

Redes Neuronales Artificiales En La Predicción De La Vulnerabilidad De La Placa De Ateroma

Ricardo Caballero¹, Miguel Ángel Martínez^{1,2}, Estefanía Peña^{1,2}

¹Applied Mechanics and Bioengineering, Aragón Institute of Engineering Research (I3A).
Universidad de Zaragoza, Mariano Esquillor s/n, 50018, Zaragoza, Spain.

²Biomedical Research Networking Center in Bioengineering, Biomaterials and Nanomedicine (CIBER-BNN), Spain
Tel. +34-976762707, e-mail: rcaballero@unizar.es

Resumen

La predicción de la vulnerabilidad de la placa de ateroma mediante redes neuronales permite dar una respuesta rápida para paciente específico en la práctica clínica. Para realizar dicha predicción se ha desarrollado una red neuronal artificial (RNA) que toma como datos de entrada las deformaciones de la arteria coronaria aterosclerótica y da como resultado las propiedades mecánicas de la misma. Éstas se han utilizado para determinar las tensiones presentes en la capa fibrótica y, en última instancia, si la placa es o no vulnerable.

Introducción

Las enfermedades cardiovasculares son la primera causa de muerte en el mundo siendo la aterosclerosis el origen de más del 50% de las muertes súbitas¹. Por tanto, un diagnóstico rápido y fiable es crucial para mitigar los efectos de esta patología. La estimación de las propiedades elásticas de la placa de ateroma de cada paciente a partir de la información obtenida mediante ecografía intravascular por ultrasonidos (IVUS) podría ayudar en esta difícil tarea. Dado que las Redes Neuronales Artificiales son una potente herramienta de predicción, el objetivo de este estudio es determinar la vulnerabilidad de la placa por medio de la estimación de las propiedades mecánicas.

Materiales y métodos

Para construir una base de datos que permitiera entrenar la RNA para estimar los módulos de Young del núcleo (E_{core}) y de la placa (E_{placa}), se crearon nueve geometrías 2D idealizadas de arteria coronaria con placa de ateroma con diferentes grados de estenosis. Los materiales que corresponden al núcleo y a la placa se modelaron como hiperelásticos, no-lineales, isótropos e incompresibles, mediante el modelo de comportamiento Neo-Hookeano. Las capas media y adventicia se modelaron mediante el modelo hiperelástico de Gasser. Debido a una mayor variabilidad en las propiedades mecánicas del núcleo, la base de datos fue creada otorgando propiedades de

material al núcleo y placa en un rango de 1-100 kPa, 390-1200 kPa respectivamente, siguiendo una distribución logarítmica. Todos los modelos fueron desarrollados en ABAQUS (versión 6.14, Dassault Systems Simulia Corp., Providence, RI, USA). Las variables candidatas a formar parte de la entrada de la RNA fueron: deformación principal máxima (ϵ_1), deformación principal mínima (ϵ_2), variación del espesor del núcleo con respecto a su espesor inicial (ϵ_{core}), variación del espesor de la fina capa fibrótica que separa el núcleo del torrente sanguíneo con respecto a su espesor inicial (ϵ_{cap}), la variación del diámetro del lumen con respecto a su diámetro inicial (ϵ_{theta}), y el grado de estenosis (SR). Una vez construida la base de datos, se realizó un estudio estadístico previo para identificar cuáles eran las variables que mejor explicaban la respuesta. La RNA se desarrolló en el entorno de programación Jupyter Notebook (versión 6.3.0). Una vez que la RNA alcanzó errores aceptables, se estudió cómo afectaba el error en las predicciones de casos reales a la estimación de la vulnerabilidad de la placa, utilizando la tensión principal máxima como predictor (placa vulnerable si $Max. Principal Stress > 247 kPa$)

Resultados

Los resultados del análisis estadístico mostraron que, las variables más influyentes fueron SR , $\epsilon_{core-cuad}$, $\epsilon_{cap-cuad}$ y ϵ_{theta} , con un p -valor de 0.000 y una fiabilidad del modelo del 92.8%. La red neuronal artificial utilizada contó con 11 capas ocultas y un total de 4 millones de parámetros, consiguiendo un error en la función de pérdidas de aproximadamente 10^{-5} (figura 1). En la figura 2, se muestran los errores cometidos en el entrenamiento y en el test de la RNA cuando predice E_{core} y E_{placa} . Como se puede observar, los errores de entrenamiento y test son muy similares en cada caso. Sin embargo, el error cometido al predecir E_{core} es algo mayor debido a que es un material cuyas propiedades mecánicas presentan una gran variabilidad en literatura. Una vez entrenada y validada la red, se estudió su capacidad

predictiva en casos reales² (figura 3). Los errores relativos obtenidos en la estimación de los módulos de Young son aceptables (tabla 1), ya que las tensiones calculadas con las propiedades elásticas predichas y las reales son muy similares, y por tanto no se ve realmente afectada la precisión en la predicción de la vulnerabilidad de la placa.

Conclusiones

La predicción de las propiedades elásticas del núcleo resulta más compleja debido a una mayor variabilidad en sus propiedades mecánicas. Para solventar esta discrepancia se ha creado una base de datos que siga una distribución logarítmica. Los errores en la predicción de las propiedades elásticas son aceptables, pues han permitido calcular las tensiones, y, por tanto, la vulnerabilidad de la placa, con gran precisión.

Referencias y Citas

- [1]. ROTH, G., ABATE, D., ABATE, K. H., ABAY S.L., ABBAFATI, C., ABBASI, N., ABBASTABAR, H., ABD-ALLAH, F., ABDELA, J., ABDEANIM, A. Global, regional, and national age-sex-specific mortality for 282 causes of death in 195 countries and territories, 1980-2017: a systematic analysis for the global burden of disease study 2017. *The Lancet*, 392(10159):1736-1788, 2018.
- [2]. LE FLOC'H, S., OHAYON, J., TRACQUI, P., FINET, G., GHARIB, A.M., MAURICE, R.L., CLOUTIER, G. and PETTIGREW, R.I. Vulnerable Atherosclerotic Plaque Elasticity Reconstruction Based on a Segmentation-Driven Optimization Procedure Using Strain Measurements: Theoretical Framework. *IEE Trans Med Imaging*. 2009, 28(7), 1126-37. Available from: doi: 10.1109/TMI.2009.2012852.

Tabla 1. Resultados de la predicción de la RNA a geometrías reales.

Geom	Predicción			Real		
	Ecore (kPa)	Eplaca (kPa)	S1 (kPa)	Ecore (kPa)	Eplaca (kPa)	S1 (kPa)
1	4.5	1080	296.2	11.1	600	286.8
2	3.4	660	142.8	11.1	600	143.5
3	0.68	588	96.8	11.1	600	96.1
4	19.8	1200	87.7	11.1	600	81.4

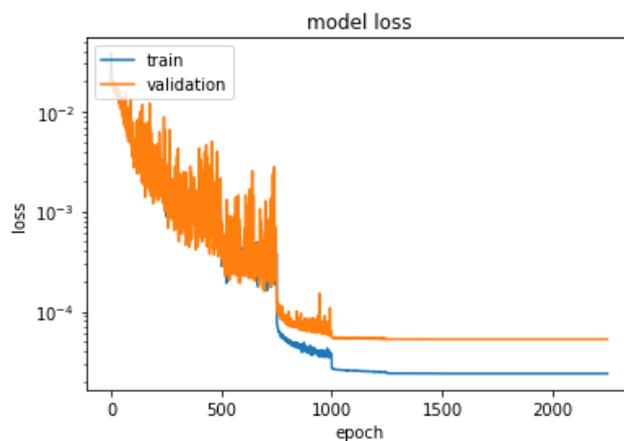


Figura 1. Evolución de la función de pérdida a lo largo del entrenamiento (azul entrenamiento, naranja validación).

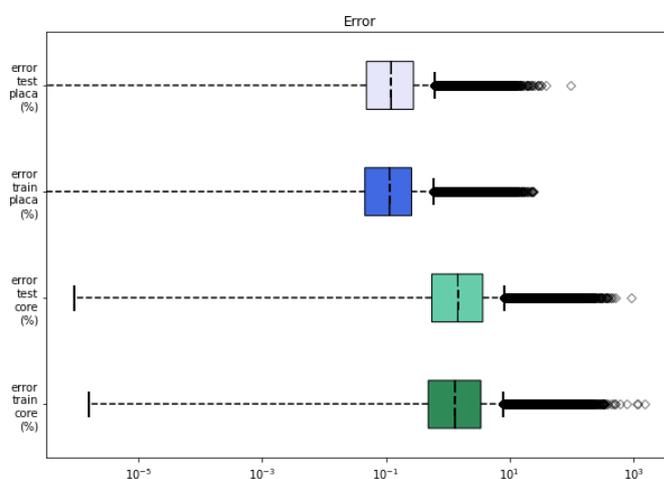


Figura 2. Error cometido en la predicción de Eplaca y Ecore durante el entrenamiento (azul) y el test (verde) de la RNA.

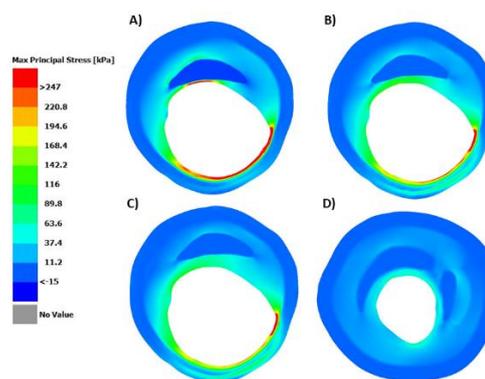


Figura 3. Tensión principal máxima en los modelos con geometría real. A) Geometría real 1: 1 lípido y espesor de la capa fibrótica de 65 μm . B) Geometría real 2: 1 lípido y espesor de la capa fibrótica de 250 μm . C) Geometría real 3: 1 lípido y espesor de la capa fibrótica de 458 μm . D) Geometría real 4: 2 lípidos, una calcificación y espesor de la capa fibrótica de 250 μm .