


# Reducción de tiempos de adquisición en resonancias magnéticas: Una solución con Deep Learning.

**Diego Antonio Villalba González**

Asesores: Dra. Jimena Olveres, Dr. Boris Escalante


Ciudad de México, 3 septiembre de 2025



## Resumen

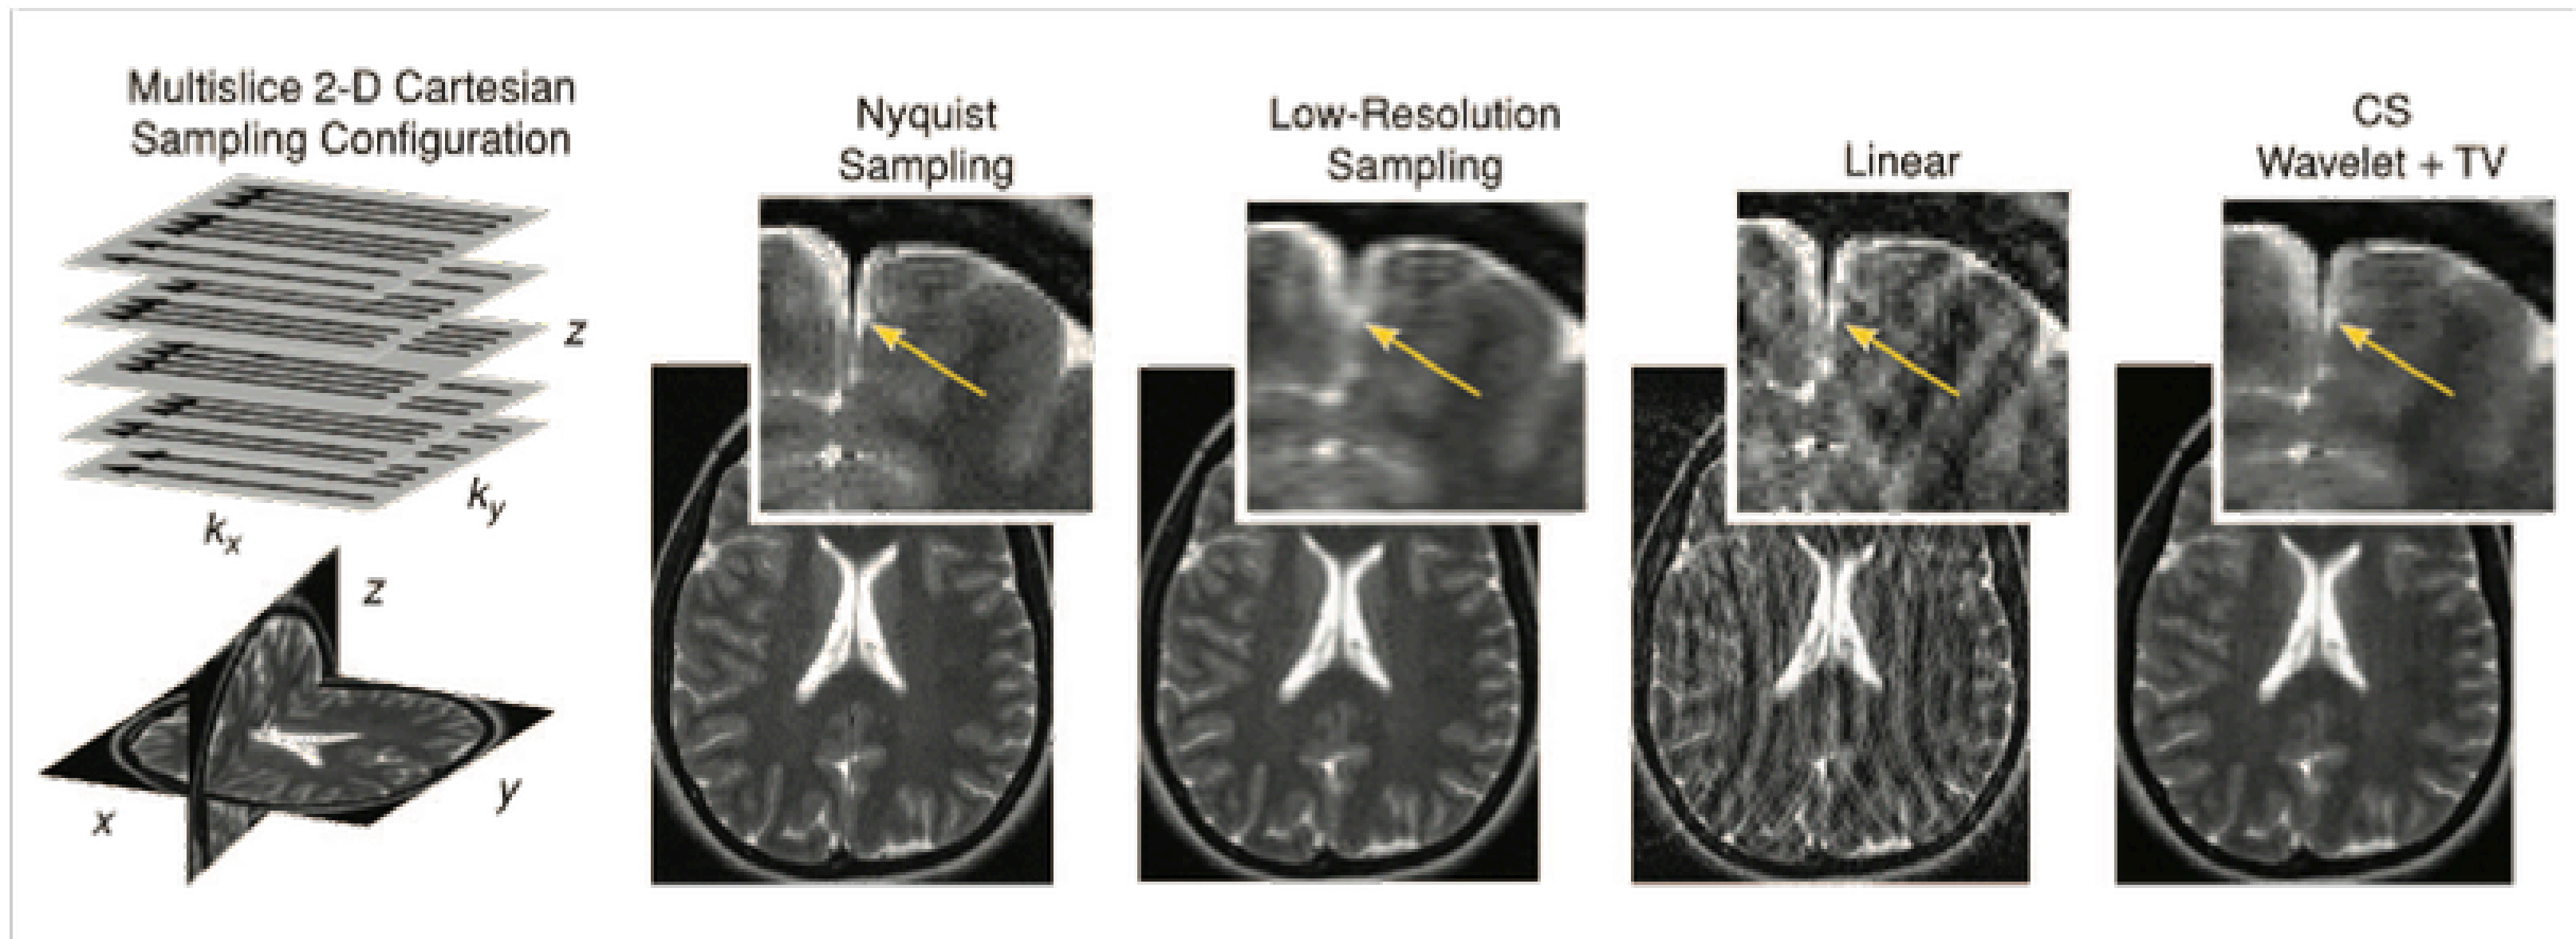
La resonancia magnética (RM) es una de las herramientas más potentes y no invasivas en el diagnóstico médico moderno. Su capacidad para generar imágenes detalladas de tejidos blandos la convierte en un recurso fundamental para detectar y monitorear diversas patologías, desde lesiones cerebrales hasta enfermedades musculoesqueléticas.

Sin embargo, este es un proceso lento (20 min en promedio) y costoso, limitando su acceso en sistemas de salud con recursos restringidos. En México, esta situación se agrava por la baja disponibilidad de equipos: existen menos de 3 resonadores por cada millón de habitantes, lo que genera tiempos de espera prolongados y retrasa diagnósticos críticos.



## Resumen

Por ello, acelerar el proceso de adquisición de imágenes, sin comprometer la calidad diagnóstica, es una prioridad urgente. Optimizar esta tecnología no solo mejora la experiencia del paciente, sino que puede tener un impacto directo en la eficiencia del sistema de salud y en la detección temprana de enfermedades.






## Resumen


ScattNet-MR es un modelo de aprendizaje profundo que integra técnicas de super-resolución con fundamentos de física estadística para acelerar significativamente el tiempo de adquisición en resonancia magnética.

Su implementación permite reducir hasta en un 75% el tiempo de exploración, manteniendo al mismo tiempo una alta similitud estructural en las imágenes y preservando la calidad diagnóstica


1/4 Adquisition Time




Model Result




Ground Truth




1/2 Adquisition Time



Model Result



Ground Truth







# Introducción

## La resonancia magnética

En una resonancia magnética hacemos precesar los protones del hidrógeno a su frecuencia resonante (de Larmor) y medimos la señal de radiofrecuencia que emiten cuando decaen al equilibrio.



**Alineación**




**Decaimiento**




## Codificación


La información espacial se codifica utilizando la fase y la frecuencia de los protones mediante la aplicación de gradientes de campo magnético, lo que permite que la señal registrada quede almacenada de forma codificada en el dominio de espacio -  $k$  (Dominio-Frecuencia).



Fase dirección de la  
flecha, frecuencia color



Señal resultante




Espacio -  $k$

## Codificación

Para obtener la imagen final realizamos una transformada de Fourier inversa.


Espacio- $k$  original



Transformada  
de  
Fourier




Imagen original






## Codificación


Es aquí donde surge la demora del proceso, es necesario realizar varias de estas mediciones para tener información suficiente en la reconstrucción.



Fase dirección de la  
flecha, frecuencia color



Señal resultante




Espacio - k




## Técnicas de aceleración


Para acelerar el proceso de adquisición es posible reducir el número de mediciones, pero esto introduce inevitablemente fenómenos de aliasing en la reconstrucción de la imagen, consecuencia directa de la violación del teorema de muestreo de Nyquist.




Espacio-k con máscara aleatoria




Reconstrucción



Espacio-k con máscara equiespaciada



Reconstrucción





¿Es posible recuperar la imagen original a partir de una versión submuestreada?





No existe una solución única ni estable sin la incorporación de información adicional o restricciones.



# Deep Learning

Un problema similar surge en el análisis de imágenes: ¿Cómo puedo reconstruir una imagen de menor resolución en una de alta resolución?




## Métodos tradicionales de interpolación

Tradicionalmente esto se alcanza mediante interpolaciones, pero estas no recuperan la información perdida.

## Deep Learning

El aprendizaje profundo emerge como una posible solución, ya que actúa esencialmente como un aproximador universal de funciones, capaz de modelar relaciones complejas y no lineales en los datos.






## Súper resolución

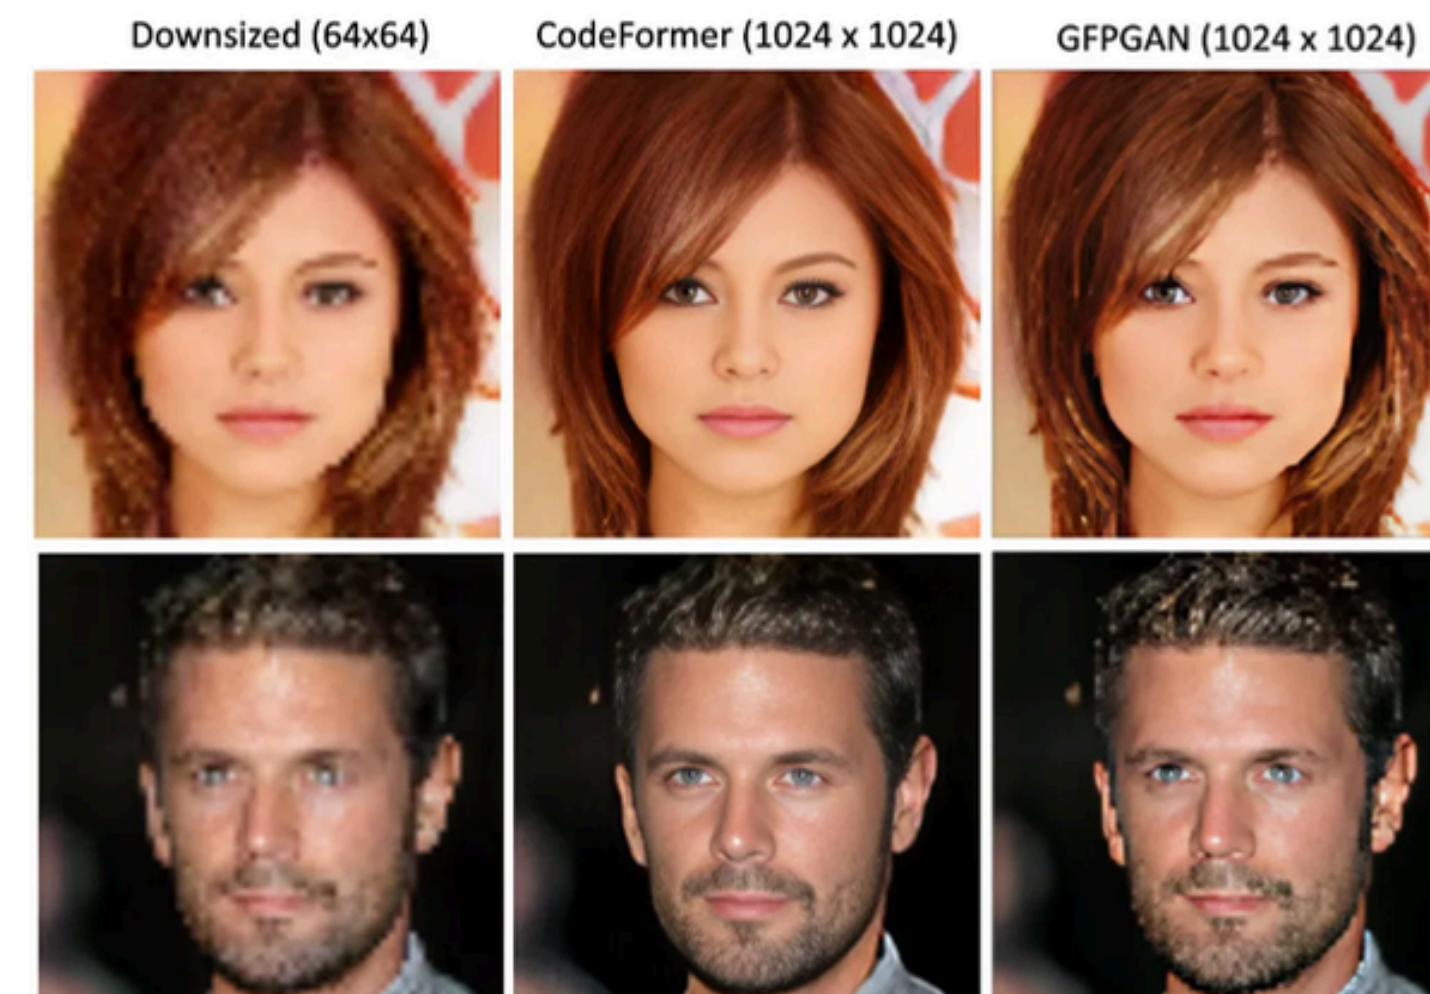
Podemos partir del supuesto de que, mediante una arquitectura adecuada y una cantidad suficiente de ejemplos de entrenamiento, la red neuronal es capaz de aprender el mapeo correcto entre los datos de entrada y la reconstrucción deseada.



Celeb-A Dataset



Red neuronal  
generativa





Mapeo resultante




## Súper resolución

Sin embargo, en la práctica este proceso resulta complejo.

En particular, en los modelos de super-resolución el mapeo de características faltantes puede conducir a reconstrucciones erróneas.



Buscamos que nuestra red funga como una brújula para casos generales





## Los principales retos

De acuerdo con Bhadra, et al. (2021). los retos a los que se enfrentan los modelos de aprendizaje profundo son :


- **Riesgo de "alucinaciones":** Los modelos de aprendizaje profundo pueden generar características falsas que parecen anatómicamente reales, lo que podría llevar a diagnósticos erróneos.
- **Insuficiencia de métricas clásicas:** Métricas globales son inadecuadas para detectar estas alucinaciones.
- **Estimación de incertidumbre:** Se necesita confianza para identificar áreas de baja fiabilidad.
- **Evaluaciones basadas en tareas:** Realizadas por radiólogos para asegurar que la información diagnóstica se preserve.

# Nuestro trabajo


## Dataset

fastMRI es un proyecto entre Facebook AI Research y NYU Langone Health, que incluye una biblioteca en Python diseñada para simular de manera realista el proceso de aceleración en resonancia magnética. En particular, el proyecto ofrece:


- Bases de datos sin procesar de estudios de rodilla, cerebro y próstata, disponibles tanto en formato k-space como en DICOM.
- Herramientas de segmentación y clasificación según la técnica empleada y el número de bobinas.
- Implementación de diversas técnicas de submuestreo en k-space orientadas a la reducción de los tiempos de escaneo, manteniendo un porcentaje de la región central.




(a)



(c)



(f)




(j)



## Dataset


Empleando una serie de máscaras cartesianas aleatorias sobre los datos crudos del espacio-k, emulamos la reducción realista a un 50% y 25% del tiempo de adquisición en 5 mil imágenes

Full time




Full acquisition

1/2 Time



50% sampled lines, 8% center lines

1/4 Time




25% sampled lines, 4% center lines


# Wavelets

Los wavelets son definidos como una onda localizada espacial y temporalmente, los cuales pueden fungir como una base ortonormal en la descomposición de una señal esta transformada ofrece una representación esparsa, eficiente y estructuralmente interpretable de imágenes que contienen bordes, transiciones abruptas o texturas localizadas.

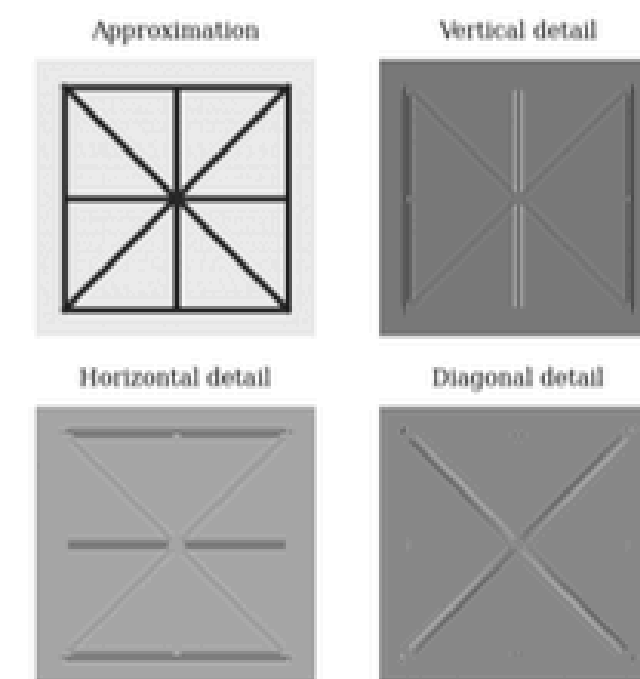
$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left( \frac{t-b}{a} \right).$$




Wavelet Morlet.



(a) Imagen a procesar





(b) Resultado de la DWT.



(c) Soporte en el espacio de Fourier.

# Wavelets

La transformada escalonada de wavelets o como nos (Wavelet Scattering Transform WST) surge como una técnica que permite extraer representaciones invariantes y estables utilizando una cascada estructurada de convoluciones y no linealidades, manteniendo la información esencial de la señal.



Soporte de Fourier

$$x'(u) = x(u - c) \Rightarrow S[p]x'(u) \approx S[p]x(u)$$

**Invarianza ante traslaciones de escala**

$$\|S_J(L_\tau x) - S_J(x)\| \leq C\|x\| \cdot \sup_u |\nabla \tau(u)|$$

**Lipschitz continua**


$$\text{energía}(S[p]x) \rightarrow 0 \quad \text{cuando } |p| \rightarrow \infty$$

**Esparsa**




## Wavelets


El trabajo de Cheng et al. y la tesis doctoral de Bruna demuestran que representaciones jerárquicas como la Wavelet Scattering Transform (WST) permiten capturar estas correlaciones a gran escala gracias a su estructura multirresolutiva y su estabilidad frente a deformaciones reteniendo información suficiente para modelar correlaciones espaciales de largo alcance, sin necesidad de reconstruir fases explícitas.




(a) Coeficiente  $S^0$



(b) Primeros coeficientes  $S^1$



(c) Primeros coeficientes  $S^2$




**Matriz de correlación**

Esta transformada funge como una red convolucional con pesos fijos (no requiere entrenamiento)


## WST como medida estadística

Para comparar una imagen reconstruida con su referencia, no basta con medir diferencias puntuales (ej. MSE), ya que estas ignoran la estructura estadística del campo.


Cuantificamos la discrepancia entre las distribuciones de coeficientes WST de dos imágenes, midiendo cuánto se pierde al usar una distribución para aproximar a la otra, análogo al trabajo mostrado por Cheng et al., 2024 y Mallat et al 2020.




Turbulencia 2D



Emulación Gausiana



Emulación ordenes  
estadísticos mayores




Emulación WST



## ScattNet-MR


La reconstrucción de una imagen puede verse como un problema de inferencia bayesiana: asumimos que las imágenes realistas siguen una distribución de probabilidad desconocida.

Para aproximar dicha distribución utilizamos una red residual convolucional que incorpora mecanismos de atención.



$$p_{\theta}(x) = \frac{1}{Z_{\theta}} \exp(-U_{\theta}(x))$$

Distribución de Probabilidad

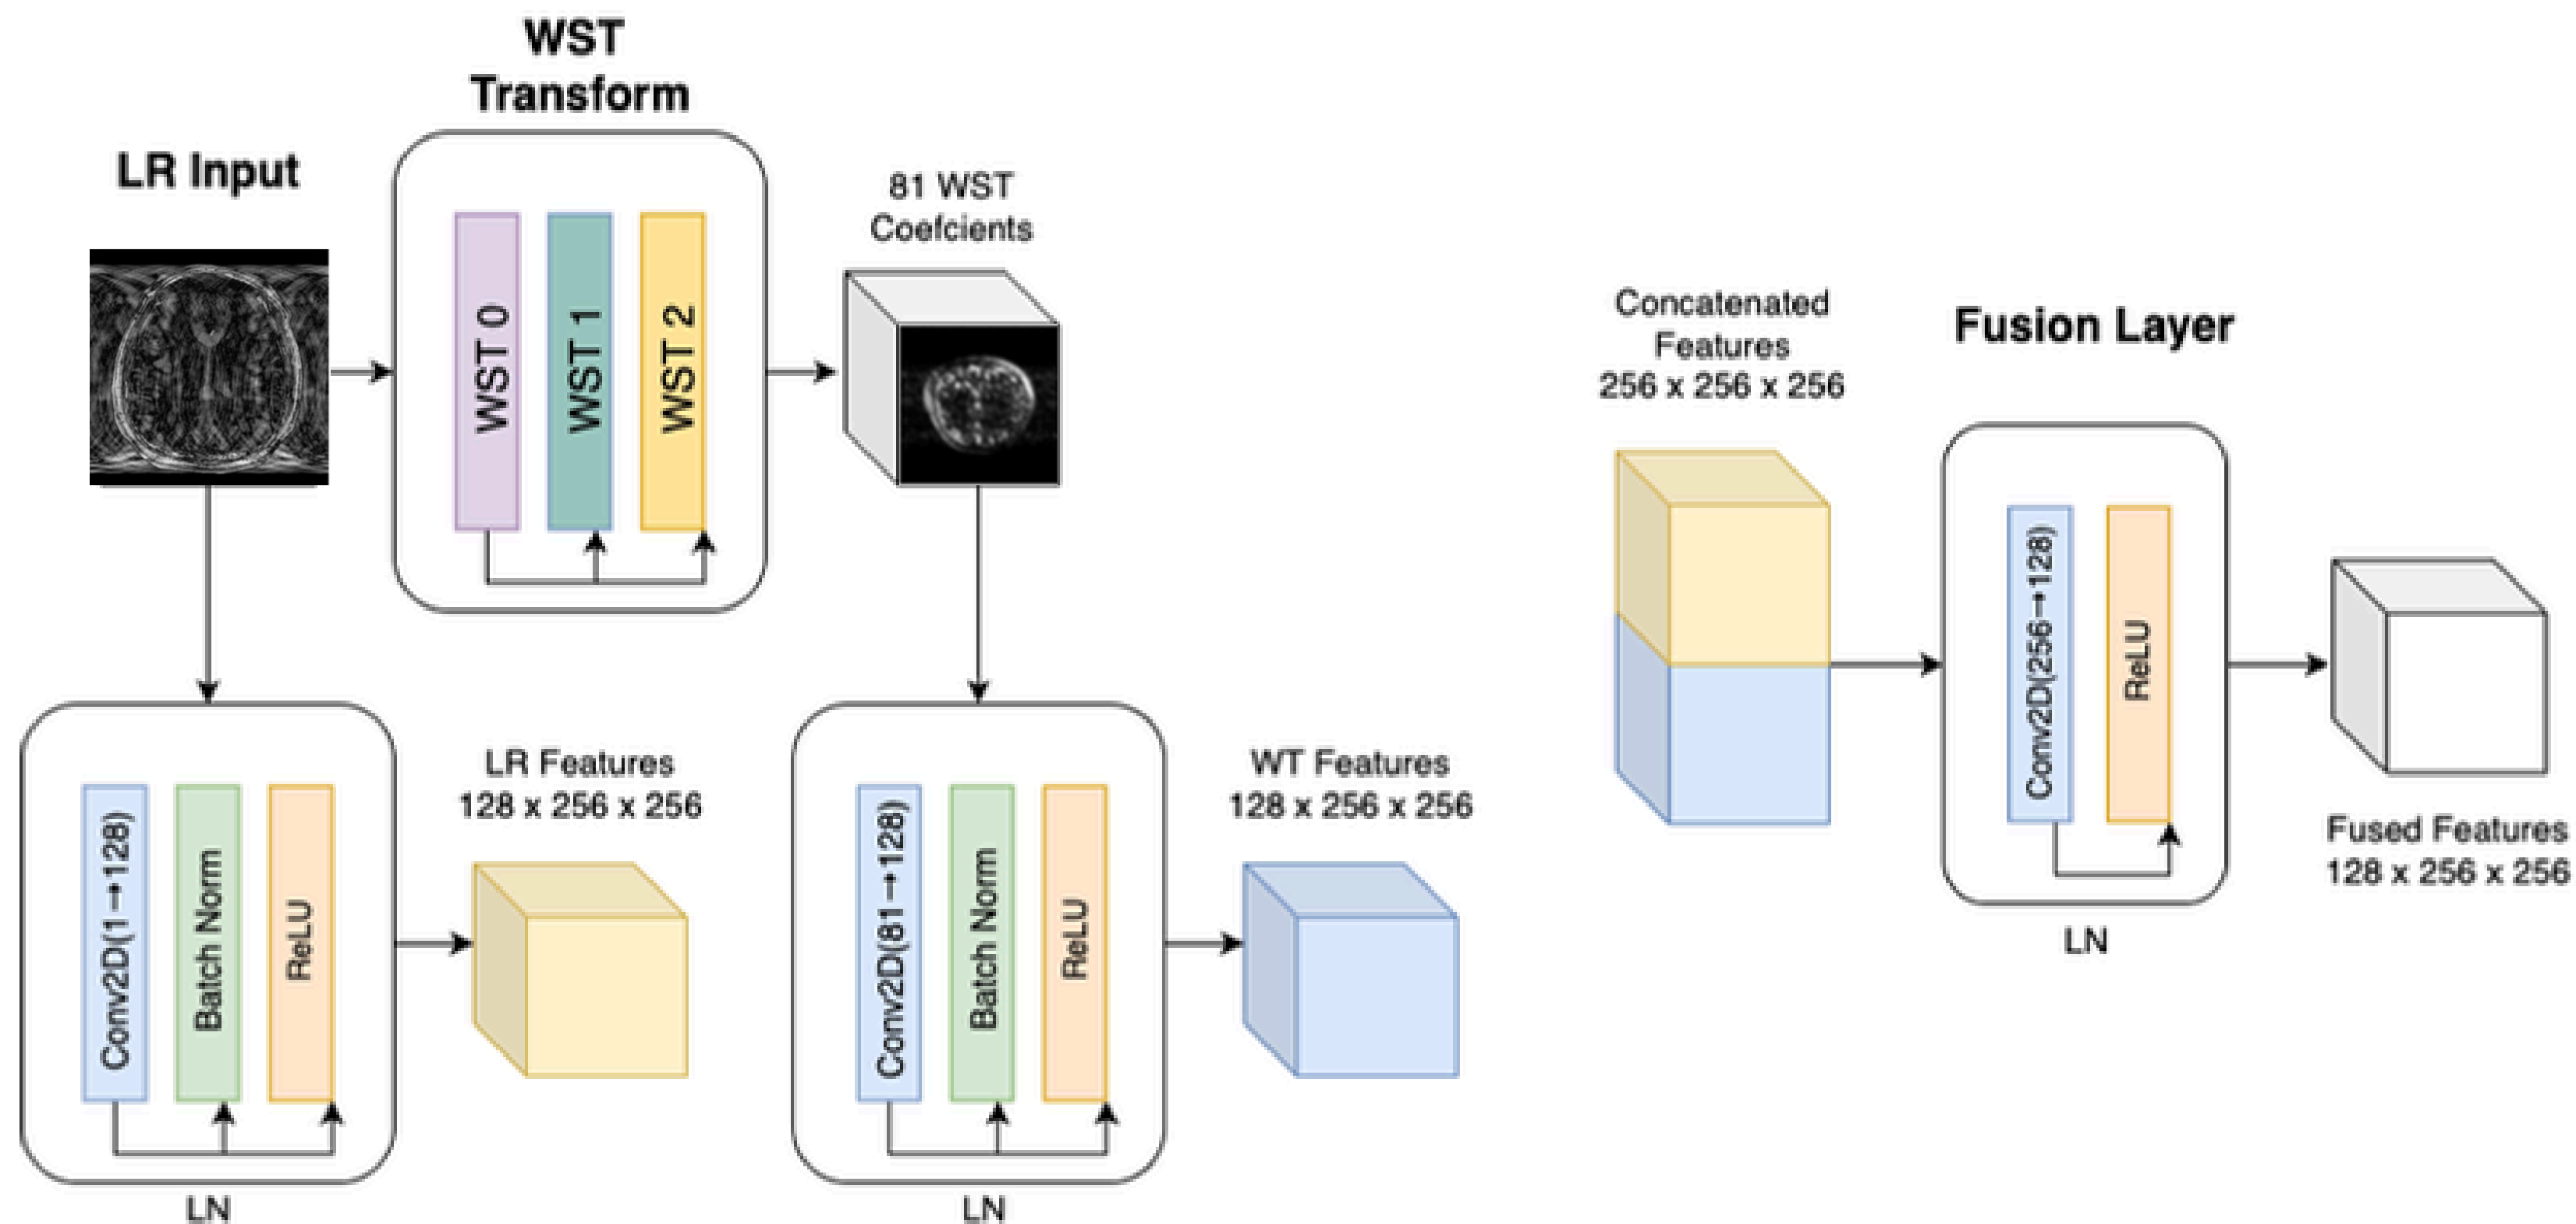


$$\begin{aligned} \mathcal{L}_{\text{total}} = & \lambda_{\text{L1}} \cdot \frac{1}{B} \sum_{b=1}^B \|\hat{x}_b - x_b\|_1 + \lambda_{\text{percep}} \cdot \frac{1}{B} \sum_{b=1}^B \|\phi(\hat{x}_b) - \phi(x_b)\|_1 \\ & + \lambda_{\text{WST}} \cdot \frac{1}{B} \sum_{b=1}^B \sum_{i=1}^D q_b(i) [\log q_b(i) - \log p_b(i)] \end{aligned}$$

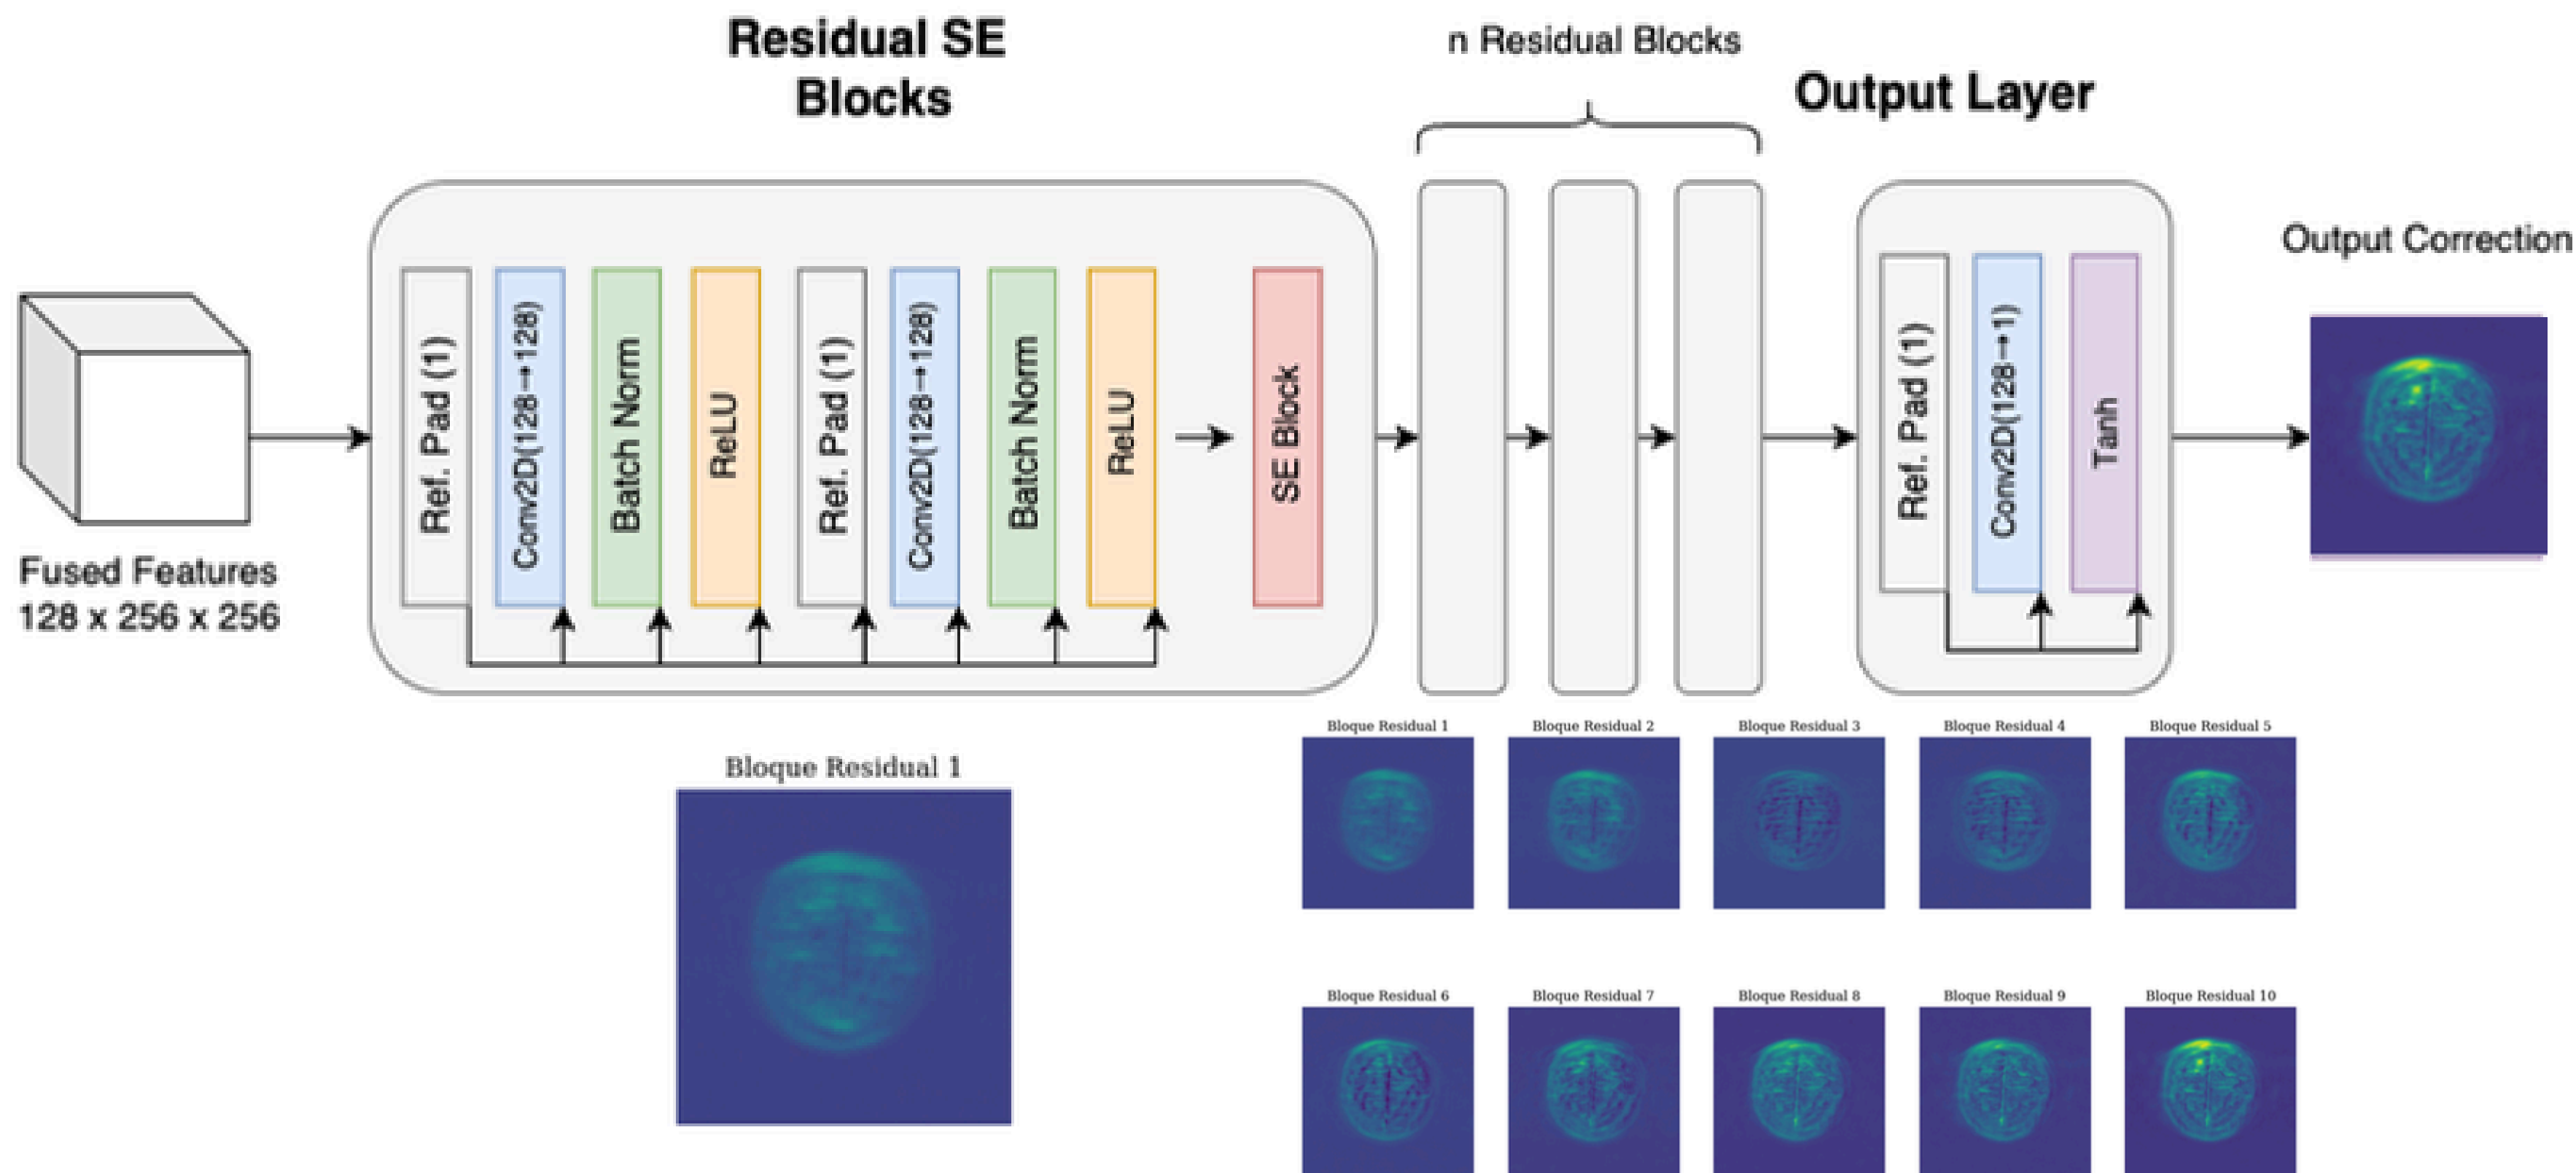
KL-Divergence



# ScattNet-MR



# ScattNet-MR



# Resultados



## ScattNet-MR

El entrenamiento del modelo se realizó en una RTX 4090 del laboratorio avanzado de procesamiento de imágenes, tomando un tiempo de entrenamiento de 14 horas para 5 mil imágenes de entrenamiento divididas en entrenamiento y validación, con aumentaciones respectivas.

El modelo presenta un total de 3.3 millones de parámetros entrenables





Accel.	Metric	SSIM_Input	PSNR_Input (dB)	SSIM_Gen	PSNR_Gen (dB)
×2	Mean	0.8586	29.68	<b>0.9412</b>	<b>35.78</b>
	Std	0.0426	2.55	0.0185	2.21
	Min	0.7290	24.66	0.8742	31.20
	Max	0.9457	36.75	0.9774	42.10
×4	Mean	0.6943	23.40	<b>0.8942</b>	<b>31.54</b>
	Std	0.0633	2.17	0.0297	1.97
	Min	0.5127	19.17	0.7953	27.54
	Max	0.8712	29.49	0.9604	37.28

$$\text{SSIM}(\mathbf{x}, \mathbf{y}) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

Brillo


Var

Cvar




## WST como medida estadística


KL divergence de los coeficientes de WST funciona como estimador estadístico que permite que el modelo aproxime una distribución estadística de valores




Submuestra vs Real




Submuestra vs generada



Real



Generada




Submuestreada

# Aceleración x2




AXT1


Subsampled Input




Reconstruction (ScattNet-MR)



Ground Truth







SSIM Map



SSIM : 0.9408.

AXT2







SSIM : 0.9310.

Subsampled Input





Reconstruction (ScattNet-MR)

Ground Truth

SSIM Map



SSIM : 0.9245.




SSIM : 0.8809

# Aceleración x4




AXT1


Subsampled Input




Reconstruction (ScanNet-MR)



Ground Truth







SSIM Map



SSIM : 0.8185.

AXT1 FLAIR



SSIM : 0.7493.





Subsampled Input

Reconstruction (ScattNet-MR)

Ground Truth





SSIM Map

AXT1 PRE



SSIM : 0.7728

AXT1 POST




SSIM : 0.7960.




# Estabilidad ante el ruido




$\sigma_z = 0$  (seed=1234, slice=10)




$\sigma_z = 0.1$  (seed=1234, slice=10)







$\sigma_z = 0.5$  (seed=1234, slice=10)




$\sigma_z = 1$  (seed=1234, slice=10)




Generator




$\sigma_k = 0$  (seed=1234, slice=10)




$\sigma_k = 0.1$  (seed=1234, slice=10)







$\sigma_k = 0.5$  (seed=1234, slice=10)




$\sigma_k = 1$  (seed=1234, slice=10)




Generator




$\sigma_k = 0$  (seed=1234, slice=10)








$\sigma_k = 0.1$  (seed=1234, slice=10)



$\sigma_k = 0.5$  (seed=1234, slice=10)




$\sigma_k = 1$  (seed=1234, slice=10)




Aceleración x4 , Ruido gaussiano




$\sigma_k = 0$  (seed=1234, slice=10)




$\sigma_k = 0.1$  (seed=1234, slice=10)







$\sigma_k = 0.5$  (seed=1234, slice=10)



$\sigma_k = 1$  (seed=1234, slice=10)







Generator



## Estabilidad


El modelo presenta una estabilidad considerable ante la presencia de ruido gaussiano simulando ruido de adquisición



# Incertidumbre del modelo



# Montecarlo dropout




# Comparación con otros modelos

## Métricas de comparación

Ante la falta de pesos de entrenamiento proveídos, nos basamos en la comparación directa con el artículo de Li., et


Muestra ventaja sobre modelos CNN directos; sin embargo, su desempeño es menor frente a arquitecturas GAN






## Métricas de comparación

Sin embargo el modelo presenta una disminución significativa respecto al número de parámetros entrenables en los modelos GAN, presentando una mayor estabilidad al entrenamiento e interpretabilidad.




## Tiempos de ejecución

ScattNet-MR no solo ofrece precisión en la reconstrucción, sino que también es altamente eficiente en GPU, habilitando experimentos estadísticos complejos (como Monte Carlo) en tiempos prácticos.



GPU: Nvidia GeForce RTX 4090



CPU: 12th Gen Intel(R) Core(TM) i9-12900

## Conclusiones

- Relevancia clínica: reducir los tiempos de adquisición en resonancia magnética es crítico para mejorar la experiencia del paciente y la eficiencia del sistema de salud.
- Aporte metodológico: ScattNet-MR integra super-resolución profunda con fundamentos de física estadística y wavelet scattering, logrando reconstrucciones fieles con tiempos de exploración hasta un 75% menores sin comprometer la calidad diagnóstica.
- Robustez: el modelo mostró estabilidad ante ruido e incorporó mecanismos de atención que mejoran la generalización y la preservación de detalles estructurales.
- Eficiencia computacional: el entrenamiento requirió 14 horas en GPU para un dataset de 5 mil imágenes, y la inferencia en CPU por imagen es eficiente, habilitando estudios estadísticos como Monte Carlo en tiempos prácticos.
- Impacto: este enfoque abre camino a implementaciones clínicas escalables, donde la reducción de tiempos no solo incrementa el número de estudios diarios posibles, sino que presenta un método fundamentado en la física y estadística.



## Áreas de oportunidad

- Optimización de arquitectura: explorar variantes más ligeras de ScattNet-MR que reduzcan parámetros y consumo energético, manteniendo la calidad de reconstrucción.
- Datos clínicos reales: validar el modelo en conjuntos de datos multicanal y multiinstitucional para garantizar robustez en entornos hospitalarios reales.
- Generalización multimodal: extender el enfoque a otras modalidades de imagen médica (p. ej. tomografía computarizada o ultrasonido) para evaluar la transferencia del método.

### Agradecimientos

Este proyecto fue llevado a cabo gracias a los programas UNAM-PAPIIT IT101624 y IN108624 .

## Contacto



**Diego Antonio Villalba González**

Facultad de Ciencias UNAM

Correo:

**[diego.villalba@ciencias.unam.mx](mailto:diego.villalba@ciencias.unam.mx)**

Página personal:


**<https://diegoviillalba.github.io/>**



**Linkedin**



**GitHub**



**Instagram**



Nebulosa de Orión

## Referencias

Bushong, S.C.; Clarke, G.D. *Magnetic Resonance Imaging: Physical and Biological Principles*, 4th ed.; Elsevier Mosby: St. Louis, MO, 2014.

Organisation for Economic Co-operation and Development. Health at a Glance 2023: OECD Indicators, 2023. <https://doi.org/10.1787/4dd50c09-en>.

Rani, B.; Singh, P.K.; et al. A Review on Accelerated Magnetic Resonance Imaging Techniques: Parallel Imaging, Compressed Sensing, and Machine Learning. *Magnetic Resonance Imaging* 2024. Early access on ResearchGate.

Sprawls, P. *Magnetic Resonance Imaging: Principles, Methods, and Techniques*; Medical Physics Publishing: Madison, WI, 2000.

Singh, A.; Yadav, S.; Sharma, N.; Pachori, R.B.; Acharya, U.R. Emerging trends in fast MRI using deep-learning reconstruction on undersampled k-space data. *Bioengineering* 2023, 10, 1012. <https://doi.org/10.3390/bioengineering10101012>.

Kusakunniran, W.; Liu, M.; Wu, S. Dual-domain deep learning reconstruction for accelerated MRI. *Magnetic Resonance Imaging* 2021, 80, 10–22. <https://doi.org/10.1016/j.mri.2021.03.002>.

Zhang, C.; Wang, Y.; Chen, Y. ROI-aware deep MRI reconstruction with Huber and perceptual loss. *Medical Image Analysis* 2022, 76, 102301. <https://doi.org/10.1016/j.media.2021.102301>.

Tolpadi, A.; Lee, S.; Gold, G.E. Anatomically guided deep learning reconstruction for accelerated MRI. *Journal of Magnetic Resonance Imaging* 2022, 55, 1489–1504. <https://doi.org/10.1002/jmri.27959>.

Quan, T.; Chang, Y.; Huang, C. RefineGAN: End-to-end adversarial MRI reconstruction. *Medical Image Analysis* 2021, 68, 101907. <https://doi.org/10.1016/j.media.2020.101907>.

Oh, G.B.; Lim, H.; Kim, H.I. CycleGAN-based cross-domain MRI reconstruction with structural consistency. *IEEE Transactions on Medical Imaging* 2022, 41, 375–387. <https://doi.org/10.1109/TMI.2021.3098564>.

Li, X.; Lv, X.; Wang, Y. Complex-valued GANs for accelerated multi-contrast MRI reconstruction. *Magnetic*

## Referencias

- Chen, Y.; Yang, G.; Wang, S. Physics-informed deep learning for MRI reconstruction: A review. *Magnetic Resonance in Medicine* **2022**, *87*, 3161–3180. <https://doi.org/10.1002/mrm.29188>.
- Luo, G.; Chen, R.; Liu, Q. Plug-and-play deep priors for iterative MRI reconstruction. *IEEE Transactions on Medical Imaging* **2021**, *40*, 1770–1782. <https://doi.org/10.1109/TMI.2021.3061284>.
- Gungor, A.; Liang, D.; Zhang, Y. Score-based diffusion models for accelerated MRI reconstruction. *Medical Image Analysis* **2022**, *78*, 102383. <https://doi.org/10.1016/j.media.2022.102383>.
- Narnhofer, D.; Langkammer, C.; Knoll, F. Bayesian deep learning for reliable MRI reconstruction under undersampling. *Magnetic Resonance in Medicine* **2023**, *89*, 130–145. <https://doi.org/10.1002/mrm.29328>.
- Wang, Z.; Bovik, A.C.; Sheikh, H.R.; Simoncelli, E.P. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing* **2004**, *13*, 600–612. <https://doi.org/10.1109/TIP.2003.819861>.
- Hore, A.; Ziou, D. Image quality metrics: PSNR vs. SSIM. In Proceedings of the 20th International Conference on Pattern Recognition, 2010, pp. 2366–2369. <https://doi.org/10.1109/ICPR.2010.579>.
- Bhadra, S.; Kelkar, V.A.; Brooks, F.J.; Anastasio, M.A. On Hallucinations in Tomographic Image Reconstruction. *IEEE Transactions on Medical Imaging* **2021**, *40*, 3249–3260. <https://doi.org/10.1109/TMI.2021.3077857>.
- Mallat, S. Group Invariant Scattering. *Communications on Pure and Applied Mathematics* **2012**, *65*, 1331–1398. <https://doi.org/10.1002/cpa.21413>.
- Zbontar, J.; Knoll, F.; Sriram, A.; Murrell, T.; Huang, Z.; Muckley, M.J.; Defazio, A.; Sodickson, D.K.; Zitnick, C.L.; Recht, M.P. fastMRI: An Open Dataset and Benchmarks for Accelerated MRI. *arXiv preprint arXiv:1811.08839* **2018**.
- Facebook AI Research and NYU Langone Health. fastmri: PyTorch library for the fastMRI dataset and models. <https://pypi.org/project/fastmri/>, 2020. Accessed: 2025-08-05.



## Referencias

- Kusakunniran, W.; Liu, M.; Wu, S. Dual-domain deep learning reconstruction for accelerated MRI. *Magnetic Resonance Imaging* **2021**, *80*, 10–22. <https://doi.org/10.1016/j.mri.2021.03.002>.
- Zhang, C.; Wang, Y.; Chen, Y. ROI-aware deep MRI reconstruction with Huber and perceptual loss. *Medical Image Analysis* **2022**, *76*, 102301. <https://doi.org/10.1016/j.media.2021.102301>.
- Tolpadi, A.; Lee, S.; Gold, G.E. Anatomically guided deep learning reconstruction for accelerated MRI. *Journal of Magnetic Resonance Imaging* **2022**, *55*, 1489–1504. <https://doi.org/10.1002/jmri.27959>.
- Quan, T.; Chang, Y.; Huang, C. RefineGAN: End-to-end adversarial MRI reconstruction. *Medical Image Analysis* **2021**, *68*, 101907. <https://doi.org/10.1016/j.media.2020.101907>.
- Chen, Y.; Yang, G.; Wang, S. Physics-informed deep learning for MRI reconstruction: A review. *Magnetic Resonance in Medicine* **2022**, *87*, 3161–3180. <https://doi.org/10.1002/mrm.29188>.
- Luo, G.; Chen, R.; Liu, Q. Plug-and-play deep priors for iterative MRI reconstruction. *IEEE Transactions on Medical Imaging* **2021**, *40*, 1770–1782. <https://doi.org/10.1109/TMI.2021.3061284>.
- Gungor, A.; Liang, D.; Zhang, Y. Score-based diffusion models for accelerated MRI reconstruction. *Medical Image Analysis* **2022**, *78*, 102383. <https://doi.org/10.1016/j.media.2022.102383>.
- Narnhofer, D.; Langkammer, C.; Knoll, F. Bayesian deep learning for reliable MRI reconstruction under undersampling. *Magnetic Resonance in Medicine* **2023**, *89*, 130–145. <https://doi.org/10.1002/mrm.29328>.
- Wang, Z.; Bovik, A.C.; Sheikh, H.R.; Simoncelli, E.P. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing* **2004**, *13*, 600–612. <https://doi.org/10.1109/TIP.2003.819861>.