

This is a postprint version of the following published document:

Del Cerro, C. F., et al. (2020, noviembre). *Estimación del desplazamiento horizontal del detector en un sistema de rayos X utilizando Aprendizaje por Transferencia*. En: CASEIB 2020: XXXVIII Congreso Anual de la Sociedad Española de Ingeniería Biomédica, libro de actas, 25–27 Nov, 2020. Sociedad Española de Ingeniería Biomédica, 2020, pp. 447–450.

URL: http://caseib.es/2020/wp-content/uploads/2020/12/CASEIB2020_LibroActas.pdf



This work is licensed under a [Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Estimación del desplazamiento horizontal del detector en un sistema de rayos X utilizando Aprendizaje por Transferencia

C. F. Del Cerro^{1,2}, R. C. Gimenez², P. M. Olmos^{1,2}, A. Pio^{1,2}, M. Descó^{1,2,3,4}, M. Abella^{1,2,3}

¹ Instituto de Investigación Sanitaria Gregorio Marañón, Madrid, España

² Dept. Bioingeniería e Ingeniería Aeroespacial, Universidad Carlos III de Madrid, Madrid, España

³ Centro Nacional Investigaciones Cardiovasculares Carlos III (CNIC), Madrid, España

⁴ Centro de Investigación Biomédica en Red de Salud Mental (CIBERSAM), Madrid, España

Resumen

En las imágenes de tomografía axial computarizada por rayos X (TAC) pueden aparecer artefactos causados por errores en la calibración geométrica del sistema de rayos X. Aunque existen muchos estudios que tratan de resolver el problema de la calibración geométrica de los sistemas de TAC, a menudo son diseñados específicamente para una configuración concreta y necesitan la adquisición previa de un maniquí. En este trabajo se propone un método basado en aprendizaje profundo (Deep Learning) para estimar la calibración geométrica de un sistema de TAC por rayos X directamente sobre una reconstrucción preliminar con artefactos. Los resultados preliminares muestran la viabilidad de la propuesta que abre la puerta a eliminar la necesidad de una fase de calibración previa con un maniquí específico para la calibración de sistemas de TAC de rayos X, sin suponer un extra de tiempo de cómputo.

1. Introducción

La tomografía axial computarizada por rayos X (TAC) combina una serie de imágenes 2D, llamadas proyecciones, tomadas desde diferentes ángulos alrededor del cuerpo para crear un volumen 3D conocido como imagen reconstruida. Para que estas imágenes sean de alta calidad se debe conocer con mucha precisión las posiciones de la fuente y del detector en cada proyección. Errores en estas posiciones resultan en artefactos de desalineamiento en la imagen reconstruida. Los sistemas TAC suelen incluir un paso de calibración geométrica para estimar los errores de la posición de los distintos elementos respecto a su posición ideal de diseño, fruto de tolerancias en los procesos de fabricación. En la Figura 1 se pueden ver algunos de estos errores en la posición del detector.

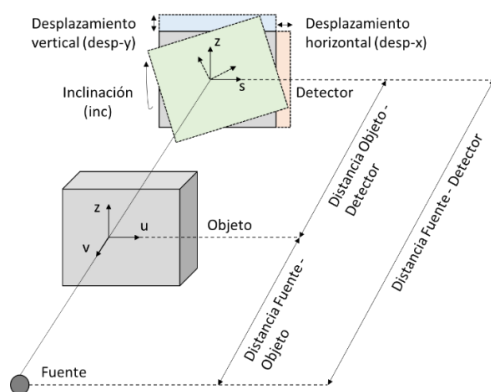


Figura 1. Esquema de un sistema TAC con diferentes errores en la posición del detector.

La aproximación tradicional al problema de la calibración geométrica hace uso de un maniquí de calibración que debe ser específicamente diseñado con marcadores que son esenciales para guiar la estimación de los parámetros. En [1] se propuso un método que estima el centro de rotación en SPECT con geometría de haz cónico a partir de las coordenadas del centro de una fuente puntual proyectada sobre 360 grados. En [2, 3] se presentaron alternativas a este enfoque para lograr una calibración más precisa. En [4] se presentó un enfoque similar para sistemas de rayos X. Más tarde, en [5], los autores desarrollaron un método analítico basado en un maniquí sencillo con dos marcadores esféricos. En [6], se mejora este método incorporando la calibración de cada proyección individualmente, sin asumir una trayectoria fuente-detector perfectamente circular, utilizando un maniquí con mayor número de marcadores. En la actualidad, han surgido alternativas de bajo coste, rápidas y flexibles para diversos sistemas de TAC de haz cónico que se basan en maniqués construidos con ladrillos de LEGO [7-9]. El principal inconveniente de las técnicas mencionadas es que precisan la adquisición previa de un maniquí de calibración, que normalmente está limitado a una configuración concreta.

Alternativamente, se han desarrollado métodos de auto-calibración que tratan de determinar los parámetros de desalineamientos a partir de los datos adquiridos, sin necesidad de maniquí de calibración. En el espacio de la proyección se propuso en [10, 11] un enfoque que trata de estimar el error aprovechando las redundancias de las proyecciones obtenidas en sistemas de TAC de haz cónico. Otros estudios han intentado optimizar la correlación cruzada en el espacio de las proyecciones para determinar desplazamientos verticales y horizontales del detector [12, 13]. Por otra parte, se han desarrollado métodos que trabajan en el espacio de la imagen reconstruida para estimar los parámetros de calibración. En [14, 15] se propuso una corrección iterativa utilizando la minimización de la entropía de la imagen reconstruida. Con un enfoque similar, [16-18] se inspiran en los métodos de autoenfoque de sistemas ópticos, en los que se maximiza la nitidez de la imagen reconstruida para estimar los desalineamientos desconocidos. En [19] se propuso un método que explota la propiedad de simetría de la suma de proyecciones para obtener los parámetros geométricos. El principal problema de los métodos de auto-calibración es su alto coste computacional.

Este trabajo propone un método de calibración para sistemas TAC con geometría de haz cónico a partir del volumen reconstruido utilizando técnicas de aprendizaje profundo. El estudio preliminar se centra en la estimación del parámetro de calibración que más impacto tiene en la calidad de la imagen, el desplazamiento horizontal del detector ($desp-x$ en la Figura 1).

2. Algoritmo Propuesto

El algoritmo comienza con una reconstrucción preliminar considerando geometría ideal ($desp-x = 0.0$ mm), que se utiliza como entrada a la red. La red devuelve un valor estimado de $desp-x$ para cada corte y después se realiza la media.

2.1. Red Neuronal Convolutiva

El algoritmo se basa en el flujo de trabajo típico de aprendizaje por transferencia. Se probaron las redes ResNet-34, ResNet-50 y ResNet-101 [20], seleccionándose ésta última al ser la que consiguió un error menor. Se han mantenido todas las capas convolucionales con los pesos generados tras entrenar la red con el conjunto de datos conocido como *Imagenet* [21], pero se ha definido un predictor nuevo inicializado aleatoriamente, tal y como se muestra en la Figura 2. Este nuevo predictor está compuesto por dos capas lineales con una función de activación (*ReLU*) entre ambas para obtener como salida la estimación del valor de $desp-x$.

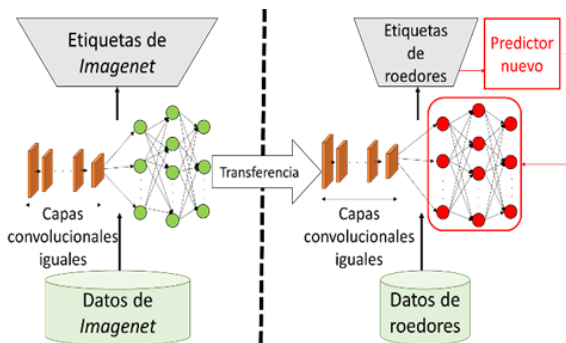


Figura 2. Estrategia de aprendizaje por transferencia implementada en este trabajo.

2.2. Generación de la base de datos

Para crear la base de datos se utilizaron seis estudios de roedor adquiridos con el micro-CT Add-On de SEDECAL [22] mostrados en la Figura 3.




Figura 3. Corte axial central de los seis estudios de roedor utilizados.

Para cada roedor, se simuló 25 conjuntos de proyecciones con distintos valores de $desp-x$ siguiendo una distribución uniforme con media 0 y desviación estándar usando la herramienta de simulación FuxSim [23]. Cada conjunto de proyecciones se reconstruyó tomando $desp-x = 0.0$ mm, resultando en un volumen con artefactos de dimensiones $336 \times 436 \times 200$ y tamaño de píxel 0.12 mm. De cada volumen se extrajeron los 200 cortes axiales generando una base de datos de imágenes 2D. Los 200 cortes axiales correspondientes a los cinco primeros roedores se utilizaron para entrenar la red y los del sexto para validar el modelo. La Figura 4 muestra ejemplos con distintos valores de $desp-x$ para el corte axial central del roedor 1.




Figura 4. Corte axial del roedor 1 reconstruido con diferentes valores de $desp-x$: 1.9 mm (A), -0.5 mm (B), -3.8 mm (C).

2.3. Entrenamiento y validación de la red

Se utilizaron 25000 imágenes para el entrenamiento y 5000 para la validación. El entrenamiento de la red realizó en dos pasos: en un primer paso se entrenó el predictor, manteniendo intactos los pesos de las capas convolucionales y en un segundo paso entrenó la red de principio a fin para aumentar la precisión del modelo. Como función de coste usó el error cuadrático medio entre el valor real del desalineamiento y el valor la salida de la red. El optimizador elegido fue Adam [24]. Para seleccionar la tasa de aprendizaje más adecuada se utilizó la prueba diseñada por Leslie N. Smith en [25], cuyo resultado se puede ver en la Figura 5 para el entrenamiento del predictor.

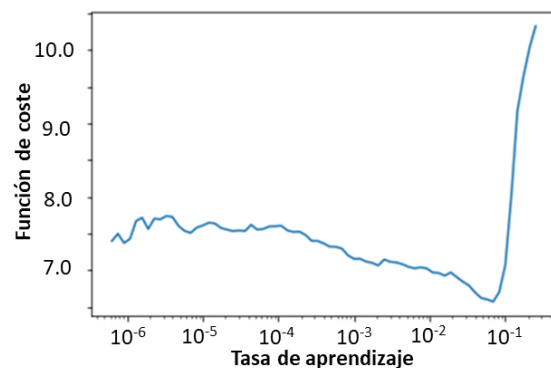


Figura 5. Resultado de la prueba de Leslie N. Smith para determinar el valor óptimo de la tasa de aprendizaje para el predictor.

Observando el resultado de la Figura 5, se decidió un valor para la tasa de aprendizaje de 10^{-3} (zona de máxima pendiente). Una vez alcanzado un error lo suficientemente pequeño, se descongelaron las capas convolucionales y se volvió a realizar la prueba de Leslie N. Smith para determinar la tasa de aprendizaje óptima para entrenar la red de principio a fin, obteniendo el resultado mostrado en la Figura 6.

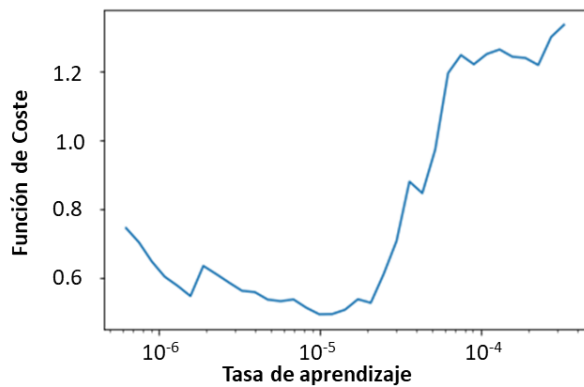


Figura 6. Resultado de la prueba de Leslie N. Smith para determinar el valor óptimo de la tasa de aprendizaje para la red completa.

En este caso se seleccionó una tasa de aprendizaje discriminativa entre 10^{-6} y 10^{-5} correspondiente de nuevo con la zona de máxima pendiente.

Una vez definidos todos los parámetros, el error cuadrático medio conseguido por la red es de 0.3 mm sobre el conjunto de validación.

3. Evaluación del método y resultados

Para evaluar el método se utilizó el roedor 6, que no se incluyó en el conjunto de entrenamiento. Se generaron proyecciones con $desp-x$ igual a 1.2 mm, que es un valor representativo de este tipo de desalineamiento en sistemas TAC de pequeño animal. El valor de $desp-x$ estimado fue de 1.1 mm. En la Figura 7 se puede observar el corte axial central de los volúmenes reconstruidos con $desp-x$ igual a 1.2 mm (ideal), 0.0 mm (sin calibrar) y 1.1 mm (estimado) y el zoom de una región de interés donde se puede observar mejor las diferencias. Se puede comprobar como la reconstrucción con el valor estimado mediante el método propuesto consigue recuperar los detalles presentes en el caso ideal.




Figura 7. Corte axial central de los volúmenes reconstruidos con $desp-x$ igual a: 1.2mm (A), 0.0 mm (B), 1.1 mm (C). Aumento de: (A) en (D), (B) en (E), (C) en (F).

El error cuadrático medio con el volumen ideal se reduce de 0.0038 para el volumen reconstruido con $desp-x = 0.0$ mm a 0.0012 cuando se reconstruye con la estimación obtenida con el método propuesto. Se aprecia como el método propuesto reduce los dobles bordes debido a los errores de calibración. Sin embargo, aún se aprecian ligeros artefactos probablemente debidos al error de 0.1 mm de la estimación.

4. Discusión y Conclusiones

Este trabajo propone una nueva metodología de calibración geométrica en imágenes de TAC mediante el uso de aprendizaje profundo, basada en el análisis directo de una reconstrucción preliminar con artefactos. Esta idea abre la puerta a eliminar la necesidad de una fase de calibración previa con un maniquí específico para la calibración de sistemas de TAC de rayos X, sin suponer un extra de tiempo de cómputo. En este trabajo se presenta una primera aproximación, considerando solo errores debidos al desplazamiento horizontal del detector, que es el parámetro que más afecta en la calidad de imagen reconstruida.

Los resultados muestran una recuperación de los detalles dobles bordes, pero mantienen ligeros artefactos debido al error en la estimación de $desp-x$. Esto puede deberse a que para el entrenamiento se han utilizado imágenes en las que las zonas con artefactos eran pequeñas respecto a la imagen completa. Por otra parte, la base de datos actualmente compuesta por seis estudios de roedor, lo que limita tanto el número de muestras como la variabilidad de estas. Como trabajo futuro, se ampliará esta base de datos para intentar reducir el error y obtener un modelo más robusto.

El paso siguiente será la incorporación de errores en otros parámetros geométricos. Por último, se investigará la posibilidad de trasladar este modelo a sistemas de adquisición más complejos donde cada una de las proyecciones adquiridas tiene una calibración diferente, lo que supondría un avance significativo para los sistemas de tomografía con geometrías no estándar.

5. Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Ciencia, Innovación y Universidades (Instituto de Salud Carlos III, proyecto DTS17/00122; Agencia Estatal de Investigación, proyecto DPI2016-79075-R-AEI/FEDER, RTI2018-099655-B-100, UE), cofinanciado por Fondos de la Unión Europea (FEDER), "A way of making Europe". Además, ha sido financiado por el Programa de apoyo a la realización de proyectos interdisciplinarios de I+D para jóvenes investigadores de la Universidad Carlos III de Madrid 2019-2020 en el marco del Convenio Plurianual Comunidad de Madrid- Universidad Carlos III de Madrid (proyecto DEEPCT-CM-UC3M). El CNIC está financiado por el Ministerio de Ciencia, Innovación y Universidades y la fundación PRO-CNIC y es un centro de excelencia Severo Ochoa (SEV-2015-0505).

Referencias

- [1] G. T. Gullberg, B. M. W. Tsui, C. R. Crawford, J. G. Ballard, and J. T. Hagijs, "Estimation of geometrical parameters and collimator evaluation for cone beam tomography," *Med. Phys.*, vol. 17, pp. 264–72, 1990.
- [2] J. Li, R. Jaszczak, H. Wang, K. Greer, and R. Coleman, "Determination of both mechanical and electronic shifts in cone beam SPECT," *Physics in Medicine & Biology*, vol. 38, p. 743, 1993.
- [3] P. Rizo, P. Grangeat, and R. Guillemaud, "Geometric calibration method for multiple-head

- cone-beam SPECT system," *IEEE transactions on nuclear science*, vol. 41, pp. 2748-2757, 1994.
- [4] A. Rougée, C. Picard, C. Ponchut, and Y. Troussel, "Geometrical calibration of X-ray imaging chains for three-dimensional reconstruction," *Computerized Medical Imaging and Graphics*, vol. 17, pp. 295-300, 1993.
- [5] F. Noo, R. Clackdoyle, C. Mennessier, T. A. White, and T. J. Roney, "Analytic method based on identification of ellipse parameters for scanner calibration in cone-beam tomography," *Physics in Medicine & Biology*, vol. 45, p. 3489, 2000.
- [6] Y. Cho, D. J. Moseley, J. H. Siewerdsen, and D. A. Jaffray, "Accurate technique for complete geometric calibration of cone-beam computed tomography systems," *Medical physics*, vol. 32, pp. 968-983, 2005.
- [7] F. Quercioli, B. Tiribilli, A. Mannoni, and S. Acciai, "Optomechanics with LEGO," *Applied optics*, vol. 37, pp. 3408-3416, 1998.
- [8] Z. H. Levine, S. Grantham, D. S. Sawyer IV, A. P. Reeves, and D. F. Yankelevitz, "A low-cost fiducial reference phantom for computed tomography," *Journal of research of the National Institute of Standards and Technology*, vol. 113, p. 335, 2008.
- [9] V. Nguyen, J. De Beenhouwer, J. Sanctorum, S. Van Wassenbergh, S. Bazrafkan, J. Dirckx, *et al.*, "A low-cost geometry calibration procedure for a modular cone-beam X-ray CT system," *Nondestructive Testing and Evaluation*, pp. 1-14, 2020.
- [10] V. Patel, R. Chityala, K. Hoffmann, C. Ionita, D. Bednarek, and S. Rudin, "Self-calibration of a cone-beam micro-CT system," *Medical physics*, vol. 36, pp. 48-58, 2009.
- [11] D. Panetta, N. Belcari, A. Del Guerra, and S. Moehrs, "An optimization-based method for geometrical calibration in cone-beam CT without dedicated phantoms," *Physics in Medicine & Biology*, vol. 53, p. 3841, 2008.
- [12] S. Mayo, P. Miller, D. Gao, and J. Sheffield-Parker, "Software image alignment for X-ray microtomography with submicrometre resolution using a SEM-based X-ray microscope," *Journal of microscopy*, vol. 228, pp. 257-263, 2007.
- [13] A. Sasov, X. Liu, and P. L. Salmon, "Compensation of mechanical inaccuracies in micro-CT and nano-CT," in *Developments in X-ray Tomography VI*, 2008, p. 70781C.
- [14] Y. Kyriakou, R. Lapp, L. Hillebrand, D. Ertel, and W. Kalender, "Simultaneous misalignment correction for approximate circular cone-beam computed tomography," *Physics in Medicine & Biology*, vol. 53, p. 6267, 2008.
- [15] Y. Kyriakou, R. Lapp, L. Hillebrand, D. Ertel, and W. Kalender, "Image-based online correction of misalignment artifacts in cone-beam CT," in *Medical Imaging 2009: Physics of Medical Imaging*, 2009, p. 72581V.
- [16] A. Kingston, A. Sakellariou, A. Sheppard, T. Varslot, and S. Latham, "An auto-focus method for generating sharp 3D tomographic images," in *Developments in X-Ray Tomography VII*, 2010, p. 78040J.
- [17] A. Kingston, A. Sakellariou, T. Varslot, G. Myers, and A. Sheppard, "Reliable automatic alignment of tomographic projection data by passive auto-focus," *Medical physics*, vol. 38, pp. 4934-4945, 2011.
- [18] T. Varslot, A. Kingston, G. Myers, and A. Sheppard, "High-resolution helical cone-beam micro-CT with theoretically-exact reconstruction from experimental data," *Medical physics*, vol. 38, pp. 5459-5476, 2011.
- [19] Y. Meng, H. Gong, and X. Yang, "Online geometric calibration of cone-beam computed tomography for arbitrary imaging objects," *IEEE transactions on medical imaging*, vol. 32, pp. 278-288, 2012.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [21] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, *et al.*, "Imagenet large scale visual recognition challenge," *International journal of computer vision*, vol. 115, pp. 211-252, 2015.
- [22] J. Vaquero, S. Redondo, E. Lage, M. Abella, A. Sisniega, G. Tapias, *et al.*, "Assessment of a new high-performance small-animal X-ray tomograph," *IEEE transactions on nuclear science*, vol. 55, pp. 898-905, 2008.
- [23] M. Abella, E. Serrano, J. Garcia-Blas, I. Garcia, C. De Molina, J. Carretero, *et al.*, "FUX-Sim: Implementation of a fast universal simulation/reconstruction framework for X-ray systems," *PloS one*, vol. 12, p. e0180363, 2017.
- [24] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [25] L. N. Smith, "Cyclical learning rates for training neural networks," in *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2017, pp. 464-472.