

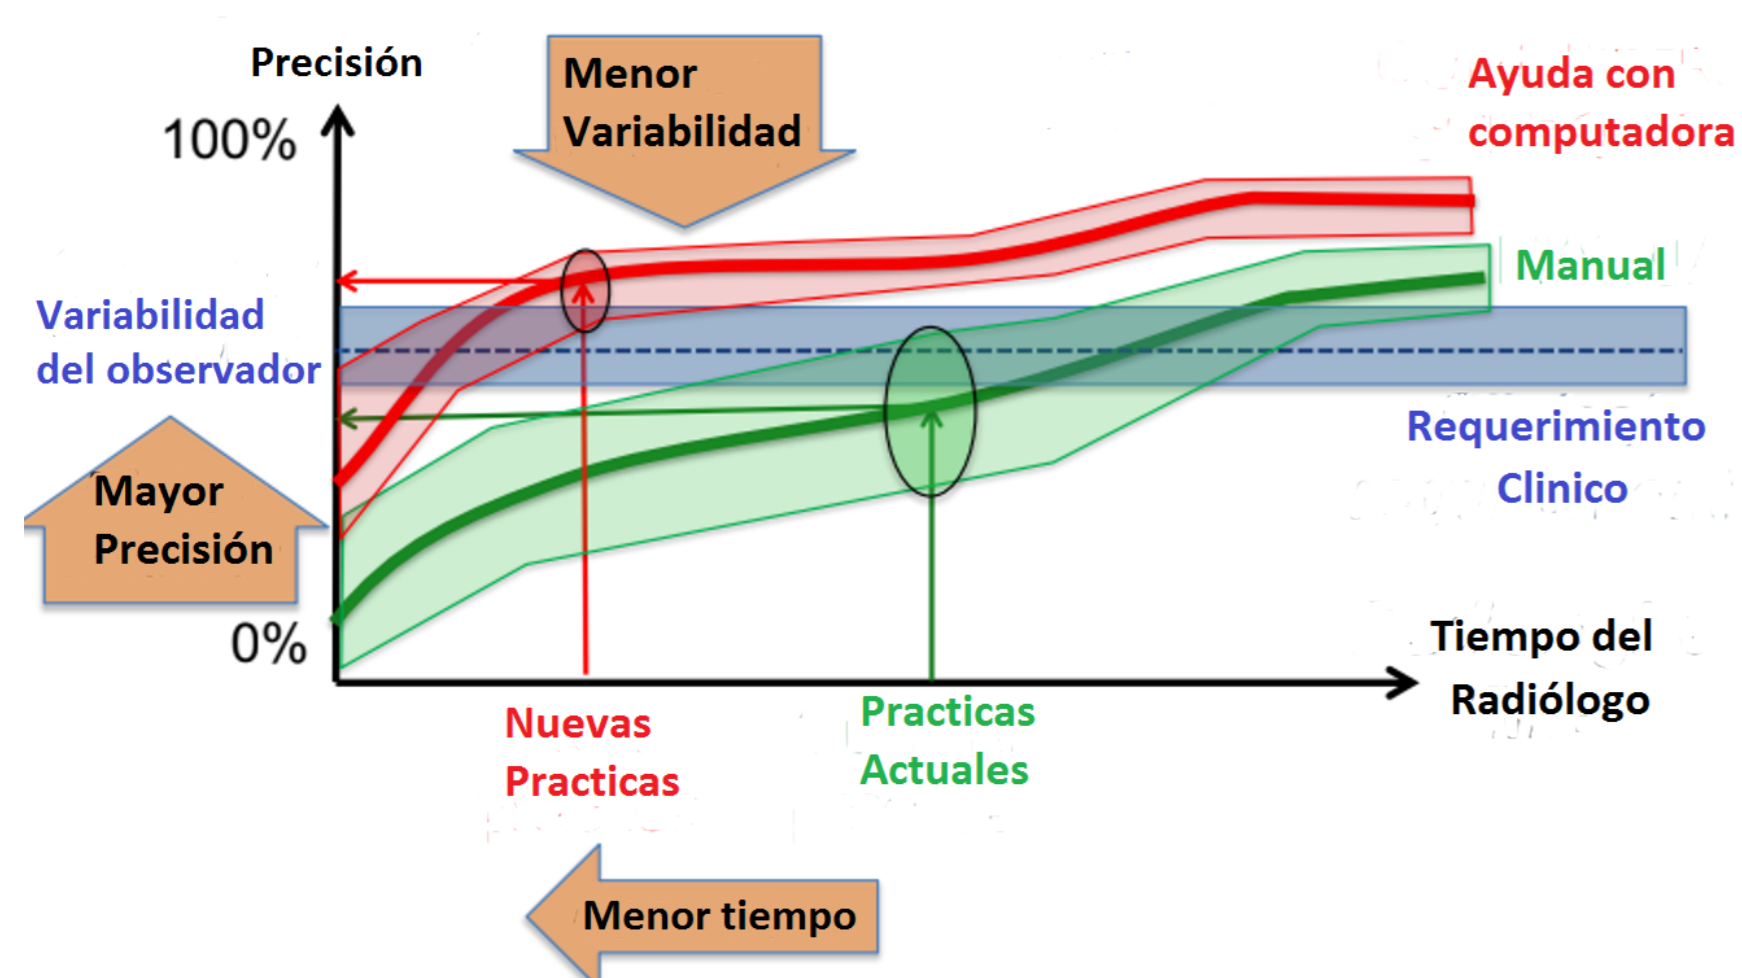


# Segmentación de Imágenes Médicas mediante UNET

Steve Avendaño<sup>1</sup>, Dra. Jimena Olveres<sup>2</sup>, Dr. Boris Escalante-Ramírez<sup>2</sup>,

<sup>1</sup>Facultad de Ciencias, UNAM; <sup>2</sup> Facultad de Ingeniería; <sup>3</sup>Centro Virtual de Computacion. UNAM CDMX.


En el área de las enfermedades cardiovasculares, estas constituyen la primera causa de enfermedad y muerte en el mundo occidental, con un continuo avance en los países en vías de desarrollo. El estudio del corazón y sus enfermedades, así como el desarrollo y uso de nuevas técnicas de automatización han incrementado su importancia debido a la gran cantidad de información e imágenes que se genera en el quehacer diario de la práctica clínica, siendo una de las tareas iniciales y de gran importancia la de la segmentación del corazón, la cual se ha realizado durante años utilizando diferentes técnicas de cómputo (automatizadas y semiautomatizadas), siendo apoyadas con métodos de aprendizaje de máquina. En este trabajo mostramos una aplicación con aprendizaje profundo, utilizando la red U-NET para llevar a cabo la segmentación en el volumen cardíaco, con la finalidad de lograr mejores resultados en estos procesos.



**Fig1.** Justificación: Se muestra de forma gráfica las ventajas que presenta la automatización de procesos repetitivos, particularmente en el área de imagenología médica [5]

## Selección de Modelo


Para la selección del modelo, se tomó en cuenta el trabajo llevado a cabo por Olaf et al. (2015) [3], el cual consiste en un proceso tipo encoder-decoder, en el cual parte de la información en el proceso de extracción de características se almacena y posteriormente se transfiere al proceso de recuperación de la información espacial.



**Fig2.** Arquitectura de la red: a) El diseño de esta arquitectura tiene la finalidad de extraer las características (features) principales que permitan diferenciar entre las distintas regiones anatómicas (encoder), así como disminuir la pérdida de la información espacial (localización) mediante un proceso de reconstrucción (decoder), lo que permite llevar a cabo una segmentación de las regiones anatómicas de interés [3]

## Conjunto de Datos


Las imágenes junto con sus etiquetas fueron tomadas de un set de datos de uso libre, que fue generado con el propósito de desarrollar algoritmos que permitan segmentar de forma automática el corazón. El set de datos consiste de imágenes 3D adquiridas por Resonancia Magnética Cardiovascular durante una práctica clínica en el Hospital de Niños de Boston, Boston, MA, USA. Los casos incluyen una variedad de enfermedades congénitas del corazón. Algunos de los pacientes han sido sometidos a intervenciones [6].



**Fig3.** Set de datos: El set de datos cuenta con los volúmenes de imágenes adquiridos de nueve pacientes.

## Imágenes y Etiquetas

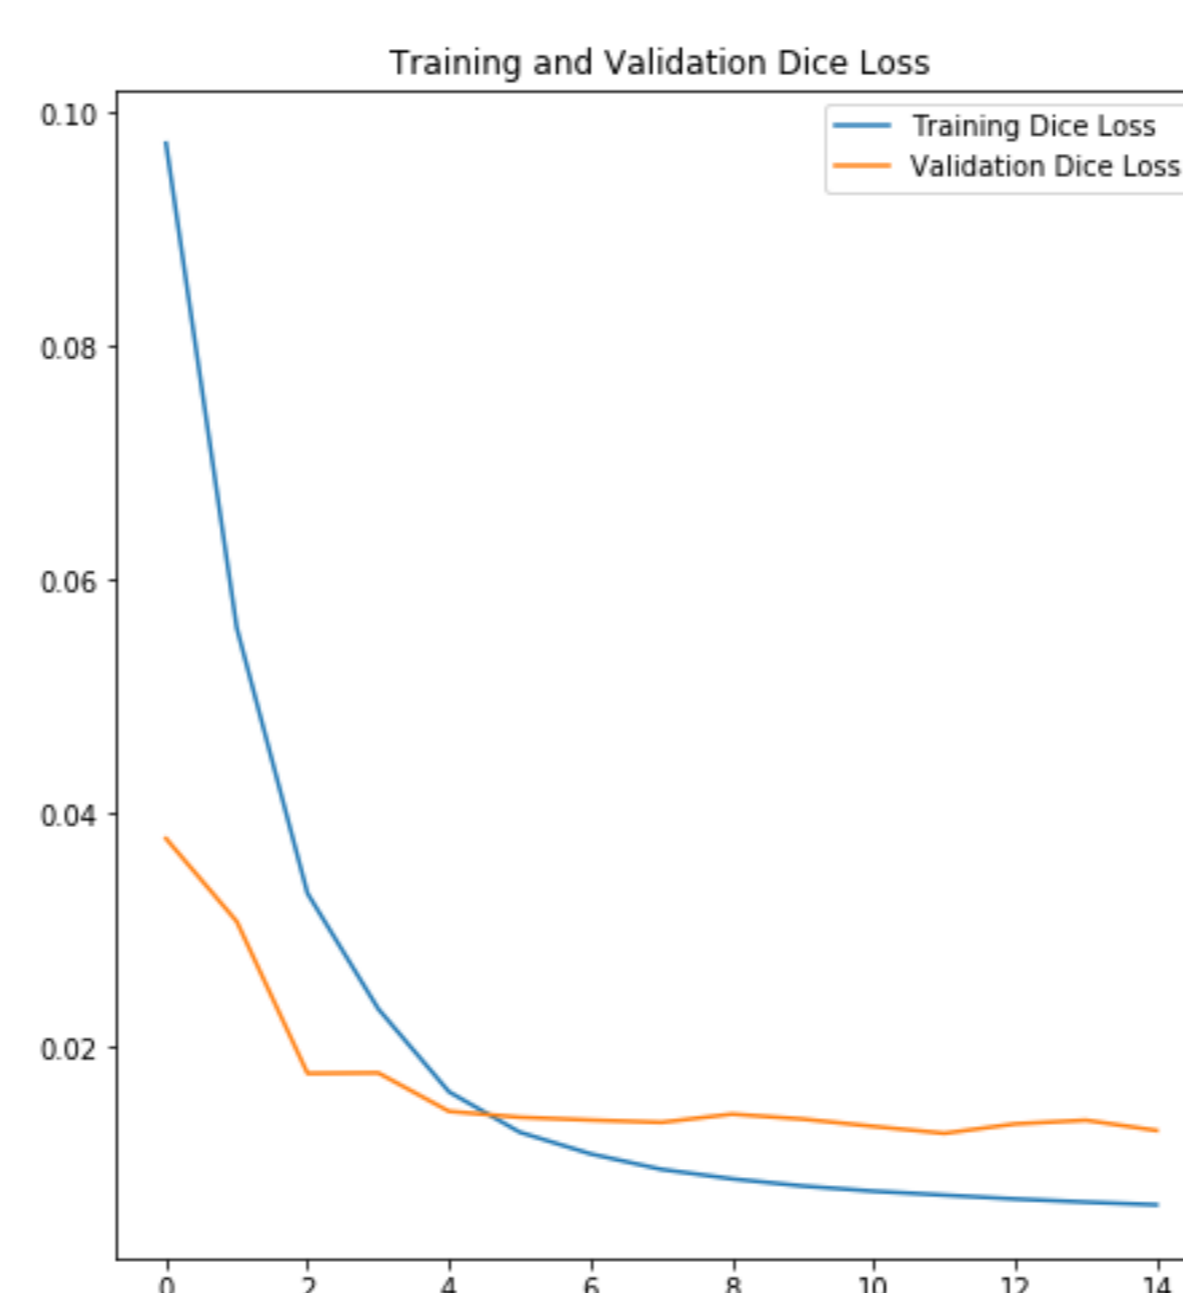
La segmentación manual de las cavidades ventriculares y las paredes del miocardio fue llevada a cabo por una persona entrenada y validada por dos clínicos expertos.



**Fig4.** Imagen y etiquetas: a) La clase a la que están asociados los volúmenes de sangre incluye los atrios izquierdo y derecho, los ventrículos izquierdo y derecho, aorta, venas pulmonares, arterias pulmonares y la vena cava superior e inferior. Los vasos sanguíneos (exceptuando la aorta) se extienden unos pocos centímetros fuera de su origen: esto pues vasos que son demasiado largos cuando la superficie 3D del corazón es empleada para la planeación de cirugías. b) La clase asociada al miocardio incluye la pared muscular que rodea los dos ventrículos y el septum que los separa.

## Algoritmo de entrenamiento


El Algoritmo de aprendizaje fue gradiente estocástico de descenso, tomando en cuenta el momento. Como función de coste se tomó la suma de la entropía categórica cruzada y el coeficiente de dice. El entrenamiento se llevó a cabo en una unidad de TPU, empleada en la plataforma de google colab. La evaluación del desempeño final en un set de prueba fue llevada a cabo empleando el coeficiente de dice, el cual resultó en un valor de error (pérdida) de 0.0388



**Fig5.** Visualización del entrenamiento: Se grafica la función de coste del set de validación (naranja) y del de entrenamiento (azul) en función de la época de entrenamiento

## Resultados del entrenamiento

Para poder comparar de forma cualitativa la máscara de segmentación que resulta del uso de nuestra red convolucional, se superponen la máscara original y la máscara obtenida, con una copia de la imagen del corazón como se muestra a continuación.



**Fig6.** Resultado de segmentación: Es esta imagen se muestra de manera cualitativa una comparación entre la segmentación de forma manual y automatizada. **Izquierda)** Se superpone la máscara de segmentación original sobre la imagen médica. **Derecha)** Se superpone la máscara que resulta de emplear la red convolucional desarrollada y se superpone sobre la imagen médica.

## Conclusión

Fue posible demostrar que la arquitectura U-NET presenta una buena opción para llevar a cabo la segmentación de imágenes médicas, sin embargo, este modelo también podría mejorar al modificar de manera adecuada los hiperparámetros presentes durante el proceso de entrenamiento o incluso recurriendo a herramientas como el aprendizaje transferido de redes convolucionales con un propósito más general, así como añadiendo capas que permitan refinar el proceso de segmentación (ej. modelos gráficos probabilísticos).

## Agradecimientos

Los autores agradecen el apoyo de los proyectos UNAM PAPIIT IA103119 y IN116917.

## Referencias

- [1] A. A. Novikov et al. Fully convolutional architectures for multi-class segmentation in chest radiographs. 2018.
- [2] Gray et al. Virusmapper: open-source nanoscale mapping of viral architecture through super-resolution microscopy. *Scientific reports*, 6:29132, 2016.
- [3] Olaf R. et al. U-net: Convolutional networks for biomedical image segmentation. 2015.
- [4] Aaron Courville Ian Goodfellow, Yoshua Bengio. *Deep Learning*. 2016.
- [5] Dr. Leo Joskowicz. Inteligencia artificial y radiología ¿qué se puede automatizar?.
- [6] T. Geva A.J. Powell M.H. Moghari P. Golland. • D.F. Pace, A.V. Dalca. Interactive whole-heart segmentation in congenital heart disease. *Lecture Notes in Computer Science*; 9351:80-88., 2015.