

Evaluación del bloque residual sobre la arquitectura U-Net para la segmentación de esqueletos de arterias coronarias

Juan Manuel Cuevas Gaytan ¹, Emmanuel Ovalle-Magallanes ^{2,*}

¹Universidad de Monterrey, Ingeniería y Tecnologías. juan.cuevasg@udem.edu

²Dirección de Investigación y Doctorado, Facultad de Ingenierías y Tecnologías, Universidad La Salle Bajío, Av. Universidad 602. Col. Lomas del Campestre, León, 37150, Guanajuato, México. *eovalle@lasallebajio.edu.mx

1. Objetivo

El objetivo de esta investigación fue implementar y comparar el rendimiento de las arquitecturas U-NET y ResU-Net en la segmentación de angiogramas de arterias coronarias, con el fin de generar imágenes esqueléticas de las arterias. Estas imágenes esqueléticas resaltan las estructuras esenciales de las arterias, simplificándolas a una representación de un solo píxel de grosor, lo que facilita su análisis y la identificación de posibles bloqueos o anomalías.

2. Métodos

2.1 Materiales

La codificación de los modelos U-net y Res-Unet se realizó completamente en Python, utilizando el framework PyTorch para la implementación de los modelos de Deep Learning. El entrenamiento de los modelos se llevó a cabo en un entorno de Google Colab, utilizando una GPU para acelerar el proceso.

El conjunto de datos empleado para el entrenamiento consta de 314 angiogramas obtenidos de 99 pacientes, que incluyen escaneos tanto de la arteria coronaria izquierda como de la derecha.

Dado que los datos etiquetados disponibles no eran muy útiles para generar el output deseado, aplicamos un proceso de esquelización a cada imagen segmentada en nuestro conjunto de datos. Para la esquelización, se utilizó el algoritmo de Zhang-Suen.

2.2 Arquitectura

En esta investigación se implementaron dos modelos: U-Net y ResU-Net. En la etapa de contracción de la U-Net, se realiza dos

convoluciones de 3x3, seguidas de una activación ReLU y una operación de max pooling. Para la etapa de expansión, también se emplea doble convolución, pero antes de cada convolución, se pasaba el tensor correspondiente de la parte de contracción, realizando la concatenación con el nivel equivalente.

En el caso de ResU-Net, se utilizó la misma estructura que en la U-Net. Sin embargo, se introdujo un cambio en la doble convolución. En lugar de realizar solo la doble convolución de 3x3, el input recibido se concatenaba directamente al resultado de las convoluciones antes de pasar por la activación ReLU.

2.3 Entrenamiento

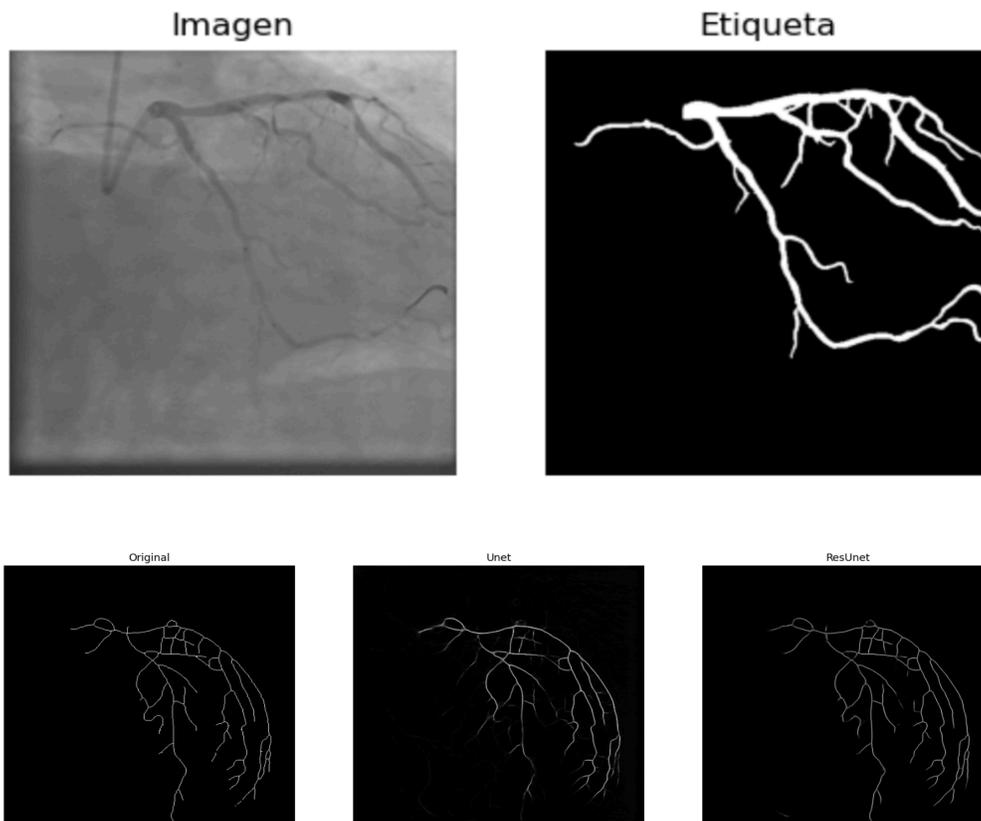
Ambos modelos fueron entrenados durante 25 épocas, utilizando el 80% de las imágenes para el entrenamiento, mientras que el 20% restante se dividió entre los conjuntos de prueba y validación. Se utilizó el optimizador Adam con una tasa de aprendizaje de 0.0001, con el objetivo de actualizar los pesos mediante el cálculo del gradiente, y la función de pérdida aplicada fue la Binary Cross Entropy Loss.

3. Resultados

La U-Net alcanzó una precisión final ligeramente mayor, con 0.9933 frente a 0.9926 de la ResU-Net, esta última superó a la U-Net en recall, obteniendo 0.5429 contra 0.3545. En cuanto al F1 score, la ResU-Net logró un valor de 0.5598, superando el 0.4635 de la U-Net. De igual manera, el Dice score de la ResU-Net fue superior, con 0.5581 frente a 0.4572. Sin embargo, la U-Net tuvo un mejor desempeño en precisión, con un valor de 0.6708 frente a 0.5773 para la ResU-Net.

En cuanto a las salidas de los modelos, la ResU-Net también se acercó más a la imagen original, proporcionando una segmentación más precisa

de las arterias coronarias, mientras que la U-Net mostró dificultades en las ramificaciones de las arterias.



4. Conclusiones

En este estudio, se compararon dos modelos de segmentación, U-Net y ResU-Net, para evaluar su desempeño en la segmentación de imágenes de arterias coronarias. Los resultados muestran que, en términos de pérdida de entrenamiento y validación, la ResU-Net supera a la U-Net, lo que puede atribuirse a la implementación de la doble convolución residual. Además, ninguno de los modelos muestra signos de sobreajuste, ya que tanto la pérdida de entrenamiento como la de validación disminuyen de manera consistente. La ResU-Net logró un mejor desempeño en todas las métricas con respecto a la U-Net. En términos de calidad de la segmentación, la ResU-Net mostró una mayor precisión en la identificación de las ramificaciones de la arteria coronaria,

mientras que la U-Net mostró limitaciones para detectar las estructuras finas de las arterias.

5. Referencias.

- Zhang, T. Y., & Suen, C. Y. (1984). A fast parallel algorithm for thinning digital patterns. *Communications of the ACM*, 27(3), 236-239.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. *Lecture Notes in Computer Science*(), vol 9351. Springer, Cham.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).