

This is a postprint version of the following published document:

Berdón, P. M. et al. (2020, noviembre). *Corrección del Artefacto de Truncamiento en TAC mediante Aprendizaje profundo*. 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. 285–288.

URL: [http://caseib.es/2020/wp-content/uploads/2020/12/CASEIB2020\\_LibroActas.pdf](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/).

# Corrección del Artefacto de Truncamiento en TAC mediante Aprendizaje profundo

P. M. Berdón<sup>1,2</sup>, C. F. Del Cerro<sup>1,2</sup>, R. C. Gimenez<sup>2</sup>, M. Desco<sup>1,2,3,4</sup>, M. Abella<sup>1,2,3</sup>

<sup>1</sup> Dept. Bioingeniería e Ingeniería Aeroespacial, Universidad Carlos III de Madrid, Madrid, España

<sup>2</sup> Instituto de Investigación Sanitaria Gregorio Marañón, Madrid, España

<sup>3</sup> Centro Nacional Investigaciones Cardiovasculares Carlos III (CNIC), Madrid, España

<sup>4</sup> Centro de Investigación Biomédica en Red de Salud Mental (CIBERSAM), Madrid, España

## Resumen

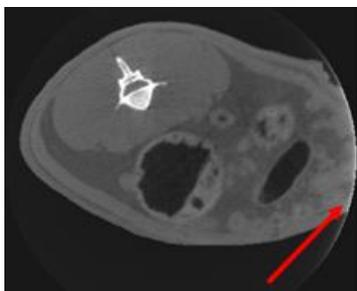
*La adquisición de proyecciones incompletas debido a que parte de la muestra se extiende fuera del campo de visión, resulta en inconsistencias en los datos que dan lugar a lo que se conoce como artefacto de truncamiento. Se han propuesto varios métodos para la compensación de la falta de datos, basados en la extrapolación de las proyecciones, pero ninguno consigue recuperar completamente los datos truncados.*

*Este trabajo presenta un nuevo método de compensación del artefacto de truncamiento en imágenes de TAC basado en técnicas de aprendizaje profundo. La evaluación en datos simulados a partir de estudios de roedores muestra la viabilidad de la propuesta.*

## 1. Introducción

La obesidad es una enfermedad mundial con una incidencia del 13% de la población adulta y un 18% en niños y adolescentes en 2016 según la OMS [1]. Existen países en los que esta enfermedad tiene una mayor prevalencia como en Estados Unidos. Esto puede ser un problema en estudios de Tomografía Axial Computarizada (TAC) ya que las posibilidades de que el paciente se extienda fuera del campo de visión son mayores, produciendo un truncamiento en los datos.

Esta falta de datos hace que no sea cuantitativa la imagen reconstruida y aparezcan artefactos como el halo brillante que se muestra en la Figura 1.



**Figura 1.** Corte axial de un TAC de roedor con proyecciones truncadas. La flecha roja señala el artefacto brillante debido al truncamiento

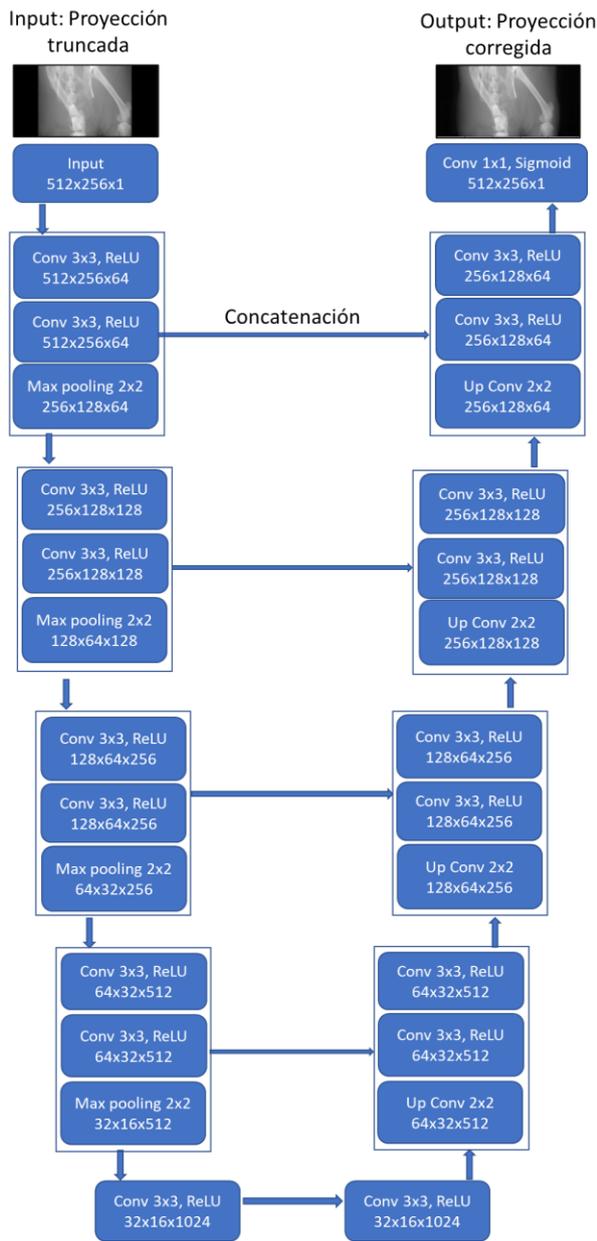
En la literatura encontramos algoritmos para la corrección del truncamiento basados en la extrapolación de los datos tanto en el dominio la proyección como en el dominio de imagen reconstruida. En [2], los autores proponen una

extrapolación de espejo simétrico de las proyecciones truncadas basada en un modelo de senoide, que asegura una caída de los valores de atenuación suave, garantizando la continuidad en el punto de truncamiento. En [3, 4] se propone un método que se basa en modelar la muestra como si estuviera inmersa en un cilindro lleno de agua. De esta forma, se ajusta el cilindro basándose en la intensidad de las proyecciones no truncadas colindantes. Otro método explorado en [5] se basa en completar las sinusoides del sinograma truncado. A diferencia de los métodos anteriores, que buscan corregir el truncamiento extendiendo las proyecciones, en [6] los autores tratan de compensar la falta de datos en la imagen reconstruida mediante extrapolación de las proyecciones truncadas usando la técnica *Deformable Image Registration*, de tal forma que sus proyecciones coincidan con las proyecciones del TAC de referencia.

En este trabajo se propone un método automático de corrección de truncamiento en imágenes de TAC basado en la extrapolación de las proyecciones haciendo uso de técnicas de aprendizaje profundo. Para el entrenamiento de la red se usan datos simulados de truncamiento en a partir de estudios TAC de roedor.

## 2. Algoritmo propuesto

El método propuesto hace uso de la arquitectura U-Net [7] siguiendo el diseño de la implementación de [8], basada en la arquitectura codificador-decodificador, diseñada para la segmentación de imágenes biomédicas (Figura 2). La razón de elegir esta red es que permite mantener la resolución espacial entre la imagen de entrada y salida. El número de bloques sigue lo descrito en [8], pero se modifica el número de canales de características a 64, tras probar diferentes valores, para extraer más detalles de las imágenes y propagar la información útil a las capas de mayor resolución. Se usa el optimizador de Adam, que converge más rápido y es más estable que otros optimizadores [9], con una tasa de aprendizaje de 0.001 después de probar valores en el rango de 0.0001 a 0.03. La función de coste es el error cuadrático medio (MSE), comúnmente usada [10] y fácil de implementar.

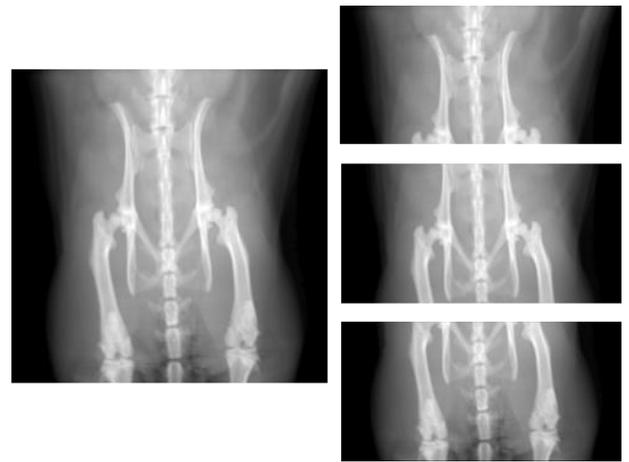


**Figura 2.** Arquitectura de la red de U-Net utilizada para la corrección del truncamiento. Debajo de la especificación de cada capa aparece la dimensionalidad de un solo ejemplo que emite esta capa

### 3. Generación de la base de datos

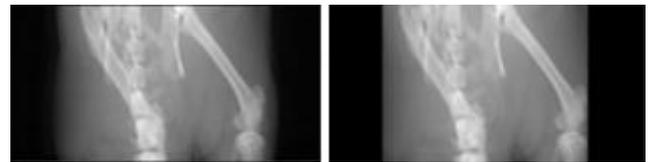
Para generar la base de datos se ha utilizado un estudio TAC de roedor adquirido con el sistema micro-TAC Add-On de SEDECAL [11], obteniendo 360 proyecciones de tamaño 512×512 píxeles, cubriendo todo el rango angular de 360 grados.

Para ampliar la base de datos, el estudio se divide a lo largo del eje axial en tres subconjuntos de proyecciones de 512×256 píxeles, como se muestra en la Figura 3.



**Figura 3.** Proyección original del estudio de TAC (izquierda) y subconjuntos de datos asociados (derecha)

Se han simulado once casos realistas de truncamiento para cada subvolumen, poniendo a cero las bandas externas de la proyección (Figura 4). Como resultado, se dispone de un total de 2880 imágenes de entrenamiento y 1080 imágenes para validación.



**Figura 4.** Proyección sin truncar (izquierda), proyección truncada (derecha)

### 4. Evaluación

La evaluación del método se hace con un TAC de roedor que no se ha usado para el entrenamiento de la red, con un tamaño de la matriz de las proyecciones de 512×256 píxeles, adquirida con el mismo sistema. La reconstrucción de la imagen se hace con Raptor, un algoritmo basado en FDK [12, 13], resultando en un volumen de 512×512×256. La Figura 5 muestra la zona truncada sobre una proyección de este estudio y la imagen reconstruida.



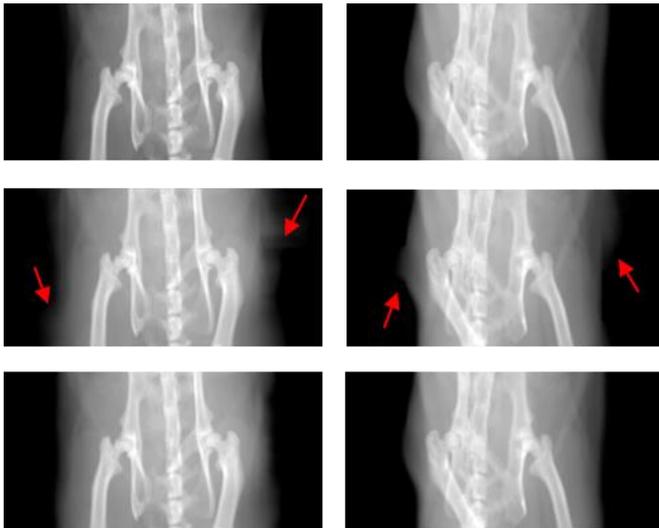
**Figura 5.** Ejemplo de proyección y corte axial del estudio de TAC usado para evaluación

El método propuesto se compara con el método de Ohnesorge et al. [2], el algoritmo más citado en la literatura, en base al *Root Mean Square Error* (RMSE) entre la reconstrucción ideal y la que se obtiene con las proyecciones truncadas corregidas.

### 5. Resultados

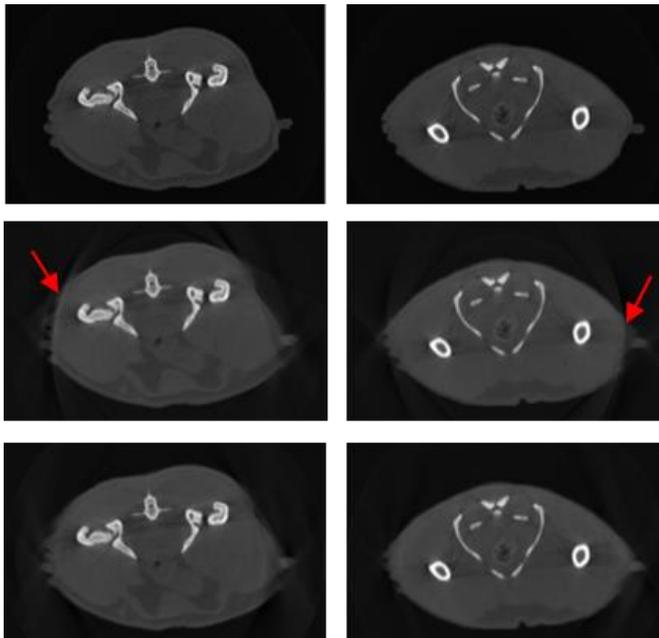
La Figura 6 muestra la recuperación de los datos truncados superior con el método propuesto que con el algoritmo de

Ohnesorge, que extiende demasiado el tejido blando de la proyección.



**Figura 6.** Proyecciones originales (arriba), proyecciones truncadas corregida por el algoritmo de Ohnesorge (centro) y proyecciones truncadas corregida por el método propuesto (abajo)

La Figura 7 muestra una mejor recuperación de los datos truncados con el método propuesto, consiguiendo eliminar la banda de más intensidad que introduce el algoritmo de Ohnesorge.



**Figura 7.** Reconstrucción proyecciones originales (arriba), reconstrucción de las proyecciones truncadas corregidas mediante el algoritmo de Ohnesorge (centro) y reconstrucción de las proyecciones truncadas corregidas por el método propuesto (abajo)

La Tabla 1 muestra un error 15% inferior con el método propuesto respecto al algoritmo de Ohnesorge, resultando en valores más parecidos a la imagen original.

	RMSE
Algoritmo de Ohnesorge	0.0203
Método propuesto	0.0176

**Tabla 1.** RMSE de la reconstrucción para los dos métodos de evaluación

## 6. Discusión y trabajo futuro

Este trabajo presenta un algoritmo de corrección del artefacto de truncamiento basado en la extrapolación de las proyecciones usando técnicas de aprendizaje profundo.

La evaluación en datos de TAC reales muestra una recuperación significativa del artefacto de truncamiento, un 15% superior que la obtenida con el método clásico propuesto por Ohnesorge, ampliamente citado. Sin embargo, se observa un salto en el borde entre datos medidos y datos extrapolados. Esto se puede deber a una poca variabilidad en los datos de entrenamiento o a un limitado número de canales. Por otro lado, sería interesante evaluar casos con truncamiento de zonas el hueso, ya que sus valores son muy altos y no hay una transición suave entre los bordes.

Se observa una pérdida de resolución de la imagen, debida seguramente a la función de coste utilizada. La elección de esta función de coste se hizo en base a su simplicidad, que permitía una primera aproximación para obtener unos primeros resultados y evaluar la viabilidad del método. En la siguiente versión del método se explorará su sustitución por una función de coste basada en *perceptual loss* [14], que compara la salida de los filtros de las capas convolucionales para conseguir más detalles.

En conclusión, se ha propuesto un nuevo método de corrección del artefacto de truncamiento que permite compensar las inconsistencias en los datos, eliminando los artefactos y recuperando la cuantitividad de la imagen reconstruida, en menos de 16 ms.

## 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, 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 interdisciplinares 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] Salud OMD. Obesidad y sobrepeso 2020 [cited 2020]. Available from: <https://www.who.int/es/news-room/fact-sheets/detail/obesity-and-overweight>.
- [2] Ohnesorge B, Flohr T, Schwarz K. Efficient correction for CT image artifacts caused by objects extending outside the scan field of view. *Med Phys*. Vol. 27, Sup. 1, 2000, pp. 39-46.
- [3] Hsieh J, Chao E, Thibault J. A novel reconstruction algorithm to extend the CT scan field-of-view. *Med Phys*. Vol. 31, Sup. 9, 2004, pp. 2385-91.
- [4] Baojun Li, Junjun Deng, Albert H. Lonn, Hsieh J. An enhanced reconstruction algorithm to extend CT scan field-of-view with z-axis consistency constraint. *Med Phys*. Vol. 39, Sup. 10, 2012.
- [5] Chityala R, Hoffmann K.R., S R. Artifact reduction in truncated CT using Sinogram completion. *Proc SPIE 5747, Medical Imaging*. 2005.
- [6] Zhen X, Yan H, Zhou L, Jia X, Jiang S. Deformable image registration of CT and truncated cone-beam CT for adaptive radiation therapy. *Phys Med Biol*. Vol. 55, Sup. 22, 2013, pp. 7979-93.
- [7] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS*. Vol. 9351, 2015, pp. 234-41.
- [8] Buda M, Saha A, Mazurowski MA. Association of genomic subtypes of lower-grade gliomas with shape features automatically extracted by a deep learning algorithm. *Computers in Biology and Medicine*. Vol. 109, 2019.
- [9] Diederik P. Kingma, Ba J. Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*. 2014.
- [10] Mohamed M. Zahra, Mohamed H. Essai, Ellah ARA. Performance Functions Alternatives of Mse for Neural Networks Learning. *International Journal of Engineering Research & Technology (IJERT)*. Vol. 3, Sup. 1, 2014.
- [11] Vaquero JJ, Redondo S, Lage E, Abella M, Sisniega A, Tapias G, et al. Assessment of a New High-Performance Small-Animal X-ray Tomograph. *IEEE Trans Nucl Sci*. Vol. 55, Sup. 3, 2008, pp. 898-905.
- [12] Abella García M, Vaquero López JJ, Sisniega A, Pascau González Garzón J, Udías Á, García V, et al. Software architecture for multi-bed FDK-based reconstruction in X-ray CT scanners. *Computer Methods and Programs in Biomedicine*. Vol. 107, Sup. 2, 2012, pp. 218-32.
- [13] Blas JG, Abella M, Isaila F, Carretero J, Desco M. Surfing the optimization space of a multiple-GPU parallel implementation of a X-ray tomography reconstruction algorithm. *Journal of Systems and Software*. Vol. 95, 2014, pp. 166-75.
- [14] Justin Johnson, Alexandre Alahi, Fei-Fei L. Perceptual Losses for Real-Time Style Transfer and Super-Resolution. *European Conference on Computer Vision*. 2016.