

Aplicación de deep learning para filtrado de baja dosis y trabajos futuros

Mónica Chillarón

Dpto. Sistemas Informáticos y Computación.
Universitat Politècnica de València.

Reunión Anual Proyecto TED

Ayuda TED2021-131091B-I00, financiada por MCIN/AEI/10.13039/501100011033/ y por la Unión Europea Next-GenerationEU/PRTR

Valencia, 28 de febrero de 2024

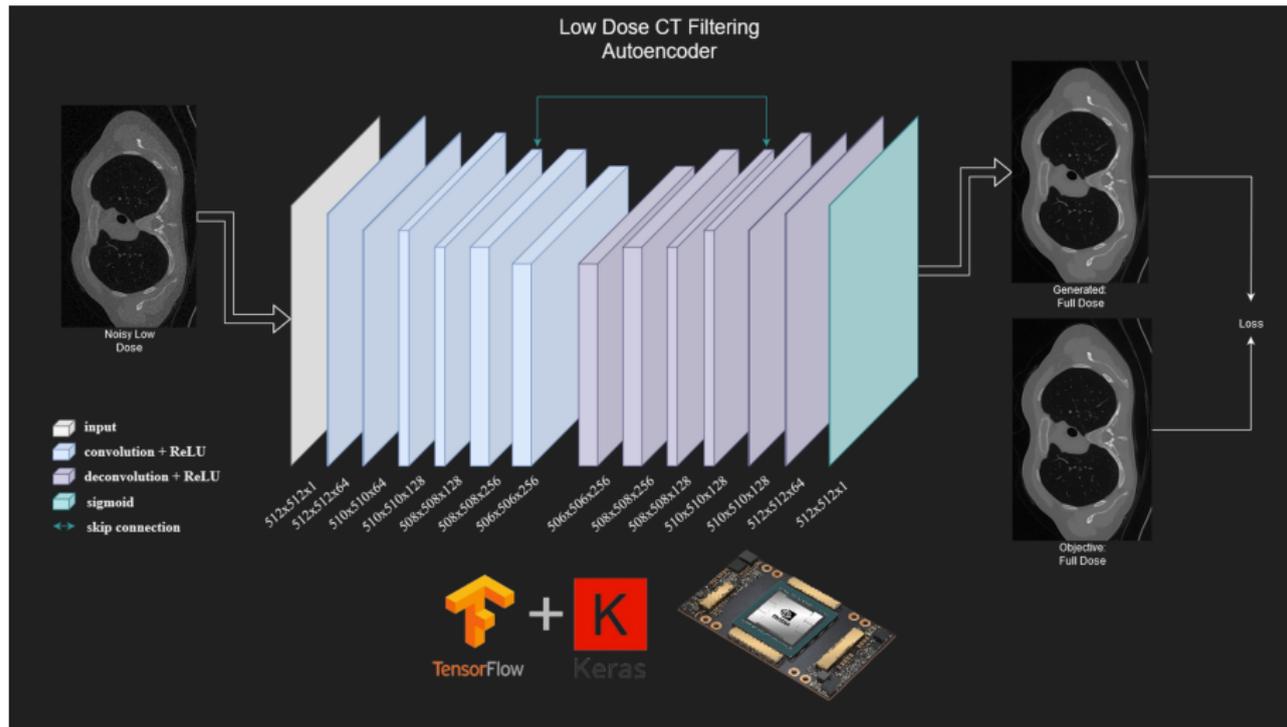
1. Autoencoder para el filtrado de imágenes de baja dosis

2. Trabajo Futuro con IA

Autoencoder para el filtrado de imágenes de baja dosis

- Objetivo: entrenar una red que reciba una imagen de baja dosis y genere una nueva que imite el aspecto de las de dosis completa.
- Empleo del dataset DICOM-CT-PD de la clínica Mayo.
- Adecuación de los datos para la lectura y el manejo de las imágenes desde Python y Keras.
- Implementación de una red de tipo Autoencoder.

Autoencoder para el filtrado de imágenes de baja dosis



Autoencoder para el filtrado de imágenes de baja dosis

- Las imágenes tiene resolución 512×512 y ocupan mucha memoria en la GPU: batches pequeños y dinámicos mediante `flow_from_dataframe`.
- Genera parejas de datos: imagen ruidosa (baja dosis) y su referencia sin ruido (dosis completa).
- Optimizador Adam.
- Tres conjuntos de datos: 64 % entrenamiento, 16 % validación, 20 % test.
- Ahora mismo se está entrenando cada tipo de imagen por separado (tórax, hígado, cabeza).
- Las de cabeza no están funcionando bien, probablemente debido a que hay imágenes vacías.

Se pretende estudiar tres funciones de pérdida:

- **Binary Crossentropy** (estándar). Mide la similitud entre dos imágenes considerando cada píxel como una clasificación binaria (pertenece a la imagen original o no).

La BCE penalizará la red por cada píxel de la imagen reconstruida que no coincida con el valor del píxel correspondiente en la imagen original.

La BCE no tiene en cuenta la estructura espacial de las imágenes. Es sensible al ruido y a las variaciones de iluminación. No es una medida directa de la calidad visual de la imagen reconstruida.

- **MS_SSIM**: Multi-Scale SSIM. Va más allá del SSIM (índice de similitud estructural) básico al considerar los detalles de la imagen en diferentes resoluciones.

$$Loss = 1 - MS_SSIM$$

- **Mix-Loss**: Combinación de MAE y SSIM. Combina estas dos pérdidas individuales utilizando un factor de mezcla ponderado.

$$Loss = alpha * loss_mae + (1 - alpha) * (loss_ms_ssim)$$

Resultados Hígado

Mix Loss

Full dose



Low dose



Autoencoder



MS-SSIM

Full dose



Low dose



Autoencoder



Resultados Hígado

Mix Loss

Full dose



Low dose



Autoencoder



MS-SSIM

Full dose



Low dose



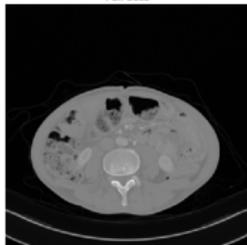
Autoencoder



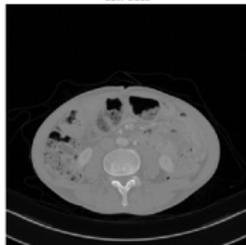
Resultados Hígado

Mix Loss

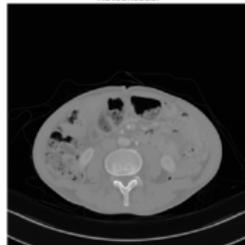
Full dose



Low dose

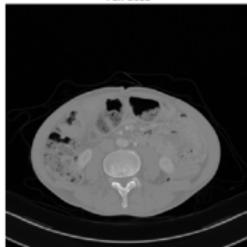


Autoencoder

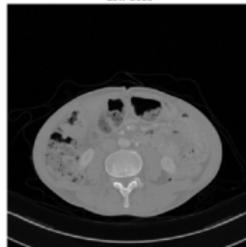


MS-SSIM

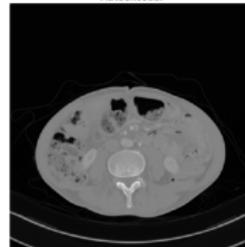
Full dose



Low dose



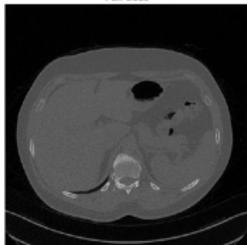
Autoencoder



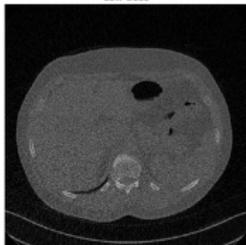
Resultados Tórax

Mix Loss

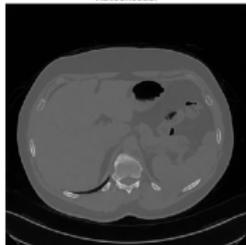
Full dose



Low dose

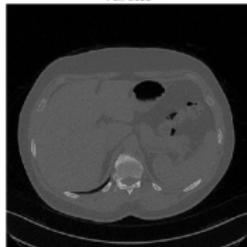


Autoencoder

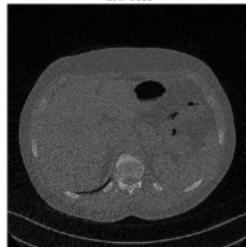


MS-SSIM

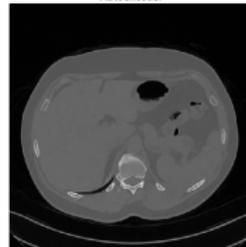
Full dose



Low dose



Autoencoder



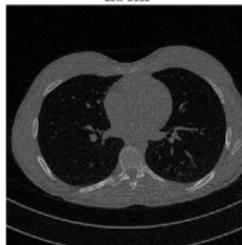
Resultados Tórax

Mix Loss

Full dose



Low dose



Autoencoder



MS-SSIM

Full dose



Low dose



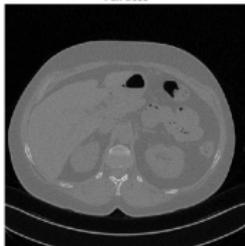
Autoencoder



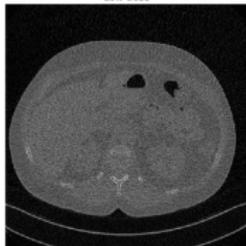
Resultados Tórax

Mix Loss

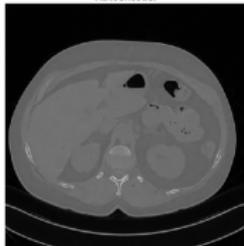
Full dose



Low dose

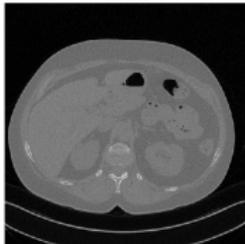


Autoencoder

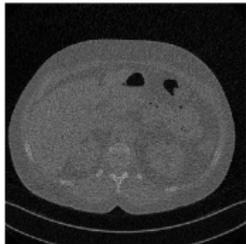


MS-SSIM

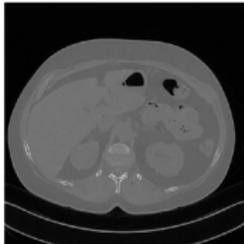
Full dose



Low dose



Autoencoder



Conclusiones y trabajo futuro

- Esta aplicación está en fase de desarrollo. Todavía hay que ajustarla y estudiar los resultados.
- Una posible mejora sería dividir los volúmenes en partes más pequeñas y aplicar el filtrado en 3D. Sería una nueva red.
- Este tipo de red puede servir para combinar con otros métodos. Por ejemplo, limpiar los artefactos de raya al bajar el número de proyecciones, o los que obtiene la QR cuando subimos de resolución.
- Los datos de entrada se normalizan entre 0 y 1. Todavía hay que ver cómo volver a pasarlos a la escala original.

Trabajo Futuro con IA

Tarea 5.1. Interpolación de sinogramas con pocas proyecciones mediante Redes Neuronales Convolucionales (CNNs) para formar sinogramas de rango completo.

- Se ha investigado la bibliografía sobre este tema. Hay trabajos que lo han planteando combinando con reconstrucción del sinograma generado en cada etapa para validar la imagen:

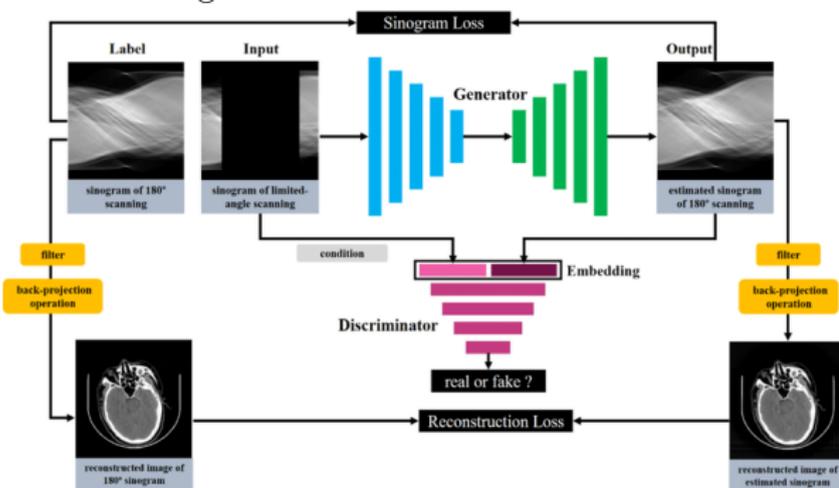


Fig. : LI, Ziheng, et al. Promising generative adversarial network based sinogram inpainting method for ultra-limited-angle computed tomography imaging. *Sensors*, 2019, vol. 19, no 18, p. 3941.

Tarea 5.2. Desarrollo de una Red Generativa Adversaria (GAN) para obtener directamente una imagen de TC a partir de una proyección TC.

- Este tipo de red es más compleja que la anterior. Podría funcionar para imágenes generales, pero es complicado en imagen médica puesto que puede no ser fiable.
- Se ha encontrado un trabajo que hace esto para imágenes de PET muy pequeñas:

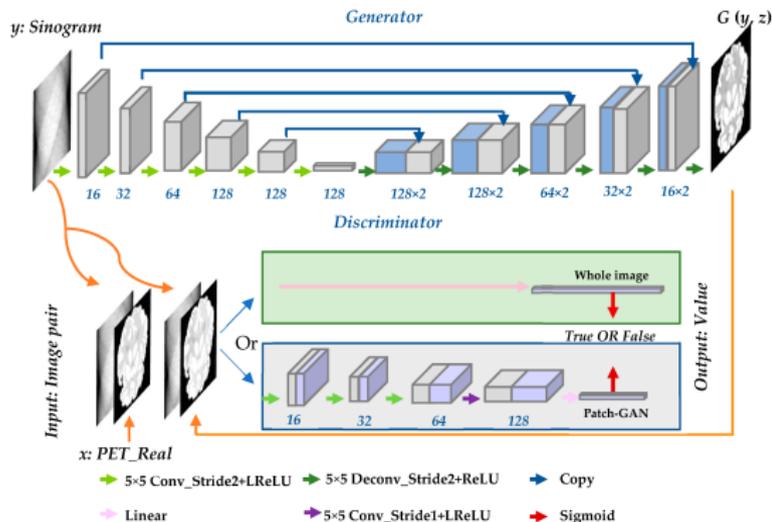


Fig. : LIU, Zhiyuan; YE, Huihui; LIU, Huafeng. Deep-Learning-Based Framework for PET Image Reconstruction from Sinogram Domain. Applied Sciences, 2022, vol. 12, no 16, p. 8118.



Financiado por
la Unión Europea
NextGenerationEU



UNIVERSITAT
POLITÀCNICA
DE VALÈNCIA

Gracias por su atención.

Mónica Chillarón

Dpto. Sistemas Informáticos y Computación.
Universitat Politècnica de València.

Ayuda TED2021-131091B-I00, financiada por MCIN/AEI/10.13039/501100011033/
y por la Unión Europea NextGenerationEU/PRTR