

De la señal al píxel: inteligencia artificial en la adquisición y reconstrucción de imagen médica.

Papel actual de la reconstrucción profunda en RM y TC: fundamentos, impacto clínico, eficiencia y limitaciones.

Daniel Alejandro Cadavid Cadavid, Andrea Senovilla Ardid, Sofía Thais Escobar Narro, Natalia Lourdes Tobajas Ramos, Marina Rozas Quesada, Maria Riera Martí, Myriam Segarra Hernández, Elena Pascual Pérez.

Hospital Universitario Miguel Servet, Zaragoza

Objetivo docente

- Revisar el papel actual de la inteligencia artificial en las etapas iniciales del proceso radiológico, con especial atención a la **adquisición** y la **reconstrucción** de imagen.
 - Resumir los fundamentos de la **deep learning reconstruction (DLR)** en **resonancia magnética (RM)** y **tomografía computarizada (TC)**.
 - Mostrar su impacto en **calidad de imagen, tiempo de exploración, dosis y eficiencia operativa**.
 - Señalar sus principales **limitaciones y cautelas clínicas** antes de su adopción generalizada.
-

DE LA SEÑAL A LA IMAGEN

La imagen médica no se obtiene de forma directa: primero se adquiere una señal o dato crudo, que posteriormente debe ser reconstruido para generar la imagen diagnóstica. La IA puede intervenir no solo en el análisis posterior, sino también en la generación misma de la imagen.



Adquisición

Obtención del dato original



Reconstrucción

Transformación del dato crudo en imagen



Posprocesado

Análisis o reformato posterior

La IA ya no actúa solo sobre la imagen final: también participa en cómo se genera.

RM Y TC NO PARTEN DEL MISMO TIPO DE DATO

Aunque RM y TC terminan generando una imagen diagnóstica, no parten de la misma información. En **RM**, la imagen se construye a partir del **k-space**; en **TC**, a partir del **sinograma** o **dato crudo**. En ambos casos, primero se adquieren datos y después se reconstruyen para formar la imagen final.

K-space: datos de la RM antes de ver la imagen

Sinograma: datos de la TC antes de ver la imagen

RM → k-space



TC → sinograma / raw data



Datos primero, imagen después

La imagen final no aparece directamente: primero se adquieren datos y luego se reconstruyen.

QUÉ ES LA DLR Y DÓNDE PUEDE ACTUAR

La **reconstrucción profunda (DLR)** utiliza modelos de inteligencia artificial para transformar los datos adquiridos en una imagen diagnóstica. No es una única técnica: puede aplicarse en distintos puntos del proceso, tanto en RM como en TC.

En RM

- ▶ **Image domain:** actúa sobre una imagen ya formada
- ▶ **K-space:** actúa sobre los datos antes de formar la imagen
- ▶ **Direct mapping:** genera la imagen final directamente desde los datos

En TC

- ▶ **Image-based:** actúa sobre la imagen reconstruida
- ▶ **Sinogram/raw-data-based:** actúa sobre los datos originales
- ▶ **Hybrid / direct:** combina varios pasos o reconstruye directamente

DLR = uso de modelos de IA para reconstruir mejor una imagen a partir de los datos adquiridos.

La DLR no es una sola estrategia: puede actuar antes, durante o después de la reconstrucción clásica.

CÓMO ACELERA LA RM: MENOS INFORMACIÓN, RECONSTRUCCIÓN MÁS INTELIGENTE


En RM, acortar el tiempo de exploración suele implicar **recoger menos información**. La **DLR** ayuda a obtener una imagen diagnóstica a partir de datos incompletos, integrándose con **parallel imaging** y **compressed sensing**.

Concepto	Qué significa	Para qué sirve
Datos en RM	Información que recoge el resonador antes de formar la imagen	Materia prima de la reconstrucción
K-space	Donde se guarda la información antes de convertirla en imagen	Permite reconstruir la imagen final
Bobinas	Antenas que reciben la señal del cuerpo	Ayudan a captar mejor la información
Parallel imaging	Usa varias bobinas al mismo tiempo	Acelera la exploración
Compressed sensing	Reconstruye la imagen con menos información	Reduce el tiempo de adquisición
DLR	Usa IA para reconstruir mejor a partir de datos incompletos	Imagen útil con menos datos

La RM puede ser más rápida si recoge menos información, siempre que la reconstrucción mantenga calidad diagnóstica.

CÓMO HA EVOLUCIONADO LA RECONSTRUCCIÓN EN TC

La reconstrucción en TC ha evolucionado desde métodos **rápidos pero más ruidosos** hacia técnicas capaces de reducir ruido y mejorar calidad. La **DLR** representa el paso más reciente en esta evolución.



FBP: reconstrucción clásica **IR / MBIR:** reconstrucción iterativa **DLR:** reconstrucción basada en IA

La DLR en TC surge para mejorar simultáneamente calidad de imagen y eficiencia, especialmente en baja dosis.

IMPACTO OPERATIVO: TIEMPO, DOSIS, RUIDO Y ARTEFACTOS

La implementación de la DLR puede mejorar no solo la calidad de imagen, sino también la **eficiencia del servicio** y la **experiencia del paciente**, reduciendo tiempo en RM y facilitando protocolos de menor dosis en TC.

RM Reducción significativa del tiempo de adquisición y del tiempo de sala

TC Posibilidad de menor dosis manteniendo utilidad diagnóstica

↓ Menor ruido y menos artefactos

✓ Menor necesidad potencial de repetir estudios

La DLR no solo mejora la imagen: también impacta en la eficiencia del flujo de trabajo.

RM ACELERADA CON DLR: EVIDENCIA CLÍNICA

Parámetro	RM estándar	RM con DLR
Tiempo de adquisición	328 s	100 s
Reducción de tiempo	—	≈70%
Diferencia diagnóstica	—	<4%
Umbral de equivalencia	—	5%

Las secuencias aceleradas con DLR fueron diagnósticamente intercambiables con el protocolo estándar, con una reducción sustancial del tiempo.

Almansour H, Herrmann J, Kannengiesser S, Nittka M, Schmidt B, Penzkofer T, et al. Deep learning reconstruction for accelerated spine MRI: prospective analysis of interchangeability. **Radiology**. 2022;305(3):675-85.

RECONSTRUCCIÓN PROFUNDA EN RM: IMPACTO OPERATIVO EN PRÁCTICA REAL

Estudio retrospectivo multicéntrico en práctica clínica real

7346

exploraciones analizadas

10

equipos clínicos RM 1.5 T

↓ **53%**

en tiempo de escaneo

↓ **41%** tiempo en sala

Variable Beneficio dependiente del algoritmo y del tipo de estudio

La DLR no solo mejora la imagen: puede aumentar el throughput y la capacidad asistencial en RM.

*Yang J, Mann A, Wang C, Kijowski R, Fritz J. Impact of deep learning image reconstruction methods on MRI throughput. **Radiol Artif Intell.** 2024;6(2):e230181.*

EVIDENCIA CLÍNICA SELECCIONADA — TC: PANORAMA GENERAL

La utilidad clínica de la DLR en TC es mayor cuando el **ruido** o la **baja dosis** comprometen la **calidad diagnóstica**, especialmente en **abdomen** y **tórax**.

Abdomen

Lesiones hepáticas, páncreas, DECT y baja dosis

Tórax

Parénquima pulmonar, nódulos, LDCT y ULDCT

Mayor beneficio cuando la tarea depende de la relación **contraste-ruido**

La DLR en TC no aporta igual en todos los contextos: su valor aumenta cuando el ruido condiciona la tarea clínica.

DLR EN TC ABDOMINAL: VISIBILIDAD LESIONAL Y BAJA DOSIS

En TC abdominal, la DLR puede mejorar ruido, CNR y visibilidad de lesiones, incluso en protocolos con reducción importante de dosis. La evidencia destaca especial utilidad en **lesiones hepáticas, páncreas y DECT/monoenergéticas**.

66-67%

menos dosis



Visibilidad lesional mantenida / mejorada

En abdomen, la DLR puede mantener o mejorar la visibilidad de las lesiones incluso con reducción importante de dosis.

Mileto A, Marin D, Nelson RC, Samei E. State-of-the-art deep learning CT reconstruction algorithms in abdominal imaging. **Abdom Radiol (NY)**. 2024;49:2103-19.

DLR EN TC TORÁCICA: BAJA DOSIS, NÓDULOS Y PARÉNQUIMA PULMONAR

En tórax, la DLR resulta especialmente útil en protocolos de **baja** y **ultrabaja dosis**, donde el ruido afecta la valoración del **parénquima pulmonar**, la detectabilidad de **nódulos** y la apreciación de lesiones sutiles.

- ▶ Mejora de calidad de imagen y valoración del parénquima pulmonar en LDCT
- ▶ En ULDCT, detección de nódulos 83.4% con DLR vs 74.0% con HIR
- ▶ Dosis efectiva 0.16 ± 0.02 mSv en ULDCT vs 1.77 ± 0.67 mSv en SDCT
- ▶ Mejora de la nitidez de lesiones sutiles como vidrio deslustrado

En TC torácica, la DLR puede mejorar detectabilidad y calidad de imagen donde la baja dosis dificulta ver lesiones sutiles.

LIMITACIONES, CAUTELAS Y VARIABILIDAD ENTRE FABRICANTES

Aunque la DLR mejora parámetros físicos y calidad visual, su utilidad clínica no puede asumirse automáticamente. El rendimiento depende del **fabricante**, la **arquitectura**, el **dataset de entrenamiento** y la **tarea diagnóstica** concreta.

- ! Resultados dependiente de fabricante
- ! Posibles cambios en textura de imagen y preservación del detalle
- ! Riesgo de artefactos inducidos por el algoritmo
- ! Ausencia de estándares universales de validación
- ! Necesidad de evaluación basado en enfoque clínico

La mejora visual de la imagen no siempre implica mejora diagnóstica.

CONCLUSIONES

1. La IA está redefiniendo el inicio del flujo radiológico: ya no se limita a analizar imágenes, sino que también participa en su generación.
2. En RM, la DLR facilita adquisiciones más rápidas manteniendo calidad diagnóstica en escenarios seleccionados.
3. En TC, su mayor utilidad clínica aparece en escenarios de baja o ultrabaja dosis donde el ruido limita la detectabilidad.
4. La evaluación debe centrarse en el rendimiento diagnóstico clínico, no solo en la calidad visual.

BIBLIOGRAFÍA

1. Koetzier LR, Mastrodicasa D, Szczykutowicz TP, Samei E. Deep learning image reconstruction for CT: technical principles and clinical prospects. **Radiology**. 2023;306(3):e222067.
2. Kiryu S, Ghodadra A, Elsayes KM, Riascos RF. Clinical impact of deep learning reconstruction in MRI. **Radiographics**. 2023;43(11):e230031.
3. Almansour H, Herrmann J, Kannengiesser S, Nittka M, Schmidt B, Penzkofer T, et al. Deep learning reconstruction for accelerated spine MRI: prospective analysis of interchangeability. **Radiology**. 2022;305(3):675-85.
4. Yang J, Mann A, Wang C, Kijowski R, Fritz J. Impact of deep learning image reconstruction methods on MRI throughput. **Radiol Artif Intell**. 2024;6(2):e230181.
5. Mileto A, Marin D, Nelson RC, Samei E. State-of-the-art deep learning CT reconstruction algorithms in abdominal imaging. **Abdom Radiol (NY)**. 2024;49:2103-19.
6. Hossain MS, Jannat F, Ahmed S, Ali MH, Rahman MM, Islam MN, et al. A systematic review and identification of the challenges of deep learning techniques for undersampled MRI reconstruction. **Sensors (Basel)**. 2024;24(3):753.
7. Küstner T, Di Sopra L, Elbaz MSM, Oksuz I. The intelligent imaging revolution: artificial intelligence in MRI and MRS acquisition and reconstruction. **Magn Reson Mater Phys Biol Med**. 2024;37:635-7.
8. Szczykutowicz TP, Hermus JR, Geurts B, Halliburton S, Samei E. A review of deep learning CT reconstruction: concepts, limitations, and promise in clinical practice. **J Med Imaging (Bellingham)**. 2022;9(5):052411.