



Trabajo Fin de Grado

Modelling the behaviour of pipe flange using
machine learning

Modelado del comportamiento de la brida
mediante aprendizaje automático

Autor/es

HALIZATUL SOFIA BINTI AHMAD HALIM

Director/es

JAVIER BLASCO ALBERTO
JOSÉ ANTONIO BEA CASCAROSA

Escuela de Ingeniería y Arquitectura Zaragoza
2020-2021



**DECLARACIÓN DE
AUTORÍA Y ORIGINALIDAD**

(Este documento debe entregarse en la Secretaría de la EINA, dentro del plazo de depósito del TFG/TFM para su evaluación).

D./Dª. Halizatul Sofia Binti Ahmad Halim ,en
aplicación de lo dispuesto en el art. 14 (Derechos de autor) del Acuerdo de 11 de
septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el
Reglamento de los TFG y TFM de la Universidad de Zaragoza,
Declaro que el presente Trabajo de Fin de (Grado/Máster)
Grado de Ingeniería Mecánica (Título del Trabajo)
Modelado del comportamiento de la brida mediante aprendizaje automático

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

Zaragoza, 17 de Junio de 2021

Fdo: HALIZATUL SOFIA BINTI AHMAD HALIM





AGRADECIMIENTO

Este trabajo fin de grado, lo dedique especialmente;

A mi familia, que siempre cree en mí y me anima desde el primer día de la carrera hasta hoy.

A Javier Blasco y José Antonio, que siempre me guió y me motivó a dar lo mejor de mí para este trabajo. Me proporcionaron un sinfín de motivaciones y apoyos para asegurarme de llevar a cabo este proyecto con éxito.

Un millón de gracias por todo.



ÍNDICE GENERAL

AGRADECIMIENTO.....	i
ÍNDICE GENERAL.....	ii
ÍNDICE DE FIGURAS.....	iii
ÍNDICE DE TABLAS.....	iii
RESUMEN.....	1
OBJETIVOS.....	2
1. INTRODUCCION.....	3
1.1 Introducción general.....	3
1.2 ¿Que es el aprendizaje automático?.....	4
2. ANALISIS DE ELEMENTOS FINITOS.....	6
2.1 Descripción de la brida.....	7
2.2 Propiedades de los materiales.....	8
2.3 Contactos y mallados.....	9
2.4 Carga y condiciones de contorno.....	12
3. EL APRENDIZAJE AUTOMATICO.....	14
4. RESULTADOS Y DISCUSIONES.....	19
4.1 Análisis elementos finitos.....	19
4.2 Aprendizaje automáticos.....	23
5. CONCLUSIONES.....	25
6. REFERENCIAS.....	26
7. ANEXOS.....	27
ANEXO A : Propiedades de los materiales.....	27
ANEXO B: Gráfico de dispersión de los resultados previstos.....	33
❖ Gráficos de la presión normal de la brida (diámetro exterior).....	33
❖ Gráficos de la presión normal de la brida (centro).....	36
❖ Gráficos de la presión normal de la brida (interno).....	39
❖ Gráficos de las tensiones equivalentes Von Mises (la junta).....	42
❖ Gráficos de las tensiones equivalentes Von Mises (el tornillo).....	45
❖ Gráficos de las tensiones equivalentes Von Mises (la tubería).....	48
❖ Gráficos de las tensiones equivalentes Von Mises (la brida).....	51
ANEXO C: Test and score Orange.....	54



ÍNDICE DE FIGURAS

<i>Figura 1 : Esquema evolución de la junta de la brida (Adaptando desde Hector Estrada [4]).....</i>	4
<i>Figura 2 : El procedimiento general en aprendizaje automático (Adaptando desde Yang. H [10]).....</i>	5
<i>Figura 3 : El esquema del proyecto en ANSYS Workbench.....</i>	6
<i>Figura 4 : La geometría de la brida [11].....</i>	7
<i>Figura 5 : El modelo de la brida en ANSYS SpaceClaim.....</i>	7
<i>Figura 6 : El gráfico de tensión-deformación de un material.....</i>	8
<i>Figura 7 : El mallado de la brida Clase 150 NPS 0.5 en ANSYS Mechanical.....</i>	9
<i>Figura 8 : Los contactos entre la tubería-brida y el tornillo-brida.....</i>	10
<i>Figura 9 : El deslizamiento libre en superficie de la junta.....</i>	11
<i>Figura 10 : La carga del tornillo en Caso A.....</i>	12
<i>Figura 11 : Cargas operativas en el Caso C.....</i>	13
<i>Figura 12 : Flujo de trabajo de aprendizaje automático en Orange.....</i>	14
<i>Figura 13 : Regresión Lineal en Orange.....</i>	15
<i>Figura 14 : Configuración de kNN en Orange.....</i>	16
<i>Figura 15 : Configuración de Red Neuronal en Orange.....</i>	16
<i>Figura 16 : Gradient Boosting en Orange.....</i>	17
<i>Figura 17 : AdaBoost en Orange.....</i>	17
<i>Figura 18 : Configuración Random Forest en Orange.....</i>	18
<i>Figura 19 : Distribución de la tensión normal en la junta de Class 150 NPS 0.5..</i>	19
<i>Figura 20 : El gráfico de la distribución de tensión normal a lo largo de la junta (Class 150 NPS 0.5).....</i>	20
<i>Figura 21 : Distribución de tensión Von Mises en la junta y la tubería de Class 150 NPS 0.5.....</i>	21
<i>Figura 22 : Distribución de tensión normal Von Mises de la brida de Class 150 NPS 0.5.....</i>	21
<i>Figura 23 : Distribución de tensión Von Mises en la brida de Class 150 NPS 1.0.22</i>	
<i>Figura 24 : La gráfica de dispersión de Red Neuronal para la tensión normal (diámetro externo).....</i>	24
<i>Figura 25 : La gráfica de dispersión de AdaBoost para la tensión Von Mises de la junta.....</i>	24

ÍNDICE DE TABLAS

<i>Tabla 1 : El detalle del mallado de la brida Clase 150 NPS 0.5.....</i>	9
<i>Tabla 2 : Resultados de R²en el widget prueba y puntuación.....</i>	23



RESUMEN

En este mundo de la tecnología que avanza tan rápidamente, ¿cómo contribuyen la inteligencia artificial y el aprendizaje automático al campo de la ingeniería? Este resumen tiene como objetivo dibujar el posible futuro del aprendizaje automático en el campo de la ingeniería; centrándose en el comportamiento de la brida de la tubería.

A lo largo de muchos años, se han realizado muchas investigaciones para investigar el problema de las fugas en la brida de la tubería. En este trabajo fin de grado (TFG) se explicará cómo se estudian la distribución de la presión normal de la junta mediante el análisis de elementos finitos. También se estudia la tensión equivalente (Von Mises) de cada componente de la brida. Los resultados se presentan y se analizan para estudiar cómo el aprendizaje automático puede ser útil para predecir sin problemas el comportamiento de la brida de la tubería.

Este trabajo fin de grado confirma que el aprendizaje automático se puede utilizar para sustituir el análisis repetitivo de elementos finitos y ademas tiene un futuro brillante en la transformación y creación de nuevos enfoques en el futuro mundo de la ingeniería.



OBJETIVOS

Los objetivos de este estudio son estudiar el comportamiento de la junta de brida en diversas condiciones de contorno y predecir su comportamiento a través del aprendizaje automático sin tener que pasar varias veces por simulaciones repetitivas mediante elementos finitos.

Este informe está organizado en 4 secciones: la Sección 1 dará un vistazo a la introducción de este documento; la Sección 2 nos dará detalles sobre el análisis de elementos finitos que se realiza usando ANSYS Student 2020 R2; la Sección 3 nos explicará la parte del aprendizaje automático, con la ayuda del software Orange; la Sección 4 explicará los resultados y discusiones de las simulaciones y, por último, la Sección 5 dará un breve resumen sobre la conclusión de este proyecto de investigación.

Al final de la investigación, esperamos encontrar las respuestas a estas preguntas:

- ¿Cómo se comporta la brida al aumentar la presión interna y la temperatura de trabajo?
- ¿Cuál es el límite de trabajo para que la brida de la tubería comience a tener fugas?
- ¿Podrá el aprendizaje automático ayudar y mejorar la investigación para predecir el comportamiento de la brida?
- ¿Tiene futuro el aprendizaje automático en el campo de la ingeniería?



1. INTRODUCCION

1.1 Introducción general

Viviendo en el siglo XXI, el mundo avanza a gran velocidad, especialmente en el campo de la innovación y la tecnología. La inteligencia artificial (IA) y el aprendizaje automático son dos palabras comunes hoy en día, ya que ambas se están expandiendo rápidamente y contribuyen espléndidamente a muchos aspectos de nuestra vida diaria. Pero la verdadera pregunta es; ¿Podemos realmente enseñar a una máquina a pensar como un ingeniero?

Antes de nada, hay que tener en cuenta que la brida de tubería juega un papel importante en el mundo del sistema de tuberías que normalmente consta de dosbridas acopladas, los tornillos y una junta que la hacen más ventajosa que otros tipos de accesorios de tubería porque se puede desmontar fácilmente durante el trabajo de mantenimiento. Se utiliza principalmente para sellar la conexión y evitar fugas.

El presente trabajo es una extensión del TFG de Burrull Allan, Xavier [1] en el que presentó la comparación del análisis de la brida basado en dos códigos estándar de cálculo diferentes; ASME PCC-1 y EN 1591-1. Su artículo concluyó que el código EN 1591-1 tiene un porcentaje más bajo de error relativo (~28% para el ángulo de rotación y ~30% en la carga de presión) que el ASME PCC-1 [3]. En este trabajo, nos centraremos en el comportamiento de los diseños de brida especificados por ASME B16.5 2009 [2]. ASME B16.5 es un estándar de fabricación que cubre lasbridas y las conexiones de tubería con clasificaciones de presión-temperatura hasta Clase 2500 en tamaños NPS 1/2 a NPS 24.

El comportamiento de la brida de la tubería es complejo y difícil de predecir debido a diversas condiciones de contorno, especialmente durante el estado de trabajo. Hector Estrada [4] declaró en su artículo que dos problemas críticos comunes en una junta de brida de tubería son las fugas y la resistencia de la junta. El problema de las fugas está muy relacionada con la carga del tornillo, la presión interna, la temperatura y los materiales utilizados para la brida y la junta. Se han realizado muchas investigaciones [5-7] para estudiar este problema, pero aún no se ha encontrado la solución exacta y óptima.

Por otro lado, Jenco y Hunt [8] declararon que pueden ocurrir fugas durante el estado de trabajo cuando se aplica una pretensión inicial baja del tornillo, pero una pretensión inicial mayor del tornillo también dará un problema porque dañará la junta y la brida pivotará en ese punto exacto. La Figura 1 muestra la evolución de la junta de la brida de la tubería en tres incrementos de carga diferentes adaptados de Hector Estrada [4].

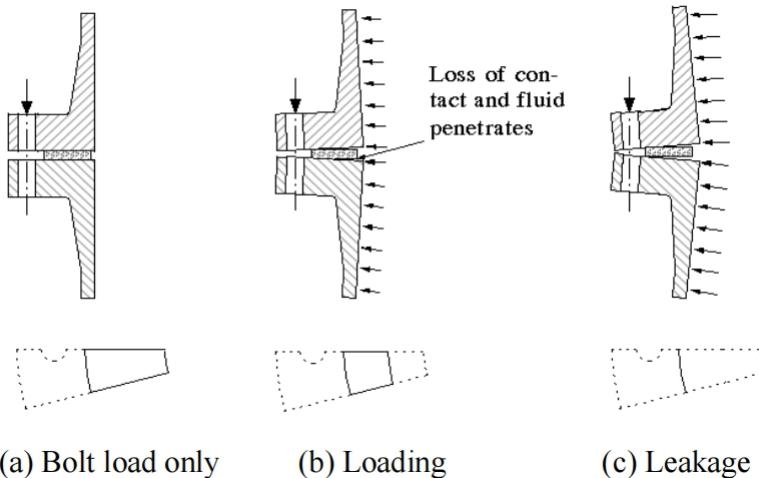


Figura 1: Esquema evolución de la junta de la brida (Adaptando desde Hector Estrada [4])

1.2 ¿Qué es el aprendizaje automático?

El aprendizaje automático se conoce como un subconjunto de la inteligencia artificial. Sus algoritmos ayudarán al programa a encontrar modelos en conjuntos de datos masivos y, por lo tanto, tomar una decisión acertada. El aprendizaje automático, en otras palabras, es darle a la computadora la capacidad de recordar lo que hizo, y luego permitirle adaptarse, evolucionar y aprender de los datos pasados. El único requisito para el aprendizaje automático es una alta calidad de datos que sea diversa y tenga suficiente información. Toda la idea de estas innovaciones es crear máquinas que puedan comportarse y pensar como la mente de un ser humano. La pregunta ahora es; ¿Son capaces de aprender y pensar?

Los tipos más comunes de aprendizaje automático son el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje reforzado. En el aprendizaje supervisado, los datos de entrenamiento etiquetados se alimentan para estudiar cómo funcionan los datos, pero cuando la máquina tiene que encontrar los patrones entre los datos no etiquetados por sí misma, lo llamamos aprendizaje no supervisado. Finalmente, el aprendizaje por refuerzo permite que la máquina se adapte rápidamente y crezca más allá de nuestra comprensión, ya que puede mejorar por sí misma. Es un algoritmo de composición abierta que se está entrenando para brindar la mejor solución posible para futuras predicciones.

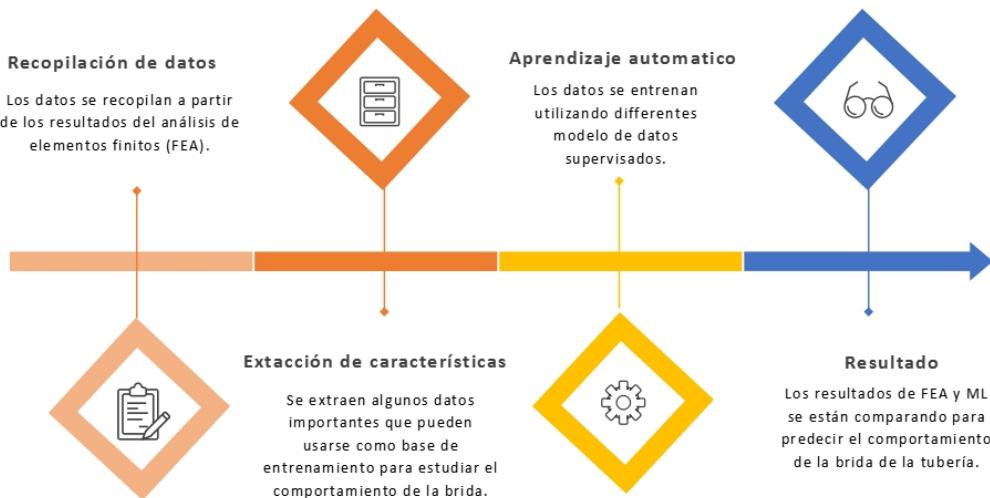


Figura 2: El procedimiento general en aprendizaje automático (Adaptando desde Yang. H [10])

El aprendizaje automático es conocido por su margen de mejora continua y porque no se necesita intervención humana para predecir el resultado en comparación con el análisis de elementos finitos (FEA). En este proyecto utilizaremos el concepto de aprendizaje supervisado para estudiar y predecir el comportamiento de lasbridas de las tuberías en determinadas condiciones de trabajo. Los datos etiquetados del análisis de elementos finitos en ANSYS se transfieren al aprendizaje automático y veremos cómo lo analiza y predice el comportamiento de la brida de la tubería. La Figura 2 se muestra el proceso común en aprendizaje automático desde la primera etapa.

2. ANALISIS DE ELEMENTOS FINITOS

Como se mencionó anteriormente, este estudio es una extensión del trabajo Burrull Allan, Xavier [1] en el que nos centraremos más en el comportamiento de la junta trabajando bajo diferentes limitaciones de presión. Adaptaremos su modelo al software ANSYS Student 2020 R2 [12] para examinar cómo cambia el comportamiento de la brida respecto del tiempo.

El objetivo de esta simulación ANSYS es la variación de la presión de contacto en la superficie de contacto entre la brida y la junta. Se espera la reducción de la presión de contacto en la superficie de la junta con el aumento de la presión interna. También estamos esperando la deformación o la fractura de los componentes cuando la presión interna aplicada es demasiado alta, ya que la resistencia de materiales afirma que la brida tiene capacidad de deformarse permanente cuando sometido a tensiones por encima de su esfuerzo ultimo o punto de rotura.

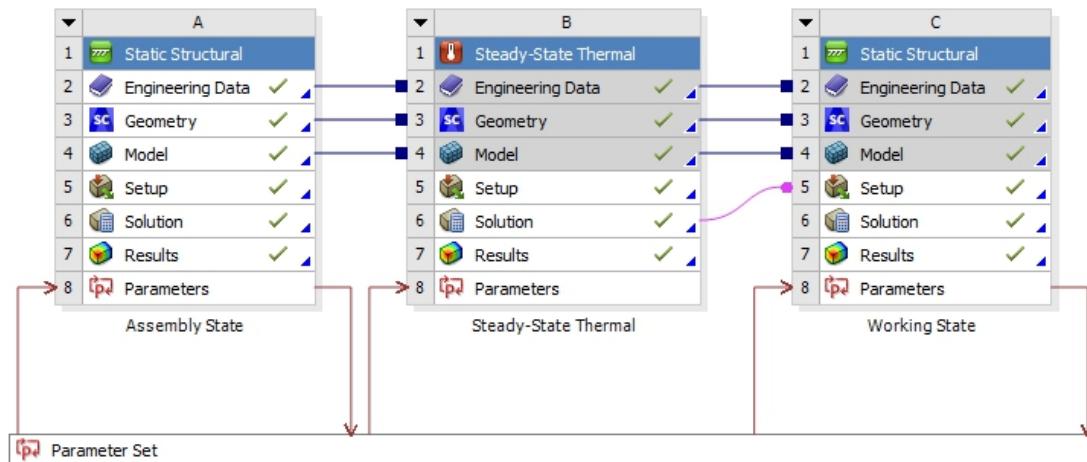


Figura 3 : El esquema del proyecto en ANSYS Workbench

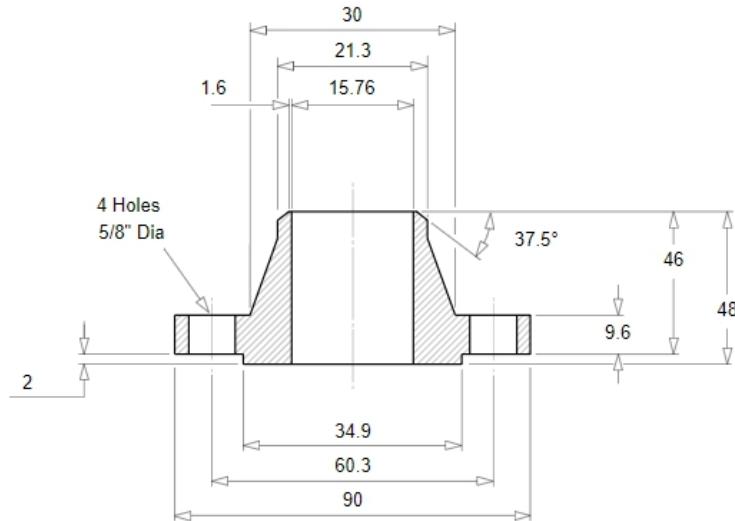
Según el esquema del proyecto, Figura 3, se identifica que este análisis de elementos finitos consta de tres fases diferentes del estudio.

- El primer caso es el estado de ensamblaje en el que la brida de la tubería se carga con la fuerza inicial del tornillo. Durante este paso, no se aplica ninguna otra carga.
- El segundo caso es cuando aplicamos la temperatura de funcionamiento a la junta de brida.
- El ultimo es el escenario operativo real en el que aplicamos la presión interna de diseño con la carga térmica y también el valor de pretensión del tornillo del primer caso.



2.1 Descripción de la brida.

Flange Weight: 0.50 kg
S/Bolts and Nuts: 0.46 kg



StudBolt Size: 1/2" UNC (or M14) x 55 Long

ASME B16.5 2019

Figura 4: La geometría de la brida [11]

La Figura 4 anterior muestra la geometría de la junta de brida de cuello de soldadura (“welding neck”) utilizada en este estudio, donde se extrajo de la página web “pipedata.com” [11]. Se confirma que la dimensión de la junta de brida cumple con la norma ASME B16.5 2019 [2]. Debido a las limitaciones de la licencia de software, solo se ha modelado una octava parte de toda la modelo. No obstante, creemos que esta geometría, Figura 5, puede dar información suficientemente relevante.

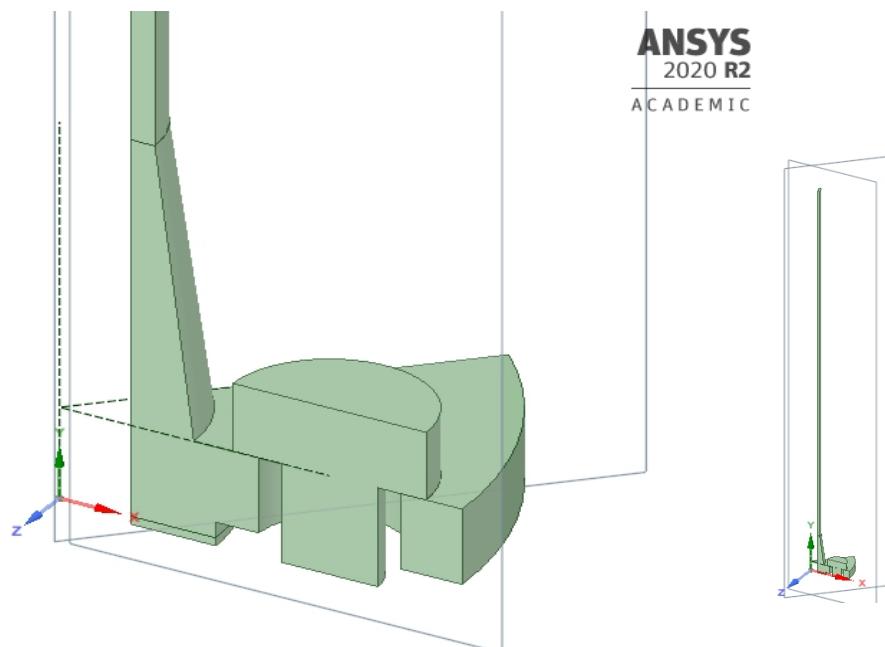


Figura 5: El modelo de la brida en ANSYS SpaceClaim

2.2 Propiedades de los materiales

En este estudio, consideramos las propiedades del endurecimiento isotrópico bilineal de los materiales. Estas propiedades nos permiten comprender cómo se comporta el material desde una vista microscópica. Respecto de la Figura 6, de tensión-deformación de un material específico, podemos observar su límite elástico, la resistencia a la tracción última y el punto de rotura.

Teóricamente, cuando el valor de la tensión es menor que su módulo de elasticidad, un material volverá a su estado original ya que todavía está "trabajando" en la región elástica. Mientras tanto, el límite de rendimiento se define como el punto donde el material se deformará permanentemente debido a sus deslocaciones atómicas y nunca volverá a su estado original. Este proceso de endurecimiento alcanzará el punto de máxima resistencia a la tracción y cualquier valor de tensión mayor que eso provocará una fractura del material.

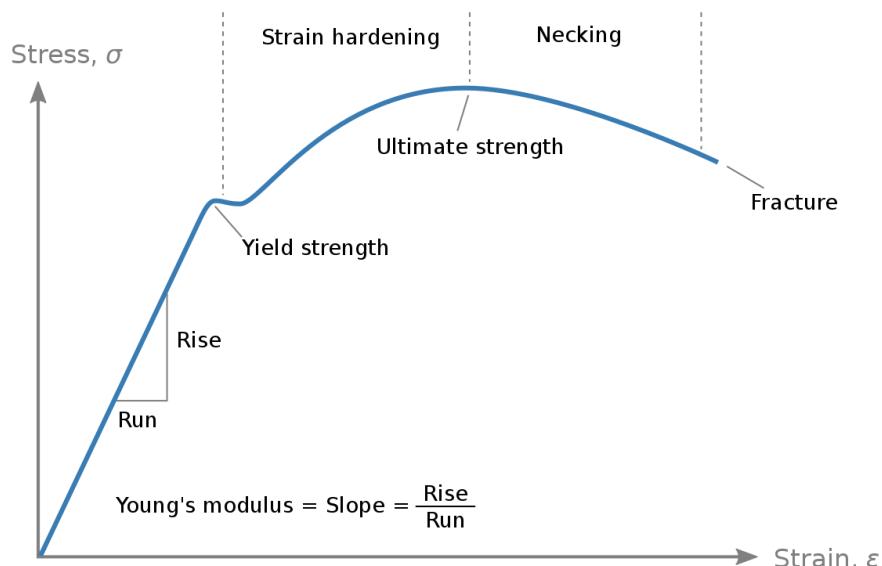


Figura 6 : El gráfico de tensión-deformación de un material

El material utilizado tanto para la brida como para la tubería es acero al carbono forjado (A105), mientras que para el tornillo se utiliza acero al cromo (A193-B7). La junta generalmente se modela utilizando un comportamiento no lineal en sus propiedades de carga y descarga pero debido a su complejidad y la limitación de la licencia de estudiante de ANSYS, consideraremos el material de la junta como acero inoxidable (321) con el modelo bilineal; Módulo de Young, $E = 193 \text{ GPa}$, coeficiente de Poisson, $\nu = 0,31$. En el [Anexo A](#) se ofrecen más detalles sobre las propiedades del material y su gráfico de tensión-deformación.

2.3 Contactos y mallados

En el análisis de elementos finitos, las interfaces de contacto entre los modelos y el mallado juegan un papel crucial porque estos afectarán los resultados y la dinámica de la simulación. Dado que este tipo de licencia tiene un límite de mallado con el número máximo de nodos es 32.000, se han aplicado diferentes tipos de mallado al modelo, Figura 7. Se ha aplicado una malla gruesa a la tubería considerando que es una pieza grande y tiene menos significativo en este estudio. Para el tornillo y la brida, se ha aplicado una malla intermedia con tetraedro mientras que se ha aplicado una malla fina de aproximadamente 1 mm de tamaño a la junta. Esta distribución de mallado se realiza para obtener resultados razonables bajo las limitaciones del software mencionado antes, ver Tabla 1.

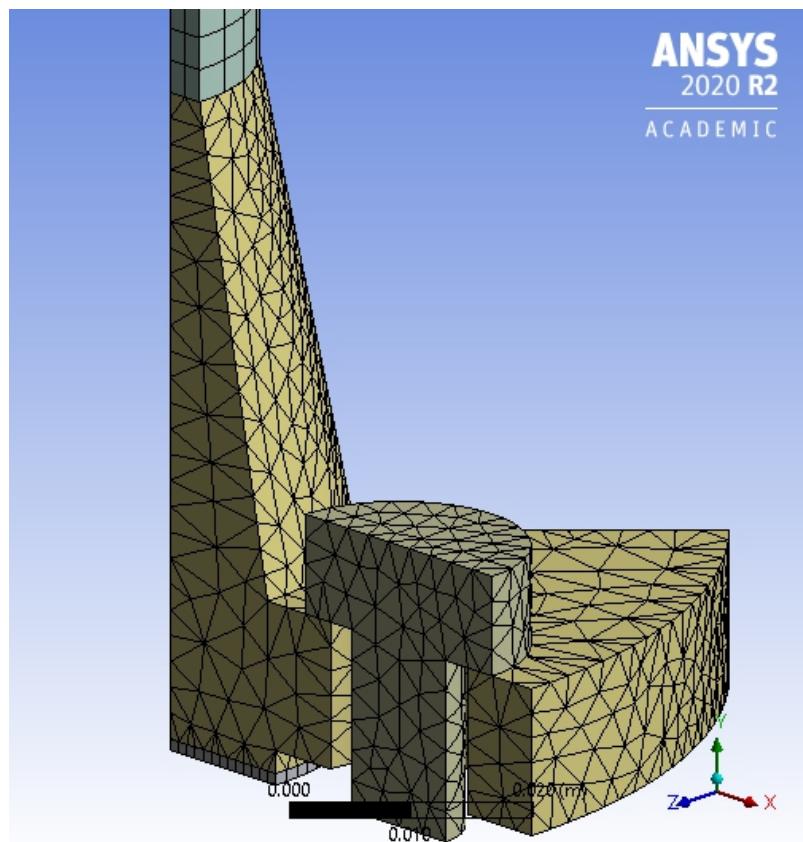


Figura 7: El mallado de la brida Clase 150 NPS 0.5 en ANSYS Mechanical

Componentes	Brida	Tornillo	Tubería	Junta
Nodos	4308	1812	3738	803
Elementos	495	1029	1920	100

Tabla 1: El detalle del mallado de la brida Clase 150 NPS 0.5

Examinaremos brevemente ahora los tipos de contactos, el área de contacto entre la conexión de la tubería y el cuerpo de la brida se considera como una entidad unidas que no permite deslizamiento o separación entre ellos, mientras que el área de contacto entre la cabeza del tornillo y el cuerpo de la brida se simula como un contacto brusco para evitar cualquier deslizamiento tangencial, ver la Figura 8.

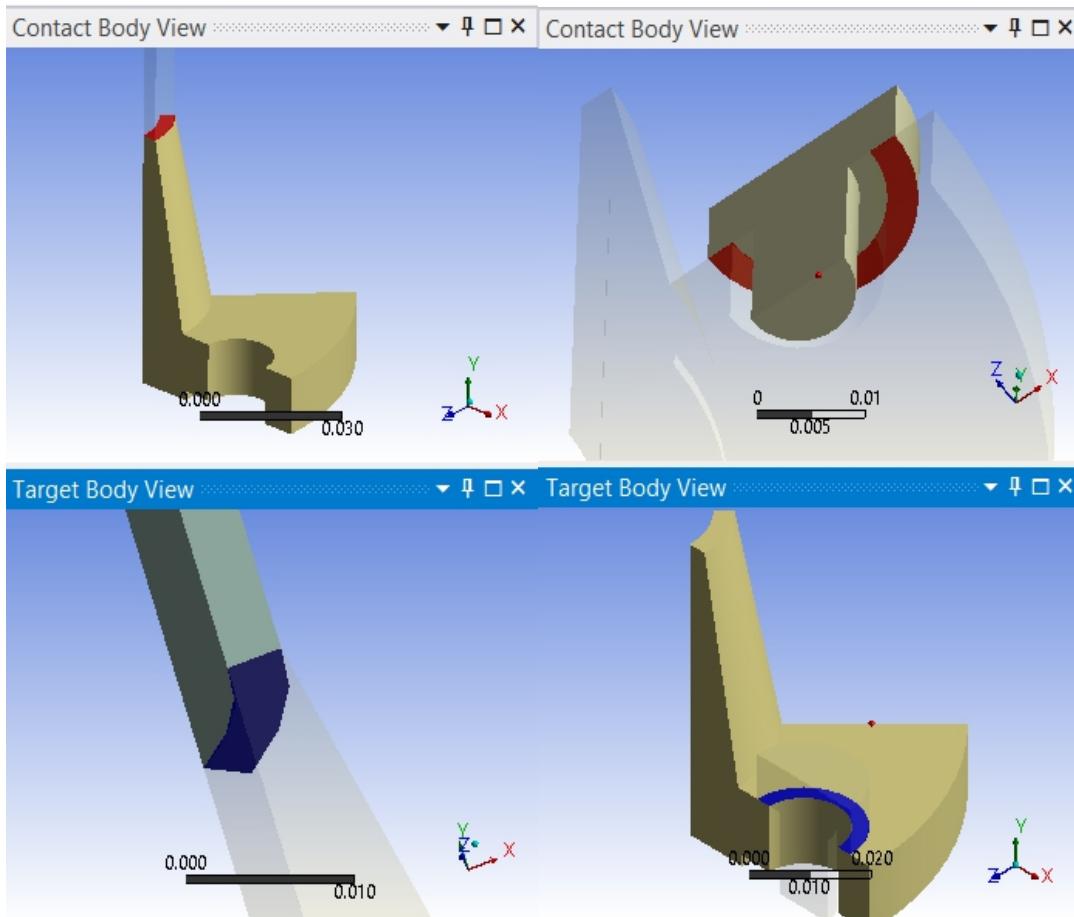


Figura 8: Los contactos entre la tubería-brida y el tornillo-brida

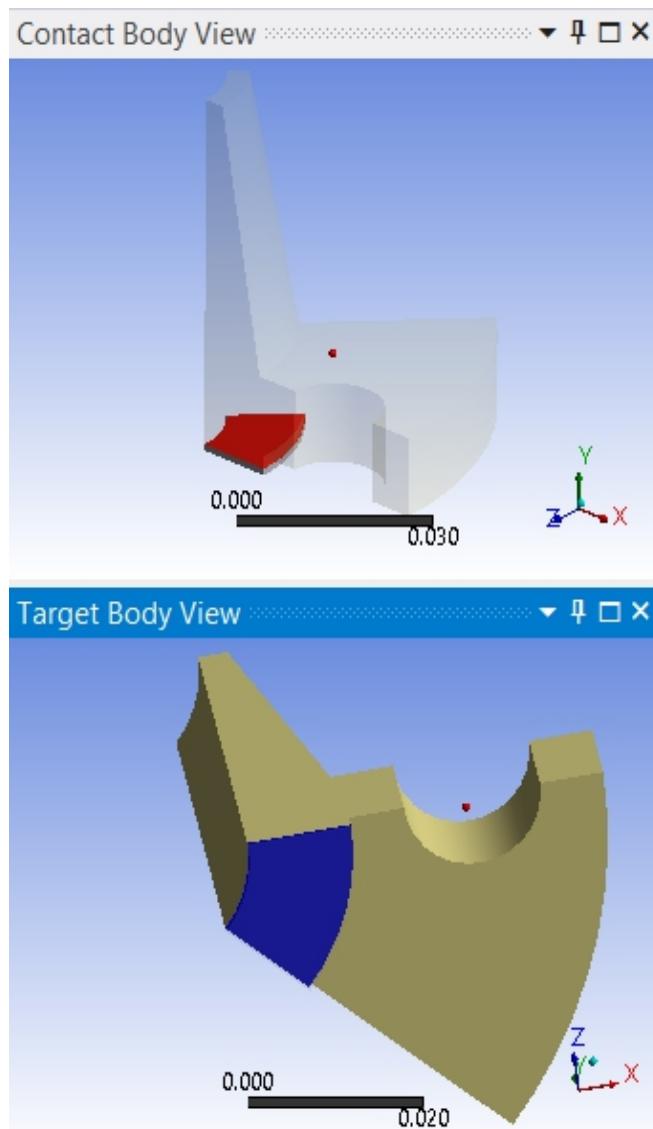


Figura 9 : El deslizamiento libre en superficie de la junta

Al final, el ajuste de deslizamiento libre asumiendo un coeficiente de fricción cero, se utiliza entre el área de contacto entre la superficie de la junta y el parte inferior de la brida [Figura 9]. Este contacto sin fricción permite un espacio en las superficies dependiendo de la carga aplicada.

2.4 Carga y condiciones de contorno

En este estudio, se aplica una condición de límite de simetría en el plano XY del modelo y el desplazamiento axial ($U_y = 0$) se restringe en el plano de simetría tanto de la junta como del punto del tornillo. Se simulan tres diferentes casos de carga diferentes para estudiar el comportamiento de la junta según la Figura 1.

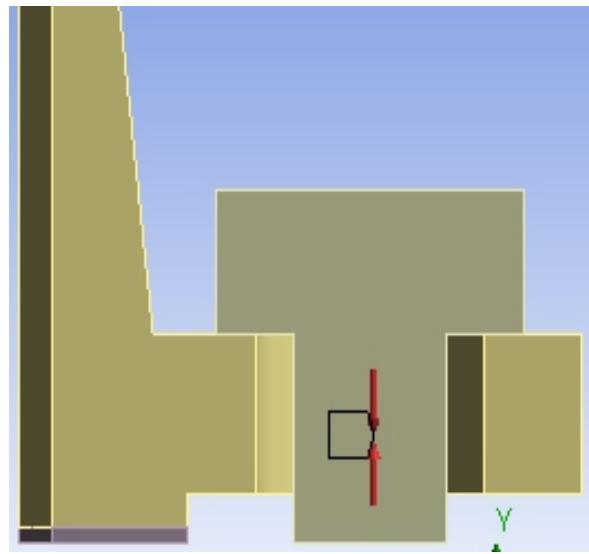


Figura 10: La carga del tornillo en Caso A

Caso B: Carga térmica.

En este segundo escenario, se aplica un gradiente de temperatura a la junta de brida. La temperatura de trabajo utilizada se recomienda según ASME B16.5 2009 [2]. Todo el plano de simetría del modelo se configura como perfectamente aislado mientras que en la parte exterior del modelo, un coeficiente de convección genérico para el aire ambiente de $10 \text{ W/m}^2\text{C}$ [1]. Los resultados de este caso se están utilizando en el caso de carga final para simular una situación más real.

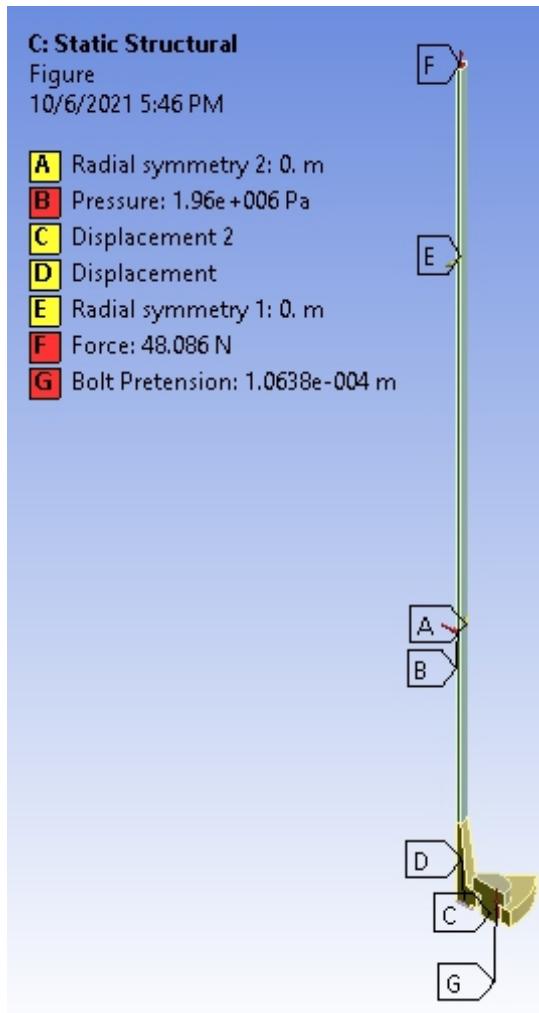


Figura 11: Cargas operativas en el Caso C

Caso C: Carga operativa.

En este último caso, según la Figura 11, se simula una condición de funcionamiento real que incluye la presión de diseño interna, la carga térmica y la tensión longitudinal en la conexión de la tubería. Según la referencia [1], se aplica una fuerza vertical al final de la conexión de la tubería utilizando esta fórmula:

$$\begin{aligned} \text{Tensión}_{\text{tuberia}} &= \text{Presión interna}_{\text{brida}} \times \text{Area contacto}_{\text{tuberia-brida}} \\ &= \text{Presión interna}_{\text{brida}} \times \left(\frac{\pi \times d_0^2}{8 * \text{No de tornillo}} \right) \end{aligned}$$

Este fuerza vertical es debido de la presión interna de la brida que producir una tensión longitudinal en la tubería. A continuación, la presión interna se aplica a la superficie interna de la junta de brida. Esta presión actuará sobre la parte interior de las conexiones de la tubería, la junta de la brida y la superficie interior de la junta.

3. EL APRENDIZAJE AUTOMÁTICO

La siguiente parte de este proyecto es el aprendizaje automático con la ayuda del software Orange Data Mining [13]. Todos los resultados obtenidos del análisis de elementos finitos se transfieren al aprendizaje automático como datos de entrada. En Orange, tratamos los siguientes parámetros como nuestros datos de entrada, son:

- Dimensiones de la brida [mm]
- Número de los tornillos, N
- Temperatura [$^{\circ}$ C]
- Presión interna [Pa]
- Fuerza vertical [N]
- Carga de los tornillos [N]

Los siguientes parámetros son las variables de salidas que se estimarán mediante el aprendizaje automático.

- Tensión normal de la junta (exterior, centro, interior) [Pa]
- Tensión equivalente (Von Mises) de junta [Pa]
- Tensión equivalente (Von Mises) de tubería [Pa]
- Tensión equivalente (Von Mises) de tornillo [Pa]
- Tensión equivalente (Von Mises) de brida [Pa]

El software Orange consta de diferentes modelos. En concreto, el “Data Sampler” se utiliza para dividir nuestros datos de entrada en un 70% de ellos que se tratan como los datos de entrenamiento para construir el modelo y el resto son los datos de prueba que se utilizarán para estimar la precisión del modelo. Los datos se denominan instancias y se clasifican según sus funciones : (feature, meta, target y skip).

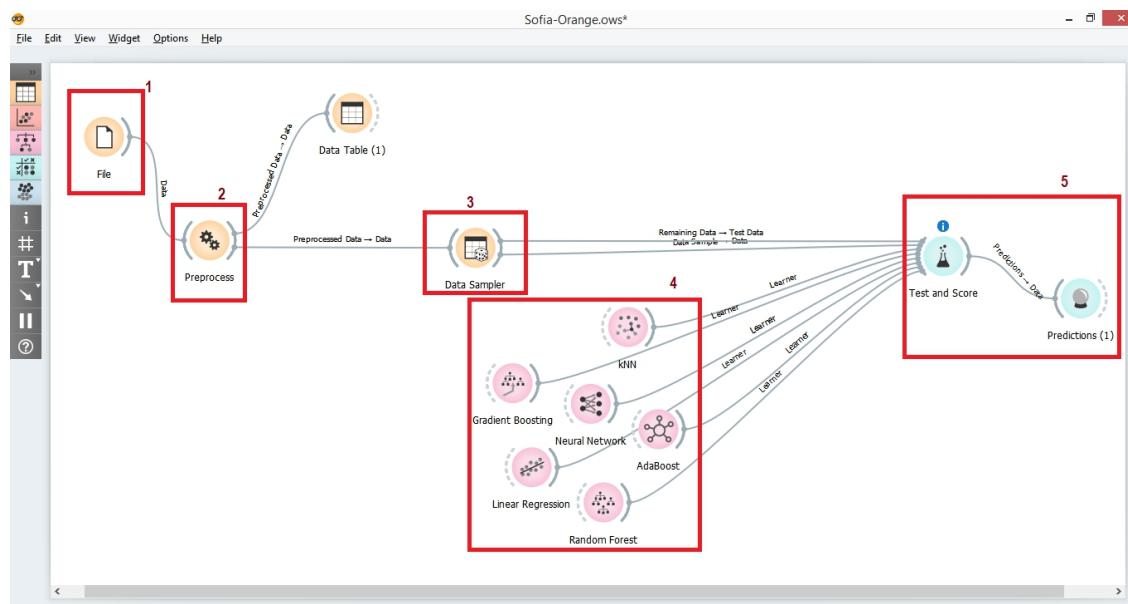


Figura 12: Flujo de trabajo de aprendizaje automático en Orange

En el aprendizaje supervisado, la naturaleza de los problemas se divide en dos tipos diferentes grupos que es Clasificación y Regresión. En el tipo de clasificación, se utiliza para clasificar datos discretos en una etiqueta de clase (estado, clase, género, tipo, etc.). Mientras tanto, la regresión se utiliza para predecir cualquier dato continuo. En este proyecto, nos centraremos más en el aprendizaje de regresión supervisado y, como se ilustra en la Figura 12 anterior, se utilizan seis diferentes modelos de aprendizaje supervisado para entrenar y probar los datos.

Entre los módulos utilizados para este aprendizaje supervisado son kNN, Neutral Network, Gradient Boosting, AdaBoost, Linear Regression y Random Forest.

El primero es Regresión Lineal. Es el modelo más simple en aprendizaje automático que se usa siempre para predecir la relación lineal entre la variable de entrada y la variable de salida. Hay que tener en cuenta que la regresión lineal solo se aplica a la tarea de regresión y no a la tarea de clasificación.

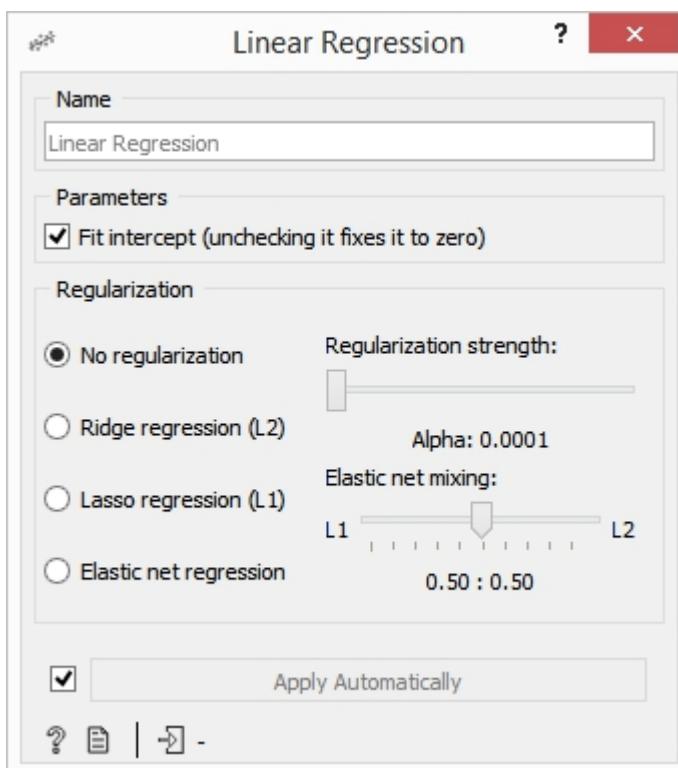


Figura 13: Regresión Lineal en Orange

A continuación, el algoritmo k-Neighbors Neighbours (kNN) se conoce como el aprendizaje perezoso entre los científicos de datos porque simplemente clasifica los datos en la categoría más cercana o muy similar a los datos de muestra sin aprender inmediatamente de ellos. El número de vecinos más cercanos elegidos son 5, la métrica de Manhattan y el peso uniforme se eligen por defecto. La métrica de Manhattan usa el total de las diferencias absolutas de todos los atributos al clasificar y el peso uniforme asumiendo que los puntos de cada barrio están distribuidos por igual.

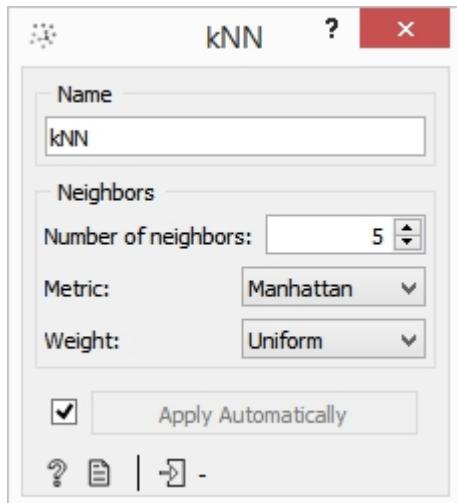


Figura 14: Configuración de kNN en Orange

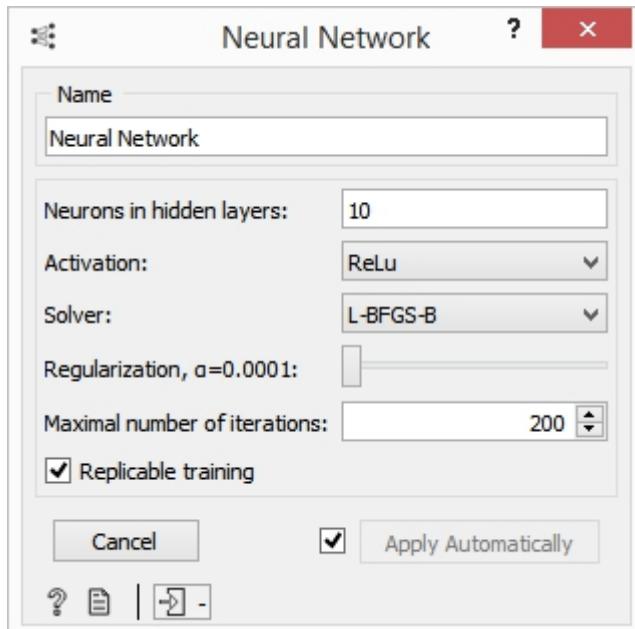


Figura 15 : Configuración de Red Neuronal en Orange

En la red neuronal, usamos la activación ReLu que es una función de unidad lineal rectificada y el solver como L-BFGS-B y también con la optimización de los métodos quasi-Newton. La red neuronal consta de varias capas ocultas y cada capa tiene su propia responsabilidad, que consta de neuronas que recibirán información de los datos de muestra u otros nodos y calcularán una salida en función de su importancia relativa. Esto se llama perceptrón multicapa y se funciona de manera muy similar con el cerebro humano. En lugar de aprender de las experiencias, necesitan muchos datos de entrada para aprender y adquirir experiencia. La precisión aumentará con la cantidad de datos a lo largo del tiempo.



A continuación, Gradient Boosting y AdaBoost tienen el mismo concepto de mejorar la predicción débil, en el que AdaBoost implementa la mayoría de votos con las instancias que se clasifican en función de los votos de la predicción débil y la nueva predicción débil se agregará de forma secuencial, más sobre los patrones difíciles mientras en el Gradient Boosting se agregará una predicción débil a la vez y el existente permanecerá sin cambios para minimizar la función de pérdida del modelo. Gradient Boosting es la combinación de AdaBoost y la minimización ponderada, lo que lo hace más confiable y más flexible. A continuación se muestra la configuración predeterminada de ambos modelos en Orange.

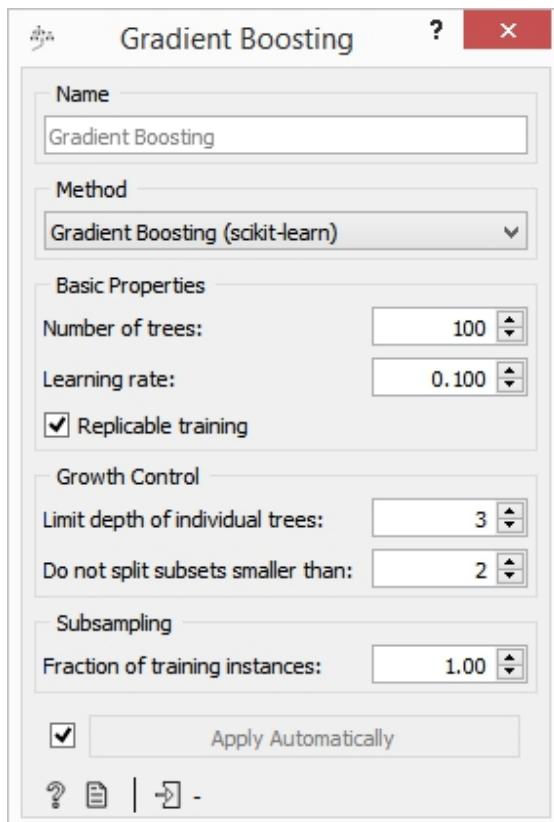


Figura 16: Gradient Boosting en Orange

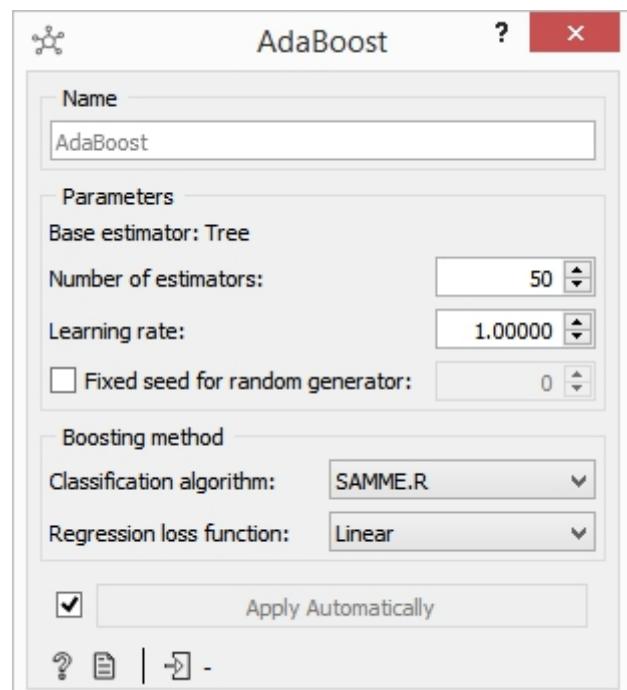


Figura 17 : AdaBoost en Orange

Por último, Random Forest es un modelo que consta de múltiples árboles de decisión y toma las predicciones de cada árbol y predice las predicciones promedio como resultado final. Cuanto mayor sea el número de árboles, mejores serán las predicciones de salida y se puede evitar un ajuste excesivo. A continuación se muestra la configuración predeterminada de Random Forest en Orange.

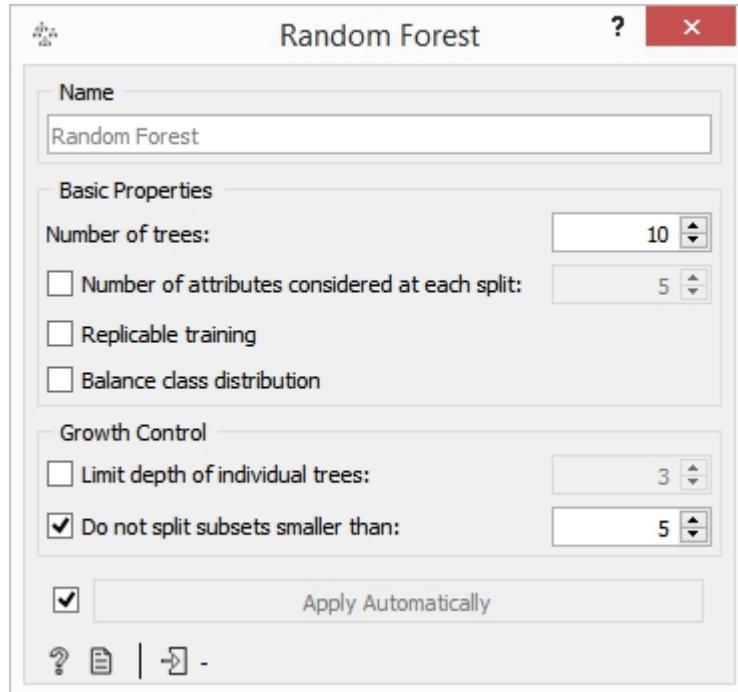


Figura 18: Configuración Random Forest en Orange

De todos los modelos explicados anteriormente, entendemos que cada modelo tiene sus propias ventajas y desventajas en función de la naturaleza del problema. Estudiaremos cuál de ellos que tiene los valores de salida mejor pronosticados y tiene la mejor precisión utilizando el widget prueba y puntuación ("test and score") y el de predicción.

Finalmente, el widget prueba y puntuación probará cada uno de los algoritmos de aprendizaje. Aquí, el 30% de los datos se tratarán como datos de prueba para validar la precisión de cada modelo. Por último, el widget de predicción nos mostrará los valores predichos para cada variable de salida.

4. RESULTADOS Y DISCUSIONES

4.1 Análisis elementos finitos

El análisis de elementos finitos se lleva a cabo en el software ANSYS del modelo ilustrado en la Figura 4 con diferentes tamaños nominales de tubería. El análisis se realiza bajo algunas limitaciones como el numero total de elementos a 32.000 como máximo y el tamaño de mallado por el tipo de licencia. Se explica mejor en detalles sobre el mallado en el [Apartado 2.3](#) anterior.

La Figura 17 a continuación se muestra la distribución de tensión normal en el superficie de la junta bajo el Caso C, ver el [Apartado 2.4](#), en el que se aplican la presión de diseño interna, la carga térmica y la fuerza en la conexión de la tubería. A la temperatura de trabajo de 38 °C, la presión interna de 1.96 MPa y la carga del tornillo es 10,405 kN, podemos observar que la tensión normal es la más alta en el diámetro externo de la junta y disminuye hacia adentro.

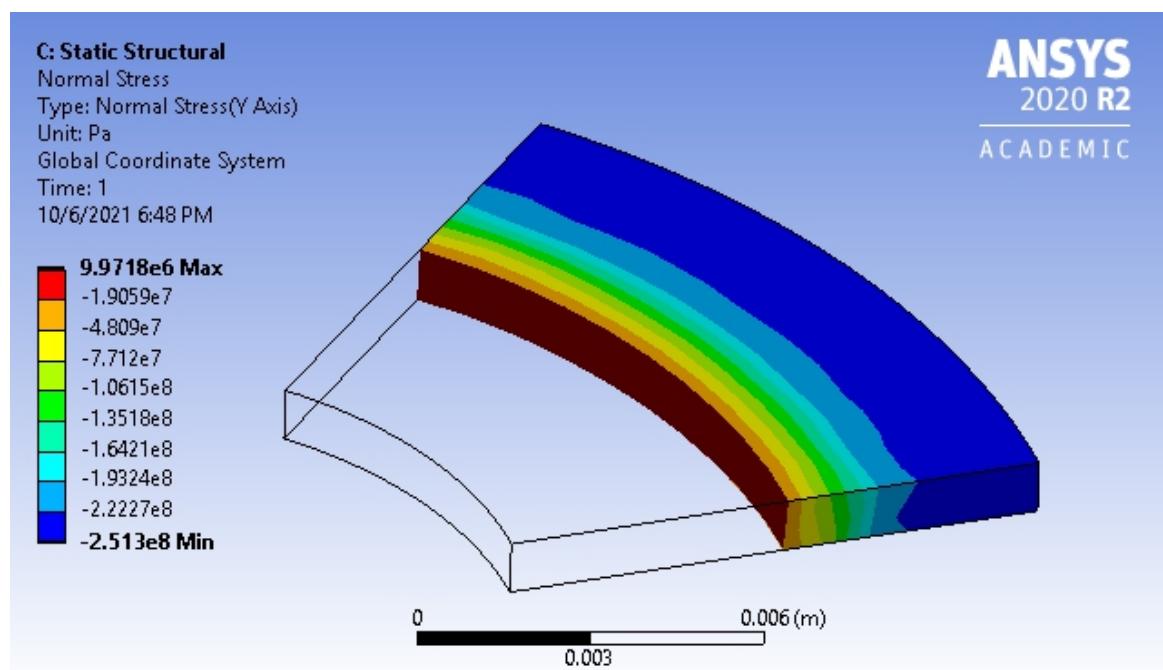


Figura 19: Distribución de la tensión normal en la junta de Class 150 NPS 0.5

La distribución de la tensión normal a lo largo de la superficie de la junta se representa en la Figura 20 a continuación. En este caso de carga, a medida que se aplica la presión interna al cuerpo de la brida, el cuerpo de la junta comienza a perder contacto y comienza a separarse de la brida. Refiriéndonos a la Figura 1, entendemos que si la presión interna aumenta más allá de la presión de diseño, el fluido finalmente romperá la superficie de la junta, causando que la junta de la brida tenga fugas.

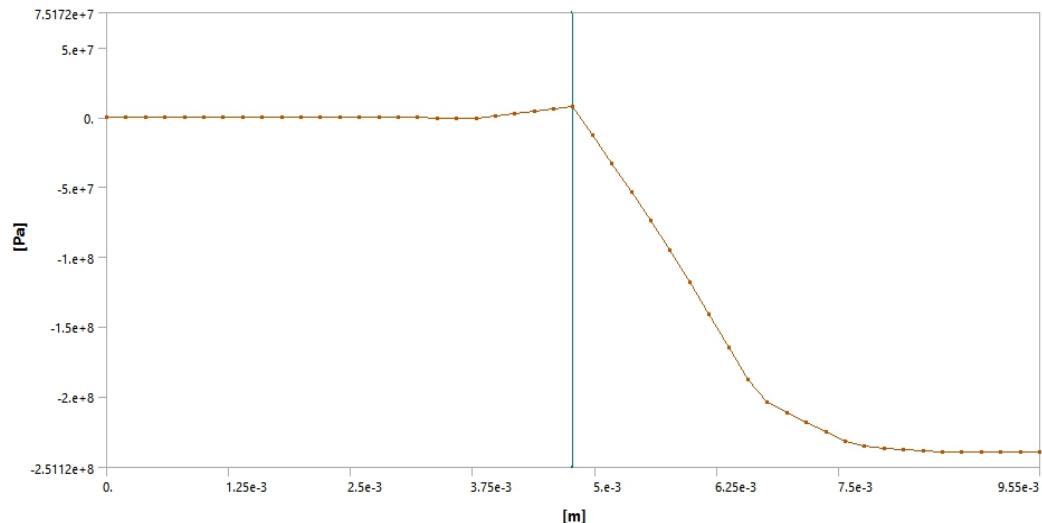


Figura 20: El gráfico de la distribución de tensión normal a lo largo de la junta (Class 150 NPS 0.5)

El valor positivo en el diámetro interior indica la tracción, pero dado que su magnitud es mucho menor que el valor negativo que indica la compresión, podemos concluir que la fuerza más alta en el diámetro exterior es lo suficientemente fuerte para comprimir la junta evitando así que se produzcan fugas.

De hecho, este tema está relacionado con la limitación de la licencia de estudiante donde la malla fina aplicada en la junta no es lo suficientemente fina, lo que hace que el algoritmo de detección del contacto falle, lo que nos da el resultado de que falta el contacto entre la brida y la junta. Sin embargo, este problema es imposible en la vida real porque esta siempre trabaja bajo compresión y el alto valor negativo de la tensión normal en el diámetro exterior de la junta nos confirma que se plastificará pero no se romperá. Por ese motivo, fijaremos en detalle sobre la tensión equivalente de Von Mises.

Otro factor importante para determinar el comportamiento de la junta de brida es la resistencia del material, ver el [Apartado 2.2](#). Respecto al comportamiento plástico bilineal que se ilustra en el gráfico de tensión-deformación en la Figura 6, cada material tiene su valor máximo de resistencia última y a trabajar con un valor de fuerza sobre ese punto es algo que no es correcto y peligroso, ya que provocará fallas y el material se deformará, lo que provocará que toda la junta de la brida estallar y romper. Teniendo en cuenta el límite máximo de resistencia de cada material utilizado, podemos identificar fácilmente qué componente se romperá o no.

La Figura 21 siguiente se muestra el gráfico de la tensión equivalente (Von Mises) de la junta y el cuerpo de la brida. La brida y la tubería están hechos de acero al carbono (A105) mientras que la junta está hecha de acero inoxidable, cada uno tiene una resistencia máxima de 483 MPa y 568 MPa respectivamente. A continuación se encuentra que la junta, la tubería y el cuerpo de la brida no se romperán ya que su valor de tensión equivalente se encuentra por debajo de su respectivo límite máximo de resistencia última.

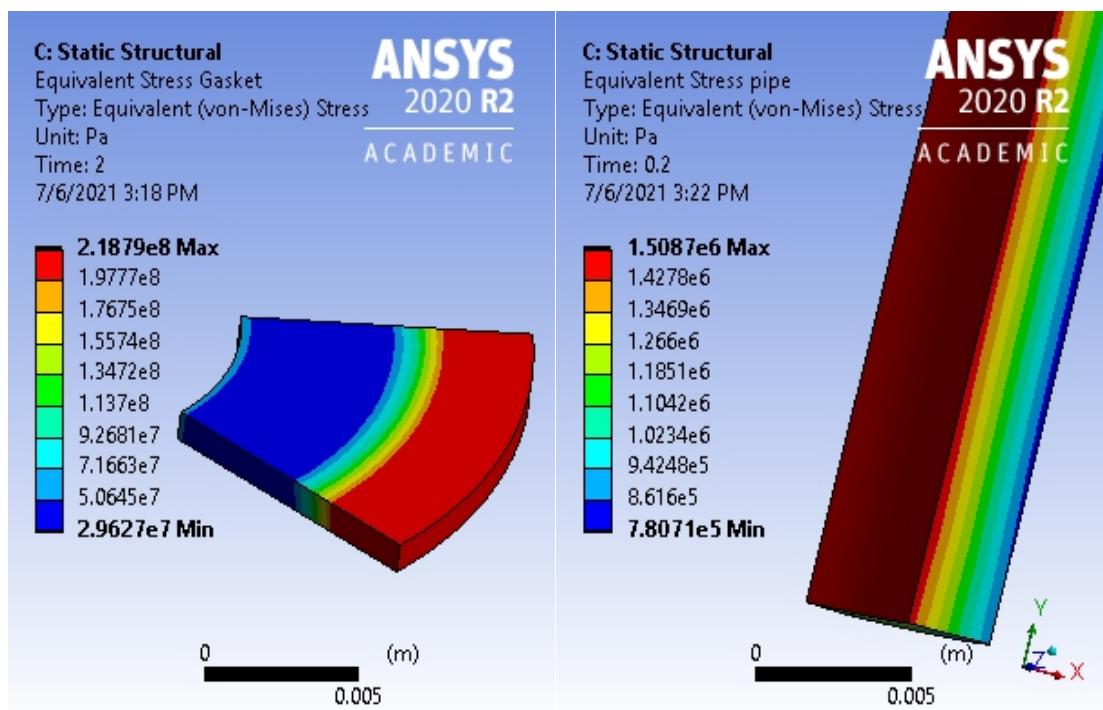


Figura 21: Distribución de tensión Von Mises en la junta y la tubería de Class 150 NPS 0.5

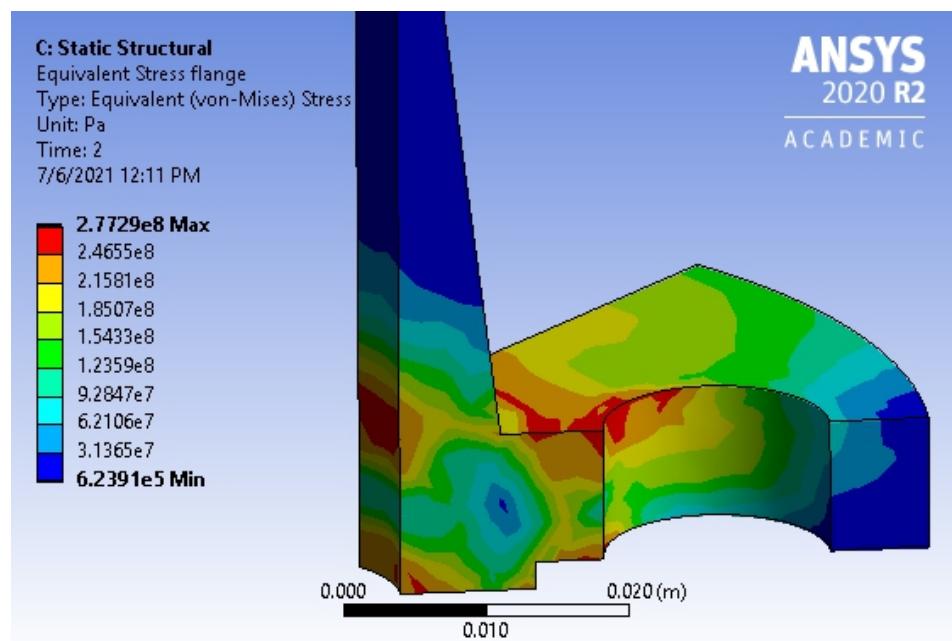


Figura 22: Distribución de tensión normal Von Mises de la brida de Class 150 NPS 0.5

De la Figura 22, podemos observar que la tensión máxima se puede encontrar en el área del cuello de la brida y también en la cabeza del tornillo. Ambos son el área crítica de la junta y se deben tener en cuenta consideraciones y precauciones adicionales al determinar el valor de la carga en estos dos. En este estudio, se ha aplicado una malla intermedia con tetraedro a la brida provocando las irregularidades en la distribución de la tensión equivalente Von Mises en la Figura 20.

En general, sobre la junta de todo la brida, el área con el valor máximo de tensión equivalente se puede encontrar en el cuerpo del tornillo aproximadamente a 613 MPa (Resistencia máxima a rotura para acero al cromo (A193-B7) usada para tornillos = 862 MPa). Este escenario confirma la hipótesis de que el aumento de la presión interna de la brida empujará toda la junta hacia afuera, lo que dará una fuerza adicional al cuerpo del tornillo para evitar fugas. Esto confirma que elegir el valor correcto para el atornillado afectará la integridad y el comportamiento de la junta de brida.

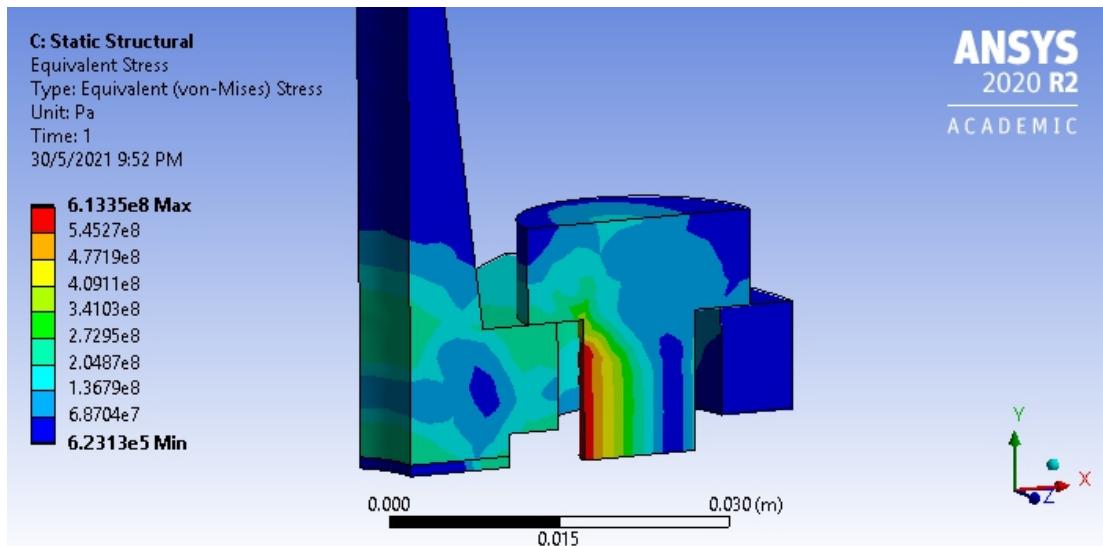


Figura 23: Distribución de tensión Von Mises en la brida de Class 150 NPS 1.0

Finalmente, se realiza el análisis paramétrico con el fin de estudiar el comportamiento de la junta de brida a diferentes temperaturas y presiones. Todos los resultados se tabulan y se transfieren a la siguiente fase del proyecto, que es el aprendizaje automático.



4.2 Aprendizaje automáticos

En esta segunda fase del proyecto, entrenar proporciones del 70% de los datos como muestra o datos de entrenamiento en Orange con diferentes tipos de modelo de aprendizaje supervisado nos ayudan a identificar qué modelo es el mejor y el más preciso cerca del análisis elementos finitos.

La división de los datos proporciona una base sólida para que la máquina aprenda y entrene el modelo. El 30% restante de los datos se tratan como datos de prueba para validar la precisión de cada modelo activando la "prueba en datos de prueba" en el widget de prueba y puntuación.

Variables de salidas	Coeficiente de determinación (R^2 score) sobre los datos de test					
	kNN	Random Forest	Neural Network	Linear Regression	Gradient Boosting	AdaBoost
Tension Normal (Externo)	0.9879	0.9999	0.9923	0.9627	0.9999	0.9999
Tension Normal (Centro)	0.9996	0.9997	0.9994	0.9973	0.9998	0.9998
Tension Normal (Interno)	0.9823	0.9998	0.9999	0.7945	0.9999	0.9999
Von Mises junta	0.8752	0.9395	0.8311	0.5407	0.8509	0.9631
Von Mises tubería	0.9855	0.9962	0.9999	0.9437	0.9995	0.9997
Von Mises tornillo	0.9994	0.9999	0.9999	0.9968	0.9999	0.9999
Von Mises brida	0.9454	0.9937	0.9907	0.9504	0.9942	0.9937

Tabla 2: Resultados de R^2 en el widget prueba y puntuación

La Tabla 2 anterior se muestra la puntuación R^2 de cada variable de salida entrenada en aprendizaje automático. El coeficiente de determinación o R^2 es el valor estático para medir qué tan cerca los datos predichos con los datos reales. Cuanto más se acerque la puntuación R^2 a 1, mejores serán los resultados previstos. En el [Anexo C](#) se pueden encontrar más detalles sobre los resultados. A partir de esos valores de R^2 , podemos concluir que AdaBoost, Random Forest y Neural Network se encuentran entre los modelos que tienen mayor ajuste y precisión.

La relación entre los resultados previstos y los resultados reales de FEA se representa en las figuras siguientes. Cuanto más cerca esté el valor predicho de la línea de referencia, más precisos y exactos serán los resultados. Todos los diagramas de dispersión de cada modelo se pueden encontrar en el [Anexo B](#).

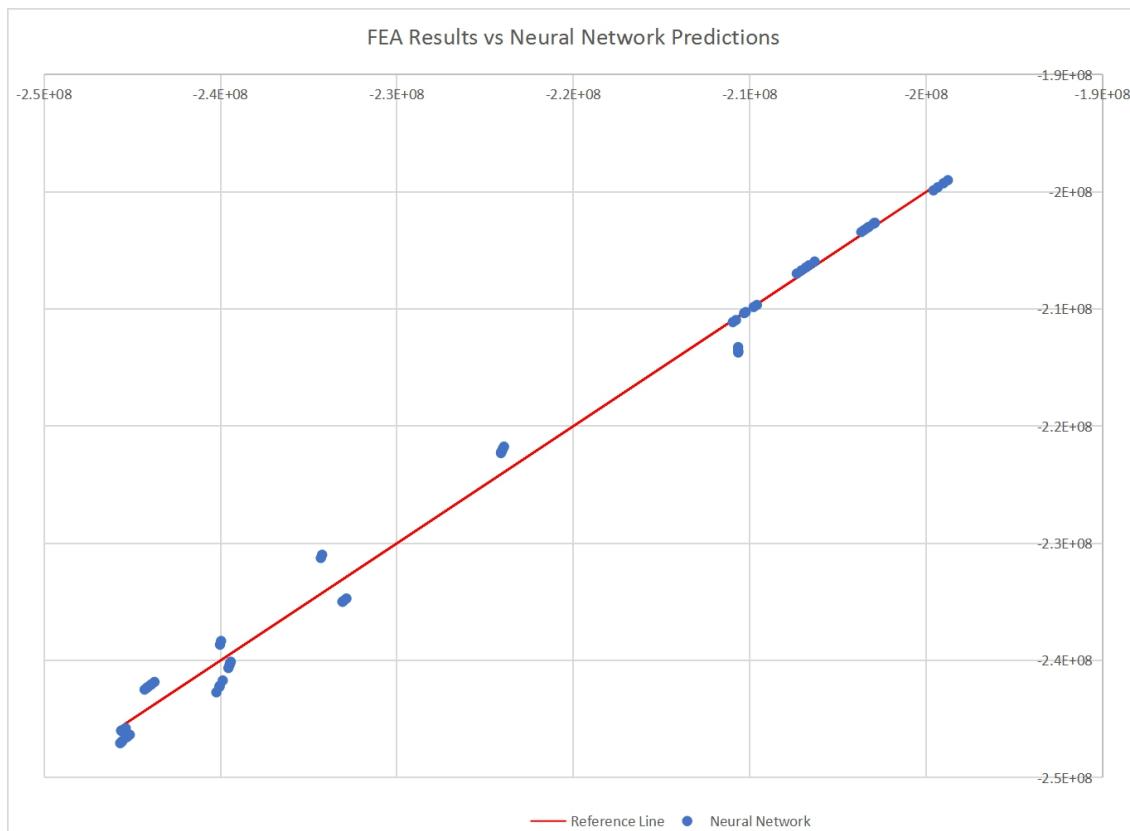


Figura 24: La gráfica de dispersión de Red Neuronal para la tensión normal (diámetro externo)

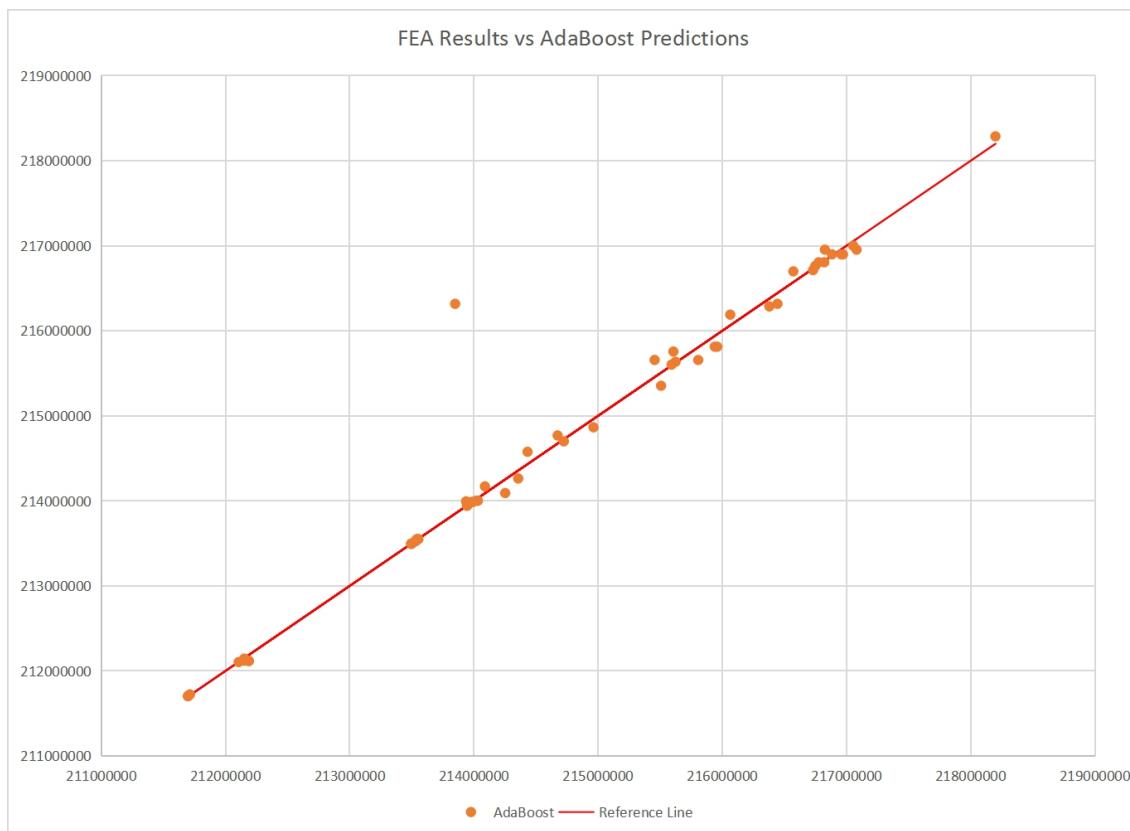


Figura 25: La gráfica de dispersión de AdaBoost para la tensión Von Mises de la junta



5. CONCLUSIONES

Para simplificar, en este trabajo fin de grado se ha realizado una simulación en el software ANSYS Student 2020 y Orange Data Mining para estudiar el comportamiento de una brida. Aunque es bastante complicado, especialmente en determinar la pretensión del tornillo, elegir el mejor material para la junta y proporcionar el tipo correcto de contacto en la superficie de la junta, podemos asegurar que bajo las limitaciones establecidas en ASME B16.5 (presión-temperatura clasificación, pretensión de los tornillos y tipo de materiales), la junta de brida es capaz de funcionar correctamente sin tener fugas o roturas.

Para investigar el comportamiento de la junta de brida, se implementa una forma tradicional y común en la primera parte de este trabajo fin de grado mediante el análisis de elementos finitos realizado con ANSYS mientras que en la segunda fase, se plantea una nueva y más sofisticada forma que es el aprendizaje automático. La distribución normal de la tensión en la superficie de la junta confirma que, según la regulación de ASME B16.5, no se detecta la presencia de fugas. También confirmamos que ninguno de los componentes sufre rotura y falla ya que el esfuerzo equivalente (Von Mises) de cada uno de ellos se encuentra por debajo de su respectivo límite máximo último.

Obviamente, se tardó mucho en obtener los resultados en el análisis de elementos finitos debido a la complejidad del modelo y la limitación de la licencia del software, mientras que en el aprendizaje automático se tardó menos en alimentar los datos y enseñar a la máquina sobre la naturaleza de los problemas. Aquí, entre las posibles mejoras que se pueden hacer en el futuro es, realizar el análisis de elementos finitos utilizando la licencia profesional que no tiene limitación en el tamaño de la malla y también hacer un análisis experimental para estudiar la situación de la vida real de su principio de funcionamiento y comparar más adelante los tres enfoques diferentes podría proporcionarnos una mejor visión sobre el comportamiento de la brida.

A continuación, al comparar los resultados de ambos programas, podemos concluir que los resultados predichos del aprendizaje automático son aproximadamente precisos y similares al análisis de elementos finitos. Sin duda, el aprendizaje automático ha demostrado tener un futuro brillante en el campo de la ingeniería debido a su simplicidad pero a su rápida adaptabilidad para aprender y pensar como un humano.

En conclusión, la idea sobre el aprendizaje automático presentada en este trabajo, si que tiene futuro en el campo de la ingeniería y también se puede utilizar para una investigación más crítica y profunda de cualquier componente mecánico en la industria, ya que se ha desarrollado y avanza rápidamente en la actualidad.



6. REFERENCIAS

- [1] Burrull Allan Xavier, Blasco Alberto Javier Amadeo, Bea Cascarosa José Antonio. Análisis mediante elementos finitos de bridas, 2020.
- [2] ASME B16.5 2009, Pipe Flanges and Flanged Fittings, NPS 1/2 Through NPS 24 Metric/Inch Standard.
- [3] ASME PCC-1, 2019 Edition, September 30, 2019 - Guidelines for Pressure Boundary Bolted Flange Joint Assembly.
- [4] Estrada, H. Analysis of leakage in bolted-flanged joints using contact finite element analysis. Journal of Mechanics Engineering and Automation, 5(3), 135-142, 2015.
- [5] M. Murali Krishna, M.S. Shunmugam, N. Siva Prasad. A study on the sealing performance of bolted flange joints with gaskets using finite element analysis, International Journal of Pressure Vessels and Piping, Volume 84, Issue 6, 2007.
- [6] Sawa, T., Higurashi, N., and Akagawa, H. (November 1, 1991). A Stress Analysis of Pipe Flange Connections. ASME. J. Pressure Vessel Technol. November 1991; 113(4): 497–503.
- [7] Sawa, T., Ogata, N., and Nishida, T. (November 8, 2002). "Stress Analysis and Determination of Bolt Preload in Pipe Flange Connections With Gaskets Under Internal Pressure ." ASME. J. Pressure Vessel Technol. November 2002; 124(4): 385–396.
- [8] Jenco, J. M., & Hunt, E. S. (2000). Generic issues effecting spiral-wound gasket performance. International Journal of Pressure Vessels and Piping, 77, 825-830.
- [9] Mohit, S. (2020, April 1). Bolted Flange Design Leakage Analysis. Skill-Lync. <https://skill-lync.com/projects/Bolted-Flange-Design-Leakage-Analysis-13084>
- [10] Yang, H., Liu, X., Zhang, D., Chen, T., Li, C., & Huang, W. (2021). Machine learning for power system protection and control. The Electricity Journal, 34(1), 106881.
- [11] Index. (n.d.). Pipe Data. Retrieved May 29, 2021, from <https://www.pipedata.com/WebApp/Content/>
- [12] Ansys® Academic Research Mechanical, Release 2020 R2.
- [13] Demsar J, Curk T, Erjavec A, Gorup C, Hocevar T, Milutinovic M, Mozina M, Polajnar M, Toplak M, Staric A, Stajdohar M, Umek L, Zagar L, Zbontar J, Zitnik M, Zupan B (2013) Orange: Data Mining Toolbox in Python, Journal of Machine Learning Research 14(Aug): 2349–2353.



7. ANEXOS

ANEXO A : Propiedades de los materiales

Los materiales utilizados en este proyecto son de Burrull Allan, Xavier [1] excepto de la junta. Todos los materiales están siendo recomendados por la empresa Red-Bag y se confirma que cumplen con los criterios mencionados en ASME B16.5 2009 [2].

❖ La brida y la tubería (ASME SA 105)

Los materiales utilizados para la brida y la tubería son el material de acero al carbono (A-105) con la siguiente especificación. La Imagen 1 se muestra la diagrama tensión-deformación según el comportamiento plástico bilineal.

The screenshot shows the Biluna software interface for managing material properties. The main window displays a material list table and detailed properties for ASME SA-105. The table includes columns for specno, typegrade, thicknlm, form_id, class_id, structure_id, composition, alloyno, treatmer, document, issue, and notes. The selected row for ASME SA-105 has its details expanded in the lower panel, which includes sections for Yield/Tensile, ASME II part D allow., ASME B31.X allow., and various physical properties like Composition (Carbon steel), Yield 20 Celsius (250 MPa), and Heat Treatment (K03504). Other sections include External Pressure Table (CS-2), Modulus of Elasticity Table (ASME II part D, TM-1, CS C > 0.30%), Thermal Expansion Table (ASME II part D, TE-1, CS Low Alloy (Group 1) [Note (1)]), and Creep Table (none).

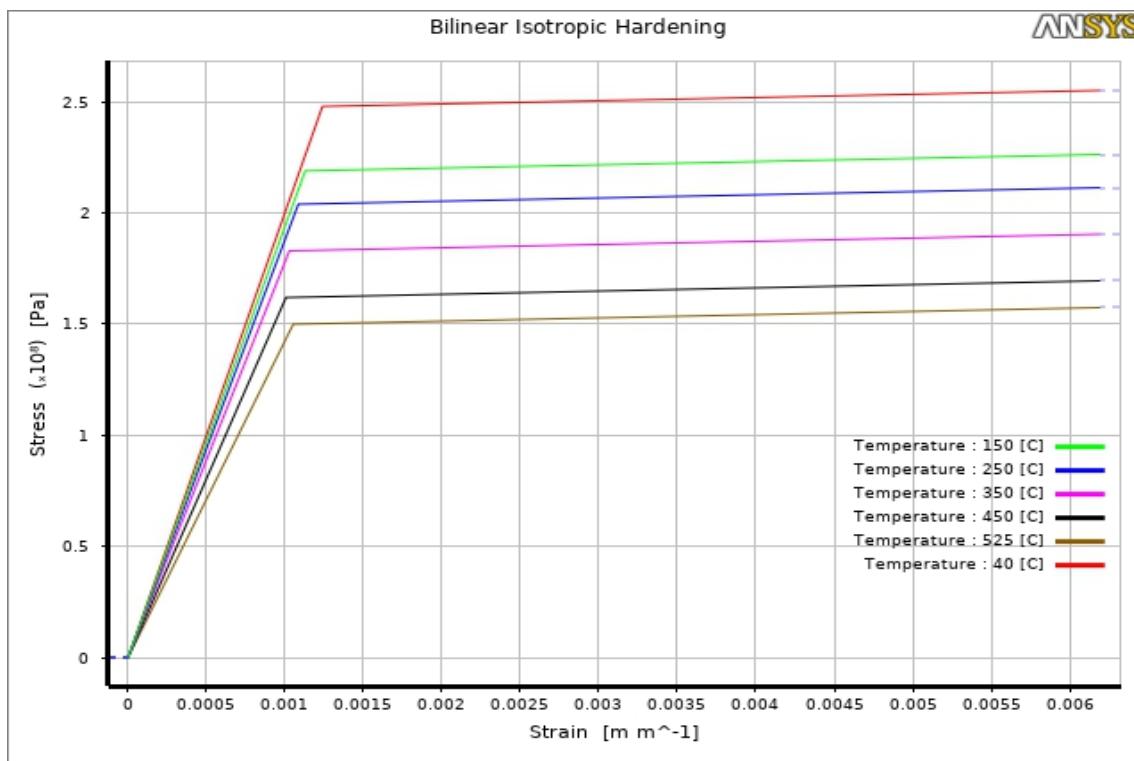
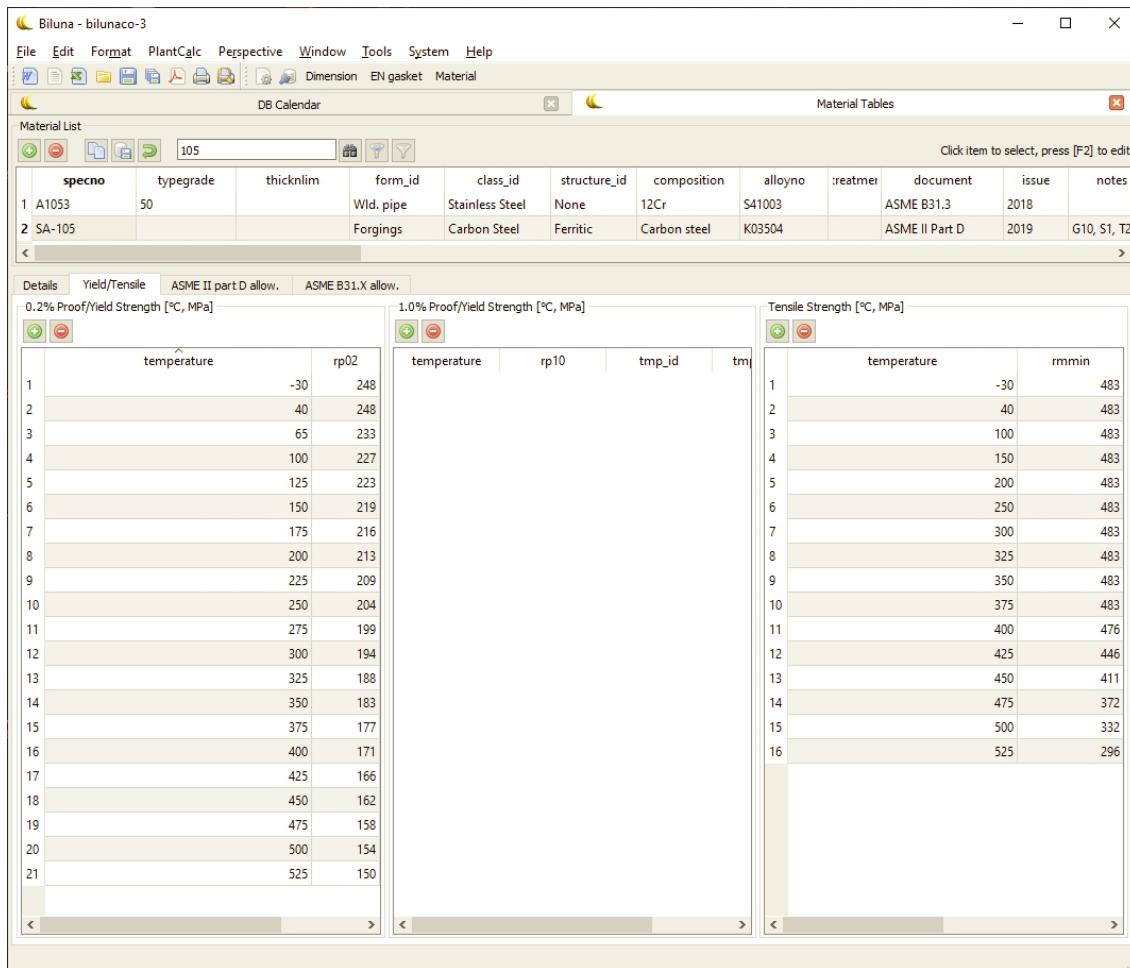


Imagen 1: Diagrama tensión-deformación para el ASME SA105 en ANSYS



❖ Los tornillos (ASME SA 193 B7)

En cuanto al tornillo, optamos por simular el tornillo que está hecho de acero al cromo, (A-193 B7). La siguiente tabla muestra las propiedades del tornillo según lo recomendado por la empresa Red-Bag.

The screenshot shows the Biluna software interface. At the top, there's a menu bar with File, Edit, Format, PlantCalc, Perspective, Window, Tools, System, Help. Below the menu is a toolbar with various icons. The main window has tabs for DB Calendar, Material Tables, and EN 1591-1 Flange Calculation. The Material List tab is active, showing a table with columns: specno, typegrade, thicknlm, form_id, class_id, structure_id, composition, alloyno, and a dropdown. Rows 1 through 6 are listed, with row 3 selected (highlighted in blue). Below the table, there are three tabs: Details, Yield/Tensile, and Allowable Stress. The Details tab is selected, displaying various properties: Specification (SA-193), Type/Grade (B7), Thickness Limit (<=64), Form (Bolting), Class (Low Alloy), Structure (Ferritic), Composition (1Cr- 1/5Mo), Alloy No. (G41400), Heat Treatment (none), Document (ASME II Part D), Issue (2015), Notes (T5), Notes Y (none), Notes B31.1 (none), Notes B31.3 (none), Yield 20 Celsius (725 MPa), Yield 1% 20 Celsius (0 MPa), Min. Tensile 20 Celsius (860 MPa), Spec. Gravity (0 kg/dm³), Elong. Rupture (0 percent), ASME I Temp. Limit (427 Celsius), ASME III Temp. Limit (538 Celsius), ASME VIII div1 T. Limit (427 Celsius), and ASME XII Temp. Limit (343 Celsius).



Biluna - bilunaco-5

File Edit Format PlantCalc Perspective Window Tools System Help

Dimension EN gasket Material

DB Calendar Material Tables EN 1591-1 Flange Calculation

Material List Click item to select, press [F2] to edit

	specno	typegrade	thicknlm	form_id	class_id	structure_id	composition	alloyno	l ^
1	SA-193	B7	100 < t <= 175	Bolting	Low Alloy	Ferritic	1Cr- 1/5Mo	G41400	
2	SA-193	B7	64 < t <= 100	Bolting	Low Alloy	Ferritic	1Cr- 1/5Mo	G41400	
3	SA-193	B7	<=64	Bolting	Low Alloy	Ferritic	1Cr- 1/5Mo	G41400	
4	SA-193	B7M	<=64	Bolting	Low Alloy	Ferritic	1Cr- 1/5Mo	G41400	
5	SA-671	CB70		Wld. pipe	Carbon Steel	Ferritic	Carbon steel	K03101	
6	SA-671	CB70		Wld. pipe	Carbon Steel	Ferritic	Carbon steel	K03101	10.▼

Details Yield/Tensile Allowable Stress

0.2% Proof/Yield Strength [$^{\circ}$ C, MPa]

	temperature	rp02
1	-30	724
2	40	724
3	65	698
4	100	671
5	125	658
6	150	648
7	175	640
8	200	632
9	225	623
10	250	614
11	275	605
12	300	595
13	325	583
14	350	568
15	375	553
16	400	534
17	425	511
18	450	485
19	500	416
20	525	374

1.0% Proof/Yield Strength [$^{\circ}$ C, MPa]

	temperature	rp10	tmp_id
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			
11			
12			
13			
14			
15			

Tensile Strength [$^{\circ}$ C, MPa]

	temperature	rmmin
1	-30	862
2	40	862
3	100	862
4	150	862
5	200	862
6	250	862
7	300	862
8	325	862
9	350	852
10	375	819
11	400	787
12	425	750
13	450	709
14	500	618
15	525	567

A continuación, la Imagen 2 se muestra la diagrama tensión-deformación para el acero al cromo (A-193 B7) según el comportamiento plástico bilineal.

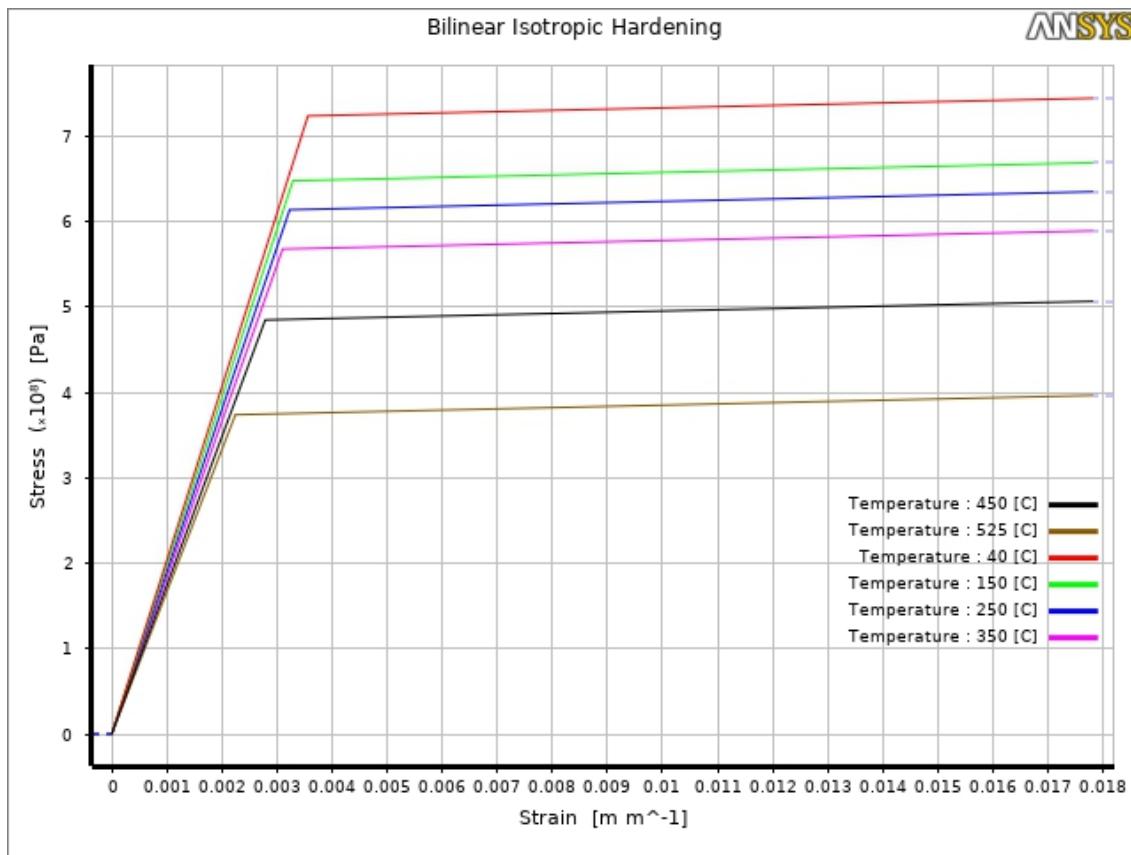


Imagen 2: Diagrama tensión-deformación para el ASME SA 193-B en ANSYS

❖ La junta (Acero inoxidable NL)

Por un lado, la selección del material de la junta es muy importante para evitar fugas. El acero inoxidable NL con endurecimiento isotrópico bilineal se utiliza según lo recomendado por Mohit, 2020 [8].

Properties of Outline Row 6: Stainless Steel				
	A	B	C	D E
1	Property	Value	Unit	
2	Material Field Variables	Table		
3	Density	7750	kg m ⁻³	
4	Isotropic Secant Coefficient of Thermal Expansion	Table		
5	Coefficient of Thermal Expansion	1.7E-05	C ⁻¹	
6	Isotropic Elasticity			
7	Derive from	Young's Modulus and Poiss...		
8	Young's Modulus	1.93E+11	Pa	
9	Poisson's Ratio	0.31		
10	Bulk Modulus	1.693E+11	Pa	
11	Shear Modulus	7.3664E+10	Pa	
12	Bilinear Isotropic Hardening			
13	Yield Strength	2.1E+08	Pa	
14	Tangent Modulus	1.8E+09	Pa	
15	Tensile Yield Strength	2.07E+08	Pa	
16	Compressive Yield Strength	2.07E+08	Pa	
17	Tensile Ultimate Strength	5.86E+08	Pa	
18	Compressive Ultimate Strength	0	Pa	
19	Isotropic Thermal Conductivity	15.1	W m ⁻¹ C ⁻¹	

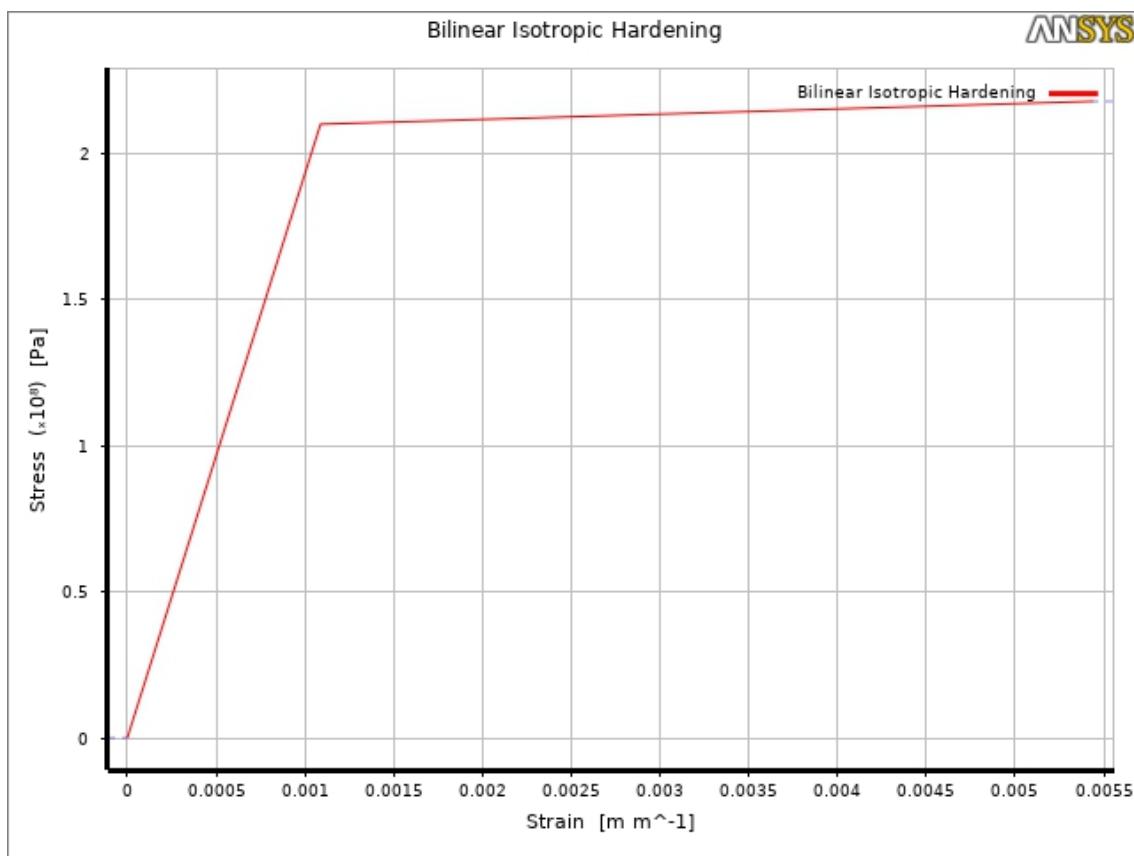
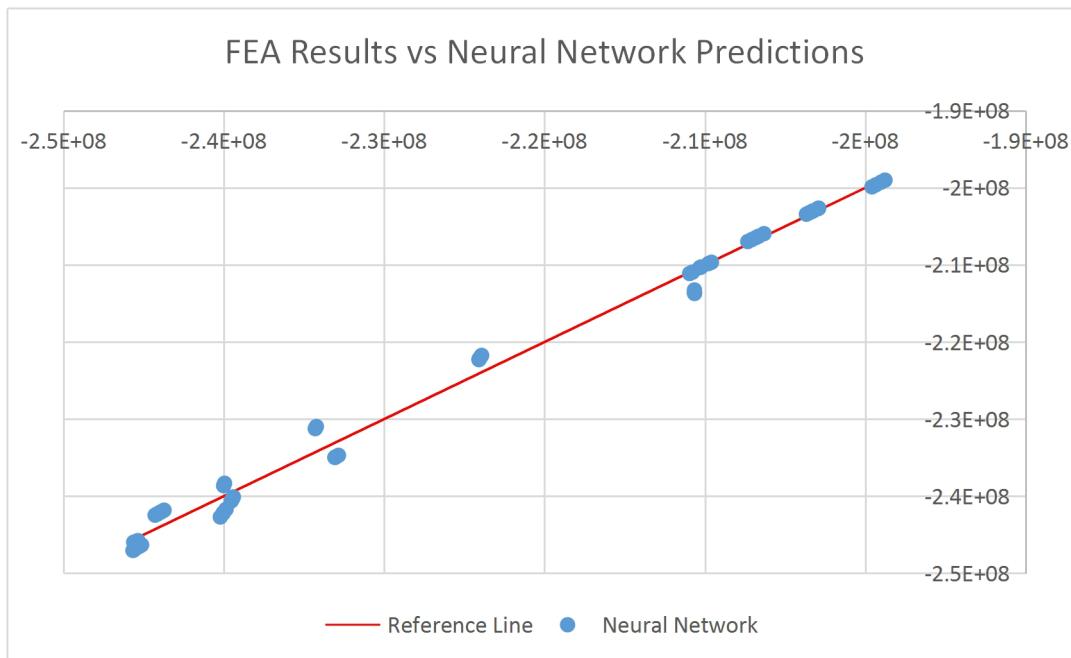
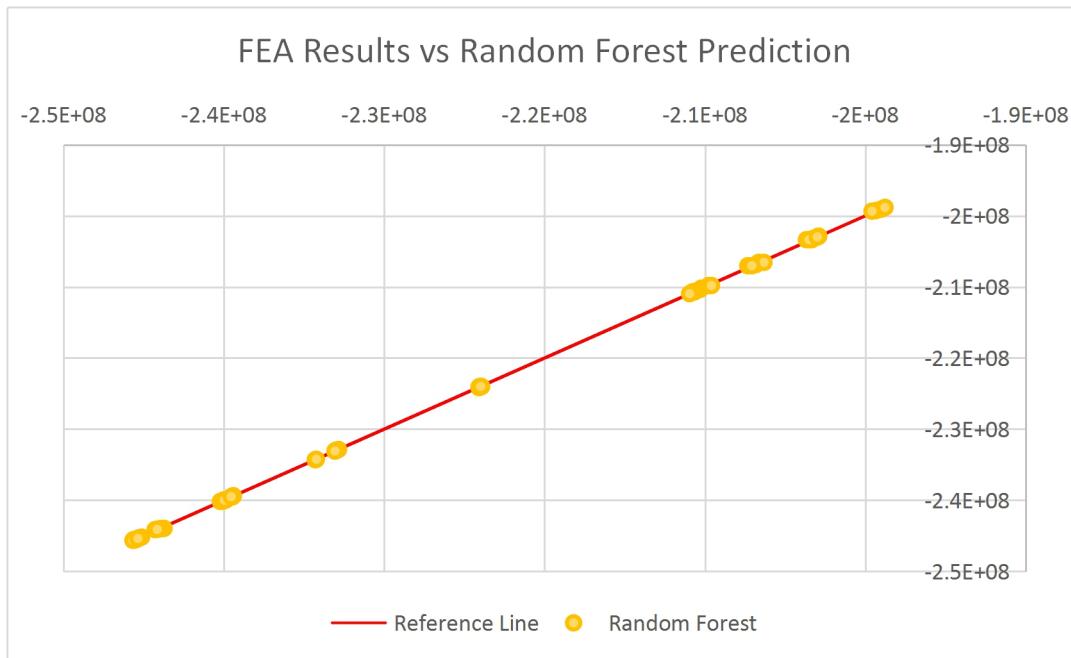


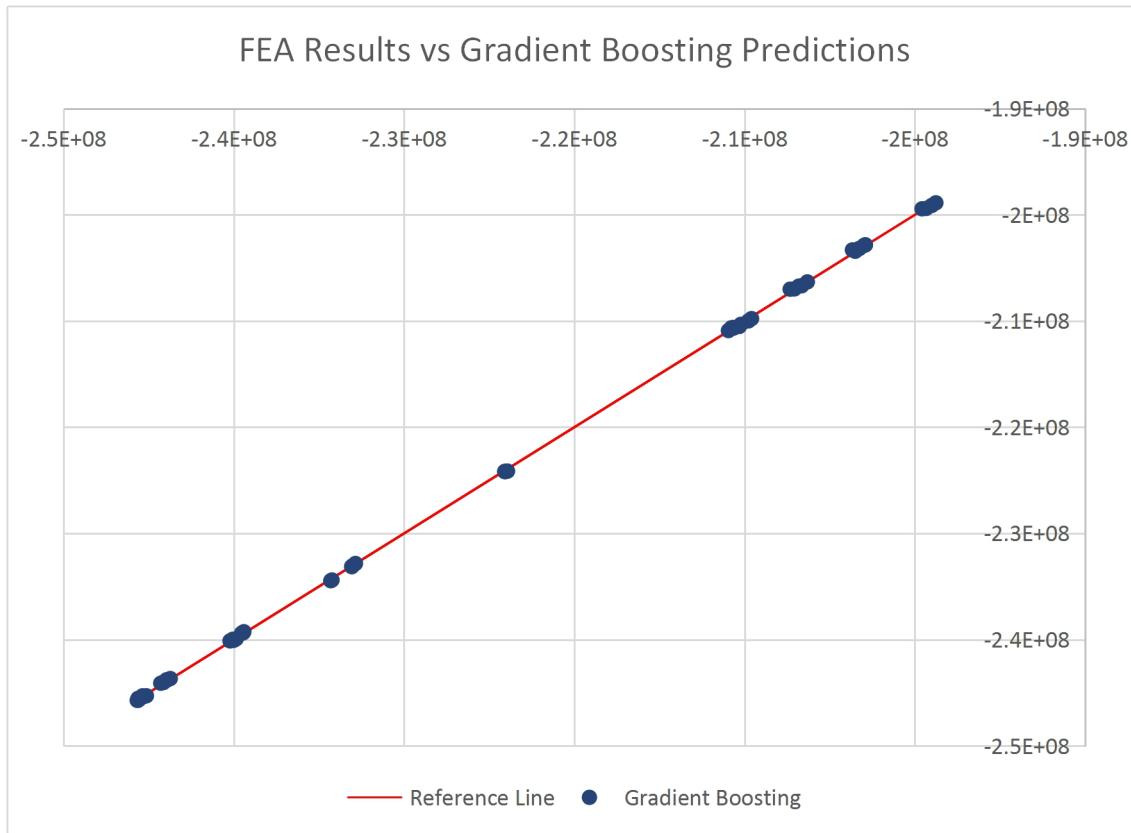
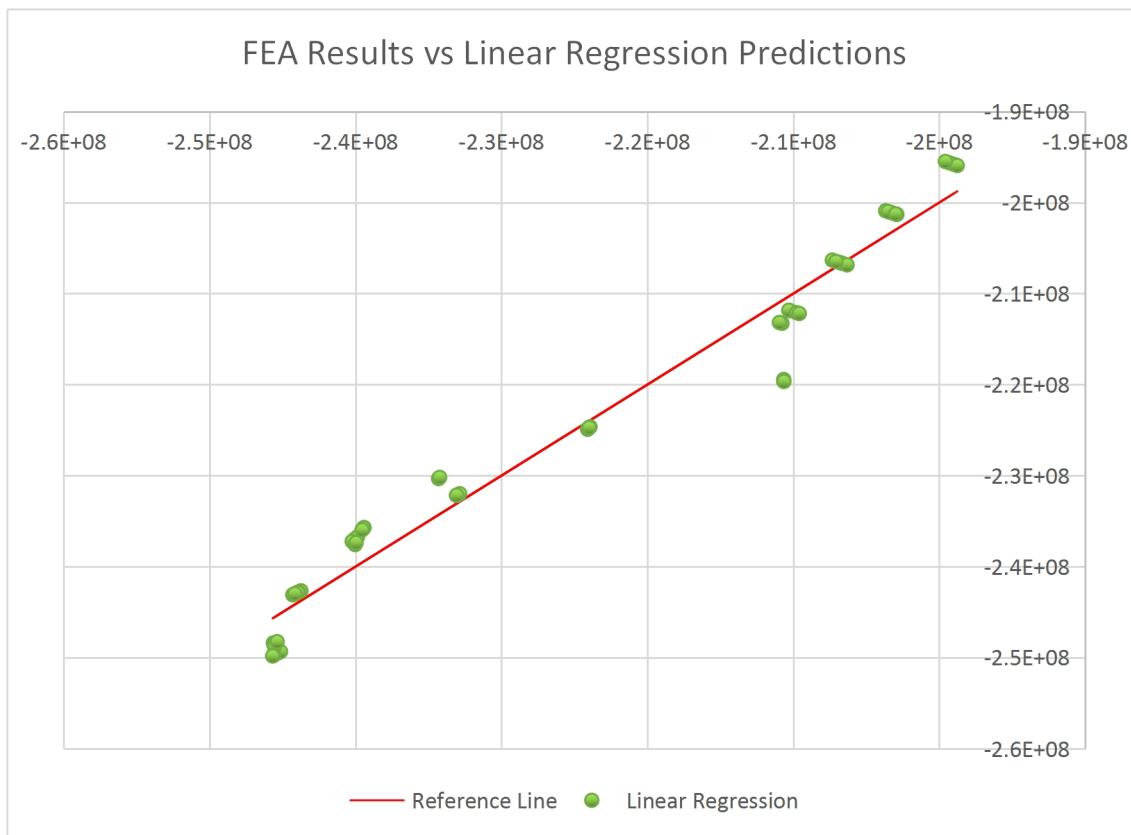
Imagen 3: Diagrama tensión-deformación para el acero inoxidable NL en ANSYS

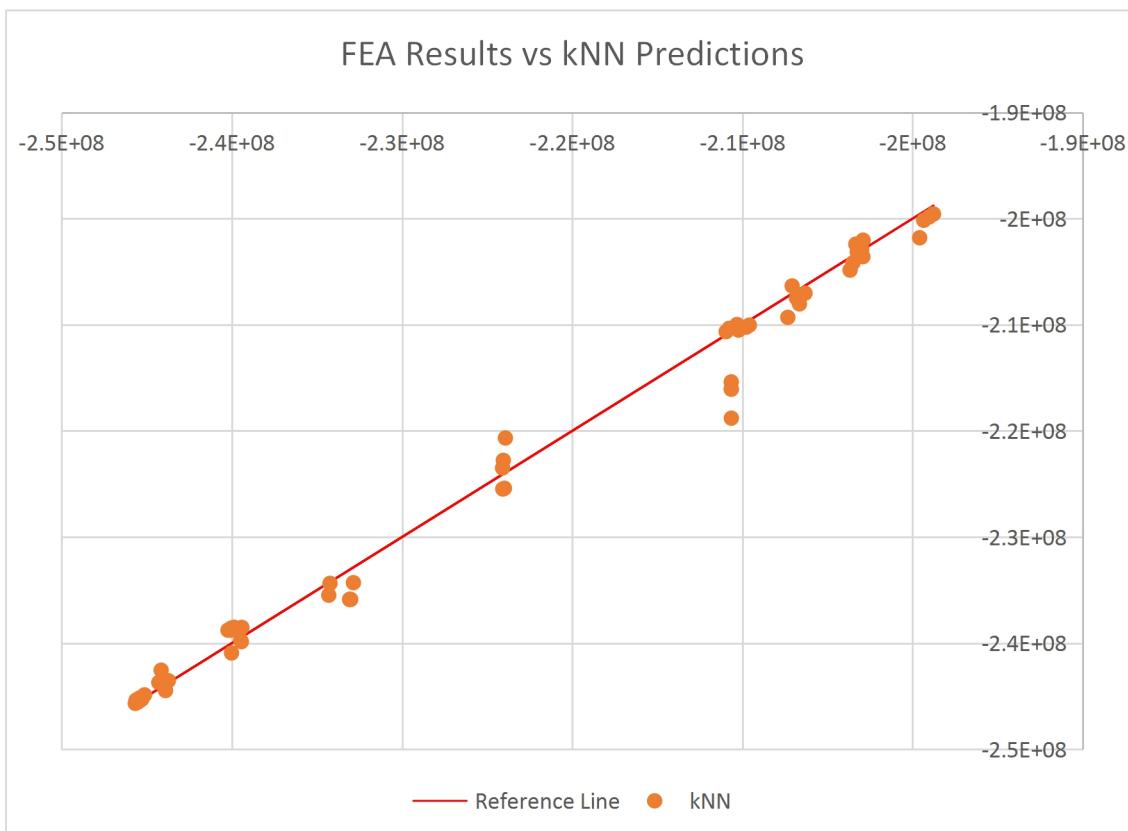
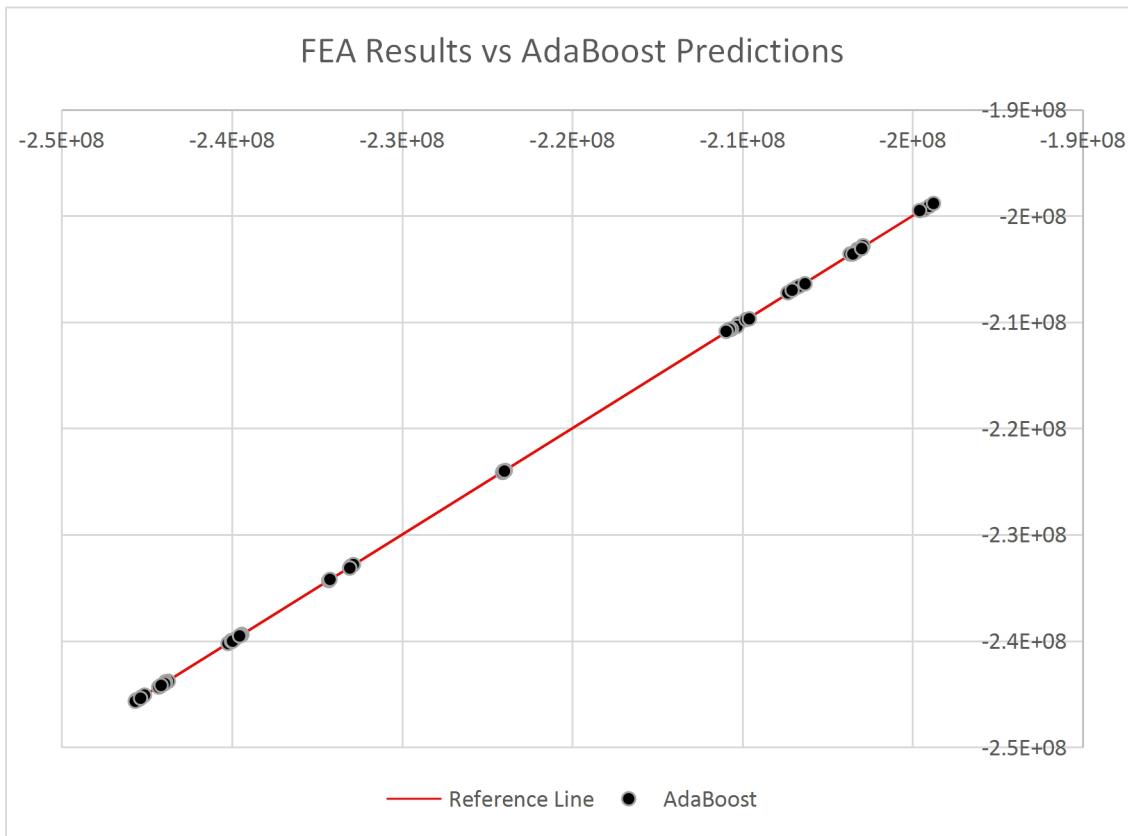
ANEXO B: Gráfico de dispersión de los resultados previstos.

Desde el widget de predicción en Orange, los valores de salida predichos se han trazado para compararlos con los resultados de FEA. Como se mencionó anteriormente, cuanto más cerca esté el valor predicho de la línea diagonal, más preciso será el valor, mejor sea el modelo.

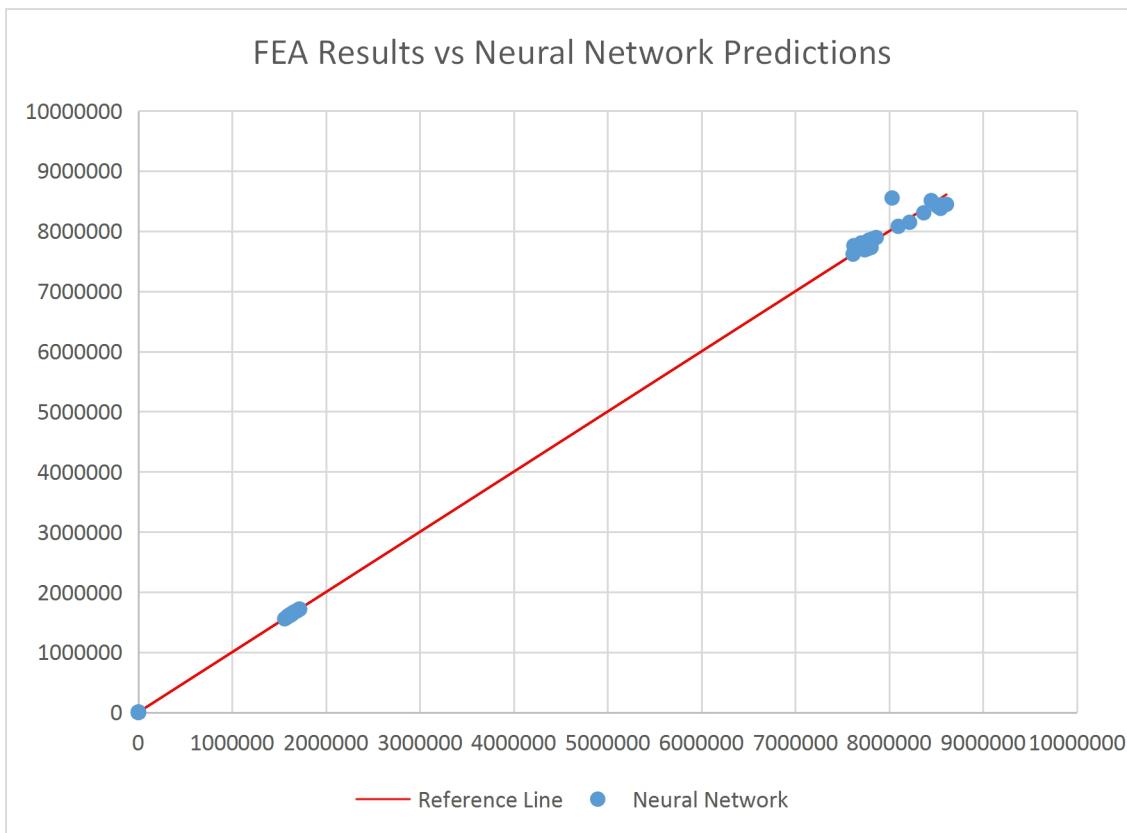
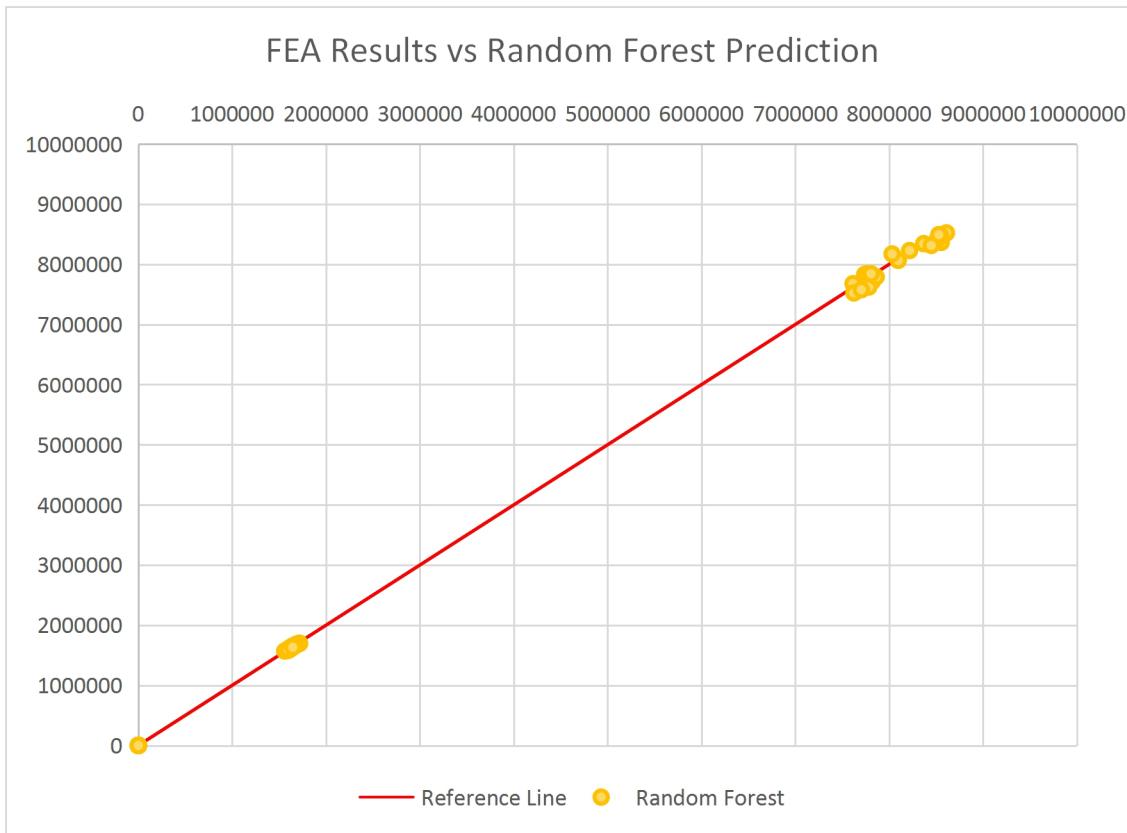
❖ Gráficos de la presión normal de la brida (diámetro exterior)

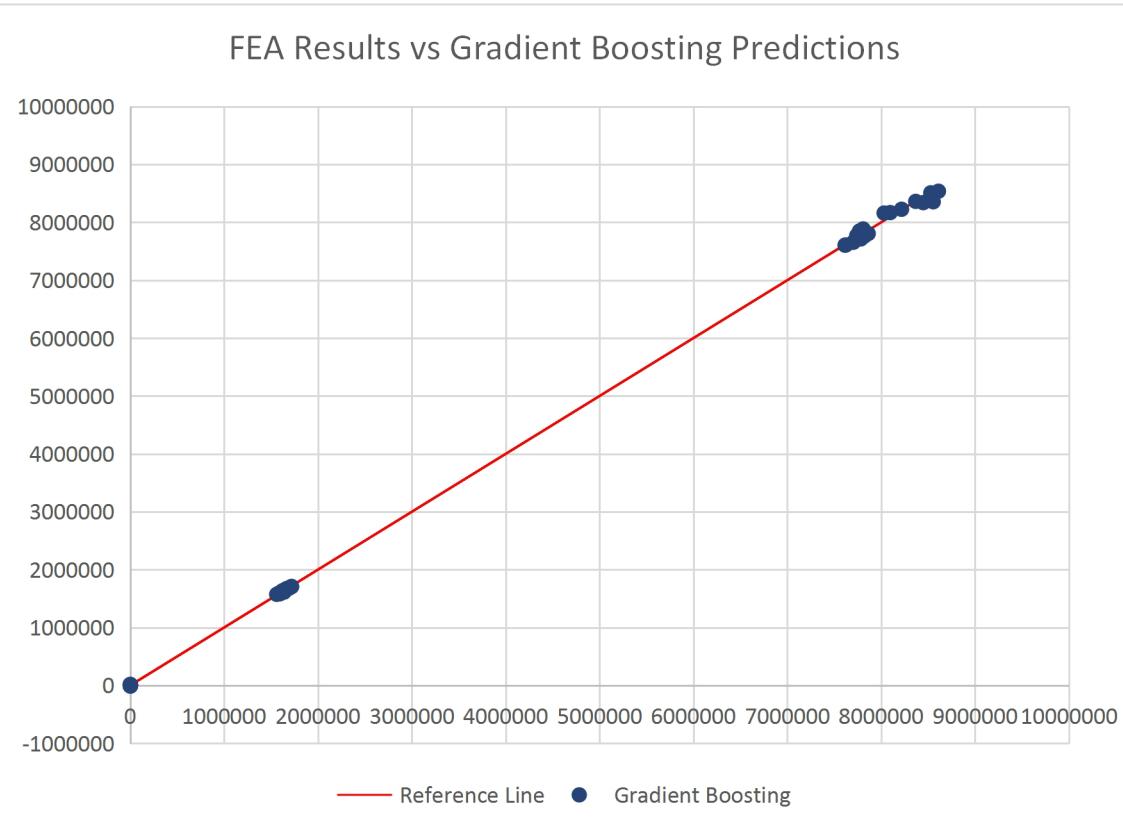
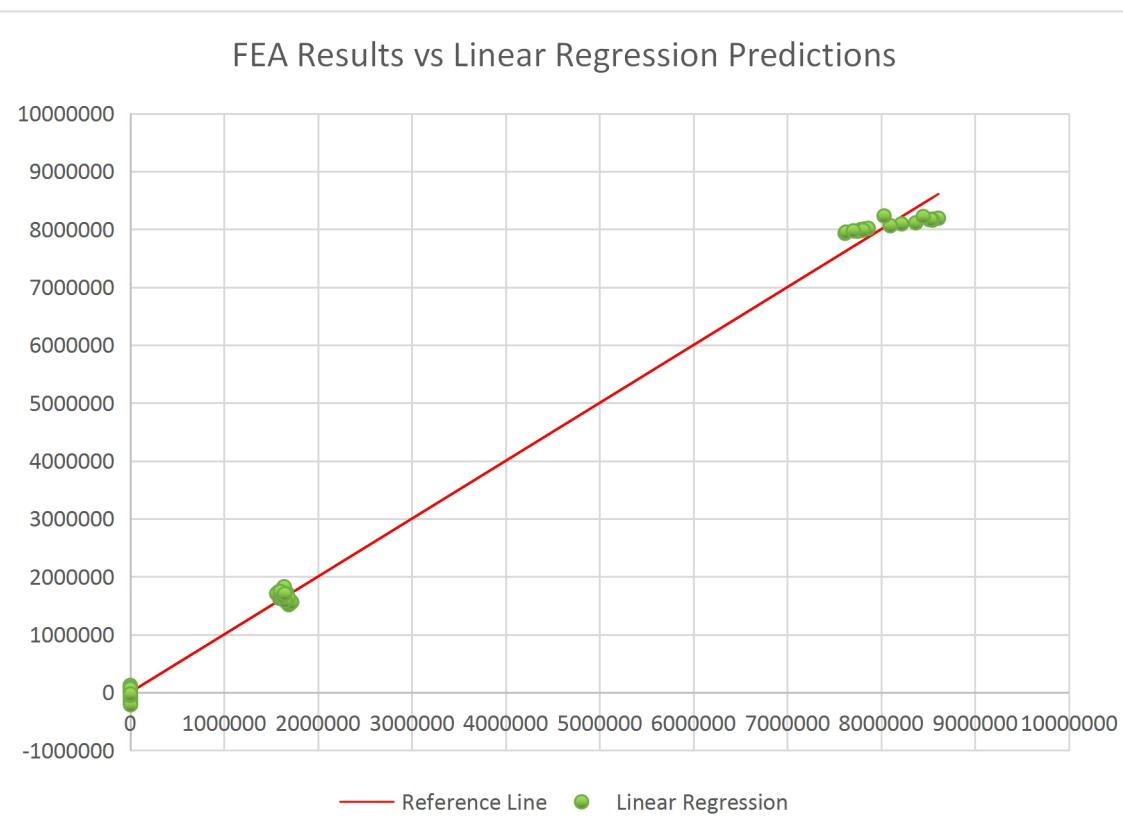


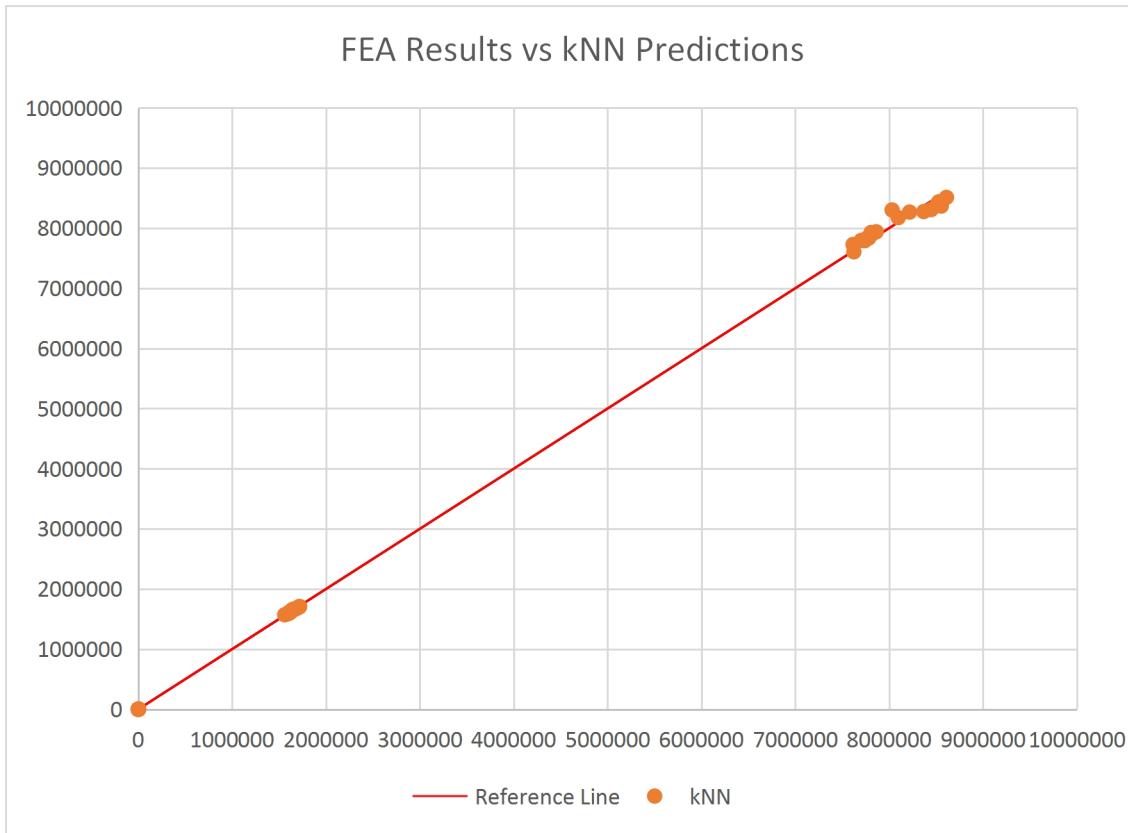
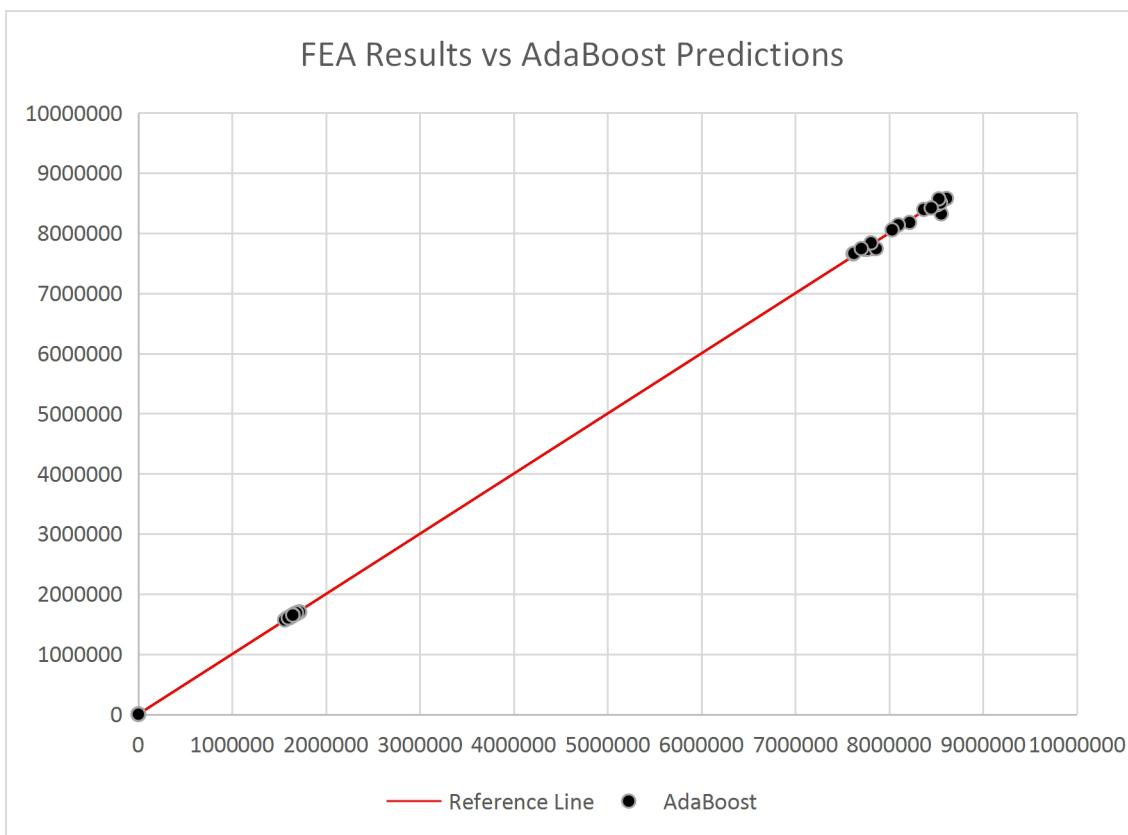




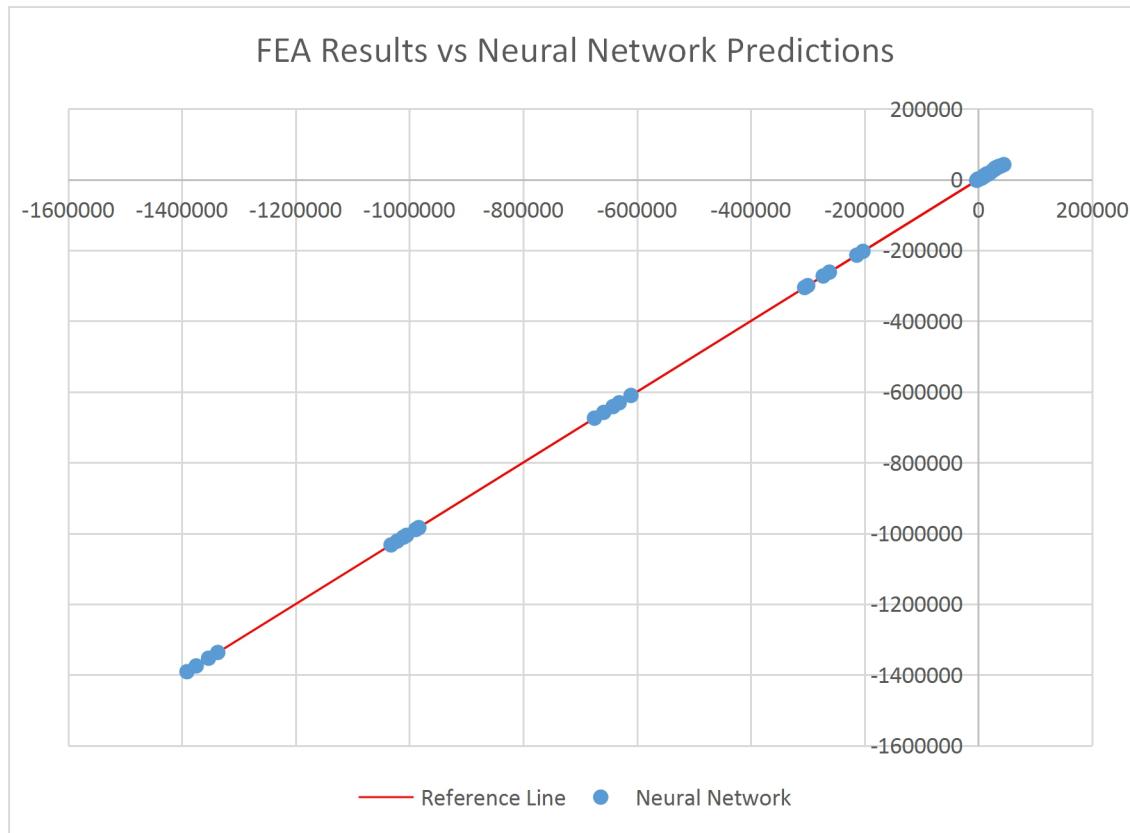
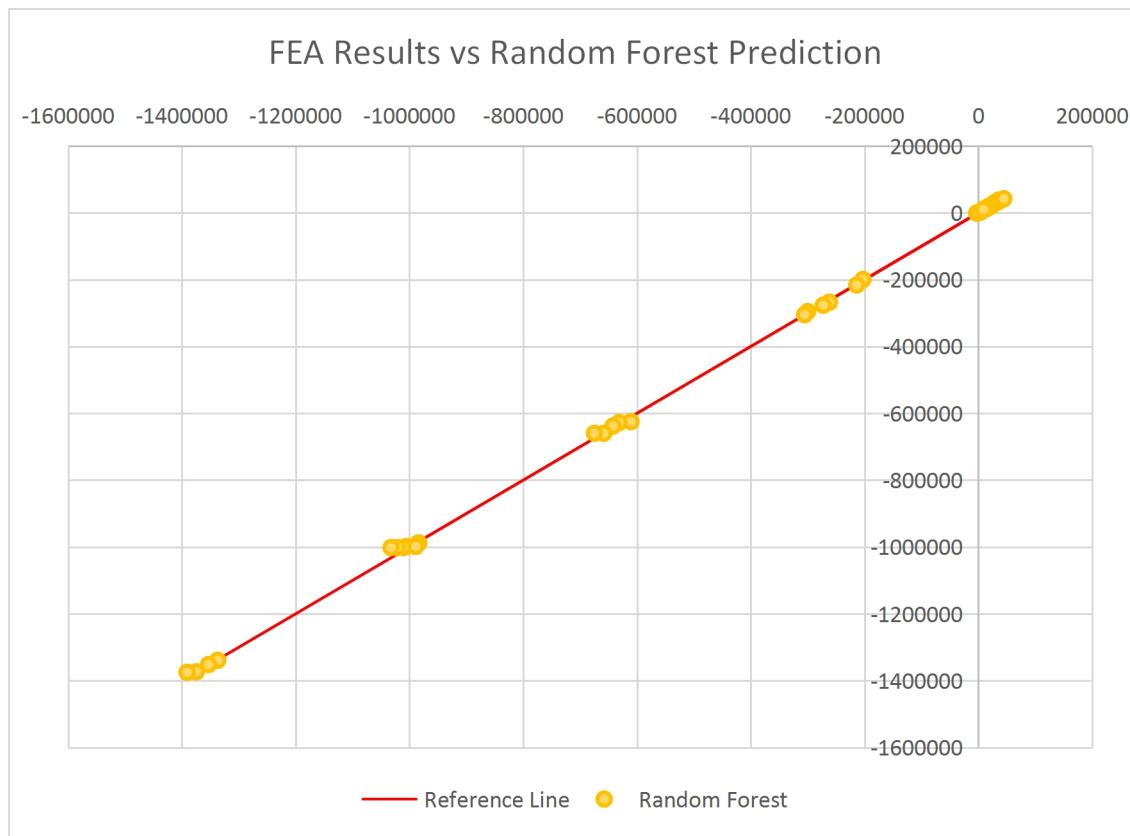
❖ Gráficos de la presión normal de la brida (centro)



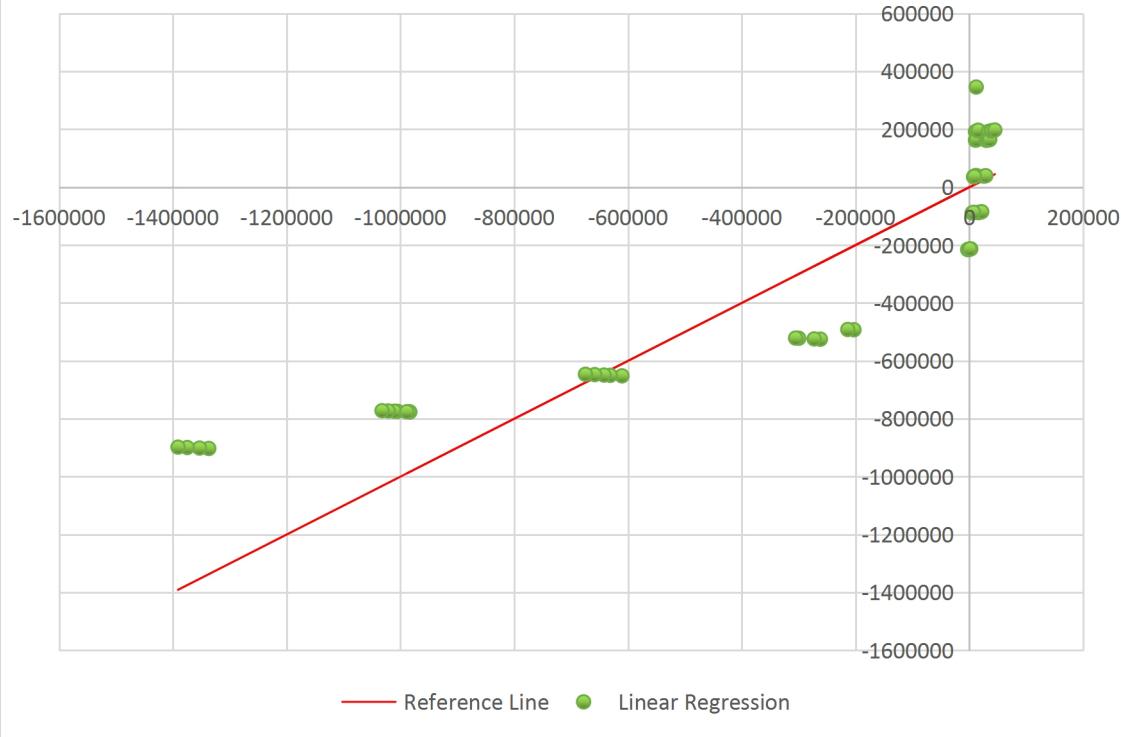




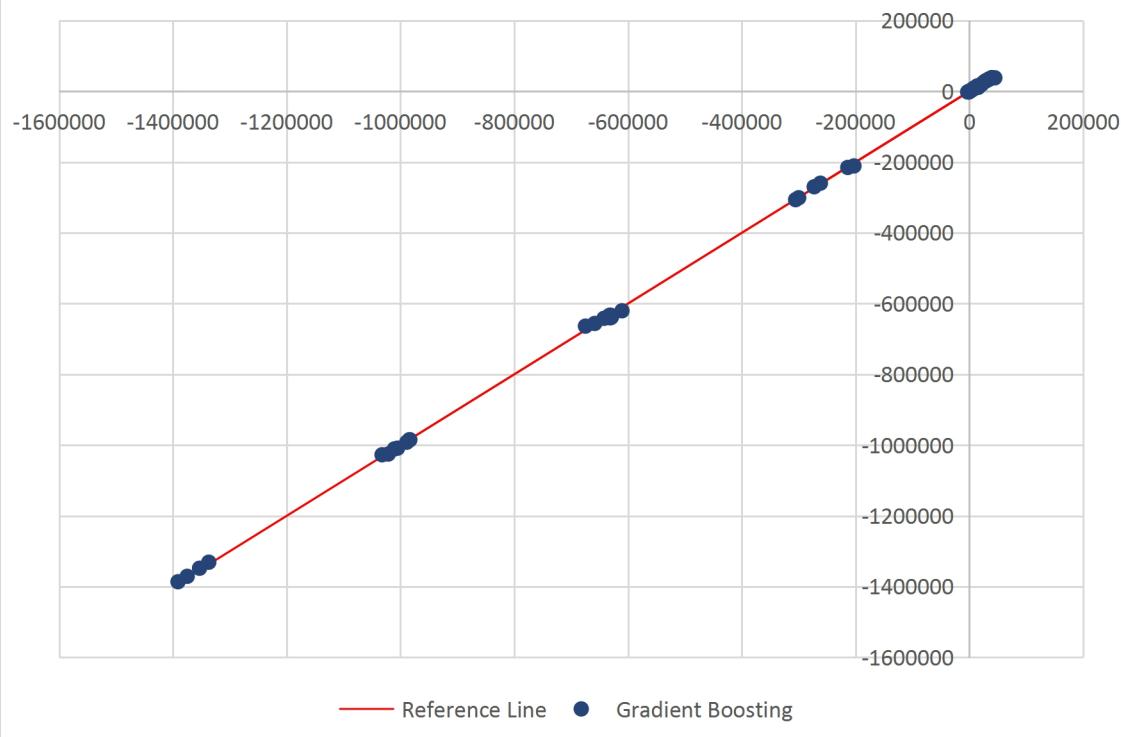
❖ Gráficos de la presión normal de la brida (interno)

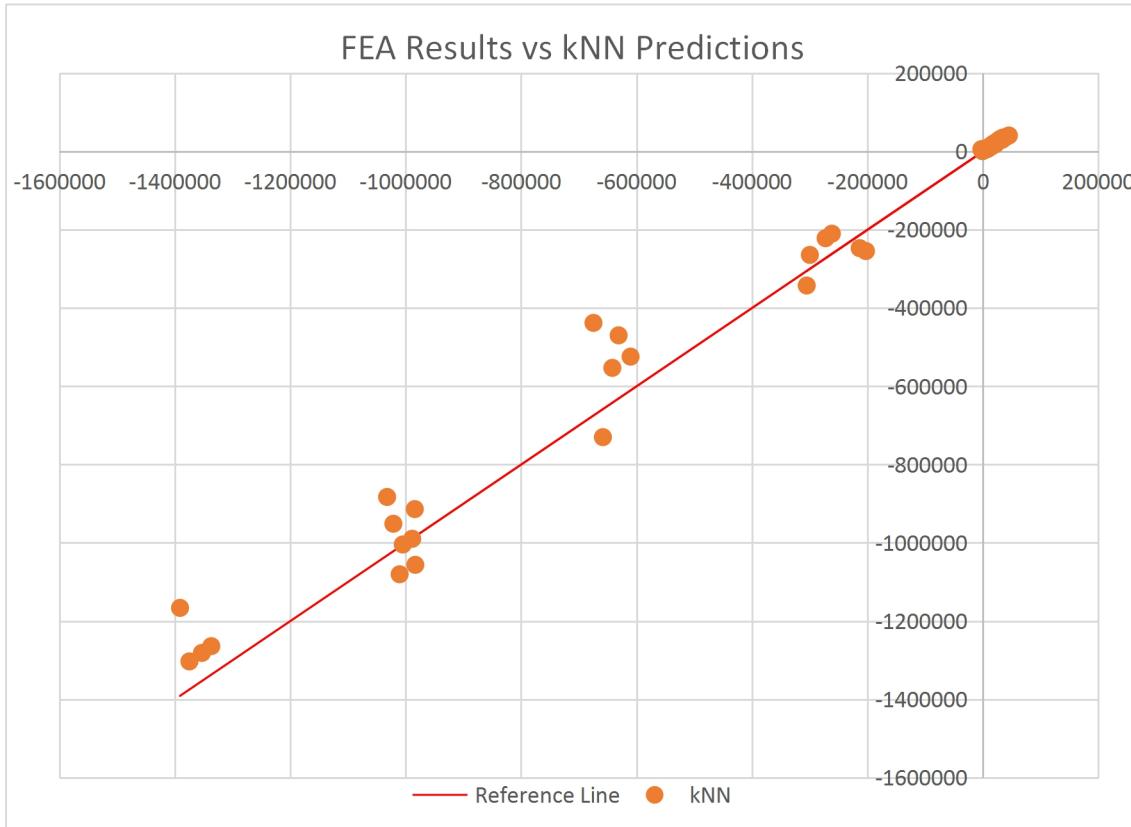
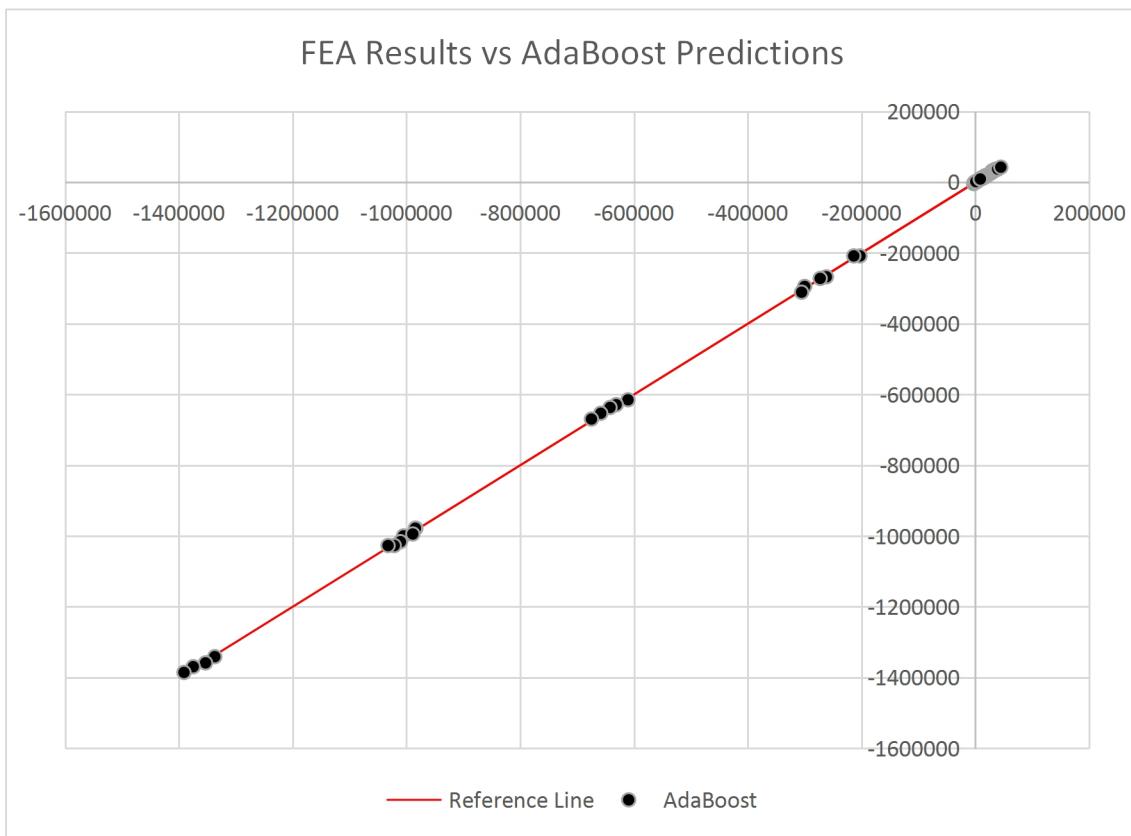


FEA Results vs Linear Regression Predictions

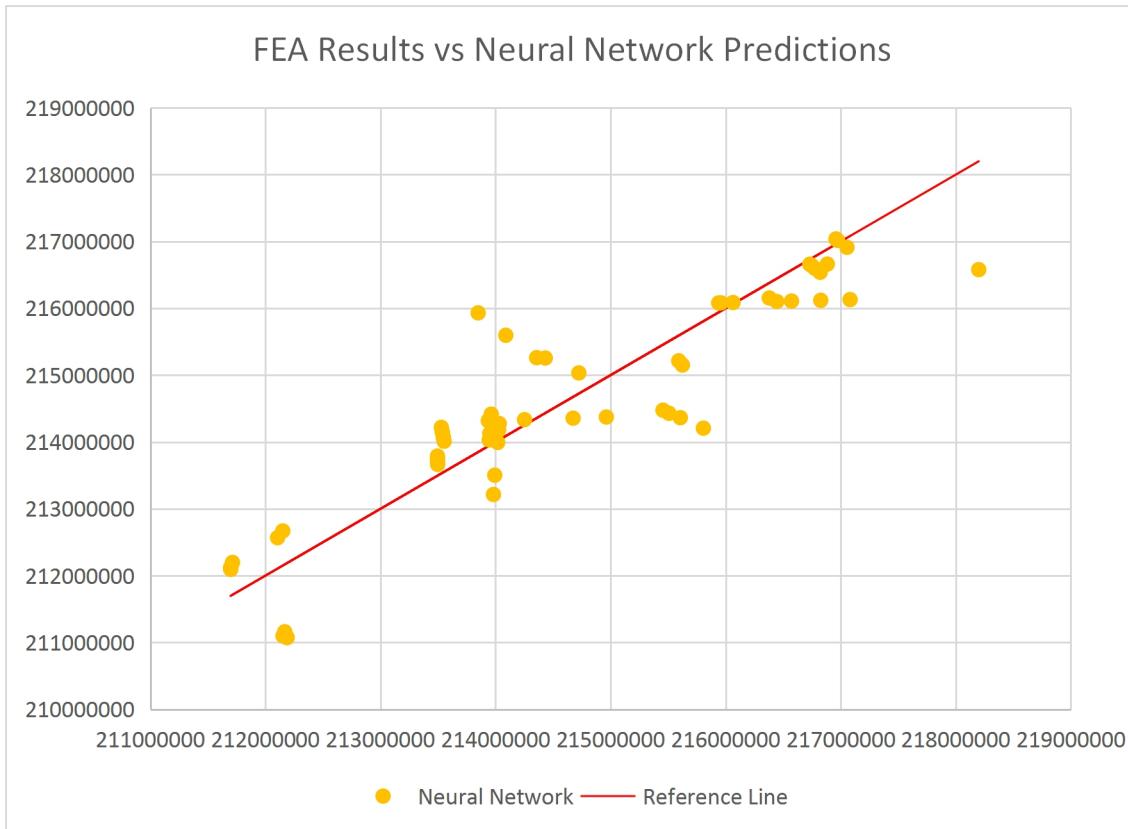
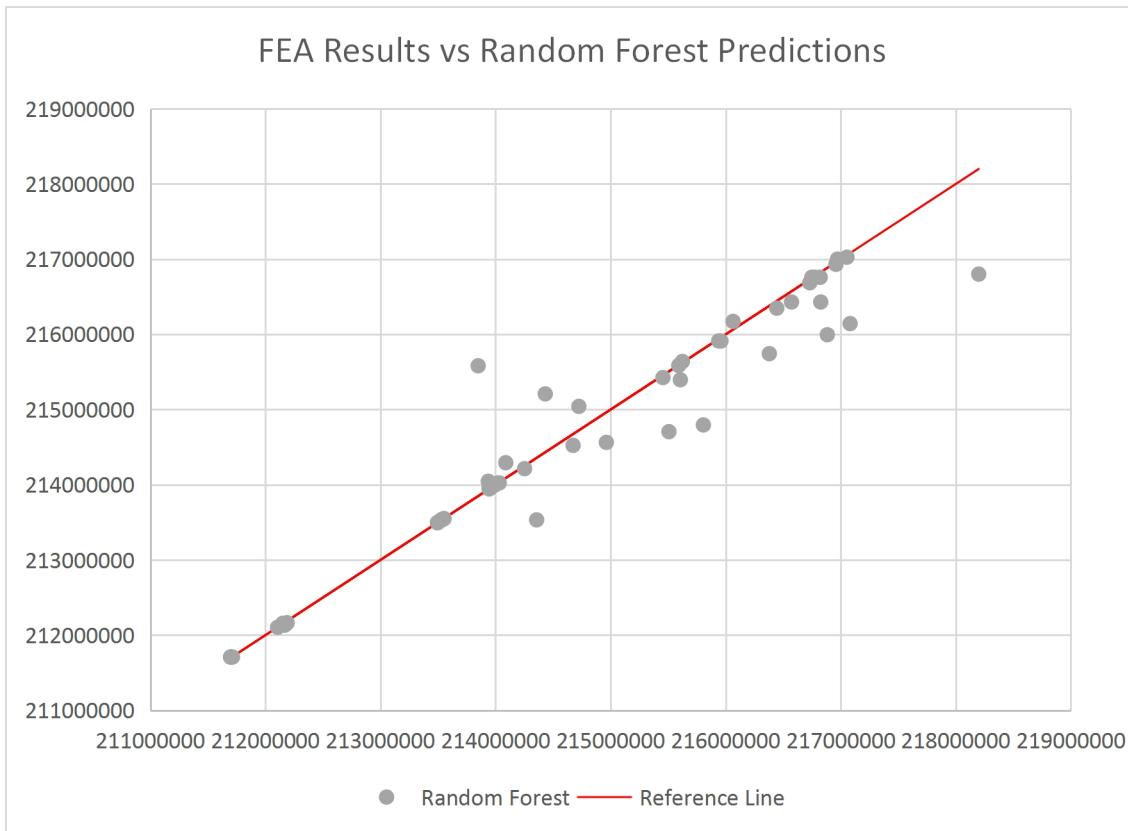


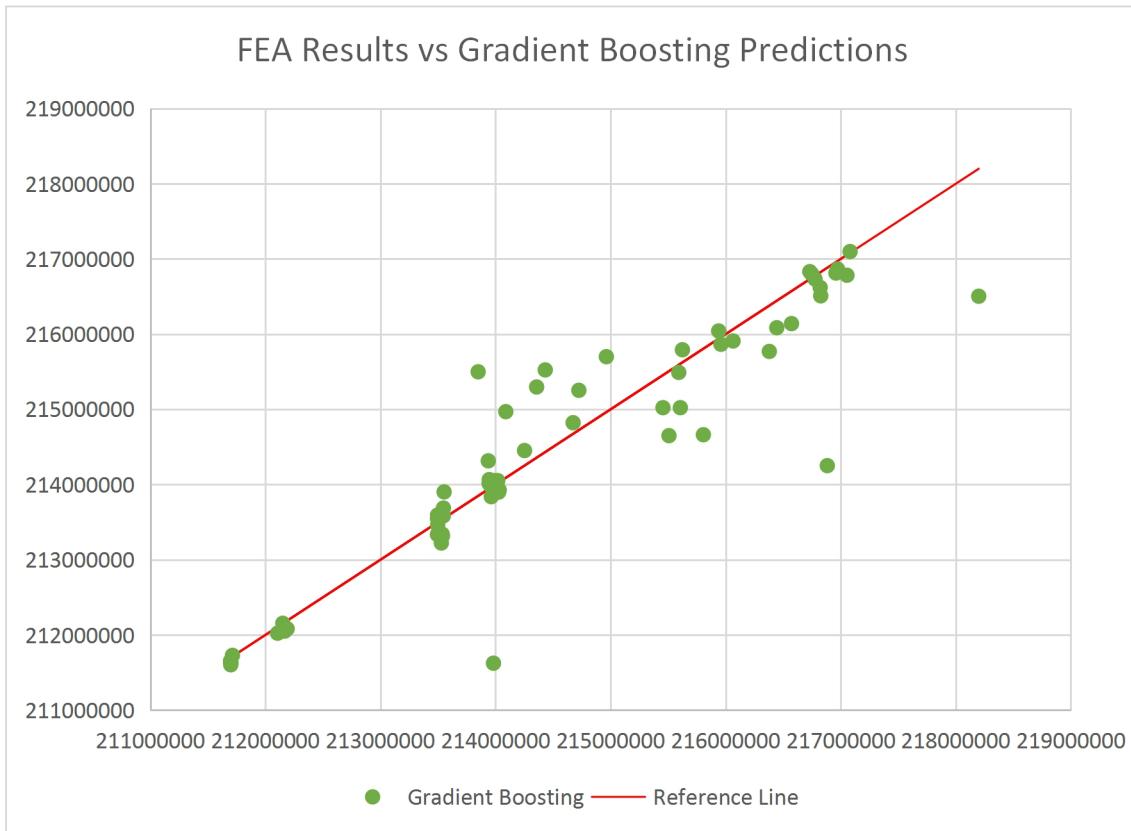
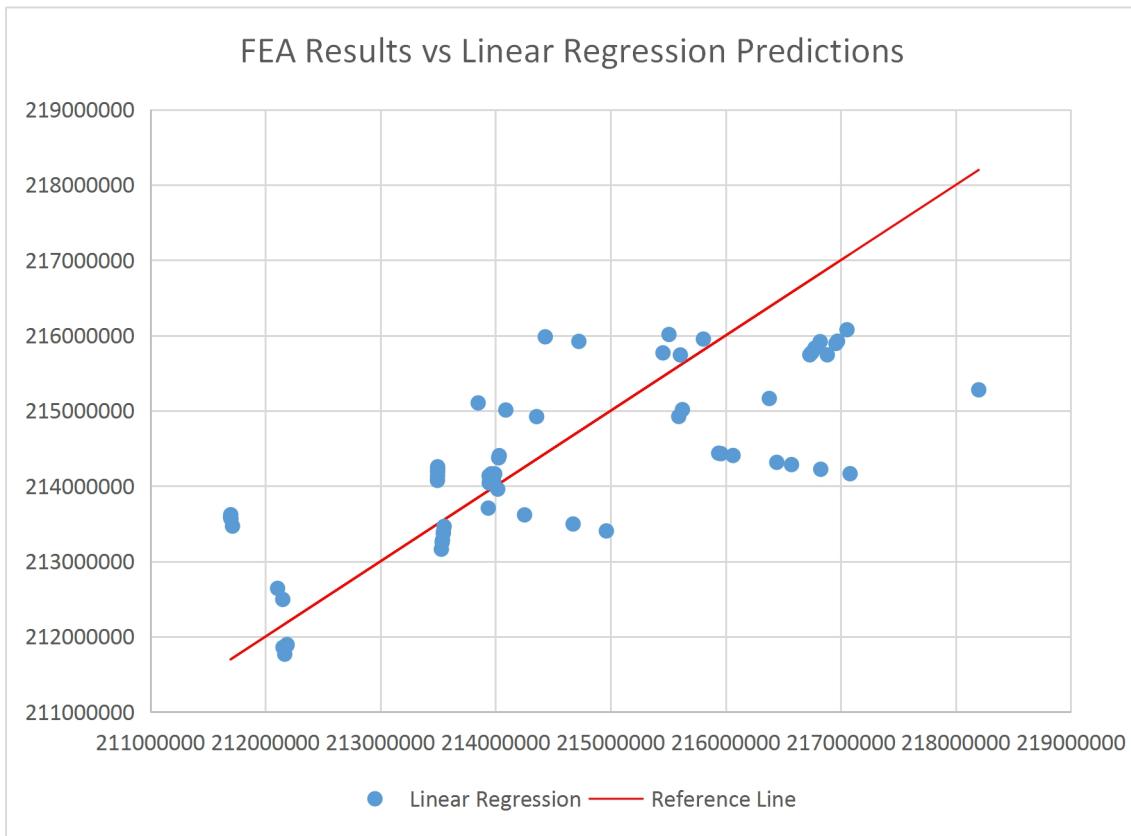
FEA Results vs Gradient Boosting Predictions

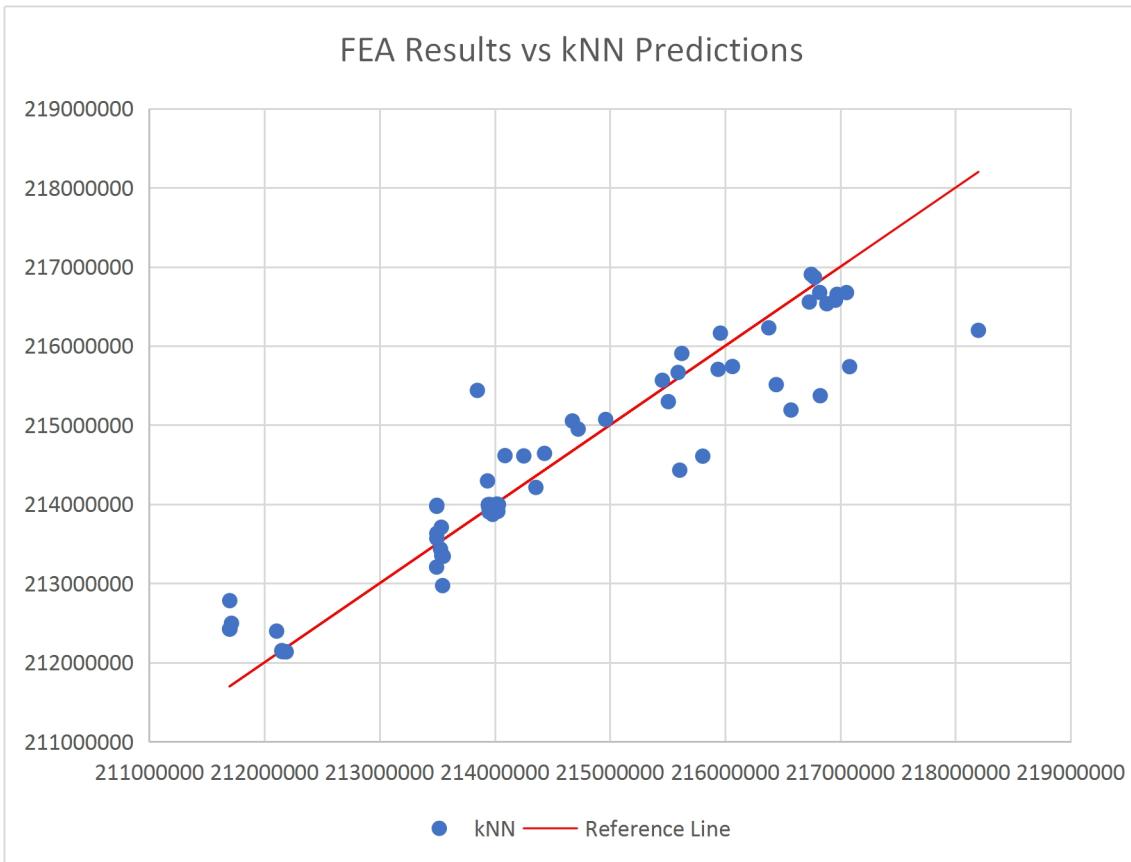
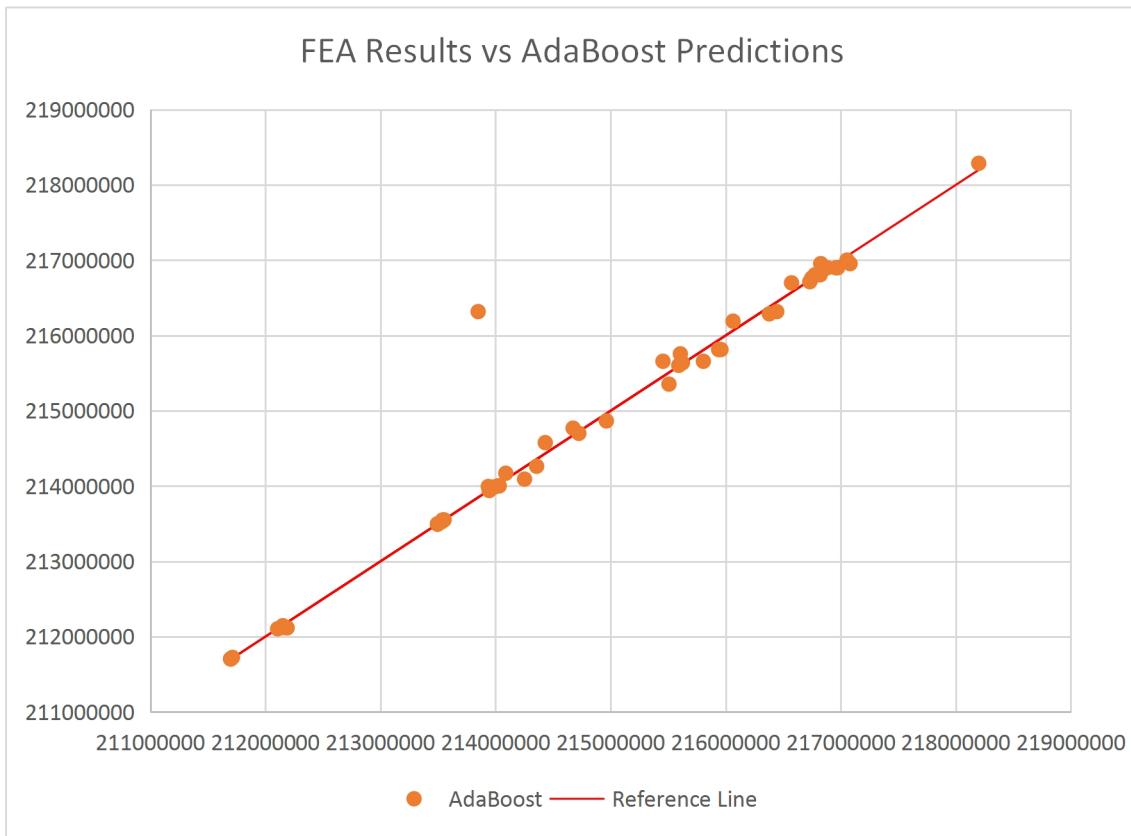




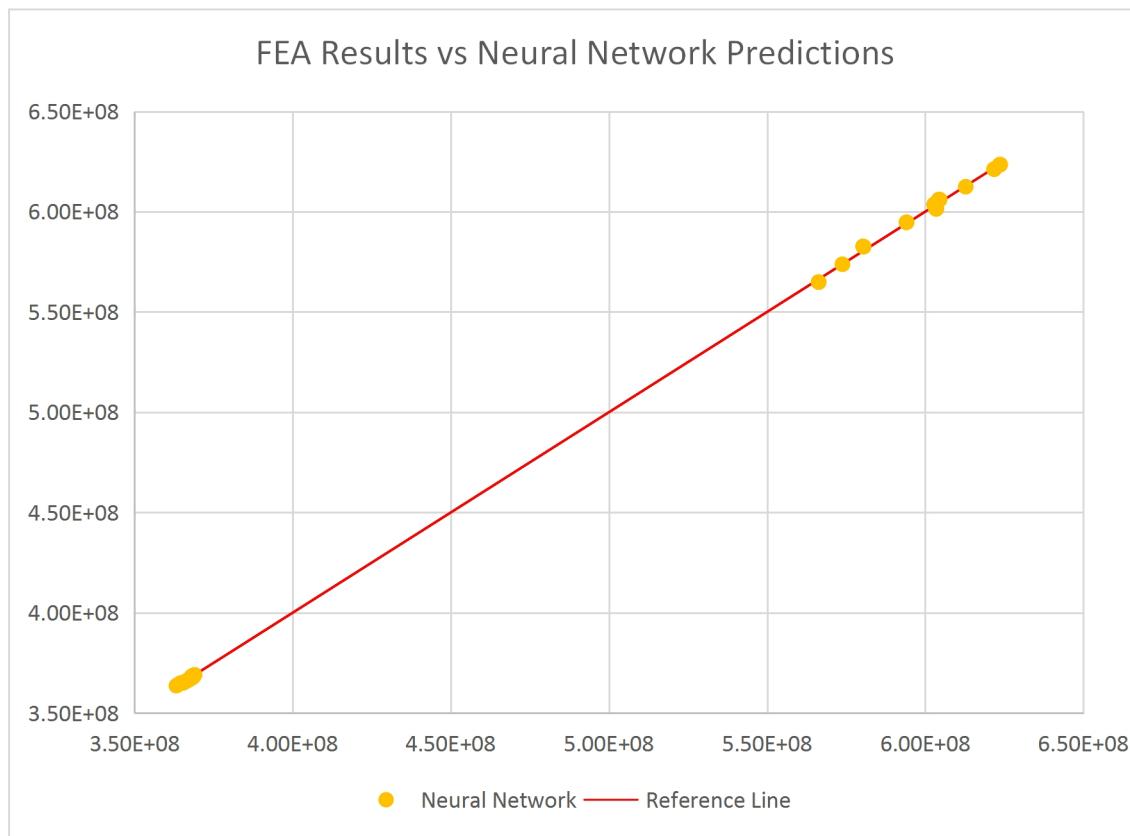
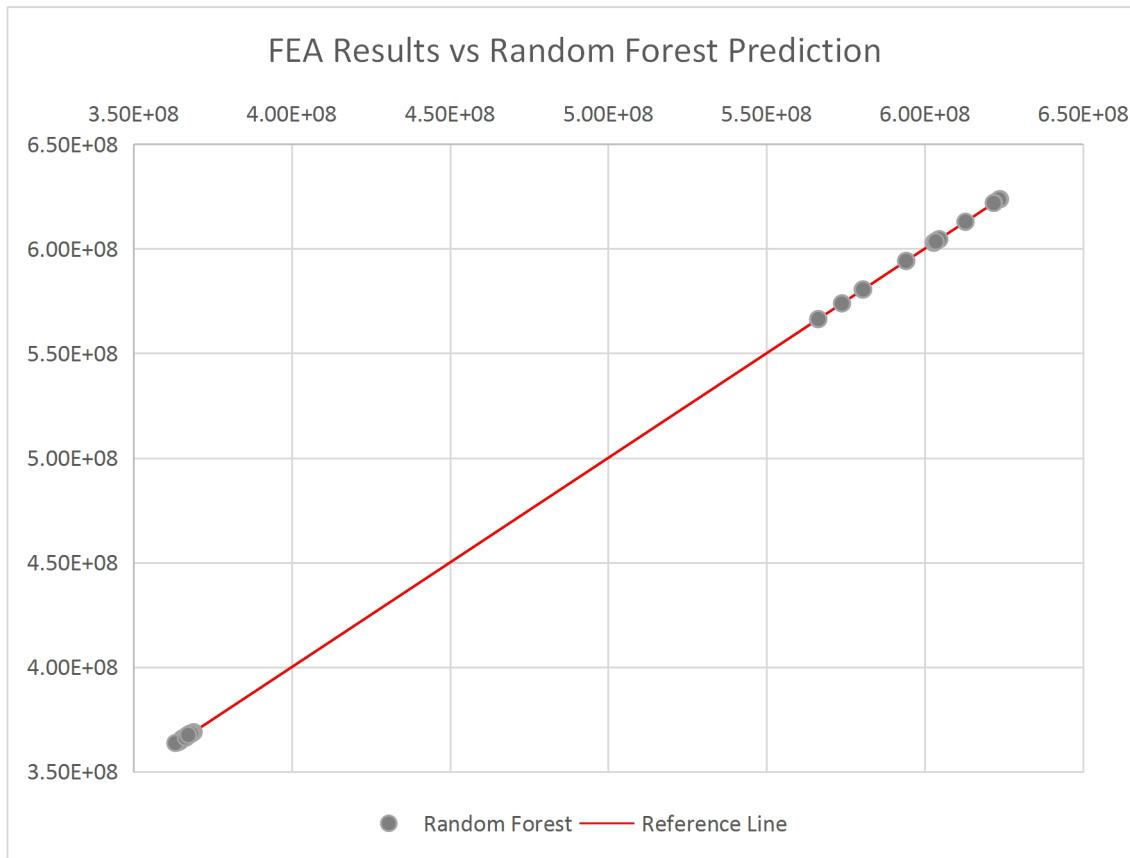
❖ Gráficos de las tensiones equivalentes Von Mises (la junta)

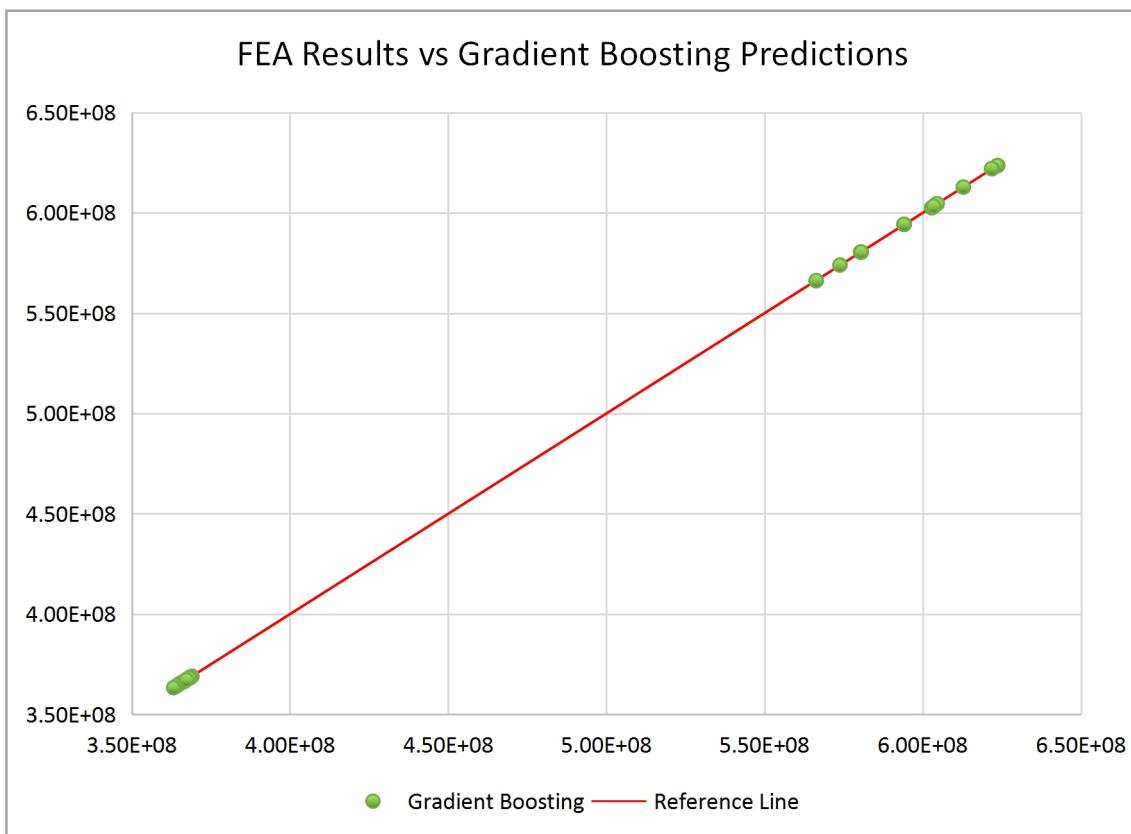
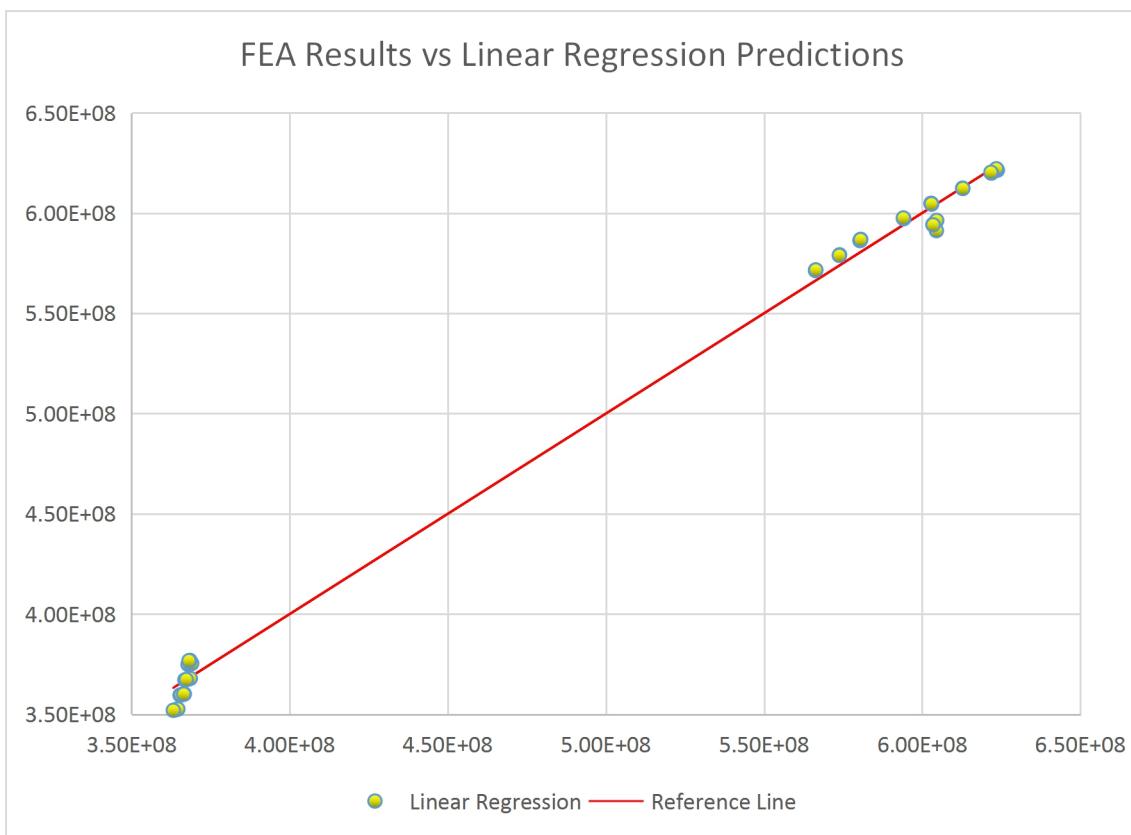


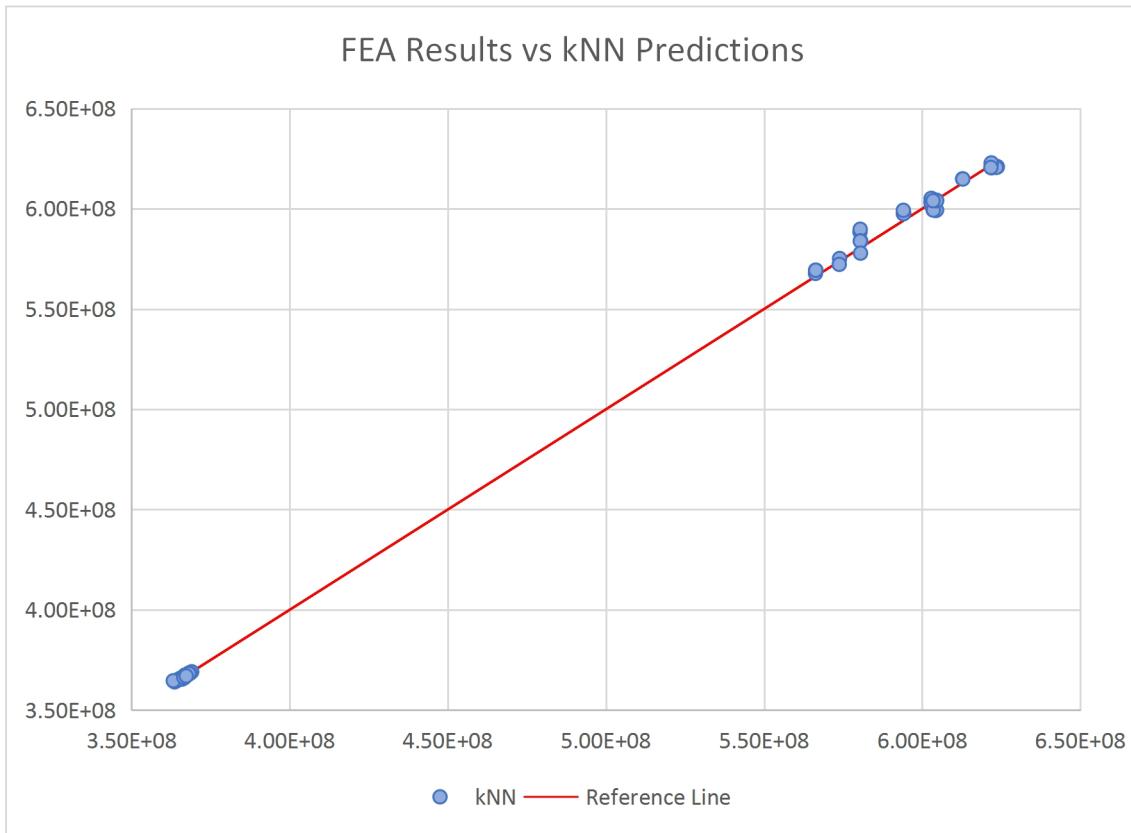
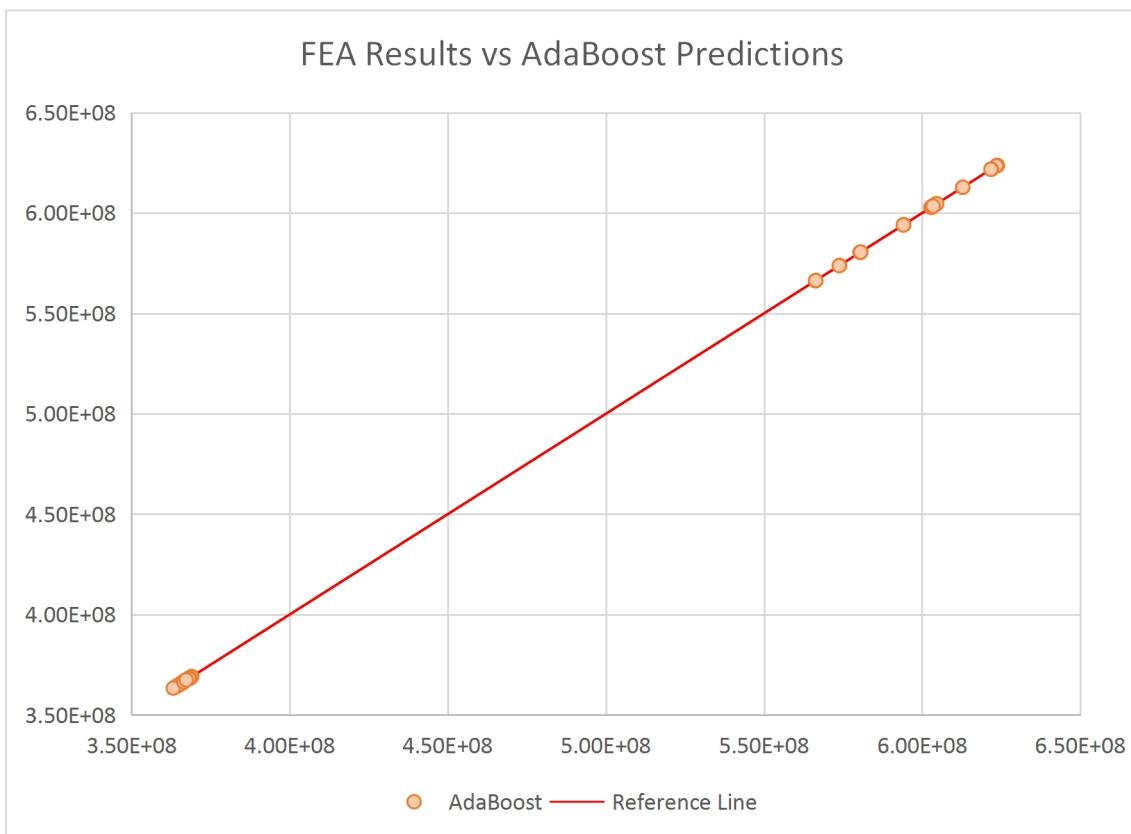




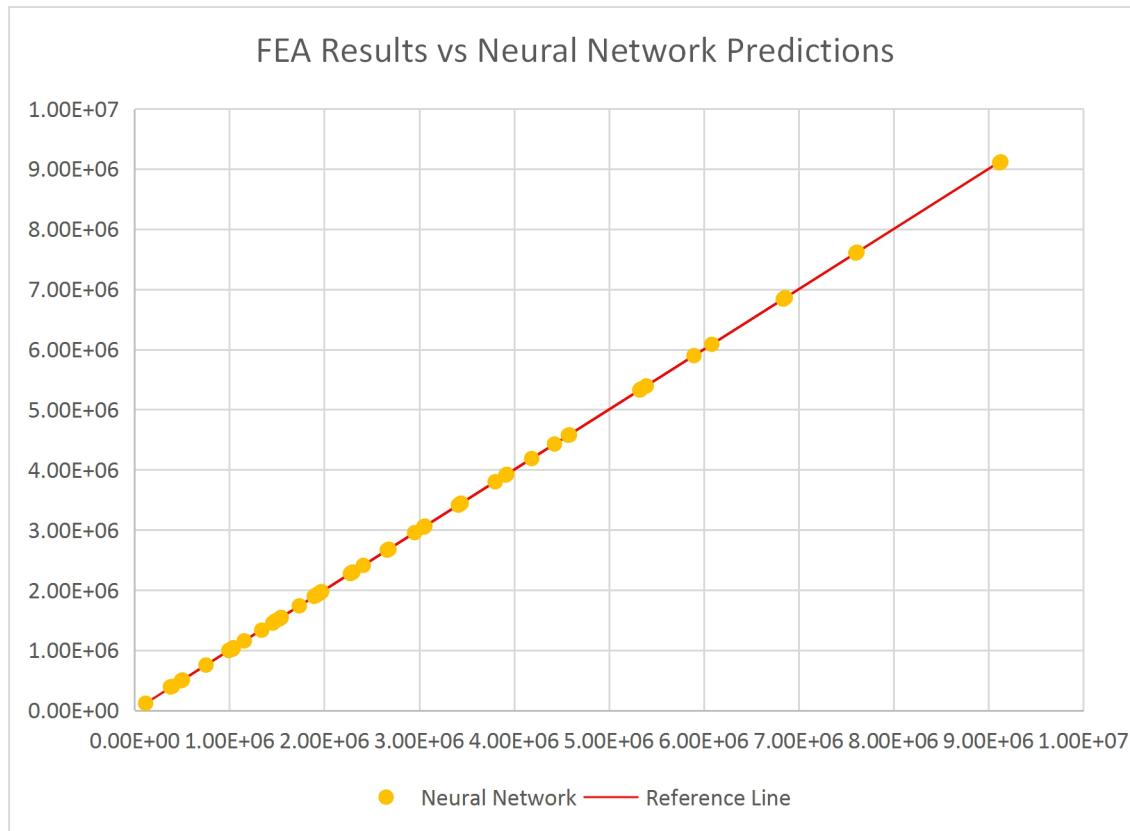
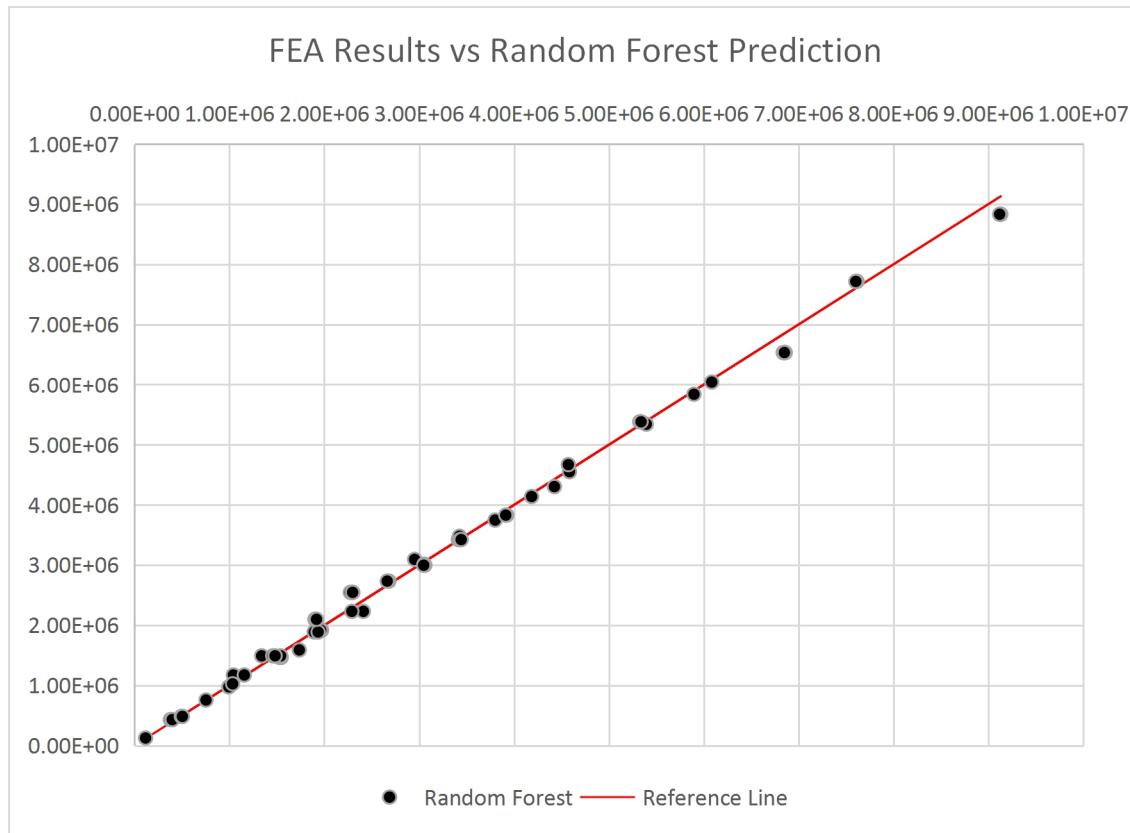
❖ Gráficos de las tensiones equivalentes Von Mises (el tornillo)

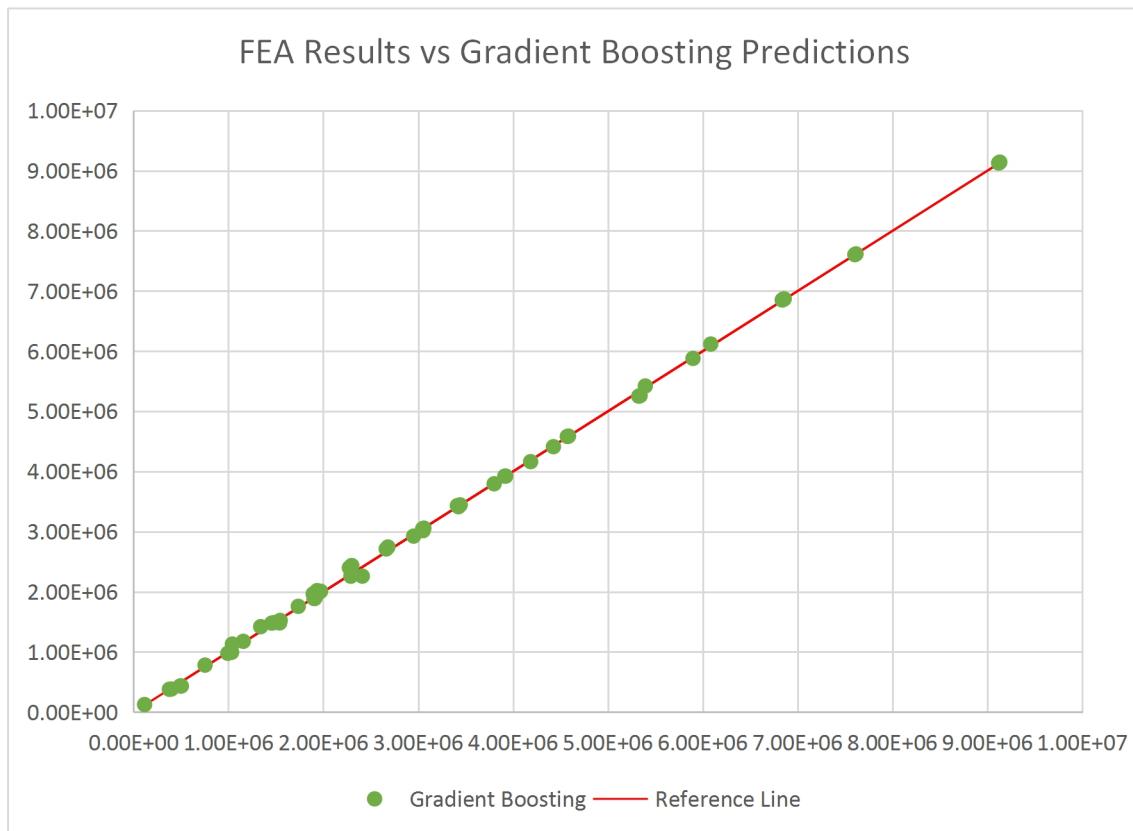
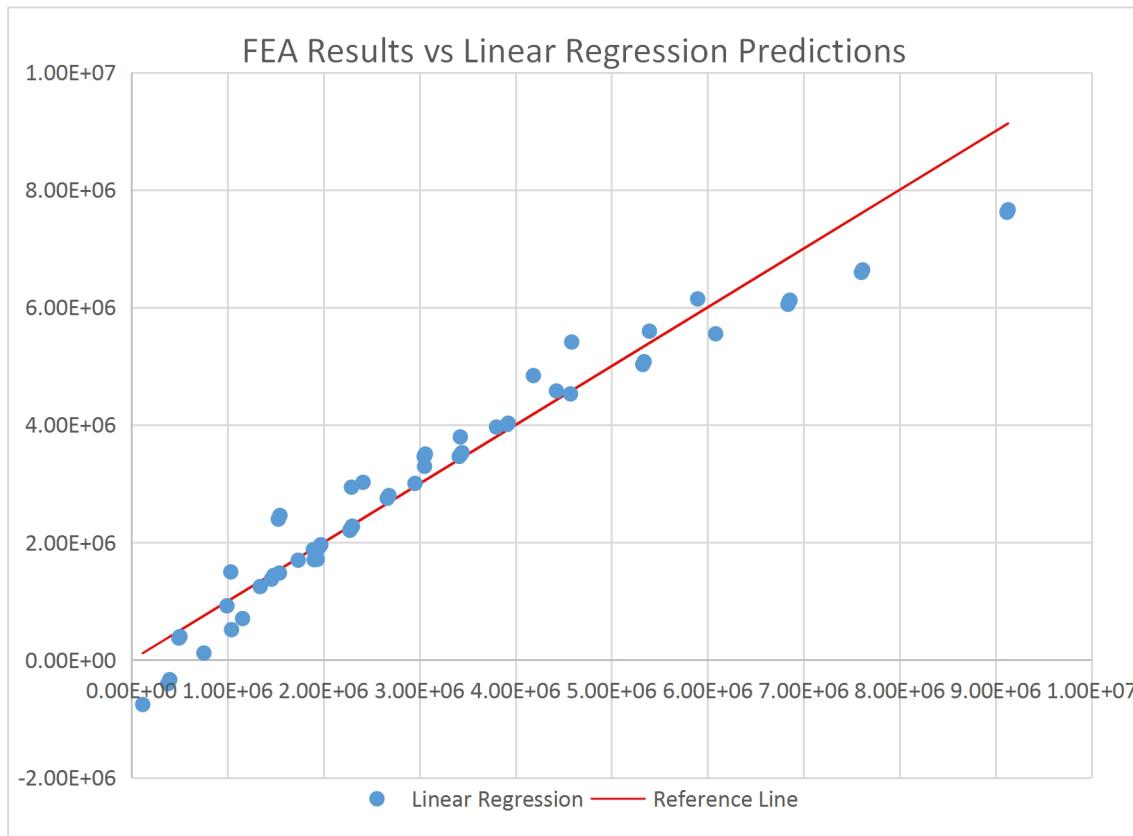


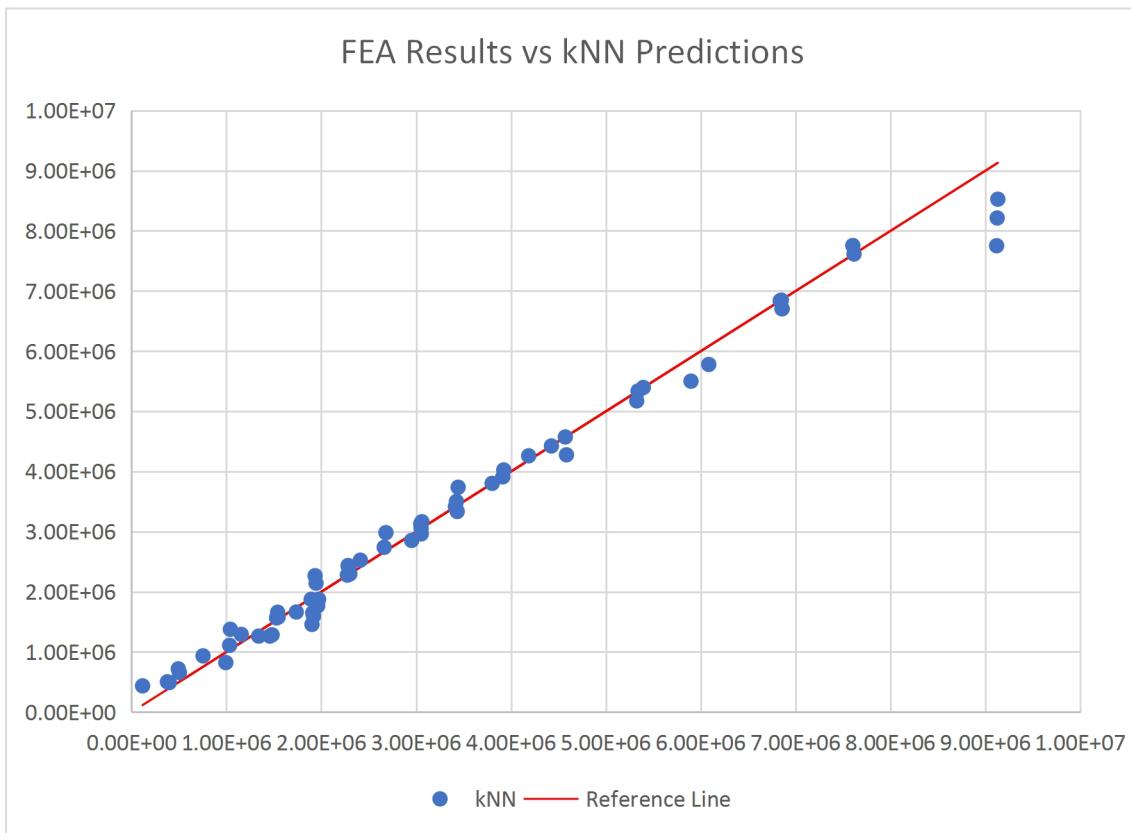
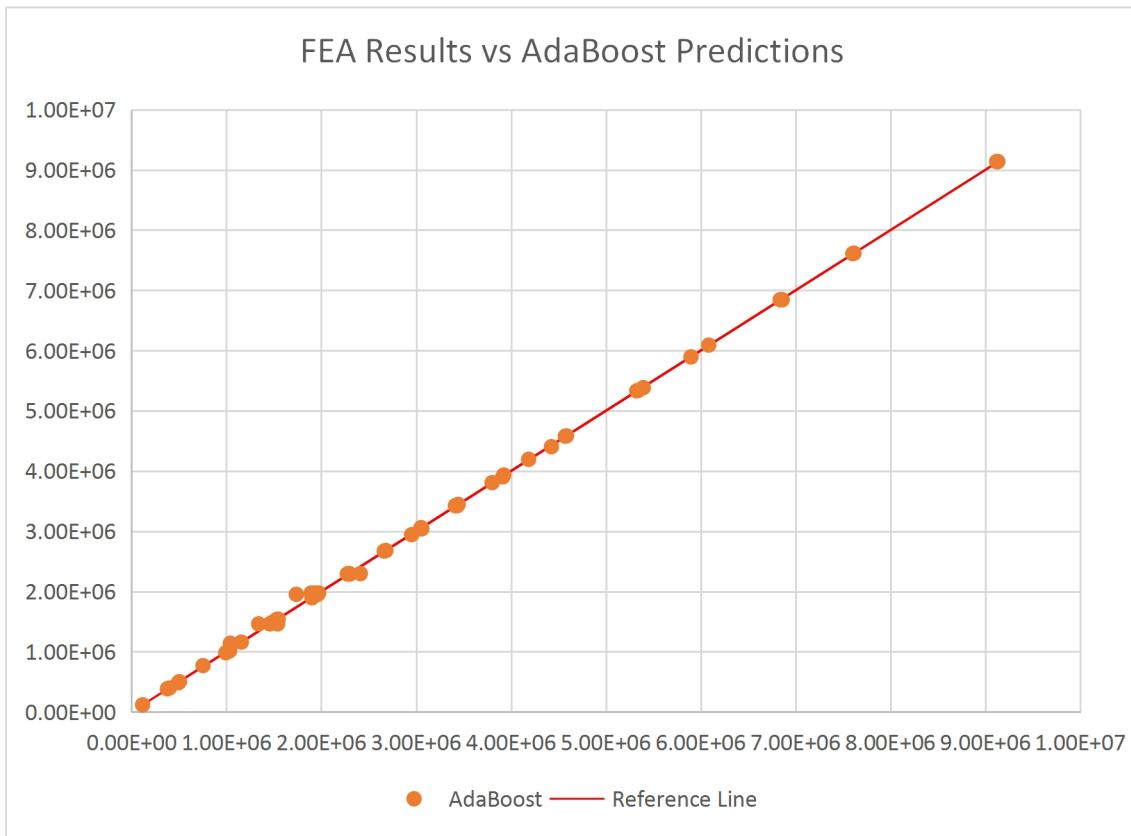




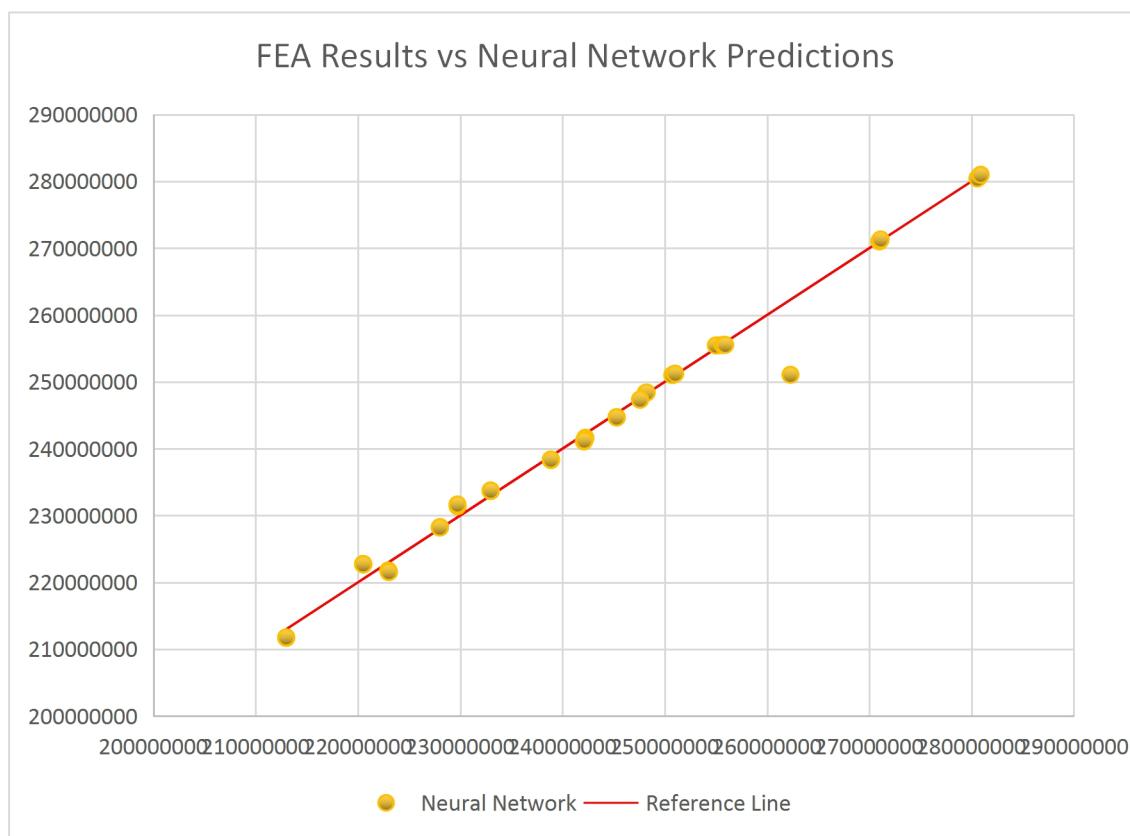
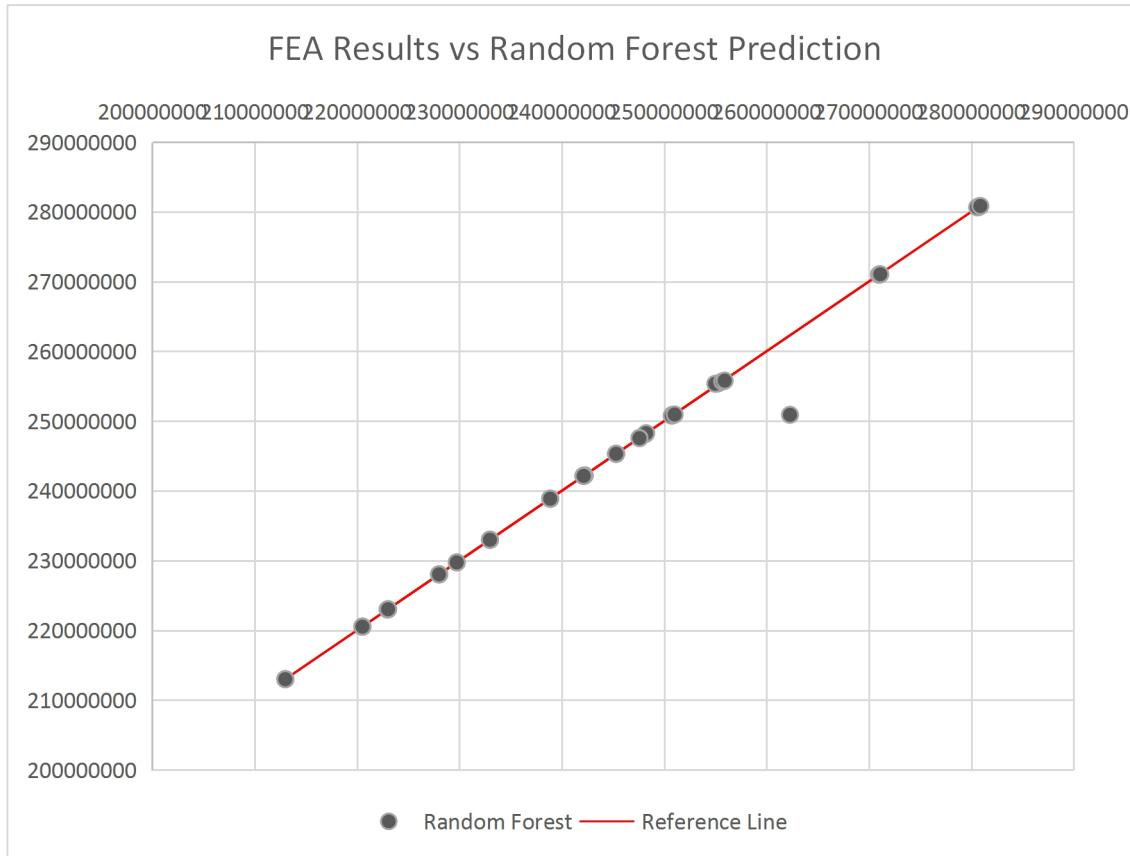
❖ Gráficos de las tensiones equivalentes Von Mises (la tubería)

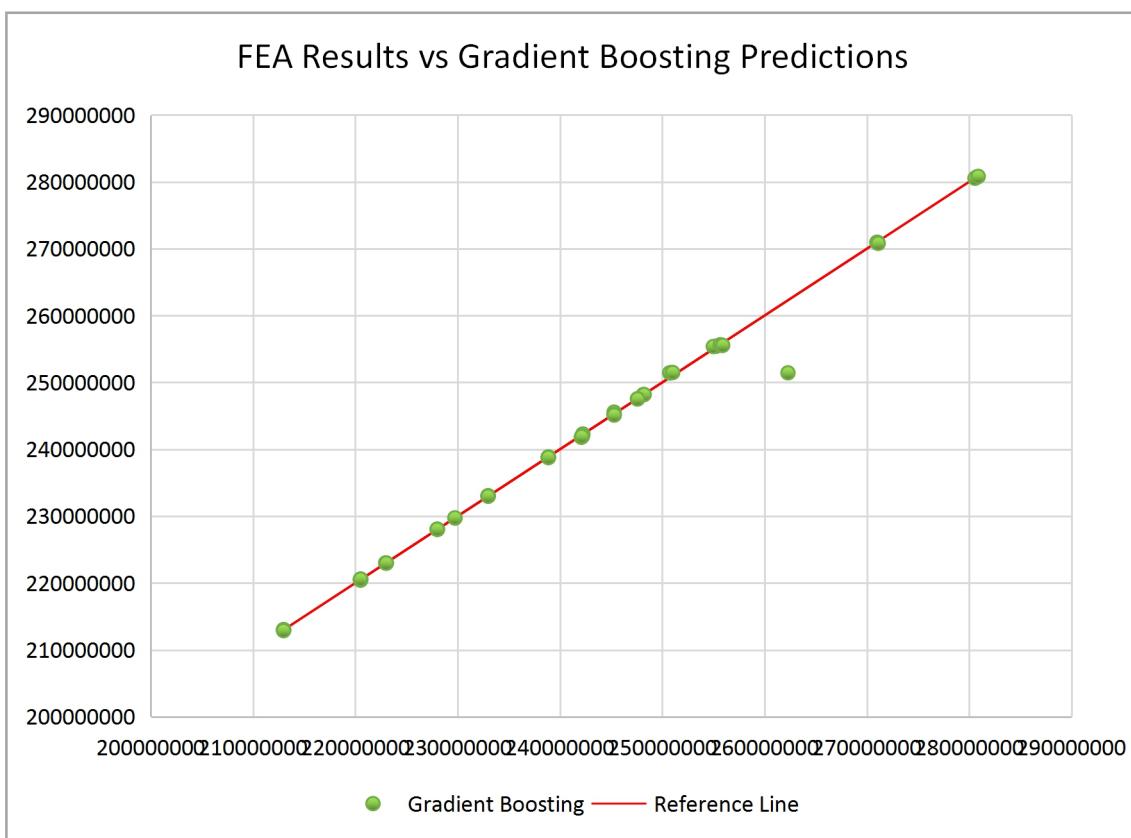
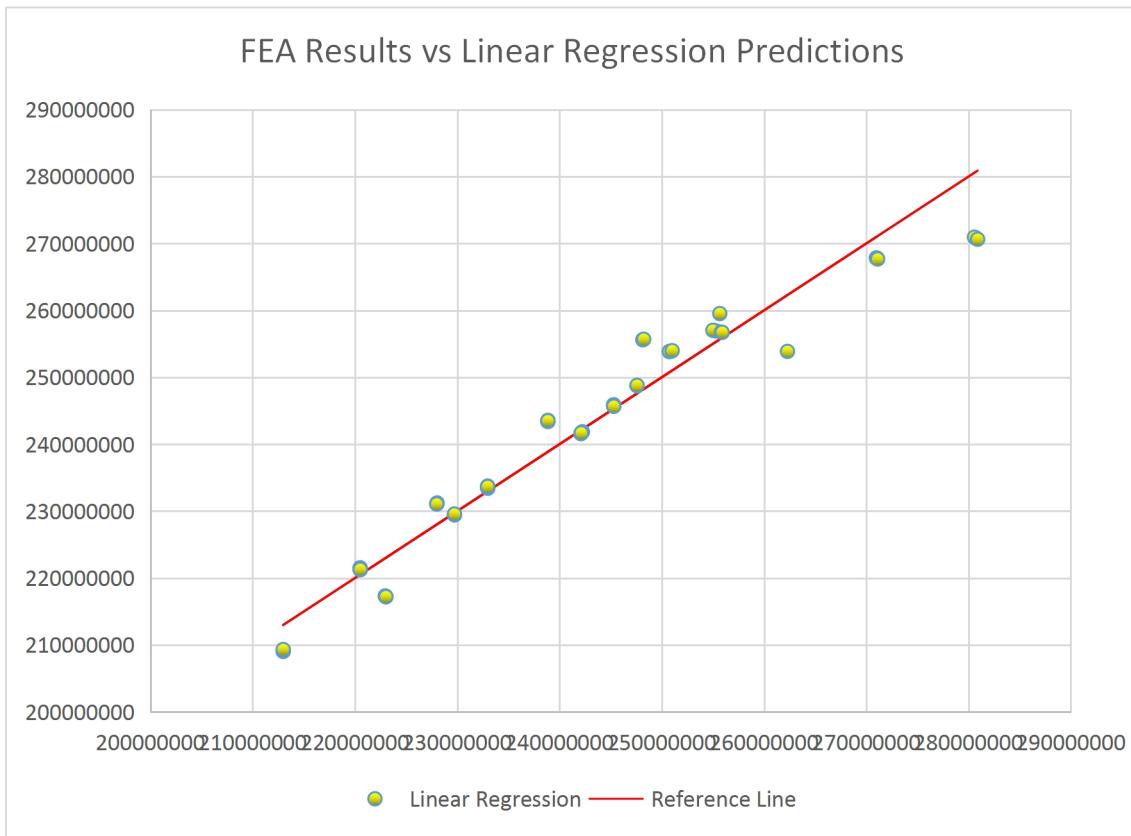


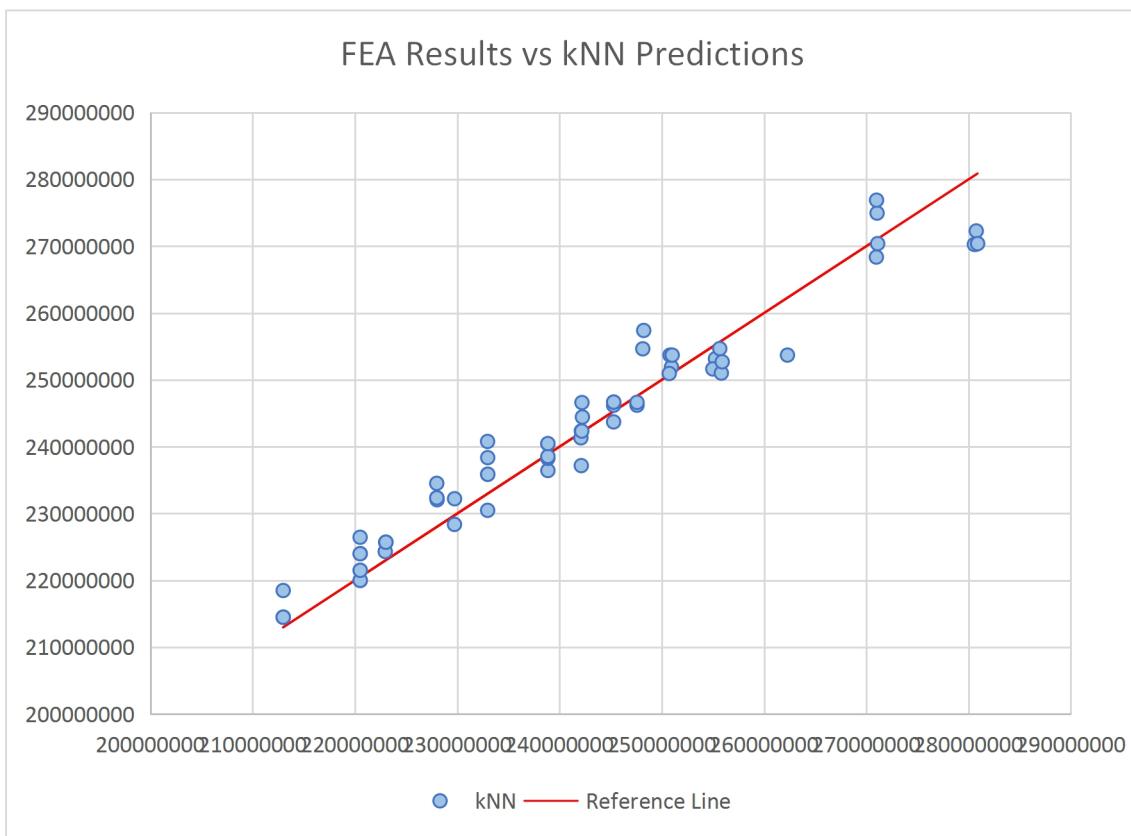
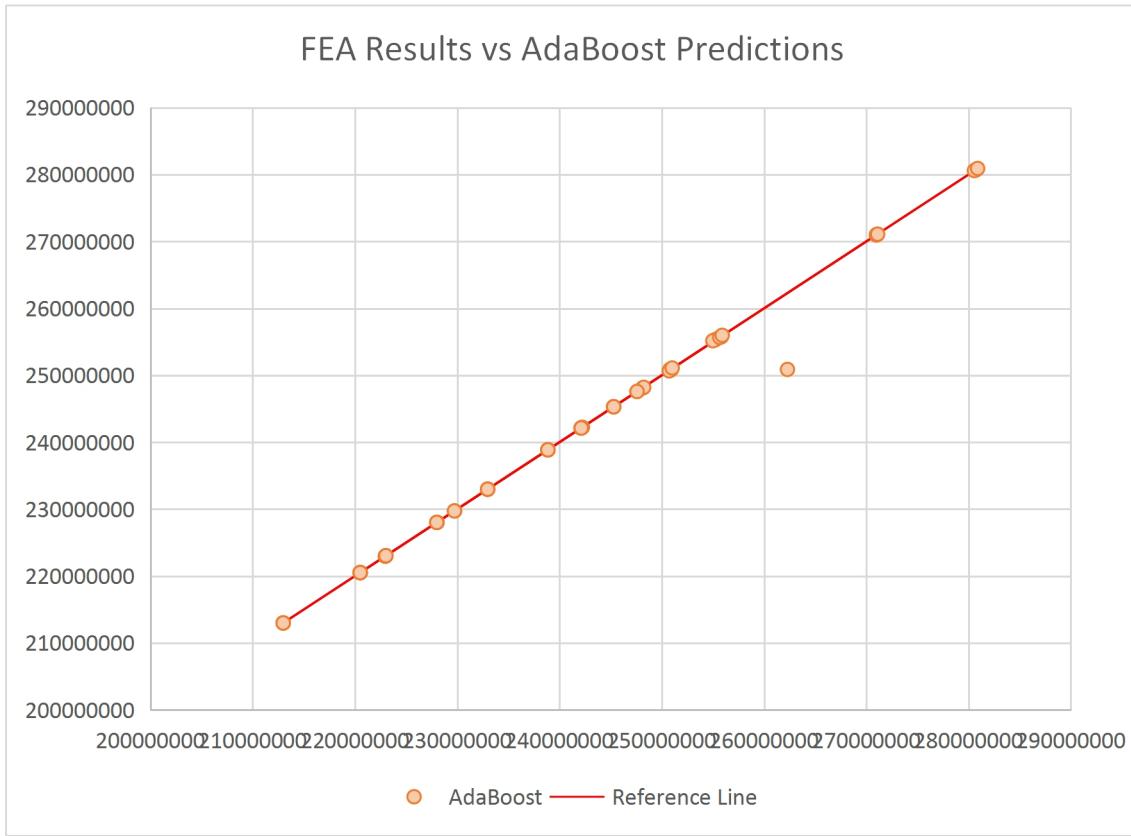




❖ Gráficos de las tensiones equivalentes Von Mises (la brida)









ANEXO C: Test and score Orange

Según la [13], las definiciones de los parámetros de resultados son:

- ❖ MSE = El promedio de los cuadrados de los errores o desviaciones, que es la diferencia entre el estimador y lo que se estima.
- ❖ RMSE = La raíz cuadrada de la media aritmética de los cuadrados de un conjunto de números que refleja la imperfección del estimador de los datos.
- ❖ MAE = La medición que refleja la proximidad entre los predicciones de los resultados finales.
- ❖ R^2 = La proporción de la varianza en la variable dependiente que es predecible a partir de la variable independiente.

A continuación, se muestran los resultados de “test and score” de cada variables de salidas según el modelo aprendizaje automático correspondiente. Cuanto más se acerque la puntuación R^2 a 1, mejores serán el modelo.

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	3592294061271.113	1895334.8150844253	1190577.4222184562	0.9879307241810625
Random Forest	9192323046.504314	95876.60322781734	63433.39122378968	0.9999691159241496
Neural Network	2302281653285.5933	1517327.1411549961	1194028.9567364492	0.9922648670146589
Linear Regression	11107602835854.492	3332807.050498797	2663414.2222044435	0.9626810277703984
Gradient Boosting	14621958272.408089	120921.2895746985	99642.45943640574	0.9999508736076744
AdaBoost	3331868260.5745306	57722.33762222846	49283.68253971376	0.9999888056945385

outer normal stress

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	4070204935.850882	63798.15777787696	33110.872191220245	0.9996498367398328
Random Forest	2993803350.841518	54715.65910085995	29372.631303318227	0.999742440501608
Neural Network	6776715426.90708	82320.8079825938	32673.75617878778	0.9994169932952982
Linear Regression	31825743441.953156	178397.71142577237	148212.50723896374	0.9972620036935435
Gradient Boosting	2032414768.995773	45082.31104319934	24512.333489852957	0.9998251495949859
AdaBoost	1543163680.8141148	39283.12208587951	18333.994543650853	0.9998672402903632

centre normal stress

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	3541512003.478118	59510.60412630776	29448.41231422307	0.9823004606374789
Random Forest	39149687.40152967	6256.971104418629	3227.6647483178776	0.9998043402274189
Neural Network	855422.8085435296	924.8907008633666	712.9158675995783	0.9999957248232798
Linear Regression	41120999776.96629	202783.13484352265	169241.78362171876	0.7944881300800781
Gradient Boosting	9329965.245841658	3054.4991808546383	1901.019602349024	0.9999533713038505
AdaBoost	10053174.15010928	3170.6740844983233	2358.2838271643895	0.9999497568972198

inner normal stress

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	346609207829.01074	588735.2612414266	383373.7165332995	0.8751687940564974
Random Forest	167878320295.2544	409729.56971062557	186198.37179880624	0.9395386715041787
Neural Network	468951178119.2002	684800.1008463713	525812.9823486431	0.8311073688436895
Linear Regression	1275375742776.2712	1129325.3485051468	863889.5073797291	0.5406737951393599
Gradient Boosting	413869060446.3021	643326.5581695676	359748.88770070294	0.8509451775911763
AdaBoost	102391807023.83551	319987.1982186717	90415.62709093046	0.9631236203170193

vm gasket

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	77279579798.40945	277992.04988346243	170191.65540308546	0.9855360665186692
Random Forest	20338444317.217136	142612.9177782193	104016.24949089636	0.9961933811430477
Neural Network	19923209.39622234	4463.542247612578	2631.520601559277	0.9999962710980547
Linear Regression	300858606763.43445	548505.794648912	389483.27406274446	0.9436901845628082
Gradient Boosting	2612129633.9187756	51108.99758280117	34798.431377742614	0.9995111041057914
AdaBoost	1641012750.8477683	40509.41558264903	18948.60976246103	0.9996928619522493

```
vm pipe
```

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	7047042513944.63	2654626.624206242	1813383.521287376	0.9994318509214386
Random Forest	27421966437.97412	165595.79233173202	102502.10568574781	0.9999977891768166
Neural Network	1260414175855.3713	1122681.6894629444	874431.0255351483	0.999898382456016
Linear Regression	39690992979876.79	6300078.807433824	5302063.785504849	0.996800019150717
Gradient Boosting	24385314402.342037	156157.97899032262	128315.89575486902	0.9999980339988186
AdaBoost	8656774205.479317	93041.78741554418	68098.72701675835	0.9999993020705809

vm bolt

Settings

Sampling type: No sampling, test on testing data

Scores

Model	MSE	RMSE	MAE	R2
KNN	17953740117017.137	4237185.4003591975	3252802.3734838055	0.9454430897669328
Random Forest	2065212037843.3525	1437084.5618276442	206485.3002903627	0.993724338938488
Neural Network	3037489707029.2817	1742839.552864601	940923.0429148135	0.9907698311215282
Linear Regression	16323271864542.14	4040206.9086300693	2981651.7285110014	0.9503976735755639
Gradient Boosting	1906816158564.006	1380875.1422789847	294440.2490562801	0.9942056642618361
AdaBoost	2068122159760.1235	1438096.714327699	199782.99520323862	0.9937154958083577

vm flange