



**Universidad**  
Zaragoza

## Trabajo Final de Máster

Predicción Temprana de Aneurismas Aórticos  
Abdominales: Una Metodología Basada en  
Simulación Computacional de Modelos de Aortas

Early Prediction of Abdominal Aortic Aneurysms: A  
Methodology Based on Computational Simulation of  
Aortas Models

Autor

Caro Sierra, David

Directores

Peña Baquedano, Estefanía

Latorre Molins, Álvaro Tomás

ESCUELA DE INGENIERÍA Y ARQUITECTURA  
MÁSTER UNIVERSITARIO EN INGENIERÍA BIOMÉDICA  
2023-2024





## DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe remitirse a [seceina@unizar.es](mailto:seceina@unizar.es) dentro del plazo de depósito)

D./D<sup>a</sup>. David Caro Sierra

en aplicación de lo dispuesto en el art. 14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de Estudios de la titulación de

Máster Universitario en Ingeniería Biomédica

(Título del Trabajo)

Predicción Temprana de Aneurismas Aórticos Abdominales: Una Metodología Basada en Simulación Computacional de Modelos de Aortas

es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada debidamente.

Zaragoza, 20/06/2024

Fdo:



# AGRADECIMIENTOS

Quiero expresar mi profundo agradecimiento a mis tutores, Fany y Álvaro, por su orientación, apoyo y dedicación durante todo el proceso de desarrollo de este trabajo. Agradezco especialmente el respaldo incondicional de mi familia a lo largo de este camino. Sin el constante apoyo de mis padres, Alfonso y Angelines, este logro no habría sido posible. Por último, quiero dedicar un especial agradecimiento a Nazaret, por su paciencia y constante respaldo durante este período.

Muchas gracias.



# RESUMEN

La ruptura de los aneurismas de aorta abdominal constituye una de las principales causas de mortalidad a nivel mundial. Actualmente, los criterios clínicos para predecir el riesgo de ruptura de los aneurismas incluyen el valor del diámetro máximo y la velocidad de crecimiento. Sin embargo, los estudios muestran que estos criterios no son predictores fiables, ya que no ofrecen la fiabilidad deseada para evaluar el riesgo de ruptura. Esta falta de precisión subraya la necesidad de desarrollar métodos más efectivos para predecir el riesgo de ruptura de los aneurismas aórticos abdominales y así, mejorar significativamente las tasas de detección precoz para poder implementar el tratamiento oportuno.

Con el propósito de mejorar la capacidad de predicción del riesgo de ruptura de los aneurismas de aorta abdominal, se ha desarrollado un método innovador que emplea la representación de gradientes de deformaciones para detectar las fases iniciales de la formación de aneurisma. Este enfoque combina tecnologías de modelado computacional con datos clínicos y de técnicas de imagen médica para obtener una evaluación más precisa del riesgo de ruptura. Este proceso implica obtener imágenes MRI/CT, extraer desplazamientos y deformaciones, y aplicar gradientes de deformación. En este trabajo se han utilizado modelos paramétricos, en lugar de imágenes clínicas, para construir y validar la metodología

En el presente trabajo de investigación, se exponen los fundamentos de este método propuesto, así como los resultados obtenidos durante la fase inicial de validación. Estos resultados preliminares muestran una correlación prometedora entre las características de las deformaciones en los aneurismas aórticos abdominales y la detección temprana del aneurisma, lo que sugiere un potencial significativo para mejorar la predicción y la gestión clínica de esta condición.

Dichos resultados revelan la factibilidad de llevar a cabo la evaluación clínica del riesgo de aneurismas de aorta abdominal a través de la utilización de mapas de deformaciones obtenidos a partir de imagen clínica. Esta metodología emergente presenta una oportunidad para mejorar la precisión y la eficacia de la evaluación del riesgo de ruptura de los aneurismas, lo que podría tener un impacto significativo en la práctica clínica y en la calidad de vida de los pacientes afectados.



# ABSTRACT

Ruptured abdominal aortic aneurysms are one of the leading causes of mortality worldwide. Currently, clinical criteria for predicting the risk of aneurysm rupture include the maximum diameter value and growth velocity. However, studies show that these criteria are not reliable predictors, as they do not offer the desired reliability for assessing the risk of rupture. This lack of accuracy underlines the need to develop more effective methods to predict the risk of rupture of abdominal aortic aneurysms and thus significantly improve early detection rates in order to implement timely treatment.

In order to improve the ability to predict the risk of rupture of abdominal aortic aneurysms, an innovative method has been developed that uses deformation gradient representation to detect the early stages of aneurysm formation. This approach combines computational modelling technologies with clinical and medical imaging data to obtain a more accurate assessment of the risk of rupture. This process involves obtaining MRI/CT images, extracting displacements and deformations, and applying deformation gradients. In this work, parametric models, rather than clinical images, have been used to build and validate the methodology.

In this research paper, the rationale for this proposed method, as well as the results obtained during the initial validation phase, are presented. These preliminary results show a promising correlation between deformation characteristics in abdominal aortic aneurysms and early aneurysm detection, suggesting significant potential for improved prediction and clinical management of this condition.

These results reveal the feasibility of performing clinical risk assessment of abdominal aortic aneurysm risk using deformation maps derived from clinical imaging. This emerging methodology presents an opportunity to improve the accuracy and efficacy of aneurysm rupture risk assessment, which could have a significant impact on clinical practice and the quality of life of affected patients.



# Índice

<b>1. Introducción</b>	<b>1</b>
1.1. Contenidos . . . . .	1
1.2. Contexto: Aneurismas e Ingeniería Biomédica aplicada a tejido vascular	3
1.2.1. Aneurismas de Aorta Abdominal . . . . .	3
1.2.2. Técnicas vigentes de detección . . . . .	5
1.3. Motivación . . . . .	6
1.4. Objetivo . . . . .	8
<b>2. Modelo de Elementos Finitos de la Arteria Sana y Patológica</b>	<b>9</b>
2.1. Geometrías empleadas . . . . .	10
2.1.1. Aorta Abdominal Sana . . . . .	10
2.1.2. Aorta Abdominal Patológica . . . . .	12
2.1.3. Aorta Abdominal Patológica con trombo intraluminal . . . . .	13
2.1.4. Aorta Abdominal Sana con Heterogeneidades . . . . .	14
2.2. Caracterización del material . . . . .	15
2.3. Condiciones de contorno . . . . .	17
2.4. Cargas . . . . .	18
2.5. Mallado . . . . .	19
2.6. Geometría cero presión . . . . .	22
2.6.1. Introducción al método . . . . .	22
2.6.2. Aplicación del método . . . . .	23
<b>3. Procesado de Datos</b>	<b>25</b>
3.1. Simulación de datos clínicos . . . . .	25
3.2. Metodología para la Detección de Tejido Patológico . . . . .	26

<b>4. Resultados</b>	<b>31</b>
4.1. Simulación numérica de Aorta Abdominal . . . . .	31
4.1.1. Simulación numérica de Aorta Abdominal Sana . . . . .	31
4.1.2. Simulación numérica de AAA . . . . .	32
4.1.3. Simulación numérica de AAA más ILT . . . . .	34
4.2. Metodología de detección temprana . . . . .	36
4.2.1. Análisis Cualitativo . . . . .	36
4.2.2. Análisis Cuantitativo . . . . .	38
4.3. Mapas de gradientes de deformación. . . . .	41
4.3.1. Análisis de Modelos con Heterogeneidades . . . . .	41
4.3.2. Influencia de los Instantes de Presión Seleccionados . . . . .	43
4.3.3. Comparación entre AAA y AAA con ILT . . . . .	45
<b>5. Conclusiones</b>	<b>47</b>
5.1. Conclusiones . . . . .	47
5.2. Limitaciones . . . . .	48
5.3. Líneas futuras . . . . .	48
<b>6. Bibliografía</b>	<b>49</b>
<b>Lista de Figuras</b>	<b>53</b>
<b>Lista de Tablas</b>	<b>59</b>
<b>Glosario</b>	<b>61</b>
<b>Anexos</b>	<b>63</b>
<b>A. Aneurismas</b>	<b>65</b>
<b>B. Geometrías patológicas</b>	<b>67</b>
B.1. Geometrías de AAA con ILT. . . . .	68
B.2. Geometrías de aorta con heterogeneidades. . . . .	71
<b>C. Respuesta tensional hiperelástica. Modelos hiperelásticos para tejidos biológicos blandos.</b>	<b>77</b>

C.1. Formulación . . . . .	78
C.2. Obtención de los parámetros . . . . .	80
C.3. Implementación de estados en modelos heterogéneos . . . . .	82
C.4. Implementación de las fibras en Abaqus . . . . .	84
<b>D. Análisis de sensibilidad de malla.</b>	<b>85</b>
D.1. Construcción de los distintos mallados. . . . .	85
<b>E. Algoritmo de Geometría Cero Presión.</b>	<b>91</b>
E.1. Variables utilizadas en el algoritmo . . . . .	92
E.2. Algoritmo Pull Back . . . . .	93
E.3. Resultados de $K_{c_{opt}}$ . . . . .	98
<b>F. Resultados Complementarios</b>	<b>99</b>
F.1. Simulación Numérica de AAA más ILT . . . . .	99
F.2. Mapas de Gradiente de Deformación de los Modelos con Heterogeneidades	101
F.3. Mapas de Gradiente de Deformación de los Modelos AAA más ILT . . .	111



# Capítulo 1

## Introducción

En este capítulo se plantea el problema abordado en este trabajo, explicando de manera concisa cómo se puede detectar tempranamente los aneurismas aórticos abdominales (AAA) mediante simulación computacional, los fundamentos de la patología de los AAA y las metodologías actuales empleadas para su predicción. Se presenta la motivación del trabajo y se establecen los objetivos que se buscan alcanzar durante el desarrollo y el alcance del mismo.

### 1.1. Contenidos

Esta memoria está compuesta por cinco capítulos en los que se diferenciará una introducción, un planteamiento de los problemas, las soluciones propuestas y por último unas conclusiones junto a posibles líneas futuras de investigación:

- **Capítulo uno:** En este primer capítulo se presenta la introducción al estudio, se describe brevemente el contexto y la relevancia del análisis de AAA. Además, se incluyen la motivación y los objetivos que se pretenden alcanzar con la realización de este trabajo.
- **Capítulo dos:** En el segundo capítulo se detalla el modelo de elementos finitos de la arteria sana y patológica. Al estar desarrollando un estudio teórico, en lugar de aplicar directamente la metodología a datos clínicos, se generarán datos in silico mediante modelos de elementos finitos. Por lo tanto, se enfocará en la creación y validación de estos modelos numéricos, proporcionando una base sólida para el análisis y la detección de anomalías en la aorta.

- **Capítulo tres:** En el tercer capítulo se aborda el procesado de datos, donde se describe el método para la detección temprana de aneurismas mediante la representación de las variables del gradiente de deformación. Se describen los análisis cualitativos y cuantitativos utilizados para seleccionar la mejor variable que permita detectar tejido patológico de manera precisa.
- **Capítulo cuatro:** En el cuarto capítulo se presentan los resultados obtenidos a partir de las simulaciones computacionales. Se analizan los comportamientos de los modelos bajo distintas condiciones y se discuten los hallazgos más relevantes.
- **Capítulo cinco:** En el quinto y último capítulo se recogen las conclusiones del trabajo, junto a limitaciones surgidas en el estudio y líneas futuras en cuanto a aplicaciones y posibles mejoras del método propuesto para la detección temprana de AAA.

## 1.2. Contexto: Aneurismas e Ingeniería Biomédica aplicada a tejido vascular

### 1.2.1. Aneurismas de Aorta Abdominal

Un aneurisma es una dilatación anómala y permanente en la pared de un vaso sanguíneo, causada por una lesión o debilidad de dicha pared, donde la presión sanguínea empuja hacia fuera, tendiendo a agrandarse con el tiempo (Nieto Palomo, 2016). Para más detalles sobre aneurismas en general, consulte el *Anexo A: Aneurismas*.

Los AAA (Figura 1.1) son una causa significativa de mortalidad. Según el Centro para el Control y la Prevención de Enfermedades (CDC, 2023), se estima que causan entre 10,000 y 15,000 muertes anuales en los Estados Unidos, con una mayor incidencia a nivel mundial debido a variaciones en la prevalencia y factores de riesgo. Esta patología vascular consiste en una dilatación que supera el 50 % del diámetro normal del vaso o alcanza un diámetro igual o mayor a 3 cm, resultante de un debilitamiento de la pared vascular, típicamente localizado en la porción infrarrenal de la aorta, una región sometida a fuertes fuerzas hemodinámicas (Bravo-Merino et al., 2017).




Figura 1.1: Diferencia entre AAA y aorta abdominal sana (Servei, 2023).

Hasta un 75 % de los AAA son asintomáticos y suelen descubrirse mediante pruebas de imagen. La detección temprana y eficaz de un aneurisma es una prioridad para las Sociedades Científico-Sanitarias. Se ha observado que la sensibilidad de la exploración física para el diagnóstico de los aneurismas varía entre el 33 % y el 100 %, la especificidad oscila entre el 75 % y el 100 %, y el valor predictivo positivo va del 14 % al 100 % (Lahoz et al., 2016). Por lo tanto, el nivel de predicción depende en gran medida de la calidad de las técnicas de imagen médica utilizadas y del estado de la enfermedad.

## **Estructura de Aorta Abdominal**

La aorta abdominal consta de tres capas principales: la túnica íntima, la túnica media y la túnica adventicia. La íntima es la capa más interna, formada por células endoteliales que facilitan el flujo sanguíneo. La media, la capa más gruesa, está compuesta de células musculares lisas y fibras elásticas, proporcionando elasticidad y fuerza a la arteria. La adventicia es la capa externa, hecha de tejido conectivo, colágeno y elastina, que aporta soporte estructural y elasticidad (Brouhard, 2023). En estos tejidos puede formarse un trombo intraluminal (ILT), que es una acumulación de coágulos sanguíneos dentro del aneurisma, influenciando la mecánica de la pared arterial y afectando el riesgo de rotura (Piechota-Polanczyk et al., 2015).

Las fibras de colágeno y elastina dentro de la aorta contribuyen a su comportamiento anisotrópico, es decir, sus propiedades mecánicas varían en diferentes direcciones. Las fibras de colágeno brindan resistencia a la tracción, mientras que las fibras de elastina permiten la elasticidad necesaria para la función normal de la arteria, soportando y distribuyendo eficientemente las tensiones internas (Alleva, 2023). Esta anisotropía es esencial para la función biomecánica de la aorta y su capacidad para adaptarse a las variaciones de presión y flujo sanguíneo (Hacking et al., 2023).

### 1.2.2. Técnicas vigentes de detección

Las técnicas predictivas para la detección temprana AAA han avanzado significativamente, incorporando métodos basados en biomarcadores y técnicas de imagen de alta resolución. Los estudios recientes destacan el uso de biomarcadores genéticos, como los productos de genes de respuesta temprana *Nurr1* y *NR4A3*, que muestran potencial en la predicción del desarrollo y progresión de AAA (Wanhainen et al., 2024).

Recientemente se ha demostrado la eficacia del uso de modelos de aprendizaje automático (machine learning) para mejorar la detección del AAA. Salzler et al. (2024) desarrolló un modelo predictivo utilizando datos de registros médicos electrónicos de 18,660 pacientes. Este modelo incorporó 41 factores clínicos y logró un aumento del 200 % en la detección de AAA en comparación con los métodos tradicionales. Además, una revisión sistemática de algoritmos de aprendizaje automático para la predicción de la progresión del AAA mostró que estos modelos pueden predecir con mayor precisión el crecimiento del aneurisma en comparación con los modelos de referencia estándar. Los estudios incluidos en la revisión utilizaron enfoques de aprendizaje supervisado y se centraron en indicadores como el diámetro luminal máximo, el volumen del AAA, el ILT y el diámetro mediado por flujo (FMD) (Ullah et al., 2024).

Actualmente, la tomografía computarizada (TC) y la imagen de resonancia magnética (IRM) continúan siendo herramientas más utilizadas en la planificación preoperatoria y en el seguimiento postoperatorio. Estas técnicas, junto con la ecografía, forman el núcleo de las estrategias actuales de detección y monitorización (Wanhainen et al., 2024). Por lo tanto, en la práctica clínica actual, la detección de aneurismas se realiza básicamente utilizando estas técnicas debido a su alta precisión y capacidad para proporcionar información detallada sobre la anatomía y progresión del aneurisma.

### 1.3. Motivación

La finalidad de este trabajo es desarrollar y evaluar un método basado en la representación de mapas de deformaciones para la predicción temprana de AAA. La detección temprana de estas patologías es crucial, ya que la ruptura de estos constituye una de las principales causas de mortalidad a nivel mundial. Los criterios clínicos actuales, como el diámetro máximo y la tasa de crecimiento, no son predictores fiables, por lo que se necesitan métodos alternativos más precisos.

Para desarrollar y validar la metodología, se utilizaron datos generados por modelos de elementos finitos en lugar de datos clínicos directos. Se crearon modelos paramétricos a partir de bibliografía, simulando tanto aortas abdominales sanas (AA) como en diferentes estados de enfermedad. Se realizaron simulaciones detalladas de diversas geometrías aórticas, incluyendo modelos con y sin la presencia de ILT.

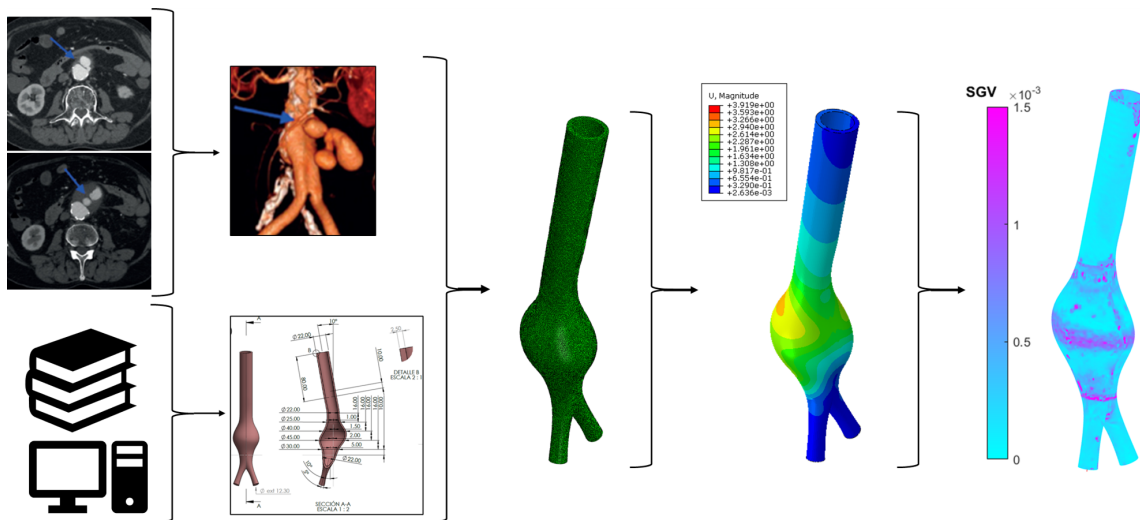


Figura 1.2: Esquema del proceso desde la obtención de imágenes médicas / modelos de bibliografía hasta la construcción de mapas de gradientes de deformación.

La Figura 1.2 muestra el proceso desde la obtención de imágenes médicas hasta la creación de mapas de gradientes de deformación. Primero, se adquieren imágenes detalladas del AAA o se construyen modelos paramétricos a partir de bibliografía. Luego, se desarrollan modelos de elementos finitos (EF) para simular la deformación del aneurisma bajo presión sanguínea. Si se usaran datos clínicos directos, no se necesitarían modelos EF, ya que las variables se extraerían directamente. Finalmente, los resultados de las simulaciones se transforman en mapas de gradientes de deformación, que indican cambios en el material y sugieren el inicio de una patología.

El trabajo enfrentó desafíos significativos, como ajustar los modelos geométricos para representar con precisión la geometría de presión cero (GCP) y realizar simulaciones detalladas, lo que implicó un alto tiempo computacional. Se optimizaron parámetros del modelo y se usaron técnicas de filtrado para manejar grandes volúmenes de datos.

En resumen, este trabajo proporciona una herramienta más precisa y fiable para la predicción temprana de AAA, abordando los desafíos técnicos y computacionales asociados con la simulación y validación de modelos aórticos complejos.

## 1.4. Objetivo

El objetivo del presente estudio es desarrollar y validar un método innovador para la detección temprana de AAA mediante el uso de mapas de gradientes de deformación, aplicados a modelos de pacientes idealizados. Este método pretende superar las limitaciones de los criterios clínicos actuales, que no siempre son predictores fiables del riesgo de ruptura.

Entre los objetivos específicos se incluyen:

- **Desarrollo del Modelo:** Desarrollar modelos paramétricos detallados y precisos de la aorta abdominal y los aneurismas, incorporando datos obtenidos de la bibliografía. Al ser un estudio teórico, utilizamos estos modelos para simular la información clínica que se obtendría a partir de IRM o TC.
- **Caracterización de los materiales constituyentes:** Los materiales utilizados para construir los modelos de elementos finitos se obtuvieron a partir de curvas experimentales realizadas en trabajos anteriores. Se realizó un ajuste del comportamiento mecánico de las curvas con el software Hyperfit, permitiendo una representación precisa de las propiedades materiales en las simulaciones.
- **Generación de Mapas Deformaciones:** Implementar técnicas avanzadas para generar y analizar mapas de gradientes de deformación. Esta metodología se utilizará para visualizar la detección de la zona enferma, permitiendo identificar las áreas de mayor estrés y deformación en el aneurisma.
- **Optimización del Proceso:** Refinar el algoritmo de detección para mejorar su precisión y reducir el tiempo de procesamiento.

Este proyecto aspira a proporcionar una herramienta clínica robusta y precisa para la detección temprana de aneurismas en sus primeras fases de crecimiento.

## Capítulo 2

# Modelo de Elementos Finitos de la Arteria Sana y Patológica

En este punto del estudio se emplean modelos de elementos finitos para simular aortas reales. Estos modelos permiten realizar simulaciones detalladas y precisas del comportamiento mecánico de los aneurismas bajo diversas condiciones fisiológicas, proporcionando información crucial para la detección y el análisis de las zonas enfermas.

Este capítulo se centra en la construcción y caracterización de los modelos, así como en los aspectos fundamentales relacionados con la geometría empleada, incluyendo la obtención de la GCP, la caracterización del material, las cargas aplicadas, las condiciones de contorno y el proceso de mallado. Además, se explora la relevancia de cada uno de estos elementos en el contexto de la investigación, estableciendo así las bases necesarias para el desarrollo y la validación de la metodología propuesta.

## 2.1. Geometrías empleadas

### 2.1.1. Aorta Abdominal Sana

Para el desarrollo de este trabajo, se emplearon modificaciones de los modelos paramétricos propuestos en el estudio de Patnaik et al. (2019) (Figura 2.1). Estas adaptaciones se realizaron con el objetivo de mejorar la precisión y la fidelidad del modelo respecto a la realidad anatómica.




Figura 2.1: Modelo geométrico base y sus dimensiones para la AA sana (Patnaik et al., 2019).

Se siguió una metodología similar a la empleada en el estudio de Gao et al. (2020), donde se ajustó la geometría de la aorta utilizando como referencia la curvatura de las vértebras lumbares. Con este fin, se trazó la curva de las vértebras lumbares conectando el punto medio anterior de las cinco vértebras lumbares ( $\mathbf{L}_1$  a  $\mathbf{L}_5$ ) en azul oscuro (Figura 2.2.A). Este enfoque permitió una mejor aproximación a la anatomía real de la aorta, mejorando así la precisión y la utilidad del modelo para la simulación y análisis de aortas abdominales (Figura 2.2.B).




Figura 2.2: Adaptación del modelo geométrico. A) Obtención de la curva de las vértebras lumbares. Curva de las vértebras lumbares conectando el punto medio de las cinco vértebras lumbares mostradas en azul (Gao et al., 2020). B) Modelo utilizado en el estudio presente una vez aplicada la curvatura .

Después de realizar las adaptaciones necesarias, se obtuvo una representación más precisa de una AA sana monocapa. Aunque la aorta tiene tres capas de tejido, solo se modela una, ya que las imágenes médicas no proporcionan detalles sobre los espesores de cada capa. Los modelos paramétricos se generaron con el software SolidWorks (Hirschtick, 2024). La curva obtenida se adaptó en tres dominios con diferentes ángulos, como se muestra en la Figura 2.3.

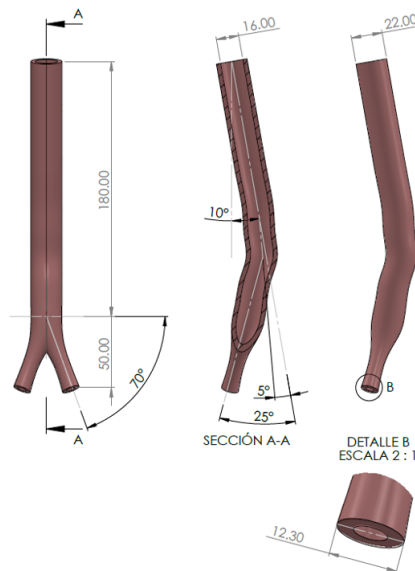


Figura 2.3: Adaptación del modelo geométrico para AA sana monocapa.

A partir de esta curva , se crean superficies cilíndricas con un radio de 10 mm en la zona abdominal y 5.15 mm para las arterias iliacas (Patnaik et al., 2019). Estas superficies se unen siguiendo la trayectoria de la curva. Luego, se realiza un vaciado para obtener el espesor deseado (3 mm) para la AA sana.



### 2.1.3. Aorta Abdominal Patológica con trombo intraluminal

Para la creación del modelo patológico con ILT se partió del modelo patológico preexistente. La presencia de este trombo puede aumentar la presión sobre la pared del aneurisma y modificar la distribución del estrés.

Se realizaron ajustes en los radios que originaban el aneurisma, disminuyéndolos significativamente para simular la presencia del trombo de manera realista. Utilizando operaciones booleanas en el software de modelado, se fusionaron los modelos de AAA con el ILT. Se generaron un total de 4 modelos diferentes para analizar la influencia del trombo en la estructura del aneurisma. En este documento se presenta el primer modelo (Figura 2.5), que exhibe una mayor cantidad de tejido trombótico. Los detalles adicionales sobre los modelos restantes se encuentran disponibles en el *Anexo B: Geometrías sanas y patológicas*. Esta aproximación permite estudiar de manera detallada y comparativa el impacto del trombo en la formación y evolución de los AAA.




Figura 2.5: Modelo 01 utilizado en el estudio presente de AAA monocapa con ILT.

### 2.1.4. Aorta Abdominal Sana con Heterogeneidades

Para la construcción de la AA con heterogeneidades, que se utilizará para la detección preventiva de aneurismas, se utilizó la misma geometría que en el modelo AA. Esta geometría fue importada al software comercial Abaqus (Hibbitt et al., 2017), donde se llevarán a cabo las simulaciones y se generarán las heterogeneidades. Estas heterogeneidades consisten en divisiones del tejido que se introducen en el modelo para simular condiciones más realistas y variadas, lo que permitirá una evaluación más precisa de la salud arterial y una detección temprana de posibles anomalías. Se generaron un total de 10 modelos diferentes para analizar la influencia de tejido patológico. En este documento se presenta el primer modelo (Figura 2.6) el cual representa una anilla de tejido patológico en la zona propensa a padecer un AAA. Los detalles adicionales sobre los modelos restantes se encuentran disponibles en el *Anexo B: Geometrías sanas y patológicas*, donde se crean modelos con diferentes formas y número de zonas patológicas que sugieren el inicio de aneurismas.




Figura 2.6: Modelo utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## 2.2. Caracterización del material

De acuerdo a lo visto en el capítulo 1.2.2, los vasos sanguíneos son materiales anisótropos y fibrados. Al estar sometidos continuamente a grandes deformaciones se ha empelado un modelo de comportamiento hiperelástico, no lineal, anisótropo e incompresible. Tal y como ya se realizó en estudios anteriores (Cilla, 2013; Latorre et al., 2022) se toma el modelo de comportamiento de material definido por Gasser et al. (2006) (Ecuación 2.1) y se consideran dos tipos de tejidos, sanos y enfermos. Tanto el desarrollo de la formulación como la obtención de los parámetros vienen detallados en el *Anexo C: Respuesta tensional hiperelástica. Modelos hiperelásticos para tejidos biológicos blandos*.

$$\bar{\Psi} = \frac{1}{D}(J-1)^2 + \mu_1(\bar{I}_1 - 3) + \frac{k_1}{2 \cdot k_2} \sum_{i+j=1}^N \exp(k_2 \cdot [\kappa \cdot (\bar{I}_1 - 3) + (\bar{I}_1 - 3 \cdot \kappa) \cdot (\bar{I}_i - 1)]^2) - 1 \quad (2.1)$$

Este modelo de Gasser et al. (2006) considera dos familias de fibras, pero con un mismo comportamiento, donde  $k_1$  kPa corresponde a la rigidez general del tejido y  $k_2(-)$  es la rigidez del colágeno (final del comportamiento del vaso). El valor  $D$  es referido al factor de incompresibilidad, en este caso es  $D = 0$  por ser un material incompresible, debido a su alto contenido en agua. El parámetro  $\mu$  kPa es la rigidez proporcionada por la matriz,  $\kappa(-)$  aporta información sobre la dispersión de las fibras y puede obtenerse de forma experimental. En el caso particular de  $\kappa = 0.33$ , se considera que el material es completamente isótropo. El parámetro  $\gamma(^{\circ})$  representa el ángulo de las fibras respecto a la dirección circunferencial.

A partir de curvas de comportamiento obtenidas en ensayos experimentales reportados en la bibliografía (Geest et al., 2006; Holzapfel and Gasser, 2000), se extraen los puntos necesarios utilizando el software libre *WebPlotDigitizer*. Con los datos obtenidos, se construyen los ficheros de datos y se procesan los parámetros de ajuste mediante el software *Hyperfit*. El *Anexo C: Respuesta tensional hiperelástica. Modelos hiperelásticos para tejidos biológicos blandos* detalla el proceso completo para obtener los parámetros que definen el comportamiento mecánico del modelo. En la Tabla 2.1 se pueden observar los parámetros utilizados para cada material.

Material	$\mu[kPa]$	$D[-]$	$k_1[kPa]$	$k_2[kPa]$	$\kappa[-]$	$\gamma[^\circ]$
<i>AAA</i>	1.589	0	2911.433	2326.247	0.333	0
<i>Sana</i>	100	0	20000	61	0.233	43

Tabla 2.1: Constantes de la función de densidad de energía del tejido patológico y sano obtenido en el software comercial Hyperfit.

Además, se definieron 7 estados diferentes de las propiedades que abarcan desde una patología pura hasta una arteria completamente sana. Para obtener estos valores intermedios, se realizó una interpolación lineal de los parámetros que definen el comportamiento mecánico:

ESTADO	$\mu[kPa]$	$D[-]$	$k_1[kPa]$	$k_2[kPa]$	$\kappa[-]$	$\gamma[^\circ]$
$E_{01}$ / <i>AAA</i>	001.589	0	02991.43	2326.25	0.3333	0
$E_{02}$	017.991	0	05826.27	1948.72	0.3133	7
$E_{03}$	034.393	0	08661.07	1571.18	0.2966	14
$E_{04}$	050.795	0	11495.87	1193.64	0.2799	22
$E_{05}$	067.197	0	14330.67	0816.10	0.2632	29
$E_{06}$	083.599	0	17165.47	0438.56	0.2465	36
$E_{07}$ / <i>Sana</i>	100.000	0	20000.00	0061.00	0.2330	43

Tabla 2.2: Constantes de la función de densidad de energía del los estados transitorios entre tejido patológico y sano.

## 2.3. Condiciones de contorno

Las condiciones de contorno se imponen a las geometrías obtenidas en el punto 2.1. Ya que son idénticas en todos los modelos, la geometría sana se utilizará como ejemplo (Figura 2.7.A). Se implementaron sistemas locales en coordenadas cilíndricas en las caras superior e inferior para establecer las condiciones de contorno (Figura 2.7.C-D). Con ello se logra bloquear los movimientos en la dirección z para las caras, lo que simula la continuidad de la arteria y evita representar una corte real. Los movimientos radiales se bloquean a lo largo de la generatriz, proporcionando un soporte natural similar al de las costillas. Esto asegura una representación más precisa de las condiciones anatómicas y mecánicas a las que está sujeta la arteria en el cuerpo humano (Figura 2.7.B). La replicación fiel del entorno fisiológico de la arteria es posible gracias a esta metodología, lo que facilita una simulación más realista de las tensiones y deformaciones a las que está sujeta.

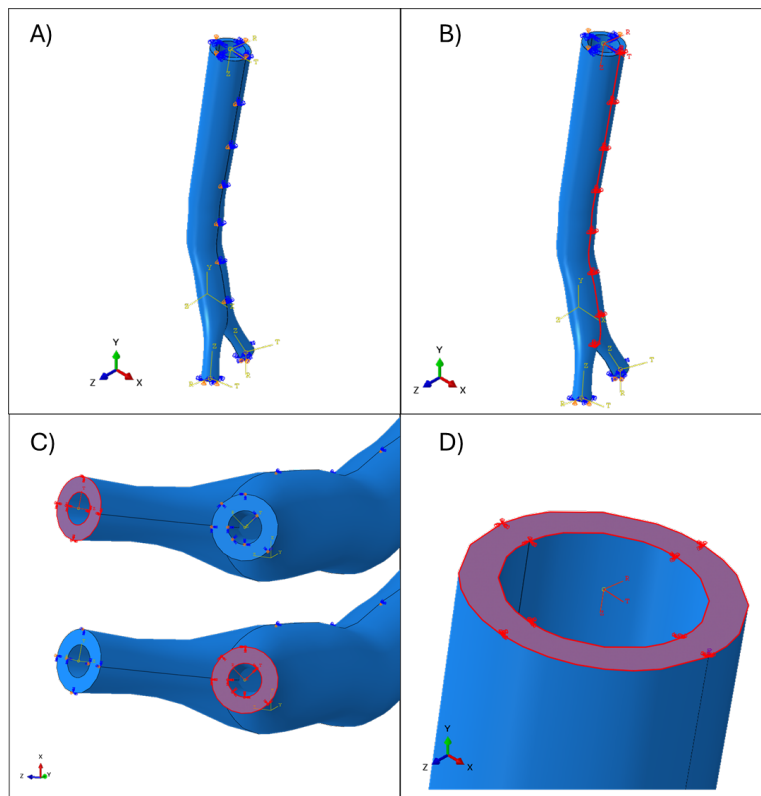


Figura 2.7: Condiciones de contorno aplicadas. A) Modelo completo, B) detalle de condición aplicada a la generatriz, C) bloqueo de las caras inferiores y D) bloqueo de la cara superior.

## 2.4. Cargas

La presión sanguínea en la AA sana se encuentra entre 80 y 120 mmHg, el pico de presión sistólica en pacientes con AAA no llega a ser muy superior a los 120 mmHg (Manapurathe et al., 2022), que es lo mismo que 16 kPa. En la Figura 2.8 se observa la aplicación de dicha presión en el interior de la pared arterial.

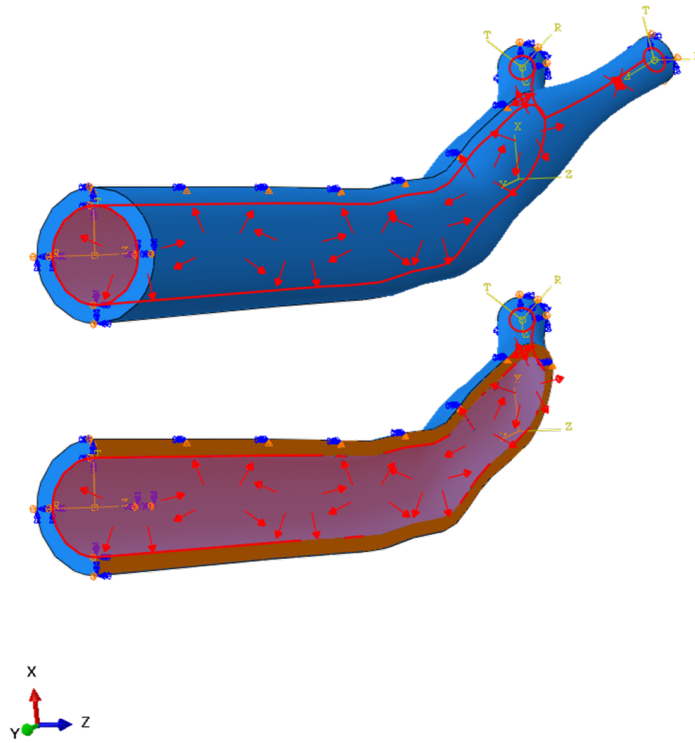


Figura 2.8: Presión sistólica aplicada en el modelo MEF.

## 2.5. Mallado

Uno de los pasos críticos antes de calcular el modelo es realizar una malla sobre el modelo. Es crucial mencionar que una malla muy fina produce resultados más precisos, generando un mapa de valores mucho más suavizado en comparación con una malla gruesa. Sin embargo, este enfoque tiene sus desventajas: El cálculo tomará más tiempo para terminarse y resultará en un aumento significativo del tiempo necesario para el post-procesamiento de datos dentro de Matlab. Por otro lado, una malla gruesa posibilitaría realizar los cálculos y procesar los datos de forma más veloz.

Para abordar estos desafíos, se llevó a cabo un estudio de sensibilidad de mallado. Este estudio permitió proponer diferentes estrategias de mallado adecuadas para distintas fases del análisis. El análisis consta de dos partes:

1. **Análisis del Modelo pre-GCP.** Los geometrías realizadas se han construido a partir de datos bibliográficos de arterias humanas *in vivo*. Es decir, las medidas están tomadas sobre la arteria presurizada. Por lo tanto, en la primera parte de análisis se realiza un algoritmo de *Pull-Back* para recuperar la geometría despresurizada.
2. **Análisis de Carga Sistólica.** A partir de la GCP, se añade la presión sistólica de AAA, para calcular todo el ciclo cardiaco. Este análisis va a simular los datos obtenidos a partir de imágenes clínicas, por lo que la malla ha de ser más fina.

Es fundamental verificar la convergencia de los resultados entre los diferentes niveles de mallado para los diversos modelos (sano, enfermo y con ILT). Si los cambios en los mapas de tensiones entre el mallado grueso y el mallado fino son menores que un cierto criterio de convergencia (en este caso, una diferencia del 5% debido a la naturaleza biológica del modelo), se puede considerar que los resultados han convergido. Este enfoque garantiza que los resultados obtenidos sean confiables y representen de manera precisa el comportamiento del sistema bajo estudio (Para ver todo el proceso de selección de mallado ver *Anexo D: Análisis de sensibilidad de malla*).

Así pues los mallados seleccionados son los siguientes:

MODELO	Tipo de Elementos	Nº de Elementos	Nº de Nodos	Seed Global (mm)
Modelo sano/heterogeneidad pre-GCP	C3D4H	044931	011286	3.0
Modelo sano/heterogeneidad post-GCP	C3D4H	316091	068086	1.0
Modelo AAA pre-GCP	C3D4H	060873	015535	1.0
Modelo AAA post-GCP	C3D4H	371197	082463	2.0
Modelo AAA + ILT 01 pre-GCP	C3D4H	109810	021439	3.0
Modelo AAA + ILT 02 pre-GCP	C3D4H	072863	015726	3.0
Modelo AAA + ILT 03 pre-GCP	C3D4H	080469	017262	3.0
Modelo AAA + ILT 04 pre-GCP	C3D4H	102652	021851	3.0
Modelo AAA + ILT 01 post-GCP	C3D4H	574257	112232	1.1
Modelo AAA + ILT 02 post-GCP	C3D4H	610144	120123	1.1
Modelo AAA + ILT 03 post-GCP	C3D4H	605573	120598	1.1
Modelo AAA + ILT 04 post-GCP	C3D4H	571492	109624	1.1

Tabla 2.3: Información sobre las mallas de los diferentes modelos.

Los diferentes modelos descritos en la tabla 2.3 están todos construidos con un único elemento de malla: tetraedros lineales utilizando aproximación híbrida (C3D4H). Estos modelos representan diversas condiciones de la aorta abdominal y se utilizan para evaluar el comportamiento mecánico bajo diferentes escenarios:

- **Modelo sano/heterogeneidad pre-GCP y post-GCP:** Representan una aorta saludable antes y después de ajustar la GCP, respectivamente. La heterogeneidad se refiere a la variabilidad en las propiedades del material a lo largo de la aorta.
- **Modelo AAA pre-GCP y post-GCP:** Representan una aorta con AAA antes y después de ajustar la GCP, respectivamente. Estos modelos permiten estudiar cómo el aneurisma afecta la distribución de tensiones y deformaciones.
- **Modelos AAA + ILT pre-GCP y post-GCP:** Representan aortas con aneurisma e ILT en diferentes configuraciones (01, 02, 03, 04) antes y después de ajustar la GCP. El ILT es una acumulación de coágulos dentro del aneurisma que puede influir en la mecánica de la pared arterial.

El número de elementos y nodos, así como el tamaño del "seed" global, varían entre los modelos para asegurar una malla adecuada que permita una simulación precisa y convergente.




Figura 2.9: Modelo AAA pre-GCP y post-GCP.




Figura 2.10: Detalle del espesor del modelo AAA pre-GCP y post-GCP.

## 2.6. Geometría cero presión

### 2.6.1. Introducción al método

La GCP es una representación de la forma natural de un vaso sanguíneo cuando no está sometido a ninguna presión interna. En el contexto de los AAA, esta geometría es crucial para entender la configuración inicial del tejido arterial antes de cualquier deformación causada por la presión sanguínea. La geometría reconstruida del AAA a partir de imágenes de TC o creada como un modelo paramétrico está presurizada y, por lo tanto, no es la configuración de presión cero. Asumir la geometría como la configuración de presión cero puede conducir a deformaciones y tensiones inexactas, lo que puede llevar a cálculos erróneos del riesgo de ruptura del AAA. Para abordar este problema, se ha introducido un algoritmo de Pull-Back (Raghavan et al., 2006; Latorre et al., 2022), y así, obtener, mediante métodos iterativos, la geometría despresurizada (Figura 2.11). Además, permite evaluar de manera más precisa la respuesta del tejido arterial a diferentes condiciones de carga y presión. Esto es fundamental para predecir el comportamiento de los aneurismas y diseñar intervenciones médicas adecuadas.

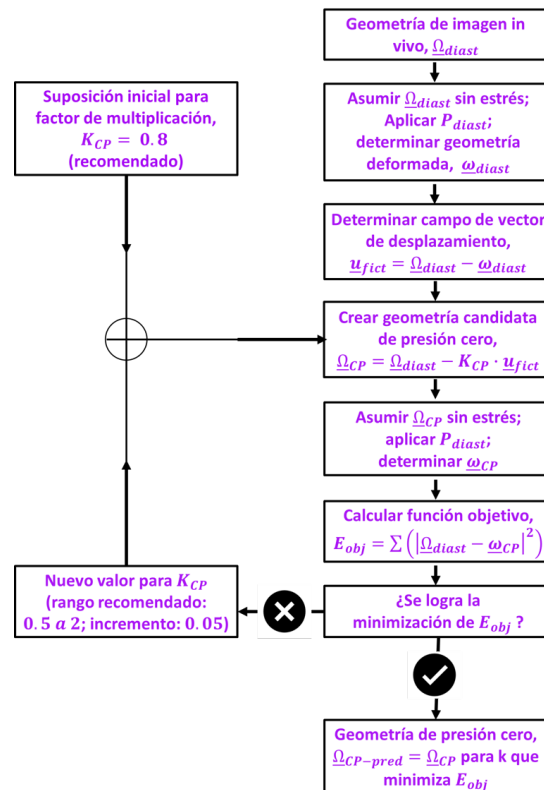


Figura 2.11: Esquema de algoritmo pull back empleado por Raghavan et al. (2006)

El algoritmo para ajustar la GCP en modelos de AAA se puede resumir en los siguientes pasos:

1. La geometría inicial se considera como la geometría en presión diastólica ( $\Omega_{\text{diast}}$ ).
2. A  $\Omega_{\text{diast}}$  se le añade la presión diastólica en el lumen para obtener un campo de desplazamientos ficticio ( $u_{\text{fict}}$ ).
3. La GCP ( $\Omega_{\text{CP}}$ ) se obtiene utilizando la ecuación:

$$\Omega_{\text{CP}} = \Omega_{\text{diast}} - K_{\text{CP}} \cdot u_{\text{fict}}$$

donde  $K_{\text{CP}}$  es una constante cuyo valor se debe optimizar.

4. Se añade la presión diastólica a la configuración de cero presión y se obtiene  $\Omega'_{\text{diast}}$ . Luego, se calcula el error entre  $\Omega_{\text{diast}}$  y  $\Omega'_{\text{diast}}$ . Mediante un proceso de optimización, se varía el valor de  $K_{\text{CP}}$  hasta reducir el error a un nivel aceptable.

En conclusión, la GCP es esencial para realizar simulaciones precisas en el estudio de los AAA. Este enfoque proporciona una base sólida para entender y analizar cómo responden las arterias a diferentes cargas y presiones. Para más detalles sobre el algoritmo y su implementación, consulte el *Anexo E: Algoritmo de Geometría Cero Presión*.

### 2.6.2. Aplicación del método

El algoritmo de GCP se aplica a todos los modelos pre-GCP, incluyendo el modelo sano/heterogeneidad, el modelo de AAA y el modelo de AAA con ILT.

Una vez obtenidos estos valores de  $K_{cp}$ , se aplica nuevamente el algoritmo con un mallado mucho más preciso. Se calcula la geometría despresurizada con el valor de  $K_{cp}$  y una malla fina, y luego se le añade una presión de 16 kPa. La optimización de la GCP con un mallado menos preciso toman unas 4 horas por modelo para obtener  $K_{cp}$  óptimo. En cambio, con un mallado muy preciso, el tiempo sería de unas 48 horas por modelo. Este enfoque reduce significativamente el tiempo computacional, haciendo el proceso más eficiente.



# Capítulo 3

## Procesado de Datos

En este capítulo se describe el proceso para simular los datos obtenidos a partir de imágenes clínicas y la posterior detección de las zonas patológicas. Se profundiza en el método y la representación de las variables del gradiente de deformación, sentando las bases teóricas y metodológicas para la implementación y análisis de la simulación computacional. Cabe destacar que esta metodología se desarrolló inicialmente para una patología diferente en modelos 2D (Latorre et al., 2022), y se ha adaptado para su aplicación en modelos 3D, ajustándose a diferentes patologías y tipos de aorta. El postprocesado de los datos se realiza en Matlab, lo que permite una manipulación y análisis detallado de las variables obtenidas de las simulaciones.

### 3.1. Simulación de datos clínicos

Actualmente, gracias a técnicas de imagen como la TC y la RM, es posible obtener la geometría y los desplazamientos relativos entre dos instantes de presión en imágenes clínicas. Estas técnicas permiten capturar con precisión la estructura y los cambios en la aorta bajo diferentes condiciones de presión, proporcionando datos esenciales para la simulación y el análisis biomecánico.

Para simular los datos clínicos, utilizamos los resultados de las simulaciones de elementos finitos a 115 y 120 mmHg. Una vez realizada la simulación, se importan las coordenadas nodales ( $X$ ,  $Y$ ,  $Z$ ) y los desplazamientos relativos ( $U_x$ ,  $U_y$ ,  $U_z$ ) de los análisis de EF para los instantes de presión de 115 y 120 mmHg. Estas coordenadas nos proporcionan la geometría de la aorta y los desplazamientos relativos, que también se pueden obtener a partir de datos clínicos mediante software de correlación de imagen. Una función lee los datos generados por Abaqus y devuelve una matriz separada por variables (coordenadas, desplazamientos, etc.), facilitando el análisis detallado de la deformación y las tensiones en la aorta.

## 3.2. Metodología para la Detección de Tejido Patológico

Para el desarrollo de la metodología es necesario definir una serie de variables que permitan evaluar la efectividad en la detección de tejido patológico. En este contexto, se han considerado seis variables. Son fundamentales para identificar y cuantificar los contornos de las áreas afectadas por AAA. Se consideran variables como las deformaciones principales o las deformaciones equivalentes porque son invariantes, lo que significa que no se ven afectadas por el cambio de sistema de coordenadas que pueda usarse en los métodos de imagen clínica. Además, dado que trabajamos con pequeños incrementos de presión (aproximadamente 5 mmHg), podemos calcular las variables de interés (SGV) bajo la hipótesis de pequeñas deformaciones a partir de los desplazamientos relativos entre 115 y 120 mmHg:

### 1. Módulo del Gradiente de la Deformación Principal I ( $|\nabla\varepsilon_I|$ )

$$|\nabla\varepsilon_I| = \left| \frac{\partial\varepsilon_I}{\partial x}, \frac{\partial\varepsilon_I}{\partial y}, \frac{\partial\varepsilon_I}{\partial z} \right| \quad (3.1)$$

- $\nabla\varepsilon_I$ : Gradiente de la Deformación Principal I.
- $\varepsilon_I$ : Deformación Principal Máxima.
- $\frac{\partial\varepsilon_I}{\partial x}, \frac{\partial\varepsilon_I}{\partial y}, \frac{\partial\varepsilon_I}{\partial z}$ : Derivadas parciales de la deformación principal I respecto a las coordenadas espaciales  $x, y, z$ .

### 2. Módulo del Gradiente de la Deformación Principal II ( $|\nabla\varepsilon_{II}|$ )

$$|\nabla\varepsilon_{II}| = \left| \frac{\partial\varepsilon_{II}}{\partial x}, \frac{\partial\varepsilon_{II}}{\partial y}, \frac{\partial\varepsilon_{II}}{\partial z} \right| \quad (3.2)$$

- $\nabla\varepsilon_{II}$ : Gradiente de la Deformación Principal II.
- $\varepsilon_{II}$ : Deformación Principal Media.
- $\frac{\partial\varepsilon_{II}}{\partial x}, \frac{\partial\varepsilon_{II}}{\partial y}, \frac{\partial\varepsilon_{II}}{\partial z}$ : Derivadas parciales de la deformación principal II respecto a las coordenadas espaciales  $x, y, z$ .

### 3. Módulo del Gradiente de la Deformación Principal III ( $|\nabla\varepsilon_{III}|$ )

$$|\nabla\varepsilon_{III}| = \left| \frac{\partial\varepsilon_{III}}{\partial x}, \frac{\partial\varepsilon_{III}}{\partial y}, \frac{\partial\varepsilon_{III}}{\partial z} \right| \quad (3.3)$$

- $\nabla\varepsilon_{III}$ : Gradiente de la Deformación Principal III.
- $\varepsilon_{III}$ : Deformación Principal Mínima.
- $\frac{\partial\varepsilon_{III}}{\partial x}, \frac{\partial\varepsilon_{III}}{\partial y}, \frac{\partial\varepsilon_{III}}{\partial z}$ : Derivadas parciales de la deformación principal III respecto a las coordenadas espaciales  $x, y, z$ .

### 4. Módulo del Gradiente de la Deformación Equivalente de von Mises ( $|\nabla\varepsilon_{VM}|$ )

$$|\nabla\varepsilon_{VM}| = \sqrt{\left(\frac{\partial\varepsilon_I}{\partial x}\right)^2 + \left(\frac{\partial\varepsilon_{II}}{\partial y}\right)^2 + \left(\frac{\partial\varepsilon_{III}}{\partial z}\right)^2} \quad (3.4)$$

- $\nabla\varepsilon_{VM}$ : Módulo del Gradiente de la Deformación Equivalente de von Mises.
- $\varepsilon_I, \varepsilon_{II}, \varepsilon_{III}$ : Componentes principales de la deformación.
- $\frac{\partial\varepsilon_I}{\partial x}, \frac{\partial\varepsilon_{II}}{\partial y}, \frac{\partial\varepsilon_{III}}{\partial z}$ : Derivadas parciales de las componentes principales de la deformación respecto a las coordenadas espaciales  $x, y, z$ .

### 5. Módulo del Gradiente de la Deformación Equivalente Tresca ( $|\nabla\varepsilon_{TR}|$ )

$$|\nabla\varepsilon_{TR}| = \max\left(\left|\frac{\partial\varepsilon_I}{\partial x}\right|, \left|\frac{\partial\varepsilon_{II}}{\partial y}\right|, \left|\frac{\partial\varepsilon_{III}}{\partial z}\right|\right) \quad (3.5)$$

- $\nabla\varepsilon_{TR}$ : Módulo del Gradiente de la Deformación Equivalente Tresca.
- $\varepsilon_I, \varepsilon_{II}, \varepsilon_{III}$ : Componentes principales de la deformación.
- $\left|\frac{\partial\varepsilon_I}{\partial x}\right|, \left|\frac{\partial\varepsilon_{II}}{\partial y}\right|, \left|\frac{\partial\varepsilon_{III}}{\partial z}\right|$ : Valores absolutos de las derivadas parciales de las componentes principales de la deformación respecto a las coordenadas espaciales  $x, y, z$ .

### 6. Módulo del Gradiente de la Anisotropía Fraccional ( $|\nabla FA|$ ) (Soleimanifard et al., 2010; Latorre et al., 2022):

$$|\nabla FA| = \sqrt{\left(\frac{\partial FA}{\partial x}\right)^2 + \left(\frac{\partial FA}{\partial y}\right)^2 + \left(\frac{\partial FA}{\partial z}\right)^2} \quad (3.6)$$

- $FA = \frac{\sqrt{3}}{\sqrt{2}} \cdot \frac{\sqrt{(\lambda_1 - \lambda)^2 + (\lambda_2 - \lambda)^2 + (\lambda_3 - \lambda)^2}}{\sqrt{\lambda_1^2 + \lambda_2^2 + \lambda_3^2}}$ , donde  $\lambda = \frac{\lambda_1 + \lambda_2 + \lambda_3}{3}$ ,  $y \lambda_i = \varepsilon_i + 1$
- $\frac{\partial FA}{\partial x}, \frac{\partial FA}{\partial y}, \frac{\partial FA}{\partial z}$ : Derivadas parciales de la anisotropía fraccional respecto a las coordenadas espaciales  $x, y, z$ .

Además de representar estas variables individualmente, se puede realizar una combinación de estas para mejorar la precisión de la detección del tejido patológico (Latorre et al., 2022). Este proceso implica el análisis de cada variable y su capacidad para identificar las áreas afectadas por el aneurisma (Ver Figura 3.1).




Figura 3.1: Ejemplo entre la combinación A)  $|\nabla\varepsilon_{II}| - |\nabla\varepsilon_{VM}|$  y B)  $|\nabla\varepsilon_{II}| - |\nabla\varepsilon_{II}|$ .

Para determinar que variable o combinación de variables es mejor, primero se realiza un **análisis cualitativo** mediante la observación visual de cómo las distintas combinaciones de variables del gradiente de deformación detectan el contorno del tejido patológico en diferentes estados del modelo, tal y como se muestra en la Figura 3.1. Se generan todas las combinaciones posibles de dos variables entre las seis mencionadas. Esto resulta en 36 combinaciones, de las cuales 18 son únicas (dado que  $0,5 \cdot |\nabla\varepsilon_I| + 0,5 \cdot |\nabla\varepsilon_{II}|$  es igual a  $0,5 \cdot |\nabla\varepsilon_{II}| + 0,5 \cdot |\nabla\varepsilon_I|$ ). Se generan imágenes que muestran cómo cada combinación de variables detecta el tejido patológico. Estas imágenes se observan y se decide visualmente cuál detecta mejor.

Por otro lado, el **análisis cuantitativo** permitirá obtener una evaluación objetiva y numérica de la precisión de las variables seleccionadas, proporcionando una medida adicional de confianza en los resultados obtenidos del análisis cualitativo. De esta manera, se podrá garantizar que la variable elegida no solo es adecuada desde un punto de vista visual y subjetivo, sino que también cumple con criterios rigurosos de precisión y fiabilidad cuantitativa.

Para este análisis se utilizará el modelo  $H_{01}$  (Ver Figura 2.6), ya que cuenta con la geometría más sencilla de tejido patológico. Al algoritmo descrito previamente se le añade una función extra que calculará el porcentaje de volumen real detectado de la siguiente forma. Primero, se obtiene el volumen del tejido patológico real. Luego, se filtran los nodos almacenados usando límites definidos ( $SGV_{limite}$ ) para identificar el tejido patológico. Se eliminan los datos atípicos generados por la geometría del modelo. A partir de esto, se calcula el volumen de la geometría patológica generando una malla de puntos. Finalmente, se determina la relación porcentual entre el volumen patológico detectado y el real. De esta forma, se integran ambos enfoques, cualitativo y cuantitativo, para seleccionar la variable que mejor detecte el tejido patológico, asegurando así una evaluación robusta y precisa.

Posteriormente, se filtra la variable seleccionada para eliminar picos altos que podrían representar datos atípicos o ruido (Ver Figura 3.2). Este proceso es crucial porque los picos altos en los datos pueden ser el resultado de errores de medición, anomalías en la geometría del modelo o ruido introducido durante la simulación. Si estos picos no se eliminan, pueden llevar a una interpretación errónea de los resultados y afectar negativamente la precisión de la detección del tejido patológico.

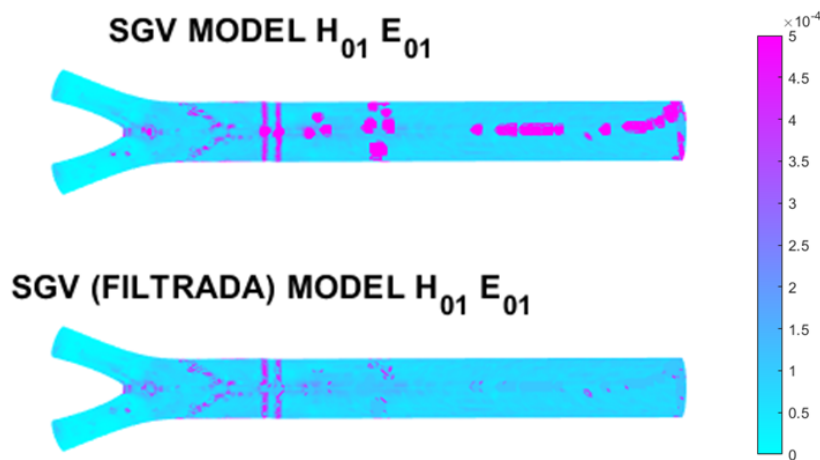


Figura 3.2: Resultado de los mapas de deformación con y sin filtrado.



# Capítulo 4

## Resultados

El presente capítulo se centra en la presentación y análisis de los resultados obtenidos mediante la simulación numérica de AAA y AA. Se examinan los diferentes escenarios simulados para comparar los resultados de los modelos sanos y patológicos, destacando las diferencias y comparando los valores obtenidos con la literatura para validar los modelos. Además, se presentan los mapas de gradientes de deformación generados a partir de los resultados de la simulación, los cuales proporcionan una visión detallada de las áreas críticas y potencialmente propensas al desarrollo de aneurismas. También se discute la efectividad de la metodología para la detección precoz de aneurismas. Este capítulo constituye un análisis exhaustivo de los hallazgos obtenidos a partir de la simulación computacional, que servirá como base para las conclusiones y recomendaciones futuras del estudio.

### 4.1. Simulación numérica de Aorta Abdominal

#### 4.1.1. Simulación numérica de Aorta Abdominal Sana

En este punto se presentan los resultados de la simulación numérica de una AA. Se analizará el mapa de tensión principal máxima, lo cual permite evaluar la tensión fisiología de la AA sana. Este análisis es fundamental para determinar evaluar modelos con aneurisma.

El límite de representación se estableció en 180 kPa (Ver figura 4.1), ya que se considera que a partir de esta tensión puede existir riesgo de rotura (Hall et al., 2000). En el mapa de tensiones se aprecia una distribución muy homogénea, indicando que la AA sana mantiene un comportamiento uniforme bajo condiciones fisiológicas normales. Esta homogeneidad en el mapa de tensiones es esperada en un tejido sano y es crucial para comparar con los modelos que presentan aneurismas.




Figura 4.1: Mapa de tensión principal máxima (kPa) (tensión longitudinal) en el modelo de AA. Limite de representación 180 kPa.

#### 4.1.2. Simulación numérica de AAA

En esta sección se presentan los resultados de la simulación numérica de un AAA. Este análisis es fundamental para determinar el riesgo de rotura del aneurisma, comparando los resultados obtenidos con datos de la bibliografía existente.




Figura 4.2: Mapa de tensión principal máxima (kPa) (tensión longitudinal) en el modelo de AAA. Limite de representación 180 kPa. El dominio gris muestra el tejido que ha superado dicho umbral.

La Figura 4.2 muestra el mapa de tensión principal máxima obtenido a partir de la simulación. En la imagen, se pueden identificar las zonas donde la tensión interna supera el umbral de rotura definido, lo que indica las áreas de mayor riesgo de rotura.

### **Comparación con la bibliografía**

Para evaluar la fiabilidad de los resultados obtenidos, se realiza una comparación con estudios previos sobre la tensión en AAA.

- **Hall et al. (2000)**: Reporta tensiones máximas en AAA de aproximadamente 180 kPa, indicando un riesgo significativo de rotura cuando las tensiones exceden este valor siguiendo la Ley de Laplace.
- **Fillinger et al. (2002)**: Encuentra tensiones máximas que varían entre 240 y 470 kPa, sugiriendo que las tensiones que actúan sobre un AAA no están distribuidas uniformemente y no pueden describirse adecuadamente mediante la Ley de Laplace.

Al comparar estos valores con los obtenidos en la simulación, se observa que las tensiones en las áreas críticas del modelo de AAA están dentro del rango reportado en la literatura, lo que valida la precisión de la simulación numérica. Este análisis comparativo refuerza la utilidad del modelo desarrollado para predecir el comportamiento mecánico de los AAA y evaluar el riesgo de rotura.

### 4.1.3. Simulación numérica de AAA más ILT

En esta sección se presentan los resultados de la simulación numérica de AAA con la inclusión de un ILT. La finalidad es comparar las tensiones en los modelos 01 y 04, correspondientes al modelo con mayor ILT y al modelo con menor ILT, respectivamente. Los resultados adicionales se presentarán en el *Anexo F: Resultados Complementarios*. Este análisis permitirá entender mejor la influencia de añadir ILT en la predicción del riesgo de ruptura.

#### Comparación de Tensiones en Modelos con Diferente Carga de ILT

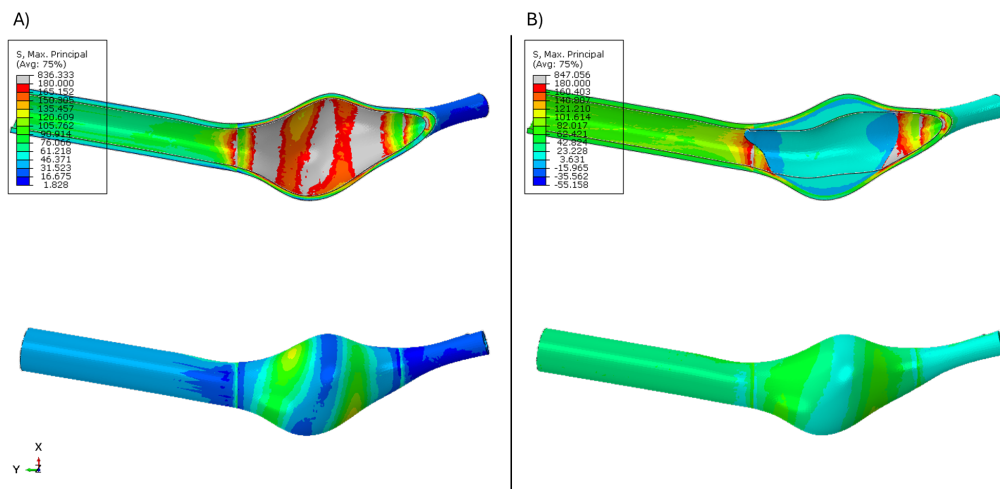


Figura 4.3: Mapa de tensión principal máxima (kPa) en el modelo 01 (mayor ILT) comparado con el modelo AAA.

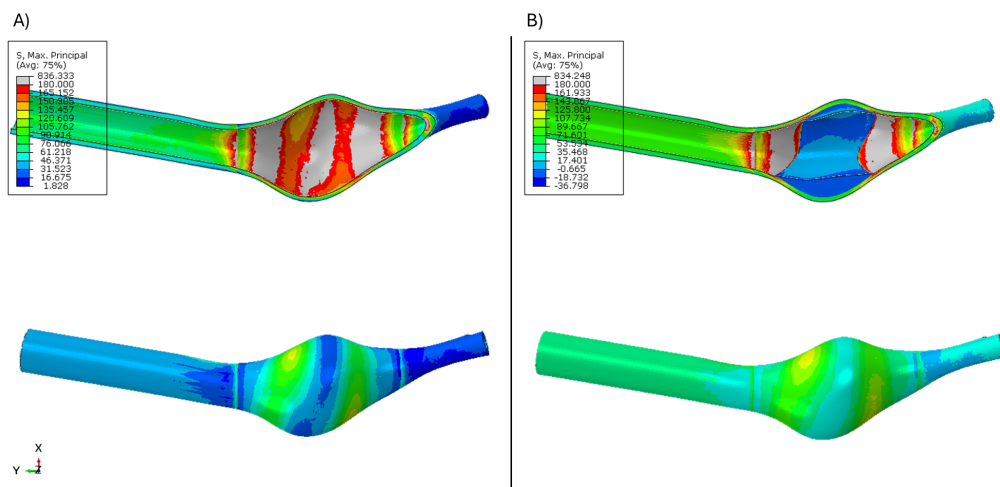


Figura 4.4: Mapa de tensión principal máxima (kPa) en el modelo 04 (menor ILT) comparado con el modelo AAA.

La comparación (Figuras 4.3 y 4.4) entre estos dos modelos revela cómo la presencia y cantidad de ILT influye en la distribución de tensiones dentro y fuera del aneurisma. Un mayor ILT a priori asegura una mayor amortiguación de las tensiones en la pared aórtica disminuyendo así el riesgo de rotura.

### **Influencia del ILT en los AAA**

Distintos estudios han investigado la influencia del ILT en los AAA. En Wang et al. (2002) se encontró que la presencia de ILT puede reducir las tensiones en la pared del aneurisma, actuando como un amortiguador mecánico que distribuye las cargas de manera más uniforme.

Al comparar los resultados obtenidos con estos estudios, se puede concluir que el ILT tiene un impacto significativo en la biomecánica de los AAA. En el modelo 01, con mayor carga de ILT, las tensiones máximas en la pared del aneurisma son menores en comparación con el modelo 04, con menor ILT. Esto sugiere que el ILT puede actuar como un elemento protector en ciertos escenarios.

## 4.2. Metodología de detección temprana

En esta sección se discutirá la metodología utilizada para identificar la variable más efectiva en la detección temprana de AAA. Este proceso se basa en análisis cualitativos y cuantitativos.

### 4.2.1. Análisis Cualitativo

En la figura 4.5, se muestra la detección del contorno de tejido patológico para el modelo  $H_{01}$  en dos estados distintos:  $E_{01}$  (tejido patológico al 100%) y  $E_{06}$  (tejido casi sano). Este modelo presenta una geometría sana con un anillo de propiedades patológicas alrededor de la aorta, permitiendo analizar cómo las diferentes configuraciones de tejido patológico afectan la detección del contorno y la progresión del aneurisma.

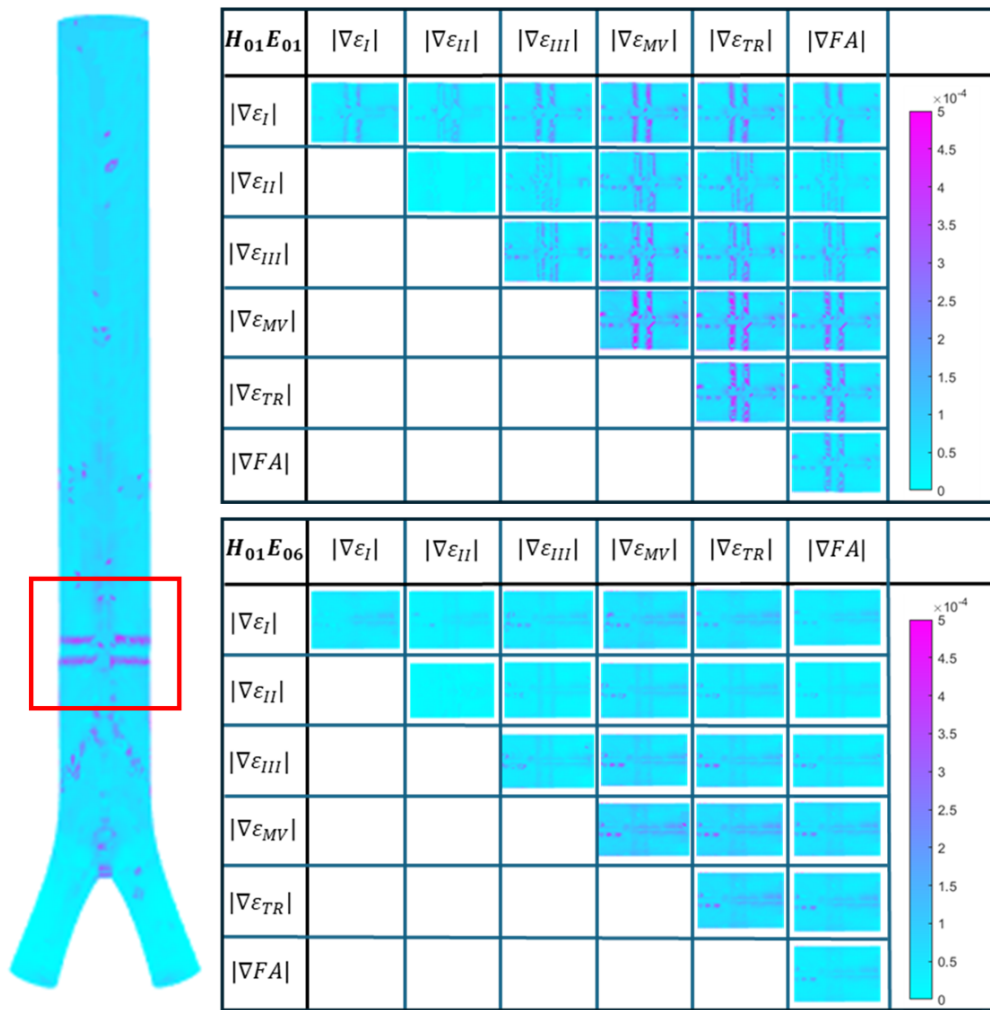


Figura 4.5: Análisis cualitativo de detección de tejido patológico para el modelo  $H_{01}$  en el estado  $E_{01}$  y  $E_{06}$ .

A partir de las imágenes generadas, se realiza un análisis cualitativo observando cuáles combinaciones de variables detectan mejor el contorno del tejido patológico. Esto se resume en las tablas 4.1 y 4.2, donde se categoriza la efectividad de cada combinación utilizando la siguiente leyenda de colores:

$H_{01} E_{01}$	$ \nabla\varepsilon_I $	$ \nabla\varepsilon_{II} $	$ \nabla\varepsilon_{III} $	$ \nabla\varepsilon_{VM} $	$ \nabla\varepsilon_{TR} $	$ \nabla FA $
$ \nabla\varepsilon_I $	■	■	■	■	■	■
$ \nabla\varepsilon_{II} $		■	■	■	■	■
$ \nabla\varepsilon_{III} $			■	■	■	■
$ \nabla\varepsilon_{VM} $				■	■	■
$ \nabla\varepsilon_{TR} $					■	■
$ \nabla FA $						■

Tabla 4.1: Análisis cualitativo de detección del contorno del tejido patológico para el modelo  $H_{01} - E_{01}$ . Leyenda: Verde, Detección Sólida con Baja Probabilidad de Contaminación de Ruido; Amarillo, Detección Moderada con Posible Contaminación de Ruido y Rojo, Nivel de Detección Mínimo.

$H_{01} E_{01}$	$ \nabla\varepsilon_I $	$ \nabla\varepsilon_{II} $	$ \nabla\varepsilon_{III} $	$ \nabla\varepsilon_{VM} $	$ \nabla\varepsilon_{TR} $	$ \nabla FA $
$ \nabla\varepsilon_I $	■	■	■	■	■	■
$ \nabla\varepsilon_{II} $		■	■	■	■	■
$ \nabla\varepsilon_{III} $			■	■	■	■
$ \nabla\varepsilon_{VM} $				■	■	■
$ \nabla\varepsilon_{TR} $					■	■
$ \nabla FA $						■

Tabla 4.2: Análisis cualitativo de detección del contorno del tejido patológico para el modelo  $H_{01} - E_{06}$ . Leyenda: Verde, Detección Sólida con Baja Probabilidad de Contaminación de Ruido; Amarillo, Detección Moderada con Posible Contaminación de Ruido y Rojo, Nivel de Detección Mínimo.

Del análisis cualitativo se extrae que las mejores combinaciones son  $|\nabla\varepsilon_{VM}|$ ,  $|\nabla\varepsilon_{TR}|$  y  $|\nabla FA|$  combinadas entre ellas, así como  $|\nabla\varepsilon_{VM}|$  y  $|\nabla\varepsilon_{TR}|$  combinadas con  $|\nabla\varepsilon_I|$ . Tal y como cabía esperar, cuanto mayor es la diferencia entre el tejido sano y el tejido patológico, mejor se detecta el contorno del tejido patológico. Esto demuestra la efectividad de utilizar gradientes de deformación para identificar áreas críticas en diferentes estados del tejido.

El análisis cualitativo se basa en la observación visual y la interpretación subjetiva de los resultados, lo cual no es suficiente para determinar qué variable o combinación de variables detecta mejor el tejido patológico en este contexto. Para asegurar la robustez y validez de la selección de variables, se procederá a realizar un análisis cuantitativo.

## 4.2.2. Análisis Cuantitativo

Al igual que en el análisis cualitativo, se ha utilizado el modelo  $H_{01}$ , ya que cuenta con la geometría más sencilla de tejido patológico. Siguiendo la metodología descrita en el punto 3.2 se obtienen las siguientes relaciones porcentuales:

A) %	SGV (I)	SGV (II)	SGV (III)	SGV (MV)	SGV (TRESCA)	SGV (FA)
SGV (I)	70.8057%	65.1065%	70.9198%	85.1661%	78.9494%	69.7438%
SGV (II)		53.7156%	71.8875%	81.6316%	77.8151%	69.3840%
SGV (III)			76.7520%	93.2709%	86.4830%	71.3455%
SGV (MV)				95.2117%	94.0625%	86.9832%
SGV (TRESCA)					92.1584%	79.9694%
SGV (FA)						70.9545%

B) %	SGV (I)	SGV (II)	SGV (III)	SGV (MV)	SGV (TRESCA)	SGV (FA)
SGV (I)	7.9495%	0.0000%	2.7685%	62.0989%	56.8310%	2.6198%
SGV (II)		0.0000%	0.0000%	35.9288%	0.0000%	0.0000%
SGV (III)			25.5376%	46.9865%	62.7662%	4.8043%
SGV (MV)				88.5131%	85.6065%	63.0599%
SGV (TRESCA)					78.1212%	56.1642%
SGV (FA)						0.0000%

-	Detección Perfecta
-	Detección Alta
-	Detección Moderada
-	Detección Baja
-	Detección Mínima

Figura 4.6: Relación porcentual entre volumen patológico detectado y volumen patológico real para los modelos  $H_{01}$  en los estados A)  $E_{01}$  y B)  $E_{06}$ . Límite de filtrado:  $SGV_{limite} = 10^{-4}$ .

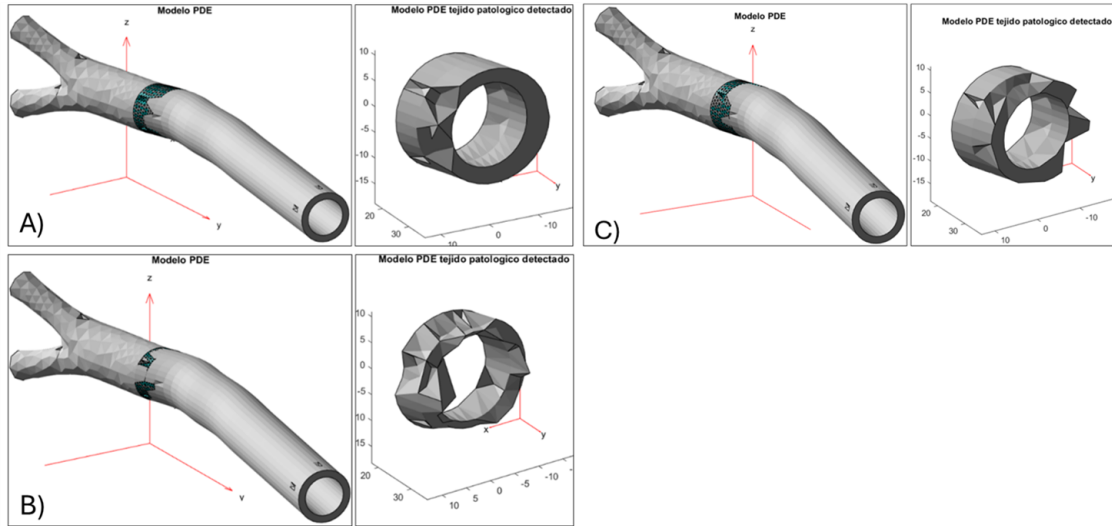


Figura 4.7: A) Análisis  $|\nabla\varepsilon_{VM}| - |\nabla\varepsilon_{VM}|$  del modelo  $H_{01}-E_{01}$ . Detección del 95.2117% del tejido patológico. B) Análisis  $|\nabla\varepsilon_{II}| - |\nabla\varepsilon_{II}|$  del modelo  $H_{01}-E_{01}$ . Detección del 53.7156% del tejido patológico. C) Análisis  $|\nabla\varepsilon_{VM}| - |\nabla\varepsilon_{VM}|$  del modelo  $H_{01}-E_{06}$ . Detección del 88.5131% del tejido patológico. Límite de detección  $10^{-4}$ .

La Figura 4.6 presenta la relación porcentual entre el volumen patológico detectado y el volumen patológico real para los estados  $E_{01}$  y  $E_{06}$  del modelo  $H_{01}$ , con un límite de filtrado de  $SGV_{limite} = 10^{-4}$ . Estos resultados evalúan la precisión del modelo en diferentes estados del aneurisma. La Figura 4.7 muestra un análisis detallado de la detección de tejido patológico utilizando diferentes combinaciones de variables del gradiente de deformación.

Al filtrar los nodos, si se usa un límite menor ( $SGV_{limite} = 7 \cdot 10^{-5}$ ), los porcentajes de detección serán los siguientes:

%	SGV (I)	SGV (II)	SGV (III)	SGV (MV)	SGV (TRESCA)	SGV (FA)
SGV (I)	83.6688%	78.0461%	88.0138%	97.6234%	95.7664%	82.7938%
SGV (II)		73.1243%	89.7792%	97.3275%	95.4837%	79.1534%
SGV (III)			96.8316%	97.6284%	97.6284%	92.2512%
SGV (MV)				99.1166%	99.1046%	95.2117%
SGV (TRESCA)					99.0012%	94.0625%
SGV (FA)						80.9195%

%	SGV (I)	SGV (II)	SGV (III)	SGV (MV)	SGV (TRESCA)	SGV (FA)
SGV (I)	58.4257%	0.0000%	63.2934%	92.8673%	85.9277%	2.6198%
SGV (II)		0.0000%	0.0000%	35.9288%	0.0000%	0.0000%
SGV (III)			64.1322%	90.6564%	83.1035%	60.4530%
SGV (MV)				98.5180%	98.4751%	91.7658%
SGV (TRESCA)					97.1848%	85.1745%
SGV (FA)						0.0000%

-	Detección Perfecta
-	Detección Alta
-	Detección Moderada
-	Detección Baja
-	Detección Mínima

Figura 4.8: Relación porcentual entre volumen patológico detectado y volumen patológico real para los modelos  $H_{01}$  en los estados A)  $E_{01}$  y B)  $E_{06}$ . Límite de filtrado:  $SGV_{limite} = 7 \cdot 10^{-5}$ .

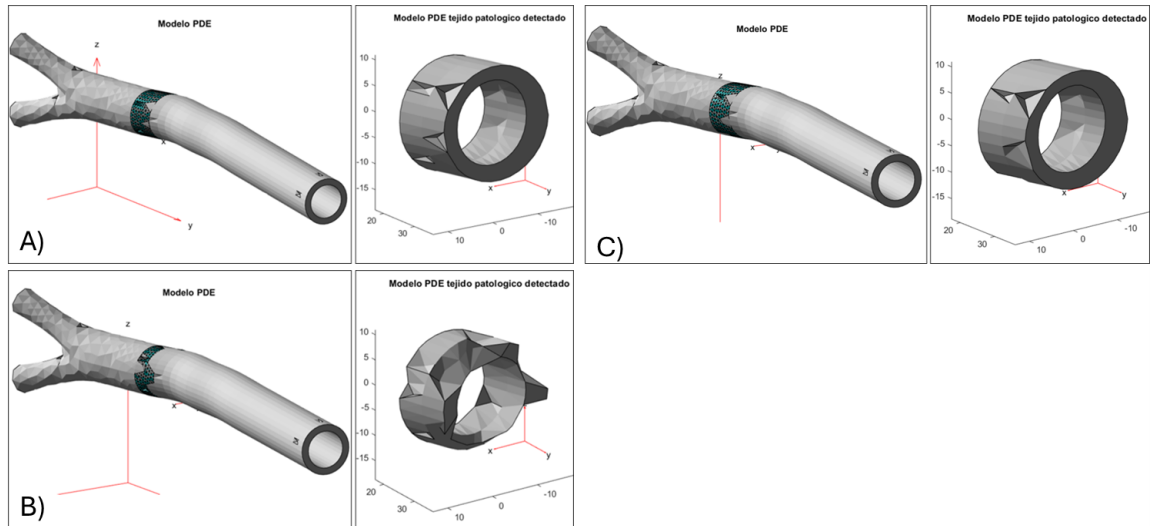


Figura 4.9: A) Análisis  $|\nabla\varepsilon_{VM}| - |\nabla\varepsilon_{VM}|$  del modelo  $H_{01}-E_{01}$ . Detección del 99.1166 % del tejido patológico. B) Análisis  $|\nabla\varepsilon_{II}| - |\nabla\varepsilon_{II}|$  del modelo  $H_{01} E_{01}$ . Detección del 73.1243% del tejido patológico. C) Análisis  $|\nabla\varepsilon_{VM}| - |\nabla\varepsilon_{VM}|$  del modelo  $H_{01}-E_{06}$ . Detección del 98.5180 % del tejido patológico. Límite de detección  $7 \cdot 10^{-5}$ .

De estos resultados se deduce que a menor límite, mayor será el tejido detectado. Esto se debe a que al reducir el valor de  $SGV_{límite}$ , se permite que más nodos sean considerados como parte del tejido patológico, incrementando así la sensibilidad del algoritmo. Es importante resaltar que, aunque los valores específicos cambian en las tablas al ajustar el límite de detección, los resultados cualitativos permanecen constantes. Las variables efectivas en la detección del tejido patológico con un límite de detección más alto continúan mostrando buenos resultados con un límite más bajo. Sin embargo, una mayor sensibilidad puede llevar a la inclusión de tejido sano, comprometiendo la especificidad del algoritmo y aumentando el riesgo de falsos positivos. Por lo tanto, es crucial encontrar un balance adecuado en la selección del límite de detección, equilibrando el riesgo de falsos positivos con el de falsos negativos.

Así, tras los dos análisis realizados, se concluyó que la mejor variable para analizar era la combinación  $|\nabla_{\varepsilon_{VM}}| - |\nabla_{\varepsilon_{VM}}|$ , es decir,  $|\nabla_{\varepsilon_{VM}}|$ . Esta decisión se basó en varios factores observados durante los análisis. En el análisis cualitativo, las imágenes correspondientes la variable  $|\nabla_{\varepsilon_{VM}}|$  demostraron una capacidad superior para resaltar las áreas patológicas, facilitando la identificación precisa de las zonas afectadas. En el análisis cuantitativo, la variable  $|\nabla_{\varepsilon_{VM}}|$  mostró una alta relación porcentual entre el volumen patológico detectado y el volumen patológico real, detectando hasta el 95.2% del tejido patológico en el modelo  $H_{01}-E_{01}$  y el 88.5% en el modelo  $H_{01}-E_{06}$ .

En resumen, **la variable  $|\nabla_{\varepsilon_{VM}}|$  fue seleccionada como el mejor predictor para detectar tejido patológico** debido a su excelente desempeño tanto en el análisis cualitativo como en el cuantitativo. Esta combinación ofrece una detección precisa y fiable del tejido patológico, garantizando así la efectividad del método propuesto en la predicción temprana de AAA.

### 4.3. Mapas de gradientes de deformación.

En esta sección se presentan los mapas de gradientes de deformación obtenidos después de aplicar la metodología explicada en el capítulo 3, teniendo en cuenta la variable seleccionada para analizar ( $|\nabla_{\varepsilon_{VM}}|$ ). Estos mapas permiten visualizar y analizar las zonas con mayores deformaciones, lo que es crucial para la detección temprana de AAA y la evaluación del riesgo de ruptura.

#### 4.3.1. Análisis de Modelos con Heterogeneidades

En esta sección se analizarán los modelos con heterogeneidades  $H_{01}$ ,  $H_{05}$  y  $H_{10}$  (Figura 4.10). Se evaluarán siete estados diferentes en función de la progresión de la enfermedad, donde el Estado 1 ( $E_{01}$ ) corresponde al tejido con aneurisma y el Estado 7 ( $E_{07}$ ) corresponde al tejido sano. Este análisis permite observar cómo varían las propiedades mecánicas y de detección del tejido a lo largo del desarrollo de la enfermedad. El resto de los modelos se presentarán en el *Anexo F: Resultados Complementarios*.




Figura 4.10: Tejido patológico al que se le aplicó la metodología.

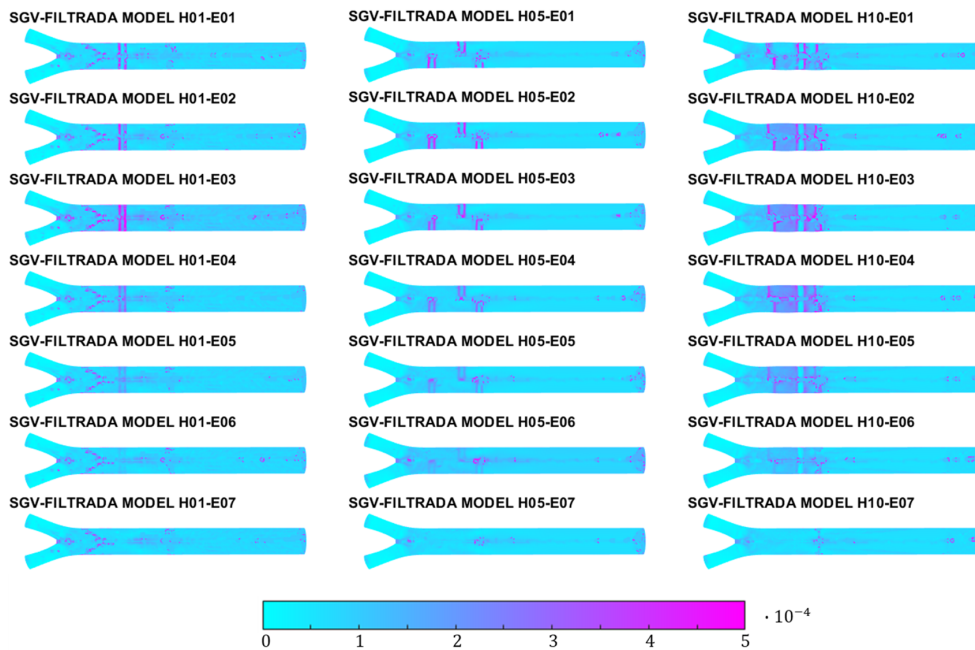


Figura 4.11: Comparación de  $|\nabla_{\varepsilon_{VM}}|$  para los modelos con heterogeneidades  $H_{01}$ ,  $H_{05}$  y  $H_{10}$  a lo largo de los 7 estados.

La Figura 4.11 muestra la evolución de los mapas de gradiente de deformación para los modelos con heterogeneidades  $H_{01}$ ,  $H_{05}$  y  $H_{10}$  a lo largo de 7 estados. Permite observar cómo la cantidad y configuración del tejido patológico afectan la detección. En los estados iniciales ( $E_{01}$  a  $E_{03}$ ), con mayor proporción de tejido patológico, hay una mayor concentración de gradientes de deformación en las áreas afectadas. En los estados con menos tejido patológico ( $E_{04}$  a  $E_{07}$ ), la homogeneidad del tejido sano es más evidente y los gradientes disminuyen significativamente. En el modelo  $H_{01}$ , con una geometría sana y un anillo patológico, se detecta claramente el contorno del tejido patológico en los primeros estados. En el modelo  $H_{05}$ , con una configuración más compleja, las heterogeneidades impactan la distribución del gradiente de deformación. El modelo  $H_{10}$ , con la mayor complejidad, muestra una evolución gradual en la detección, destacando la efectividad del gradiente de deformación  $|\nabla\varepsilon_{VM}|$  como predictor en diferentes configuraciones y estados de la enfermedad. Estos resultados subrayan la importancia de usar mapas de gradiente de deformación para la detección temprana y precisa de tejido patológico en AAA.

La figura 4.12 compara la detección en el estado con mayor tejido patológico ( $E_{01}$ ) y el estado con menor ( $E_{06}$ ). El estado crítico ( $E_{01}$ ) muestra una buena detección del aneurisma, mientras que el estado ( $E_{06}$ ), casi sano, es el más desafiante para identificar correctamente el tejido patológico.



Figura 4.12: Comparación de la detección en el caso más favorable ( $E_{01}$ ) y el caso más crítico ( $E_{06}$ ).

La metodología es más precisa en modelos con tejido patológico simple y de menor volumen (modelos  $H_{01}$  y  $H_{05}$ , estado  $E_{01}$ ). Sin embargo, esta precisión disminuye en casos más complejos y críticos (estado  $E_{06}$ , modelo  $H_{10}$ ) debido a la mayor heterogeneidad y distribución del tejido patológico. Así, la complejidad y el volumen del tejido afectan significativamente la efectividad del método de detección.

### 4.3.2. Influencia de los Instantes de Presión Seleccionados

Se analizará la influencia de los instantes de presión seleccionados para la selección de datos y cómo estos afectan al ruido de los resultados utilizando el modelo  $H_{05}$ . Este análisis es crucial para entender cómo la temporalidad de las mediciones puede influir en la precisión de la detección del tejido patológico.



Figura 4.13: Influencia del intervalo de presión seleccionado para la selección de datos en el modelo  $H_{05}$ .

Uno de los principales problemas, además de la geometría y el dominio de tejido patológico, es la confusión que puede surgir al confundir ruido con tejido patológico. Inicialmente, se aplicó la metodología en el intervalo de presiones (120-115) mmHg. Una posible solución para asegurar si algo es ruido fue calcular distintos instantes de presión (Figura 4.13).

**SGV-FILTRADA MODEL H05-E02 INSTANTE 120-115**



**SGV-FILTRADA MODEL H05-E02 INSTANTE 090-085**



Figura 4.14: Influencia en el ruido para dos intervalos (120-115) y (90-85) mmHg.

Como se observa en la Figura 4.14, se puede deducir que la comparación de los resultados obtenidos en diferentes intervalos de presión puede ayudar a distinguir el ruido del tejido patológico real. Al comparar los intervalos de presión (120-115) y (90-85) mmHg, se nota que el ruido presente en los resultados varía, lo que sugiere que analizar varios instantes de presión pueden proporcionar datos más fiables para la detección de tejido patológico.

Este enfoque de comparar distintos intervalos de presión representa una primera posible solución para mejorar la precisión de la detección, minimizando la influencia del ruido y asegurando que las áreas identificadas como patológicas sean realmente representativas del tejido afectado. El ruido puede deberse a la metodología, al aproximar el comportamiento con la teoría de pequeñas deformaciones, así como a la precisión de los resultados del post-procesado en MATLAB. Los decimales de los resultados que vienen de Abaqus a veces generan imprecisiones puntuales. La elección de los instantes de presión adecuados es, por tanto, un factor clave en la optimización de la metodología propuesta.

### 4.3.3. Comparación entre AAA y AAA con ILT

Por último, se analizó la capacidad de esta metodología para detectar grandes aneurismas completos y cómo podría llegar a influir si estas contaban con ILT. Para ello se compararán también los mapas de gradiente de deformación de los modelos AAA y AAA con ILT 01 y 04, el resto de los modelos se presentarán en el *Anexo F: Resultados Complementarios*. Esta comparación permitirá evaluar cómo la presencia y cantidad de ILT influye en la distribución del gradiente de deformaciones.




Figura 4.15: Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 01.




Figura 4.16: Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 04.

Las figuras 4.15 y 4.16 muestran los mapas de gradiente de deformación comparando el modelo AAA con los modelos ILT 01 e ILT 04, respectivamente. En estas figuras, se observan gradientes muy marcados debido a los cambios de sección (diámetro-espesor) de la zona patológica, lo cual provoca un aumento en el gradiente de deformaciones. Estos cambios contribuyen a resaltar las áreas críticas y facilitan la detección de tejido patológico. El mapa de gradiente de deformación en la Figura 4.15 muestra un modelo AAA con una carga elevada de ILT, destacando las áreas de mayor deformación y facilitando la identificación de regiones patológicas. Sin embargo, este incremento en la detección viene acompañado de un aumento en el ruido, lo cual puede complicar la interpretación precisa de los resultados. Al reducir el tamaño del ILT, como se observa en la Figura 4.16, se mantiene el nivel de ruido, pero de manera menos notable, permitiendo una visualización mejorada de las áreas deformadas. Esto sugiere que un tamaño moderado de ILT podría ser más adecuado para la detección del tejido patológico sin incrementar significativamente el ruido.



# Capítulo 5

## Conclusiones

En este capítulo se exponen las principales conclusiones y limitaciones obtenidas en este estudio y se plantean posibles líneas futuras de investigación como continuación.

### 5.1. Conclusiones

El objetivo principal de este trabajo ha consistido en la caracterización experimental del comportamiento biomecánico de los aneurismas de aorta abdominal para desarrollar una metodología que permita su detección temprana. Se ha definido una metodología numérica para predecir la evolución de los AAA, utilizando simulaciones de elementos finitos con modelos paramétricos y datos de pacientes reales. La **metodología se ha implementado y validado** mediante el software de elementos finitos ABAQUS y el software de cómputo numérico Matlab.

Tras analizar múltiples combinaciones de variables, se concluye que la precisión del método depende de las variables elegidas. La variable  $|\nabla\varepsilon_{VM}|$  proporciona los resultados más precisos.

Los modelos de elementos finitos propuestos reproducen el comportamiento biomecánico de las arterias abdominales con y sin aneurismas, así como con la presencia de ILT. La metodología desarrollada detecta áreas propensas a la formación de AAA mediante mapas de gradientes de deformación. Este proceso también permite detectar áreas de tejido patológico en geometrías idealizadas. Es efectiva para la detección precoz y el seguimiento de aneurismas en etapas iniciales, cuando los cambios geométricos aún no son evidentes. Sin embargo, cuando el aneurisma está completamente desarrollado y es detectable mediante técnicas de imagen clínica, la metodología no aporta información adicional significativa.

## 5.2. Limitaciones

La simulación de los AAA ha permitido replicar el comportamiento analítico de la aorta abdominal en diversas condiciones, pero no garantiza una reproducción exacta en un entorno clínico debido a:

1. Las curvas experimentales de tejido no distinguían entre capas de la aorta, por lo que se construyó un modelo monocapa.
2. Las heterogeneidades en el modelo son geométricas y no reflejan completamente la realidad.
3. El ruido generado por la triangulación de la geometría del modelo podría aumentar con geometrías más complejas.

En conclusión, a pesar de las limitaciones mencionadas, la metodología desarrollada para la detección temprana de aneurismas de aorta abdominal mediante simulaciones computacionales es válida en una primera aproximación.

## 5.3. Líneas futuras

Este estudio es relevante para la detección temprana de aneurismas de aorta abdominal mediante simulaciones computacionales y sienta las bases para futuras investigaciones en biomecánica vascular. Algunas líneas futuras son:

- Validar y mejorar la metodología con datos clínicos reales.
- Diferenciar entre capas de la aorta en el modelo numérico para obtener resultados más precisos.
- Introducir heterogeneidades más realistas en las geometrías simuladas.
- Mejorar la detección del ruido mediante técnicas avanzadas de filtrado y análisis de datos.
- Ampliar el estudio a otras localizaciones y tipos de aneurismas, como los torácicos.

# Capítulo 6

## Bibliografía

- J. Duarte Pineda Adoni and Nicolás Sabillón. Aneurismas. revisión bibliográfica. Revista de Ciencias Forenses de Honduras, 2017.
- B. Alleva. Capas de las arterias: Una mirada a la histología de los vasos sanguíneos. Fisioterapia Sol y Luz, 2023.
- L. Bravo-Merino, N. Gonzalez-Lozano, R. Maroto-Salmon, G. Meijide-Santos, P. Suarez-Gil, and A. Fañanas-Mastral. Validez de la ecografía abdominal en atención primaria para detección de aneurisma de aorta abdominal en varones de entre 65 y 75 años. Elsevier, 2017.
- R. Brouhard. La anatomía de la aorta abdominal. Medsalud, 2023.
- CDC. Aortic aneurysm statistics. Centers for Disease Control and Prevention (CDC), 2023.
- M. Cilla. Technical effects on the atheroma plaque appearance, growth and vulnerability. Universidad de Zaragoza. Escuela de ingeniería y arquitectura, 2013.
- M. F. Fillinger, M. L. Raghavan, S. P. Marra, J. L. Cronenwett, and F. E. Kennedy. In vivo analysis of mechanical wall stress and abdominal aortic aneurysm rupture risk. J Vasc Surg, 2002.
- Z. Gao, J. Xiong, Z. Chen, X. Deng, Z. Xu, A. Sun, and Y. Fan. Gender differences of morphological and hemodynamic characteristics of abdominal aortic aneurysm. BMC, 2020.
- T. C. Gasser, R. W. Ogden, and G. A. Holzapfel. Hyperelastic modelling of arterial layers with distributed collagen fibre orientations. Journal of the Royal Society, 2006.

- V. Geest, J. P. Sacks, and M. S. Vorp. A planar biaxial constitutive relation for the luminal layer of intra-luminal thrombus in abdominal aortic aneurysms. J. Biomech, 2006.
- C. Hacking, J. Jones, and D. Bell. Aortic aneurysm. Radiopaedia, 2023.
- A. J. Hall, E. F. Busse, D. J. McCarville, and J. J. Burgess. Aortic wall tension as a predictive factor for abdominal aortic aneurysm rupture: improving the selection of patients for abdominal aortic aneurysm repair. Ann Vasc Surg, 2000.
- D. Hibbitt, B. Karlsson, and P. Sorensen. Abaqus unified fea. <https://www.3ds.com/es/productos-y-servicios/simulia/productos/abaqus/>, 2017.
- J. Hirschtick. Solidworks. <https://www.solidworks.com/es>, 2024.
- G. A. Holzapfel and T. C. Gasser. A new constitutive framework for arterial wall mechanics and a comparative study of material models. Journal of Elasticity, 2000.
- V. Kumar, A.K. Abbas, and J.C. Aster. Robbins y cotran. patología estructural y funcional. Elsevier, 2015.
- C. Lahoz, C. Gracia, L. García, S. Montoya, Á. Hernando, and Á. Heredero. Sea-seacv 2015: Guía para el diagnóstico y tratamiento del aneurisma de aorta abdominal. Clin Investig Arterioscler, 2016.
- Á. T. Latorre, M. A. Martínez, M. Cilla, J. Ohayón, and E. Peña. Atherosclerotic plaque segmentation based on strain gradients: A theoretical framework. Mathematics, 2022.
- D. T. Manapurathe, J. V. Moxon, S. M. Krishna, F. Quigley, M. Bourke, B. Bourke, R. E. Jones, and J. Golledge. Cohort study examining the association of optimal blood pressure control at entry with infrarenal abdominal aortic aneurysm growth. Front. Cardiovasc. Med., 2022.
- Felix Nieto Palomo. Predicción del riesgo de ruptura de aneurismas de aorta abdominal. método basado en los biodeterminantes geométricos. Universidad de Valladolid. Escuela de ingenierías industriales, 2016.
- NIH. ¿qué es un aneurisma de aorta? National Heart, Lung and Blood Institute, 2022.
- S. S. Patnaik, S. Piskin, N. R. Pillalamarri, G. Romero, G. P. Escobar, E. Sprague, and E. A. Finol. Biomechanical restoration potential of pentagalloyl glucose after arterial extracellular matrix degeneration. J. Bioengineering, 2019.

- A. Piechota-Polanczyk, A. Jozkowicz, W. Nowak, W. Eilenberg, C. Neumayer, T. Malinski, I. Huk, and C. Brostjan. The abdominal aortic aneurysm and intraluminal thrombus: Current concepts of development and treatment. Front Cardiovasc Med, 2015.
- M. L. Raghavan, B. Ma, and M. F. Fillingier. Non-invasive determination of zero-pressure geometry of arterial aneurysms. Ann Biomed Eng, 2006.
- G. G. Salzler, E. J. Ryer, R. W. Abdu, A. Lanyado, T. Sagiv, E. N. Choman, A. A. Tariq, J. Urick, E. G. Mitchell, R. M. Maff, G. DeLong, S. L. Shriner, and J. R. Elmore. Development and validation of a machine-learning prediction model to improve abdominal aortic aneurysm screening. J Vasc Surg, 2024.
- Servei. Aneurisma de aorta abdominal. Sociedad Española de Radiología Vascul ar e Intervencionista, 2023.
- S. Soleimanifard, K. Z. Abd-Elmoniem, H. K. Agarwal, M. S. Tomás, T. Sasuno, E. Vonken, A. Youssef, M. R. Abraham, T. P. Abraham, and J. L. Prince. Identification of myocardial infarction using three-dimensional strain tensor fractional anisotropy. Institute of Electrical and Electronic Engineers. International Symposium on Biomedical Imaging: From Nano to Macro, 2010.
- E. Soudah, G. Vilalta, M. Bordone, F. Nieto, J. A. Vilalta, and C. Vaquero. Estudio paramétrico de tensiones hemodinámicas en modelos de aneurismas de aorta abdominal. Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería, 2014.
- Stanford. Aneurisma cerebral. Stanford Medicine University. Children’s Health, 2024.
- N. Ullah, W. K. Chou, R. Vardanyan, A. A. Rad, V. Shah, S. Torabi, D. Avavde, A. A. Airapetyan, A. Zubarevich, A. Weymann, A. Ruhparwar, G. Miller, and J. Malawana. Development and validation of a machine-learning prediction model to improve abdominal aortic aneurysm screening. Minerva Medica, 2024.
- H. J. Wang, S. Makaroun, W. Webster, and A. Vorp. Effect of intraluminal thrombus on wall stress in patient-specific models of abdominal aortic aneurysm. J Vasc Surg, 2002.
- A. Wanhainen, I. Van Herzelee, F. B. Goncalves, S. Bellmunt Montoya, X. Berard, J. R. Boyle, and M. D’Oria. European society for vascular surgery (esvs) 2024 clinical practice guidelines on the management of abdominal aorto-iliac artery aneurysms. J Vasc Endovasc Surg, 2024.



# Lista de Figuras

1.1. Diferencia entre AAA y aorta abdominal sana (Servei, 2023). . . . .	3
1.2. Esquema del proceso desde la obtención de imágenes médicas / modelos de bibliografía hasta la construcción de mapas de gradientes de deformación. . . . .	6
2.1. Modelo geométrico base y sus dimensiones para la AA sana (Patnaik et al., 2019). . . . .	10
2.2. Adaptación del modelo geométrico. A) Obtención de la curva de las vértebras lumbares. Curva de las vértebras lumbares conectando el punto medio de las cinco vértebras lumbares mostradas en azul (Gao et al., 2020). B) Modelo utilizado en el estudio presente una vez aplicada la curvatura . . . . .	11
2.3. Adaptación del modelo geométrico para AA sana monocapa. . . . .	11
2.4. Adaptación del modelo geométrico para AAA monocapa. A) Modelo geométrico base y sus dimensiones para la aorta abdominal patológica (Patnaik et al., 2019). B) Modelo utilizado en el estudio presente de AAA monocapa. . . . .	12
2.5. Modelo 01 utilizado en el estudio presente de AAA monocapa con ILT.	13
2.6. Modelo utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	14
2.7. Condiciones de contorno aplicadas.A) Modelo completo, B) detalle de condición aplicada a la generatriz, C) bloqueo de las caras inferiores y D) bloqueo de la cara superior. . . . .	17
2.8. Presión sistólica aplicada en el modelo MEF. . . . .	18
2.9. Modelo AAA pre-GCP y post-GCP. . . . .	21
2.10. Detalle del espesor del modelo AAA pre-GCP y post-GCP. . . . .	21
2.11. Esquema de algoritmo pull back empleado por Raghavan et al. (2006) .	22

3.1.	Ejemplo entre la combinación A) $ \nabla\varepsilon_{II} $ $ \nabla\varepsilon_{VM} $ y B) $ \nabla\varepsilon_{II} $ $ \nabla\varepsilon_{II} $ .	28
3.2.	Resultado de los mapas de deformación con y sin filtrado. . . . .	29
4.1.	Mapa de tensión principal máxima (kPa) (tensión longitudinal) en el modelo de AA. Limite de representación 180 kPa. . . . .	32
4.2.	Mapa de tensión principal máxima (kPa) (tensión longitudinal) en el modelo de AAA. Limite de representación 180 kPa. El dominio gris muestra el tejido que ha superado dicho umbral. . . . .	32
4.3.	Mapa de tensión principal máxima (kPa) en el modelo 01 (mayor ILT) comparado con el modelo AAA. . . . .	34
4.4.	Mapa de tensión principal máxima (kPa) en el modelo 04 (menor ILT) comparado con el modelo AAA. . . . .	34
4.5.	Análisis cualitativo de detección de tejido patológico para el modelo $H_{01}$ en el estado $E_{01}$ y $E_{06}$ . . . . .	36
4.6.	Relación porcentual entre volumen patológico detectado y volumen patológico real para los modelos $H_{01}$ en los estados A) $E_{01}$ y B) $E_{06}$ . Límite de filtrado: $SGV_{limite} = 10^{-4}$ . . . . .	38
4.7.	A) Análisis $ \nabla\varepsilon_{VM} $ $ \nabla\varepsilon_{VM} $ del modelo $H_{01}$ - $E_{01}$ . Detección del 95.2117 % del tejido patológico. B) Análisis $ \nabla\varepsilon_{II} $ $ \nabla\varepsilon_{II} $ del modelo $H_{01}$ $E_{01}$ . Detección del 53.7156 % del tejido patológico. C) Análisis $ \nabla\varepsilon_{VM} $ $ \nabla\varepsilon_{VM} $ del modelo $H_{01}$ - $E_{06}$ . Detección del 88.5131 % del tejido patológico. Límite de detección $10^{-4}$ . . . . .	38
4.8.	Relación porcentual entre volumen patológico detectado y volumen patológico real para los modelos $H_{01}$ en los estados A) $E_{01}$ y B) $E_{06}$ . Límite de filtrado: $SGV_{limite} = 7 \cdot 10^{-5}$ . . . . .	39
4.9.	A) Análisis $ \nabla\varepsilon_{VM} $ $ \nabla\varepsilon_{VM} $ del modelo $H_{01}$ - $E_{01}$ . Detección del 99.1166 % del tejido patológico. B) Análisis $ \nabla\varepsilon_{II} $ $ \nabla\varepsilon_{II} $ del modelo $H_{01}$ $E_{01}$ . Detección del 73.1243 % del tejido patológico. C) Análisis $ \nabla\varepsilon_{VM} $ $ \nabla\varepsilon_{VM} $ del modelo $H_{01}$ - $E_{06}$ . Detección del 98.5180 % del tejido patológico. Límite de detección $7 \cdot 10^{-5}$ . . . . .	39
4.10.	Tejido patológico al que se le aplico la metodología. . . . .	41
4.11.	Comparación de $ \nabla\varepsilon_{VM} $ para los modelos con heterogeneidades $H_{01}$ , $H_{05}$ y $H_{10}$ a lo largo de los 7 estados. . . . .	41
4.12.	Comparación de la detección en el caso más favorable ( $E_{01}$ ) y el caso más crítico ( $E_{06}$ ). . . . .	42

4.13. Influencia del intervalo de presión seleccionado para la selección de datos en el modelo $H_{05}$ . . . . .	43
4.14. Influencia en el ruido para dos intervalos (120-115) y (90-85) mmHg. . .	43
4.15. Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 01. . . . .	45
4.16. Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 04. . . . .	45
A.1. Tipos de aneurismas según su morfología: A) Aneurismas saculares y B) Aneurismas fusiformes (Stanford, 2024). . . . .	65
A.2. Tipos de aneurismas según su localización: A) Aneurismas intracraneales (Stanford, 2024), B) Aneurismas torácicos y C) Aneurismas abdominales (NIH, 2022). . . . .	66
B.1. Modelo 01 utilizado en el estudio presente de AAA monocapa con ILT.	68
B.2. Modelo 02 utilizado en el estudio presente de AAA monocapa con ILT.	69
B.3. Modelo 03 utilizado en el estudio presente de AAA monocapa con ILT.	69
B.4. Modelo 04 utilizado en el estudio presente de AAA monocapa con ILT.	70
B.5. Modelo 01 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	71
B.6. Modelo 02 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	71
B.7. Modelo 03 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	72
B.8. Modelo 04 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	72
B.9. Modelo 05 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	73
B.10. Modelo 06 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	73
B.11. Modelo 07 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	74
B.12. Modelo 08 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	74

B.13. Modelo 09 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	75
B.14. Modelo 10 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad. . . . .	75
C.1. Datos experimentales biaxiales de Geest et al. (2006) A) direcciones circunferencial y B) longitudinal. . . . .	80
C.2. Ajuste dada la relación de cargas (A, D) 1:1, (B, E) 1:0.5 y (C, F) 0.5:1 y la dirección (A-C) circunferencial y (D-F) longitudinal. . . . .	80
C.3. Curvas experimentales biaxiales de Holzapfel and Gasser (2000) A) direcciones circunferencial y B) longitudinal. . . . .	81
C.4. Curvas de los estados transitorios. . . . .	83
C.5. Código para la implementación de 2 familias de fibras. . . . .	84
D.1. Localización de las semillas aplicadas en: A) El modelo empleado. B) Caras superiores e inferiores, C) generatriz, D) caras intermedias y E) generatriz media. . . . .	85
D.2. Localización de los gérmenes estudiados: A) Elemento 1, generatriz media externa. B) Elemento 2, generatriz media interna. C) Elemento 3, generatriz superior externa. . . . .	87
D.3. Curvas de convergencia en diferentes modelos de mallado. . . . .	88
D.4. A) Detección de tejido patológico con el modelo 7. B) Detección de tejido patológico con el modelo 1. . . . .	89
E.1. Variabilidad de $K_{cp_{opt}}$ calculadas en los modelos con heterogeneidades. . . . .	98
F.1. Mapa de tensión principal máxima (kPa) en el modelo 01 (mayor ILT) comparado con el modelo AAA. . . . .	99
F.2. Mapa de tensión principal máxima (kPa) en el modelo 02 comparado con el modelo AAA. . . . .	100
F.3. Mapa de tensión principal máxima (kPa) en el modelo 02 comparado con el modelo AAA. . . . .	100
F.4. Mapa de tensión principal máxima (kPa) en el modelo 04 (menor ILT) comparado con el modelo AAA. . . . .	100
F.5. Mapa de gradiente de deformación para modelo $H_{01}$ . . . . .	101
F.6. Mapa de gradiente de deformación para modelo $H_{02}$ . . . . .	102

F.7. Mapa de gradiente de deformación para modelo $H_{03}$ . . . . .	103
F.8. Mapa de gradiente de deformación para modelo $H_{04}$ . . . . .	104
F.9. Mapa de gradiente de deformación para modelo $H_{05}$ . . . . .	105
F.10. Mapa de gradiente de deformación para modelo $H_{06}$ . . . . .	106
F.11. Mapa de gradiente de deformación para modelo $H_{07}$ . . . . .	107
F.12. Mapa de gradiente de deformación para modelo $H_{08}$ . . . . .	108
F.13. Mapa de gradiente de deformación para modelo $H_{09}$ . . . . .	109
F.14. Mapa de gradiente de deformación para modelo $H_{10}$ . . . . .	110
F.15. Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 01. . . . .	111
F.16. Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 02. . . . .	111
F.17. Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 03. . . . .	111
F.18. Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 04. . . . .	111



# Lista de Tablas

2.1.	Constantes de la función de densidad de energía del tejido patológico y sano obtenido en el software comercial Hyperfit. . . . .	16
2.2.	Constantes de la función de densidad de energía del los estados transitorios entre tejido patológico y sano. . . . .	16
2.3.	Información sobre las mallas de los diferentes modelos. . . . .	20
4.1.	Análisis cualitativo de detección del contorno del tejido patológico para el modelo $H_{01} - E_{01}$ . Leyenda: Verde, Detección Sólida con Baja Probabilidad de Contaminación de Ruido; Amarillo, Detección Moderada con Posible Contaminación de Ruido y Rojo, Nivel de Detección Mínimo. . . . .	37
4.2.	Análisis cualitativo de detección del contorno del tejido patológico para el modelo $H_{01} - E_{06}$ . Leyenda: Verde, Detección Sólida con Baja Probabilidad de Contaminación de Ruido; Amarillo, Detección Moderada con Posible Contaminación de Ruido y Rojo, Nivel de Detección Mínimo. . . . .	37
C.1.	Constantes de la función de densidad de energía del tejido patológico obtenido en el software comercial Hyperfit. . . . .	81
C.2.	Constantes de la función de densidad de energía del tejido sano obtenido en el software comercial Hyperfit. . . . .	81
C.3.	Constantes de la función de densidad de energía del los estados transitorios entre tejido patológico y sano. . . . .	82
D.1.	Información sobre las mallas de los diferentes modelos. . . . .	86
E.1.	Descripción de las variables utilizadas en el algoritmo de geometría de presión cero. . . . .	92
E.2.	Valores de $K_{c_{opt}}$ calculados. . . . .	98



# Glosario

**AA** Aorta abdominal. 6

**AAA** Aneurismas aórtico abdominales. 1

**GCP** Geometría cero presión. 7

**ILT** Trombo intraluminal. 4

**IRM** Resonancia magnética. 5

**TC** Tomografía computarizada. 5



# Anexos



# Anexos A

## Aneurismas

Un aneurisma es una dilatación anómala y permanente en la pared de un vaso sanguíneo, causada por una lesión o debilidad de la pared, donde la presión sanguínea empuja hacia fuera, tendiendo a agrandarse con el tiempo (Nieto Palomo, 2016). Aunque pueden ocurrir en cualquier vaso sanguíneo, la mayoría sucede en arterias y en localizaciones específicas. Se clasifican según su localización, morfología y etiología (Nieto Palomo, 2016). Según su etiología, los aneurismas realmente ocurren en paredes arteriales o miocárdicas sanas, donde el grosor de la pared se adelgaza. Ejemplos incluyen aneurismas ateroscleróticos (con placa de ateroma formada por lípidos), sífilíticos (causados por infección de sífilis cardiovascular) y congénitos (presentes desde el nacimiento). Por su forma, pueden ser saculares o fusiformes (Kumar et al., 2015): Los aneurismas saculares (Figura A.1.A) son protuberancias esféricas que afectan una porción de la pared vascular y suelen asociarse a trombosis. Los aneurismas fusiformes (Figura A.1.B) presentan dilatación circunferencial de una porción longitudinal del vaso sanguíneo de hasta 30 cm (Adoni and Sabillón, 2017). La dilatación es simétrica, mostrando la protuberancia en todos los lados de la arteria.

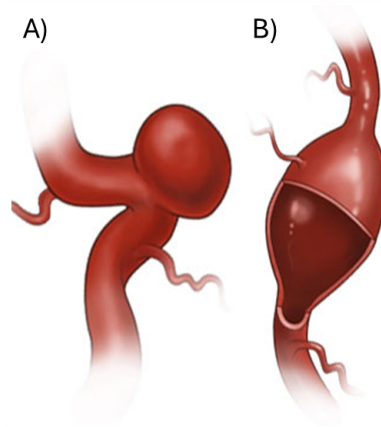


Figura A.1: Tipos de aneurismas según su morfología: A) Aneurismas saculares y B) Aneurismas fusiformes (Stanford, 2024).

Finalmente, según su localización, pueden existir aneurismas intracraneales (Figura A.2.A) que se forman en la base del cerebro, en curvaturas abruptas o bifurcaciones de arterias cerebrales. Los aneurismas aórticos se generan en la aorta torácica (Figura A.2.B) o abdominal (Figura A.2.C).

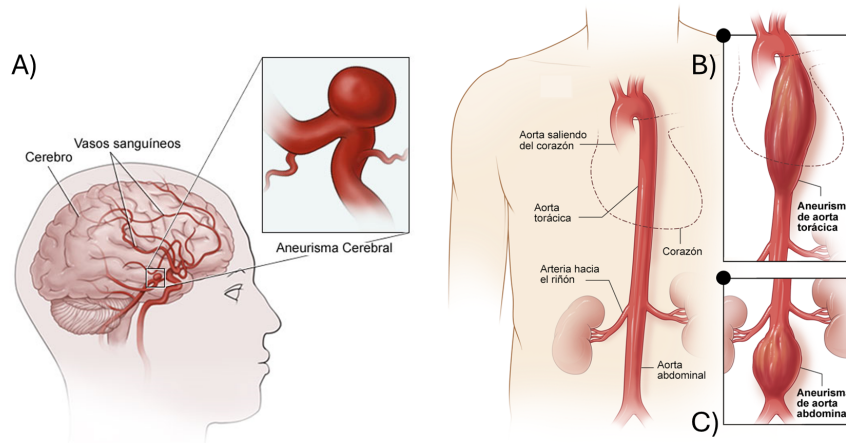


Figura A.2: Tipos de aneurismas según su localización: A) Aneurismas intracraneales (Stanford, 2024), B) Aneurismas torácicos y C) Aneurismas abdominales (NIH, 2022).

# Anexos B

## Geometrías patológicas

En este anexo se detallarán las diferentes geometrías patológicas empleadas en el estudio de la predicción temprana de AAA. Se comentarán las características y particularidades de las cuatro geometrías de AAA con ILT y los diez modelos de aorta con heterogeneidades.

En las siguientes secciones de este anexo, se proporcionarán descripciones detalladas de cada una de las geometrías patológicas, acompañadas de representaciones visuales y análisis de sus características. Esta información es fundamental para comprender el contexto en el que se aplican los métodos de detección y para interpretar los resultados obtenidos en el estudio.

## B.1. Geometrías de AAA con ILT.

Las geometrías de AAA con ILT representan una etapa avanzada de la patología, donde el ILT desempeña un papel crucial en la alteración de las propiedades mecánicas de la aorta. Estas geometrías se emplean para evaluar cómo la presencia del ILT afecta la distribución del gradiente de deformación y la identificación del tejido patológico. Cada uno de los cuatro modelos presenta variaciones en la distribución y tamaño del trombo, permitiendo un análisis detallado de su influencia en la detección de aneurismas.

### Modelo 01




Figura B.1: Modelo 01 utilizado en el estudio presente de AAA monocapa con ILT.

## Modelo 02




Figura B.2: Modelo 02 utilizado en el estudio presente de AAA monocapa con ILT.

## Modelo 03




Figura B.3: Modelo 03 utilizado en el estudio presente de AAA monocapa con ILT.




Figura B.4: Modelo 04 utilizado en el estudio presente de AAA monocapa con ILT.

### Modelo 04

Cada uno de los modelos de AAA con ILT presenta una reducción progresiva en el tamaño del trombo, permitiendo observar cómo este factor afecta el flujo sanguíneo y la detección del tejido patológico.

El modelo 01 se diseñó para simular una condición en la que el ILT permite un flujo similar al de una aorta sana. En este modelo, el ILT es relativamente grande y se adapta significativamente el flujo sanguíneo sano, lo que proporciona un punto de referencia para comparar con los modelos más avanzados. A medida que avanzamos a los siguientes modelos, se observa una reducción gradual del tamaño del ILT. El modelo 04 cuenta con un ILT mínimo, representando el paso previo a una AAA sin ILT. Estos modelos permiten un análisis detallado de la influencia del ILT en la mecánica de la aorta y en la eficacia de los métodos de detección de aneurismas.

## B.2. Geometrías de aorta con heterogeneidades.

Los diez modelos de aorta con heterogeneidades se diseñaron para representar el avance de tejido patológico en las propiedades del tejido aórtico. Estas heterogeneidades pueden surgir debido a factores como la degeneración del tejido o variaciones en la estructura del colágeno. Los modelos se utilizaron para estudiar cómo estas diferencias afectan la detección de áreas patológicas y la precisión del algoritmo de predicción.

### Modelo 01




Figura B.5: Modelo 01 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

### Modelo 02




Figura B.6: Modelo 02 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.




Figura B.7: Modelo 03 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

**Modelo 03**

**Modelo 04**




Figura B.8: Modelo 04 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## Modelo 05




Figura B.9: Modelo 05 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## Modelo 06




Figura B.10: Modelo 06 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## Modelo 07




Figura B.11: Modelo 07 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## Modelo 08




Figura B.12: Modelo 08 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## Modelo 09




Figura B.13: Modelo 09 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

## Modelo 10




Figura B.14: Modelo 10 utilizado en el estudio presente de aorta abdominal monocapa con heterogeneidad.

Los modelos de aorta con heterogeneidades están diseñados de manera que, con cada modelo sucesivo, se incrementa el tamaño del tejido patológico y se complica su geometría. Este enfoque tiene la intención de estudiar cómo estas variaciones afectan la detección del tejido patológico y la precisión del algoritmo utilizado.

En los primeros modelos, las heterogeneidades son mínimas con geometría anulares muy sencillas, lo que permite evaluar el comportamiento del tejido patológico en condiciones más controladas y menos complejas. A medida que se avanza a modelos posteriores, el tamaño de las áreas de tejido patológico aumenta y la geometría se vuelve más irregular. Estas complicaciones adicionales representan escenarios más realistas y desafiantes, donde la detección del tejido patológico se vuelve más difícil.

Este incremento gradual en la complejidad de las heterogeneidades tiene como objetivo evaluar la robustez y la efectividad del algoritmo de detección bajo diversas condiciones. Al analizar cómo el aumento en el tamaño del tejido patológico y las variaciones geométricas influyen en los resultados, se puede identificar posibles limitaciones del método y áreas de mejora.

## Anexos C

# Respuesta tensional hiperelástica. Modelos hiperelásticos para tejidos biológicos blandos.

En este anexo se definirá tanto la formulación necesaria para la simulación de vasos sanguíneos como la obtención de todos los parámetros necesarios. Se comenzará describiendo los fundamentos teóricos y matemáticos que subyacen en la modelización de la biomecánica de los vasos sanguíneos. Además, se detallarán los procedimientos experimentales y las técnicas de ajuste utilizados para determinar los parámetros mecánicos de los tejidos, tales como módulos de elasticidad, coeficientes de anisotropía, y otros parámetros específicos necesarios para la simulación. Finalmente, se proporcionarán ejemplos de código y configuraciones específicas empleadas en el software de simulación Abaqus.

## C.1. Formulación

La respuesta mecánica del vaso se basa en la definición de una función de energía de deformación que define el comportamiento hiperelástico anisótropo:

$$\Psi = \Psi(\mathbf{C}, \mathbf{N}, \mathbf{M}). \quad (\text{C.1})$$

Esta función depende de las variables de estado,  $\mathbf{F}$  (gradiente de deformación) a través de  $\mathbf{C} = \mathbf{F}^T \mathbf{F}$  (tensor de deformación de Cauchy-Green) y de los tensores estructurales  $\mathbf{M} = \mathbf{m}_0 \otimes \mathbf{m}_0$  y  $\mathbf{N} = \mathbf{n}_0 \otimes \mathbf{n}_0$ , que definen la anisotropía del material debida a la dirección preferencial de las fibras del colágeno para el vaso sanguíneo. La función de energía de deformación puede dividirse en dos partes, una que contempla la energía cuando se produce cambio de volumen y otra asociada a la conservación del mismo, llamada desviadora; este tratamiento permite gestionar computacionalmente la restricción de cuasi-incomprensibilidad. Además, la parte desviadora, se divide en una contribución pasiva,  $\bar{\Psi}_p$ . Por consiguiente, la función energía de deformación total  $\Psi$  puede expresarse como:

$$\Psi = \Psi_{vol}(J) + \bar{\Psi}_p(\bar{\mathbf{C}}, \mathbf{N}, \mathbf{M}). \quad (\text{C.2})$$

La Eq.(C.2) se puede expresar en función de los invariantes del tensor de deformación y formularse como:

$$\Psi = \Psi_{vol}(J) + \bar{\Psi}_p(\bar{I}_1, \bar{I}_2, \bar{I}_4, \bar{I}_6). \quad (\text{C.3})$$

A continuación se describen cada una de las contribuciones.

La parte volumétrica se define mediante el jacobiano  $J$  de  $\mathbf{F}$ :

$$\Psi_{vol}(J) = \frac{1}{D}(J - 1)^2 \quad (\text{C.4})$$

La función de la energía de deformación pasiva,  $\bar{\Psi}_p$ , se define como una función de los invariantes:

$$\bar{I}_1 = tr \bar{\mathbf{C}}, \quad \bar{I}_2 = \frac{1}{2}((tr \bar{\mathbf{C}})^2 - tr \bar{\mathbf{C}}^2), \quad \bar{I}_4 = \mathbf{n}_0 \cdot \bar{\mathbf{C}} \mathbf{n}_0 \quad \bar{I}_6 = \mathbf{m}_0 \cdot \bar{\mathbf{C}} \mathbf{m}_0. \quad (\text{C.5})$$

donde  $\bar{I}_1$  y  $\bar{I}_2$  son el primer y segundo invariante del tensor de deformación simétrico de Cauchy-Green modificado  $\bar{\mathbf{C}} = J^{-1/3} \mathbf{C}$ , e  $\bar{I}_4, \bar{I}_6$  es el pseudo-invariante relativo a la anisotropía de la respuesta del material.

Para caracterizar el material se utilizará una función densidad energía de deformación pasiva,  $\bar{\Psi}_p$ , se puede expresar como el sumatorio de tres términos:

$$\bar{\Psi}_p = \sum_{i=1}^N \bar{\Psi}_i = \bar{\Psi}_1 + \bar{\Psi}_4 + \bar{\Psi}_6 \quad (\text{C.6})$$

El primer término  $\bar{\Psi}_1$  corresponde a la matriz isotrópica, cuya función de densidad de energía de deformación es una particularización de la función de energía del modelo polinomial:

$$\bar{\Psi}_1 = \sum_{i+j=1}^N C_{ij} (\bar{I}_1 - 3)^i (\bar{I}_2 - 3)^j \quad (\text{C.7})$$

Con  $i = 1$ ,  $j = 0$  y  $N = 1$  se obtiene la particularización óptima para tejidos poliméricos:

$$\bar{\Psi}_1 = \mu_1 (\bar{I}_1 - 3) \quad (\text{C.8})$$

A esta función de densidad hay que incorporar el efecto de anisotropía de las fibras proporcionado por Gasser et al. (2006):

$$\bar{\Psi}_i = \frac{k_1}{2 \cdot k_2} \sum_{i+j=1}^N \exp(k_2 \cdot [\kappa \cdot (\bar{I}_1 - 3) + (\bar{I}_1 - 3 \cdot \kappa) \cdot (\bar{I}_i - 1)]^2) - 1 \quad (\text{C.9})$$

De esta forma se obtiene la siguiente ecuación:

$$\bar{\Psi} = \frac{1}{D} (J-1)^2 + \mu_1 (\bar{I}_1 - 3) + \frac{k_1}{2 \cdot k_2} \sum_{i+j=1}^N \exp(k_2 \cdot [\kappa \cdot (\bar{I}_1 - 3) + (\bar{I}_1 - 3 \cdot \kappa) \cdot (\bar{I}_i - 1)]^2) - 1 \quad (\text{C.10})$$

## C.2. Obtención de los parámetros

Dependiendo del tipo de tejido, se necesitan diferentes parámetros; en otras palabras, los parámetros variarán entre el tejido sano y el tejido patológico. Se ajustaron 6 curvas en total para el tejido patológico, considerando la orientación de las fibras, ya sea circunferencial o longitudinal, y la relación de cargas aplicadas en el ensayo biaxial.

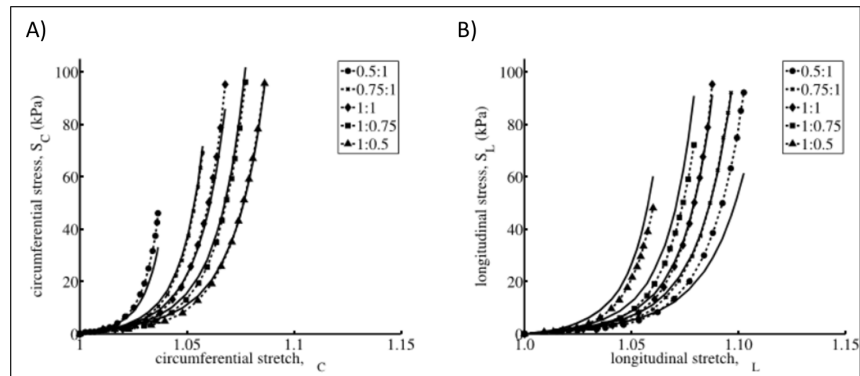


Figura C.1: Datos experimentales biaxiales de Geest et al. (2006) A) direcciones circunferencial y B) longitudinal.

A partir de las curvas experimentales de Geest, se ajustaron las siguientes curvas, obteniendo los siguientes parámetros:

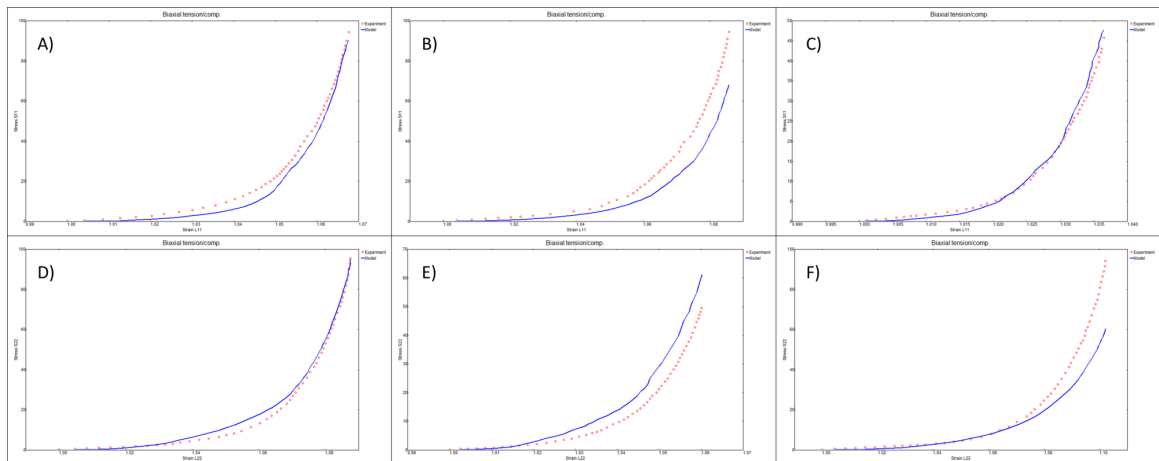


Figura C.2: Ajuste dada la relación de cargas (A, D) 1:1, (B, E) 1:0.5 y (C, F) 0.5:1 y la dirección (A-C) circunferencial y (D-F) longitudinal.

Constante	Valor	Unidad	Descripción
$\mu$	0001.589	[kPa]	Rigidez de la matriz
$D$	0000.000	[-]	Factor de incompresibilidad
$k_1$	2911.433	[kPa]	Rigidez general
$k_2$	2326.247	[kPa]	Rigidez del colágeno
$\kappa$	0000.333	[-]	Dispersión de las fibras
$\gamma$	0000.000	[°]	Ángulo de las fibras sobre la dirección circunferencial

Tabla C.1: Constantes de la función de densidad de energía del tejido patológico obtenido en el software comercial Hyperfit.

Para el tejido sano, se ajustaron 2 curvas según la orientación de las fibras y siempre con una relación de tensiones 1:1.




Figura C.3: Curvas experimentales biaxiales de Holzapfel and Gasser (2000) A) direcciones circunferencial y B) longitudinal.

Basándose en las curvas experimentales, se ajustaron las curvas, obteniendo los siguientes parámetros:

Constante	Valor	Unidad	Descripción
$\mu$	00100.00	[kPa]	Rigidez de la matriz
$D$	00000.00	[-]	Factor de incompresibilidad
$k_1$	20000.00	[kPa]	Rigidez general
$k_2$	00061.00	[kPa]	Rigidez del colágeno
$\kappa$	00000.23	[-]	Dispersión de las fibras
$\gamma$	00043.00	[°]	Ángulo de las fibras sobre la dirección circunferencial

Tabla C.2: Constantes de la función de densidad de energía del tejido sano obtenido en el software comercial Hyperfit.

### C.3. Implementación de estados en modelos heterogéneos

Se definieron 7 estados diferentes de las propiedades que abarcan desde una patología pura hasta una arteria completamente sana para la creación del modelo de heterogeneidades. Se generaron estos estados intermedios de forma lineal entre los dos extremos, lo que permite una transición gradual y realista de las propiedades del tejido. Cada estado refleja diferentes grados de salud arterial mediante un conjunto específico de parámetros mecánicos y estructurales que varían progresivamente.

Para obtener estos valores intermedios, se realizó una interpolación lineal de los parámetros clave:

Material	$\mu[kPa]$	$D[-]$	$k_1[kPa]$	$k_2[kPa]$	$\kappa[-]$	$\gamma[^\circ]$
ESTADO 01 / <i>AAA</i>	001.589	0	02991.43	2326.25	0.3333	0
ESTADO 02	017.991	0	05826.27	1948.72	0.3133	7
ESTADO 03	034.393	0	08661.07	1571.18	0.2966	14
ESTADO 04	050.795	0	11495.87	1193.64	0.2799	22
ESTADO 05	067.197	0	14330.67	0816.10	0.2632	29
ESTADO 06	083.599	0	17165.47	0438.56	0.2465	36
ESTADO 07 / <i>Sana</i>	100.000	0	20000.00	0061.00	0.2330	43

Tabla C.3: Constantes de la función de densidad de energía del los estados transitorios entre tejido patológico y sano.

Se diseñaron cuidadosamente estos valores para garantizar una transición suave y realista de las propiedades del tejido, lo que permite una evaluación detallada y precisa de la influencia de las heterogeneidades en la arteria. Se necesitaba representar gráficamente las curvas de cada estado (Figura C.4) para poder visualizar y detectar posibles incoherencias en los parámetros asignados a los distintos niveles de salud arterial.

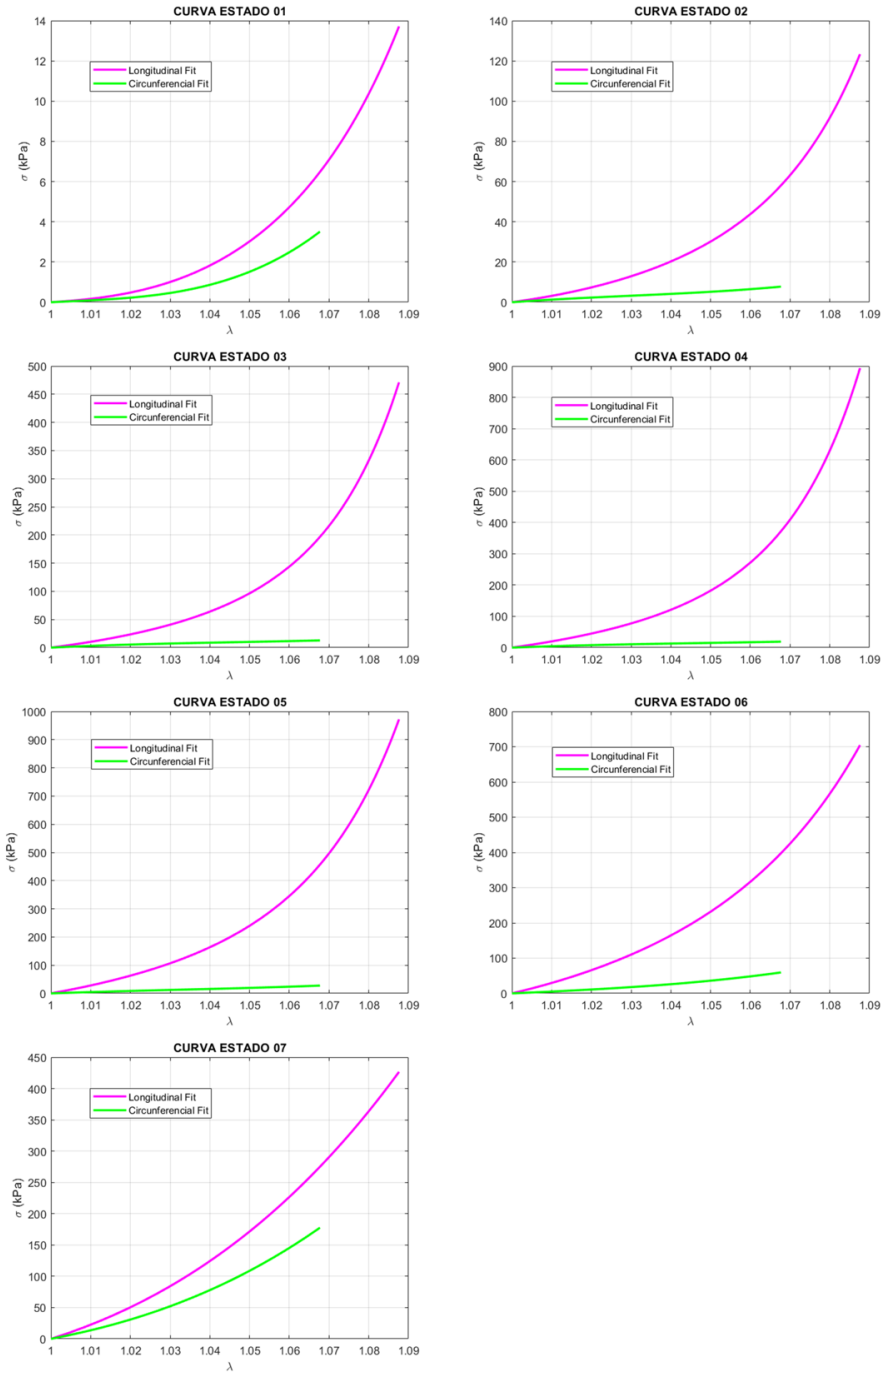


Figura C.4: Curvas de los estados transitorios.

Al trazar estas curvas, se puede detectar y corregir cualquier irregularidad en la interpolación de los parámetros para asegurar que cada estado intermedio refleje fiel y precisamente las características mecánicas y estructurales del tejido arterial.

## C.4. Implementación de las fibras en Abaqus

En el modelo, las fibras de los materiales anisótropos se especifican directamente en las ventanas del software Abaqus CAE. Sin embargo, conserva solo la última orientación asignada, lo que limita los modelos con múltiples orientaciones de fibras. Para superar este límite, es preciso agregar las orientaciones al archivo .inp de forma manual. Esto se puede lograr utilizando el siguiente código:

```
*parameter
Pi = 3.141592654
gamma1 = 43
theta1 = gamma1 - 90
c1 = cos(theta1*Pi/180)
s1 = sin(theta1*Pi/180)
theta2 = theta1-2*gamma1
c2 = cos(theta2*Pi/180)
s2 = sin(theta2*Pi/180)
*Orientation, name=Ori-1, system=RECTANGULAR, local directions=2
Ori-1-DiscOrient
3,0.0
<c1>, <s1>, 0.0
<c2>, <s2>, 0.0
```

Figura C.5: Código para la implementación de 2 familias de fibras.

# Anexos D

## Análisis de sensibilidad de malla.

### D.1. Construcción de los distintos mallados.

Para la construcción de los distintos tipos de mallado se partió del modelo de aorta sana, ya que este es el modelo al cual se le aplicará la metodología de detección principalmente. Se generaron diez modelos de mallado distintos, basándose en la asignación de distintos tipos de semillas según la localización (Ver Figura D.1). Dada la variedad de posibles distribuciones, se construyó la siguiente tabla de semillas:

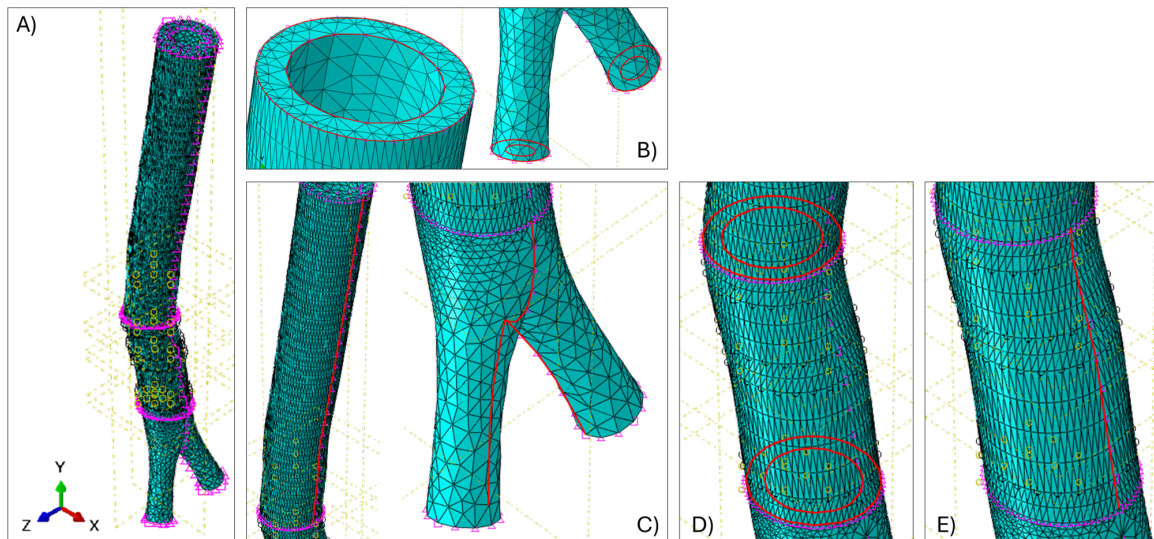


Figura D.1: Localización de las semillas aplicadas en: A) El modelo empleado. B) Caras superiores e inferiores, C) generatriz, D) caras intermedias y E) generatriz media..

La incomprensibilidad de los tejidos representa un obstáculo significativo a la hora de simular los modelos, por lo que ha sido necesario emplear elementos híbridos de mallado en Abaqus para poder resolver este problema. Esto da como resultados emplear elementos del tipo C3D4H. Los C3D4H son tetraedros, lo que significa que tienen cuatro nodos y cada cara del tetraedro es un triángulo. Esto hace que estos elementos sean

fáciles de usar en mallas complejas y adaptables a geometrías irregulares. Debido a su formulación híbrida, los elementos C3D4H son ideales para modelar materiales que no cambian de volumen fácilmente bajo carga (incomprensibles), como ciertos tipos de tejidos biológicos.

Seed ( <i>mm</i> )	Cara Sup./Inf.	Cara Mid.	Gen.	Gen. Mid.	Global	Nº de Elementos	Tipo de Elementos
Modelo 01	-	-	2	2	1.00	316091	C3D4H
Modelo 02	2	-	4	4	2.00	042961	C3D4H
Modelo 03	2	-	4	4	3.00	024973	C3D4H
Modelo 04	1	-	3	3	3.00	066862	C3D4H
Modelo 05	2	-	4	4	3.00	024973	C3D4H
Modelo 06	3	-	5	5	3.00	015502	C3D4H
Modelo 07	3	1	5	5	3.00	044931	C3D4H
Modelo 08	3	1	5	2	3.00	053206	C3D4H
Modelo 09	2	-	4	4	1.60	068995	C3D4H
Modelo 10	2	-	4	4	1.25	214747	C3D4H

Tabla D.1: Información sobre las mallas de los diferentes modelos.

De estos diez modelos, se analizaron un total de tres gérmenes distintos en el modelo para determinar cuáles de estos modelos convergían y en qué tiempo, con el fin de seleccionar el mejor mallado para la aplicación de la geometría de cero presión. Se escogieron puntos pertenecientes a la generatriz para asegurar que, independientemente del modelo, siempre se analizase el mismo dominio. En concreto, se analizaron dos elementos en la zona pro-patológica y un tercero en una zona sana:




Figura D.2: Localización de los gérmenes estudiados: A) Elemento 1, generatriz media externa. B) Elemento 2, generatriz media interna. C) Elemento 3, generatriz superior externa.

- Elemento 1: Ubicado en una región propensa a desarrollar patologías, se seleccionó para observar cómo las distintas configuraciones de mallado afectaban la convergencia y precisión en una área de interés crítico.
- Elemento 2: También en una zona pro-patológica, este elemento adicional permitió una comparación directa dentro de áreas con similares características estructurales y de estrés.
- Elemento 3: Situado en una región sana, se escogió para contrastar los resultados obtenidos en las áreas pro-patológicas, proporcionando un punto de referencia para la evaluación de la calidad del mallado en un tejido sin alteraciones patológicas.

Analizando las tensiones máximas obtenidas en los tres elementos seleccionados en los diez modelos, se obtuvieron las siguientes curvas de convergencia:

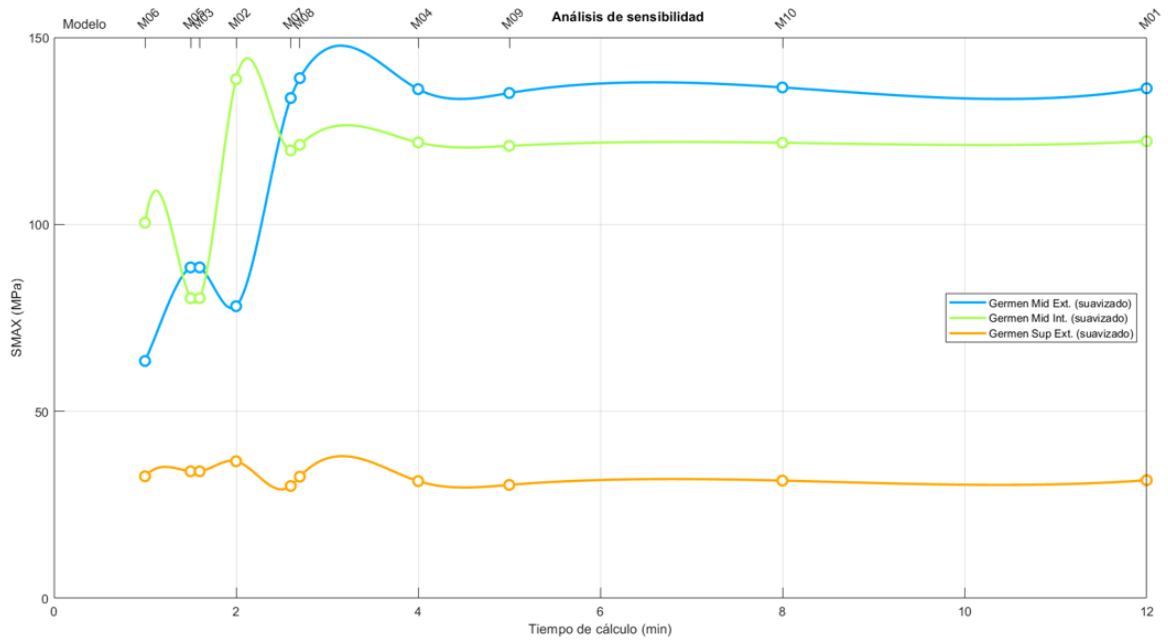


Figura D.3: Curvas de convergencia en diferentes modelos de mallado.

De las curvas obtenidas, se seleccionó el modelo 7 para el mallado en la geometría de cero presión y el modelo 1 para el mallado aplicado en la detección de tejido patológico. El modelo 7 fue elegido porque permite calcular el factor  $K_{CP_{opt}}$ , esencial para determinar la geometría de cero presión. Este modelo ofrece una adecuada representación inicial de la arteria bajo condiciones de presión nula, lo cual es crucial para establecer una base de referencia precisa.

Sin embargo, el modelo 7 presenta una limitación significativa: no proporciona la precisión necesaria para detectar con fiabilidad las zonas de tejido patológico (ver Figura D.4.A). Esta falta de precisión podría comprometer la exactitud de la detección de aneurismas y otras patologías asociadas, debido a la menor resolución de detalles críticos en el modelo.

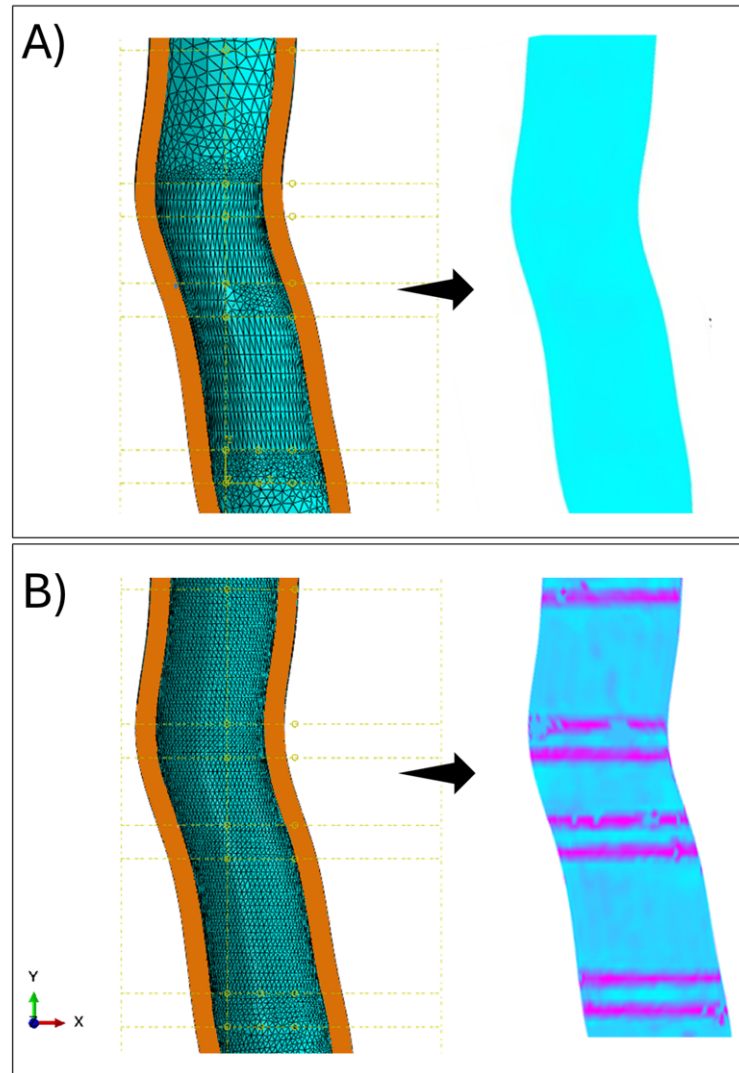


Figura D.4: A) Detección de tejido patológico con el modelo 7. B) Detección de tejido patológico con el modelo 1.

Para superar esta limitación, se decidió aplicar el factor  $K_{CP_{opt}}$  obtenido del modelo 7 al modelo de mallado 1. El modelo 1 fue seleccionado para esta etapa porque, a diferencia del modelo 7, ofrece una precisión aceptable tanto en los resultados obtenidos como en el tiempo de cálculo requerido. Esta combinación permite beneficiarse de las ventajas de ambos enfoques: el cálculo preciso de la geometría de cero presión proporcionado por el modelo 7 y la alta resolución y precisión del modelo 1 para la detección de tejidos patológicos.



## Anexos E

# Algoritmo de Geometría Cero Presión.

En este anexo, se presentará primero una tabla con todas las variables empleadas en el algoritmo de geometría de presión cero. Posteriormente, se procederá a un análisis detallado del algoritmo, explicando cada uno de sus pasos y la importancia de las variables involucradas en el proceso. Esta estructura permitirá una comprensión completa y detallada del método utilizado para determinar la geometría de presión cero y su relevancia en las simulaciones biomecánicas.

## E.1. Variables utilizadas en el algoritmo

Variable	Descripción
$k$	Factor iterativo inicial establecido en 1.
$X_Z^0$	Geometría inicial definida como la geometría de la imagen $X_{image}$ .
$X_{csys}, Y_{csys}, Z_{csys}$	Coordenadas del sistema de referencia extraídas del archivo INP de entrada.
$X_0, Y_0, Z_0$	Coordenadas iniciales de los nodos corregidas con $X_{csys}, Y_{csys}, Z_{csys}$ .
$X_{image}$	Geometría de la imagen inicial $(X_0, Y_0, Z_0)$ .
$U_x, U_y, U_z$	Desplazamientos obtenidos de la simulación en Abaqus.
$\sigma$	Tensor de tensiones definido como $\sigma = 2\frac{1}{J}F\frac{\partial W}{\partial C}F^T$ .
$B^{k-1}$	Dominio en la iteración $k - 1$ .
$u _{\partial B_t^{k-1}, \partial B_b^{k-1}}$	Condiciones de frontera en la simulación.
$P_{diast}$	Presión en la frontera durante la simulación.
$J(K_{cp})$	Función de costo definida como el error cuadrático medio normalizado (NRMSE).
$\Delta$	Tamaño inicial del paso en el algoritmo de búsqueda de patrones.
$K_{cp0}$	Punto inicial para el factor $K_{cp}$ .
$K_{nuevo}$	Nuevo valor de $K_{cp}$ que minimiza la función de costo.
$K_{cpopt}$	Valor óptimo de $K_{cp}$ después de la optimización.
$X_Z^k$	Geometría de presión cero actualizada en la iteración $k$ .
$X_Z^{k-1}$	Geometría de presión cero en la iteración $k - 1$ .
$X_{def}^k$	Geometría deformada en la iteración $k$ .
$f_{aniso}$	Indicador de si el material es anisotrópico.
$F^k$	Deformación en la iteración $k$ .
$n^k$	Vector de fibras ajustado en la iteración $k$ .
matriz_pressurized	Coordenadas presurizadas en el cálculo de error.
Coord_iter	Coordenadas iterativas en el cálculo de error.
Error	Error definido como $100 \cdot \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (\text{matriz\_pressurized}_i - \text{Coord\_iter}_i)^2}}{ \frac{1}{n} \sum_{i=1}^n \text{matriz\_pressurized}_i }$ .
$tol$	Tolerancia de error establecida para las condiciones de parada.
$maxiter$	Número máximo de iteraciones permitidas.

Tabla E.1: Descripción de las variables utilizadas en el algoritmo de geometría de presión cero.

## E.2. Algoritmo Pull Back

El siguiente algoritmo se utiliza para reconstruir la geometría de presión cero de un modelo de AAA a partir de la geometría basada en imágenes de CT, o en el caso actual, modelo paramétrico:

### 1. Inicialización:

- Establecer  $k := 1$
- Establecer  $X_Z^0 := X_{image}$

El algoritmo comienza con la fase de inicialización, donde se establece el valor inicial del factor iterativo  $k$  como  $k := 1$  y se define la geometría inicial  $X_Z^0$  como la geometría de la imagen  $X_{image}$ . Este paso prepara el entorno para las siguientes etapas del proceso.

### 2. Extracción de coordenadas:

- Obtener  $X_{csys}, Y_{csys}, Z_{csys}$  del archivo INP de entrada.
- Obtener  $X_0, Y_0, Z_0$  del archivo de entrada y corregir con  $X_{csys}, Y_{csys}, Z_{csys}$ . El modelo debe de ser independiente.  $X_{image} = (X_0, Y_0, Z_0)$

En la siguiente fase, se realiza la extracción de coordenadas. Se obtienen las coordenadas del sistema de referencia  $X_{csys}, Y_{csys}, Z_{csys}$  del archivo INP de entrada y se corrigen las coordenadas iniciales de los nodos  $X_0, Y_0, Z_0$  utilizando estas coordenadas del sistema de referencia. Es esencial que el modelo sea independiente en esta fase para garantizar la precisión de las coordenadas iniciales.

### 3. Simulación del modelo en Abaqus, obtener desplazamientos $U_x, U_y, U_z$ resolviendo las condiciones de contorno y cargas:

- $\nabla \cdot \sigma = 0$  en  $B^{k-1}$
- $\sigma = 2\frac{1}{J}F\frac{\partial W}{\partial C}F^T$
- Condiciones de frontera:  $u|_{\partial B_t^{k-1}, \partial B_b^{k-1}} = \bar{u}$
- Presión en la frontera:  $(\sigma \cdot m_i)|_{\partial B_i^k} = P_{diast}$

Luego, se simula el modelo en Abaqus para obtener los desplazamientos  $U_x, U_y, U_z$ . Esto se logra resolviendo las ecuaciones de equilibrio:

$$\nabla \cdot \sigma = 0 \quad \text{en} \quad B^{k-1} \quad (\text{E.1})$$

donde  $\sigma$  es el tensor de tensiones definido como

$$\sigma = 2 \frac{1}{J} F \frac{\partial W}{\partial C} F^T \quad (\text{E.2})$$

Las condiciones de frontera se establecen con

$$u|_{\partial B_t^{k-1}, \partial B_b^{k-1}} = \bar{u} \quad (\text{E.3})$$

y la presión en la frontera se define como

$$(\sigma \cdot m_i)|_{\partial B_t^k} = P_{diast} \quad (\text{E.4})$$

#### 4. Definir función de costo:

- Definir la función de costo como el error cuadrático medio normalizado (NRMSE):

$$J(K_{cp}) = \frac{100 \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{image,i} - X_{Z,i}(k))^2}}{\left| \frac{1}{n} \sum_{i=1}^n X_{image,i} \right|}$$

Para guiar la optimización, se define una función de costo basada en el error cuadrático medio normalizado (NRMSE) entre la geometría presurizada y la geometría de presión cero generada. La función de costo  $J(K_{cp})$  se expresa matemáticamente como:

$$J(K_{cp}) = \frac{100 \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{image,i} - X_{Z,i}(K_{cp}))^2}}{\left| \frac{1}{n} \sum_{i=1}^n X_{image,i} \right|} \quad (\text{E.5})$$

Esta métrica permite cuantificar la discrepancia entre las dos geometrías y dirigir el proceso de optimización.

#### 5. Optimización de $K_{cp}$ :

- Inicialización:
  - Seleccionar un punto inicial  $K_{cp0}$  para el factor  $K_{cp}$ .
  - Definir el tamaño inicial del paso  $\Delta$ .
  - Establecer las condiciones de parada, como la tolerancia y el número máximo de iteraciones.
- Definir la Función de Costo:

- La función de costo  $J(K_{cp})$  se define como el error cuadrático medio normalizado (NRMSE) entre la geometría presurizada y la geometría de presión cero generada:

$$J(K_{cp}) = \frac{100 \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{image,i} - X_{Z,i}(K_{cp}))^2}}{\left| \frac{1}{n} \sum_{i=1}^n X_{image,i} \right|}$$

La fase de optimización de  $K_{cp}$  comienza con la selección de un punto inicial  $K_{cp0}$ , el tamaño inicial del paso  $\Delta$  y el establecimiento de las condiciones de parada, como la tolerancia y el número máximo de iteraciones.

– Iteración del Algoritmo de Búsqueda de Patrones:

a) Generar un Conjunto de Puntos de Prueba:

- Generar puntos de prueba alrededor del valor actual  $K_{cp}$  utilizando un patrón predefinido. Por ejemplo, en una dimensión, los puntos de prueba pueden ser  $K_{cp} + \Delta$  y  $K_{cp} - \Delta$ .

Durante la optimización, el algoritmo genera puntos de prueba alrededor del valor actual de  $K_{cp}$  utilizando un patrón predefinido. Por ejemplo, en una dimensión, los puntos de prueba pueden ser  $K_{cp} + \Delta$  y  $K_{cp} - \Delta$ .

b) Evaluar la Función de Costo:

- Evaluar la función de costo  $J(K_{cp})$  en cada uno de los puntos de prueba generados.

La función de costo  $J(K_{cp})$  se evalúa en cada uno de los puntos de prueba generados. Si se encuentra un punto  $K_{cpnuevo}$  tal que  $J(K_{cpnuevo}) < J(K_{cp})$ , el valor de  $K_{cp}$  se actualiza a  $K_{cpnuevo}$  y, posiblemente, se aumenta el tamaño del paso. Si no se encuentra ningún punto mejor, se reduce el tamaño del paso  $\Delta$ .

c) Actualizar el Punto Actual:

- Si se encuentra un punto  $K_{cpnuevo}$  tal que  $J(K_{cpnuevo}) < J(K_{cp})$ , actualizar  $K_{cp} \leftarrow K_{cpnuevo}$  y posiblemente aumentar el tamaño del paso.
- Si no se encuentra ningún punto mejor, reducir el tamaño del paso  $\Delta$ .

Este proceso iterativo continúa hasta que se cumplen las condiciones de parada, como alcanzar una tolerancia de error específica o llegar al número máximo de iteraciones. El valor  $K_{cp}$  actual al final del proceso se considera el  $K_{cp}$  óptimo  $K_{cpopt}$ .

d) Verificar Condiciones de Parada:

- Verificar si se cumple alguna de las condiciones de parada, como que el error sea menor o igual a la tolerancia establecida o que se haya alcanzado el número máximo de iteraciones.

e) Finalización:

- El algoritmo termina cuando se cumplen las condiciones de parada. El valor  $K_{cp}$  actual se considera el  $K_{cp}$  óptimo  $K_{cp_{opt}}$ .

Después de encontrar  $K_{cp_{opt}}$ , el algoritmo actualiza la geometría de presión cero con la fórmula:

$$X_Z^k := X_Z^{k-1} + K_{cp_{opt}} \cdot (X_{def}^k - X_{image}) \quad (E.6)$$

Si el material es anisotrópico (es decir,  $f_{aniso} == 1$ ), las fibras se ajustan según:

$$F^k := \frac{\partial X_{image}}{\partial X_Z^k}, \quad n^k := (F^k)^{-1}n \quad (E.7)$$

Se calcula el error como:

$$\text{Error} = 100 \cdot \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (\text{matriz\_pressurized}_i - \text{Coord\_iter}_i)^2}}{\left| \frac{1}{n} \sum_{i=1}^n \text{matriz\_pressurized}_i \right|} \quad (E.8)$$

## 6. Repetir:

a) **Actualizar la geometría de presión cero:**

$$X_Z^k := X_Z^{k-1} + K_{cp_{opt}} \cdot (X_{def}^k - X_{image})$$

b) **Ajustar las fibras:**

– Si  $f_{aniso} == 1$ :

$$F^k := \frac{\partial X_{image}}{\partial X_Z^k}$$

$$n^k := (F^k)^{-1}n$$

c) **Calcular el error:**

$$\text{Error} = 100 \cdot \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (X_{image,i} - X_Z^k)^2}}{\left| \frac{1}{n} \sum_{i=1}^n X_{image,i} \right|}$$

d) **Incrementar el iterador:**

$$k := k + 1$$

Finalmente, se incrementa el iterador  $k := k + 1$ .

**7. Hasta que:**

- Error  $\leq tol$
- $k < maxiter$

El proceso se repite hasta que el error sea menor o igual a la tolerancia especificada y el número de iteraciones sea menor que el máximo permitido. Cuando estas condiciones se cumplen, el algoritmo termina.

**8. Fin:**

- El proceso termina.

En conclusión, la geometría de presión cero es un componente esencial para realizar simulaciones precisas en el estudio de los AAA. Este concepto proporciona una base sólida para entender y analizar cómo las arterias responden a diferentes cargas y presiones.

### E.3. Resultados de $K_{cp_{opt}}$

$K_{cp_{opt}}$	E01	E02	E03	E04	E05	E06	E07
M. Sano	-	-	-	-	-	-	0.6503
M. H01	0.6792	0.6820	0.6842	0.6750	0.6726	0.6731	0.6673
M. H02	0.6655	0.6908	0.6864	0.6718	0.6644	0.6604	0.6686
M. H03	0.6957	0.7104	0.6857	0.6796	0.6727	0.6616	0.6685
M. H04	0.6918	0.6749	0.6504	0.6336	0.6339	0.6181	0.6281
M. H05	0.7731	0.7218	0.6430	0.5925	0.5578	0.5549	0.5810
M. H06	0.6575	0.6496	0.6557	0.6245	0.6086	0.6125	0.6198
M. H07	0.6895	0.6832	0.6442	0.6203	0.5819	0.5919	0.5900
M. H08	0.7278	0.7434	0.6713	0.6163	0.5819	0.5667	0.6170
M. H09	0.7924	0.7925	0.7920	0.7287	0.6633	0.6223	0.6279
M. H10	0.8313	0.8269	0.8170	0.7468	0.6768	0.6315	0.6224
M. AAA	0.9024	-	-	-	-	-	-
M. AAA-ILT01	1.0422	-	-	-	-	-	-
M. AAA-ILT02	1.0195	-	-	-	-	-	-
M. AAA-ILT03	1.0461	-	-	-	-	-	-
M. AAA-ILT04	1.0500	-	-	-	-	-	-

Tabla E.2: Valores de  $K_{cp_{opt}}$  calculados.




Figura E.1: Variabilidad de  $K_{cp_{opt}}$  calculadas en los modelos con heterogeneidades.

Al representar  $K_{CP_{opt}}$  (Figura E.1), se puede apreciar que a mayor cantidad de tejido patológico, menor es la homogeneidad de la variable.

# Anexos F

## Resultados Complementarios

En este anexo se presentan resultados adicionales que complementan los análisis realizados en la memoria principal. Los ejemplos mostrados en la memoria principal son suficientes para entender la metodología y corroborar su validez; estos resultados adicionales no otorgan información extra significativa, pero sirven para complementar la memoria y proporcionar una visión más completa del estudio. Este anexo se divide en tres secciones principales:

### F.1. Simulación Numérica de AAA más ILT

En esta sección se comentarán los resultados de la simulación numérica de AAA con ILT para los cuatro modelos. Estos modelos fueron analizados para evaluar la influencia de la cantidad de ILT en la distribución de tensiones y el riesgo de ruptura.

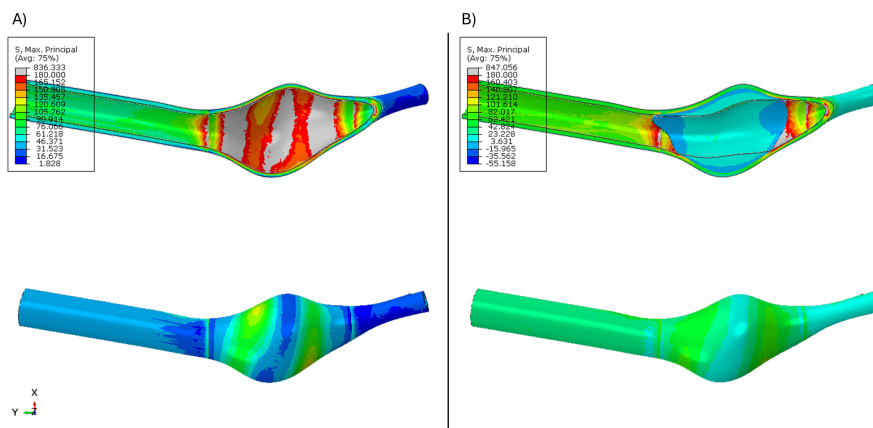


Figura F.1: Mapa de tensión principal máxima (kPa) en el modelo 01 (mayor ILT) comparado con el modelo AAA.

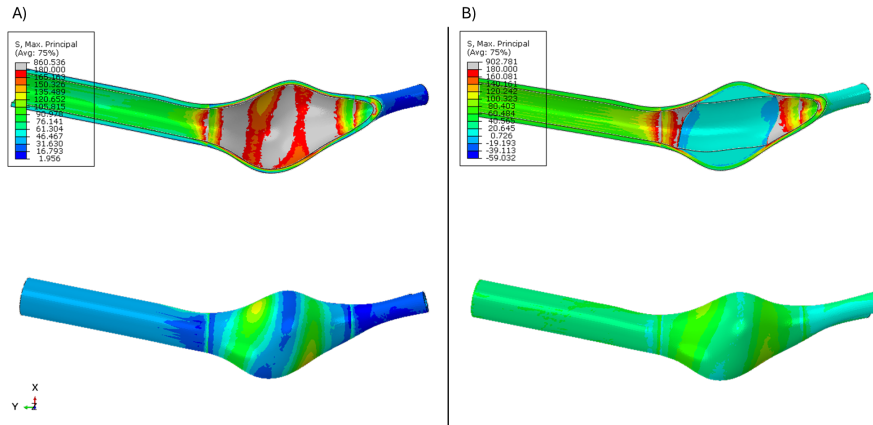


Figura F.2: Mapa de tensión principal máxima (kPa) en el modelo 02 comparado con el modelo AAA.

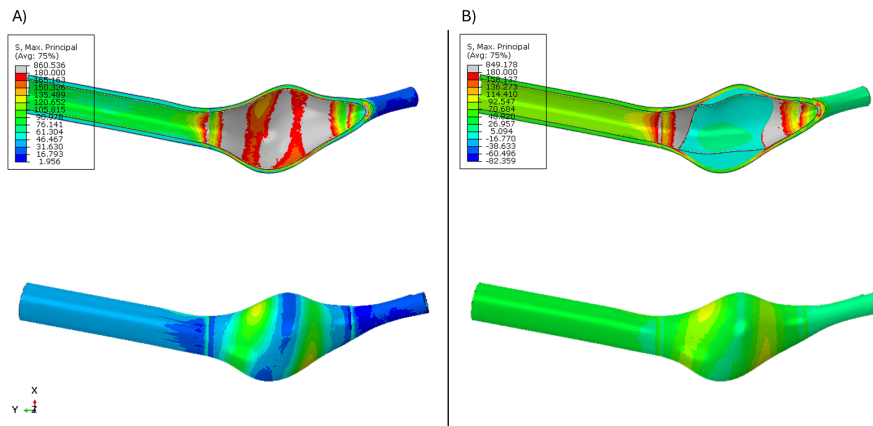


Figura F.3: Mapa de tensión principal máxima (kPa) en el modelo 02 comparado con el modelo AAA.

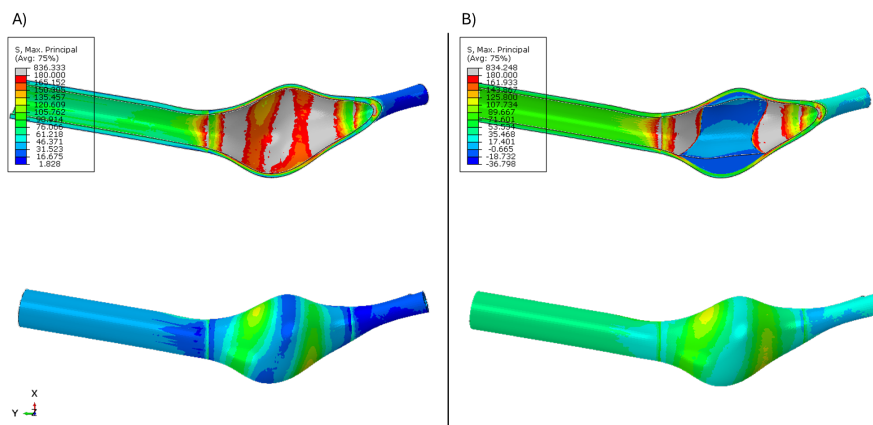


Figura F.4: Mapa de tensión principal máxima (kPa) en el modelo 04 (menor ILT) comparado con el modelo AAA.

## F.2. Mapas de Gradiente de Deformación de los Modelos con Heterogeneidades

Aquí se añadirán los mapas de gradiente de deformación para los diez modelos con heterogeneidades. Estos modelos se estudiaron para evaluar cómo la cantidad y distribución de tejido patológico influye en la detección de AAA.



Figura F.5: Mapa de gradiente de deformación para modelo  $H_{01}$ .




Figura F.6: Mapa de gradiente de deformación para modelo  $H_{02}$ .



Figura F.7: Mapa de gradiente de deformación para modelo  $H_{03}$ .




Figura F.8: Mapa de gradiente de deformación para modelo  $H_{04}$ .




Figura F.9: Mapa de gradiente de deformación para modelo  $H_{05}$ .




Figura F.10: Mapa de gradiente de deformación para modelo  $H_{06}$ .




Figura F.11: Mapa de gradiente de deformación para modelo  $H_{07}$ .




Figura F.12: Mapa de gradiente de deformación para modelo  $H_{08}$ .




Figura F.13: Mapa de gradiente de deformación para modelo  $H_{09}$ .



Figura F.14: Mapa de gradiente de deformación para modelo  $H_{10}$ .

### F.3. Mapas de Gradiente de Deformación de los Modelos AAA más ILT

En esta última sección se presentan los mapas de gradiente de deformación para los cuatro modelos de AAA con ILT. Estos mapas proporcionan una visión detallada de cómo varía el gradiente de la deformación en función de la cantidad de ILT presente.




Figura F.15: Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 01.




Figura F.16: Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 02.




Figura F.17: Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 03.




Figura F.18: Comparación de los mapas de gradiente de deformación del modelo AAA con el modelo ILT 04.