

## **Selección automática de cortes representativos para la segmentación asistida de volúmenes.**

González Lozano K.D., Arce Santana E.R. y Alba Cadena F.A.

Maestría en Ingeniería Electrónica, Facultad de Ciencias, UASLP.

### **Introducción:**

La segmentación de imágenes médicas es un área con diversas aplicaciones clínicas. Con el uso de redes neuronales convolucionales se han obtenido resultados satisfactorios, pero requieren de una gran cantidad de imágenes de entrenamiento.

Cuando hay pocos datos disponibles, surge la necesidad de nuevas técnicas. Recientemente, se ha trabajado con el entrenamiento de una red neuronal U-Net<sup>1</sup> por paciente, que consiste en elegir algunos cortes del volumen, segmentarlos manualmente y utilizarlos como datos de entrenamiento, para que la red sea capaz de segmentar los cortes restantes. Los resultados de esta técnica son prometedores, sin embargo, se ha observado la necesidad de definir un método de selección automática de los cortes que representan mejor a todo el volumen.

### **Objetivo:**

Diseñar una estrategia de selección automática de  $k$  cortes representativos de un volumen de imágenes de resonancia magnética para su uso en el entrenamiento de una U-Net individual.

### **Metodología:**

#### Estrategia de selección de cortes

Se diseñó una estrategia que consta de cuatro pasos principales:

- 1) Siendo  $L$  la longitud del volumen, el primer paso consiste en seleccionar  $k$  subvolúmenes distribuidos de manera uniforme, de  $c$  cortes cada grupo, cumpliendo con  $L/(k * c) \leq 15$ . Con la técnica de aumento de datos se producen  $600k$  imágenes, con las cuales se forman  $2k(600 - 1)$  pares de entrenamiento, mitad positivos (similares) y mitad negativos (diferentes), los cuales serán utilizados en el siguiente paso.
- 2) Entrenar una red neuronal siamesa<sup>2</sup>: Esta red aprende las características que hacen a dos imágenes similares o diferentes, consta de dos sub-redes convolucionales idénticas en paralelo. Cada sub-red recibe una imagen de entrada y da como resultado un vector de características en  $\mathbb{R}^n$ . Al final, se calcula la distancia euclidiana entre los vectores, generando a la salida un valor real que indica si las dos imágenes son similares o diferentes. El entrenamiento se realiza al minimizar una función de pérdida, aumentando la distancia entre dos muestras diferentes y disminuyéndola entre dos muestras similares.
- 3) Agrupación de cortes similares con k-medias: Con la red siamesa entrenada se genera el vector de características en el espacio  $\mathbb{R}^n$  para cada uno de los  $L$  cortes. Posteriormente, estos vectores que forman cúmulos son agrupados en  $k$  clases mediante el algoritmo de k-medias.
- 4) En cada grupo se calcula la muestra más cercana a la media, habiendo excluido las muestras atípicas mediante el método de Tukey. Finalmente, se obtienen  $k$  muestras que corresponden a  $k$  cortes representativos.

## Segmentación con U-Net

Los  $k$  cortes representativos con sus respectivas segmentaciones manuales (máscaras) se utilizan para entrenar la U-Net. Gracias al aumento de datos, a partir de los  $k$  cortes se generan 2000 imágenes de entrenamiento (10% para validación). La U-Net ajusta sus pesos al minimizar una función de pérdida, en este caso, la función se basa en el coeficiente de similitud DICE.

### **Resultados:**

#### Estrategia de selección de cortes

De un volumen de MRI cerebral con  $L = 145$  y  $k = 5$ , se seleccionaron 5 subvolúmenes de 3 cortes cada uno, y con el aumento de datos se generaron 5990 pares para entrenar la red siamesa, la tercera parte de los pares se utilizó como datos de validación. En la época 2 se logró el menor costo en el conjunto de validación, con un valor de  $0.1 \times 10^{-6}$  y una exactitud mayor al 99%, por lo que la red ha aprendido a identificar cuándo un par de cortes es similar o diferente.

Con la red entrenada se generaron los 145 vectores de características en el espacio  $\mathbb{R}^3$ , estos fueron agrupados en 5 clases con el método de  $k$ -medias. Por último, el método de Tukey ha permitido excluir las muestras atípicas y seleccionar los siguientes cortes representativos: 18, 46, 76, 115, 142.

#### Segmentación de la materia gris con U-Net

El entrenamiento de la U-Net se detuvo en la época 46, con DICE igual a 0.9212 en el conjunto de validación. Finalmente se realizó la prueba segmentando la materia gris en los 145 cortes del volumen, para los cuales se calculó el índice DICE individual (mayor a 0.8 para la mayoría de los cortes) y el índice DICE volumétrico (igual a 0.9269).

A pesar de que la U-Net ha sido entrenada solo con 5 cortes del volumen, con la información aprendida es capaz de segmentar la materia gris de los cortes restantes con un alto valor de similitud. Los pequeños errores en los cortes del inicio y del final se deben a que la cantidad de materia gris es mínima y se confunde con otras estructuras. El número de cortes con los que fue entrenada la U-Net representa el 3.44% del total del volumen.

### **Conclusión:**

La estrategia presentada en este trabajo es una prueba de concepto que nos indica que es posible seleccionar de manera automática los cortes representativos de un volumen y determinar a cuáles cortes representa cada uno, utilizando técnicas de aprendizaje profundo y agrupamiento de datos.

Al utilizar esta estrategia de selección automática de cortes representativos no es necesario observar a detalle las imágenes del volumen para saber con cuáles entrenar la U-Net. Este es un punto de partida que permitirá la exploración de las redes neuronales para separar un conjunto de imágenes en cierto número de grupos, imágenes de las cuales no se tiene información previa.

### **Referencias:**

[1] Ronneberger et al. (2015). U-net: Convolutional networks for biomedical image segmentation. *Lecture Notes in Computer Science*, 9351, 234–241.

[2] Bromley et al. (1993). Signature verification using a “siamese” time delay neural network. *International Journal of Pattern Recognition and Artificial Intelligence*, 7(04), 669-688.