

Vicente Cajas Barrientos <sup>2,3</sup>, Sebastián Millar Tordecillas <sup>2,3</sup>, Denisse Karl Sáez <sup>2,3</sup>, Víctor Castañeda <sup>2,3</sup>, Carlos F. Navarro <sup>1,3</sup>

<sup>1</sup> Departamento de Ingeniería Eléctrica, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile. <sup>2</sup> Departamento de Tecnología Médica, Facultad de Medicina de la Universidad de Chile. <sup>3</sup> Technology for Medical Image-Based Clinical Support Systems Lab(Tech4Medics-Lab), Facultad de Medicina, Universidad de Chile.

## INTRODUCCIÓN

La densidad mamaria (DM) se define como la relación entre el tejido fibroglandular de la mama y su tejido adiposo, siendo calculada como la proporción entre el tejido fibroglandular respecto al volumen total de la mama [1]. Esta relación corresponde a un factor de riesgo importante frente al cáncer de mama [2], cuya patología es la primera causa de muerte por cáncer en mujeres y la neoplasia más frecuente a nivel mundial [3]. La resonancia magnética (RM) mamaria, a diferencia de la mamografía digital y la tomosíntesis mamaria, es considerada el estándar de oro para la diferenciación del tejido fibroglandular mamario y el tejido graso, dada su alta resolución de contraste. En la actualidad, escasos estudios han incurrido en la segmentación del tejido fibroglandular y la estimación del porcentaje de DM mediante RM y algoritmos de deep learning.

## OBJETIVO

Desarrollar un algoritmo de inteligencia artificial basado en deep learning para la estimación de la densidad mamaria en imágenes de resonancia magnética mamaria potenciadas en T1, con el fin de objetivar la caracterización del tejido mamario y permitir su uso en modelos de predicción de riesgo para cáncer de mama.

## MATERIALES Y MÉTODOS

Estudio retrospectivo, cuantitativo, observacional y correlacional.

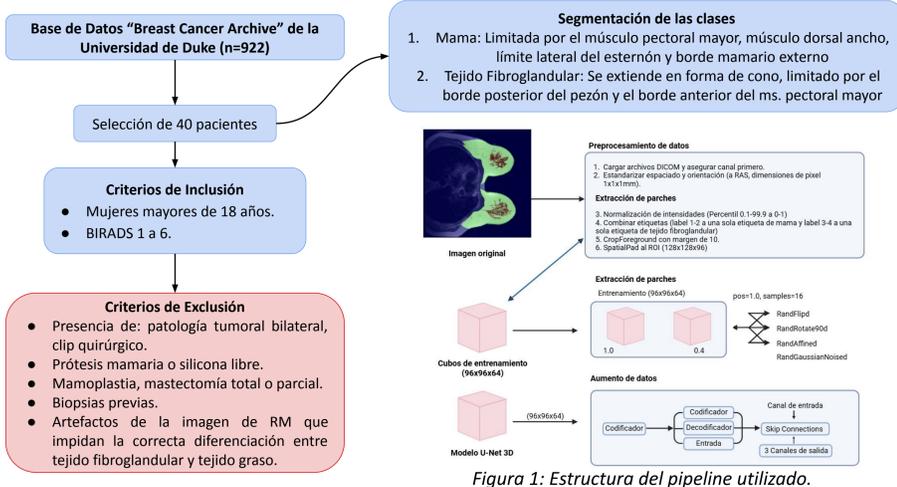


Figura 1: Estructura del pipeline utilizado.

## RESULTADOS Y DISCUSIÓN

### Evaluación del rendimiento del algoritmo

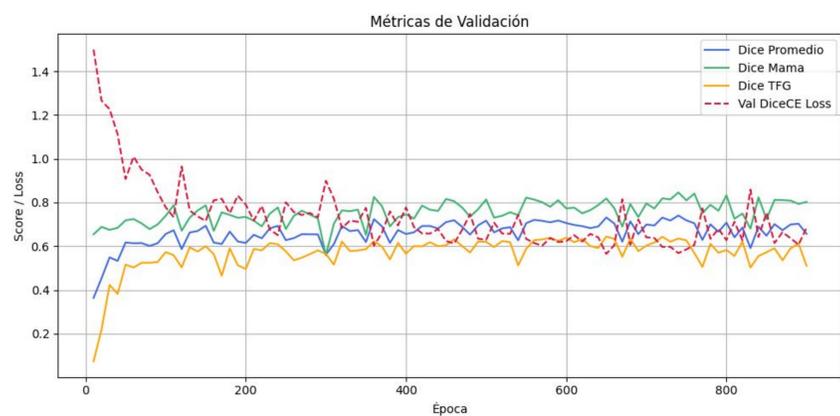


Figura 2: Gráfico resumen de las métricas obtenidas en el conjunto de validación. Se obtuvo en la mejor época un Dice Promedio de 0.7404, o 74%.

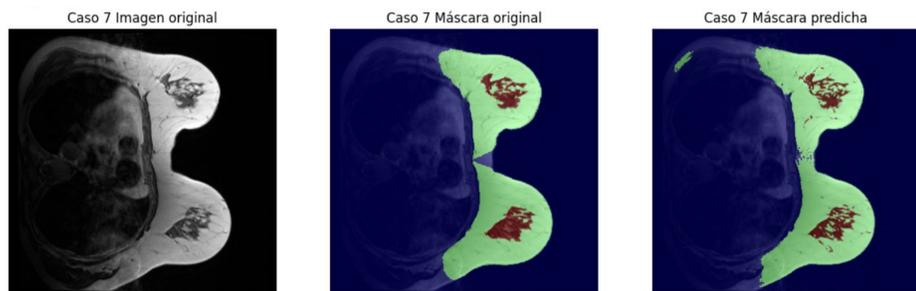


Figura 3: Etiquetado manual y predicción hecha por el mejor modelo en el estudio BMRI041, con un Dice de 0.9275 para el contorno mamario y 0.7445 para el tejido fibroglandular.

## REFERENCIAS

- [1] Gudhe NR, Behravan H, Sudah M, Okuma H, Vanninen R, Kosma VM, Mannermaa A. Area-based breast percentage density estimation in mammograms using weight-adaptive multitask learning. Sci Rep. 2022 Jul 14;12(1):12060. doi: 10.1038/s41598-022-16141-2.
- [2] Rice MS, Bertrand KA, VanderWeele TJ, et al. Mammographic density and breast cancer risk: a mediation analysis. Breast Cancer Res. 2016;18:94. doi: 10.1186/s13058-016-0750-0.
- [3] Wild CP, Weiderpass E, Stewart BW, editores. World Cancer Report: Cancer Research for Cancer Prevention. Lyon, France: International Agency for Research on Cancer; 2020. Disponible en: <http://publications.iarc.fr/586>.
- [4] Van der Velden, BHM, Janse, MHA, Ragusi, MAA, Loo, CE, Gilhuijs, KGA. Volumetric breast density estimation on MRI using explainable deep learning regression. Sci rep., 2020; 10(1), 18095. doi: 10.1038/s41598-020-75167-6
- [5] Pehlivan G, Wild CM, Baumgartl J, Hartmann D, Ditsch N, Kramer F, et al. Deep learning based automatic fibroglandular tissue segmentation in breast magnetic resonance imaging screening. Studies in Health Technology and Informatics. IOS Press; 2024. doi: 10.3233/SHTI240606.

## RESULTADOS Y DISCUSIÓN

### Evaluación de la estimación del %DM con el algoritmo de RM

Comparación del porcentaje de densidad mamaria entre los dos tipos de segmentación

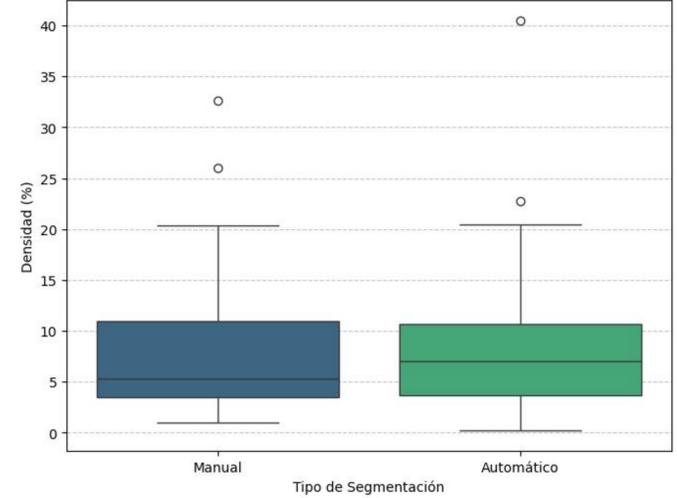


Figura 4: Gráfico de caja para comparar la diferencia entre la estimación del porcentaje de densidad mamaria con el etiquetado manual y automático.

Gráfico de Bland-Altman para el porcentaje de densidad mamaria entre los dos tipos de segmentación

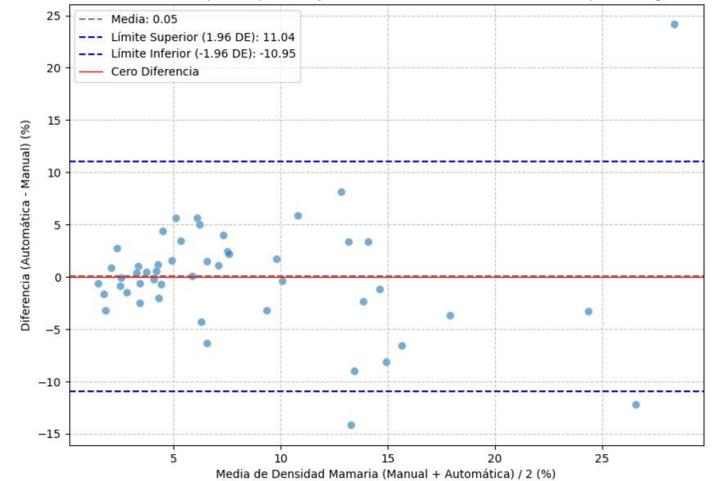


Figura 5: Gráfico de Bland-Altman para el porcentaje de densidad mamaria (%) entre el etiquetado manual y automático por el algoritmo de deep learning (DL)

### Trabajos futuros

- Validación del algoritmo con imágenes de RM del HCUCH.
- Relacionar estimación de la DM entre estudios de Mx, DBT y RM.

### Limitaciones del estudio

- Distribución del tejido fibroglandular mamario.
- Presencia de artefactos en regiones extramamarias.

### Propuestas de mejora

- Segmentación de mayor cantidad de clases.
- Segmentación de mayor cantidad de estudios.

## CONCLUSIÓN

El presente estudio expone el desarrollo de un algoritmo para la segmentación de tejido fibroglandular mamario y del tejido mamario en toda su extensión, basado en imágenes de resonancia magnética potenciadas en T1, ampliando su espectro de aplicación, a diferencia de los estudios de van der Velden et al. y Pehlivan et al.. Si bien su desempeño es óptimo para la mayoría de estudios, el rendimiento frente a mamas extremadamente densas otorga lugar para mejoras.

## AGRADECIMIENTOS

Estudios de resonancia magnética anonimizados extraídos gracias a la base de datos "The Cancer Imaging Archive" (TCIA) de la Universidad de Duke. Powered@NLHPC: Este trabajo fue parcialmente apoyada por la infraestructura de supercómputo del NLHPC (CCSS210001) Proyecto financiado por el fondo de investigación del Departamento de Tecnología Médica.

## DATOS DE CONTACTO

Vicente Cajas:

[vicente.cajas@ug.uchile.cl](mailto:vicente.cajas@ug.uchile.cl)

Sebastián Millar:

[sebastian.millar.t@ug.uchile.cl](mailto:sebastian.millar.t@ug.uchile.cl)