

Corrección de atenuación en SPECT mediante aprendizaje profundo con ventanas de fotopico y dispersión

Deep Learning-Based Attenuation Correction in SPECT Using Photopeak and Scatter Windows

Doctoranda:

Mariana PRIETO CANALEJO

<https://orcid.org/0009-0004-1338-8021>

Universidad Tecnológica Nacional, Facultad Regional Buenos Aires, Ciudad Autónoma de Buenos Aires, Argentina.
mprietocanalejo@frba.utn.edu.ar

Director:

Daniel MINSKY

Comisión Nacional de Energía Atómica, Centro Atómico Constituyentes, Buenos Aires, Argentina

Codirector:

Mauro NAMÍAS

Fundación Centro Diagnostico Nuclear (FCDN), Buenos Aires, Argentina

Resumen

Los artefactos de atenuación constituyen una limitación importante para la interpretación de los estudios SPECT. Aunque la corrección basada en CT es el método de referencia, requiere infraestructura específica y supone una exposición adicional a la radiación. En este trabajo se propone un modelo de aprendizaje profundo basado en una U-Net de doble entrada, capaz de generar mapas sintéticos de corrección por atenuación a partir de las ventanas del fotopico y de dispersión, incorporando la segmentación del contorno corporal. Se incluyeron 320 estudios SPECT de perfusión miocárdica realizados con 99mTc-MIBI: 258 para entrenamiento y validación, y 62 para evaluación. El modelo propuesto alcanzó un MSSIM de 0,98 y un MRE de 7,28 % para los mapas de atenuación, y un MSSIM de 0,99 y un MRE de 4,8 % para las imágenes reconstruidas. Los límites de concordancia al 95 % fueron $[-6,87; 6,76]$ % a nivel de vóxel y $[-7,81; 8,21]$ % a nivel segmentario. En conjunto, estos resultados indican que la combinación de la información del fotopico, la ventana de dispersión y la segmentación corporal permite obtener una alternativa basada únicamente en datos de emisión, con potencial para evitar el uso de CT en la corrección por atenuación.

Palabras clave: SPECT; corrección de atenuación; aprendizaje profundo; ventana de dispersión

Abstract

Attenuation artifacts represent a major limitation in the interpretation of SPECT studies. Although CT-based attenuation correction remains the reference method, it requires dedicated infrastructure and involves additional radiation exposure. In this work, we propose a deep learning model based on a dual-input U-Net capable of generating synthetic attenuation correction maps from the photopeak and scatter windows, while incorporating body contour segmentation. A total of 320 SPECT myocardial perfusion studies using 99mTc-MIBI were included: 258 for training and validation, and 62 for evaluation. The proposed model achieved an MSSIM of 0.98 and an MRE of 7.28% for the attenuation maps, and an MSSIM of 0.99 and an MRE of 4.8% for the reconstructed images. The 95% limits of agreement were $[-6.87, 6.76]$ % at the voxel level and

$[-7.81, 8.21]$ % at the segment level. These results indicate that combining photopeak information, the scatter window, and body segmentation provides an emission-only alternative with the potential to avoid the use of CT for attenuation correction.

Keywords: SPECT; attenuation correction; deep learning; scatter window

Introducción

La tomografía computada por emisión de fotón único (SPECT) es una técnica de medicina nuclear ampliamente utilizada en cardiología, neurología y oncología (Holman & Tumeh, 1990). Sin embargo, la calidad de imagen y la precisión cuantitativa se ven afectadas por la atenuación de los fotones, cuya magnitud varía según las características anatómicas y corporales de cada paciente. Estos efectos pueden generar artefactos que dificultan tanto la interpretación visual como la evaluación cuantitativa (Singh et al., 2007).

La corrección de atenuación basada en tomografía computada (CT) es actualmente el estándar de referencia en SPECT. Sin embargo, su implementación rutinaria se ve limitada por el mayor costo y complejidad del sistema, la exposición adicional a radiación del paciente, y el hecho de que una parte importante de los equipos SPECT en uso clínico no cuenta con CT integrado. Los métodos clásicos de corrección de atenuación basados exclusivamente en emisión requieren modelos físicos simplificados y procedimientos de optimización computacionalmente intensivos, lo que limita su robustez en flujos de trabajo clínicos (Berker & Li, 2016).

En los últimos años, el desarrollo de modelos generativos mediante aprendizaje profundo ha revolucionado el reconocimiento y el análisis de imágenes (Dayarathna et al., 2024). Este enfoque se ha explorado en imágenes médicas para obtener CT sintéticas e imágenes corregidas de medicina nuclear (Arabi et al., 2021; P. Yang et al., 2025), lo que sugiere su potencial para mejorar la calidad de imagen, reducir el tiempo de adquisición y minimizar la exposición a la radiación (Hu et al., 2024; F. Yang et al., 2025).

En este trabajo se propone un método basado en aprendizaje profundo para la generación de mapas de corrección de atenuación (MCA) en estudios SPECT de perfusión miocárdica. El método combina información proveniente de las ventanas de fotopico y dispersión mediante una arquitectura de doble codificador. A partir de un enfoque previo basado únicamente en la ventana de fotopico (Prieto Canalejo et al., 2023), se incorporó la ventana de dispersión como una fuente adicional de información, con el objetivo de superar las limitaciones del enfoque basado únicamente en el fotopico y mejorar la estimación de los mapas de atenuación. Asimismo, se aplicó una segmentación automática al mapa de atenuación de referencia para delimitar el contorno formado por el cuerpo del paciente y la camilla del equipo, utilizando el modelo Segment Anything (SAM) (Kirillov et al., 2023).

Desarrollo

Para este trabajo se utilizaron 320 estudios SPECT de perfusión miocárdica, correspondientes a estudios de esfuerzo y reposo realizados en pacientes con hallazgos normales y anormales, utilizando ^{99m}Tc -MIBI. Los mismos fueron realizados en la Fundación Centro Diagnóstico Nuclear (FCDN), Buenos Aires, Argentina. Las imágenes SPECT y CT se adquirieron mediante un sistema Millennium Hawkeye VG (GE Healthcare). La ventana de energía del fotopico fue de 129,5 a 150,5 keV, mientras que la ventana inferior de dispersión fue de 111 a 129 keV. La CT se adquirió a 140 kV, dos revoluciones por minuto y una corriente de tubo de 2,5 mA.

Las imágenes de emisión del fotopico se reconstruyeron mediante un algoritmo OSEM 3D (Ordered Subsets Expectation Maximization) con 3 iteraciones y 10 subconjuntos. La reconstrucción no incluyó corrección de dispersión ni de atenuación, utilizando un software de reconstrucción desarrollado localmente (Namías & Jeraj, 2017). De este modo se obtuvieron imágenes del fotopico sin corrección de atenuación. Las imágenes de dispersión se reconstruyeron con el mismo algoritmo, empleando las proyecciones de dispersión como entrada de emisión, para producir imágenes de dispersión sin corrección de atenuación. Las imágenes CT se reconstruyeron con el software del equipo. Los valores de las imágenes CT se convirtieron de unidades Hounsfield (HU) a MCA a 140 keV mediante una transformación bilineal. Debido a los artefactos presentes en las imágenes CT, se utilizó SAM para segmentar el contorno corporal y eliminar el ruido externo. Este modelo ha demostrado

un buen desempeño en distintas tareas de segmentación de imágenes médicas (Ma et al., 2024), especialmente cuando las estructuras presentan límites claros y bien definidos. Finalmente, la máscara adecuada se seleccionó según su ubicación, suavidad y circularidad.

Se propone una red neuronal convolucional profunda (DCNN) basada en la arquitectura U-Net (Ronneberger et al., 2015). Esta arquitectura y sus variantes permiten crear modelos generativos y se han utilizado en el ámbito médico para generar imágenes CT sintéticas. En este trabajo, la U-Net se adaptó para incorporar dos ramas codificadoras, diseñadas para procesar información complementaria proveniente de las imágenes SPECT reconstruidas del fotopico y de dispersión (Figura 1). Cada entrada es procesada de manera independiente por una rama codificadora específica, lo que permite a la red extraer características especializadas de acuerdo con las propiedades particulares de los datos del fotopico y de dispersión. Las salidas de ambos codificadores se integran en un módulo de fusión, donde se combina su información complementaria para generar como salida final una imagen CT sintética.




Figura 1: Arquitectura U-Net con doble codificador y ramas separadas para las entradas del fotopico y de dispersión de baja energía. Entrada: SPECT sin corregir de 3 canales; una rama recibe la reconstrucción de la ventana del fotopico y la otra, la reconstrucción de la ventana de dispersión. Salida: MCA en cm^{-1} .

La función de pérdida combina el índice medio de similitud estructural (MSSIM) con la métrica L1 relativa (Ecuación 1). El MSSIM (Ecuación 2) evalúa la calidad visual perceptual de las imágenes y se aplica ampliamente en tareas como compresión y restauración de imágenes. Por su parte, la métrica L1 relativa (Ecuación 3) cuantifica la diferencia absoluta media entre los valores predichos y los valores objetivo, y proporciona una medida directa de la exactitud numérica.

$$\mathcal{L}(Y, \hat{Y}) = \alpha (1 - \text{MSSIM}(Y, \hat{Y})) + (1 - \alpha) \text{Rel}\mathcal{L}_1(Y, \hat{Y}) \quad \text{Ec. (1)}$$

$$\text{MSSIM}(Y, \hat{Y}) = \sum_{j=1}^M \text{SSIM}(y_j, \hat{y}_j) \quad \text{Ec. (2)}$$

$$\text{Rel}\mathcal{L}_1(Y, \hat{Y}) = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i + \epsilon} \right| \quad \text{Ec. (3)}$$

Para mejorar la robustez y la capacidad de generalización de la red se aplicó aumento de datos. Este incluyó rotaciones aleatorias alrededor del eje z (entre -5° y 5°), inversiones aleatorias en los planos coronal, axial y sagital, y desplazamientos horizontales y verticales aleatorios (≤ 7 vóxeles). Los hiperparámetros fueron optimizados mediante búsqueda aleatoria, con 206 estudios para entrenamiento, 52 para validación y 62 para evaluación independiente.

El desempeño fue evaluado mediante el índice de similitud estructural (MSSIM), el error relativo medio (MRE) y análisis de Bland-Altman a nivel de vóxel para los MCAs sintéticos y las imágenes reconstruidas. Para analizar la contribución de la información de dispersión y de la segmentación, se evaluaron configuraciones basadas únicamente en fotopico, modelos de doble entrada fotopico-dispersión y variantes con y sin segmentación. Adicionalmente, se evaluó la distribución de la captación miocárdica de acuerdo con el modelo de 17 segmentos de la Asociación Estadounidense del Corazón. Se calcularon

los errores cuantitativos relativos para cada segmento, para la ROI miocárdica global y para los principales territorios vasculares: la arteria descendente anterior izquierda (LAD), analizada por separado en la región apical y en el territorio restante sin incluir el ápex (LADwa), la arteria circunfleja izquierda (LCX) y la arteria coronaria derecha (RCA).

Resultados

El modelo propuesto se entrenó con 206 pacientes y se evaluó con 62 pacientes. Los hiperparámetros óptimos incluyeron el optimizador Adam, una tasa de aprendizaje de 5×10^{-5} y un valor de alfa de 0.78. Además, se incorporó detención temprana para evitar el sobreajuste. La Figura 2 muestra ejemplos de los MCA generados y de las imágenes AC-SC correspondientes a un paciente del conjunto de prueba.




Figura 2: Fusión de las imágenes SPECT corregidas por atenuación y dispersión (AC-SC) con sus correspondientes mapas de corrección de atenuación (MCA) para un paciente representativo del conjunto de prueba.

Las métricas de calidad de imagen de los mapas sintéticos de corrección por atenuación (MCA) y de las imágenes reconstruidas con corrección por atenuación y dispersión (AC-SC) se resumen en la Tabla 1. El modelo completo (fotopico + dispersión + segmentación) obtuvo el mejor desempeño, con $\text{MSSIM} = 0.98 \pm 0.02$ y $\text{MRE} = 7.28 \pm 2.8\%$ para los MCAs sintéticos, y $\text{MSSIM} = 0.99 \pm 0.0006$ y $\text{MRE} = 4.8 \pm 2.2\%$ para las emisiones reconstruidas, con límites de concordancia al 95% de $[-6.87; 6.76]\%$ a nivel de vóxel. Como se observa en la Tabla 1, la mejora progresiva respecto de las configuraciones con menor información de entrada indica que la ventana de dispersión y la segmentación corporal contribuyen a la calidad de los MCAs sintéticos.

		MSSIM	MRE	95% LoA
Fotopico	MCAs	0.97 ± 0.01	$9.15 \pm 3.7 (\%)$	$[-23.49, 25.27] \%$
	Emisión reconstruida	0.99 ± 0.003	$5.9 \pm 2.8 (\%)$	$[-9.04, 9.00] \%$
Fotopico + Segmentación	MCAs	0.97 ± 0.006	$8.18 \pm 3.36 (\%)$	$[-23.27, 21.77] \%$
	Emisión reconstruida	0.99 ± 0.002	$5.6 \pm 1.9 (\%)$	$[-8.05, 8.18] \%$
Fotopico + Dispersión	MCAs	0.98 ± 0.008	$8.72 \pm 2.04 (\%)$	$[-20.93, 21.32] \%$
	Emisión reconstruida	0.99 ± 0.001	$5.2 \pm 3.1 (\%)$	$[-7.41, 7.38] \%$
Fotopico + Dispersión + Segmentación	MCAs	0.98 ± 0.02	$7.28 \pm 2.8 (\%)$	$[-20.12, 19.68] \%$
	Emisión reconstruida	0.99 ± 0.0006	$4.8 \pm 2.2 (\%)$	$[-6.87, 6.76] \%$

Tabla 1: Métricas de calidad de la emisión reconstruida y de los MCA para cada configuración del modelo.

La evaluación de la captación miocárdica confirmó la consistencia cuantitativa de las imágenes reconstruidas mediante los MCA sintéticos (Tabla 2). El análisis de captación miocárdica mostró sesgos por debajo del 0.40% en todos los territorios vasculares, con límites de concordancia al 95% a nivel de segmento de $[-7.81; 8.21]\%$ (Figura 3). La mayor variabilidad se observó en la región apical ($\text{SD} = 4.6\%$). Los resultados mejoran los obtenidos en trabajos previos basado únicamente en fotopico (Prieto Canalejo et al., 2023).

	Segment	Global	LADwa	LCX	RCA	Apex
SD	4.1	3.8	4.5	4.1	3.8	4.6
95% LoA	[-7.7, 8.2]	[-7.0, 7.8]	[-8.8, 8.9]	[-8.3, 7.7]	[-7.7, 7.0]	[-8.9, 9.6]
bias	0.25	0.40	0.05	-0.30	-0.35	0.35

Tabla 2: Errores cuantitativos por territorio vascular (%)




Figura 3: Boxplot de los errores cuantitativos de las imágenes SPECT reconstruidas con corrección por atenuación y dispersión (AC-SC), discriminados por territorio vascular y por segmento, para los 62 pacientes del conjunto de prueba.

Conclusiones

El método propuesto permitió generar MCAs sintéticos de calidad clínicamente aceptable a partir exclusivamente de datos de emisión de las ventanas de fotopico y dispersión, sin requerir CT. La incorporación de la ventana de dispersión y la segmentación automática del contorno corporal mejoró de forma aditiva la precisión de los mapas sintéticos y de las imágenes reconstruidas.

En este trabajo, todos los conjuntos de datos de entrenamiento y validación provinieron de estudios SPECT de perfusión miocárdica adquiridos con 99mTc-sestamibi. No obstante, el enfoque propuesto presenta potencial para generalizarse a otros radiofármacos SPECT y a estudios de otras regiones anatómicas, incluidas aplicaciones extracardiacas y de neuroimagen. Estas extensiones requerirían conjuntos de datos de entrenamiento específicos para desarrollar modelos optimizados para cada combinación de trazador y órgano.

Desde una perspectiva práctica, esta arquitectura representa un equilibrio favorable entre desempeño y complejidad. Evita la necesidad de adquirir imágenes CT y aprovecha datos de emisión obtenidos rutinariamente. Además, la segmentación puede automatizarse con facilidad, lo que permite implementar un flujo de procesamiento basado íntegramente en emisión y apto para la práctica clínica.

Utilización de IA generativa / herramientas IA

Declaro la utilización de la herramienta de inteligencia artificial ChatGPT, desarrollada por OpenAI, como apoyo para la revisión y mejora de la redacción del presente trabajo. Su uso se limitó a realizar ajustes de claridad, coherencia y estilo, sin sustituir el análisis ni la elaboración de los contenidos. Confirmando que, luego de su utilización, los textos obtenidos fueron revisados, verificados y editados, por lo que asumo plena responsabilidad por el contenido presentado en este trabajo.

Referencias

Arabi, H., AkhavanAllaf, A., Sanaat, A., Shiri, I., & Zaidi, H. (2021). The promise of artificial intelligence and deep learning in PET and SPECT imaging. *Physica Medica*, 83, 122.

- Berker, Y., & Li, Y. (2016). Attenuation correction in emission tomography using the emission data: A review. *Medical Physics*, 43, 807.
- Dayarathna, S., Islam, K. T., Uribe, S., Yang, G., Hayat, M., & Chen, Z. (2024). Deep learning based synthesis of MRI, CT and PET: Review and analysis. *Medical Image Analysis*, 92, 103046.
- Holman, B. L., & Tumeh, S. S. (1990). Single-photon emission computed tomography: Applications and potential. *JAMA*, 263, 561.
- Hu, X., Zhang, H., Caobelli, F., Huang, Y., Li, Y., Zhang, J., Shi, K., & Yu, F. (2024). The role of deep learning in myocardial perfusion imaging for diagnosis and prognosis: A systematic review. *iScience*, 27, 111374.
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A., Lo, W.-Y., Dollár, P., & Girshick, R. (2023). Segment anything. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 3992–4003).
- Ma, J., He, Y., Li, F., et al. (2024). Segment anything in medical images. *Nature Communications*, 15, 654.
- Namías, M., & Jeraj, R. (2017). A quantitative reconstruction software suite for SPECT imaging. In *Proceedings of the 13th International Conference on Medical Information Processing and Analysis*. SPIE.
- Prieto Canalejo, M. A., Palau San Pedro, A., Geronazzo, R., Minsky, D. M., Juárez-Orozco, L. E., & Namías, M. (2023). Synthetic attenuation correction maps for SPECT imaging using deep learning: A study on myocardial perfusion imaging. *Diagnostics*, 13, 2214.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *Lecture Notes in Computer Science* (Vol. 9351, p. 234). Springer.
- Singh, B., Bateman, T. M., Case, J. A., & Heller, G. V. (2007). Attenuation artifact, attenuation correction, and the future of myocardial perfusion SPECT. *Journal of Nuclear Cardiology*, 14, 153.
- Yang, P., Zhang, Z., Wei, J., Jiang, L., Yu, L., Cai, H., Li, L., & Guo, Q. (2025). Deep learning-based CT-free attenuation correction for cardiac SPECT: A new approach. *BMC Medical Imaging*, 25, 38.
- Yang, F., Lei, B., Zhou, Z., Song, T. A., Balaji, V., & Dutta, J. (2025). AI in SPECT imaging: Opportunities and challenges. *Seminars in Nuclear Medicine*, 55, 294.