

# Segmentación de Ecografías de la Arteria Carótida Común mediante Reconocimiento de Patrones con Perceptrones Multicapa

Rosa María Menchón Lara, José Luis Sancho Gómez, María Consuelo Bastida Jumilla,  
Juan Morales Sánchez, Jorge Larrey Ruiz.  
Grupo de Teoría y Tratamiento de Señal.  
Departamento de Tecnologías de la Información y las Comunicaciones.  
Universidad Politécnica de Cartagena. Plaza del Hospital, N° 1, 30202 Cartagena (Murcia)  
E-mail: rmml@alu.upct.es

**Resumen.** La arteriosclerosis es una enfermedad cardiovascular muy común que, a largo plazo, puede tener graves consecuencias. Un indicador precoz de esta patología es el grosor íntima-media (IMT). Normalmente, el IMT se mide de forma manual, en unos pocos puntos, sobre ecografías de la arteria carótida común. Mediante técnicas de segmentación de imagen es posible detectar y medir este parámetro en toda la imagen, proporcionando una información más completa al doctor. También es deseable que este proceso sea independiente del usuario, eliminando la subjetividad de la medida. En este artículo se presenta un efectivo método de segmentación que permite detectar y extraer de forma automática el IMT. La tarea se plantea como un problema de clasificación binaria y un conjunto de Perceptrones Multicapa es entrenado para resolverla de forma satisfactoria. Los resultados obtenidos al testear este sistema demuestran su validez para resolver el problema planteado.

## 1. Introducción

Las enfermedades cardiovasculares se encuentran entre las principales causas de mortalidad del mundo desarrollado. Una afección muy común entre la población adulta es la *arteriosclerosis*. Esta patología se caracteriza por la acumulación de placas de ateroma en las paredes arteriales, lo que produce un engrosamiento y reducción de la elasticidad de las mismas. Puede evolucionar a una oclusión total de los vasos sanguíneos, desencadenando problemas severos como infartos, embolias o isquemias. De ahí que resulte crucial diagnosticar y tratar la arteriosclerosis cuando la enfermedad aún se encuentre en su fase incipiente. Un indicador precoz y fiable de esta afección cardiovascular es el *grosor íntima-media* (IMT) de la *arteria carótida común* (CCA) [1].

El IMT se mide sobre *ecografías en modo B* de la carótida. Esta modalidad de imagen médica presenta ciertas ventajas que la hacen muy adecuada para la realización de estudios clínicos. Se trata de una técnica no invasiva, prácticamente inocua (ya que no utiliza radiaciones ionizantes) y relativamente barata. Sin embargo, la resolución y el contraste de estas imágenes es, por lo general, muy pobre.

El IMT es la distancia entre las interfaces I5 e I7 (ver Fig. 1), correspondientes a las separaciones entre lumen-íntima e íntima-adventicia. Es necesario asegurar la repetibilidad y reproducibilidad de la medición del IMT, por lo que es importante unificar el protocolo de medida [2]. Normalmente, el especialista realiza la medida del IMT manualmente, marcando puntos sobre la imagen, por lo que el proceso está asociado a una cierta subjetividad.

Con el objetivo de mejorar el proceso de medida del

IMT, se ha propuesto la aplicación de diferentes técnicas de procesado de imagen. Mediante algoritmos de segmentación de imagen, es posible detectar las interfaces I5 e I7 en toda la imagen, permitiendo medir el IMT no sólo en unos pocos puntos. En este trabajo se presenta una técnica de segmentación mediante *redes neuronales* para extraer y medir el IMT de forma automática.

## 2. Método Propuesto

El objetivo principal de este trabajo es desarrollar una técnica de segmentación de imagen, precisa y automática, que permita obtener el IMT. La segmentación es una tarea fundamental dentro del procesado de imagen que subdivide una imagen en las regiones que la constituyen. Esto implica realizar una clasificación de los píxeles de la imagen, por lo que se puede plantear como un problema de reconocimiento de patrones [3]. Siguiendo esta idea, proponemos un método para segmentar ecografías de la CCA basado en la utilización de *Perceptrones Multicapa* (MLPs). Ante una imagen de entrada, nuestro sistema deberá clasificar sus píxeles en dos clases: por un lado, los pertenecientes a las interfaces I5 e I7 (*'IMT-boundary'*) y, por otro lado, el resto de píxeles (*'non-IMT-boundary'*), que no pertenecen a la región de interés.




Figura 1. Vista longitudinal de la CCA en una ecografía.

## 2.1. Configuración de los MLPs

Los MLPs usados en este trabajo constan de una única capa oculta y son entrenados bajo la regla de aprendizaje *Back-Propagation* (BP). Existen variaciones del método estándar más rápidas y eficientes basadas en otras técnicas de optimización. En nuestro caso, hemos utilizado el algoritmo de *gradiente conjugado escalado* (SCG).

La información de entrada al MLP se compone de los valores de intensidad de los píxeles vecinos del píxel a clasificar. De esta forma, para construir los patrones de entrada a la red, se lleva a cabo un proceso de enventanado desplazando una ventana cuadrada ( $W \times W$ ) píxel a píxel sobre la imagen original. Para cada patrón de entrada, la red proporciona una única componente de salida, correspondiente a la salida deseada (o *target*) asociada al píxel central de la ventana de entrada.

Puesto que el SCG es una técnica de aprendizaje supervisado, requiere un conjunto de datos etiquetados para el entrenamiento. En nuestro caso, las imágenes fueron etiquetadas de forma manual. De este proceso resultan imágenes target binarias, donde los píxeles con valor '1' representan la clase '*IMT-boundary*' y los píxeles con valor '0' la clase '*non-IMT-boundary*'.

Todas las ecografías usadas en este estudio fueron obtenidas con un ecógrafo *Philips iU22 Ultrasound System* y almacenadas en formato *DICOM*. A la hora de reunir el conjunto de datos, resulta inapropiado utilizar todos los píxeles de una imagen, pues esto conduciría a un número de muestras extremadamente grande. Además, los píxeles de la clase '*IMT-boundary*' representan una fracción mínima dentro de una imagen, por lo que tendríamos un conjunto altamente desbalanceado. En nuestro caso, hemos empleado muestras de tres imágenes diferentes para construir el conjunto de datos, que incluye 6000 patrones: 41.7% de clase '*IMT-boundary*' y 58.3% de clase '*non-IMT-boundary*'.

Los métodos de descenso por gradiente son sensibles a la inicialización [4], por lo que los MLPs fueron reentrenados 20 veces. El número óptimo de neuronas ocultas se ha determinado mediante un proceso de validación cruzada.

## 2.2. Selección manual de características

En este trabajo, analizamos diferentes tamaños de ventana. En concreto, consideramos  $W = 3, 5, 7$  y  $9$ ; por tanto, patrones de entrada con 9, 25, 49 y 81 componentes, respectivamente. El uso de un conjunto de datos relativamente grande y la alta dimensionalidad del espacio de características conducen a una etapa de entrenamiento muy lenta. A fin de solventar este problema, asignamos un número fijo de 9 características de entrada para todas las ventanas consideradas. La Fig. 2 muestra la selección manual de características de entrada realizada, donde los cuadrados grises representan los píxeles seleccionados en cada caso.




Figura 2. Características de entrada seleccionadas para cada MLP.

## 2.3. Comité de expertos

Los problemas de clasificación complejos requieren la contribución de varias redes neuronales para lograr una solución óptima [3]. Esto se traduce en que la tarea de aprendizaje sea compartida entre un número de *expertos*. La combinación de estos expertos constituye una *comité de redes neuronales*.

En el campo del procesado de imagen, se pueden encontrar resultados que demuestran que la precisión en la clasificación proporcionada por un comité supera la precisión de la mejor red en solitario [5].

Con el propósito de mejorar la precisión y robustez del método de segmentación propuesto, planteamos el uso de un comité de expertos como el de la Fig. 3. De esta forma, los resultados de cuatro expertos son combinados mediante una '*meta*' red neuronal. El proceso de entrenamiento de la meta red es similar al de los cuatro expertos. A cada experto se le asocia a un tamaño de ventana diferente, de los cuatro considerados, asumiendo la selección manual de características de entrada detallada en 2.2.

Para construir el conjunto de datos de la meta red, las tres imágenes consideradas anteriormente se presentan, de forma completa, a los cuatro expertos. Una vez obtenidas las imágenes de salida para cada experto, se lleva a cabo un nuevo proceso de enventanado sobre las mismas, en este caso con una ventana  $3 \times 3$ . Así, los patrones de entrada a la meta red cuentan con 36 componentes. Finalmente, para el meta conjunto de datos se seleccionan las muestras correspondientes a los mismos píxeles considerados para los conjuntos de datos de los expertos.

## 3. Resultados

Una vez completada la etapa de entrenamiento de las diferentes redes que componen el esquema propuesto y después de analizar el rendimiento de las mismas, estamos en disposición de evaluar la respuesta del método propuesto ante nuevas imágenes.

En la Fig. 4 vemos un ejemplo imagen segmentada a la salida del comité. Se puede observar que los píxeles adyacentes a las interfaces I5 e I7 resultan ser




Figura 3. Configuración del comité de expertos propuesto.






Figura 4. Imagen de entrada (izquierda) e imagen segmentada a la salida del comité de expertos (derecha).

especialmente conflictivos. Aunque la imagen target sugiere que esos píxeles se deben clasificar como ‘non-IMT-boundary’, la baja resolución y el proceso de etiquetado manual llevan a detectar un borde grueso en lugar de un contorno de un píxel.

Una vez que la imagen segmentada se obtiene a la salida del comité de expertos, es necesaria una etapa de depuración de resultados. En esta etapa de post-procesado, se aplican técnicas de morfología matemática para extraer los componentes conectados, rellenar huecos, eliminar impurezas o píxeles mal clasificados y refinar los contornos (ver Fig. 5).

Sobre los resultados de esta etapa se mide el IMT (en milímetros) a lo largo de la imagen, calculando el valor medio. Los valores obtenidos pueden ser comparados con los valores de referencia, calculados sobre las imágenes target (véase la Tabla 1).

## 4. Conclusiones

En este artículo se presenta un método de segmentación de las paredes de la arteria carótida a fin de medir el IMT automáticamente sobre imágenes ecográficas. Esta tarea se plantea como un problema de reconocimiento de patrones en el que un MLP debe realizar una clasificación binaria de los píxeles de la imagen para encontrar las interfaces que definen el IMT.

Los patrones de entrada a la red se componen de valores de intensidad de píxeles vecinos al píxel a clasificar. Para ello, se lleva a cabo un proceso de enventanado considerando diferentes tamaños para la




Figura 5. Detalle del resultado final obtenido (tras la etapa de depuración) para tres imágenes diferentes.

Tabla 1. Valores medios del IMT (mm) a lo largo de la imagen.

	IMT obtenido	IMT referencia	Error Relativo
Fig. 5 (a)	0.491	0.509	3.5 %
Fig. 5 (b)	0.454	0.491	7.5 %
Fig. 5 (c)	0.553	0.529	4.5 %

ventana deslizante y aplicando una selección de las características de entrada. Buscando mejorar la precisión de la clasificación, se propone utilizar un comité de expertos. Concretamente, los resultados de cuatro expertos son combinados mediante una meta-red neuronal.

El sistema propuesto produce errores de clasificación en aquellas regiones en las que se aprecia un patrón oscuro-claro-oscuro en los valores de intensidad similar al que caracteriza al contorno del IMT. Por esta razón, se diseña una etapa de post-procesado para depurar los resultados. Tras ésta, se puede medir el IMT y compararlo con el resultado esperado.

En vista de los resultados obtenidos, que han resultado ser satisfactorios, queda demostrada la validez del método. De entre las ventajas del enfoque propuesto, destacamos que el proceso de medida del IMT es independiente del observador. Futuros trabajos se podrían centrar en la búsqueda de características que permitan reducir los errores de clasificación y, por tanto, facilitar el proceso de medida del IMT.

## Agradecimientos

Este trabajo está financiado por el Ministerio de Ciencia e Innovación a través del proyecto TEC2009-12675. Las imágenes utilizadas han sido proporcionadas por el Departamento de Radiología del Hospital Universitario Virgen de la Arrixaca.

## Referencias

- [1] Loizou, C. et al. (2009) “Ultrasound image texture analysis of the intima and media layers of the common carotid artery and its correlation with age and gender”. *Computerized Medical Imaging and Graphics*, pp. 317-324, vol. 33(4).
- [2] Velázquez, F. et al. (2008) “Reproducibility of sonographic measurements of carotid intima-media thickness”. *Acta Radiológica*, pp. 1162-1166, vol. 49(10).
- [3] Meyer-Base, A. (2004) *Pattern Recognition for Medical Imaging*. Academic Press.
- [4] Haykin, S. (1999) *Neural Networks: A Comprehensive Foundation*. Prentice Hall.
- [5] Giacinto, G., Roli, F. (2001) “Desing of effective neural network ensembles for image classification purposes”. *Image and Vision Computing*, pp. 699-707, vol. 19(9-10).