

Trabajo Fin de Máster Máster en Ingeniería Aeronáutica

Entrenamiento con medidas experimentales de una red neuronal como modelo de material para materiales hiperelásticos

Autor: Juan Pérez Gómez

Tutor: Israel García García y Adrià Quintanas Corominas

Dpto. de Mecánica de Medios continuos y Teoría de
Estructuras
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2024



Trabajo Fin de Máster
Máster en Ingeniería Aeronáutica

Entrenamiento con medidas experimentales de una red neuronal como modelo de material para materiales hiperelásticos

Autor:

Juan Pérez Gómez

Tutor:

Israel García García y Adrià Quintanas Corominas

Profesor Titular e Investigador Postdoctoral Barcelona Supercomputing Center

Dpto. de Mecánica de Medios continuos y Teoría de Estructuras
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2024

Trabajo Fin de Máster: Entrenamiento con medidas experimentales de una red neuronal como modelo de material para materiales hiperelásticos

Autor: Juan Pérez Gómez

Tutor: Israel García García y Adrià Quintanas Corominas

El tribunal nombrado para juzgar el trabajo arriba indicado, compuesto por los siguientes profesores:

Presidente:

Vocal/es:

Secretario:

acuerdan otorgarle la calificación de:

El Secretario del Tribunal

Fecha:

Agradecimientos

A mi familia, por estar siempre a mi lado apoyándome y animándome para que dé mi mejor versión, son los pilares de mi vida.

No quería irme sin agradecer a Israel y a Adrià toda su ayuda. A pesar de que el comienzo de este proyecto no fue fácil, ellos han estado siempre ahí para ofrecer cualquier ayuda. Gracias por hacer que aún me apasione más este mundo.

*Juan Pérez Gómez
Sevilla, 2024*

Resumen

En este proyecto, se parte de un modelo de red neuronal ya existente para la creación y evaluación de un modelo de material hiperelástico, utilizando medidas experimentales para su entrenamiento.

Inicialmente se profundiza en la naturaleza de los materiales hiperelásticos, sus características y los distintos modelos existentes que definen su comportamiento. También se estudiaron las bases y peculiaridades de las redes neuronales.

La campaña de ensayos experimentales, en la que se sometieron probetas de material hiperelástico a diversas cargas, proporcionó los datos necesarios para entrenar la red neuronal, tratando estas simulaciones de sustituir a los ensayos reales en laboratorio. Mientras que, los resultados obtenidos se compararon con el Método de Elementos Finitos (MEF) de ABAQUS, mostrando que el modelo neuronal captura con precisión el comportamiento mecánico bajo diversas condiciones de carga.

Este enfoque no solo ofrece una nueva alternativa a métodos tradicionales, sino que también reduce el tiempo y los recursos necesarios para el desarrollo de nuevos materiales, abriendo nuevas posibilidades en la modelización y diseño de materiales avanzados. En resumen, este trabajo demuestra el potencial de las redes neuronales como herramientas poderosas y versátiles para la ingeniería de materiales, sentando las bases para futuras innovaciones en el campo de los materiales.

Abstract

In this project, an existing neural network model is used to create and evaluate a hyperelastic material model, utilizing experimental measurements for training.

Initially, the nature of hyperelastic materials, their characteristics, and the different existing models that define their behavior were studied. The fundamentals and peculiarities of neural networks were also examined.

The experimental testing campaign, in which hyperelastic material samples were subjected to various loads, provided the necessary data to train the neural network. The obtained results were compared with the Finite Element Method (FEM) of ABAQUS, showing that the neural network model accurately captures the mechanical behavior under various loading conditions.

This approach not only offers a new alternative to traditional methods but also reduces the time and resources needed for the development of new materials, opening new possibilities in the modeling and design of advanced materials. In summary, this work demonstrates the potential of neural networks as powerful and versatile tools for material engineering, laying the groundwork for future innovations in the field of materials.

Índice

<i>Resumen</i>	II
<i>Abstract</i>	III
<i>Índice de Figuras</i>	1
<i>Índice de Tablas</i>	5
1 Introducción	6
1.1 Material Hiperelástico	6
1.1.1 Modelos de material Hiperelástico	7
Modelo de Ogden	8
1.2 Redes neuronales	8
1.2.1 Historia de las redes neuronales	8
1.2.2 Concepto de red neuronal artificial	9
Funciones de activación	10
Estrategia del Back propagation	12
Overfitting y underfitting	12
Tipos de redes	13
Formas de aprendizaje	14
1.3 Análisis de las técnicas experimentales	14
1.3.1 Correlación digital de imágenes para la medida de deformaciones	14
1.3.2 Fotoelasticidad	15
1.3.3 Holografía	16
1.3.4 Análisis tensional termoelástico	17
1.4 Motivación	18
1.5 Estructura del documento	19
2 Marco computacional	20
2.1 Tensor gradiente de deformación	20
2.2 Ecuaciones de gobierno	21
2.2.1 Cinemática	21
2.2.2 Ecuaciones constitutivas	22
2.2.3 Funcionamiento	23
2.2.4 Formato de la subrutina	23
3 Entrenamiento de la ANN	27
3.1 Definición de los ensayos para entrenar la red neuronal	27
3.1.1 Ensayo a tracción	27
3.1.2 Ensayo a compresión	37
3.1.3 Ensayo de cortadura	45
3.2 Resultados obtenidos al entrenar la red neuronal	52
3.2.1 Función de pérdida	52

3.2.2	Coeficiente de determinación R^2	52
3.2.3	Resultados para los diferentes casos de carga	53
	Caso 1: Compresión	53
	Caso 2: Tracción	55
	Caso 3: Cortadura	57
	Caso 4: Combinación de cortadura y carga axial	59
4	Aplicación del modelo a un caso real	62
4.1	Resolución mediante MEF de ABAQUS	64
4.2	Resolución mediante subrutina UANISOHYPER_INV	67
4.3	Comparación entre ambos análisis	70
5	Conclusiones	74
5.1	Líneas de trabajo futuro	75

Índice de Figuras

1.1	Clasificación de modelos para materiales Hiperelásticos, [3]	7
1.2	Esquema de una red neuronal artificial	9
1.3	Función sigmoide	10
1.4	Función tangente hiperbólica	11
1.5	Función RELU	11
1.6	Ejemplo de red neuronal artificial (ANN), [1]	12
1.7	Muestra de overfitting al usar técnica Hold-Out, [7]	13
1.8	Correlación digital de imágenes, [10]	15
1.9	Proceso seguido en el método de fotoelasticidad, [10]	16
1.10	Setup típico para la grabación de un holograma, obtenido de [10]	17
1.11	Setup típico para reconstrucción de un holograma, obtenido de [10]	17
1.12	Pasos a seguir durante el desarrollo del proyecto	19
2.1	Esquema del funcionamiento de ABAQUS/Standard al utilizar la subrutina UANISOHYPER_INV	24
2.2	Algoritmo 1 de la UANISOHYPER_INV, [4]	25
2.3	Algoritmo 2 de la UANISOHYPER_INV, [4]	25
2.4	Algoritmos 3 y 4 de la UANISOHYPER_INV, [4]	26
3.1	Morfología de la probeta para el ensayo de tracción	28
3.2	Modelo de ABAQUS de la probeta usada para el ensayo de tracción	28
3.3	Modelo de material hiperelástico de Ogden en ABAQUS	29
3.4	Empotramiento en el extremo inferior de la probeta en el ensayo a tracción como condición de contorno	30
3.5	Desplazamiento impuesto en el ensayo a tracción como condición de contorno	30
3.6	Particiones creadas para establecer los 2 puntos de referencia y así hallar el desplazamiento relativo en el ensayo de tracción	31
3.7	Mallado de la probeta para el ensayo a tracción	32
3.8	Detalle del mallado de la probeta para el ensayo a tracción	32
3.9	Probeta indeformada en el ensayo a tracción	33
3.10	Probeta deformada en el ensayo a tracción	33
3.11	Desplazamientos en la dirección Y en el ensayo de tracción	34
3.12	Deformaciones en la dirección Y en el ensayo de tracción	34
3.13	Tensiones en la dirección Y en el ensayo de tracción	35
3.14	Tensiones de Von Mises en el ensayo de tracción	35
3.15	Esquema del ensayo de compresión según norma ASTM D395	37
3.16	Modelo de ABAQUS de la probeta usada para el ensayo de compresión	38
3.17	Condiciones de contorno impuestas en la superficie apoyada del disco	38
3.18	Desplazamiento impuesto en el ensayo de compresión como condición de contorno	39
3.19	Particiones creadas para establecer los 2 puntos de referencia y así hallar el desplazamiento relativo en el ensayo de compresión	39
3.20	Mallado del disco para el ensayo a compresión	40
3.21	Probeta indeformada en el ensayo de compresión	40

3.22	Probeta deformada en el ensayo de compresión	41
3.23	Desplazamientos en la dirección Z en el ensayo de compresión	41
3.24	Deformaciones en la dirección Z en el ensayo de compresión	42
3.25	Tensiones en la dirección Z en el ensayo de compresión	42
3.26	Tensiones de Von Mises en el ensayo de compresión	42
3.27	Morfología del ensayo a cortadura según la normativa ISO 1827	45
3.28	Modelo de ABAQUS de la morfología usada para el ensayo de cortadura	45
3.29	Condición de contorno de simetría con respecto a X en el modelo de ABAQUS para el ensayo de cortadura	46
3.30	Condición de contorno de simetría con respecto a Y en el modelo de ABAQUS para el ensayo de cortadura	46
3.31	Condición de contorno que restringe desplazamientos en Z en el modelo de ABAQUS para el ensayo de cortadura	47
3.32	Condición de contorno que impone la condición de carga en términos de desplazamientos en el modelo de ABAQUS para el ensayo de cortadura	47
3.33	Mallado del modelo para el ensayo de cortadura	48
3.34	Modelo indeformado del ensayo de cortadura	48
3.35	Modelo deformado del ensayo de cortadura	48
3.36	Representación de los desplazamientos como magnitud del modelo en el ensayo de cortadura	49
3.37	Deformaciones ε_{xy} del modelo en el ensayo de cortadura	49
3.38	Tensiones σ_{xy} del modelo en el ensayo de cortadura	50
3.39	Tensiones de Von Mises del modelo en el ensayo de cortadura	50
3.40	Datos para el entrenamiento de la red neuronal, obtenidos de los ensayos	53
3.41	Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de compresión	54
3.42	Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de compresión	54
3.43	Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de compresión	55
3.44	Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de tracción	56
3.45	Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de tracción	56
3.46	Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de tracción	57
3.47	Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de cortadura	58
3.48	Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de cortadura	58
3.49	Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de cortadura	59
3.50	Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga combinado de cortadura y carga axial	60
3.51	Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga combinado de cortadura y carga axial	60
3.52	Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de cortadura y carga uniaxial	61
4.1	Estado tensional alrededor del orificio de la placa	62
4.2	Dimensiones en mm de la placa con agujero central	63
4.3	Gráfica tensiones-deformaciones para la placa con orificio central imponiendo un desplazamiento de 50 mm en su extremo superior	63
4.4	Modelo de ABAQUS para la placa con agujero central	64
4.5	Malla de la placa con agujero central	64
4.6	Desplazamientos obtenidos al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS	65

4.7	Deformaciones ε_x obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS	65
4.8	Deformaciones ε_y obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS	66
4.9	Tensiones σ_x obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS	66
4.10	Tensiones σ_y obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS	67
4.11	Tensiones de Von Mises obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS	67
4.12	Desplazamientos obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV	68
4.13	Deformaciones ε_x obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV	68
4.14	Deformaciones ε_y obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV	69
4.15	Tensiones σ_x obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV	69
4.16	Tensiones σ_y obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV	70
4.17	Tensiones de Von Mises obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV	70
4.18	Comparativa de los resultado en términos de tensiones obtenidos tanto con el MEF de ABAQUS como con la UANISOHYPER_INV en función del tiempo de simulación	71
4.19	Comparativa de los resultado en términos de deformaciones obtenidos tanto con el MEF de ABAQUS como con la UANISOHYPER_INV en función del tiempo de simulación	71
4.20	Nodos seleccionadas para realizar la comparativa entre los dos métodos	72

Índice de Tablas

1.1	Valores de los coeficientes del modelo de Ogden, [11]	8
3.1	Resultados obtenidos de la simulación para el nodo inferior en el ensayo de tracción	36
3.2	Resultados obtenidos de la simulación para el nodo superior en el ensayo de tracción	36
3.3	Resultados de F_{11} obtenidos de la simulación en el ensayo de tracción	37
3.4	Resultados obtenidos de la simulación para el nodo inferior en el ensayo de compresión	43
3.5	Resultados obtenidos de la simulación para el nodo superior en el ensayo de compresión	44
3.6	Resultados de F_{11} obtenidos de la simulación en el ensayo de compresión	44
3.7	Propiedades mecánicas del acero	46
3.8	Resultados obtenidos de la simulación para el nodo inferior en el ensayo de cortadura	51
3.9	Resultados obtenidos de la simulación para el nodo superior en el ensayo de compresión	51
3.10	Resultados de F_{11} obtenidos de la simulación en el ensayo de cortadura	52
4.1	Resultados obtenidos con ambos métodos para el nodo situado a 0° en el borde del orificio	72
4.2	Resultados obtenidos con ambos métodos para el nodo situado a 90° en el borde del orificio	72
4.3	Desviaciones de la resolución mediante el modelo de la UANISOHYPER_INV con respecto al MEF de ABAQUS para el nodo situado a 0° en el borde del orificio	72
4.4	Desviaciones de la resolución mediante el modelo de la UANISOHYPER_INV con respecto al MEF de ABAQUS para el nodo situado a 90° en el borde del orificio	72

1 Introducción

Este proyecto se enfoca en la predicción del comportamiento de materiales hiperelásticos utilizando redes neuronales, basándose en datos obtenidos de una campaña de ensayos específicos. La capacidad de las redes neuronales para predecir comportamientos complejos ofrece una alternativa prometedora a los métodos tradicionales.

En los últimos años, la implementación de modelos basados en la teoría de la hiperelasticidad ha avanzado significativamente, permitiendo estudiar y predecir el comportamiento de materiales que experimentan grandes deformaciones. Estos modelos se han integrado en diversos programas de elementos finitos, proporcionando herramientas poderosas para el análisis estructural. Sin embargo, la predicción precisa del comportamiento de materiales hiperelásticos sigue siendo un desafío debido a la complejidad de su respuesta mecánica.

El objetivo de este proyecto es entrenar una red neuronal capaz de predecir el comportamiento de materiales hiperelásticos, alimentada con datos obtenidos de la simulación de ensayos experimentales específicos, sustituyendo dichas simulaciones a los ensayos reales en laboratorio. La implementación de esta red neuronal en un entorno de elementos finitos permitirá realizar análisis más precisos y eficientes. La metodología incluirá la realización de una campaña de ensayos detallada para recopilar datos que describan el comportamiento hiperelástico de los materiales, la capacitación de la red neuronal con estos datos y la integración de la red neuronal en un código de elementos finitos como ABAQUS mediante subrutinas personalizadas.

La organización de este capítulo será la siguiente: en la sección 1.1 se presentará una introducción breve a los materiales hiperelásticos. En la sección 1.2 se dedica a la teoría y aplicación de redes neuronales en la predicción de comportamientos materiales. La sección 1.3 está destinada a el entendimiento y la descripción de diversas técnicas de ensayo. Finalmente, en la sección 1.4 se detallarán los objetivos específicos del proyecto y su organización general.

1.1 Material Hiperelástico

Dado que nuestro proyecto se centra en el entrenamiento de una red neuronal para predecir el comportamiento de materiales hiperelásticos, se procede a la definición de los mismos.

Un material hiperelástico, también conocido como material elástico no lineal, es un tipo de material que se deforma de manera reversible cuando se le aplica una carga, y cuya relación entre el esfuerzo (tensión) y la deformación (distorsión) es no lineal. La característica principal de los materiales hiperelásticos es que su comportamiento elástico puede ser descrito por una función de energía de deformación, la cual depende únicamente del estado de deformación del material. Se trata de un caso particular del material elástico de Cauchy.

$$W = f(I_1, I_2, I_3) \tag{1.1}$$

El comportamiento constitutivo de este tipo de materiales, se define como se ha mencionado anteriormente, a partir de un potencial de energía de deformación, el cual se basa en los tres invariantes del tensor de deformación de Green: I_1, I_2 y I_3 .

Donde, si definimos los tres invariantes en función de los ratios de deformación principales, λ_1, λ_2 y λ_3 queda

$$I_1 = \lambda_1^2 + \lambda_2^2 + \lambda_3^2 \tag{1.2}$$

$$I_2 = \lambda_1^2 \lambda_2^2 + \lambda_2^2 \lambda_3^2 + \lambda_3^2 \lambda_1^2 \tag{1.3}$$

$$I_3 = \lambda_1^2 \lambda_2^2 \lambda_3^2 \tag{1.4}$$

Hay muchos materiales hiperelásticos que se pueden considerarse incompresibles. Este trabajo se va a centrar en este tipo de materiales, con lo que $I_3=1$. Esto implica que W es solo función de I_1 y I_2

$$W = f(I_1 - 3, I_2 - 3) \tag{1.5}$$

1.1.1 Modelos de material Hiperelástico

En general, encontramos dos tipos principales de modelos de materiales hiperelásticos. Los modelos fenomenológicos, que hacen referencia a la mecánica de medios continuos, donde las constantes del material son generadas mediante ajuste de curvas. El otro tipo, son los modelos micromecánico, con referencia a la microestructura donde las constantes del material son generadas mediante ensayos. Ambas fenomenologías se puede ver en la figura 1.1.

Aunque hay muchos modelos propuestos para describir la respuesta de este tipo de materiales, sólo unos pocos pueden describir el comportamiento de los mismos de manera satisfactoria. para diferentes estados de carga. En concreto, nos centraremos en los modelos fenomenológicos correspondientes a materiales isocóricos.

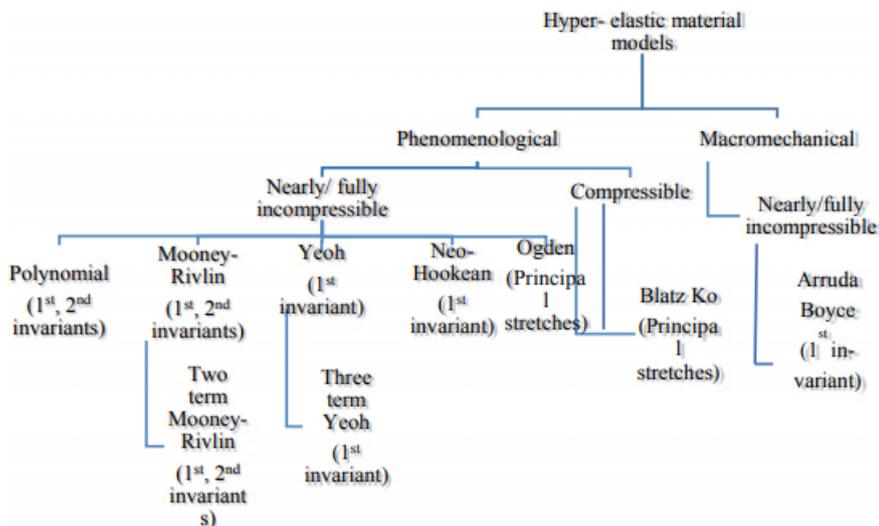


Figura 1.1 Clasificación de modelos para materiales Hiperelásticos, [3].

Los modelos en los que nos centraremos, modelan la energía de deformación almacenada en el material por unidad de volumen (densidad de energía de deformación), W , como un polinomio dependiente de términos desviatorios y volumétricos:

$$W = \sum_{i=0}^N C_{ij} (\bar{I}_1 - 3)^i (\bar{I}_2 - 3)^j + \sum_{i=1}^N \frac{1}{D_i} (J_{el} - 1) \tag{1.6}$$

donde C_{ij} son constantes del material que controla el comportamiento a cortadura y puede determinarse mediante ensayos uniaxiales, biaxiales y planos; D_i es la constante del material que controla la compresibilidad volumétrica y J_{el} es el ratio de volumen elástico.

Los modelos más característicos para este tipo de materiales son: formulación de Mooney-Rivlin, Neo-Hookeana, de Yeoh, de Ogden, de Arruda-Boyce, de Marlow, de Van der Waals, etc. Concretamente, nos centraremos en la de Ogden, pues es el que usamos para nuestro desarrollo.

Modelo de Ogden

Este modelo, se trata de un modelo fenomenológico basado en las deformaciones principales en lugar de en los invariantes. Este modelo tiene la capacidad de capturar el endurecimiento de la curva tensión-deformación y modelar a los materiales hiperelástico con precisión para grandes rangos de deformación

$$W = \sum_{i=0}^3 \frac{2\mu_i}{\alpha_i^2} (\bar{\lambda}_1^{\alpha_i} + \bar{\lambda}_2^{\alpha_i} + \bar{\lambda}_3^{\alpha_i} - 3)^i + \sum_{i=1}^3 \frac{1}{D_i} (J_{el} - 1)^{2i} \quad (1.7)$$

donde $\bar{\lambda}_i$ son las deformaciones desviadoras principales, mientras que μ_i y α_i son propiedades del material dependientes de la temperatura, tal y como se indica en [3].

La razón de usar este modelo es que proporciona buenos resultados y además sus coeficientes son fáciles de obtener y manejar, algo que no ocurre en otros modelos de material hiperelástico.

Concretamente, los coeficientes del modelo con los que se ha realizado los diferentes ensayos que se muestran más adelante son, los que aparecen en la tabla 1.1.

Tabla 1.1 Valores de los coeficientes del modelo de Ogden, [11].

μ_i [MPa]	α_i	D_i
3.723	1.545	0
6.562e-3	5.846	0
0.170	-1.835	0

Como se puede ver, se ha impuesto $N=3$.

1.2 Redes neuronales

1.2.1 Historia de las redes neuronales

Las redes neuronales han recorrido un largo camino desde sus inicios teóricos hasta convertirse en una de las técnicas más poderosas y versátiles en el campo del machine learning y la inteligencia artificial (IA). La historia de las redes neuronales comienza en 1943 con el trabajo pionero de Warren McCulloch y Walter Pitts, quienes desarrollaron el primer modelo computacional de una neurona artificial, conocido como lógica umbral. Este modelo sentó las bases para dos enfoques distintos en la investigación: uno centrado en entender los procesos biológicos del cerebro y otro en la aplicación de estos principios a la inteligencia artificial.

A finales de los años 40, el psicólogo Donald Hebb propuso una teoría sobre la plasticidad neuronal, denominada aprendizaje de Hebb, que sugería cómo las conexiones entre neuronas se fortalecen a través del uso repetido. Esta teoría fue crucial para el desarrollo de modelos computacionales de aprendizaje no supervisado. Inspirados por estas ideas, en la década de 1950, investigadores como Farley y Clark comenzaron a simular redes neuronales en computadoras primitivas, conocidas como "calculadoras", en el MIT. En 1958, Frank Rosenblatt introdujo el perceptrón, un algoritmo de reconocimiento de patrones que utilizaba una red de neuronas artificiales, aunque presentaba limitaciones significativas como la incapacidad de procesar funciones no lineales complejas, tales como el circuito de o-exclusiva.

La investigación en redes neuronales sufrió un estancamiento significativo después de que Marvin Minsky y Seymour Papert publicaran en 1969 una crítica que destacaba estas limitaciones y la falta de poder computacional de la época. Sin embargo, el campo fue revitalizado en 1975 con la introducción del algoritmo de propagación hacia atrás por Paul Werbos. Este algoritmo resolvió problemas críticos, permitiendo la formación eficiente de redes neuronales multicapa y marcando un avance fundamental.

Durante los años 80, el concepto de conexionismo, popularizado por David Rumelhart y James McClelland, promovió el uso de redes neuronales para simular procesos cognitivos en los ordenadores. A pesar de la competencia de métodos alternativos como las máquinas de soporte vectorial y los clasificadores lineales en la década de 1990, las redes neuronales encontraron aplicaciones exitosas en áreas específicas, como la predicción de estructuras de proteínas.

El verdadero resurgimiento de las redes neuronales ocurrió a principios de los años 2000 con el incremento del poder computacional y la introducción de GPUs para acelerar el entrenamiento de modelos. Técnicas como el max-pooling y la preformación no supervisada de redes multicapa permitieron superar desafíos como el problema del desvanecimiento del gradiente. Estas innovaciones dieron lugar al auge del aprendizaje profundo, aplicando redes neuronales profundas a gran escala en tareas de procesamiento de imágenes y reconocimiento visual.

El aprendizaje profundo, una subdisciplina del machine learning, ha demostrado ser extremadamente efectivo para una variedad de aplicaciones, desde la visión por computadora hasta el procesamiento del lenguaje natural. A diferencia de otros métodos de machine learning, las redes neuronales profundas pueden aprender representaciones jerárquicas complejas de los datos, lo que las hace particularmente adecuadas para problemas donde las relaciones entre las características son altamente no lineales.

En resumen, las redes neuronales han evolucionado desde modelos teóricos básicos hasta convertirse en herramientas esenciales en el arsenal del machine learning. Su capacidad para modelar y aprender de datos complejos ha transformado múltiples campos y sigue siendo un área de investigación y aplicación dinámica y en rápida evolución.

1.2.2 Concepto de red neuronal artificial

El concepto de red neuronal artificial, se engloba dentro del marco actual del machine learning y se trata de un conjunto organizado de neuronas que se agrupan en capas, de tal forma que cada capa recibe datos de la capa anterior y los entrega a la siguiente. Al colocar capas de manera secuencial conseguimos que la red aprenda un conocimiento jerarquizado.

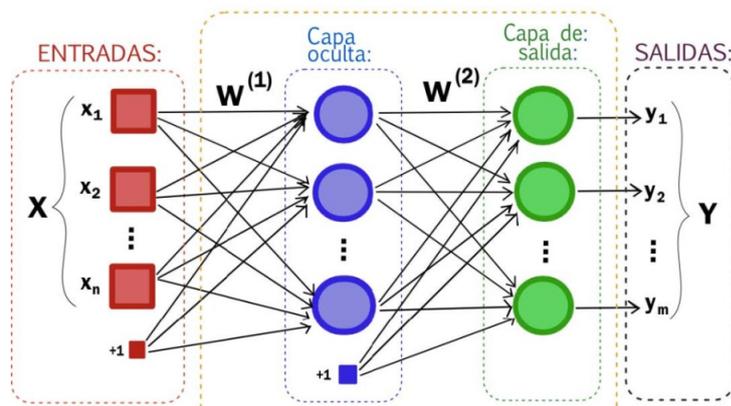


Figura 1.2 Esquema de una red neuronal artificial.

Por otro lado, el término neurona mencionado anteriormente, hace referencia a la unidad de procesamiento mínima de una red neuronal. Estas neuronas, tienen conexiones de entrada a través de las cuales reciben estímulos externos (valores de entrada). Con estos datos de entradas realizarán cálculos internos mediante una

función de activación (como por ejemplo podría ser una suma ponderada de las entradas que van multiplicadas por unos pesos) y devolverá una salida.

Como se puede ver en la figura 1.2, los parámetros designados con **X** son las entradas, los designados con **Y** las salidas y los designados con **W**^(*) son parámetros propios de la red neuronal. Estos últimos parámetros se determinan de tal forma que ante un conjunto de parámetros de entrada y de salida, el modelo de la red neuronal sea capaz de ajustarse de manera adecuada a dichos datos

Funciones de activación

La función de activación de una neurona se encarga de distorsionar su valor de salida, añadiéndole deformaciones no lineales para así poder encadenar de forma efectiva la computación de varias neuronas, ya que si todas las células lo que hiciesen fuese sumar ponderadamente las entradas, la red neuronal colapsaría y sería equivalente a tener una única neurona.

Por otro lado, no cualquier función puede ser una función de activación para una neurona, para serlo estas deben cumplir una serie de requisitos asociados a restricciones físicas, como se indica en [1]. Algunas de las funciones matemáticas que pueden ser usadas para este fin son:

- **Función sigmoide:**

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1.8)$$

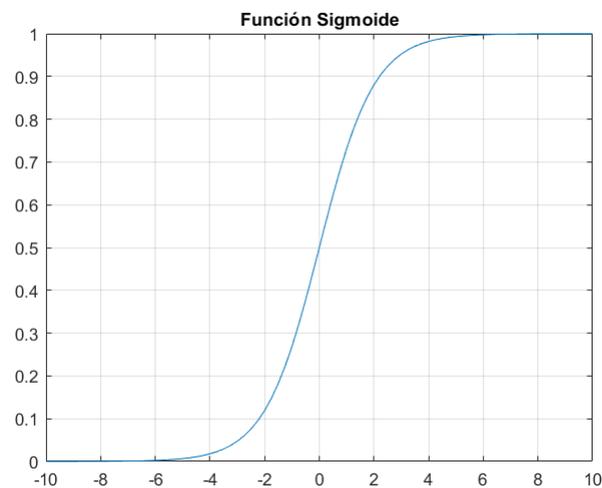


Figura 1.3 Función sigmoide.

- **Función tangente hiperbólica:**

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1.9)$$

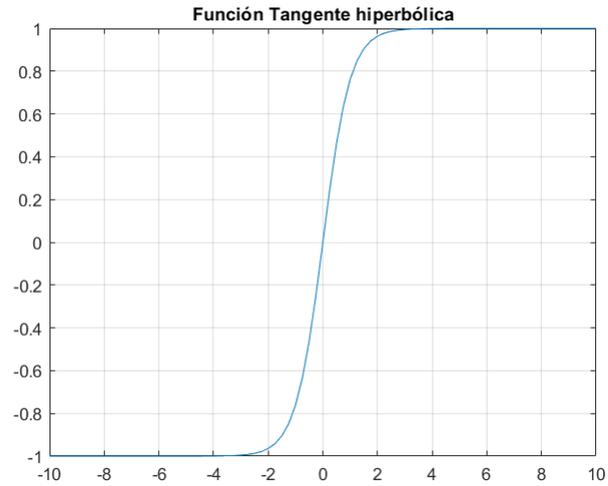


Figura 1.4 Función tangente hiperbólica.

- **Función unidad rectificadora lineal**

$$f(x) = \begin{cases} x & \text{si } x > 0 \\ 0 & \text{si } 0 < x \end{cases} \quad (1.10)$$

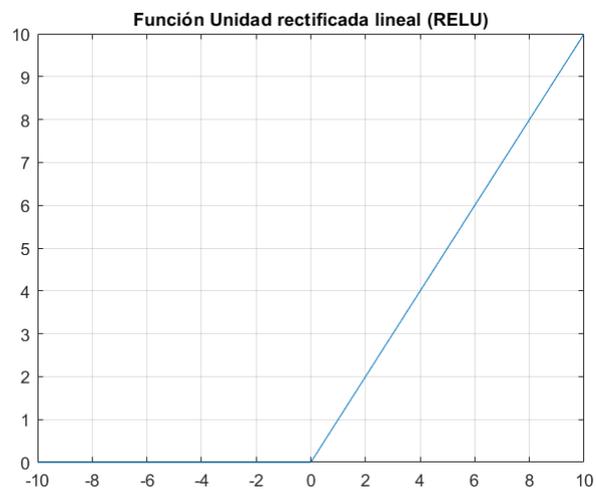


Figura 1.5 Función RELU.

Se muestra ahora un ejemplo, en la figura 1.6, del funcionamiento de una red neuronal artificial para clarificar la intervención de las funciones de activación y de los parámetros de la red, dicho ejemplo ha sido obtenido de la referencia [1].

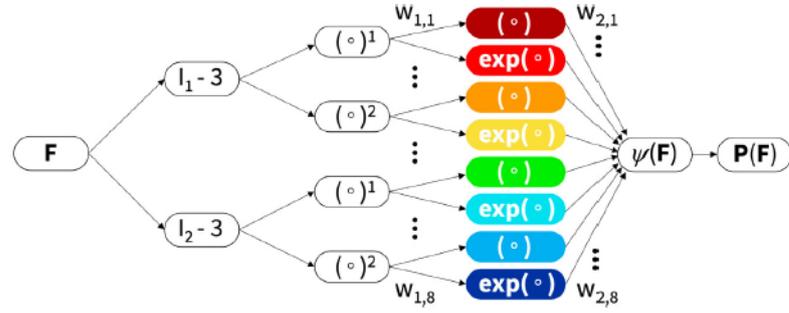


Figura 1.6 Ejemplo de red neuronal artificial (ANN), [1].

Como se puede ver, esta red neuronal cuenta con dos entradas ($I_1 - 3$) y ($I_2 - 3$) y con dos capas ocultas, la primera de ellas genera potencias $(\circ)^1$ y $(\circ)^2$ de los valores de entrada y la segunda aplica la identidad (\circ) y la función exponencial $(exp(\circ)-1)$ a estas potencias, de tal forma que el conjunto de ecuaciones para esta red neuronal es el siguiente:

$$\begin{aligned}
 \psi(I_1, I_2) = & w_{2,1}w_{1,1}[I_1 - 3] + w_{2,2}[exp(w_{1,2}(I_1 - 3)) - 1] \\
 & + w_{2,3}w_{1,3}[I_1 - 3]^2 + w_{2,4}[exp(w_{1,4}(I_1 - 3)^2) - 1] \\
 & + w_{2,5}w_{1,5}[I_2 - 3] + w_{2,6}[exp(w_{1,6}(I_2 - 3)) - 1] \\
 & + w_{2,7}w_{1,7}[I_2 - 3]^2 + w_{2,8}[exp(w_{1,8}(I_2 - 3)^2) - 1]
 \end{aligned} \tag{1.11}$$

donde $w_{n,m}$ son los parámetros de la red y son los que se determinarían mediante el entrenamiento de la red. Dicho entrenamiento como se ha dicho ya consiste en pasarle a la red conjuntos de datos de entrada y salida, de manera que los parámetros de la red se toman para que los resultados de salida de la red se ajusten de la mejor manera posible a los datos de salida proporcionados.

Estrategia del Back propagation

Se trata de una técnica mediante la cual la red neuronal artificial es capaz de ajustar por sí misma sus propios parámetros.

Se trata de realizar un análisis sobre toda la cadena de responsabilidades que ha afectado al resultado. Si durante este proceso encontramos una neurona con influencia en el error obtenido deberemos responsabilizar a esa neurona con parte del error. Este análisis tiene sentido realizarlo hacia atrás, es decir, desde la señal de error hasta las primeras capas, porque el error de las capas posteriores depende directamente del error de las capas anteriores (si los datos de una capa afectan poco al error final, las anteriores también afectarán poco. Si esto no fuese así sí que habría que revisar las capas que encontramos aguas arriba de la señal de error).

Aplicar back propagation consiste en operar de manera recursiva capa tras capa moviendo el error hacia atrás de tal forma que cuando lleguemos a la primera capa habremos obtenido el error para cada capa, para cada neurona y para cada uno de sus parámetros, de esta forma será más fácil identificar el error.

Overfitting y underfitting

El overfitting y el underfitting se tratan de dos problemas de ajuste con los que nos encontramos al realizar el entrenamiento de una red neuronal.

En concreto, el underfitting se da cuando el modelo es muy rígido de tal forma que la red no se puede adaptar a los datos y por tanto, los errores para las predicciones de datos nunca vistos (datos diferentes a los de training) son mayores. Es decir, la red no ofrece flexibilidad suficiente para adaptarse al conjunto de datos que se le proporciona.

Por otro lado, el overfitting es justo el caso contrario al anterior. Aquí el problema, es el exceso de flexibilidad con el que se dota al modelo que hace que este sea incluso capaz de modelar el ruido contenido en los datos que se le pasan a la red para su entrenamiento. Es decir, el modelo se especializa muy bien en resolver

los casos para los que ha sido entrenado (como si memorizase las soluciones) pero si a la red le pasamos un conjunto de datos diferentes a los de entrenamiento, probablemente la red no ofrezca unos buenos resultados.

Por último, cabe decir que el caso en el que el overfitting aparece se puede identificar. Para ello, sería necesario dividir el conjunto de datos del que se dispone en dos grupos: uno para realizar el entrenamiento (80% de los datos totales) y otro para realizar el testeo (20% de los datos totales) con la consigna de que estos datos deben ser independientes e idénticamente distribuidos en ambos grupos. Si al representar los errores obtenidos en el testeo y el entrenamiento sucede una situación similar a la que se muestra en la figura 1.7, el overfitting habrá tenido lugar y los resultados que se están obteniendo durante el testeo están distorsionados. Esta técnica recibe el nombre de técnica de Hold-Out, figura 1.7.

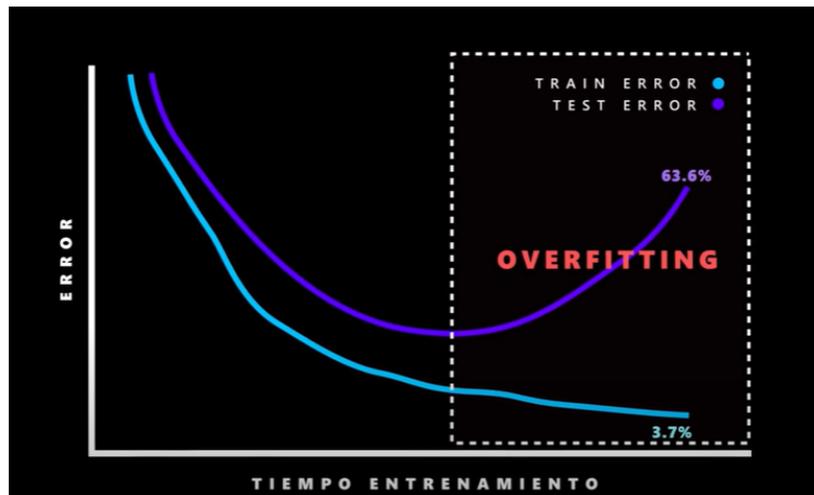


Figura 1.7 Muestra de overfitting al usar técnica Hold-Out, [7].

Tipos de redes

Hay muchos tipos de redes neuronales artificiales, a continuación se definen alguno de ellos, para ello se ha hecho uso de la referencia

- **Adaline y madaline:** Modelos adaptativos desarrollados por Bernard Widrows Y Marcian Hoff de la Universidad de Stanford.

El significado de Adaline es Adaptative Linear Element y fue desarrollado en el objetivo de reconocer patrones binarios. Su funcionamiento se basa en la suma de pesos de las entradas produciendo una salida con valor 0 o 1. Resulta un elemento muy importante ya que de él se derivan redes más complejas. Si juntásemos y organizásemos varias capas Adaline formaríamos una red Madaline (Multiple Adaptative Linear Element).

- **Red backpropagation:** Fue creada en 1986, se basa en el aprendizaje mediante asociación de patrones existentes.

El backpropagation tiene capacidad para generalizar que hace un comportamiento, esto lo consigue mediante un conjunto de muestras escogidas como patrones de entrenamiento. Es como un cerebro humano, por lo que necesita de una etapa de aprendizaje.

Este tipo de red requiere una búsqueda de una función de comportamientos que se acople a los valores muestreados y al comportamiento del sistema con un error mínimo.

- **Perceptron multicapa:** Se trata de una red conformada por un conjunto de neuronas que permite la comunicación mediante el envío de señales entre sí con un conjunto de buenas conexiones. Por otro lado, cuenta con un estado de activación que determina la salida de la neurona. Estas neuronas están

conectadas entre sí y cada conexión se termina por un peso que ayuda a fijar el efecto de la señal de la neurona. Además, cuenta con la regla de propagación que determina la entrada efectiva de una neurona a partir de entradas externas. Esta red tiene capacidad de aprendizaje.

Básicamente, se trata de un conjunto de capas compuestas por neuronas. Estas neuronas se encargan de recibir señales o patrones del exterior y propagar dichas señales a las neuronas de la siguiente capa.

A los anteriores tipos de capas se les podría sumar más pero son tecnologías que aún no están del todo maduras. Concretamente el tipo de red que usamos en el presente proyecto es el último, el de Perceptron multicapa.

Formas de aprendizaje

Generalmente, hay dos tipos de metodologías de aprendizaje, la forma supervisada y la no supervisada.

- **Aprendizaje supervisado:** Consiste en deducir una función a partir de datos o información de entrenamiento, estos datos pueden estar compuestos por vectores u objetos dados en pares, un par de la información es la entrada mientras que el otro son los resultados deseados. Su finalidad es predecir de manera adecuada cualquier entrada válida que el usuario ingrese.

Este tipo de aprendizaje, consiste en el entrenamiento de la red a través de un agente y medios externos que provea a la red de información de tal forma que el modelo pueda obtener información mediante esta entrada y así mejorar las conexiones y los parámetros internos del mismo en el caso de que el aprendizaje del modelo no sea el esperado.

- **Aprendizaje no supervisado:** De manera inversa al caso anterior, ahora el aprendizaje de la red no es supervisado por ningún agente externo ni requiere de un vector de salida, partiendo únicamente de un vector de entrada. Es la propia red la que distribuye patrones usando la densidad probabilística, extrayendo rasgos según la similitud a los datos de entrada, para ello, se necesita de una gran cantidad de vectores de entrada.

Su funcionamiento se basa en que las neuronas se presentan inicialmente por valores aleatorios y para cada característica de entrada que se le pasa a la red, estas van modificando estos valores.

1.3 Análisis de las técnicas experimentales

Dado que lo que se está buscando es entrenar a la red con los resultados obtenidos de métodos experimentales, a continuación, se analizan las principales técnicas experimentales existentes para la captación de datos para la realización de un análisis de tensiones y deformaciones, dentro del marco de la mecánica de sólidos. Aunque aquí se muestran una corta lista de técnicas hay muchas más, que se pueden encontrar en [10], referencia en la que se basa el análisis aquí mostrado.

1.3.1 Correlación digital de imágenes para la medida de deformaciones

La correlación de imágenes digital tridimensional mide el campo de desplazamientos de una superficie curva o plana en especímenes, con una precisión del orden de $\pm 0,01$ píxeles. Las deformaciones superficiales pueden extraerse de los datos de desplazamiento para muestras cuyo tamaño oscila de metros a micras y bajo una amplia gama de cargas mecánicas y condiciones ambientales, utilizando una gran batería de sistemas de imágenes incluyendo microscopía óptica, electrónica de barrido y microscopía de fuerza atómica, como puede verse en la figura 1.8.

Se trata de un método que adquiere imágenes de un objeto sin tener contacto físico directo con él. Estas imágenes son almacenadas en digital, y se analizan para extraer medidas de forma y deformaciones del campo completo.

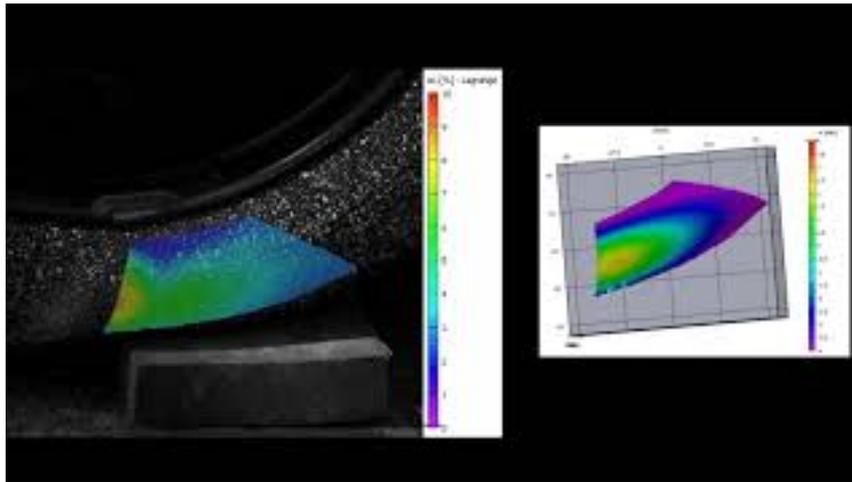


Figura 1.8 Correlación digital de imágenes, [10].

Esta técnica experimental se basa en asumir dos ideas claves para convertir imágenes en mediciones experimentales del objeto (desplazamientos y deformaciones). En primer lugar, se supone que existe una correspondencia directa entre los movimientos de los diferentes puntos del objeto en la imagen y los movimientos de puntos en el objeto. Mientras se mantenga esta suposición, los movimientos de los diferentes puntos pueden utilizarse para cuantificar los desplazamientos de los mismos. Además, dado que un objeto se representa generalmente como un medio continuo, la correspondencia entre la imagen y los puntos del objeto garantiza la continuidad, para describir la relación entre los puntos de una imagen a medida que el objeto se deforma.

En segundo lugar, se supone que cada subregión tiene un contraste luminoso (variación espacial de la intensidad luminosa), de tal forma que se puede realizar una correspondencia precisa para definir los movimientos locales de la imagen. Esto, junto con la primera suposición hace que sea posible mejorar el ajuste preciso permitiendo que cada subregión de la imagen se deforme mediante una forma funcional adecuada (por ejemplo, afín, cuadrática) y, por tanto, aumentar la precisión de los movimientos medidos. La variación puede obtenerse aplicando un patrón aleatorio de alto contraste (por ejemplo, pintando o mecanizando de la superficie) o puede producirse debido a las características naturales de la superficie del material. El perfil del objeto, o forma tridimensional del mismo también puede determinarse mediante correlación digital de imágenes, proyectando un patrón aleatorio sobre la muestra y utilizando varias disposiciones ópticas.

1.3.2 Fotoelasticidad

La fotoelasticidad se encuentra en la categoría de los interferómetros de trayecto común y las vibraciones no tienen mucho efecto en ellos. Además, los requisitos de coherencia no son estrictos. De ahí que la fotoelasticidad haya tenido tanta aceptación y se haya establecido como una excelente herramienta para visualizar/cuantificar campos de tensión, además, de usarse como ayuda didáctica para el análisis de tensiones.

Esta técnica experimental, se basa en el principio físico de la doble refracción. Dicho fenómeno tiene lugar cuando un rayo incidente da lugar a dos rayos refractados, uno ordinario y otro extraordinario en medios cristalinos que son ópticamente anisótropos. Los rayos ordinarios y extraordinarios son planos polarizados y sus planos de polarización son perpendiculares entre sí. Uno de los rayos es extraordinario en el sentido de que viola la ley de Snell en circunstancias adecuadas. Este rayo no necesita estar confinado al plano de incidencia. Además, su velocidad cambia de forma continua con el ángulo de incidencia.

Ciertos materiales transparentes no cristalinos, en particular algunos plásticos poliméricos, son ópticamente isótropos en condiciones normales, pero se vuelven doblemente refractivos o birrefringentes cuando se someten a esfuerzos. Este efecto persiste normalmente mientras se mantienen las cargas, pero desaparece casi instantáneamente o después de algún intervalo de tiempo dependiendo del material y de las condiciones de carga. Esta es la característica física en la que se basa la fotoelasticidad. El modelo fotoelástico se comporta como un retardador con diferentes características en diferentes puntos en función del campo de

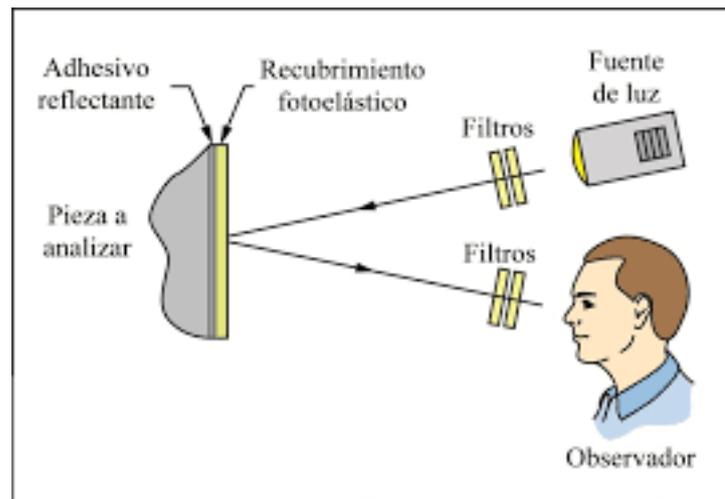


Figura 1.9 Proceso seguido en el método de fotoelasticidad, [10].

tensión inducido. La luz tiene que incidir en el modelo con incidencia normal y las direcciones principales de tensión actúan como ejes polarizadores en el punto de interés. Los rayos ordinarios y extraordinarios están polarizados con sus ejes de polarización perpendiculares entre sí y viajan en la misma dirección pero con velocidades diferentes. Cuando los rayos emergen, existe un retardo relativo entre los rayos, lo que contribuye a la formación de franjas, que indican los puntos que se encuentran a un mismo nivel tensional.

En resumen, es un método que permite visualizar y medir de manera cualitativa y cuantitativa la distribución de tensiones internas en un objeto, a partir de las deformaciones que hay presentes en el mismo. Un esquema del proceso seguido en esta metodología se puede observar en la figura 1.9.

1.3.3 Holografía

Se trata de una técnica experimental no destructiva para aplicaciones de interés en mecánica. Las áreas donde esta técnica tiene más uso son la aeroespacial, automoción, electrónica, equipamiento, dental/ortodoncia, maquinaria, medicina, embalaje, transporte y seguridad.

La holografía es una técnica que permite la recodificación de todo el frente de onda de la energía luminosa que se propaga en un medio adecuado. La grabación de la amplitud de las ondas se realiza mediante medios fotosensibles, que registran la irradiancia convirtiéndola en las correspondientes variaciones de la opacidad de la superficie de detección. La fase del frente de ondas, sin embargo, se registra utilizando el principio de interferometría. Estas mediciones de amplitud y fase se consiguen iluminando a un objeto, de cualquier complejidad, con un haz de luz de tal forma que cada punto del objeto refleja y dispersa dicha luz. Así cada punto, puede ser considerado como una fuente de ondas que emanan. Si un material fotosensible se expone de tal manera que la luz reflejada por el objeto incida directamente sobre él sin que intervenga ninguna lente, la superficie de detección del material quedará expuesta uniformemente. Es decir, no se registrará ninguna imagen porque la luz de cada punto del objeto incidirá en cada punto del material fotosensible. Por lo tanto cada parte del material será sometida a la misma energía y se producirá una exposición uniforme del medio.

En la práctica, un holograma es grabado de manera similar a la que se muestra en la figura 1.10. Se cuentan con dos haces de luz cuya superposición da lugar a un patrón de interferencia (franjas interferométricas) que es grabado en un medio fotosensible constituyendo así un holograma.

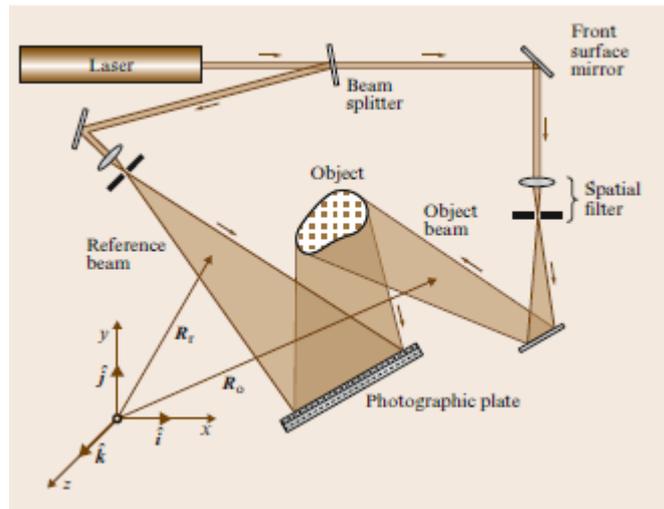


Figura 1.10 Setup típico para la grabación de un holograma, obtenido de [10].

Por otro lado, para la reconstrucción del holograma se utiliza un setup como el de la figura 1.11. Durante dicho proceso, la variación en la transmisión de la grabación holográfica, debido a las franjas grabadas, difracta la luz en los distintos órdenes de la reconstrucción del holograma. Como consecuencia de ello los frentes de onda difractados se propagan de tal manera que se asemejan, en todas sus características, al objeto original utilizado para construir el holograma. Por lo tanto las ondas difractadas de primer orden producidas por el holograma son cada una una réplica de la onda emitida por el objeto original sometida a las distorsiones impuestas por un medio holográfico.

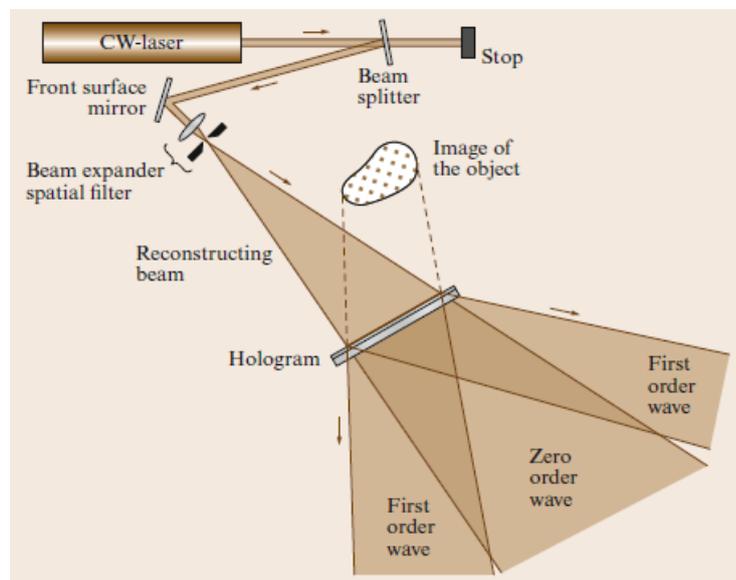


Figura 1.11 Setup típico para reconstrucción de un holograma, obtenido de [10].

Como se puede ver esta técnica tiene un gran potencial para la determinación de desplazamientos y/o deformaciones que se producen en los puntos de un objeto.

1.3.4 Análisis tensional termoelástico

El análisis tensional termoelástico es una técnica emergente que hasta la fecha se ha usado de manera exitosa en multitud de campos como la evaluación y validación de conceptos de diseño, mecánica de la fractura, detección de daños, control de la fatiga y análisis de tensiones residuales. Mediante esta técnica se obtienen unos mapas de las superficies de tensión en tiempo real midiendo los cambios de temperatura con el tiempo.

En condiciones adiabáticas y reversibles una estructura cargada cíclicamente experimenta variaciones de temperatura que, para materiales isótropos, son proporcionales al cambio en el conjunto de las tensiones o deformaciones principales. El análisis termoelástico de tensiones (o termoelasticidad) utiliza un radiómetro de infrarrojos para medir las fluctuaciones locales de temperatura y relacionar estos cambios con las tensiones dinámicas asociadas mediante principios termodinámicos. Este enfoque difiere de los métodos disipativos, como la vibrotermografía, que asocian las variaciones locales de temperatura con la energía disipada, y no a la energía almacenada.

El análisis termoelástico de tensiones, como se indica en [10], es una técnica “full-field” sin contacto que determina las tensiones térmicas (las tensiones debidas a variaciones de temperatura, no las tensiones mecánicas) de estructuras reales en sus entornos operativos con una sensibilidad similar a la de las bandas extensométricas, que se usan para medir deformaciones. Como ya es sabido, la temperatura de un gas disminuye cuando el gas se expande y aumenta cuando se comprime. En los sólidos se produce un efecto similar. Los cambios de temperatura asociados a las deformaciones elásticas en un sólido son muy pequeños y hasta hace poco se consideraban insignificantes. Sin embargo, los avances en la tecnología de detectores de fotones infrarrojos ha permitido medir estas variaciones de temperatura de forma fiable. Es por ello que resulta un técnica experimental bastante interesante para la determinación de las tensiones a las que está sometido un objeto.

Tras analizar todas las técnicas mostradas con anterioridad, se puede llegar a la conclusión de que no hay ningún ensayo que nos permita medir directamente las tensiones, por lo que para el caso que nos ocupa, desarrollaremos una campaña de ensayos que nos permita obtener pares de resultados en tensiones y deformaciones relacionados entre sí, para entrenar a la red.

1.4 Motivación

La motivación del proyecto que aquí se presenta, surge en el ámbito actual en el que la inteligencia artificial está en auge con la idea de facilitar la vida de las personas en todos los aspectos. Más concretamente, este proyecto se centra en hacerle la vida más sencilla a los científicos que trabajan en el campo de los materiales y los ensayos para determinar sus características. Para ello, el objetivo de este proyecto es el de proponer una metodología de ensayo basada en la simulación de ensayos a través de ABAQUS y así poder ajustar un modelo existente basado en redes neuronales para establecer un modelo de material para materiales hiperelásticos, de tal forma que cuando estas redes estén ya entrenadas les podamos introducir unos inputs y nos devuelva unos outputs (estos inputs y outputs pueden ser tensiones, deformaciones, desplazamientos, etc.) y que estos outputs sean lo más cercanos o próximos posibles a los que se obtendrían como resultados de ensayos reales como puede ser el ensayo de tracción. Singularmente, este modelo está destinado a materiales hiperelásticos, cuya definición ya se ha comentado en la sección 1.1.

Es importante recalcar, que ante la no posibilidad de hacer ensayos en el laboratorio para obtener los datos con los que entrenar a la red, se van a realizar modelos de ensayos en ABAQUS que sustituyan a estos ensayos en laboratorios con tal de obtener estos datos. Por lo que a modo de esquema resumen los pasos a seguir en este proyecto son los mostrados en la figura 1.12.

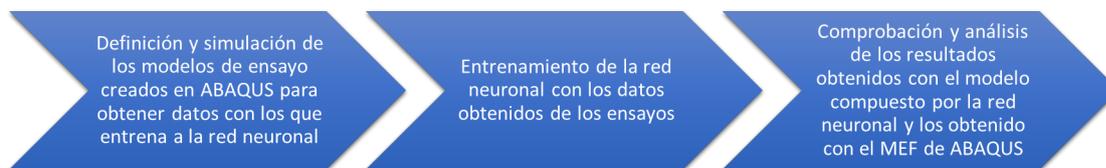


Figura 1.12 Pasos a seguir durante el desarrollo del proyecto.

También es importante mencionar, que en este proyecto no se programa ningún tipo de red neuronal ni de subrutina para crear el modelo, estas se han tomado de la referencia [1].

1.5 Estructura del documento

Tras presentar cuál es el objetivo que se pretende alcanzar con este proyecto y definir algunos conceptos claves para el desarrollo del mismo, se prosigue definiendo la estructura, en cuanto a contenido, que seguirá el documento.

En primer lugar, en el Capítulo 2 se define que es una subrutina UANISOHYPER_INV y como se integra la misma con ABAQUS. Además, se presenta el modelo que incluye dicha subrutina y como este hace uso de los datos suministrados por la red neuronal tras su entrenamiento.

Posteriormente, en el Capítulo 3 se muestran los modelos de ensayo, tanto para tracción como para compresión y cortadura, que se han modelado en ABAQUS entrando en detalle en como se ha realizado dicho modelaje y la normativa de la que se ha hecho uso para dicho fin. Además, se muestran los datos obtenidos de simular en ABAQUS dichos ensayos y que son los que posteriormente se le suministran a la red para su entrenamiento. Por otro lado, se muestran los resultados de entrenar a la red mediante gráficas comparativas en la que se confrontan el modelo proporcionado por la red neuronal y los datos experimentales disponibles, también se usan distintos parámetros para medir la calidad del modelo con respecto a dichos datos. Todo esto se realiza para distintos casos de carga.

Luego en el Capítulo 4, se presenta una comparativa entre los resultados obtenidos a través del MEF (Método de elementos finitos) de ABAQUS y el modelo generado por la red neuronal y que se introduce en la subrutina descrita en el capítulo 2. Dicha comparativa se realiza para una placa plana que cuenta con un orificio central, las razones de esta elección también se comentan en el mismo capítulo. El objetivo aquí, es el de trasladar la diferencia entre ambos métodos de resolución a números y proveer de evidencias de que el modelo generado es completamente válido y preciso para su propósito.

Por último, en el Capítulo 5 se presentarán las conclusiones obtenidas tras la realización del presente trabajo y posibles líneas de trabajo futuro con las que poder ampliarlo.

2 Marco computacional

El objetivo de este apartado es el de mostrar los aspectos generales y el modo de funcionamiento de la subrutina UANISOHYPER_INV que hemos usado para desarrollar nuestro modelo de material. Esta subrutina no es más que una herramienta usada para definir el comportamiento mecánico del material a partir del entrenamiento de la red neuronal.

Además la subrutina UANISOHYPER_INV, se usa para definir el potencial de energía de deformación de materiales hiperelásticos anisotrópicos en función de un conjunto irreducible de invariantes escalares. En este caso, la subrutina es llamada en todos los puntos de cálculo de los elementos definidos en la simulación que tiene un comportamiento hiperelástico anisótropo definido por el usuario con una formulación basada en invariantes. Por otro lado, la subrutina puede incluir el comportamiento del material dependiente de variables de campo o variables de estado. Adicionalmente, para usar esta subrutina, se requiere que los valores de las derivadas de la función de densidad de energía de deformación del material hiperelástico anisótropo se definan con respecto a las invariantes escalares. Por último, esta subrutina es llamada dos veces por punto material en cada iteración.

2.1 Tensor gradiente de deformación

El vector posición de un punto cualquiera del sólido en la configuración indeformada o de referencia es X . Este vector se usa, en la descripción lagrangiana del movimiento, como etiqueta del punto durante todo el cambio de configuración. Por ello, en la configuración actual, el vector posición x del punto será una función de X_1, X_2, X_3 y del tiempo t .

$$x = x(X_1, X_2, X_3, t) = x(X, t) \quad (2.1)$$

Derivando esta expresión en un instante t dado, se tiene

$$dx = \frac{\partial x}{\partial X} dX \quad (2.2)$$

El tensor $\frac{\partial x}{\partial X}$ se denomina tensor gradiente de deformación

$$F = \frac{\partial x}{\partial X} \quad (2.3)$$

y convierte el vector inicial dX en el vector dx resultado de la deformación

$$dx = F dX \quad (2.4)$$

Por otro lado, para hallar las pequeñas deformaciones a partir de dicho tensor hay que aplicar la siguiente transformación

$$\varepsilon = \frac{1}{2} \cdot (F^T \cdot F - I) \quad (2.5)$$

de esta forma en el caso 2D tenemos lo siguiente

$$\begin{aligned} \begin{bmatrix} \varepsilon_x & \frac{1}{2}\gamma_{xy} & \frac{1}{2}\gamma_{xz} \\ \frac{1}{2}\gamma_{xy} & \varepsilon_y & \frac{1}{2}\gamma_{yz} \\ \frac{1}{2}\gamma_{xz} & \frac{1}{2}\gamma_{yz} & \varepsilon_z \end{bmatrix} &= \frac{1}{2} \left(\begin{bmatrix} F_{11} & F_{12} & F_{13} \\ F_{21} & F_{22} & F_{23} \\ F_{31} & F_{32} & F_{33} \end{bmatrix} \cdot \begin{bmatrix} F_{11} & F_{12} & F_{13} \\ F_{21} & F_{22} & F_{23} \\ F_{31} & F_{32} & F_{33} \end{bmatrix} - \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \right) = \\ &= 0,5 \cdot \begin{bmatrix} F_{11}^2 + F_{12}F_{21} + F_{13}F_{31} - 1 & F_{11}F_{12} + F_{22}F_{12} + F_{13}F_{32} & F_{11}F_{13} + F_{12}F_{23} + F_{13}F_{33} \\ F_{11}F_{21} + F_{22}F_{21} + F_{23}F_{31} & F_{12}F_{21} + F_{22}^2 + F_{23}F_{32} - 1 & F_{21}F_{13} + F_{22}F_{23} + F_{23}F_{33} \\ F_{31}F_{11} + F_{32}F_{21} + F_{33}F_{31} & F_{12}F_{31} + F_{32}F_{22} + F_{33}F_{32} & F_{13}F_{31} + F_{23}F_{32} + F_{33}^2 - 1 \end{bmatrix} \quad (2.6) \end{aligned}$$

Por lo que, para el caso en el que se aplique compresión o tracción ($F_{11} = \lambda$, $F_{12} = F_{21} = F_{13} = F_{31} = 0$) al espécimen en cuestión queda que

$$\varepsilon_x = \frac{1}{2}(F_{11}^2 - 1) \quad (2.7)$$

Para el caso en el que se aplica cortadura ($F_{11} = F_{22} = 1$, $F_{12} = \gamma$)

$$\gamma_{xy} = 2 \cdot F_{12} \quad (2.8)$$

Dado que no siempre es posible aplicar las simplificaciones realizadas en las ecuaciones 2.7 y 2.8, se opta por la definición dada en la ecuación 2.3, para la cual en el numerador se corresponde con la diferencia de desplazamientos de unos puntos auxiliares (estos puntos se definen más adelante para cada ensayo) tras aplicar la carga en el ensayo y una vez se ha alcanzado la configuración deformada, mientras que el denominador se corresponde con la distancia inicial que separan a los dos puntos auxiliares en la configuración indeformada.

El motivo de introducir este tensor es que el entrenamiento de la red, mostrado en el Capítulo 3, se hace en términos del propio tensor. No obstante para la simulación de los ensayos mediante elementos finitos lo que se impone es el desplazamiento, por lo que es importante tener clara la relación entre el tensor gradiente de deformación, las deformaciones y los desplazamientos. Además, esta variable se usa también en desarrollos posteriores como los que se muestran en la Sección 2.2.

2.2 Ecuaciones de gobierno

Se resumen aquí las ecuaciones constitutivas y las cinemáticas. Además, se reducen el conjunto general de ecuaciones para los casos de tensión uniaxial, compresión uniaxial y cizalladura.

2.2.1 Cinemática

Para caracterizar las deformaciones, se introduce el mapeo de deformaciones φ , dicho mapeo representa las partículas del material X desde su situación indeformada, hasta la situación de las mismas la configuración deformada, $x = \varphi(X)$. Para describir las deformaciones relativas dentro de la muestra usando el tensor gradiente de deformación F , ya comentado en la sección 2.1, y su Jacobiano J .

En el estado indeformado, el gradiente de deformación es igual al tensor unitario, $F = I$, por lo que el Jacobiano sería igual a uno, $J = 1$. Un Jacobiano menor que uno, $0 < J < 1$, indica disminución de volumen y un Jacobiano mayor que uno, $1 < J$, indica aumento de volumen. Para caracterizar un material isótropo, introducimos los 3 invariantes principales I_1 , I_2 y I_3 y sus derivadas $\partial_F I_1$, $\partial_F I_2$ y $\partial_F I_3$

$$I_1 = F : F \quad \partial_F I_1 = 2F \quad (2.9)$$

$$I_2 = \frac{1}{2}[I_1^2 - [F^t \dot{F}] : [F^t \dot{F}]] \quad \partial_F I_2 = 2[I_1 F - F \dot{F}^t \dot{F}] \quad (2.10)$$

$$I_3 = \det(F^t \dot{F}) = J^2 \quad \partial_F I_3 = 2I_3 F^{-t} \quad (2.11)$$

En el estado indeformado, los tres invariantes toman los siguientes valores: $I_1 = 3$, $I_2 = 3$ y $I_3 = 1$. Para materiales isótropos, perfectamente incompresibles, el tercer invariante siempre es igual a la unidad, lo que reduce el conjunto de invariantes a dos, I_1 y I_2 .

Tracción y compresión. Para el caso de tracción y compresión uniaxial, estiramos el espécimen en una dirección, $F_{11} = \lambda_1 = \lambda$. Para material isótropo con $I_3 = \lambda_1^2 \lambda_2^2 \lambda_3^2 = 1$. Los alargamientos ortogonales a la dirección de carga son, $F_{11} = \lambda_2 = \lambda^{1/2}$ y $F_{33} = \lambda_3 = \lambda^{1/2}$. De esta forma, a partir del gradiente de deformación, podemos obtener el primer y segundo invariante y consecuentemente sus derivadas,

$$I_1 = \lambda^2 + \frac{2}{\lambda} \quad \text{con} \quad \frac{\partial I_1}{\partial \lambda} = 2\lambda - \frac{2}{\lambda^2} \quad (2.12)$$

$$I_2 = 2\lambda^2 + \frac{1}{\lambda^2} \quad \text{con} \quad \frac{\partial I_2}{\partial \lambda} = 2 - \frac{2}{\lambda^3} \quad (2.13)$$

Cizalladura. Para el caso de tensión tangencial simple, aplicando dicha tensión en una dirección, $F_{12} = \gamma$. Para un material isótropo con $F_{11} = F_{22} = F_{33}$, calculando el primer y segundo invariante y sus derivadas,

$$I_1 = 3 + \gamma^2 \quad \text{con} \quad \frac{\partial I_1}{\partial \lambda} = 2\gamma \quad (2.14)$$

$$I_2 = 3 + \gamma^2 \quad \text{con} \quad \frac{\partial I_2}{\partial \lambda} = 2\gamma \quad (2.15)$$

2.2.2 Ecuaciones constitutivas

Las ecuaciones constitutivas relacionan una tensión como la nominal P , que se trata de la fuerza por área no deformada que se suele medir en experimentos, con una medida de deformación como la del gradiente de deformación F . Como se muestra en la [4], la tensión nominal puede ser expresada como $P = \frac{\partial \psi}{\partial F}$, donde $\psi(F)$ es la derivada de la función de la energía libre de Helmutz. A esta expresión anterior de P , se le añade un término de presión para asegurar la perfecta incompresibilidad, como se indica en [4].

$$P = \frac{\partial \psi}{\partial F} - pF^{-t} \quad (2.16)$$

Aquí, p es la presión hidrostática, que actúa como multiplicador de Lagrange que se determina a partir de las condiciones de contorno. Por otro lado, en lugar de expresar la energía libre en términos del gradiente de deformación, podemos expresarlo en término de los invariantes $\psi(I_1, I_2)$, esto nos proporciona la siguiente expresión de la tensión nominal

$$P = \frac{\partial \psi}{\partial I_1} \cdot \frac{\partial I_1}{\partial F} + \frac{\partial \psi}{\partial I_2} \cdot \frac{\partial I_2}{\partial F} - pF^{-t} = 2 \left[\frac{\partial \psi}{\partial I_1} + I_1 \cdot \frac{\partial \psi}{\partial I_2} \right] \cdot F - 2 \cdot \frac{\partial \psi}{\partial I_2} \cdot F \cdot F^{-t} \cdot F - p \cdot F^{-t} \quad (2.17)$$

Tracción y compresión. Para este caso, se evalúa la tensión uniaxial nominal P_{11} usando la relación general tensión-alargamiento para materiales perfectamente incompresibles:

$$P_{ii} = \left(\frac{\partial \psi}{\partial I_1} \right) \left(\frac{\partial I_1}{\partial \lambda_i} \right) + \left(\frac{\partial \psi}{\partial I_2} \right) \left(\frac{\partial I_2}{\partial \lambda_i} \right) - \left(\frac{\partial \psi}{\partial I_1} \right) \left(\frac{1}{\lambda_i} \right) \cdot p \quad (2.18)$$

donde p es la presión hidrostática que determinamos a partir de la condición de tensión nula en las direcciones transversales $P_{22} = 0$ y $P_{33} = 0$,

$$p = \left(\frac{2}{\lambda} \right) \cdot \frac{\partial \psi}{\partial I_1} + (2\lambda + 2\lambda^2) \cdot \frac{\partial \psi}{\partial I_2} \quad (2.19)$$

De esta forma, se llega a que

$$P_{11} = 2 \left[\frac{\partial \psi}{\partial I_1} + \frac{1}{\lambda} \cdot \frac{\partial \psi}{\partial I_2} \right] \cdot \left[\lambda - \frac{1}{\lambda^2} \right] \quad (2.20)$$

Cizalladura. Para el caso de cizalladura simple, evaluamos la tensión nominal de cizalladura P_{12} utilizando la relación general tensión-alargamiento para materiales perfectamente incompresibles con los invariantes. Esto da como resultado la siguiente relación explícita de esfuerzo cortante-deformación,

$$P_{12} = 2 \left[\frac{\partial \psi}{\partial I_1} + \frac{\partial \psi}{\partial I_2} \right] \cdot \gamma \quad (2.21)$$

2.2.3 Funcionamiento

A continuación se detalla, brevemente, el funcionamiento de la subrutina. En primer lugar hay que tener en cuenta como ABAQUS resuelve los modelos de MEF. Supondremos que estamos ante modelos de un solo “step”. Un “step” se puede entender como un caso de carga, ya que a cada “step” se le asocia unas condiciones de contorno y unas cargas. Pero además de esto podemos hacer que un nuevo “step” obtenga las características modificadas del modelo por otro “step”, por ejemplo supongamos que estamos ante un modelo con un comportamiento elasto-plástico y sometemos al modelo a un “step” que produce la plastificación de cierta zona del modelo, podríamos crear un step que siguiera al anterior con lo que el nuevo “step” tendría plastificada esa zona del modelo.

Al “step” se le asigna un tiempo, el cual tiene significado físico si estamos en un caso dinámico, pero como el análisis que realizaremos es un análisis estático este tiempo carece de alguna relación con el tiempo físico. Los steps están compuestos por incrementos, y en cada incremento se aplica un “incremento” de las cargas aplicadas. En cada incremento se realizan una serie de iteraciones para llegar al equilibrio con las cargas correspondientes a este incremento. En el caso que se haya utilizado el máximo de iteraciones permitidas y el problema no llegue a converger, se desecha la solución que no alcanzó el equilibrio y se realiza un nuevo incremento con un paso de carga menor al que se ha dado anteriormente. Toda esta información es mostrada en los archivos con la terminación “.sta”.

En la figura 2.1 podemos ver un esquema del proceso que sigue ABAQUS para resolver los problemas, y donde llama a la subrutina UA. Si bien el esquema indicado puede mostrar de una forma sencilla el funcionamiento de ABAQUS y donde se ejecuta la subrutina UANISOHYPER_INV, no es válido para la primera iteración de cualquier elemento. En esta primera iteración la subrutina UANISOHYPER_INV es llamada dos veces, en la primera llamada la matriz de rigidez es montada usando la configuración de la situación inicial en el incremento. En la segunda llamada se actualiza la rigidez basándose en la configuración actualizada de la iteración anterior. En las demás iteraciones la configuración inicial estará basada en la iteración anterior.

En cada iteración que se realiza para buscar el equilibrio y para cada punto de integración de cada elemento se ejecuta la subrutina UANISOHYPER_INV.

Para cada iteración ABAQUS pasa a la subrutina las tensiones al comienzo de la iteración, las deformaciones al comienzo de la iteración y el incremento de deformaciones previstos. A partir de los datos que hemos introducido a la subrutina debemos devolverle a ABAQUS la matriz jacobiana y las tensiones actualizadas.

2.2.4 Formato de la subrutina

Tal y como aparece en [4], la UANISOHYPER_INV que usaremos se encuentra dividida en 4 algoritmos que pasamos a explicar un poco en profundidad.

El primero de estos 4 algoritmos, incluye un pseudocódigo que describe como se computa la densidad de energía de deformación (ψ) y las primeras y segundas derivadas de las mismas con respecto a los invariantes ($\partial\psi/\partial I_i$ y $\partial\psi/\partial I_i\partial I_j$) en el punto de integración durante un análisis de elementos finitos. En definitiva, se comienza a inicializar todos los índices relevantes y a leer las funciones de activación y los pesos de los nodos de la red neuronal. Seguidamente, se evalúa cada parámetro de cada nodo, en la tabla de parámetros *UNIVERSAL_TAB* que previamente a definido el usuario y se van actualizando la función de densidad de energía de deformación, sus primeras derivadas ($\partial\psi/\partial I_i$) y sus segundas derivadas ($\partial\psi/\partial I_i\partial I_j$) usando los invariantes de referencia corregidos del nodo *xInv*.

Por otro lado, el Algoritmo 2 detalla la actualización aditiva de la energía libre (ψ) y sus primeras y segundas derivadas dentro de la subrutina de material de usuario.

Por último, los algoritmos 3 y 4 proporcionan el pseudocódigo para las dos subrutinas (*uCANN_h1* y *uCANN_h2*) que evalúa la primera y segunda capa de la red para cada nodo de la red con sus funciones y pesos.

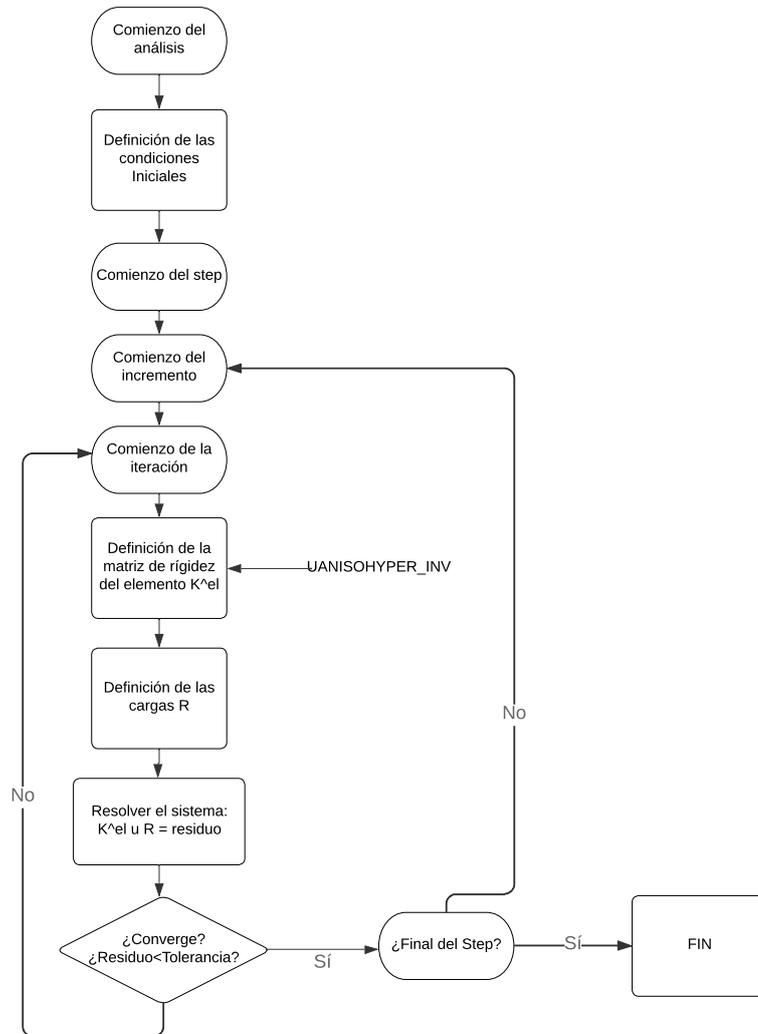


Figura 2.1 Esquema del funcionamiento de ABAQUS/Standard al utilizar la subrutina UANISOHYPER_INV.

Algorithm 1: Pseudocode for universal material subroutine UANISOHYPER_INV

```

subroutine UANISOHYPER_INV(aInv, UA, UI1, UI2)
  // Initialize energy, its derivatives, reference configuration, and model
  // parameters
  Set initial array values for UA, UI1, UI2;
  Set reference configuration array UANISOHYPER_INV;
  Retrieve discovered parameter table UNIVERSAL_TAB;
  // Evaluate all n neurons, i.e., rows in parameter table
  for k in n do
    // Extract activation functions and weights
    Extract invariants  $kf_{0,k}$ ;
    Extract activation functions  $kf_{1,k}$  and  $kf_{2,k}$ ;
    Extract weights  $w_{1,k}$  and  $w_{2,k}$ ;
    // Compute invariant in reference configuration
     $xInv_k = aInv(kf_{0,k}) - aInv0(kf_{0,k})$ ;
    // Update energy and its derivatives UA, UI1, UI2
    Call uCANN( $xInv_k$ ,  $kf_{1,k}$ ,  $kf_{2,k}$ ,  $w_{1,k}$ ,  $w_{2,k}$ , UA, UI1, UI2)
  // Return updated arrays
  Return UA, UI1, UI2;

```

Figura 2.2 Algoritmo 1 de la UANISOHYPER_INV, [4].**Algorithm 2:** Pseudocode to update energy and its derivatives for UANISOHYPER_INV

```

subroutine uCANN(xInv,  $kf_1$ ,  $kf_2$ ,  $w_1$ ,  $w_2$ , UA, UI1, UI2)
  // Process first network layer - provides  $f_1$ ,  $df_1$ , and  $ddf_1$ 
   $w_0 = 1.0$ ;
  Call uCANN_h1(xInv,  $w_0$ ,  $kf_1$ );
  // Process second network layer - provides  $f_2$ ,  $df_2$ , and  $ddf_2$ 
  Call uCANN_h2( $f_1$ ,  $w_1$ ,  $kf_2$ );
  // Update energy and its derivatives UA, UI1, UI2
   $UA \leftarrow UA + w_2 * f_2$ ;
   $UI1 \leftarrow UI1 + w_2 * df_2 * df_1$ ;
   $UI2 \leftarrow UI2 + w_2 * (ddf_2 * df_1 * df_1 + df_2 * ddf_1)$ ;

```

Figura 2.3 Algoritmo 2 de la UANISOHYPER_INV, [4].

Algorithm 3: Pseudocode to evaluate first network layer of UANISOHYPER_INV

```

subroutine uCANN_h1( $kf, w, x$ )
  // Calculate first layer output  $f$ ,  $df$ , and  $ddf$  for activation function  $kf$ 
  if  $kf = 1$  then
     $f = w * x$ ;
     $df = w$ ;
     $ddf = 0$ ;
  else if  $kf \geq 2$  then
     $f = w^{kf} * x^{kf}$ ;
     $df = kf * w^{kf} * x^{(kf-1)}$ ;
     $ddf = kf * (kf - 1) * w^{kf} * x^{(kf-2)}$ ;
  Return  $f, df, ddf$ 

```

Algorithm 4: Pseudocode to evaluate second network layer of UANISOHYPER_INV

```

subroutine uCANN_h2( $kf, w, x$ )
  // Calculate second layer output  $f$ ,  $df$ ,  $ddf$  for activation function  $kf$ 
  if  $kf = 1$  then
     $f = w * x$ ;
     $df = w$ ;
     $ddf = 0$ ;
  else if  $kf \geq 2$  then
     $f = \exp(w * x) - 1$ ;
     $df = w * \exp(w * x)$ ;
     $ddf = w^2 * \exp(w * x)$ ;
  else if  $kf \geq 3$  then
     $f = -\ln(1 - w * x)$ ;
     $df = w / (1 - w * x)$ ;
     $ddf = w^2 / (1 - w * x)^2$ ;
  Return  $f, df, ddf$ 

```

Figura 2.4 Algoritmos 3 y 4 de la UANISOHYPER_INV, [4].

3 Entrenamiento de la ANN

Para entrenar a la red nos basamos en la forma en la que se realiza en [1]. Aquí, se consideran 3 casos de carga claramente diferenciados: tracción, compresión y cortadura. Para cada uno de ellos, los datos de entrenamiento son 19 pares de datos compuestos por el valor de F_{11} (para caso de carga uniaxial) o F_{12} (para el caso de cortadura) cuyo significado se explica a continuación y la tensión correspondiente a dicho valor de la componente del tensor gradiente de deformación. El criterio seguido para la selección de los datos para entrenar a la red es el siguiente: para tracción se han seleccionado los datos en los que F_{11} se encuentra entre 1 y 1,1, para compresión se han seleccionado los datos en los que F_{11} se encuentra entre 1 y 0,9 y para cortadura se han seleccionado los datos en los que F_{12} se encuentra entre 0 y 0,2. De esta forma se ha seguido la misma filosofía de los autores de la referencia [1]. De nuevo, cabe recalcar que las simulaciones que en este capítulo se muestran sustituyen a los ensayos reales que se realizan en el laboratorio. El fin de estas simulaciones es el de obtener una base de datos con la que nutrir a la red para su entrenamiento.

3.1 Definición de los ensayos para entrenar la red neuronal

En esta sección, se presenta la metodología seguida para obtener las bases de datos necesarias para entrenar la red neuronal. Para ello, básicamente se ha hecho uso de la simulación de elementos finitos con el software ABAQUS. Concretamente, se han obtenido 3 bases de datos, una correspondiente al caso en el que se tiene tracción, otra para compresión y otra para cortadura. En todos estos casos comentados, se ha recurrido a la normativa existente y aplicable para poder definir los ensayos en ABAQUS.

También, cabe destacar que la red neuronal usada, ha sido la que aparece en la referencia [1]. En el caso que nos ocupa, únicamente se entrena dicha red a partir de los datos generados en ABAQUS mediante la simulación de los ensayos que a continuación se muestran, tratando de esta manera de imitar el papel que jugarían los ensayos reales en laboratorio.

3.1.1 Ensayo a tracción

Para establecer el modelo de este ensayo en ABAQUS, se recurre a la normativa ASTM D412. Dicha normativa es la que define los ensayos de tracción para el caucho, estableciendo como ha de ser la probeta con la que se realice el ensayo, como se muestra en la figura 3.1.

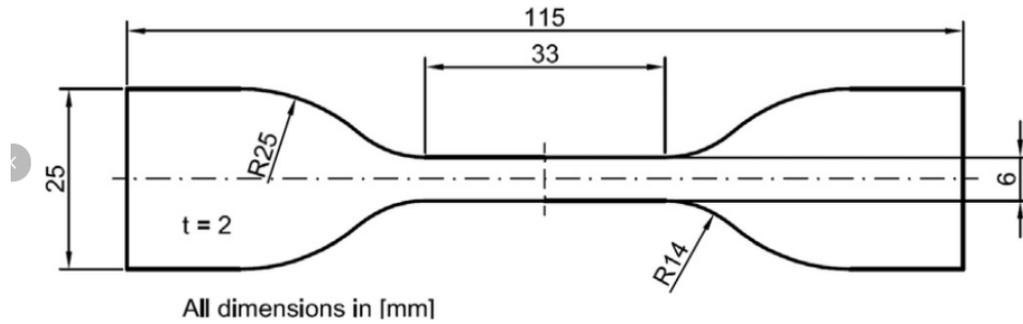


Figura 3.1 Morfología de la probeta para el ensayo de tracción.

Dicho ensayo, no presenta ninguna peculiaridad con respecto al típico ensayo de tracción que se realiza para caracterizar cualquier tipo de material. La probeta se sujeta por dos mordazas en los extremos de la misma, y se aplica tracción imponiéndole a la mordaza que sujeta el extremo superior de la probeta se desplace un cierto valor mientras que la mordaza del extremo inferior permanece fija.

Una vez definido esto, se pasa a modelar el ensayo en ABAQUS, para lo cual primeramente se genera la geometría tal cual viene descrita en la figura 3.1.

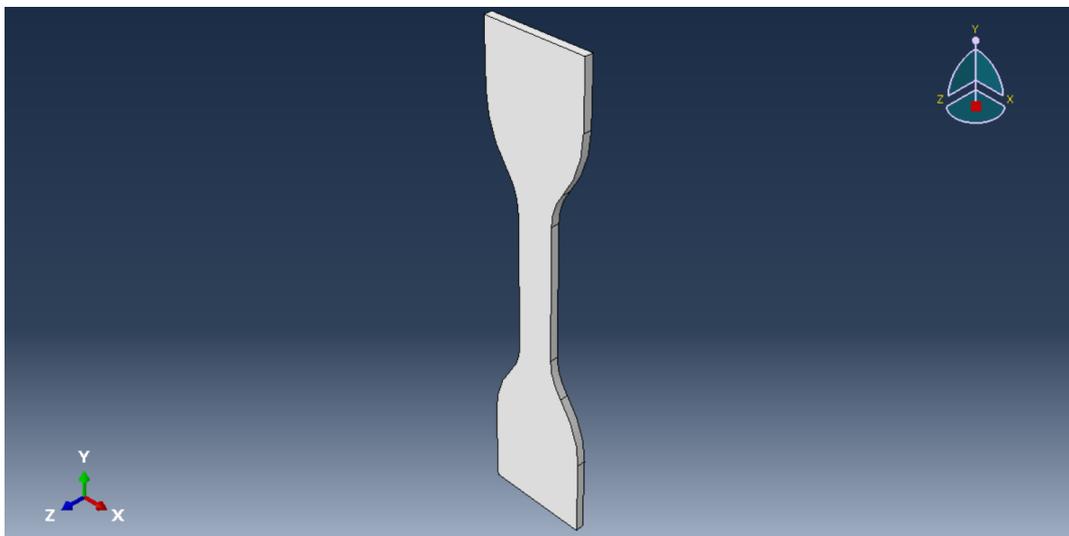


Figura 3.2 Modelo de ABAQUS de la probeta usada para el ensayo de tracción.

Tras esto, se procede a crear el modelo de material en ABAQUS y a asignarlo a la geometría mostrada en la figura 3.2.

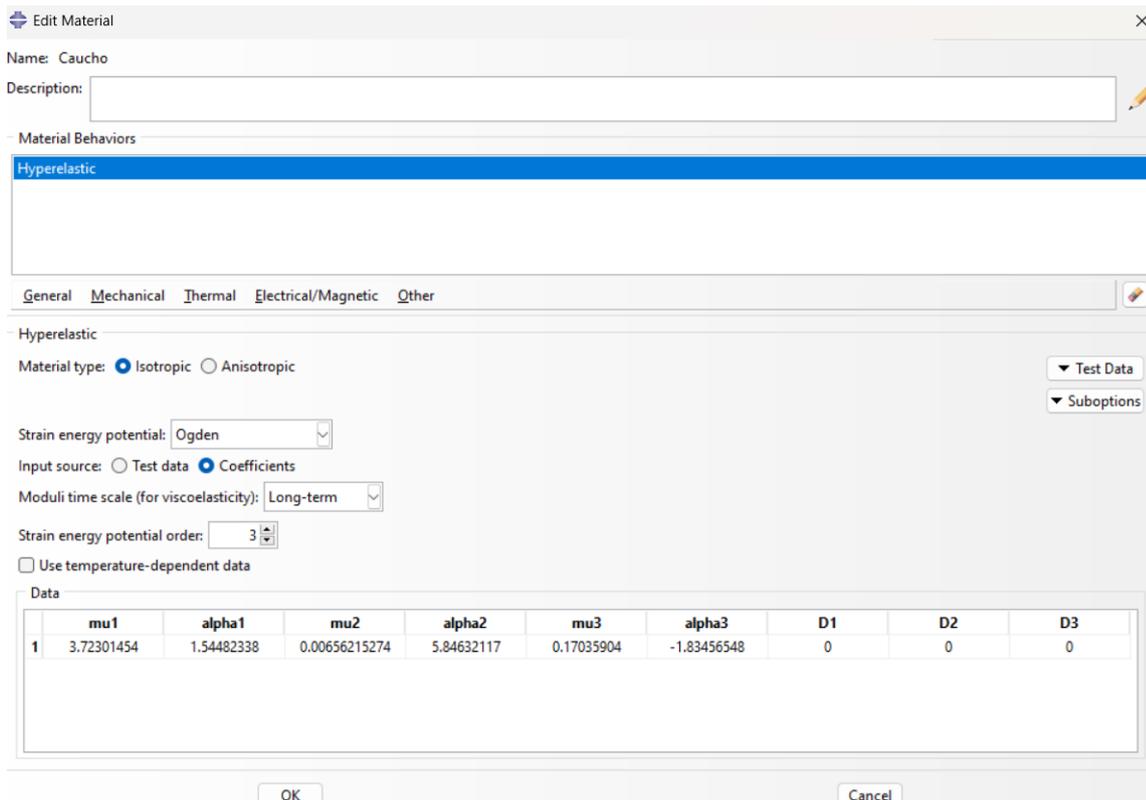


Figura 3.3 Modelo de material hiperelástico de Ogden en ABAQUS.

Como se puede comprobar los valores introducidos en los diferentes coeficientes del modelo coinciden con los mostrados en la tabla 1.1. El por qué se usan estos datos reside en que son los datos que se han tomado de ejemplo para mostrar la viabilidad de la estrategia. Además, cabe recordar que todas las simulaciones que se exponen en el presente capítulo son sustitutivas de los experimentos reales, tratando de jugar el mismo papel que dichos ensayos.

El siguiente paso, es el de crear los diferentes Steps en los cuales se aplican las diferentes condiciones de contorno. Concretamente, hemos creado un único Step, ya que el denominado "Initial" ya viene creado por defecto. El step creado ha sido denominado "LoadingStep". En el "Initial" se incluyen las condiciones de contorno en las que se restringe un grado de libertad mientras que en el "LoadingStep" la condición de carga impuesta que provoca la deformación en la probeta.

Una vez realizado esto, se procede crear las condiciones de contorno. En el extremo inferior de la probeta, se han restringido los desplazamientos a lo largo de los ejes X , Y y Z , además de los giros alrededor de X y Z (para lo que se ha impuesto la condición de simetría con respecto a Y , como se puede ver en la figura 3.4.

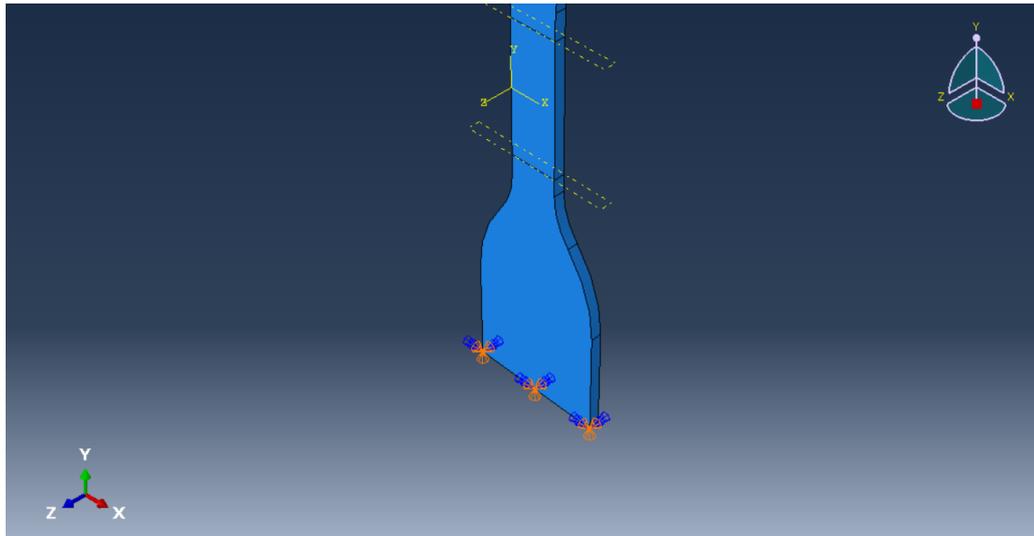


Figura 3.4 Empotramiento en el extremo inferior de la probeta en el ensayo a tracción como condición de contorno.

Por otro lado, en la superficie plana superior de la probeta es donde se ha impuesto la condición de carga, figura 3.5. Concretamente, se ha impuesto el desplazamiento para tener un mayor control sobre esta variable que es, la que al fin y al cabo interesa más (interesa más que la carga). Para este caso, el desplazamiento impuesto ha sido de 7mm.

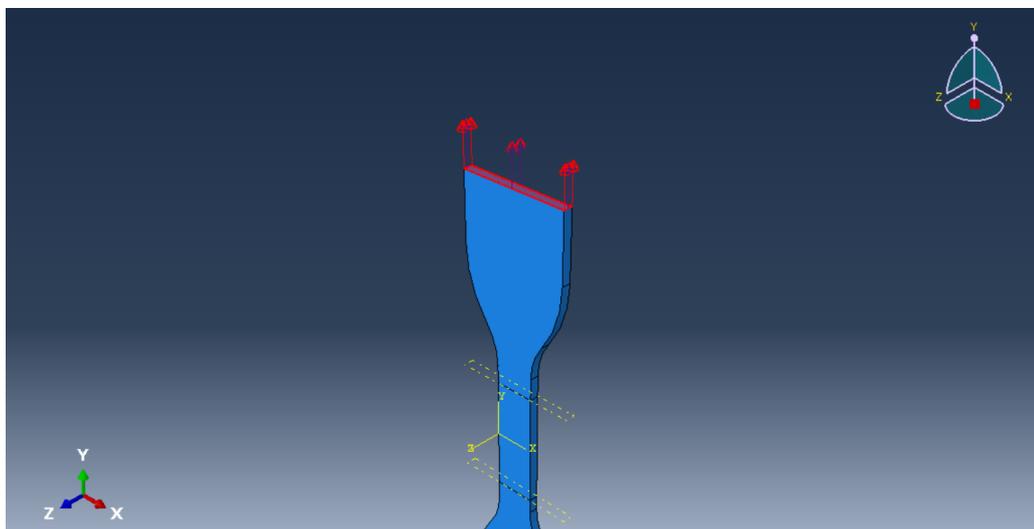


Figura 3.5 Desplazamiento impuesto en el ensayo a tracción como condición de contorno.

Adicionalmente, se han definido dos puntos auxiliares, en la parte central de la probeta (donde nos interesa medir los desplazamientos), mediante dos Sets, necesarios para medir el desplazamiento relativo. Estos puntos distan entre ellos 25mm y para crear estos Sets ha sido necesario establecer dos planos XZ y realizar una partición de la probeta, figura 3.6.

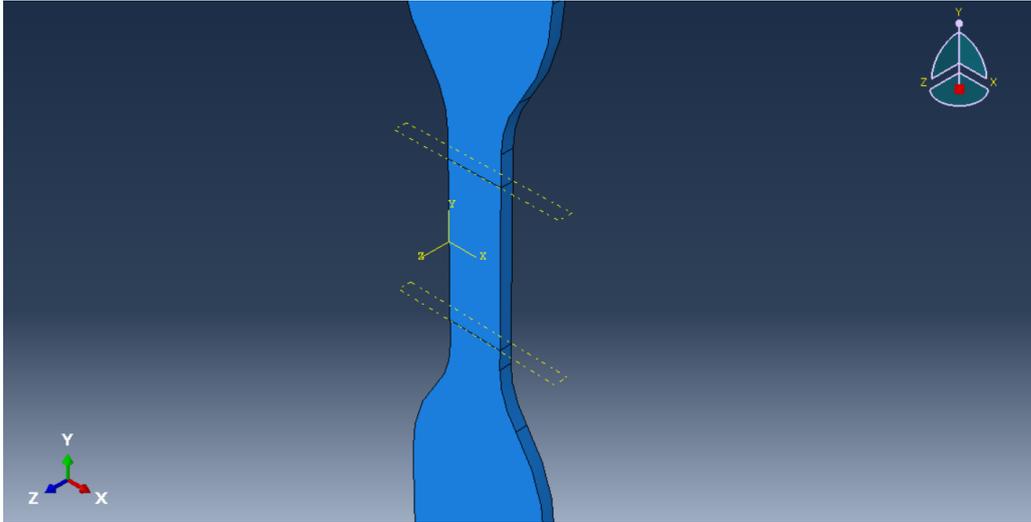


Figura 3.6 Particiones creadas para establecer los 2 puntos de referencia y así hallar el desplazamiento relativo en el ensayo de tracción.

De esta forma, la componente F_{11} del tensor gradiente de deformación es

$$F_{11} = 1 + \frac{u_{NT} - u_{NL}}{d} \quad (3.1)$$

donde u_{NT} y u_{NL} son los desplazamientos de los puntos auxiliares superior e inferior respectivamente mientras que d es la distancia inicial que los separa, es decir, 25 mm.

Definidos, estos puntos, el siguiente paso es mallar la probeta. Para ello, se ha decidido seleccionar como elementos para el mallado los de tipo "Hex" (elementos cuadrangulares) como se puede ver en las figuras 3.7 y 3.8, en lugar de los "Tet" (elementos triangulares), ya que estos proporcionan una mayor precisión, pues al ser los "Tet" elementos triangulares estaría introduciendo una rigidez adicional al modelo, distorsionando así los resultados obtenidos. Además, se ha optado por seleccionar las opciones de "Hybrid formulation" y "Reduced integration". La opción "Reduced integration" permite reducir los puntos de integración, de tal forma que solo selecciona el centroide de cada elemento que compone la malla reduciéndose así el tiempo de integración y sólo se puede usar en elementos hexaédricos o cuadriláteros. Mientras que la opción "Hybrid formulation", se usa cuando el comportamiento del material es incompresible (índice de Poisson = 0,5) o muy cercano a incompresible (índice de Poisson > 0,475). El caucho es un ejemplo de material con comportamiento material incompresible. La respuesta de un material incompresible no se puede modelar con elementos regulares (excepto en el caso de tensión plana) porque la tensión de presión en el elemento es indeterminada. Si el material es incompresible, su volumen no puede cambiar bajo esta carga. Por lo tanto, la componente esférica no se puede calcular a partir de los desplazamientos de los nodos; y, por tanto, una formulación de desplazamiento puro es inadecuada para cualquier elemento con comportamiento material incompresible. Con esta opción se incluye un grado de libertad adicional que determina directamente la tensión de presión en el elemento.

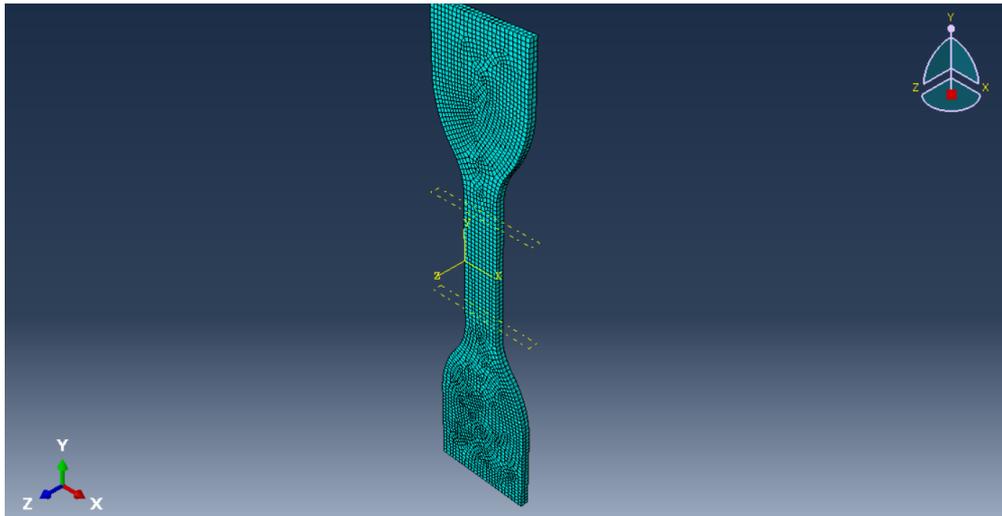


Figura 3.7 Mallado de la probeta para el ensayo a tracción.

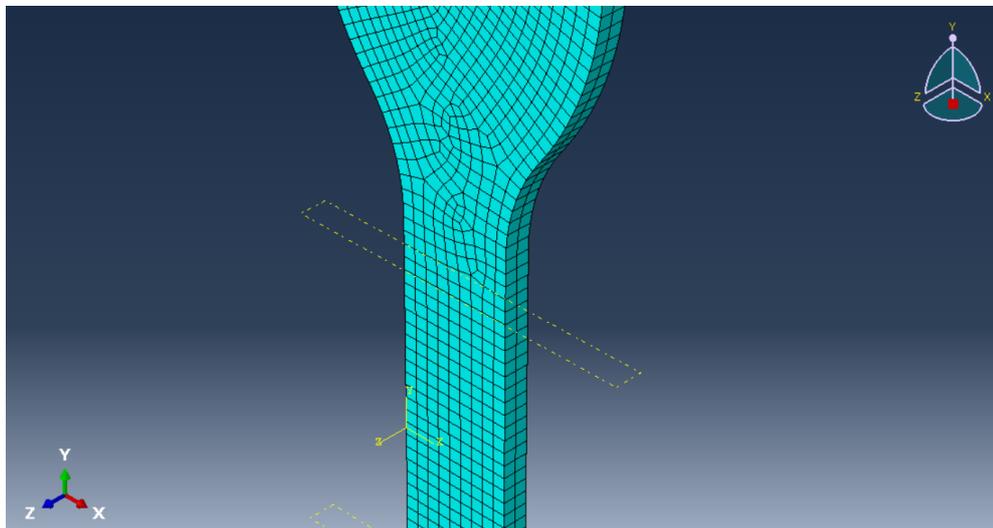


Figura 3.8 Detalle del mallado de la probeta para el ensayo a tracción.

Completado todo esto, lo siguiente es pasarle el modelo a ABAQUS para que realice el análisis y proporcione los resultados. Dichos resultados se muestran en las figuras 3.9-3.14, junto con las tablas 3.1-3.3.

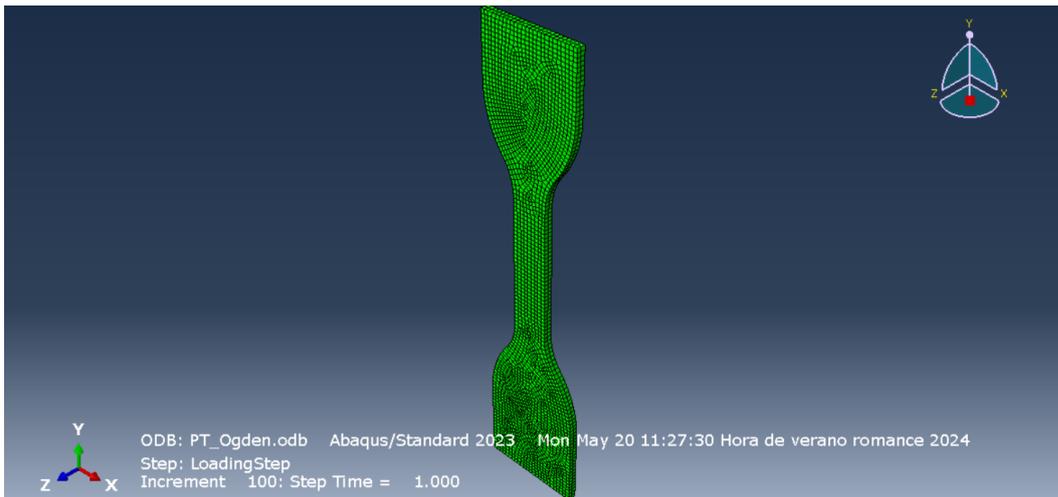


Figura 3.9 Probeta indeformada en el ensayo a tracción.

En la figura 3.10 se puede ver como queda la deformada de la probeta tras aplicar la carga de tracción, como era de esperar esta se alarga en la dirección en la que se aplica la carga.

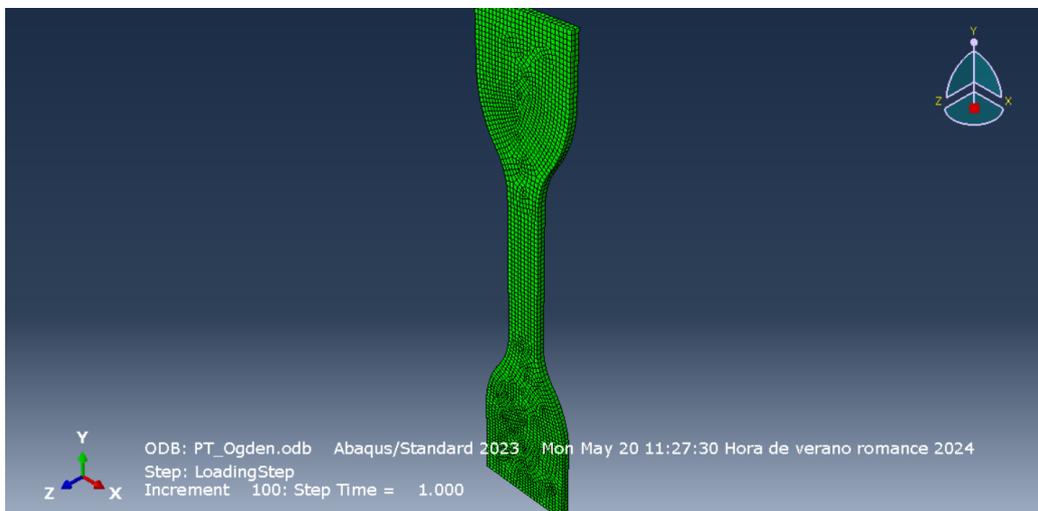


Figura 3.10 Probeta deformada en el ensayo a tracción.

A continuación, en la figura 3.11 se muestran los desplazamientos u_y que se producen en la probeta tras aplicar la carga. Como se puede observar, en el extremo inferior que es el que se encuentra empotrado los desplazamientos son nulos, mientras que en el extremo superior en el que se impone el desplazamiento como condición de carga se encuentran los desplazamientos máximos.

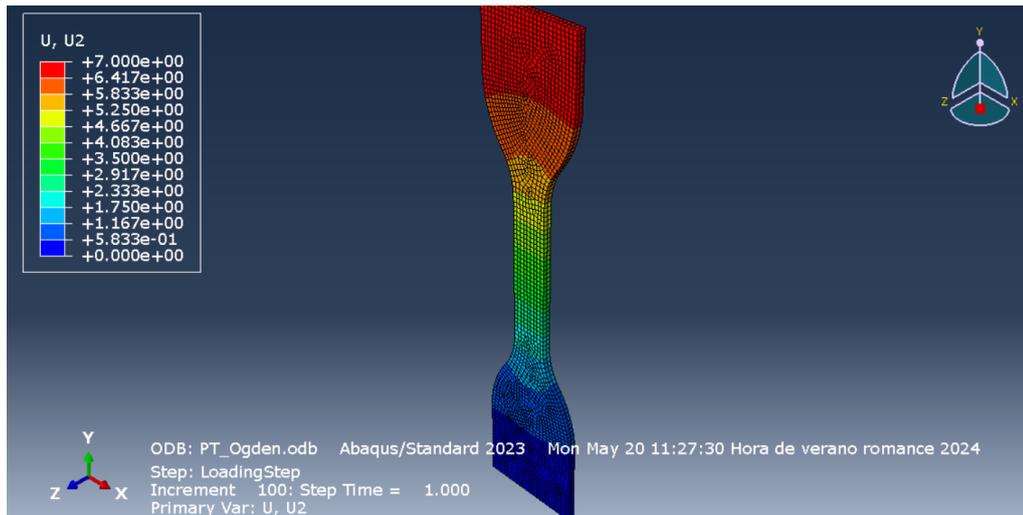


Figura 3.11 Desplazamientos en la dirección Y en el ensayo de tracción.

Por otro lado, en la figura 3.12 se presentan las deformaciones ϵ_y que se producen en la probeta tras finalizar el proceso de carga. Como era de esperar, las mayores deformaciones se producen en la parte central de la probeta debido a la reducción de la sección de la probeta.

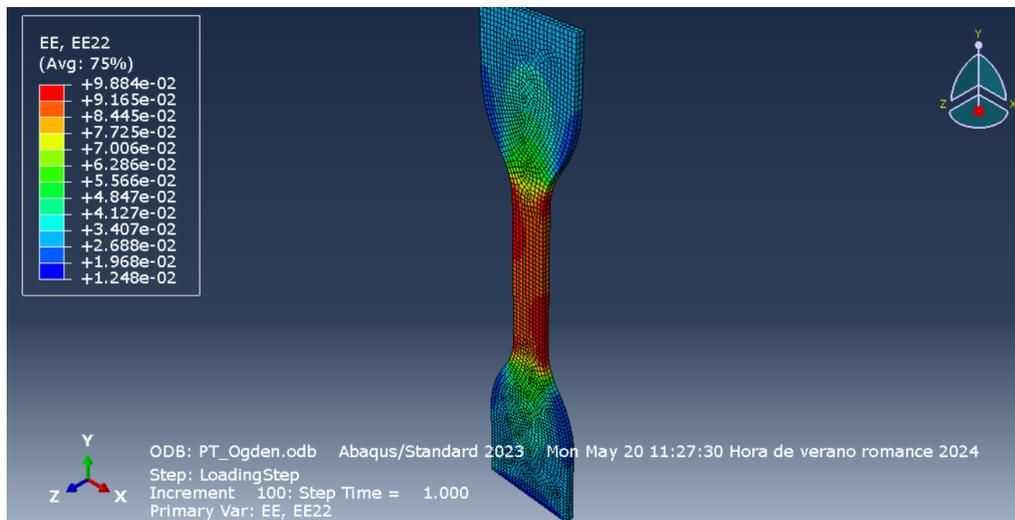


Figura 3.12 Deformaciones en la dirección Y en el ensayo de tracción.

Al igual que pasara con las deformaciones, como se puede apreciar en las figuras 3.13 y 3.14 las tensiones se concentran en el estrechamiento de la probeta y esto, como antes en las deformaciones, es debido a la reducción de la sección efectiva con respecto a la zona de la probeta donde se produce la cogida de las mordazas.

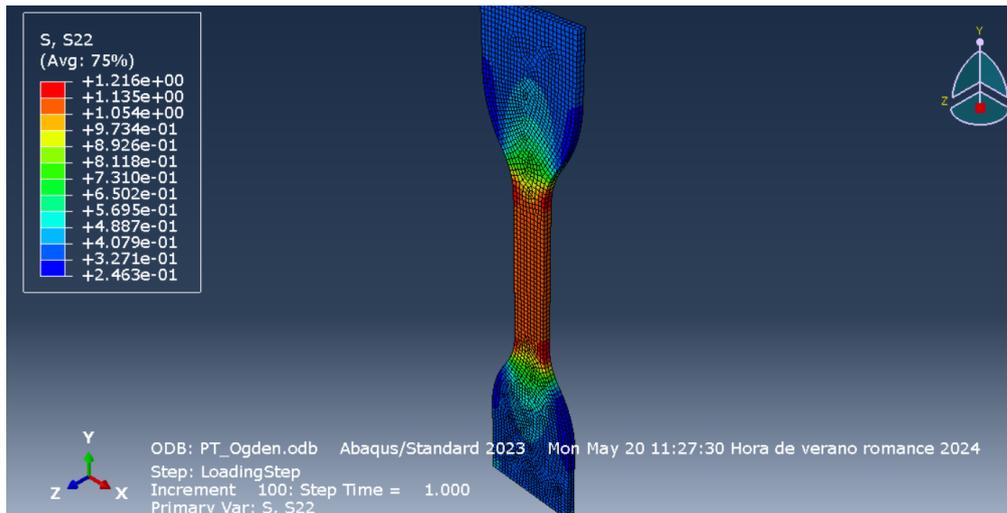


Figura 3.13 Tensiones en la dirección Y en el ensayo de tracción.

Por otro lado, tanto en la figura 3.12 como en la figura 3.13 puede verse que en la zona donde se miden los desplazamientos de los puntos auxiliares, anteriormente comentados, las deformaciones y las tensiones son uniformes.

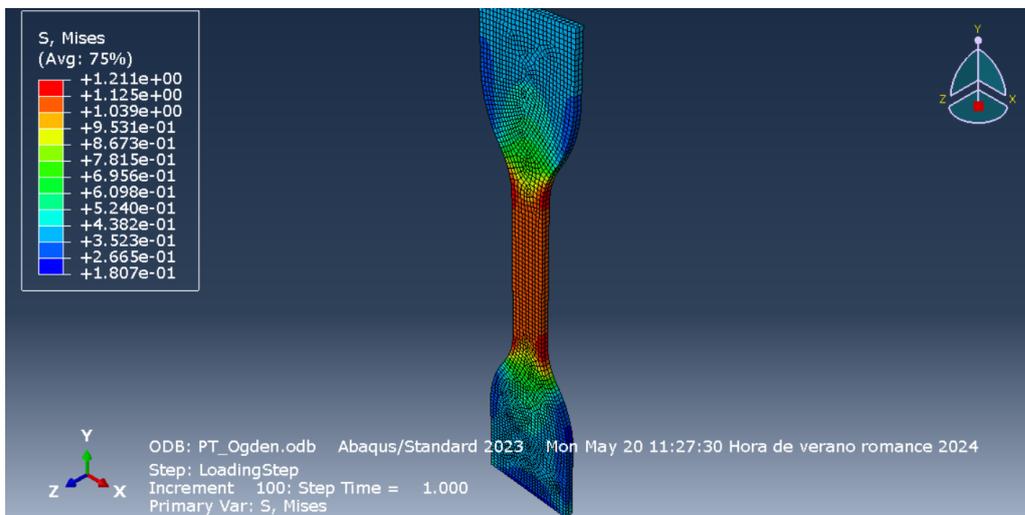


Figura 3.14 Tensiones de Von Mises en el ensayo de tracción.

A continuación, en las tablas 3.1 y 3.2 se muestran los resultados obtenidos en términos de desplazamientos, deformaciones y tensiones de los nodos auxiliares considerados para cuantificar las variables del ensayo comentadas anteriormente. A partir de estos datos y de la ecuación 3.1, en la tabla 3.3 se presentan los valores del tensor gradiente de deformación en función del tiempo de simulación, con los que nutrir a la red para su entrenamiento.

Tabla 3.1 Resultados obtenidos de la simulación para el nodo inferior en el ensayo de tracción.

Nodo inferior			
Tiempo	Desplazamientos [mm]	Deformaciones	Tensiones[Mpa]
0	0	0	0
0,02	0,05	0,002	0,02
0,04	0,09	0,004	0,04
0,07	0,16	0,01	0,08
0,1	0,23	0,01	0,11
0,12	0,28	0,01	0,13
0,14	0,32	0,01	0,15
0,17	0,39	0,02	0,19
0,2	0,46	0,02	0,22
0,23	0,53	0,02	0,25
0,27	0,62	0,03	0,3
0,3	0,69	0,03	0,33
0,33	0,76	0,03	0,37
0,38	0,88	0,04	0,42
0,4	0,93	0,04	0,44
0,43	1	0,04	0,51
0,46	1,07	0,04	0,51
0,49	1,13	0,05	0,55
0,5	1,16	0,05	0,56

Tabla 3.2 Resultados obtenidos de la simulación para el nodo superior en el ensayo de tracción.

Nodo superior			
Tiempo	Desplazamientos [mm]	Deformaciones	Tensiones[Mpa]
0	0	0	0
0,02	0,09	0,002	0,02
0,04	0,19	0,004	0,04
0,07	0,32	0,01	0,08
0,1	0,46	0,01	0,11
0,12	0,56	0,01	0,13
0,14	0,65	0,01	0,15
0,17	0,79	0,02	0,18
0,2	0,93	0,02	0,22
0,23	1,07	0,02	0,25
0,27	1,26	0,02	0,29
0,3	1,4	0,03	0,32
0,33	1,54	0,03	0,36
0,38	1,77	0,03	0,41
0,4	1,87	0,04	0,43
0,43	2,01	0,04	0,46
0,46	2,15	0,04	0,50
0,49	2,29	0,04	0,53
0,5	2,34	0,05	0,54

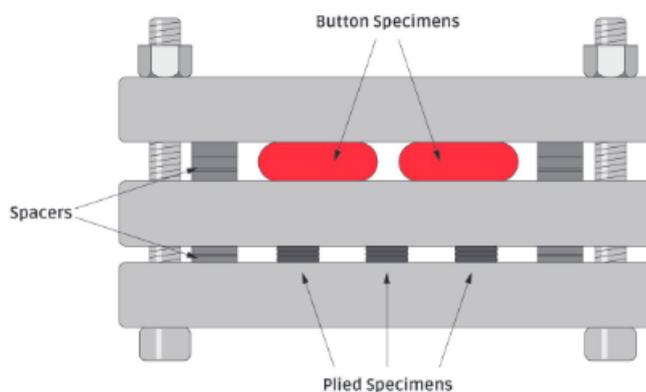
Tabla 3.3 Resultados de F_{11} obtenidos de la simulación en el ensayo de tracción.

Tiempo	F_{11}
0	1
0,02	1,0009
0,04	1,0028
0,07	1,0065
0,1	1,0122
0,12	1,0178
0,14	1,0216
0,17	1,0253
0,2	1,0310
0,23	1,0367
0,27	1,0424
0,3	1,0501
0,33	1,0559
0,38	1,0713
0,4	1,0752
0,43	1,0810
0,46	1,0869
0,49	1,0928
0,5	1,0947

Como puede verse en la tabla 3.3, todos los valores de F_{11} en tracción se encuentra entre 1 y 1,1. Ese ha sido el criterio seguido para la selección de los datos experimentales usados para entrenar la red, siguiéndose así la misma filosofía empleada por los creadores de la red para su entrenamiento.

3.1.2 Ensayo a compresión

De igual forma que se hizo en el ensayo de tracción, para compresión se recurre a normativa existente. Concretamente, para este caso se recurre a la normativa ASTM D395, que dispone de dos metodologías, nosotros nos centramos en la metodología B. La metodología de este ensayo es muy simple, consiste en someter a compresión discos de 29 mm de diámetro y 12,5 mm de espesor, mediante dos placas que se encuentran sujetas entre si por tornillos, como se ve en la figura 3.15.

**Figura 3.15** Esquema del ensayo de compresión según norma ASTM D395.

Tras tener definido el tipo de ensayo a realizar, se procede a modelar la probeta en ABAQUS, figura 3.16

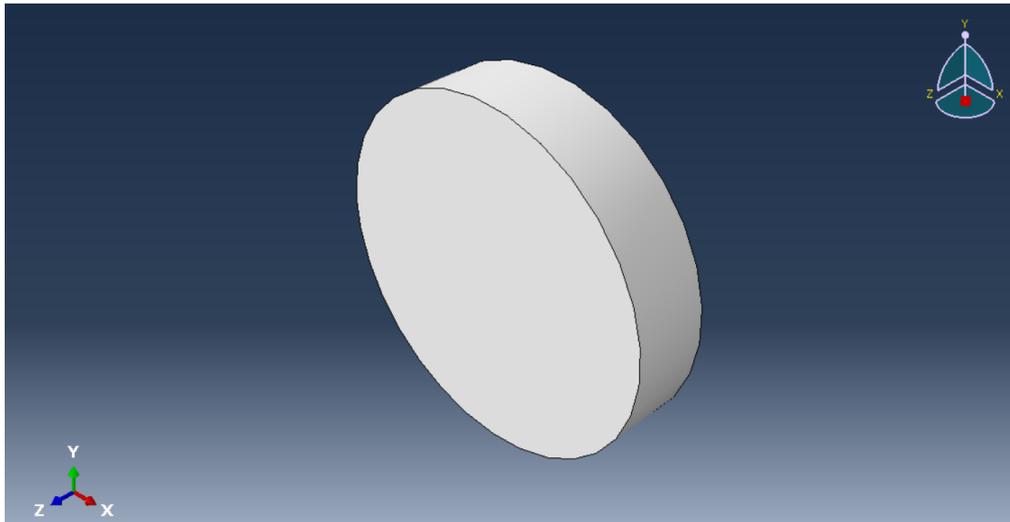


Figura 3.16 Modelo de ABAQUS de la probeta usada para el ensayo de compresión.

Además, al igual que se hizo en tracción, hay que definir el modelo de material siendo este el mismo que se usa en aquel ensayo y que viene definido en la figura 3.3. Por otro lado, los Steps creados y la función de los mismos es la misma que en el ensayo de tracción.

En lo relativo a las condiciones de contorno, en la superficie que se encuentra apoyada en el útil de ensayo se ha impedido el desplazamiento del punto central en ejes X e Y , se ha impedido el desplazamiento en X de un punto de dicha superficie del disco que se encuentra en el borde, es decir, un punto con coordenadas $X=0$, $Y=R$ y $Z=0$ siendo R el radio del disco, y ya por último, se ha impedido el desplazamiento en Z en toda la superficie inferior, figura 3.17.

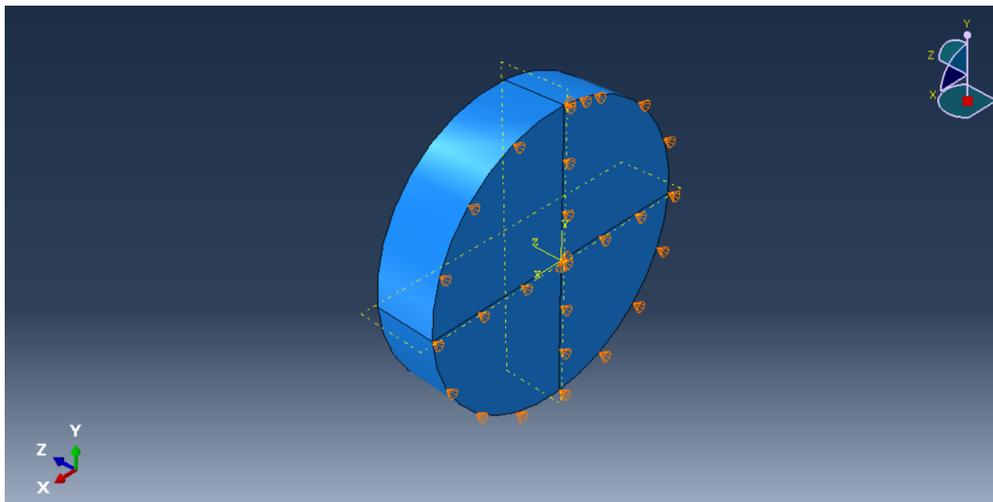


Figura 3.17 Condiciones de contorno impuestas en la superficie apoyada del disco.

Además de estas últimas condiciones impuestas, sobre la superficie superior, la no apoyada, imponemos la condición de carga, que al igual que en el ensayo de tracción, esta se define en términos de desplazamiento. Concretamente, el desplazamiento impuesto ha sido de 4 mm, figura 3.18.

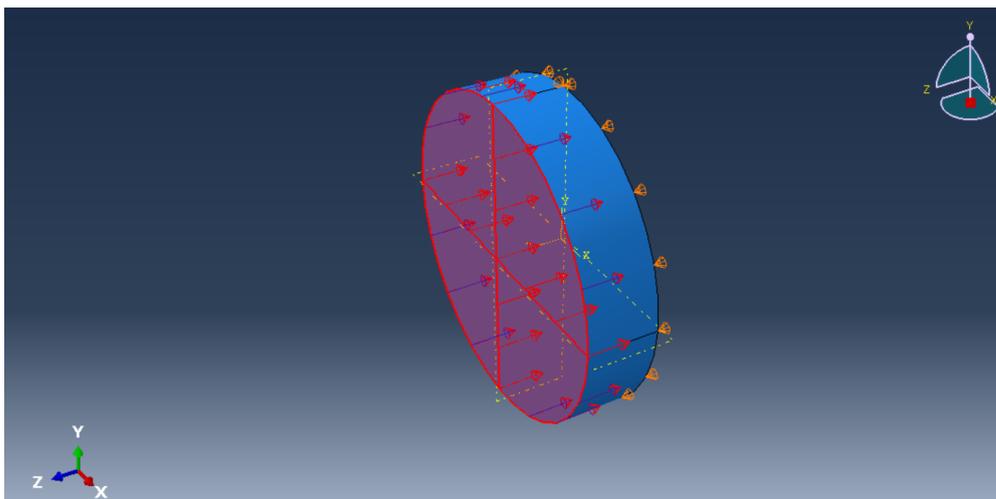


Figura 3.18 Desplazamiento impuesto en el ensayo de compresión como condición de contorno.

Al igual que antes en el ensayo de tracción, es necesario definir dos puntos auxiliares, uno en la superficie superior y otro en la inferior mediante dos Sets para medir el desplazamiento relativo. Para crear estos Sets ha sido necesario establecer un plano XY y otro plano XZ y a partir de dichos planos se han creado dos particiones, figura 3.19.

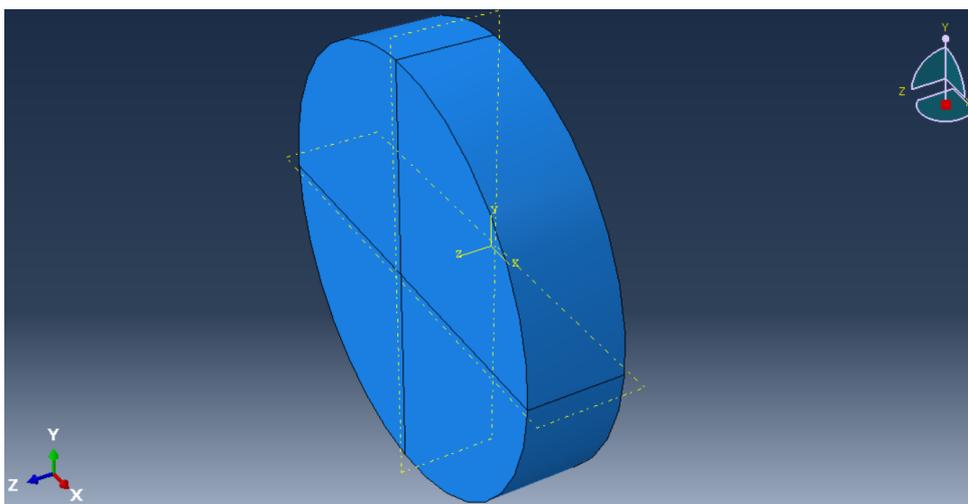


Figura 3.19 Particiones creadas para establecer los 2 puntos de referencia y así hallar el desplazamiento relativo en el ensayo de compresión.

De igual forma que en el ensayo de tracción, la componente F_{11} se calcula de la misma forma, estando definida por la ecuación 3.1, donde ahora d es 12,5 mm siendo esta distancia el espesor del disco.

Adicionalmente, al igual que con los anteriores aspectos, la metodología seguida para mallar es idéntica a como se hizo en el ensayo de tracción. Se han elegido elementos "Hex" y se han seleccionado las opciones de "Hybrid formulation" y "Reduced integration", figura 3.20.

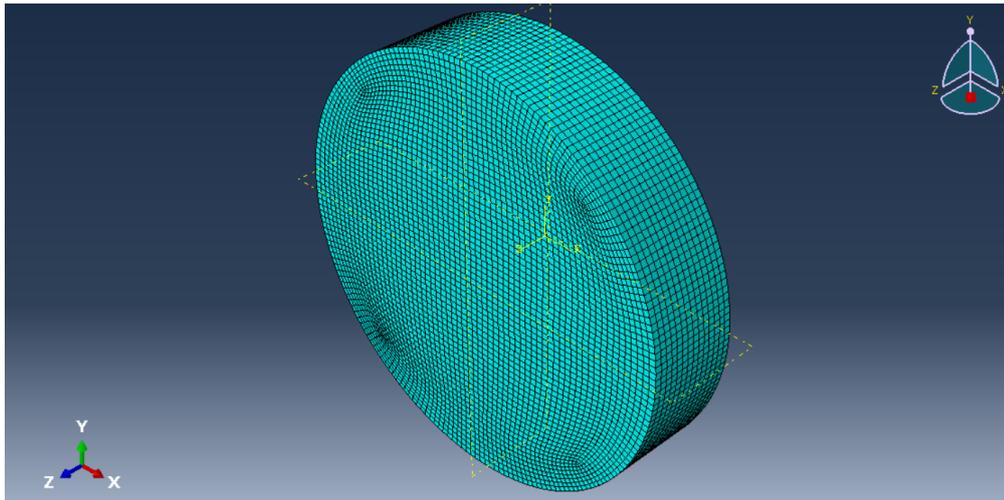


Figura 3.20 Mallado del disco para el ensayo a compresión.

Una vez definido esto, se le pasa el modelo a ABAQUS para que realice el análisis y proporcione los resultados. Estos resultados son los mostrados en las figuras 3.21-3.26.

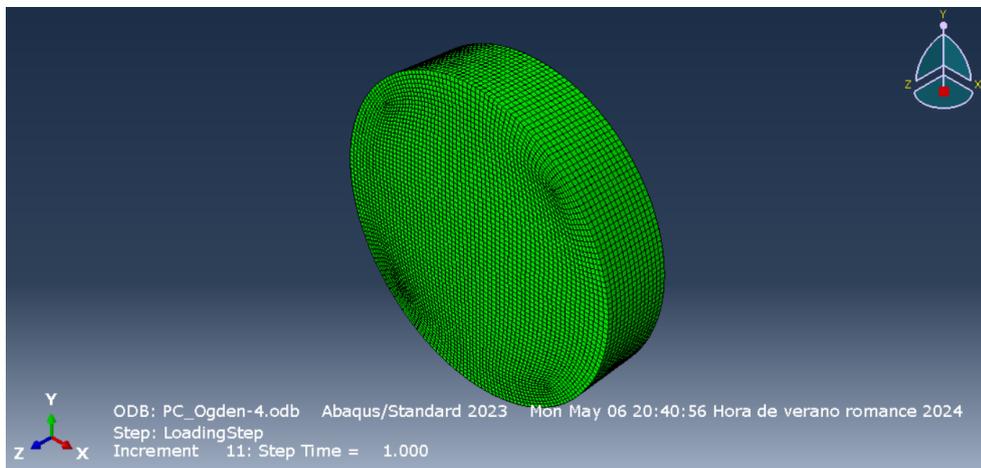


Figura 3.21 Probeta indeformada en el ensayo de compresión.

En la figura 3.22, se observa que la probeta se deforma reduciendo su espesor en la dirección Z, pues es la dirección en la cual se aplica la carga de compresión.

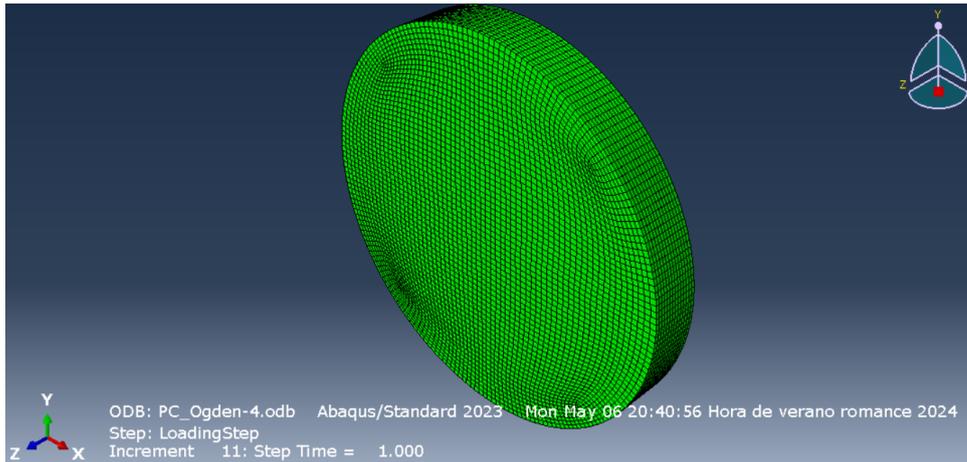


Figura 3.22 Probeta deformada en el ensayo de compresión.

Ya en la figura 3.23, se aprecia como en la superficie superior de la probeta, en la que se actúa para generar la compresión, los desplazamientos u_z son uniformes dado que el aplastamiento de la probeta con la superficie del útil también se produce de manera uniforme en la probeta. Los desplazamientos en dicha superficie son negativos debido a la naturaleza de la carga aplicada, mientras que en la superficie de la probeta donde se produce el apoyo con el útil de ensayo, dichos desplazamientos son nulos, tal y como debe de ser según las condiciones de contorno impuestas en la figura 3.17.

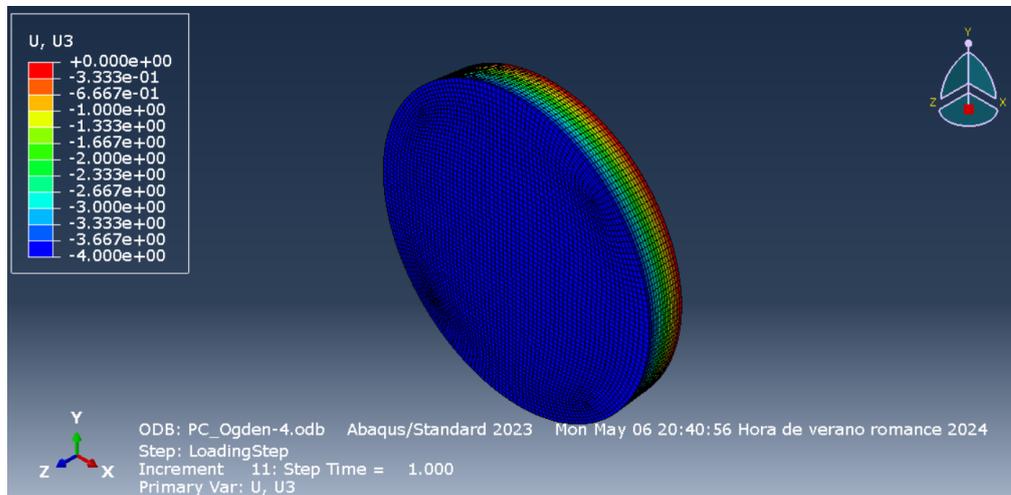


Figura 3.23 Desplazamientos en la dirección Z en el ensayo de compresión.

Además, en las figuras 3.24 y 3.25, donde se presentan la componente de las deformaciones y de las tensiones en el eje Z respectivamente se puede observar de nuevo la uniformidad de dichas variables, debido a que la carga que actúa durante la simulación es aplicada uniformemente también.

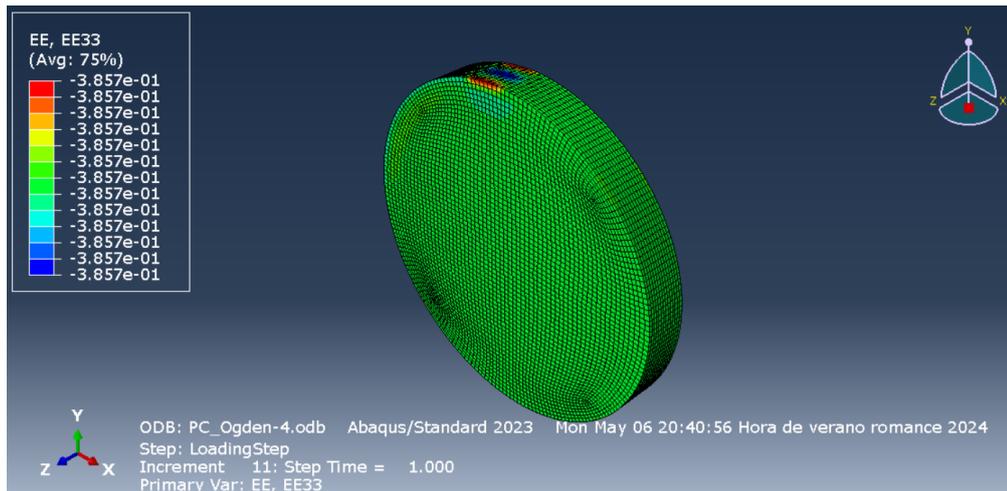


Figura 3.24 Deformaciones en la dirección Z en el ensayo de compresión.

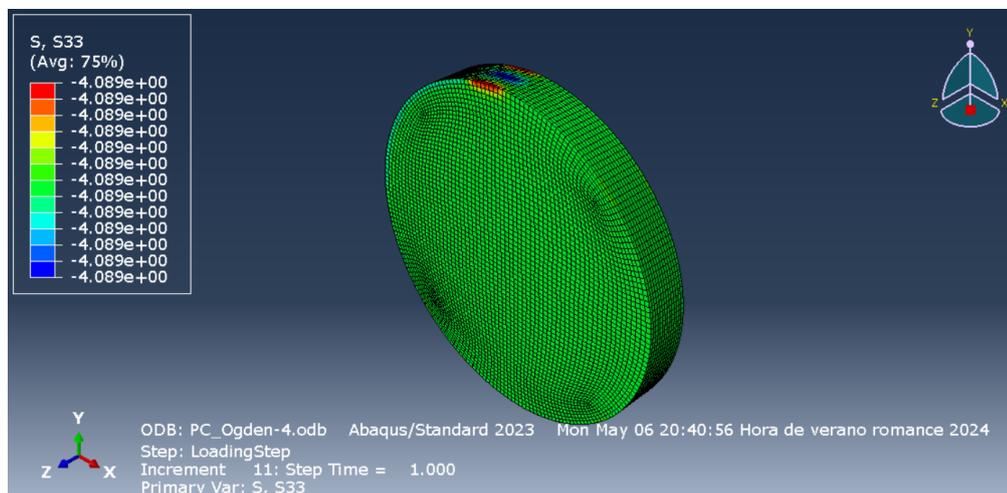


Figura 3.25 Tensiones en la dirección Z en el ensayo de compresión.

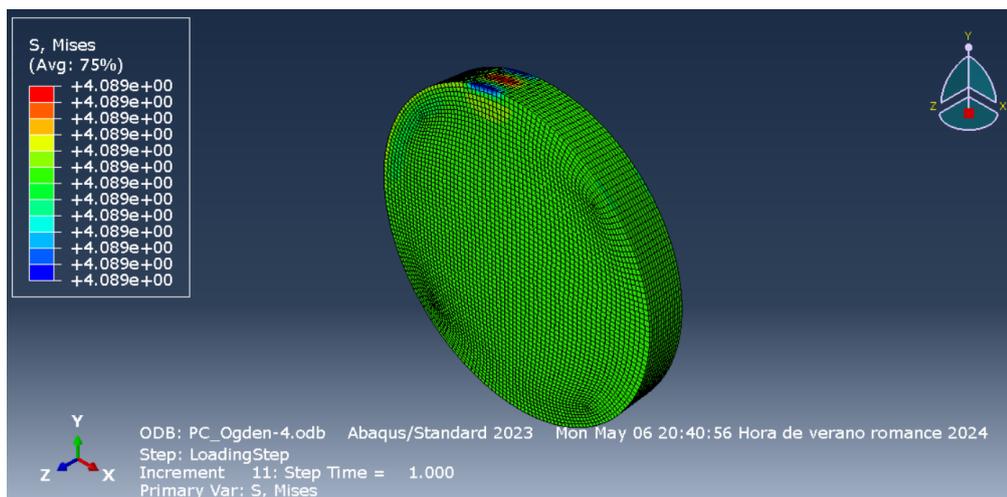


Figura 3.26 Tensiones de Von Mises en el ensayo de compresión.

Por otro lado, en las tablas 3.1 y 3.5, al igual que se hiciera en el ensayo de tracción, se presentan los valores de las variables más significativas de la simulación para nodo inferior y superior respectivamente con respecto al tiempo de simulación. A partir de estos datos y con la ecuación presentada en la expresión 3.1 se obtienen los resultados mostrados en la tabla 3.6 cuyos valores se usan para entrenar la red neuronal.

Tabla 3.4 Resultados obtenidos de la simulación para el nodo inferior en el ensayo de compresión.

Nodo inferior			
Tiempo	Desplazamientos [mm]	Deformaciones	Tensiones[Mpa]
0	0	0	0
0,001	0	-0,0003	-0,0037
0,002	0	-0,0006	-0,0075
0,0035	0	-0,0011	-0,0131
0,0058	0	-0,0018	-0,0215
0,0091	0	-0,0029	-0,0342
0,0142	0	-0,0046	-0,0532
0,0218	0	-0,0070	-0,0816
0,0332	0	-0,0107	-0,1244
0,0503	0	-0,0162	-0,1886
0,0759	0	-0,0246	-0,2852
0,0900	0	-0,02945	-0,3386
0,1143	0	-0,0373	-0,4306
0,1300	0	-0,04132	-0,4902
0,1700	0	-0,05578	-0,6422
0,1720	0	-0,0566	-0,6498
0,1900	0	-0,0623	-0,7189
0,2200	0	-0,0815	-0,8341
0,2585	0	-0,0863	-0,9818

En la tabla 3.4, como se ha comentado ya, puede apreciarse como los desplazamientos del nodo inferior usado como referencia son nulos, algo lógico pues como condición de contorno se impuso que la superficie donde se encuentra dicho punto permanezca apoyada sobre la superficie inmóvil del útil de ensayo.

Tabla 3.5 Resultados obtenidos de la simulación para el nodo superior en el ensayo de compresión.

Nodo superior			
Tiempo	Desplazamientos [mm]	Deformaciones	Tensiones[Mpa]
0	0	0	0
0,001	-0,004	-0,0003	-0,0037
0,002	-0,008	-0,0006	-0,0075
0,0035	-0,0140	-0,0011	-0,0131
0,0058	-0,0230	-0,0018	-0,0215
0,0091	-0,0871	-0,0029	-0,0342
0,0142	-0,0568	-0,0046	-0,0532
0,0218	-0,0871	-0,0070	-0,0816
0,0332	-0,1327	-0,0107	-0,1244
0,0503	-0,2010	-0,0162	-0,1886
0,0759	-0,3035	-0,0246	-0,2852
0,0900	-0,3600	-0,02945	-0,3386
0,1143	-0,4573	-0,0373	-0,4306
0,1300	-0,5201	-0,04132	-0,4902
0,1700	-0,6800	-0,05578	-0,6422
0,1720	-0,6880	-0,0566	-0,6498
0,1900	-0,8000	-0,0623	-0,7189
0,2200	-0,9231	-0,0815	-0,8341
0,2585	-1,0340	-0,0863	-0,9818

Tabla 3.6 Resultados de F_{11} obtenidos de la simulación en el ensayo de compresión.

Tiempo	F_{11}
0	1
0,001	0,9997
0,002	0,9994
0,0035	0,9989
0,0058	0,9982
0,0091	0,9971
0,0142	0,9955
0,0218	0,9930
0,0332	0,98394
0,0503	0,9839
0,0759	0,9757
0,0900	0,9712
0,1143	0,9634
0,1300	0,9584
0,1700	0,9456
0,1720	0,9450
0,1900	0,9392
0,2200	0,9296
0,2585	0,9173

Ahora, se observa en la tabla 3.6, que todos los valores de F_{11} en compresión se encuentra entre 1 y 0,9, es decir, la variable F_{11} sigue una secuencia decreciente en compresión cuando la carga aumenta, algo lógico si tenemos en cuenta la ecuación 3.1 y los valores y signos de los desplazamientos de los nodos auxiliares considerados. Por otra parte, este criterio (valores de F_{11} entre 1 y 0,9) ha sido el seguido para la selección de los datos experimentales usados para entrenar la red, siguiéndose así la misma filosofía empleada por los creadores de la red para su entrenamiento.

3.1.3 Ensayo de cortadura

Con respecto al ensayo de cortadura, se ha recurrido a la normativa ISO 1827 que permite la determinación del módulo de cortadura del caucho, considerando que este se encuentra adherido a placas metálicas. Concretamente la metodología del ensayo se muestra en la figura 3.27.

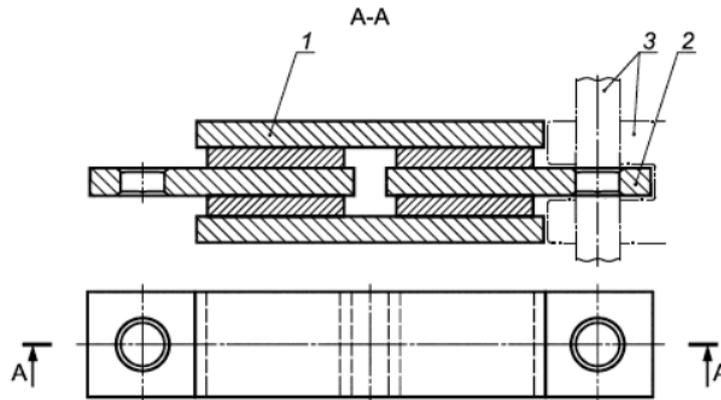


Figura 3.27 Morfología del ensayo a cortadura según la normativa ISO 1827.

El ensayo está compuesto por cuatro elementos paralelepípedos idénticos de caucho de $4 \text{ mm} \pm 1 \text{ mm}$ de espesor, $20 \text{ mm} \pm 5 \text{ mm}$ de ancho y $25 \text{ mm} \pm 5 \text{ mm}$ de largo, pegados en cada una de sus dos caras opuestas más grandes a las caras de contacto de cuatro placas rígidas del mismo ancho y de longitudes apropiadas para obtener una superficie simétrica. Adicionalmente, los elementos marcados como 1, 2 y 3 en la figura 3.27 son las placas de acero consideradas rígidas externas e internas y un pasador y dispositivo para carga de tracción respectivamente. De esta forma, el ensayo consistiría en aplicar tracción a la placa de acero intermedia de la izquierda mediante el agujero que esta tiene en la dirección horizontal.

Una vez definido esto, se pasa a modelar el ensayo en ABAQUS. Para ello, y dada la simetría que se puede apreciar en la figura 3.27 se ha optado por, en lugar de modelar las 4 probetas y todas las placas de acero, aislar únicamente una y aplicar las condiciones de contorno necesarias acordes con la simetría del problema. Es por ello que el modelo de ABAQUS es el que aparece en la figura 3.28.

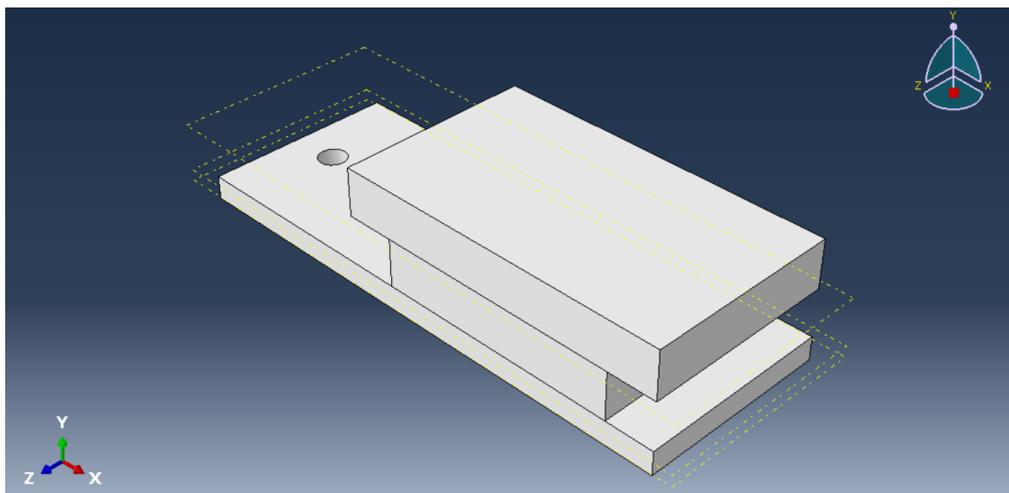


Figura 3.28 Modelo de ABAQUS de la morfología usada para el ensayo de cortadura.

A diferencia de los ensayos anteriores, ahora tenemos además de la probeta, que es el paralelepípedo intermedio en la figura 3.27, también contamos con los útiles de ensayo que son las dos placas exteriores que se ven en la misma imagen. Es por ello, que es necesario definir dos materiales, uno para la probeta cuyo

material es el caucho y otro para las placas cuyo material es el acero. Con respecto al caucho el modelo de material es el mismo que el definido en la figura 3.3, mientras que para las placas es el acero, definido tal y como aparece en la tabla 3.7. Además, para asignar cada material a cada una de las partes correspondientes del modelo ha sido necesario crear dos "Sections" una para la probeta y otra para el útil de ensayo compuesto por las dos placas de acero.

Tabla 3.7 Propiedades mecánicas del acero.

Módulo de Young [Mpa]	Coefficiente de Poisson
210×10^3	0,27

Con respecto a las condiciones de contorno, se ha impuesto simetría con respecto al eje X en las caras internas las placas de acero, aquellas que en la figura 3.28 se encuentran en el plano YZ más situadas a la derecha, tal y como se muestra en la figura 3.29.

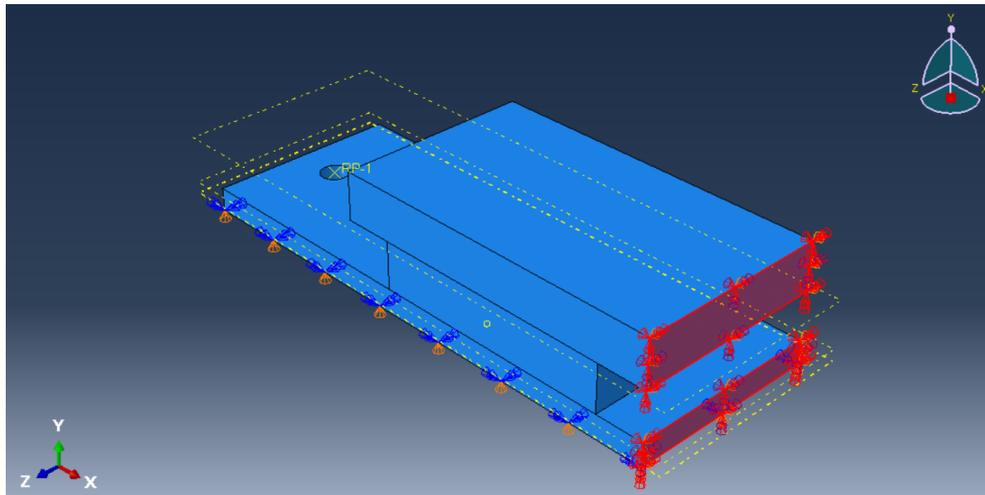


Figura 3.29 Condición de contorno de simetría con respecto a X en el modelo de ABAQUS para el ensayo de cortadura.

De igual forma, se ha tomado la mitad del espesor de la placa de acero inferior y se ha aplicado simetría con respecto al eje Y , como se muestra en la figura 3.30.

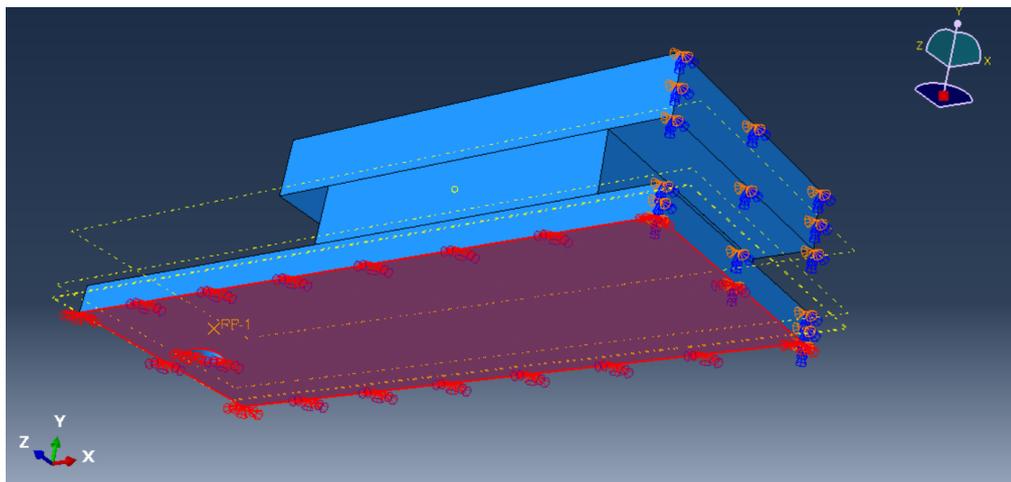


Figura 3.30 Condición de contorno de simetría con respecto a Y en el modelo de ABAQUS para el ensayo de cortadura.

Adicionalmente y para tener otro grado más de libertad restringido se impone que los desplazamientos en las superficies mostradas en la figura 3.29 a lo largo del eje Z sean nulos, como se muestra en la figura 3.31.

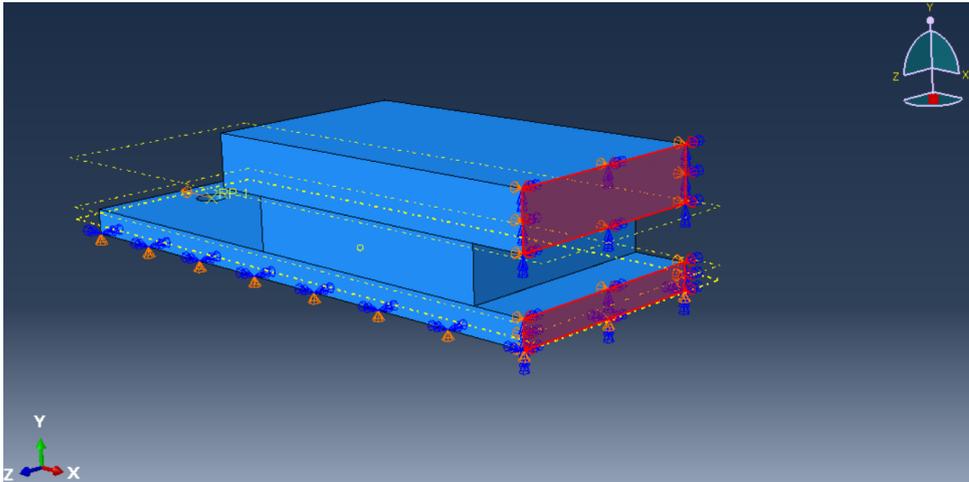


Figura 3.31 Condición de contorno que restringe desplazamientos en Z en el modelo de ABAQUS para el ensayo de cortadura.

Por último, resta imponer la condición de carga del ensayo. Al igual que en los ensayos anteriores esta condición es definida en términos de desplazamientos, dicho desplazamiento es impuesta en la dirección X en sentido negativo, tal y como se muestra en la figura 3.32, para lo cual ha sido necesario definir un "Reference point" en ABAQUS. Concretamente, el desplazamiento impuesto ha sido de 5mm.

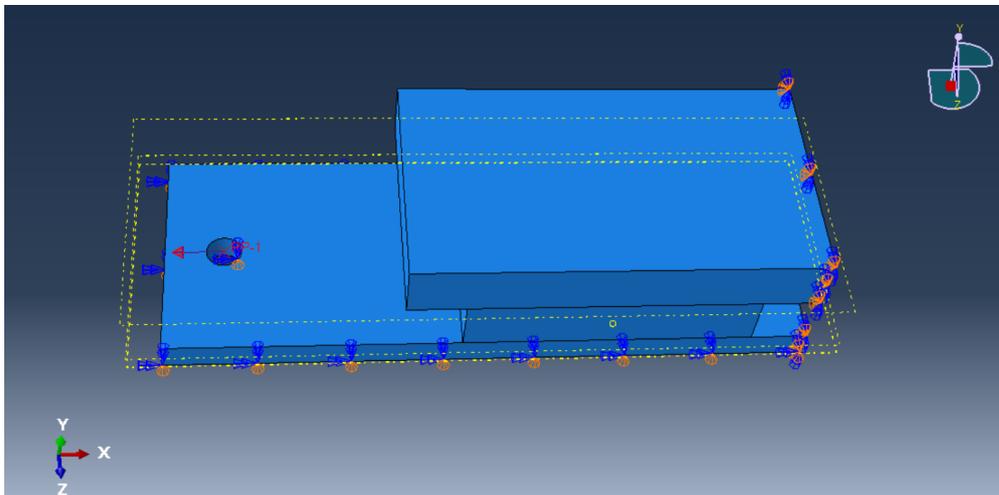


Figura 3.32 Condición de contorno que impone la condición de carga en términos de desplazamientos en el modelo de ABAQUS para el ensayo de cortadura.

Una vez definido esto, se muestra el mallado del modelo en el que esta vez dada la complejidad del mismo en cuanto a interferencias entre diferentes elementos, concretamente entre la probeta y las placas de acero no ha sido posible mallar con elementos "Hex", sino que esta vez han sido elementos tipo "Tet", el principal inconveniente de esto es que al ser elementos triangulares introducen un poco de distorsión al modelo al introducir una rigidez adicional al mismo. El resultado del mallándose muestra en la figura 3.33.

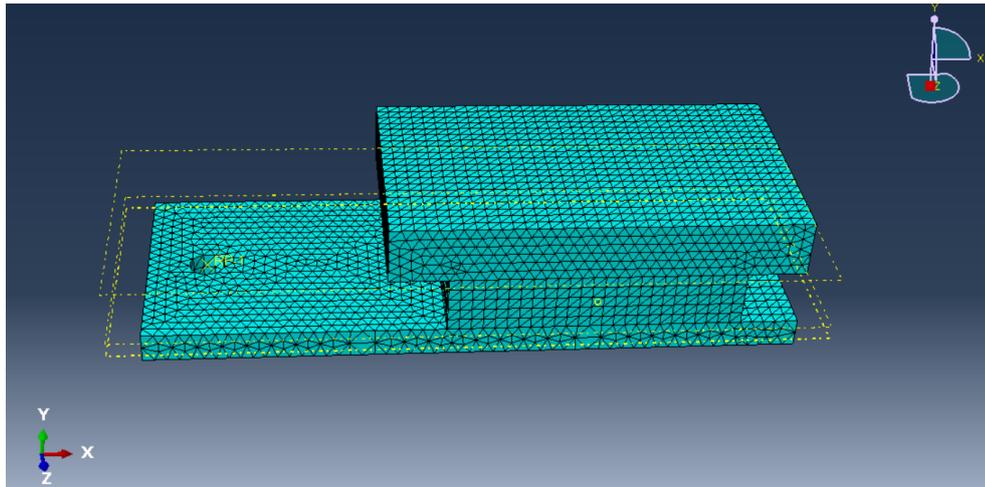


Figura 3.33 Mallado del modelo para el ensayo de cortadura.

Tras esto, se simula el análisis con ABAQUS obteniendo los resultados que se ven en las figuras 3.34-3.39.

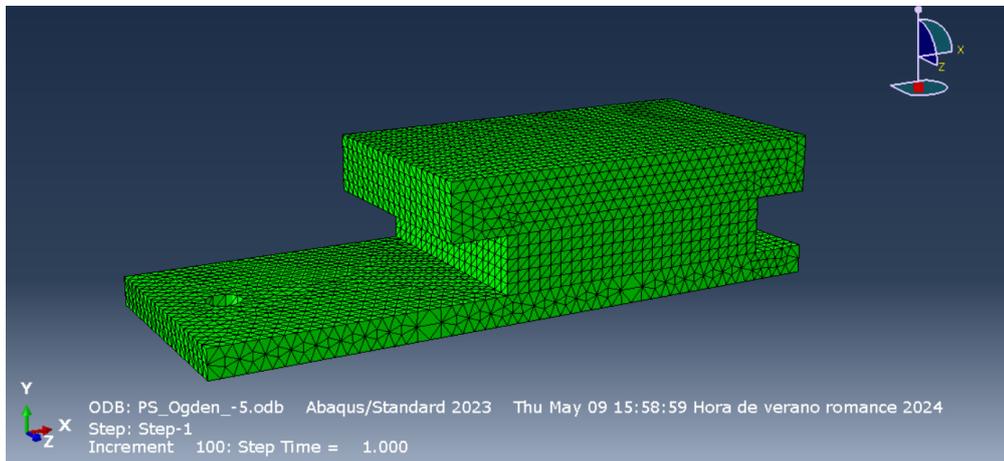


Figura 3.34 Modelo indeformado del ensayo de cortadura.

En la figura 3.35 se presenta la deformada obtenida tras finalizar el proceso de carga, como vemos en esa figura las deformaciones que interesan para nutrir a la red neuronal se encuentran en el plano XY.

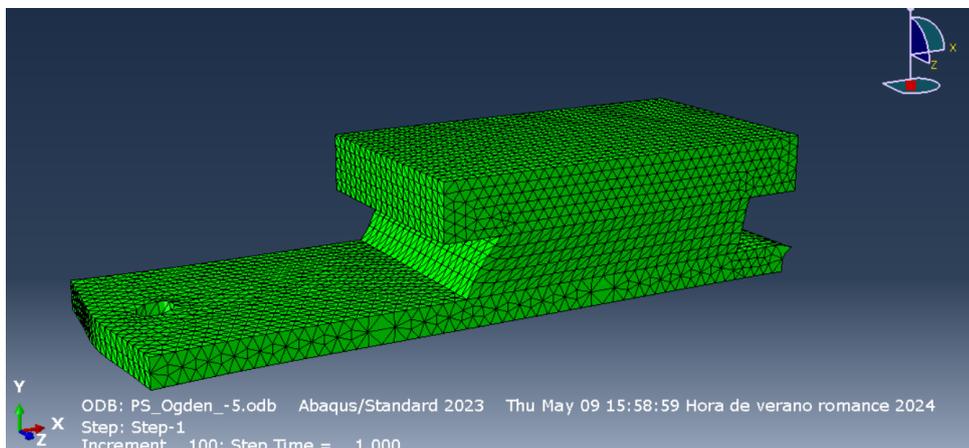


Figura 3.35 Modelo deformado del ensayo de cortadura.

A diferencia de los ensayos anteriores, en la figura 3.36 se muestra la variable desplazamiento como magnitud en lugar de como componente, la razón es que ahora entran en juego todas las componentes de los desplazamientos en los tres ejes X, Y y Z. Concretamente, nos centraremos en los desplazamientos u_{xy} . Además, en cuanto a valores máximos se puede observar en las figuras 3.36 y 3.37 cómo estos se dan en la unión entre la probeta y la placa inferior del útil de ensayo puesto que es la que se desplaza y en la que se aplica la condición de carga.

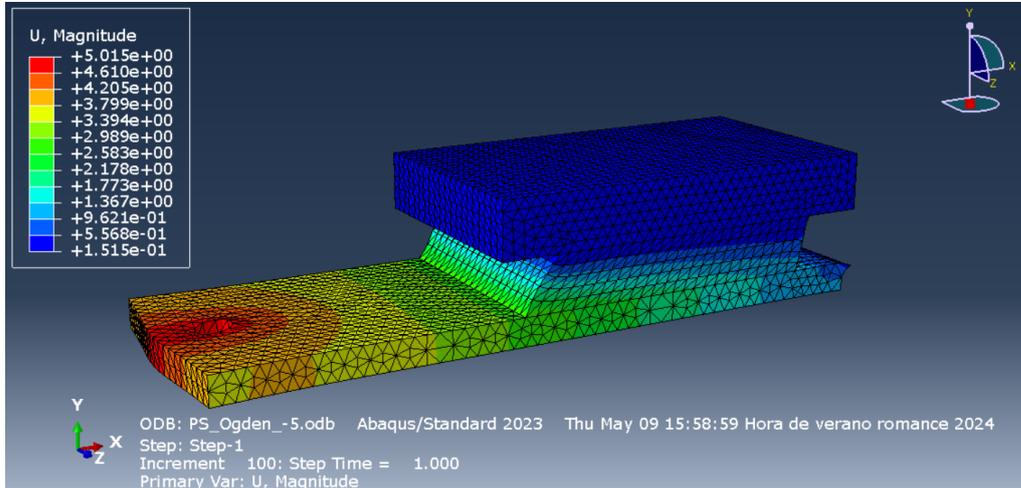


Figura 3.36 Representación de los desplazamientos como magnitud del modelo en el ensayo de cortadura.

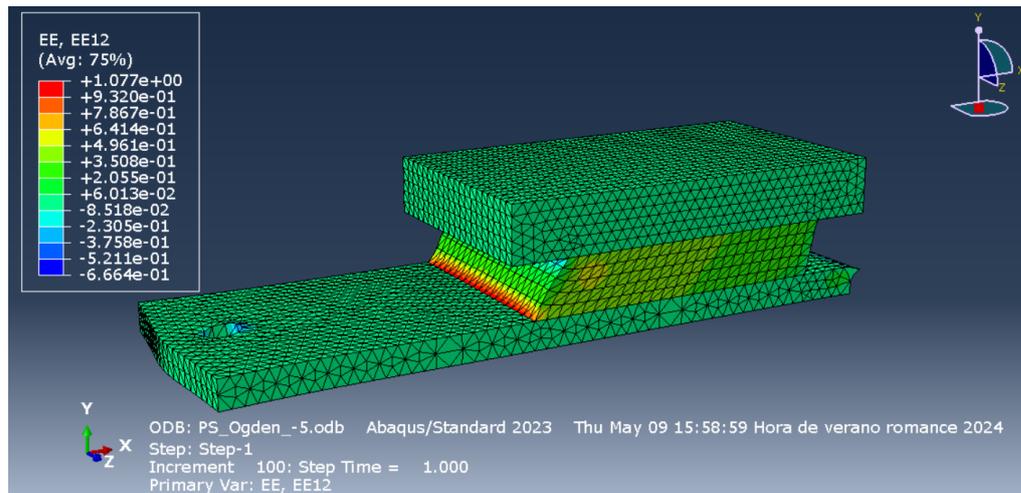


Figura 3.37 Deformaciones ϵ_{xy} del modelo en el ensayo de cortadura.

Por otro lado, en la figura 3.38 puede verse la uniformidad en las las tensiones σ_{xy} .

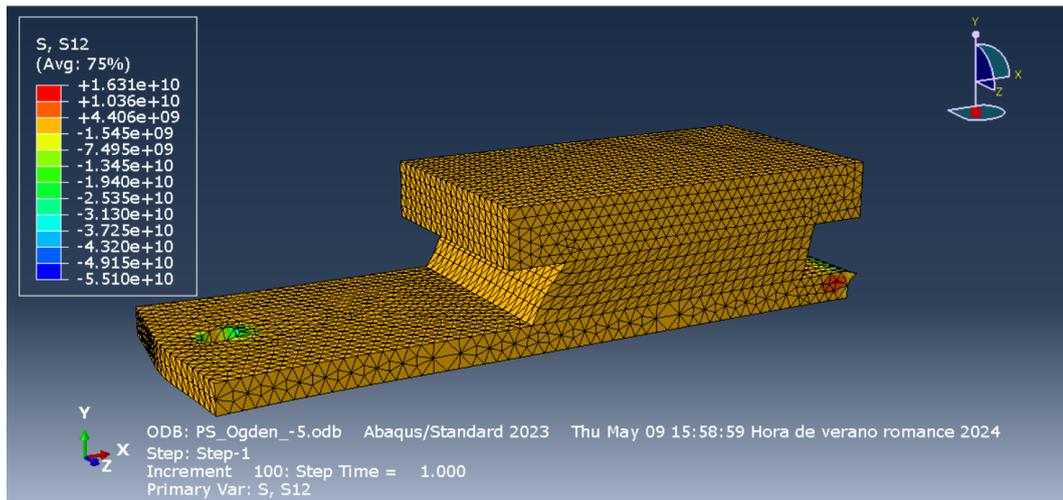


Figura 3.38 Tensiones σ_{xy} del modelo en el ensayo de cortadura.

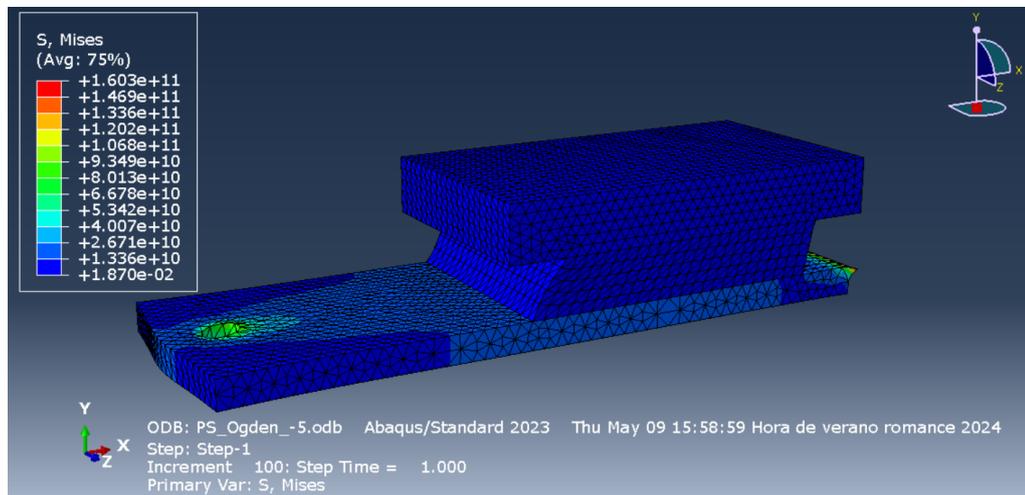


Figura 3.39 Tensiones de Von Mises del modelo en el ensayo de cortadura.

Por otro lado, los nodos seleccionados para medir los diferentes parámetros del ensayo (desplazamientos, deformaciones, tensiones, etc.) se han seleccionado de manera que se encuentren en la cara lateral de la probeta, es decir, la cara que se encuentra en las diferentes figuras anteriores y situados sobre la misma vertical. De esta manera los parámetros obtenidos son los mostrados en las tablas 3.8, 3.9 y 3.10, cuya filosofía es la misma que la indicada en los casos anteriores.

Tabla 3.8 Resultados obtenidos de la simulación para el nodo inferior en el ensayo de cortadura.

Nodo inferior			
Tiempo	Desplazamientos, u_{xy} [mm]	Deformaciones, γ_{xy}	Tensiones, σ_{xy} [Mpa]
0	0	0	0
0,03	-0,0358	0,0118	0,0462
0,06	-0,0714	0,0236	0,0921
0,09	-0,1069	0,0352	0,1377
0,13	-0,1538	0,0507	0,1980
0,16	-0,1888	0,0621	0,2429
0,19	-0,2237	0,0735	0,2875
0,22	-0,2585	0,0848	0,3318
0,24	-0,2815	0,0923	0,3612
0,26	-0,3045	0,0997	0,3905
0,29	-0,3389	0,1109	0,4342
0,32	-0,3732	0,1219	0,4777
0,35	-0,4074	0,1328	0,5209
0,37	-0,4301	0,1400	0,5496
0,39	-0,4527	0,1473	0,5782
0,42	-0,4866	0,1581	0,6209
0,45	-0,5204	0,1687	0,6633
0,47	-0,5429	0,1758	0,6915
0,49	-0,5653	0,1829	0,7196
0,52	-0,5989	0,1933	0,7615

Tabla 3.9 Resultados obtenidos de la simulación para el nodo superior en el ensayo de cortadura .

Nodo superior			
Tiempo	Desplazamientos, u_{xy} [mm]	Deformaciones, γ_{xy}	Tensiones, σ_{xy} [Mpa]
0	0	0	0
0,03	-0,0119	0,0121	0,0472
0,06	-0,0239	0,0241	0,0941
0,09	-0,0357	0,0360	0,1409
0,13	-0,0514	0,0518	0,2029
0,16	-0,0631	0,0635	0,2429
0,19	-0,0747	0,0752	0,2954
0,22	-0,0863	0,0868	0,3414
0,24	-0,0941	0,0945	0,3720
0,26	-0,1017	0,1022	0,4025
0,29	-0,1132	0,1136	0,4480
0,32	-0,1247	0,1250	0,4935
0,35	-0,1361	0,1363	0,5388
0,37	-0,1436	0,1438	0,5689
0,39	-0,1512	0,1512	0,5989
0,42	-0,1625	0,1624	0,6439
0,45	-0,1737	0,1734	0,6887
0,47	-0,1812	0,1808	0,7185
0,49	-0,1887	0,1881	0,7482
0,52	-0,1999	0,1990	0,7928

Tabla 3.10 Resultados de F_{12} obtenidos de la simulación en el ensayo de cortadura.

Tiempo	F_{12}
0	0
0,03	0,0119
0,06	0,0238
0,09	0,0356
0,13	0,0512
0,16	0,0629
0,19	0,0745
0,22	0,0860
0,24	0,0937
0,26	0,1014
0,29	0,1129
0,32	0,1243
0,35	0,1357
0,37	0,1432
0,39	0,1508
0,42	0,1621
0,45	0,1733
0,47	0,1808
0,49	0,1883
0,52	0,1995

Al igual que para los anteriores ensayos el criterio de selección de datos procedentes del ensayo para este caso es que F_{12} se encuentre entre 0 y 0,2, algo que se cumple como se puede ver en la tabla 3.10.

3.2 Resultados obtenidos al entrenar la red neuronal

Antes de mostrar los resultados obtenidos de entrenar la red, se pasa a definir ciertos parámetros que nos van a permitir conocer si los resultados son fiables o si en cambio, los resultados que nos muestra la red no son del todo válidos. Estos parámetros son la función de pérdida y el coeficiente de determinación.

3.2.1 Función de pérdida

Dicha función nos mide de cierta manera el error que se produce entre nuestro modelo de red neuronal y los datos de los que hacemos uso para su entrenamiento, tal y como se menciona en [1]

El objetivo de la red neuronal, como se ha dicho en ocasiones anteriores, es el de aprender los parámetros de la red, los pesos y los sesgos (w_k, b_k), todo esto debe hacerlo minimizando la función de pérdida, L , que penaliza el error y las desviaciones que se producen entre el modelo y los datos. Este error o diferencia se caracteriza como el error cuadrático medio, la norma al cuadrado de la diferencia entre el modelo $P(F_i)$ y los datos \hat{P}_i (siendo F la deformación), dividido entre el número de datos usados para entrenar a la red, n_{trn} .

$$L(w_k, b_k, F) = \frac{1}{n_{trn}} \sum_{i=1}^{n_{trn}} \|P(F_i) - \hat{P}_i\|^2 \rightarrow \min \quad (3.2)$$

3.2.2 Coeficiente de determinación R^2

El coeficiente de determinación, se trata de un coeficiente usado en el contexto de un modelo estadístico cuyo principal objetivo es predecir resultados futuros o probar hipótesis, tal y como se indica en [5]. Este coeficiente muestra la calidad del modelo para replicar los resultados. Su cálculo se realiza realizando cálculos estadísticos, como se puede ver en [5]. Por otro lado, el valor de este parámetro suele estar entre 0 y 1. Cuanto más cerca se sitúe su valor de 1, mayor es el ajuste del modelo a la variable que se está intentando replicar. De forma inversa, cuanto más cerca de 0, menos ajustado es el modelo y por tanto, menos fiable.

3.2.3 Resultados para los diferentes casos de carga

Llegados a este punto, en el ya se han realizado los ensayos y se han obtenido los resultados de los mismos, el siguiente paso es pasarle estos datos a la red para su entrenamiento. Concretamente, los datos que se le pasan a la red son S_{11} y F_{11} para tracción y compresión y S_{12} y F_{12} para cortadura, dado que para los tres ensayos se tienen dos datos de S_{11} o S_{12} para cada instante de tiempo, correspondientes a los dos nodos auxiliares, se ha optado por coger la media de ambos valores para entrenar la red, ya que a esta únicamente hay que proporcionarle un valor de tensión para cada valor de F_{11} o F_{12} . De esta forma, el formato en el que se le pasan los datos de entrenamiento a la red es el mostrado por la figura 3.40.

Uniaxial F11 [-]	Uniaxial P [MPa]	Shear F12 [-]	Shear P [MPa]
9,1730E-01	-9,8182E-01	-1,9952E-01	-7,6149E-01
9,3600E-01	-7,5730E-01	-1,8832E-01	-7,1855E-01
9,4500E-01	-6,4982E-01	-1,7334E-01	-6,6330E-01
9,5840E-01	-4,9020E-01	-1,6207E-01	-6,2086E-01
9,6340E-01	-4,3055E-01	-1,5077E-01	-5,7819E-01
9,7120E-01	-3,3860E-01	-1,3565E-01	-5,2093E-01
9,7570E-01	-2,8519E-01	-1,2427E-01	-4,7771E-01
9,8390E-01	-1,8863E-01	-1,1285E-01	-4,3424E-01
9,8940E-01	-1,2439E-01	-1,0139E-01	-3,9052E-01
9,9300E-01	-8,1633E-02	-8,6043E-02	-3,3182E-01
9,9550E-01	-5,3153E-02	-7,4478E-02	-2,8748E-01
9,9710E-01	-3,4178E-02	-6,2865E-02	-2,4287E-01
9,9820E-01	-2,1534E-02	-5,1201E-02	-1,9798E-01
9,9890E-01	-1,3106E-02	-3,5566E-02	-1,3768E-01
9,9940E-01	-7,4886E-03	-2,3774E-02	-9,2104E-02
9,9970E-01	-3,7441E-03	-1,1920E-02	-4,6216E-02
1,0000E+00	0,0000E+00	0,0000E+00	0,0000E+00
1,0065E+00	4,3682E-02	1,1920E-02	4,6216E-02
1,0122E+00	7,6643E-02	2,3774E-02	9,2104E-02
1,0178E+00	1,0973E-01	3,5566E-02	1,3768E-01
1,0253E+00	1,5400E-01	5,1201E-02	1,9798E-01
1,0310E+00	1,8730E-01	6,2865E-02	2,4287E-01
1,0367E+00	2,2066E-01	7,4478E-02	2,8748E-01
1,0424E+00	2,5407E-01	8,6043E-02	3,3182E-01
1,0501E+00	2,9870E-01	1,0139E-01	3,9052E-01
1,0559E+00	3,3222E-01	1,1285E-01	4,3424E-01
1,0616E+00	3,6577E-01	1,2427E-01	4,7771E-01
1,0674E+00	3,9936E-01	1,3565E-01	5,2093E-01
1,0752E+00	4,4420E-01	1,5077E-01	5,7819E-01
1,0810E+00	4,7786E-01	1,6207E-01	6,2086E-01
1,0869E+00	5,1156E-01	1,7334E-01	6,6330E-01
1,0928E+00	5,4528E-01	1,8832E-01	7,1855E-01
1,0947E+00	5,5652E-01	1,9952E-01	7,6149E-01

Figura 3.40 Datos para el entrenamiento de la red neuronal, obtenidos de los ensayos.

En dicha figura, se puede ver como los datos de los ensayos uniaxiales se han fusionado en una sola columna, mientras que para cortadura se han replicado los datos obtenidos en el sentido contrario de la dirección en la que se aplicó cortadura en el ensayo, ya que los resultados a obtener son los mismos.

Una vez definido esto y pasados los datos de la figura 3.40 a la red, esta realiza internamente su entrenamiento de la forma que ya se ha mencionado en capítulos anteriores. Para ello, la herramienta utilizada ha sido Python y como se ha comentado anteriormente, no se ha programado nada sobre la red, sino que se ha tomado de la referencia [1]. Finalizado esto, los resultados que se obtienen se muestran a continuación para diferentes casos de carga.

Caso 1: Compresión

En este caso, los datos usados para entrenar la red son únicamente aquellos obtenidos mediante el ensayo a compresión mostrado anteriormente, es decir, aquellos datos correspondiente al caso uniaxial que van desde

la fila 1 a la fila 17 de la figura 3.40.

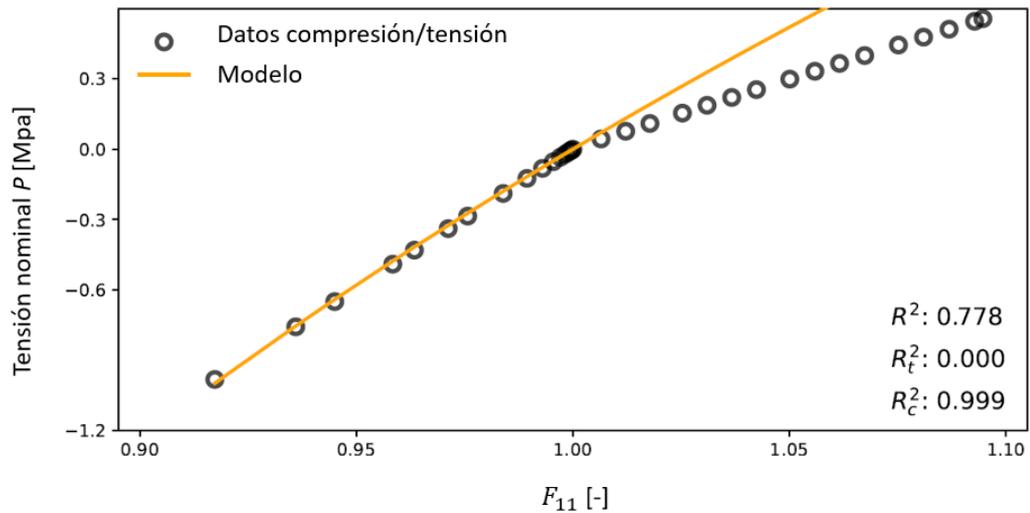


Figura 3.41 Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de compresión.

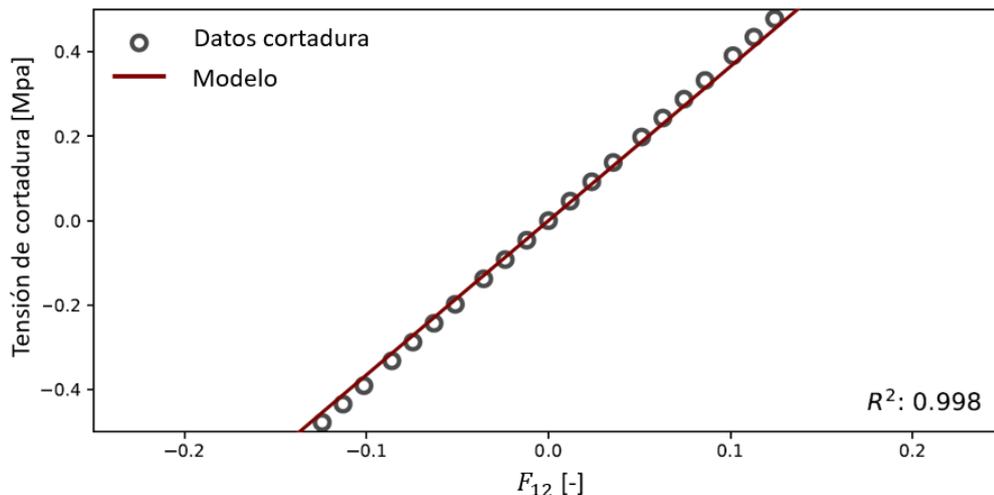


Figura 3.42 Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de compresión.

Como puede verse en las figuras 3.41 y 3.42 el modelo se ajusta bien a los datos experimentales pero únicamente en la zona en la que F_{11} está entre 0,9 y 1, justo la zona que se corresponde al caso en el que se somete a la probeta del ensayo a compresión. Además, puede verse que el coeficiente de determinación medido para los datos de compresión R_c^2 es bastante próximo a 1. Sin embargo el mismo coeficiente pero medido para los datos de tracción es prácticamente 0, consecuencia de que el modelo solo ha sido entrenado con datos correspondientes a casos en los que se tiene compresión. Esto hace que el coeficiente de determinación total para carga uniaxial sea de 0,778, un valor considerablemente bueno aunque mejorable. Por otro lado, el valor del coeficiente de determinación para carga de cortadura es de 0,998 que es bastante alto debido a que el ajuste entre modelo y datos es bastante bueno.

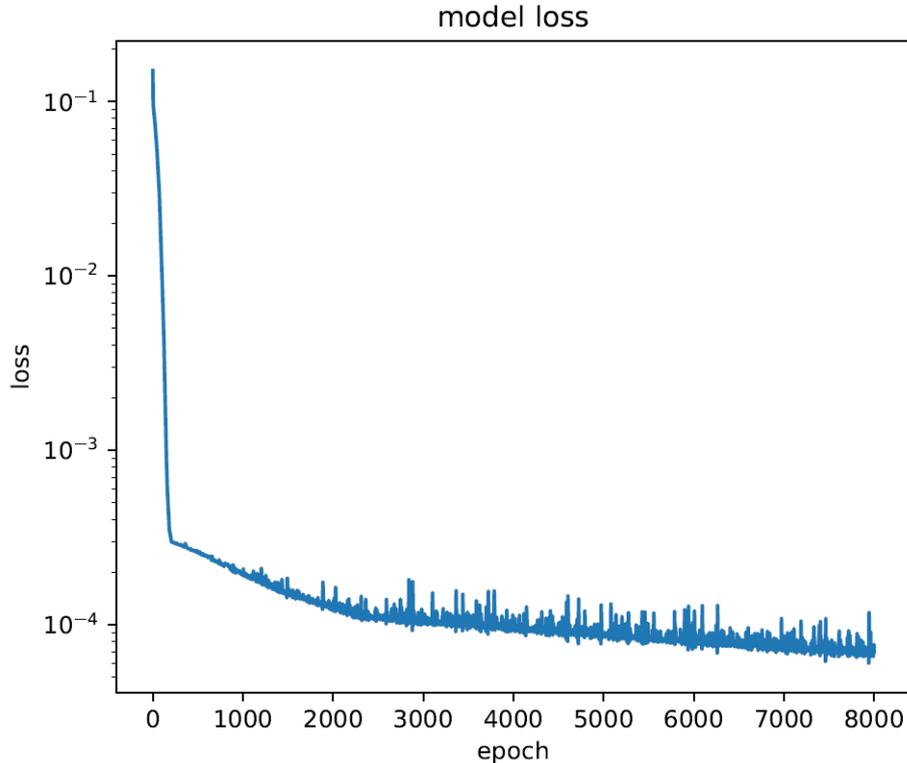


Figura 3.43 Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de compresión.

En la figura 3.43, puede verse que los valores que termina alcanzando la función de pérdida son inferiores a 10^{-4} por lo que se ha conseguido el objetivo de minimizar las diferencias entre el modelo y los datos experimentales.

Caso 2: Tracción

Ahora, los datos tomados para entrenar la red son aquellos correspondientes al ensayo de tracción definido, aquellos que van desde la fila 17 a la 34 en la figura 3.40 para el caso uniaxial.

A diferencia del caso de compresión, ahora como pueden verse en las figuras 3.44 y 3.45 el modelo se ajusta de manera muy precisa a los datos experimentales en la zona en la que F_{11} se encuentra entre 1 y 1,1, justo la zona correspondiente a valores de F_{11} de tracción, por lo que se puede concluir que el modelo proporciona buenos resultados para casos en los que se tiene tracción. Ahora, de manera contraria a como sucedía en el caso anterior, el coeficiente de determinación es 1 para casos en los que se tiene carga a tracción y algo menos para casos en los que la carga es a compresión, algo lógico pues la red se ha entrenado únicamente con datos correspondientes a casos de carga en los que se aplica tracción. De esta manera el cómputo global de este parámetro es de 0,909, siendo bastante cercano a 1. lo cual hace indicar que el modelo se ajusta bastante mejor a este caso de carga si lo comparamos con el caso anterior en el que la carga era a compresión. Por otro lado, el coeficiente de determinación para datos de cortadura baja con respecto al caso de carga uniaxial siendo su valor de 0,824, algo evidente pues el modelo no ha sido entrenado con datos correspondientes a un caso de carga en el que se tiene cortadura y prueba de ello es la diferencia entre modelo y datos que se puede apreciar en la figura 3.45.

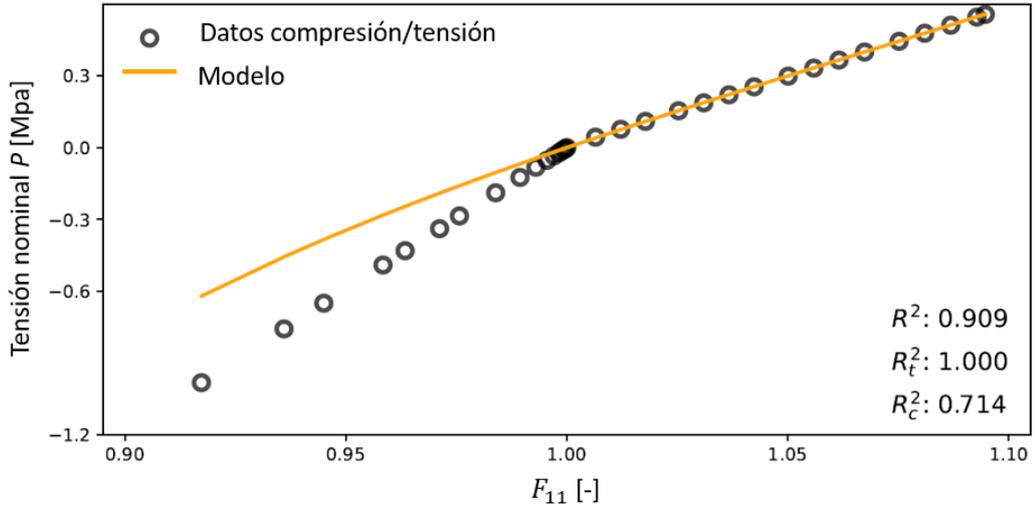


Figura 3.44 Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de tracción.

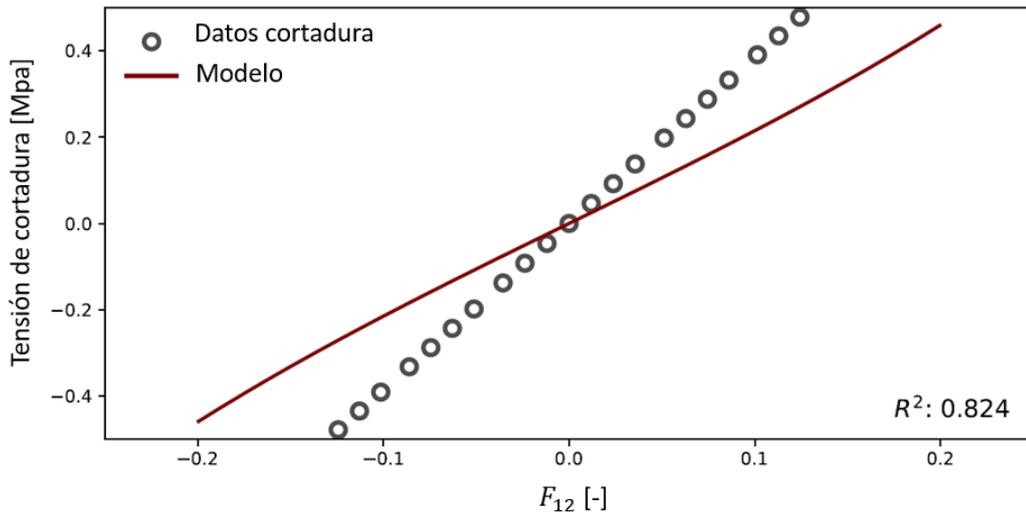


Figura 3.45 Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de tracción.

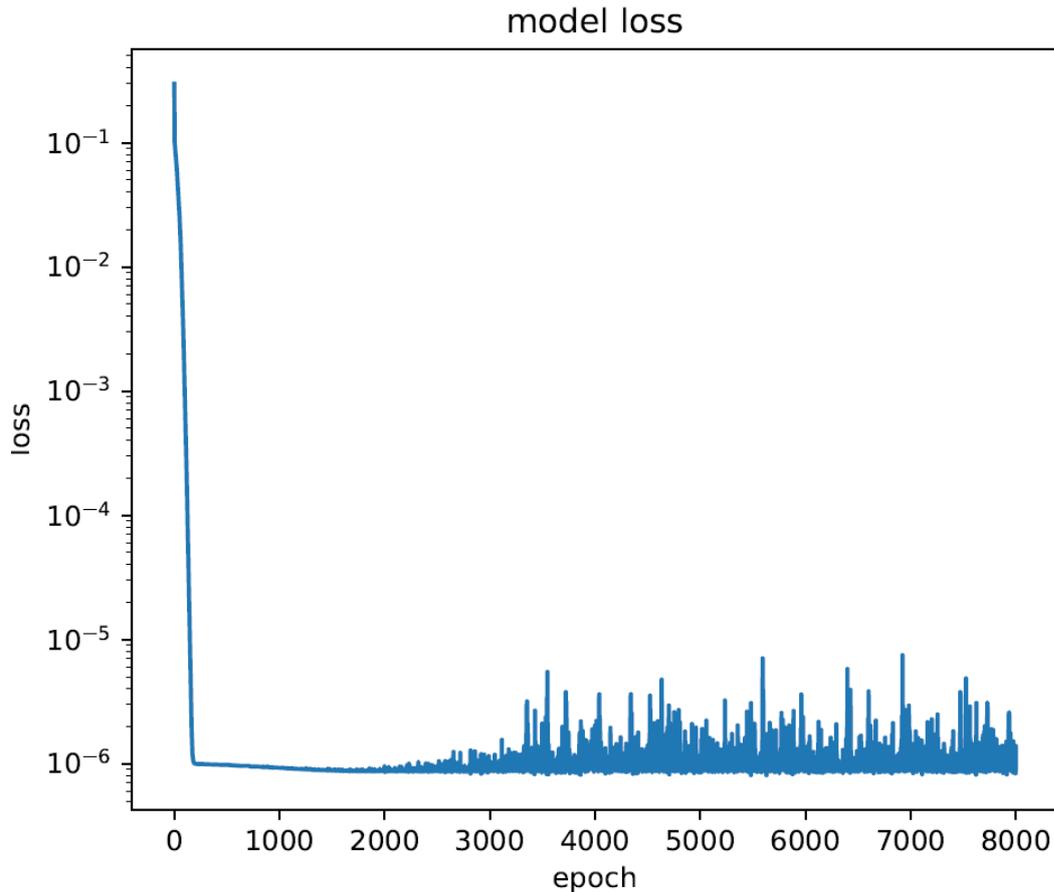


Figura 3.46 Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de tracción.

En la figura 3.46 se visualiza como la función de pérdida para el caso de tracción alcanza valores del orden de 10^{-6} , por lo que se tiene otra evidencia de que el modelo se ajusta de manera bastante precisa a los datos para este caso de carga.

Caso 3: Cortadura

Al igual que en casos anteriores, ahora los datos seleccionados para el entrenamiento de la red son los datos obtenidos del ensayo de cortadura, los que se encuentran en las columnas de shear de la figura 3.40.

Se puede apreciar en la figura 3.47 que en este caso, el modelo no se ajusta bien para los casos en los que se tiene carga de tracción, pero sí que se ajusta algo mejor para casos en los que se tiene carga de compresión. Prueba de ello, es el valor de los coeficiente de determinación que se obtienen, mientras que en compresión su valor es de 0,992, en tracción es de prácticamente 0. Esto hace que el cómputo global de este coeficiente para caso de carga uniaxial sea de 0,74. No obstante el modelo se ajusta de manera muy precisa a los datos experimentales en los casos en los que la carga aplicada es de cortadura, como se ve en la figura 3.48, en los cuales el valor de F_{12} se encuentra entre -0,2 y 0,2, algo evidente pues los datos usados para entrenar a la red han sido esta vez los correspondientes al ensayo de cortadura expuesto anteriormente y por ello el grado de determinación toma el valor unitario.

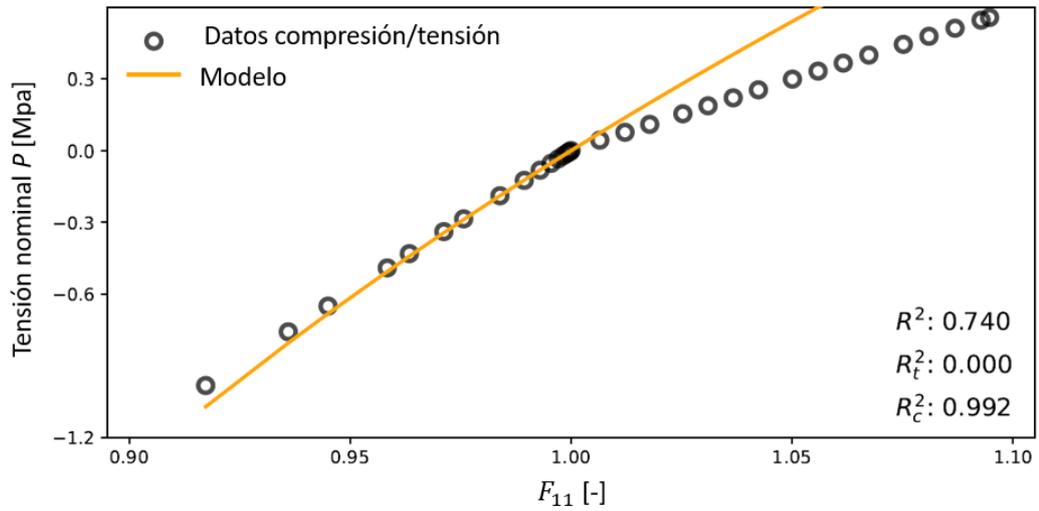


Figura 3.47 Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de cortadura.

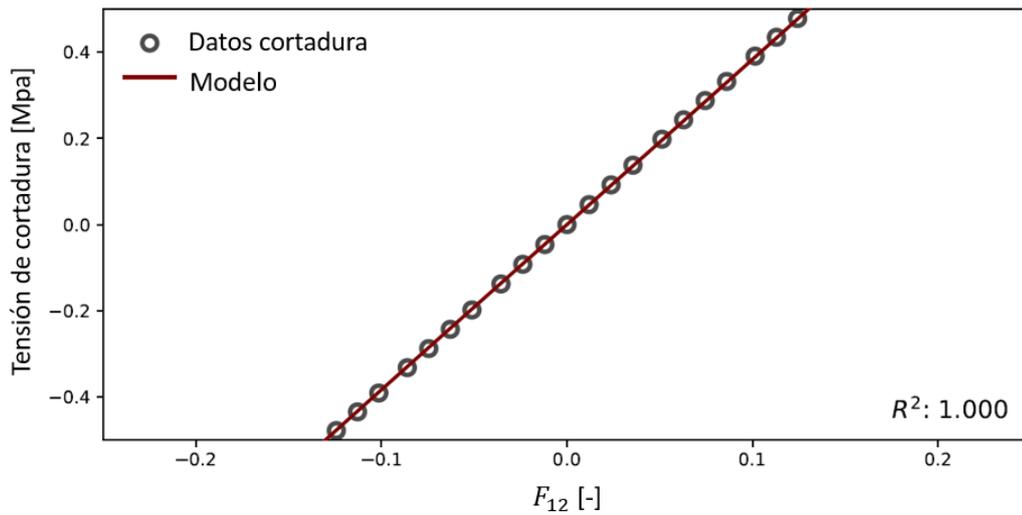


Figura 3.48 Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga de cortadura.

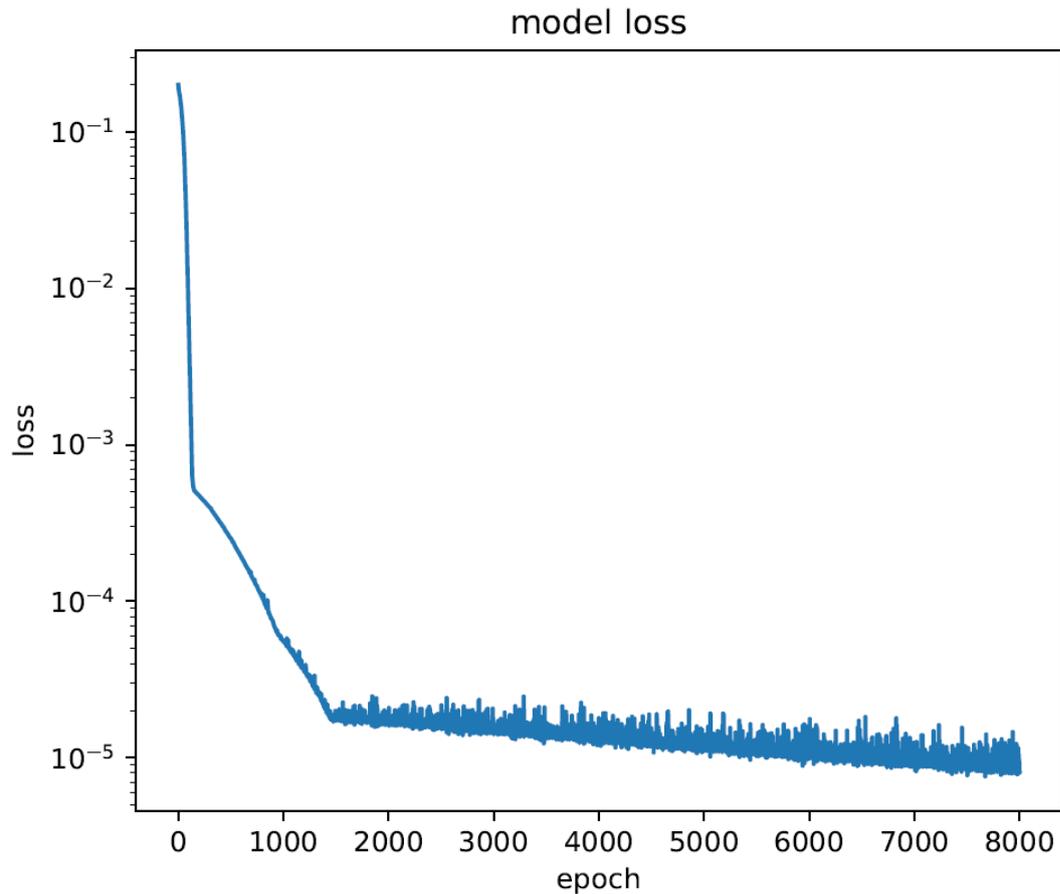


Figura 3.49 Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de cortadura.

Al igual que en casos anteriores, en la figura 3.49 se muestra la evolución de la función de pérdida, en la que se puede ver como se llega a valores de esa función del orden de 10^{-5} , lo que muestra también que el ajuste del modelo a los datos es bueno.

Caso 4: Combinación de cortadura y carga axial

A diferencia de los casos anteriores en el que se tomaban datos correspondientes a diferentes casos de carga obtenidos de los ensayos definidos con anterioridad, en este caso la red neuronal es entrenada con todos los datos de la figura 3.40 haciendo el entrenamiento de la misma mucho más realista.

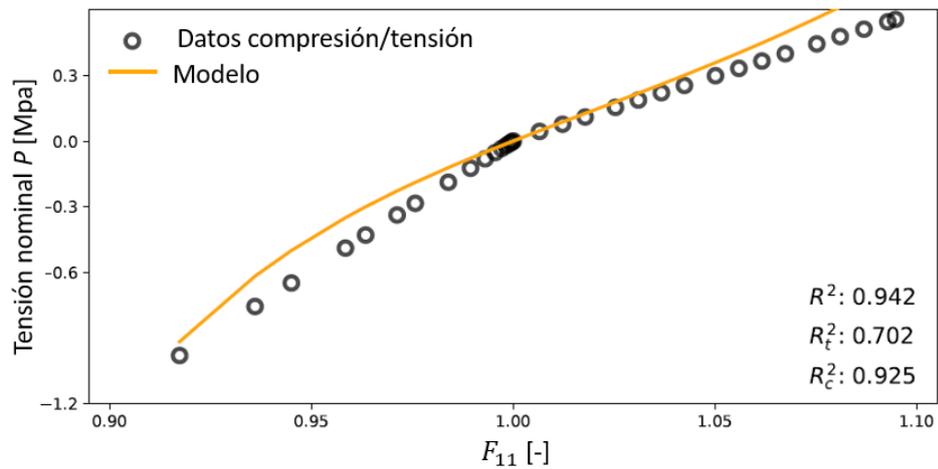


Figura 3.50 Comparación en términos de tensión nominal- F_{11} de los resultados uniaxiales obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga combinado de cortadura y carga axial.

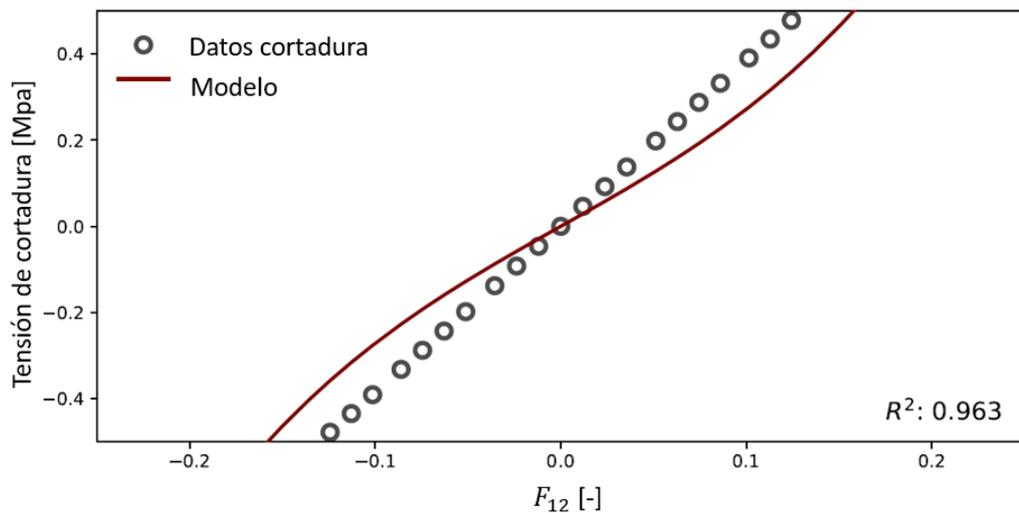


Figura 3.51 Comparación en términos de tensión de cortadura- F_{12} de los resultados de cortadura obtenidos del modelo con respecto a los datos experimentales al entrenar la red neuronal para un caso de carga combinado de cortadura y carga axial.

En las figuras 3.50 y 3.51 se muestra el ajuste del modelo a los datos experimentales, siendo dicho ajuste bueno aunque no del todo preciso, esto queda respaldado por los coeficientes de determinación que alcanzan valores bastantes cercanos a 1.

No obstante, en la figura 3.52, se ve como ahora la función de pérdida es del orden de 10^{-2} , algo superior de lo que era en casos anteriores, la razón se debe que ahora la red esta siendo entrenada con una mayor variedad de datos cuyo origen de carga es diferente, de ahí que este resultado no sea tan bueno como en casos anteriores.

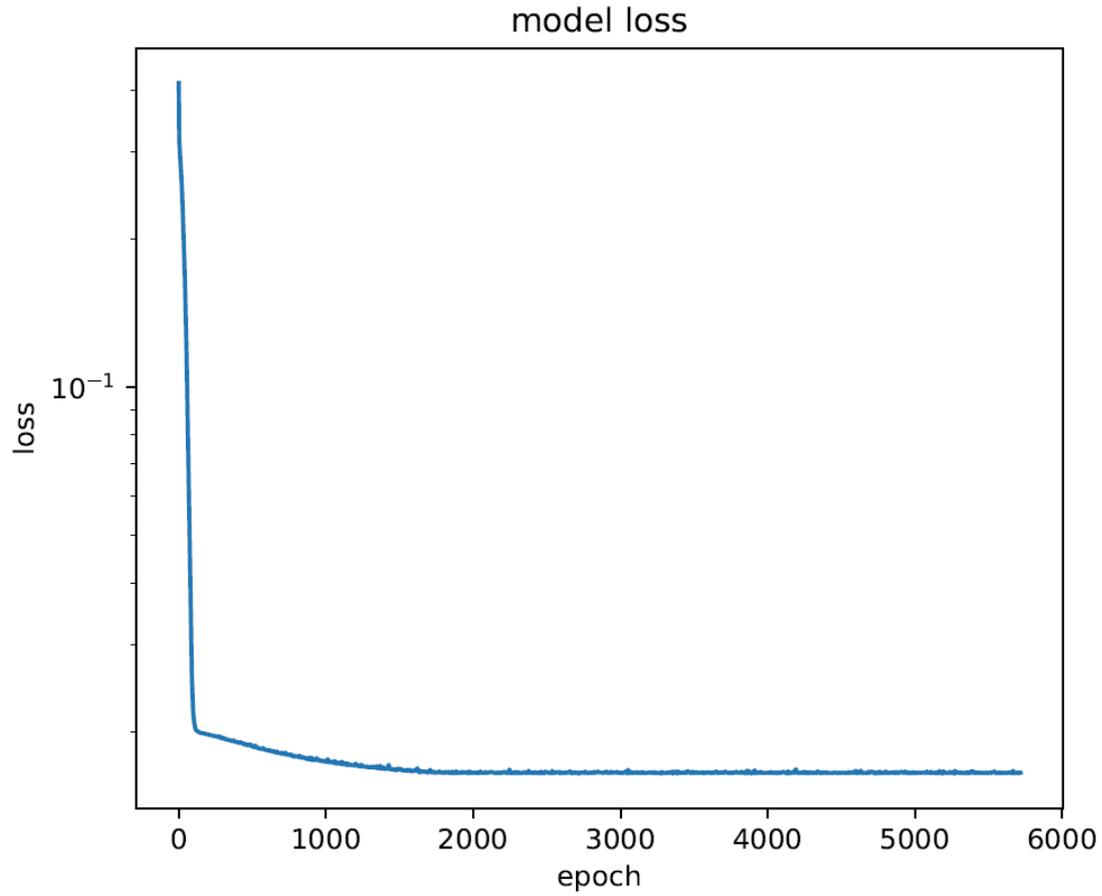


Figura 3.52 Función de pérdida correspondiente al entrenar a la red neuronal para un caso de carga de cortadura y carga uniaxial.

4 Aplicación del modelo a un caso real

El objetivo de este capítulo es el de aplicar el modelo obtenido mediante el entrenamiento de la red a un caso real. Este caso, consiste en el ensayo de tracción de una placa que contiene un agujero en su centro. De esta forma, dicho ensayo se realizará usando el propio software de elementos finitos de ABAQUS, tratando de simular el ensayo real, y también se resolverá mediante la subrutina UANISOHYPER_INV que contiene todos los datos necesarios procedentes del entrenamiento de la red neuronal, de modo que podamos comparar los resultados obtenidos por ambas metodologías.

El motivo por el cual se ha decidido tomar esta morfología para comprobar el modelo obtenido mediante el entrenamiento de la red neuronal es porque en una placa con un agujero central sometida a tracción en sus extremos, se tienen tanto compresión como tracción en las cercanías del orificio, que actúa como un concentrador de tensiones. De esta forma se testea el modelo para un caso completo en el que hay presencia de varios estados tensionales.

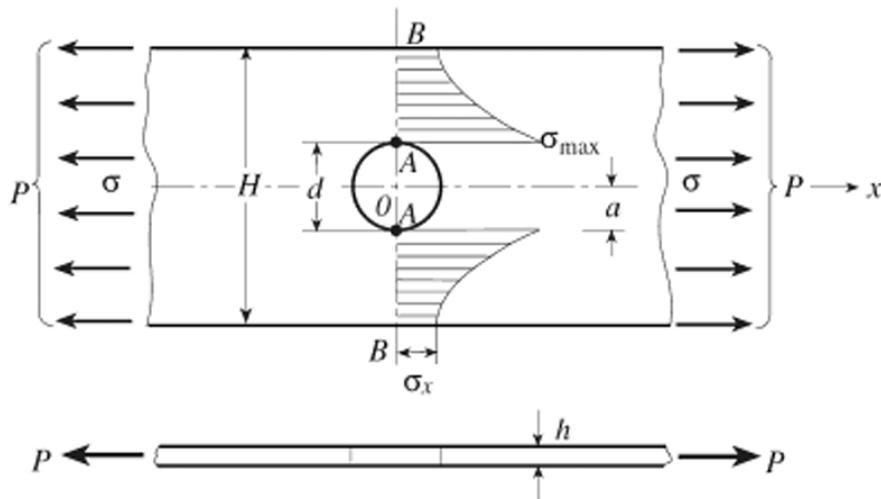


Figura 4.1 Estado tensional alrededor del orificio de la placa.

La probeta en cuestión a la que se le realiza el análisis está definida tal y como aparece en la figura 4.2, siendo su espesor de 2 mm.

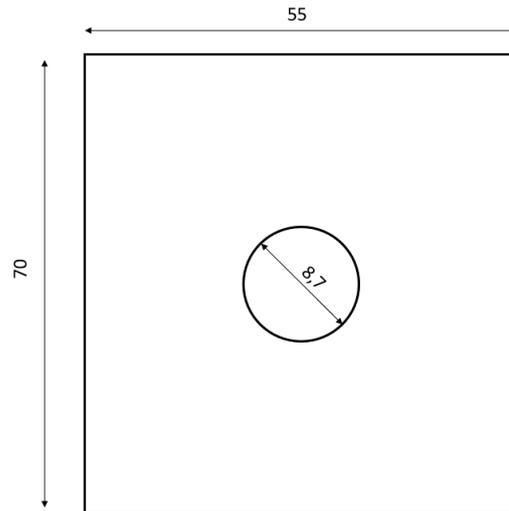


Figura 4.2 Dimensiones en mm de la placa con agujero central.

Por supuesto, el material definido para la misma ha sido caucho y se ha usado el modelo de Ogden definido en la figura 3.3.

Una vez definida la misma las condiciones de contorno impuestas son similares a las definidas en el ensayo de tracción definido con anterioridad. En el extremo inferior la probeta se somete a un empotramiento en el que se restringe tanto giro como desplazamiento alrededor de ejes X e Y y también se restringe desplazamiento a lo largo del eje Y , mientras que en el extremo superior se impone la condición de carga, en este caso, el desplazamiento impuesto en dicho extremos ha sido de 50 mm, que aunque el desplazamiento sea del orden de las longitudes de la placa no importa porque este tipo de material puede tener incrementos de longitud de 2, 3 o más veces su propia longitud. La razón de imponer este desplazamiento es salirnos de la zona de comportamiento lineal del material hiperelástico e introducirnos en una etapa de comportamiento elástico pero no lineal, esto se puede ver en la figura 4.3.

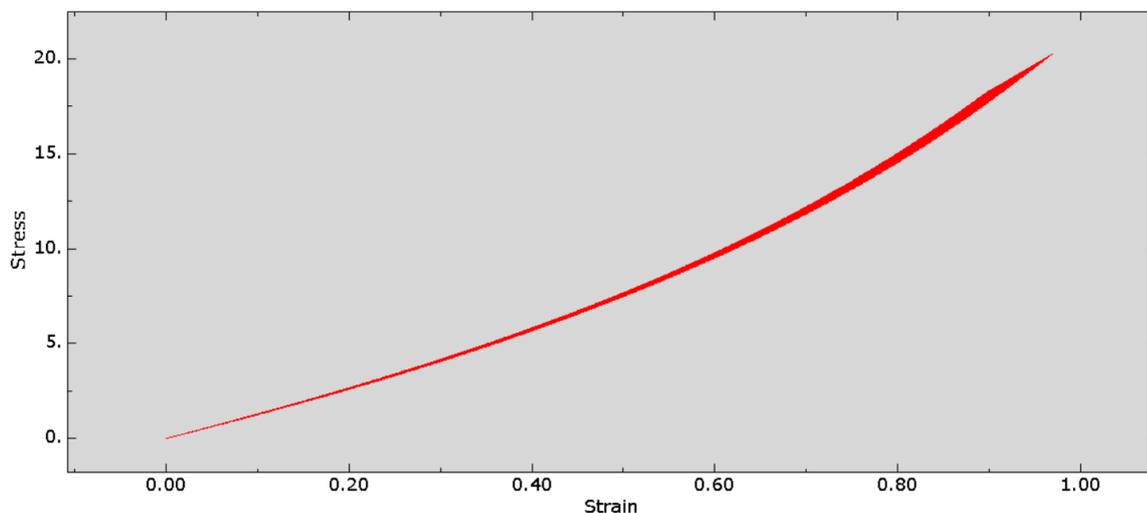


Figura 4.3 Gráfica tensiones-deformaciones para la placa con orificio central imponiendo un desplazamiento de 50 mm en su extremo superior.

De esta manera, el modelo de ABAQUS para la placa es el mostrado en la figura 4.4.

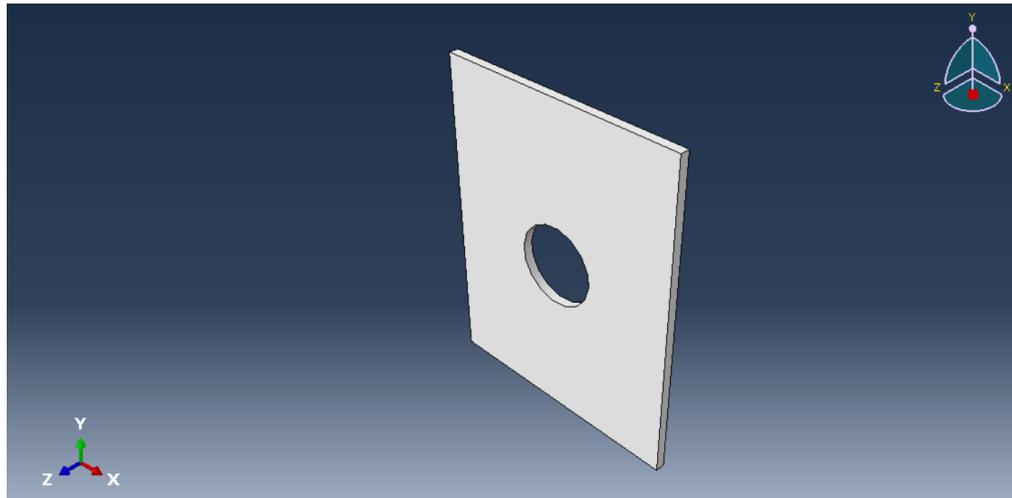


Figura 4.4 Modelo de ABAQUS para la placa con agujero central.

Una vez hecho el modelo, el mallado de la placa se hace siguiendo la misma filosofía que en los ensayos correspondientes a la obtención de datos para entrenar a la red. Se impone que los elementos de la malla sean de tipo "Hex" y se marcan las opciones de "Reduced integration" y de "Hybrid formulation".

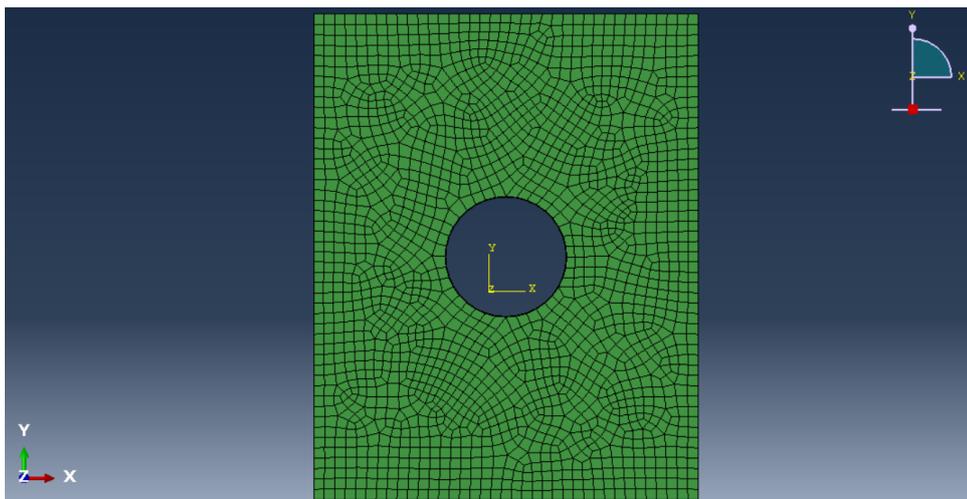


Figura 4.5 Malla de la placa con agujero central.

4.1 Resolución mediante MEF de ABAQUS

En este apartado se muestran los resultados obtenidos al resolver el problema escrito anteriormente mediante el MEF de ABAQUS. Para ello, el caso descrito anteriormente de la placa con el orificio central se procede de igual manera que se hizo con los ensayos. Una vez se tienen los dos "steps" uno inicial, donde se imponen las condiciones de contorno y otro para aplicar la condición de carga, se imponen las condiciones de contorno y se malla, se le pasa el modelo a ABAQUS para que resuelva. Los resultados obtenidos de dicha resolución son los mostrados en las figuras 4.6-4.11.

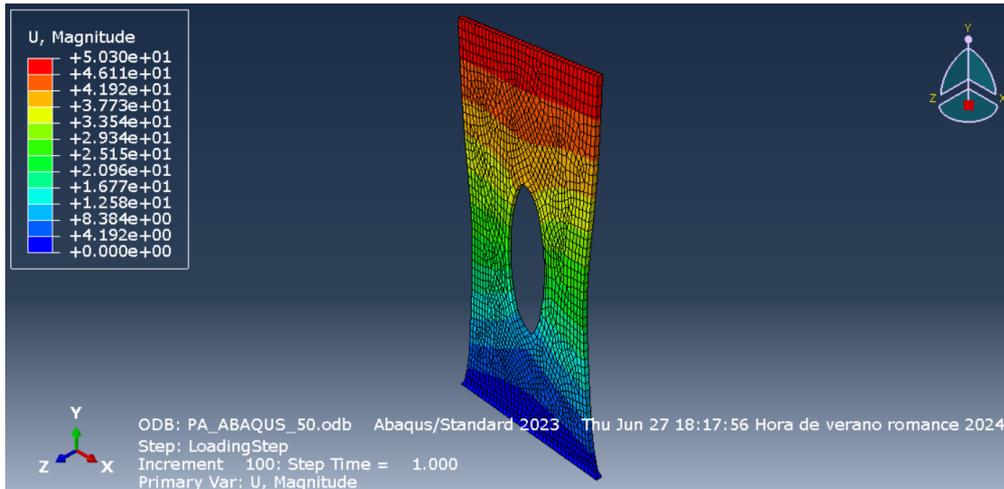


Figura 4.6 Desplazamientos obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS.

En la figura 4.6, se pueden verificar que las condiciones de contorno son las comentadas anteriormente, pues en el extremo en el que se restringieron los desplazamientos, estos son nulos mientras que en el otro extremo estos son máximos (como pasa en la simulación del ensayo de tracción) y prácticamente de 50 mm que es la condición de carga que se impuso en dicho extremo. Además, también destacar que dado que la carga se impone en el eje Y , la mayor contribución a los desplazamientos viene dada por la componente u_y , aunq en dicha figura estos se representen como magnitud.

Con respecto a las deformaciones, obtenemos lo que cabría esperar de acuerdo a los estados tensionales que se muestran en las figuras 4.9 y 4.10, las mayores deformaciones en la dirección X se dan a 0° y 180° en las proximidades del orificio y son negativas debido al efecto Poisson, mientras que las mayores deformaciones en Y se dan también a 0° y 180° que es donde mayores tensiones σ_y de tracción se concentran.

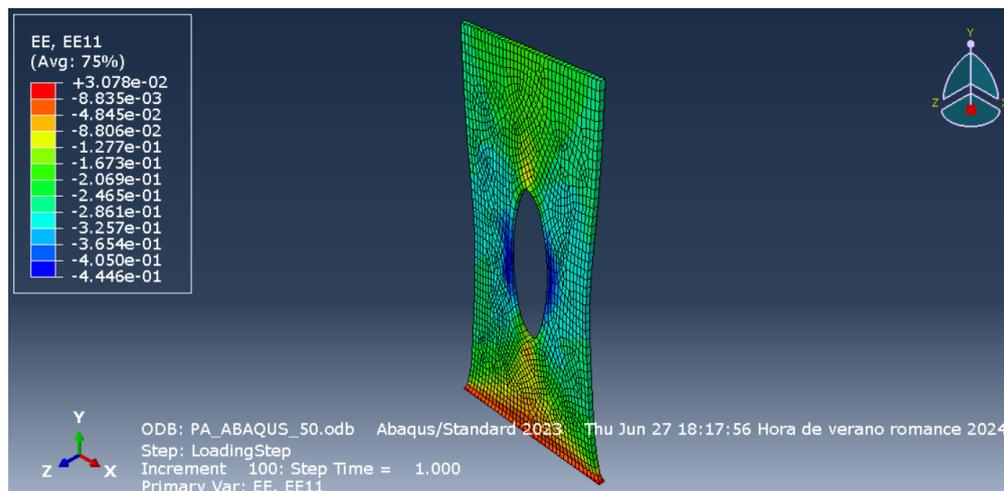


Figura 4.7 Deformaciones ϵ_x obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS.

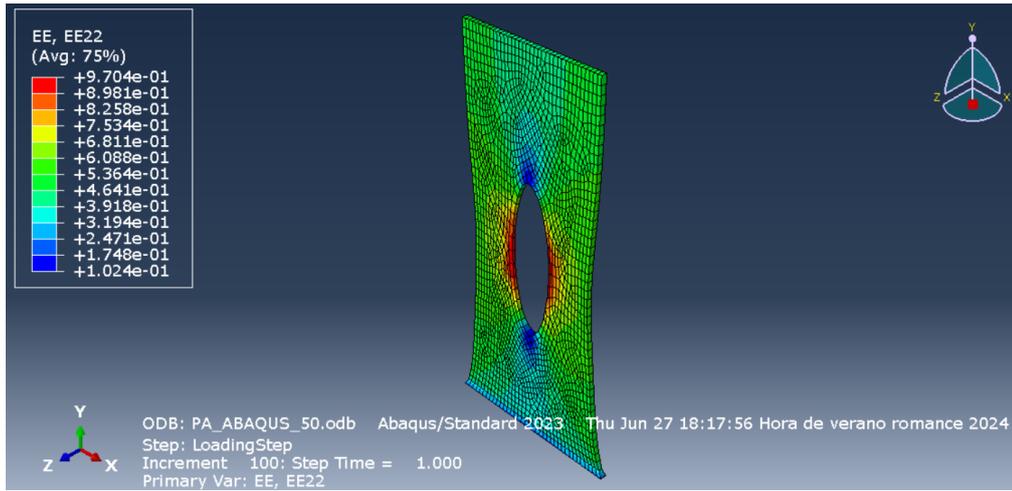


Figura 4.8 Deformaciones ϵ_y obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS.

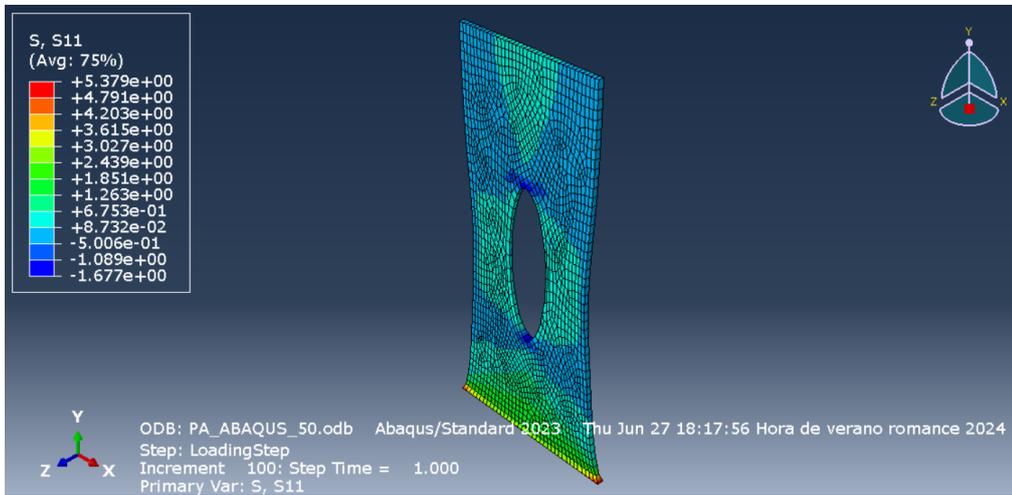


Figura 4.9 Tensiones σ_x obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS.

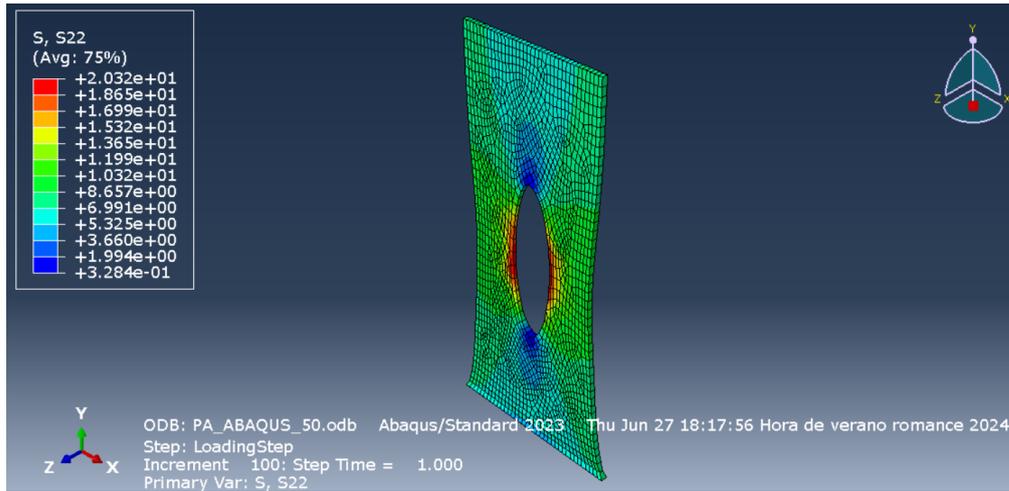


Figura 4.10 Tensiones σ_y obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS.

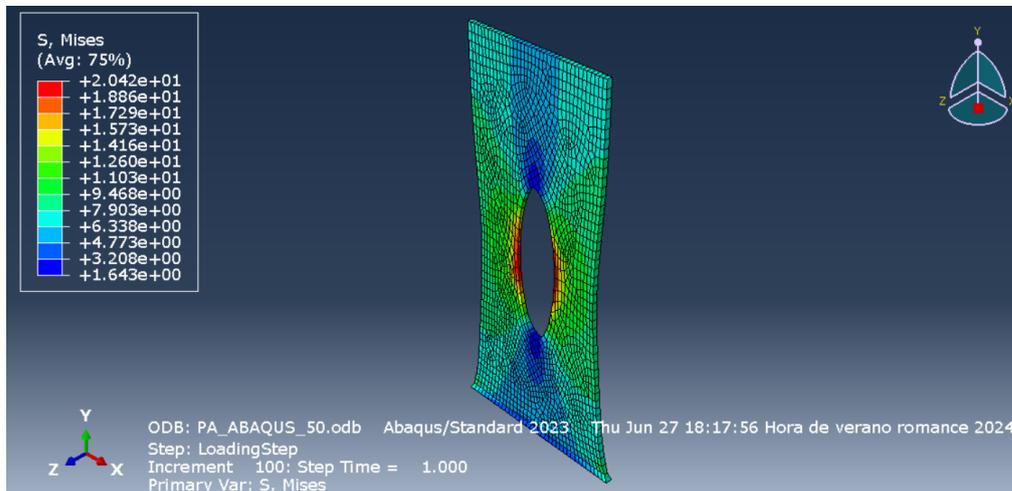


Figura 4.11 Tensiones de Von Mises obtenidas al resolver el problema de la placa con el orificio central mediante MEF de ABAQUS.

Como puede verse en las figuras 4.9 y 4.10 las tensiones se concentran en las proximidades del orificio, siendo máximas a tracción en la dirección Y en los bordes del orificio situados a 0° y 180° tal y como se mostró en un principio en la figura 4.1, mientras que en la dirección X encontramos tensiones de compresión sobre todo en los bordes situados a 90° y 270° , ya que el orificio actúa como una grieta y en esos extremos, donde se encuentra la punta de la grieta y hay mayores tensiones, la placa intenta evitar que la grieta siga creciendo mediante la separación de material es por ello que ahí las tensiones en la dirección X son de compresión, para intentar evitar esa separación. Por tanto coexisten dos estados tensionales como se mencionó con anterioridad.

4.2 Resolución mediante subrutina UANISOHYPER_INV

Con respecto a los resultados (figuras 4.12-4.17) obtenidos mediante este método de resolución, cualitativamente hay poco que destacar, son prácticamente idénticos a los obtenidos mediante el MEF de ABAQUS. No obstante sí que se puede observar que los resultados obtenidos en todas las magnitudes, tanto en desplazamiento como en deformaciones y tensiones son ligeramente superiores a los que se obtuvieron en el caso anterior, siendo estos un poco menos precisos.

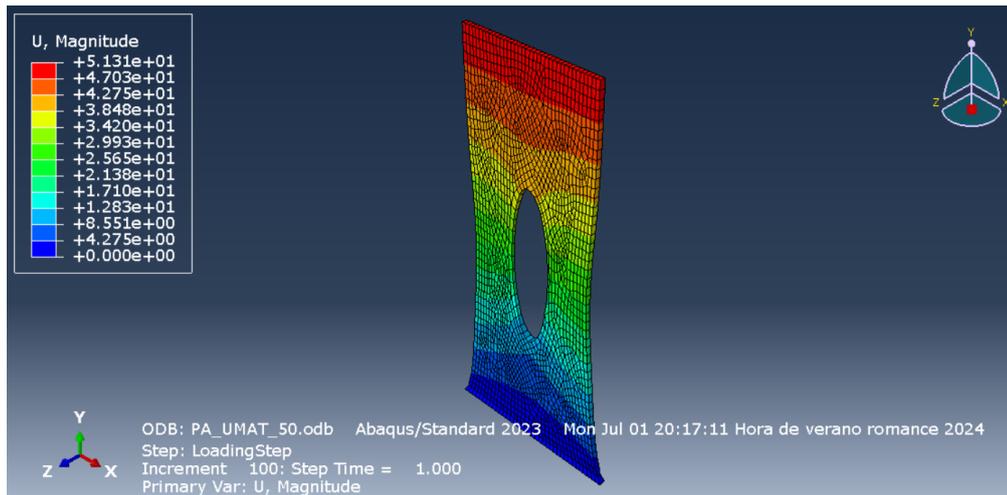


Figura 4.12 Desplazamientos obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV.

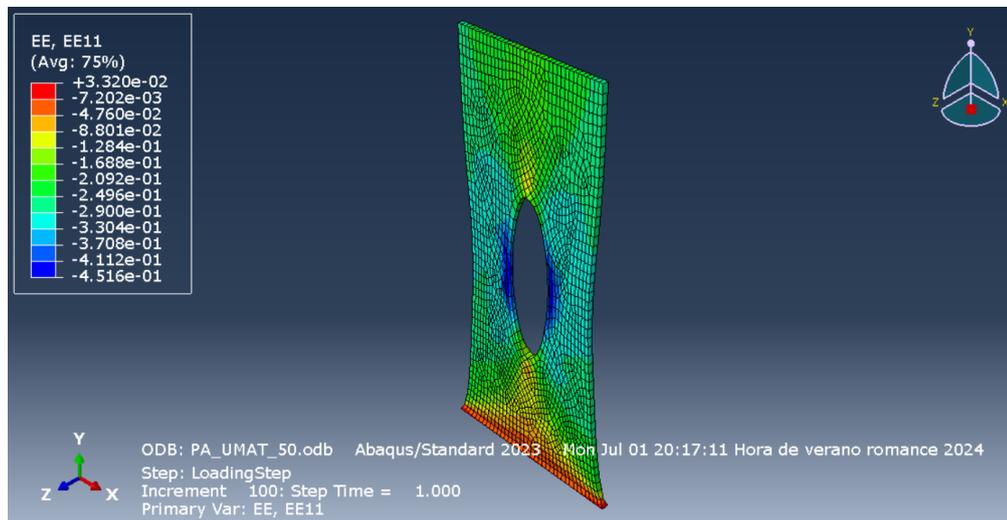


Figura 4.13 Deformaciones ϵ_x obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV.

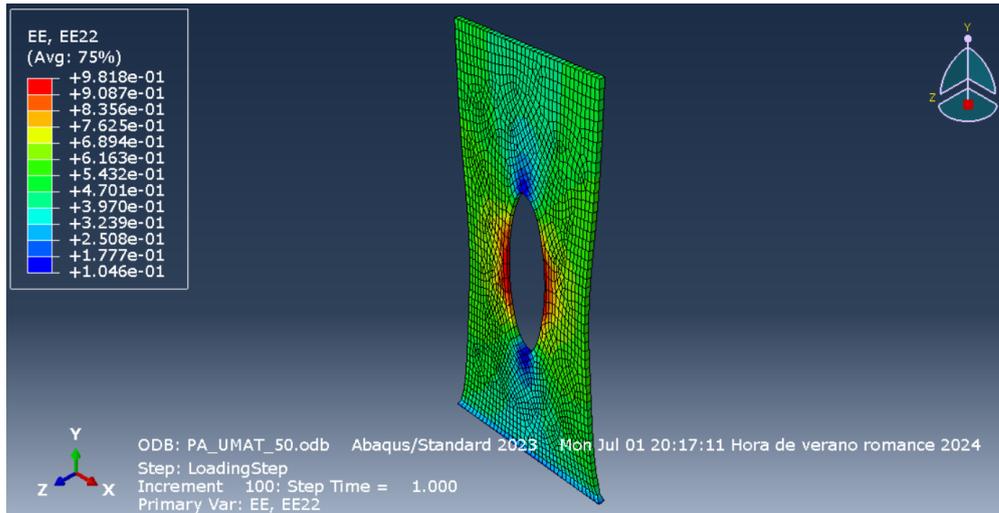


Figura 4.14 Deformaciones ϵ_y obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV.

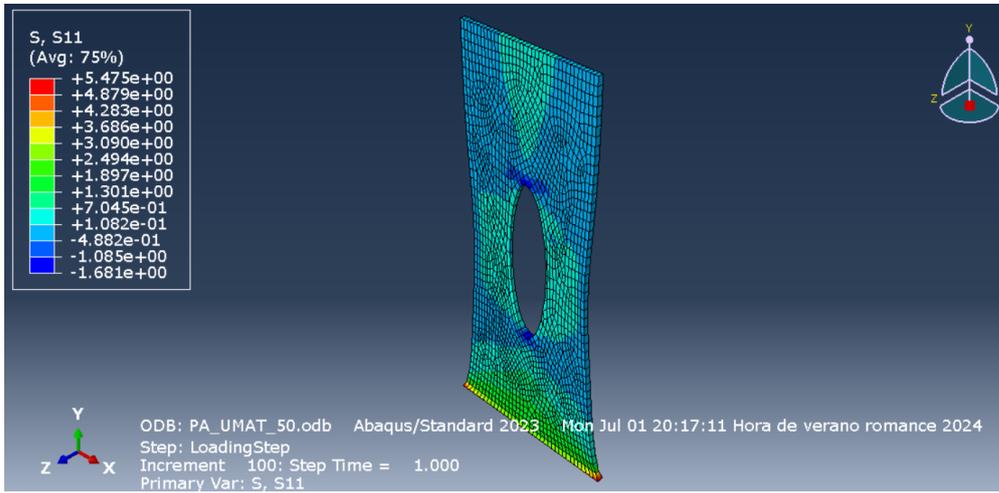


Figura 4.15 Tensiones σ_x obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV.

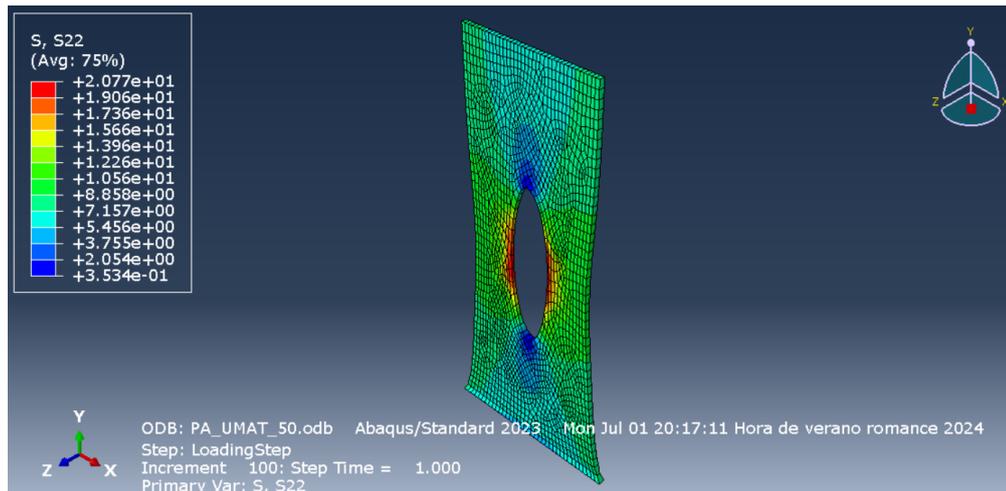


Figura 4.16 Tensiones σ_y obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV.

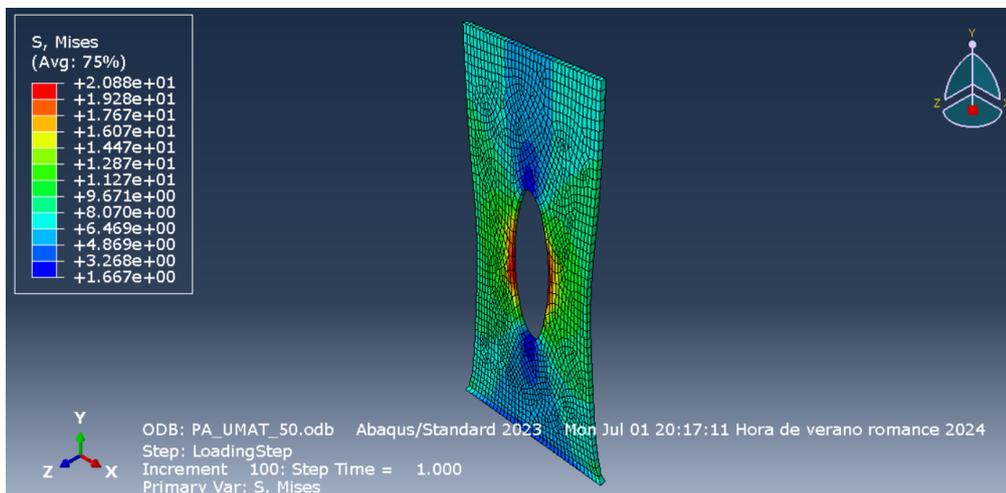


Figura 4.17 Tensiones de Von Mises obtenidas al resolver el problema de la placa con el orificio central mediante la UANISOHYPER_INV.

4.3 Comparación entre ambos análisis

El objetivo de este apartado es el de comparar los resultados mostrados en los dos apartados anteriores para ver a través de números cual es la diferencia entre ambos.

Inicialmente, se muestra en las figuras 4.18 y 4.19 una comparativa de las evoluciones de las tensiones y de las deformaciones de un nodo de la malla con respecto al tiempo de simulación.

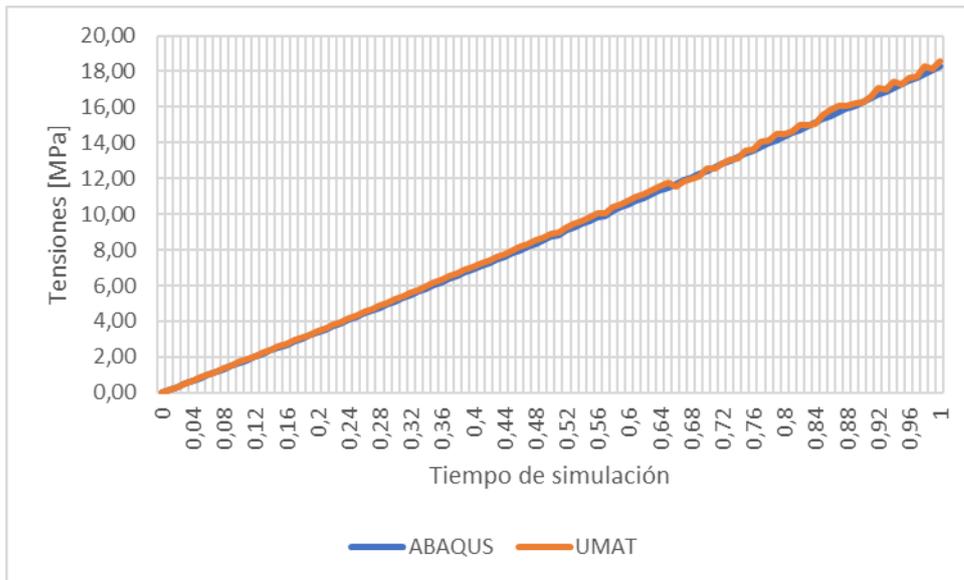


Figura 4.18 Comparativa de los resultado en términos de tensiones obtenidos tanto con el MEF de ABAQUS como con la UANISOHYPER_INV en función del tiempo de simulación.

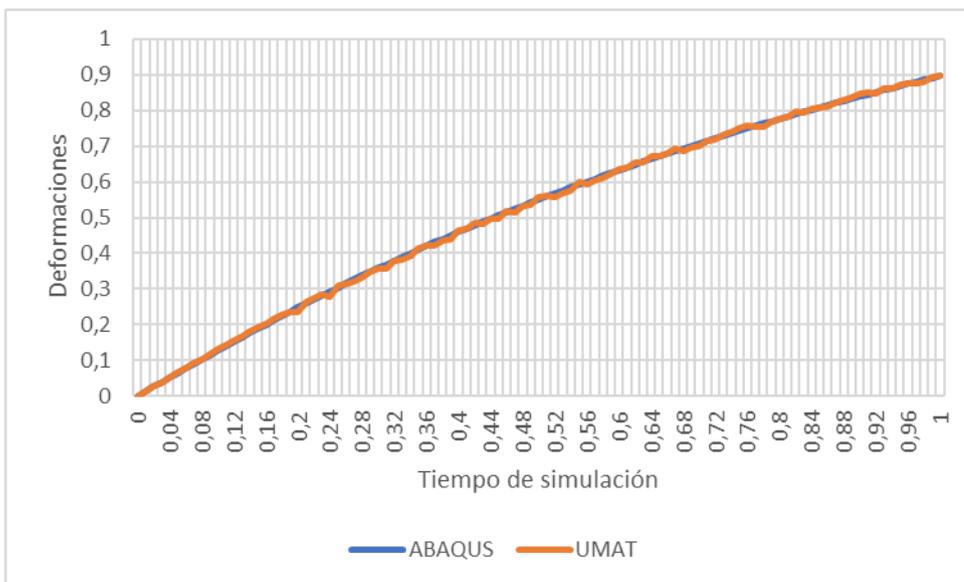


Figura 4.19 Comparativa de los resultado en términos de deformaciones obtenidos tanto con el MEF de ABAQUS como con la UANISOHYPER_INV en función del tiempo de simulación.

Como puede verse en las figuras 4.18 y 4.19, el modelo obtenido mediante la UANISOHYPER_INV se ajusta bastante bien al MEF de ABAQUS tanto en términos de tensiones como en términos de deformaciones, lo que nos da una evidencia más de que el modelo da resultados precisos y puede ser usado para estimar el comportamiento de materiales hiperelásticos.

Para realizar todo esto, nos centraremos en dos nodos, uno situado en el borde del orificio que se encuentra a 0° , mientras que el otro se sitúa a 90° también en el propio borde, de esta manera se comparan los resultados para dos nodos que se encuentran, uno en la zona a tracción en la dirección Y y otro a compresión en la dirección X . Concretamente, estos nodos son los marcados en rojo en la figura 4.20.

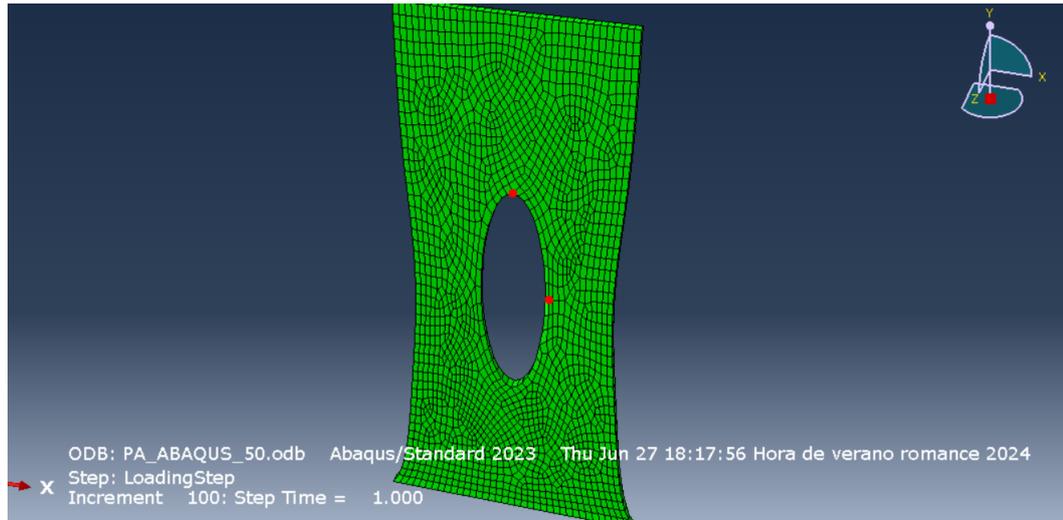


Figura 4.20 Nodos seleccionadas para realizar la comparativa entre los dos métodos.

En primer lugar, mostramos la comparativa de los resultados del nodo que está situado a 0° del orificio en la tabla 4.1.

Tabla 4.1 Resultados obtenidos con ambos métodos para el nodo situado a 0° en el borde del orificio.

Método	σ_y , [MPa]	ϵ_y	u_y , [mm]
MEF ABAQUS	18,9976	0,9280	24,2725
UANISOHYPER_INV	19,3767	0,9384	24,7568

Por otro lado, en la tabla 4.2 se muestra dicha comparativa pero para el nodo situado a 90° del orificio

Tabla 4.2 Resultados obtenidos con ambos métodos para el nodo situado a 90° en el borde del orificio.

Método	σ_x , [MPa]	ϵ_x	u_x , [mm]
MEF ABAQUS	-2,4891	-0,1822	-0.0168
UANISOHYPER_INV	-2,3019	-0,1839	-0.0178

Estos resultados, verifican y cuantifican lo que se ha mostrado en las figuras 4.7-4.10 y en las figuras 4.13-4.16. Los bordes situados a 0° y 180° del orificio están sometidos a tracción en el eje Y actuando dichos borde como concentradores de tensión, ya que las cargas tienen que distribuirse para salvar el orificio puesto que por ahí no se pueden transmitir ya que no hay material, mientras que en el eje X son sometidos a compresión debido a que las partículas del material intentan evitar el estrechamiento del orificio en dicha dirección.

Tabla 4.3 Desviaciones de la resolución mediante el modelo de la UANISOHYPER_INV con respecto al MEF de ABAQUS para el nodo situado a 0° en el borde del orificio.

σ_y	ϵ_y	u_y
2 %	1,12 %	1,99 %

Tabla 4.4 Desviaciones de la resolución mediante el modelo de la UANISOHYPER_INV con respecto al MEF de ABAQUS para el nodo situado a 90° en el borde del orificio.

σ_x	ϵ_x	u_x
7,52 %	0,93 %	5,95 %

Como puede verse en las tablas 4.3 y 4.4, las desviaciones, salvo para las deformaciones, son mayores en el caso en el que se tiene compresión, algo que podíamos presagiar ya que como se vio en la sección 3.2.3 las mayores desviaciones del modelo con los datos experimentales se producían en el caso de la compresión, que era el caso para el que el coeficiente de determinación era menor cuando se entrenaba a la red con datos de carga axial y con datos de cortadura.

5 Conclusiones

En el presente proyecto, se ha propuesto una metodología de entrenamiento de red neuronal, utilizando medidas experimentales como base para el entrenamiento. Dichas medidas experimentales, se han obtenido mediante la simulación de los ensayos en ABAQUS, sustituyéndose así los ensayos en laboratorio. Gracias a esto, se ha obtenido un modelo para la caracterización de materiales hiperelásticos. El enfoque propuesto ha demostrado ser eficaz en capturar las complejas características no lineales y de alta deformabilidad de los materiales hiperelásticos, superando las limitaciones de los modelos tradicionales basados en ecuaciones constitutivas.

Primeramente, ha sido necesario ahondar en la naturaleza de los materiales hiperelásticos, las características que estos poseen y los distintos modelos existentes que definen su comportamiento. También, se ha realizado un estudio sobre las redes neuronales, cuales son las bases de su funcionamiento y las diferentes morfologías y peculiaridades que podemos encontrar en las mismas.

Por otro lado, ha sido necesario el entrenamiento de la red neuronal, de forma que el modelo generado por la misma sea capaz de adaptarse al comportamiento de los materiales hiperelásticos. Para ello, ha sido necesario desarrollar una campaña de ensayos en los que se somete a una probeta de este tipo de material a distintos casos de carga con el objetivo de obtener datos con los que alimentar la red neuronal para su entrenamiento, parte esencial que ha ocupado la mayor parte del proyecto.

Tras esto, realizar una comparativa entre el modelo obtenido y otro método de resolución, en concreto el MEF de ABAQUS, ha sido necesaria para proveer de evidencias de que el modelo generado representa de manera adecuada el comportamiento de los materiales hiperelásticos y que estos son completamente precisos y representativos para caracterizar el comportamiento del tipo de material que nos ocupa.

Es por ello, que los resultados obtenidos muestran que las redes neuronales pueden proporcionar una precisión significativa en la predicción del comportamiento mecánico de estos materiales bajo diversas condiciones de carga. Además, el uso de medidas experimentales ha permitido una validación robusta del modelo, asegurando su aplicabilidad en escenarios reales. Tras esto, se puede concluir que el objetivo que inicialmente se marcó para este proyecto se ha alcanzado de manera satisfactoria en base a los datos y gráficas mostradas a lo largo del presente escrito.

La principal contribución de este estudio reside en la integración de técnicas de inteligencia artificial con métodos experimentales, lo que abre nuevas posibilidades en la modelización y diseño de materiales avanzados. Este enfoque no solo mejora la precisión de las predicciones, sino que también reduce el tiempo y los recursos necesarios para el desarrollo de nuevos materiales.

En resumen, este trabajo ha demostrado el potencial de las redes neuronales como herramientas poderosas y versátiles para la modelización de materiales hiperelásticos, sentando las bases para futuras innovaciones en el campo de la ingeniería de materiales.

5.1 Líneas de trabajo futuro

En cuanto a posibles trabajos futuros o ampliaciones del presente proyecto, con el objetivo de mejorarlo o trabajar en vertientes del mismo, algunas de estas líneas de trabajo pueden ser:

- Mejora de los resultados obtenidos para hacer del modelo uno más preciso y que se ajuste mejor a los datos experimentales.
- Lanzar una campaña de ensayos en laboratorio para obtener los datos con los que entrenar a la red, de manera que los resultados que se obtengan sean más precisos y realistas al eliminar el ruido que un software de elementos finitos introduce en el análisis.
- Aumentar el número de datos que se le han suministrado a la red para tratar de obtener un modelo mucho más preciso. Otra opción, podría ser también ensayar distintos casos en los que se tenga situaciones de carga combinada que doten a la red de nuevos datos para que esta cubra muchas más situaciones posibles.
- Realizar la comparativa mostrada en el capítulo 4, para otro caso de estudio.
- Extender este campo de estudio a otros tipos de materiales como podrían ser los materiales compuestos, para lo cual habría que modificar ciertos parámetros y ecuaciones de la subrutina y de la propia red neuronal.

Bibliografía

- [1] Linka, K., & Kuhl, E., "A new family of Constitutive Artificial Neural Networks towards automated model discovery", *Computer Methods in Applied Mechanics and Engineering*, vol. 403(Parte A), 2023.
- [2] S. Budday a, G. Sommer b, C. Birkl c et al., "Mechanical characterization of human brain tissue", *Acta Biomaterialia*, vol. 48, pp. 319-340, 2017.
- [3] Majid Shahzada, Ali Kamranb, Muhammad Zeeshan Siddiquia, Muhammad Farhana, "Mechanical Characterization and FE Modelling of a Hyperelastic Material", *Materials Research*, vol. 18(5), pp. 918-924, 2015. <http://dx.doi.org/10.1590/1516-1439.320414>
- [4] Mathias Peirlinck, Kevin Linka, Juan A. Hurtado, Ellen Kuhl, "On automated model discovery and a universal material subroutine", *bioRxiv*, 2023.
- [5] Dot CSV An R-squared measure of goodness of fit for some common nonlinear regression models, *Journal of Econometrics*, vol. 77(2), pp.1790-1792, 1997.
- [6] Wilmer Rivas-Asanza, Fernando Mejia, Bertha Mazon-Olivo *Capítulo 1: Generalidades de las redes neuronales artificiales* Redes Neuronales Artificiales aplicadas al reconocimiento de patrones, pp.12-31, 2018. <https://www.researchgate.net/publication/327703478> Rubber, vulcanized or thermoplastic—Determination of shear modulus and adhesion to rigid plates—Quadruple-shear methods.
- [7] Dot CSV ¿Qué es una red neuronal? [Video recording], 2018. <https://www.youtube.com/watch?v=MRIv2IwFTPg>
- [8] Professor William N. Sharpe, Jr. Department of Mechanical Engineering of The Johns Hopkins University, *Handbook of Experimental Solid Mechanics*, Springer, 2008.
- [9] Kushvaha, V., Sanjay, M. R., Madhushri, P., & Siengchin, S., *Machine Learning applied to Composite Materials*, Springer, 2022.
- [10] Professor William N. Sharpe, Jr. Department of Mechanical Engineering of The Johns Hopkins University, *Handbook of Experimental Solid Mechanics*, Springer, 2008. <https://doi.org/10.1007/978-981-19-6278-3>
- [11] Mavrodontins, N., *Modelling Hyperelastic Behavior Using Test Data in Abaqus*, 2017. <https://simulation-blog.technia.com/simulation/modelling-hyperelastic-behavior-using-test-data-in-abaqus>
- [12] Montilla Barrios, S. K., *Guía práctica de Uso: ABAQUS CAE*. Edunila. 2022
- [13] Zhang, Z., & Friedrich, K., *Artificial neural networks applied to polymer composites: A review*. *Composites Science and Technology*, vol. 63, pp. 2029-2044, 2003
- [14] Shahzad, M., Kamran, A., Zeeshan, M., & Farhan, M., *Artificial neural networks applied to polymer composites: A review*. *Composites Science and Technology*, vol. 63, pp. 2029-2044, 2003