un profesional mejor acompañado. La inteligencia artificial en Nefrología es una promesa, pero

también una responsabilidad. Ojalá sepamos usarla con sabiduría, con ética y sin olvidar nunca que en el centro de todo sigue estando el ser humano.

A quienes lean estas líneas en el futuro, quizás desde una consulta asistida por IA o frente a una pantalla que predice con precisión el curso de una enfermedad renal: gracias. Gracias por continuar este camino. Gracias por seguir cuidando. Gracias por recordarnos que la tecnología, por avanzada que sea, siempre debe estar al servicio de la ayuda y cercanía al paciente.

Me despido con gratitud. Este ha sido uno de mis últimos capítulos (o quizás sea el último), pero el vuestro apenas comienza. Con esfuerzo, responsabilidad y visión, la inteligencia artificial no será un desafío, sino una aliada que nos permitirá ofrecer una medicina más precisa, más humana y más eficaz.

**Aprender IA no es opcional, es parte de ser un buen médico en el siglo XXI.**

*Ángel L. Martín de Francisco Hernández*

