

Aprendizaje Máquina aplicado a la Evaluación Automática del Grosor Íntima-Media Carotídeo en Imágenes de Ultrasonido

Rosa María Menchón Lara, María Consuelo Bastida Jumilla, Álvaro Ginés Legaz Aparicio,
José Luis Sancho Gómez, Jorge Larrey Ruiz.

Grupo de Teoría y Tratamiento de Señal (GTTS).

Departamento de Tecnologías de la Información y las Comunicaciones.

Universidad Politécnica de Cartagena. Plaza del Hospital, Nº 1, 30202 Cartagena (Murcia).

Teléfono: 968326542

E-mail: rmm1@alu.upct.es

Resumen. *Un diagnóstico precoz de la aterosclerosis junto con el seguimiento y tratamiento de esta patología resultan cruciales en la evaluación del riesgo cardiovascular y la prevención de enfermedades más graves, como infartos o apoplejías. El grosor íntima-media de la arteria carótida común es un indicador precoz de la aterosclerosis. La técnica de diagnóstico utilizada para evaluar el grosor íntima-media carotídeo es el ultrasonido, mediante ecografías de alta resolución en modo-B. Es común medir este parámetro de forma manual, con lo que se le asocia el error propio de la subjetividad del observador. En este trabajo proponemos, como ayuda al diagnóstico precoz de la aterosclerosis, un método de segmentación de imagen completamente automático basado en técnicas de Aprendizaje Máquina para la evaluación del grosor-íntima media de la arteria carótida común.*

1. Introducción

Según las estadísticas de la Organización Mundial de la Salud [1], las *enfermedades cardiovasculares* representan la principal causa de muerte y discapacidad en el mundo. Este término engloba a las enfermedades cardíacas, accidentes cerebrovasculares y enfermedades de los vasos sanguíneos.

La patología subyacente común a este grupo de enfermedades es la *aterosclerosis*. Se trata de un proceso degenerativo crónico, muy frecuente entre la población adulta, que afecta principalmente a las arterias de mediano y gran calibre. La aterosclerosis se caracteriza por la acumulación de colesterol y materia grasa en la capa más interna de las paredes arteriales. Estos depósitos (placas de ateroma) provocan el engrosamiento y endurecimiento de los vasos sanguíneos afectados.

El proceso aterosclerótico se inicia en la niñez, siendo su largo periodo de inducción lo que hace que resulte idóneo para el estudio de la enfermedad subclínica con fines preventivos. En este sentido, el *grosor íntima-media* (GIM) de la *arteria carótida común* (ACC) se considera un marcador precoz y fiable de la aterosclerosis e indicador del riesgo cardiovascular [2].

El GIM se mide mediante ecografías de alta resolución en modo-B de la ACC, una técnica no invasiva y relativamente barata. La Fig. 1 muestra una vista longitudinal de la ACC en una imagen de ultrasonido. En la pared posterior (distal) del vaso, se puede observar el patrón característico brillante-oscuro-brillante correspondiente a las capas íntima-media-adventicia de la pared arterial. El GIM es la distancia entre la interfaz lumen-intima (LI) y la interfaz media-adventicia (MA).

En nuestro caso, nos centramos en el protocolo de medida usado por el Dpto. de Radiología del Hospital Universitario Virgen de la Arrixaca [3], de acuerdo con el cual, el GIM debe ser evaluado en la pared posterior del vaso, en una sección de 1 cm a partir de la bifurcación carotídea. El especialista mide el GIM de forma manual, marcando pares de puntos sobre la imagen y tomando el mayor valor de tres medidas.

Con el propósito de hacer más eficiente y rápido el proceso de evaluación del GIM y de reducir la subjetividad de la medida manual, se han propuesto diferentes técnicas de procesado de imagen. Además, mediante algoritmos de segmentación de imagen es posible analizar el GIM en toda la imagen, no sólo en unos pocos puntos, permitiendo la extracción de estadísticos de interés para los facultativos.

En las últimas dos décadas, se han publicado numerosas soluciones para la segmentación de las paredes carotídeas en imágenes de ultrasonidos. Una revisión bastante completa del estado del arte se puede encontrar en [4]. La mayoría de los métodos requieren la intervención del usuario para inicializar el algoritmo o validar los resultados.

En este trabajo, proponemos una técnica de segmentación completamente automática basada en técnicas de *Aprendizaje Máquina* aplicada a imágenes ecográficas de la ACC. Más concretamente, planteamos el uso de redes neuronales artificiales (RNA) para reconocer los patrones de intensidad característicos y realizar una clasificación de los píxeles de la imagen. De esta forma, se detectan las interfaces LI y MA, sobre las que se evalúa el GIM. El carácter automático de la medida mejora la reproducibilidad de la misma y evita la variabilidad entre observadores propia de la medición manual.

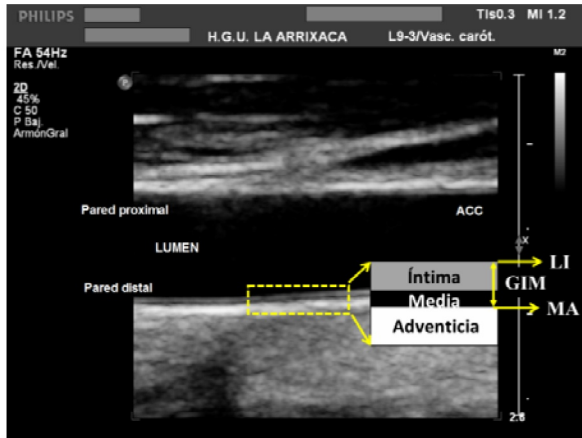


Fig. 1. Vista longitudinal de la ACC en una imagen ecográfica y definición del grosor íntima-media.

2. Metodología

La Fig. 2 muestra un diagrama del método automático propuesto en este artículo para la evaluación del GIM carotídeo. Como se puede ver, consta de tres etapas: (i) pre-procesado de la imagen para detectar la región de interés (ROI); (ii) segmentación de la pared posterior de la carótida mediante técnicas de Aprendizaje Máquina; (iii) post-procesado para el depurado de los resultados de clasificación y extracción de los contornos correspondientes a las interfaces LI y MA para proceder a la evaluación del GIM.

A continuación, se describen con más detalle cada una de estas etapas.

2.1. Pre-procesado

Esta etapa inicial, previa a la segmentación, tiene como objetivo la localización de la ROI y el recorte automático de la imagen. Con este propósito, se lleva a cabo la detección automática del lumen. En las imágenes de ultrasonido de la ACC (véase la Fig. 1), el lumen se corresponde con un área oscura delimitada por las paredes arteriales. La pared posterior (distal), donde se mide el GIM, se localiza bajo el lumen y constituye nuestra ROI.

El primer paso consiste en construir una máscara binaria como la de la Fig. 3 aplicando técnicas de Morfología Matemática [5]. El área negra de mayor tamaño identifica al lumen de la ACC en la imagen.

Una vez localizado el lumen, nos centramos en su límite inferior y realizamos una aproximación lineal de éste. Para evitar errores cuando la arteria presente cierta curvatura, esta aproximación se realiza a tramos. Las pendientes de las rectas proporcionan una estimación de la orientación de la pared posterior de la carótida. A continuación, se establecen los límites de la ROI. Concretamente, 0.6 mm por encima del punto más alto de la pared y 1.5 mm por debajo del punto más bajo. De esta forma, el tamaño de la ROI estará relacionado con la apariencia de la arteria (inclinación y curvatura) en la imagen.

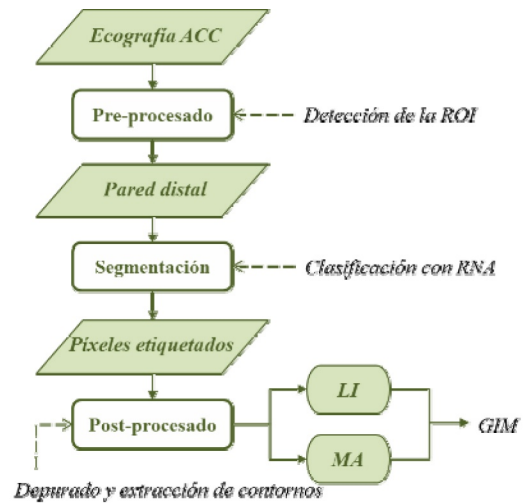


Fig. 2. Diagrama del método de segmentación propuesto.




Fig. 3. Etapa de pre-procesado: Máscara binaria calculada para la ecografía de la Fig. 1 y ROI seleccionada.

2.2. Segmentación

La segmentación es una tarea fundamental y una de las más complicadas del procesamiento de imagen. Su cometido es dividir una imagen en las regiones u objetos que la constituyen. En nuestro caso, la segmentación se plantea como un problema de reconocimiento de patrones. Los contornos del GIM en una ecografía de la ACC son extraídos clasificando sus píxeles con redes neuronales artificiales (RNA). En concreto, utilizamos *Single-Layer Feed-Forward Networks* (SLFN) diseñadas y entrenadas mediante el algoritmo *Optimally Pruned-Extreme Learning Machine* (OP-ELM) [6].

Las redes toman como única información de entrada los valores de intensidad de un determinado vecindario del píxel a clasificar. En este caso, hemos considerado un vecindario en cruz orientado según la aproximación de la pared carotídea obtenida en la etapa previa. Por tanto, se lleva a cabo un doble proceso de enventanado, en el que una ventana perpendicular a la pared arterial (31 píxeles) y otra paralela (11 píxeles), ambas centradas en el píxel a clasificar, se desplazan píxel a píxel sobre la ROI.

La SLFN debe reconocer los píxeles pertenecientes a la interfaz LI (clase '00') y los píxeles de la interfaz MA (clase '11'). Además, la red discrimina entre los píxeles no pertenecientes a los contornos del GIM. Por un lado, aquellos localizados entre ambas interfaces (clase '01'); y por otro lado, el resto de píxeles (clase '10').

Para llevar a cabo el entrenamiento supervisado de las redes, construimos un conjunto de datos etiquetado tomando muestras de diferentes ecografías segmentadas manualmente. El 80% de las muestras se utilizan para el entrenamiento y el 20% para test.

2.3. Post-procesado

Los resultados de la etapa de clasificación deben ser depurados para extraer los contornos finales de las interfaces LI y MA. Es necesario identificar y descartar, en la medida de lo posible, los píxeles mal clasificados. Con este objetivo, la imagen es procesada por columnas, buscando las salidas fiables de la etapa de clasificación. Así, de acuerdo con las etiquetas asociadas a cada píxel, sólo las transiciones '10'-'00'-'01'-'11'-'10' serán consideradas correctas en una columna dada.

Una vez depurados los resultados de clasificación, formulamos un problema de ajuste no lineal de datos para encontrar la mejor aproximación polinómica de cada interfaz. Los contornos finales se obtienen minimizando el error cuadrático entre la posición de los píxeles clasificados como '00' (LI), o como '11' (MA) y el contorno aproximado correspondiente.

3. Resultados

La Fig. 4 muestra los resultados obtenidos al aplicar el método de segmentación propuesto sobre ecografías de la ACC de cuatro pacientes diferentes. Además, la Tabla 1 recoge las correspondientes medidas del GIM (valor medio para cada imagen) y se comparan con las medidas realizadas manualmente por dos especialistas.

4. Conclusiones

Este artículo propone un procesado de imágenes ecográficas de la ACC basado en Aprendizaje Máquina, con el fin de segmentar la pared posterior (distal) de la arteria y medir el GIM de forma precisa y completamente automática.

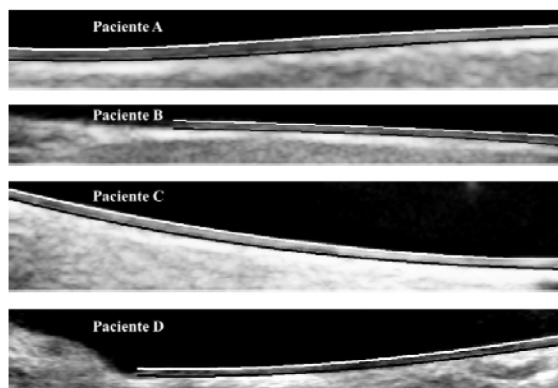


Fig. 4. Ejemplos de segmentación con el método propuesto.

Tabla 1. Medidas automáticas y manuales (dos expertos) del GIM para las ecografías de ejemplo de la Fig. 4.

Paciente	Resolución (mm/píxel)	GIM (mm) automático	GIM (mm) manual 1	GIM (mm) manual 2
A	0.033	0.451	0.461	0.445
B	0.039	0.427	0.437	0.431
C	0.050	0.571	0.608	0.608
D	0.065	0.551	0.577	0.581

Nuestro enfoque plantea la tarea de segmentación como un problema de reconocimiento de patrones. Proponemos una etapa de clasificación de píxeles mediante RNA para encontrar los contornos del GIM, es decir, las interfaces LI y MA. El método propuesto se completa con una etapa de pre-procesado, en la que la ROI es detectada de forma automática, y con una etapa de post-procesado que se encarga de la extracción de los contornos finales a partir de los resultados de la etapa de clasificación.

Actualmente, los autores están trabajando en el proceso de validación del método propuesto. Trabajos futuros se podrían centrar en el uso de otro tipo de clasificadores y técnicas de selección de características. También sería interesante adaptar nuestro método a la detección de la pared proximal de la carótida para evaluar el diámetro de la arteria, otro parámetro de interés para los facultativos.

Agradecimientos

Este trabajo está financiado por el Ministerio de Ciencia e Innovación a través del proyecto TEC2009-12675. El Hospital Universitario Virgen de la Arrixaca ha proporcionado las imágenes utilizadas.

Referencias

- [1] World Health Organization: http://www.who.int/cardiovascular_diseases/en/.
- [2] Touboul, P.J. et al. (2012) Mannheim carotid intima-media thickness and plaque consensus (2004-2006-2011). *Cerebrovasc. Dis.*, 34, 290-296.
- [3] Velázquez, F. et al. (2008) Reproducibility of sonographic measurements of carotid intima-media thickness. *Acta Radiológica*, 49(10), 1162-1166.
- [4] Molinari, F., Zeng, G., Suri, J.S. (2010) Review: A state of the art review on intima-media thickness (IMT) measurement and wall segmentation techniques for carotid ultrasound. *Comput. Methods Prog. Biomed.*, 100, 201-221.
- [5] González, R.C. et al. (2004) *Digital Image Processing using Matlab*. Pentice Hall.
- [6] Miche, Y. et al. (2010) OP-ELM: Optimally Pruned Extreme Learning Machine. *Neural Networks, IEEE Transactions on*, 21(1), 158-162.