

Instituto Tecnológico y de Estudios Superiores de Occidente

Reconocimiento de validez oficial de estudios de nivel superior según acuerdo secretarial 15018, publicado en el Diario Oficial de la Federación del 29 de noviembre de 1976.

Departamento de Matemáticas y Física
Maestría en Ciencia de Datos



Estimación del tiempo de vida de una turbina a través de Redes Neuronales y Árboles de Decisión

TRABAJO RECEPCIONAL que para obtener el **GRADO** de
MAESTRO EN CIENCIA DE DATOS

Presenta: **ROBERTO CARLOS VÁZQUEZ FLORES**

Director **DRA. ALMA NAYELI RODRÍGUEZ VÁZQUEZ**

Tlaquepaque, Jalisco, febrero de 2024.

Para mi esposa Belén y mi hijo Carlos, que me apoyaron siempre y fueron pacientes durante este proceso.

AGRADECIMIENTOS

El autor desea dar las gracias a JABIL CIRCUIT de México, quien me becó para poder obtener este título y me dio todas las facilidades.

RESUMEN

Al año 2024, gran parte de las industrias siguen basando sus programas de mantenimiento en un esquema preventivo y correctivo. Sin embargo, este tipo de mantenimiento ha demostrado no ser el más idóneo. Una alternativa que ha demostrado ser más eficiente es la implementación del mantenimiento predictivo. Este tipo de mantenimiento se caracteriza por el análisis de la información generada en el monitoreo de los equipos para crear modelos que ayuden a predecir su comportamiento. Una de las industrias que ha considerado introducir estos nuevos métodos predictivos para la prevención de fallos en las turbinas aéreas es la industria aeroespacial. Con el objetivo de implementar un mantenimiento predictivo en las turbinas aéreas, en este proyecto se propone la utilización de modelos basados en árboles de decisión y redes neuronales para modelar la propagación del daño dentro de los módulos de las turbinas de aviones y predecir el tiempo de vida restante de las turbinas utilizando los datos provenientes del C-MAPSS. Con esta información, un operador podrá tomar decisiones basadas en información para diseñar un mantenimiento predictivo que ayude a evitar fallos inesperados. Para probar el desempeño de ambos modelos se realizan varios experimentos y se calculan métricas que permiten evaluar la precisión y confiabilidad de las predicciones generadas.

TABLA DE CONTENIDO

1. INTRODUCCIÓN	9
1.1. CONTEXTO.....	9
1.2. JUSTIFICACIÓN.....	11
1.3. PROBLEMA.....	11
1.4. OBJETIVOS.....	13
1.4.1. Objetivo General:.....	13
1.4.2. Objetivos Específicos:.....	13
2. METODOLOGÍA	14
2.1. DESCRIPCIÓN DE LOS DATOS.....	14
2.2. ANÁLISIS EXPLORATORIO.....	16
2.3. DESCRIPCIÓN DE LOS MODELOS.....	19
2.3.1. Red Neuronal Recurrente.....	19
2.3.2. Random Forest Regressor.....	20
2.4. DESCRIPCIÓN DE LAS MÉTRICAS.....	20
2.5. DESCRIPCIÓN DE LOS EXPERIMENTOS / SIMULACIONES.....	22
3. RESULTADOS Y DISCUSIÓN	24
3.1. RESULTADOS Y DISCUSIÓN.....	24
3.1.1. Resultados del modelo basado en una red neuronal recurrente.....	24
3.1.2. Resultados del modelo basado en árboles de decisión.....	31
4. CONCLUSIONES	36
4.1. CONCLUSIONES.....	36
4.2. TRABAJO FUTURO.....	37
5. REFERENCIAS	38

LISTA DE FIGURAS

Figura 1. Análisis de correlación para el subconjunto de datos FD001.....	17
Figura 2. Gráficas de bigotes de una muestra de las variables del subconjunto FD001.	19
Figura 3. Estructura de la red neuronal utilizada.	22
Figura 4. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD001.	25
Figura 5. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD002.	26
Figura 6. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD003.	26
Figura 7. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD004.	27
Figura 8. Comportamiento del error durante el entrenamiento del modelo basado en redes neuronales considerando el costo y MSE para el conjunto de datos de entrenamiento y de prueba.	28
Figura 9. Resultados generados con el nuevo modelo para el subconjunto de datos FD004.....	30
Figura 10. Predicción vs salida real considerando los resultados obtenidos del modelo basado en árboles de decisión para 9 motores seleccionados aleatoriamente del subconjunto FD002.....	32
Figura 11. Importancia de las variables del subconjunto de datos FD001.	34
Figura 12. Importancia de las variables del subconjunto de datos FD002.	34
Figura 13. Serie de tiempo del sensor 11 en el subconjunto de datos FD002.	35

LISTA DE TABLAS

Tabla 1. Descripción general del conjunto de datos de prueba.	15
Tabla 2. Descripción general del conjunto de datos de entrenamiento.	15
Tabla 3. Resumen del subconjunto FD001 correspondiente al conjunto de datos de entrenamiento.	15
Tabla 4. Estadísticas básicas del conjunto de datos	16
Tabla 5. Variables eliminadas después del análisis de correlación del subconjunto FD001 y FD003.	17
Tabla 6. Valor de sesgo por cada variable de los subconjuntos FD001, FD002, FD003 y FD004.....	18
Tabla 7. Parámetros seleccionados para el modelo <i>Random Forest Regressor</i>	23
Tabla 8. Precisión (accuracy) en 30 muestras aleatorias para cada subconjunto de datos del modelo de redes neuronales recurrentes.	28
Tabla 9. Estadísticos básicos aplicados a los resultados de la Tabla 8.	29
Tabla 10. Métricas de evaluación del modelo RNN considerando una muestra aleatoria de 30 motores del subconjunto FD001.....	30
Tabla 11. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD001.	30
Tabla 12. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD002.	31
Tabla 13. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD003.	31
Tabla 14. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD004.	31
Tabla 15. Métricas de evaluación del modelo <i>Random Forest</i> considerando una muestra aleatoria de 30 motores del subconjunto FD001.	32
Tabla 16. Resumen estadístico de las métricas de evaluación del modelo <i>Random Forest</i> para 30 muestras aleatorias del subconjunto FD001.	33
Tabla 17. Resumen estadístico de las métricas de evaluación del modelo <i>Random Forest</i> para 30 muestras aleatorias del subconjunto FD002.	33
Tabla 18. Resumen estadístico de las métricas de evaluación del modelo <i>Random Forest</i> para 30 muestras aleatorias del subconjunto FD003.	33
Tabla 19. Resumen estadístico de las métricas de evaluación del modelo <i>Random Forest</i> para 30 muestras aleatorias del subconjunto FD004.	33

1. INTRODUCCIÓN

1.1. Contexto

El mantenimiento preventivo es una estrategia que se ha aplicado en la industria desde 1939 como una medida para la conservación de los equipos (Raya, 2015). El concepto de mantenimiento preventivo hace referencia a una supervisión periódica de los equipos con el fin de mantener su funcionamiento óptimo, prevenir fallos, y prolongar su vida útil (Botero, 1991).

En la industria, el mantenimiento preventivo juega un papel muy importante ya que, no considerarlo en los procesos de rutina, podría ocasionar un paro en la producción y, por consecuencia, generar impactos económicos negativos por no cumplir con las metas programadas (Sacristán, 2014). Los paros no programados son identificados como tiempos de inactividad de una máquina o línea de producción, los cuales pueden ocurrir por diversas razones tales como averías, un mal programa de mantenimiento, y por el desgaste de los equipos a través del tiempo (Flores, y otros, 2016).

Sin embargo, a partir del año 2000, empieza una nueva generación que incorpora una técnica de mantenimiento más sofisticada y eficiente. Esta técnica es conocida como mantenimiento predictivo y se caracteriza por el análisis de la información generada en el monitoreo de los equipos para crear modelos que ayuden a predecir su comportamiento (C., Botero A., & Cañón A., 2010). En el mantenimiento predictivo, se busca establecer una comunicación entre los equipos para automatizar el monitoreo de parámetros, la medición del comportamiento de los procesos y el registro de estos indicadores para su análisis y aplicación en la prevención de fallos. Esta técnica ha ganado mucha popularidad ya que ha demostrado tener una efectividad de hasta el 90%, la cual no se alcanza con un mantenimiento preventivo tradicional (Gómez, 2017).

La medición del comportamiento de los equipos y el registro de estos indicadores es esencial para entender los procesos y buscar una mejora continua. La falta de sistemas de monitoreo eficientes es la principal causa de que las empresas no puedan aplicar mantenimiento predictivo para tener un mayor control de los eventos imprevistos (Montalvo, 2016). Contar con un sistema integral conectado a cada uno de los equipos para que, de forma remota y en tiempo real, se pueda visualizar lo que está sucediendo sin la necesidad de estar ahí físicamente y sin tener que esperar a recibir un reporte de fallos días después de que

sucedieron los eventos, ayudaría a evitar que los paros se prolonguen por un tiempo mayor y que los costos de operación sigan siendo altos. De ahí surge la importancia de introducir en la industria nuevos métodos predictivos para la prevención de fallos basados en el procesamiento y análisis de la información recabada del monitoreo y la medición del comportamiento de los equipos.

De acuerdo con un estudio realizado por el MIT, 60% de las empresas más competitivas del mundo han establecido estrategias de mantenimiento predictivo para impulsar su desarrollo mediante el procesamiento y análisis de la información obtenida del monitoreo de los equipos (Juárez, 2022). Una de las industrias que ha considerado introducir estos nuevos métodos predictivos para la prevención de fallos es la industria aeroespacial. La Administración Nacional de Aeronáutica y el Espacio, conocida como la NASA (*National Aeronautics and Space Administration*) (NASA, 2024), está generando y analizando datos provenientes de un sistema llamado C-MAPSS (*Commercial Modular Aero Propulsion System Simulation*) que simula las condiciones de trabajo de una turbina aérea (Saxena & Goebel, 2008). Este software, creado por MATLAB y Simulink, simula el funcionamiento de la turbina de una aeronave, permitiendo recrear sus condiciones de operación. C-MAPSS permite editar diferentes parámetros de operación, tales como el peso del motor, la altura de trabajo, la velocidad, la temperatura, y diferentes condiciones de vuelo para recrear diferentes condiciones de operación. De estas simulaciones se generan datos que varían dependiendo de la configuración de estos parámetros de operación. El conjunto de datos que se genera en la simulación es de acceso público y se encuentra disponible con el objetivo de que la comunidad académica y científica proponga modelos que permitan predecir el tiempo de vida restante de las turbinas. El tiempo de vida restante de una turbina se conoce como RUL (*Remaining Useful Life*), el cual mide el número de ciclos de operación restantes antes de que la turbina requiera reparación o reemplazo (Ahmadzadeh & Lundberg, 2013). La estimación eficiente del RUL permitiría calendarizar los mantenimientos, optimizar la eficiencia de operación y evitar fallos imprevistos.

Existe una amplia variedad de modelos predictivos que pueden utilizarse para simular el comportamiento de las turbinas y predecir el RUL. Algunos modelos populares utilizados para realizar predicciones son los basados en árboles de decisión (Jehad, Khan, Ahmad, & Maqsood, 2012) y las redes neuronales recurrentes (Medsker & Jain, 1999). Estos modelos son de naturaleza distinta y tienen características diferentes. Por un lado, los basados en árboles de decisión ofrecen fácil implementación e interpretación sencilla, lo cual los hace ideales para comprender y comunicar la toma de decisiones. Por otro lado, las redes neuronales permiten crear relaciones complejas, lo cual las hace eficientes para modelar comportamientos sofisticados y complicados. A pesar de sus diferencias, ambos modelos han ganado popularidad por haber demostrado un alto desempeño en distintas aplicaciones (Shinde & Shah, 2018).

Con el objetivo de implementar un mantenimiento predictivo en las turbinas aéreas, en este proyecto se propone la utilización de modelos basados en árboles de decisión y redes neuronales para modelar la propagación del daño dentro de los módulos de las turbinas de

aviones y predecir el tiempo de vida restante de las turbinas utilizando los datos provenientes del C-MAPSS. Con esta información, un operador podrá tomar decisiones basadas en información para diseñar un mantenimiento predictivo que ayude a evitar fallos inesperados.

1.2. Justificación

La industria manufacturera, petrolera, energética, aéreo espacial, entre otras, se encuentran bajo presión constante debido a la necesidad de cumplir metas de producción y reducción de costos. Esto produce como efecto no deseado la sobrecarga de los activos físicos, lo que genera un aumento en los costos de mantenimiento, además de importantes pérdidas de productividad y riesgo potencial para la seguridad de los trabajadores y usuarios finales. Por tal motivo, el mantenimiento predictivo ha sido una alternativa que permite, de una forma eficiente, detectar y solucionar los problemas antes de que se produzcan.

Para la implementación de modelos de mantenimiento predictivo, los profesionales deben contar con un alto conocimiento en analítica avanzada de datos, conocer el funcionamiento de los equipos, saber los mecanismos que generalmente producen fallas, así como determinar estrategias de monitoreo. Sin embargo, contar con personal calificado no siempre es posible ni fácil. Normalmente se carece de personal que pueda llevar apropiadamente una cultura de la prevención de fallos a través de un análisis previo de la información que generan estos equipos, de tal forma que sólo se limitan a corregir el fallo cuando ya sucedió, lo que genera como consecuencia tiempos de paro que causan costos adicionales a las empresas. Por tal motivo, contar con un sistema que asista al profesional en la identificación a tiempo de posibles fallos resulta de vital importancia. Con este apoyo, el profesional no requeriría un alto gradado de capacitación, ya que el sistema recolectaría la información y la procesaría para generar un modelo predictivo que proporcione información sobre posibles fallos.

1.3. Problema

Actualmente, gran parte de las industrias siguen basando sus programas de mantenimiento de forma preventiva, designando un intervalo de tiempo para realizar las reparaciones y determinar cuáles piezas deberían ser reemplazadas. Sin embargo, este tipo de mantenimiento ha demostrado no ser el más eficiente para disminuir o eliminar los paros no programados, así como el eficiente uso de las piezas antes de ser reemplazadas.

Una alternativa que ha demostrado ser más eficiente es la implementación del mantenimiento predictivo. Sin embargo, incorporar este tipo de mantenimiento en la industria no es tan sencillo. Para la implementación de un mantenimiento predictivo es necesario que los equipos cuenten con dispositivos o sensores que estén tomando lecturas de su comportamiento para su procesamiento y análisis. Muchas industrias ya cuentan con estos dispositivos o sensores en sus equipos, pero la información recabada sólo es utilizada

para hacer un monitoreo del comportamiento de los equipos. Esta información no es analizada ni interpretada de tal forma que sea posible predecir las posibles fallas.

En este contexto resaltan varias problemáticas. En primer lugar, se requiere un cambio de paradigma en la industria, de tal forma que contemple reestructurar la forma de dar mantenimiento a sus equipos. En segundo lugar, este cambio requiere de las inversiones necesarias para hacer la adaptación en la maquinaria que necesita ser monitoreada y analizada. Finalmente, es indispensable subsanar la falta de personal calificado para realizar el procesamiento, análisis e interpretación de la información mediante la implementación de modelos que permitan predecir el funcionamiento de los equipos. En este proyecto, se busca atacar esta última problemática mediante la implementación de un modelo que asista a un operador, que pudiera estar calificado o no, en la predicción de fallos.

En este proyecto se aborda el desarrollo de un modelo que permita dar mantenimiento preventivo a una turbina aeroespacial. Las turbinas aeroespaciales son equipos que deben llevar un mantenimiento muy riguroso ya que las implicaciones por fallos son bastante costosas. Algunos de los costos asociados son:

- Costos de reparación: Incluyen el costo de mano de obra, piezas de repuesto y cualquier otra necesidad relacionada con la reparación del motor. Estos costos pueden variar según la gravedad y la naturaleza del fallo.
- Costos de tiempo de inactividad: Cuando un motor falla, es probable que la maquinaria o el sistema al que está conectado también se detenga. Esto resulta en tiempo de inactividad productivo, lo que implica pérdida de producción y oportunidades de negocio. Cuanto más tiempo dure el fallo, mayores serán los costos asociados al tiempo de inactividad.
- Costos de reemplazo: En algunos casos, los fallos en los motores pueden ser tan graves que el motor debe ser reemplazado en su totalidad. Esto implica el costo de adquirir un nuevo motor y los gastos asociados con la instalación y puesta en marcha.
- Costos de energía: Un motor defectuoso o mal ajustado puede consumir más energía de la necesaria. Esto resulta en costos adicionales de electricidad y puede tener un impacto significativo en los gastos operativos a largo plazo.
- Costos de mantenimiento adicional: Después de un fallo en el motor, es posible que se requiera un mantenimiento adicional para reparar cualquier daño o prevenir futuras fallas. Estos costos incluyen el tiempo y los recursos dedicados a la inspección, limpieza, lubricación y ajuste del motor.
- Costos de seguridad: Los fallos en los motores pueden plantear riesgos de seguridad para los trabajadores y el entorno. Esto puede implicar costos asociados con la

implementación de medidas de seguridad adicionales, la capacitación del personal y la mitigación de posibles accidentes o daños.

En esta propuesta, se busca solucionar esta problemática mediante la implementación de un modelo que ayude a predecir el RUL a través el análisis de los gráficos de serie de tiempo.

1.4. *Objetivos*

1.4.1. *Objetivo General:*

Crear un modelo predictivo que pueda predecir el RUL de una turbina. Este modelo está basado en redes neuronales y árboles de decisión, y deberá justificar, en base a las métricas de desempeño, que se tendrá una alta confiabilidad en las predicciones a fin de evitar paros inesperados en estos equipos.

1.4.2. *Objetivos Específicos:*

Se tiene varios objetivos específicos, los cual se enlistan a continuación:

- Tener un entendimiento grafico de las series de tiempo de cada variable para poder generar un modelo predictivo de alta confiabilidad
- Generar una exploración y limpieza de datos que pueda facilitar el trabajo al momento de pasar al modelo predictivo
- Aplicar modelos predictivos basados en árboles de decisión y redes neuronales
- Ajustar los parámetros de los modelos para obtener las mejores métricas al momento de la verificación de resultados
- Comparar los diferentes modelos para elegir el de mejor desempeño

2. METODOLOGÍA

2.1. Descripción de los datos

El conjunto de datos consta de cuatro subconjuntos identificados como FD001, FD002, FD003 y FD004. Los datos son extraídos del portal de la NASA “*Prognostics Center of Excellence Data Repository*” (Saxena & Goebel, 2008) y contienen el número de identificación del motor, los ciclos de cada motor, información de 21 sensores que miden los parámetros de una turbina, tales como la temperatura total en la entrada del ventilador y la temperatura total en la salida del compresor de baja presión. Además, los datos contienen 3 configuraciones operativas: la altitud de vuelo, el número de mach (se conoce como mach a la medida de velocidad relativa que se define como el cociente entre la velocidad de un objeto y la velocidad del sonido en el medio en que se mueve dicho objeto) y el ángulo de resolución del acelerador.

La descripción de cada conjunto de datos se muestra a continuación:

- FD001 tiene una condición de operación y un modo de falla
- FD002 tiene seis condiciones de operación y un modo de falla
- FD003 tiene una condición de operación y dos modos de falla
- FD004 tiene seis condiciones de operación y dos modos de falla

La naturaleza del conjunto de datos nos da mucha información ya que cada motor tiene diferentes números de ciclos, modos de operación y sensores. Por ejemplo, del subconjunto FD004 se tomó el motor 1, el cual cuenta con 258 ciclos, los cuales tienen lecturas de 24 variables (3 modos de operación y 21 sensores). La información que se puede obtener de los motores a partir de estos elementos es la degradación y el rendimiento. La degradación en del motor es capturada por los datos de los sensores mientras que el rendimiento del motor es sustancialmente influenciado por los tres escenarios operativos. Además, los motores arrancan con un grado diferente de desgaste inicial y variación de fabricación que el usuario desconoce y no se consideran como una condición de falla.

Cada uno de los conjuntos de datos consta de conjuntos separados de entrenamiento y prueba. En el conjunto de entrenamiento, los datos de los sensores se capturan hasta que el sistema falla, esto con el fin de poder capturar los valores actuales en los sensores al momento del fallo. Por otro lado, en el conjunto de prueba, los datos de los sensores se capturan hasta un cierto tiempo antes de la falla, ya que este conjunto tiene el valor del RUL

que será utilizado como variable de salida para el modelo. Las Tablas 1 y 2 muestran las especificaciones del conjunto de datos de prueba y el de entrenamiento, respectivamente.

Tabla 1. Descripción general del conjunto de datos de prueba.

Especificación	FD001	FD002	FD003	FD004
Número de motores	100	259	100	248
Condiciones de operación	1	6	1	6
Modos de falla	1	1	2	2

Tabla 2. Descripción general del conjunto de datos de entrenamiento.

Especificación	FD001	FD002	FD003	FD004
Número de motores	100	260	100	249
Condiciones de operación	1	6	1	6
Modos de falla	1	1	2	2

Como se aprecia en las Tablas 1 y 2, se tienen 4 subconjuntos de datos que son FD001, FD002, FD003 y FD004 para los datos de entrenamiento y otros 4 subconjuntos para los datos de prueba. Sobre esta información se realizó una exploración inicial para obtener un resumen de cada uno de los subconjuntos con el objetivo de ver el tipo de variable, valores omitidos, valores presentes, valores mínimos y valores máximos. En la Tabla 3 se presenta una muestra de este análisis, en el cual se observa la información del subconjunto FD001 correspondiente al conjunto de datos de entrenamiento.

Tabla 3. Resumen del subconjunto FD001 correspondiente al conjunto de datos de entrenamiento.

Nombres	Tipo de Variable	Valores perdidos	Valores presentes	Valores únicos	Valores mínimos	Valores máximos
Número de unidades	int64	0	41214	248	1	248
Ciclos	int64	0	41214	486	1	486
Condición de operación 1	float64	0	41214	536	0	42.008
Condición de operación 2	float64	0	41214	105	0	0.842
Condición de operación 3	float64	0	41214	2	60	100
Sensor1	float64	0	41214	6	445	518.67
Sensor2	float64	0	41214	1480	535.42	643.94
Sensor3	float64	0	41214	11326	1240.94	1608.05
Sensor4	float64	0	41214	13257	1024.9	1429.46
Sensor5	float64	0	41214	6	3.91	14.62
Sensor6	float64	0	41214	61	5.66	21.61
Sensor7	float64	0	41214	4173	136.06	569.17
Sensor8	float64	0	41214	709	1914.92	2388.55
Sensor9	float64	0	41214	18503	7987.03	9131.03
Sensor10	float64	0	41214	18	0.93	1.32
Sensor11	float64	0	41214	657	36.03	48.23
Sensor12	float64	0	41214	3963	128.26	536.6
Sensor13	float64	0	41214	307	2027.74	2389.22
Sensor14	float64	0	41214	12152	7849.8	8196.8
Sensor15	float64	0	41214	8724	8.204	11.017

Sensor16	float64	0	41214	2	0.02	0.03
Sensor17	int64	0	41214	49	302	397
Sensor18	int64	0	41214	6	1915	2388
Sensor19	float64	0	41214	2	84.93	100
Sensor20	float64	0	41214	536	10.19	39.71
Sensor21	float64	0	41214	16453	6.1453	23.8298

De la Tabla 3, se aprecia que no hay variables categóricas ni valores faltantes, lo cual facilita la limpieza y el procesamiento de los datos. De la misma forma, el análisis de los subconjuntos restantes muestra que todas las variables son numéricas y no hay valores faltantes. Lo único que se puede resaltar de este análisis es que los subconjuntos FD002 y FD004 cuentan con algunas variables que tienen un único valor.

2.2. Análisis exploratorio

Para el análisis exploratorio se calculan algunas estadísticas básicas al conjunto de datos, tales como la desviación estándar, la media, la cantidad de datos, los mínimos y los máximos. Este análisis se muestra en la Tabla 4. De la información proporcionada por la Tabla 4, se puede concluir que, por el rango de algunos valores, será necesario hacer escalamiento de los datos.

Tabla 4. Estadísticas básicas del conjunto de datos

	Unidades	Número	Ciclos	Condición de Operación 1	Condición de Operación 2	Condición de Operación 3	Sensor1	Sensor2	Sensor3	Sensor4
Desviación estándar	29.23	68.88	0.00	0.00	0.00	0.00	0.50	6.13	9.00	0.00
Mínimo	1.00	1.00	-0.01	0.00	100.00	518.67	641.21	1571.04	1382.25	14.62
Media	51.51	108.81	0.00	0.00	100.00	518.67	642.68	1590.52	1408.93	14.62
Máximo	100.00	362.00	0.01	0.00	100.00	518.67	644.53	1616.91	1441.49	14.62
Conteo	20631.00	20631.00	20631.00	20631.00	20631.00	20631.00	20631.00	20631.00	20631.00	20631.00
75%	77.00	156.00	0.00	0.00	100.00	518.67	643.00	1594.38	1414.55	14.62
50%	52.00	104.00	0.00	0.00	100.00	518.67	642.64	1590.10	1408.04	14.62
25%	26.00	52.00	0.00	0.00	100.00	518.67	642.33	1586.26	1402.36	14.62

Además de calcular las estadísticas básicas, se realiza un análisis de correlación de las variables en los diferentes subconjuntos de datos. En la Figura 1 se muestra el análisis de correlación del primer subconjunto de datos FD001. Al revisar el análisis de correlación, se puede observar gráficamente que la variable Sensor18, Sensor19 y operacionalset3 (condición de operación 3) no aportan información al modelo, por lo cual son las primeras candidatas para eliminarse. Adicionalmente, todas las variables que tengan un índice de correlación menor a 0.5 con respecto a la variable objetivo RUL, también serán descartadas para el modelado.




Figura 1. Análisis de correlación para el subconjunto de datos FD001.

Este mismo proceso se realiza para los demás subconjuntos, de tal forma que las variables con correlación menor a 0.5 son eliminadas del análisis. En la Tabla 5 se enlista una muestra de las variables eliminadas para el subconjunto FD001 y FD003.

Tabla 5. Variables eliminadas después del análisis de correlación del subconjunto FD001 y FD003.

FD001	FD003
OperationalSet1	OperationalSet1
OperationalSet2	OperationalSet2
OperationalSet3	OperationalSet3
Sensor1	Sensor1
Sensor5	Sensor5
Sensor6	Sensor6
Sensor9	Sensor7

Sensor10	Sensor10
Sensor14	Sensor14
Sensor16	Sensor15
Sensor18	Sensor16
Sensor19	Sensor18
	Sensor19
	Sensor20
	Sensor21

Otro análisis realizado es una prueba de sesgo a los cuatro subconjuntos de datos FD001, FD002, FD003 y FD004. Esta prueba se reporta en la Tabla 6, en la cual se puede observar que la mayoría de las variables no cuentan con problema de sesgo. Sin embargo, en el subconjunto FD001 hay tres valores que muestran problemas de sesgo, los cuales están marcados en color rojo. De forma similar, se puede apreciar que en el subconjunto FD003 existe un valor que también presenta problemas de sesgo, el cual está marcado en color rojo. Estos hallazgos refuerzan la decisión de eliminar las variables Sensor6, Sensor9 y Sensor14 del subconjunto FD001, así como la variable Sensor 10 del subconjunto FD003. Estas variables ya se habían considerado en el proceso de eliminación reportado en la Tabla 5.

Tabla 6. Valor de sesgo por cada variable de los subconjuntos FD001, FD002, FD003 y FD004.

Subconjuntos	OperationalSet1	OperationalSet2	OperationalSet3	Sensor1	Sensor2	Sensor3	Sensor4	Sensor5	Sensor6	Sensor7	Sensor8	Sensor9	Sensor10	Sensor11	Sensor12	Sensor13	Sensor14	Sensor15	Sensor16	Sensor17	Sensor18	Sensor19	Sensor20	Sensor21
FD001	0	0	0	0	0.3	0.3	0.4	0	-6.9	-0.4	0.5	2.6	0	0.5	-0.4	0.5	2.4	0.4	0	0.4	0	0	-0.4	-0.4
FD002	-0.3	-0.8	-2	0.5	0.4	0.2	0.4	0.5	0.6	0.7	-1.2	0.1	0.6	-0.5	0.7	-2	-1.4	1.1	0.7	0.2	-1.2	-2	0.6	0.6
FD003	0	0	0	0	0.4	0.3	0.6	0	-1.7	1.8	-1.4	1.9	2.7	0.6	1.9	-1.4	1.9	-0.3	0	0.4	0	0	0.1	0.2
FD004	-0.3	-0.8	-2	0.5	0.4	0.2	0.4	0.5	0.6	0.7	-1.2	0.1	0.6	-0.5	0.7	-2	-1.4	1	0.7	0.2	-1.2	-2	0.6	0.6

Además de la prueba de sesgo, también se realizó una prueba de normalidad. La prueba de normalidad utilizada es la de Shapiro-Wilk (Razali & Wah, 2011). Esta prueba demuestra que existe falta de normalidad en los datos ya que todos los P-valores resultantes son menores al valor de significancia de 0.05. Por tal motivo, es necesario normalizar los datos. Para visualizarlo, se muestran los diagramas de bigotes en la Figura 2.

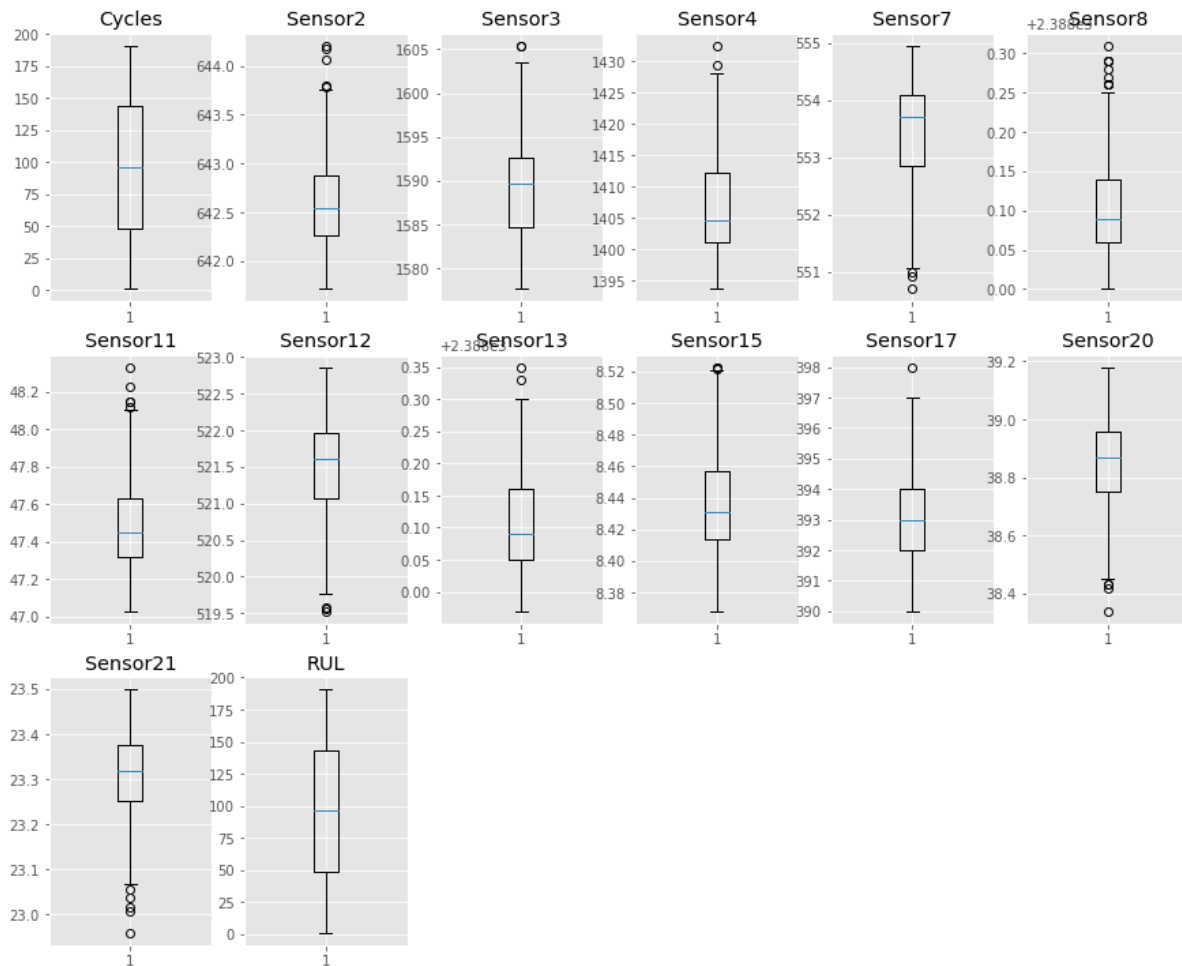


Figura 2. Gráficas de bigotes de una muestra de las variables del subconjunto FD001.

2.3. Descripción de los modelos

En este proyecto se implementaron dos modelos, uno basado en Redes Neuronales Recurrentes y otro en Árboles de Decisión. Una breve descripción de estos modelos se proporciona a continuación.

2.3.1. Red Neuronal Recurrente

Una Red Neuronal Recurrente o *Recurrent Neural Network* (RNN) es un tipo de red neuronal artificial que utiliza datos secuenciales o datos de series temporales. Así como las Redes Neuronales Convolucionales, las RNN utilizan datos de entrenamiento para aprender. Se distinguen por su "memoria", ya que obtienen información de entradas anteriores para influir en la entrada y salida actuales. La salida de las redes neuronales recurrentes depende de los elementos anteriores dentro de la secuencia. Las RNN utilizan el algoritmo de retro

propagación a través del tiempo para determinar los gradientes, que es ligeramente diferente de la retro propagación tradicional, ya que es específico para secuenciar los datos.

La ecuación generalizada para las relaciones de recurrencia es:

$$S^{(t)} = f(S^{t-1}) \quad (1)$$

La cual indica el estado del sistema que depende de un paso de tiempo anterior indicado por $t - 1$. Esta ecuación puede reescribirse como $h^{(t)}$.

$$h^{(t)} = f(h^{t-1}, h^{(t)}) \quad (2)$$

En donde $h^{(t)}$ representa la entrada de una instancia de tiempo en particular. La importancia de $h^{(t)}$ es que es una representación de los aspectos relevantes de la secuencia pasada de entradas hasta t .

2.3.2. Random Forest Regressor

Un modelo *Random Forest Regressor* está formado por múltiples árboles de decisión individuales. Cada uno de estos árboles es entrenado con una muestra ligeramente diferente de los datos de entrenamiento. Para realizar predicciones sobre nuevas observaciones, se combinan las predicciones de todos los árboles que conforman el modelo.

Unos de los beneficios que más llama la atención es el poder de manejar grandes cantidades de datos con mayor dimensionalidad. Puede manejar miles de variables de entrada e identificar las variables más significativas, por lo que se considera uno de los métodos de reducción de dimensionalidad. Además, el modelo muestra la importancia de la variable, que puede ser una característica muy útil.

2.4. Descripción de las métricas

Para la evaluación del desempeño de los modelos propuestos, es necesario utilizar diferentes métricas de acuerdo con las características de los modelos. Existen varias métricas capaces de evaluar modelos de regresión, tales como el coeficiente de determinación (R^2), el error cuadrático medio (MSE) y la raíz del error cuadrático medio (RMSE). Una descripción de estas métricas y su interpretación se describen en esta sección.

Coeficiente de determinación

Una forma común de resumir cuán bien se ajusta un modelo de regresión lineal a los datos es a través del coeficiente de determinación, o R^2 . Esto se puede calcular como el cuadrado

de la correlación entre los valores observados y los valores predichos \hat{y} . Alternativamente, también se puede calcular como:

$$R^2 = \frac{\sum(\hat{y}_t - \bar{y})^2}{\sum(y_t - \bar{y})^2} \quad (3)$$

En donde las sumas son sobre todas las observaciones. Por lo tanto, refleja la proporción de variación en la variable de pronóstico que se explica mediante el modelo de regresión.

En la regresión lineal simple, el valor de R^2 también es igual al cuadrado de la correlación entre y y x (siempre que se haya incluido una intersección). Si las predicciones están cerca de los valores reales, esperaríamos que R^2 esté cerca de 1. Por otro lado, si las predicciones no están relacionadas con los valores reales, entonces $R^2=0$ (nuevamente, suponiendo que hay una intersección). En todos los casos, R^2 se encuentra entre 0 y 1.

El valor R^2 se utiliza con frecuencia, aunque a menudo de manera incorrecta, en la predicción. El valor de R^2 nunca disminuirá al agregar un predictor adicional al modelo, y esto puede llevar a un sobreajuste. No hay reglas establecidas para lo que es un buen valor de R^2 , y los valores típicos de R^2 dependen del tipo de datos utilizados. Validar el rendimiento de pronóstico de un modelo en los datos de prueba es mucho mejor que medir el valor R^2 en los datos de entrenamiento (Hyndman, 2021).

Error cuadrático medio

MSE por sus siglas en inglés, es similar al error estándar de estimación en la regresión lineal, excepto que se calcula sobre los datos de validación en lugar de sobre los datos de entrenamiento. Tiene las mismas unidades que la variable de resultado.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (4)$$

La raíz del error cuadrático medio

RMSE por sus siglas en inglés, es similar al MSE, excepto que se calcula la raíz del MSE.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (5)$$

2.5. Descripción de los experimentos / simulaciones

En los experimentos se consideraron dos modelos, uno basado en redes neuronales recurrentes y otro basado en árboles de decisión. Ambos modelos utilizan regresión para la predicción. Estos modelos fueron seleccionados debido a que son utilizados cuando los datos de entrada son una secuencia y, debido a que la información del conjunto de datos que se desea tratar es una serie de tiempo, este tipo de modelos son ideales para su tratamiento.

En el primer experimento, el cual considera un modelo de redes neuronales recurrentes, se aplicó el modelo a 30 motores seleccionados de manera aleatoria para cada uno de los 4 subconjuntos de datos. Para la simulación se considera la paquetería KERAS en Python, así como el optimizador Adam (*Adaptative moment estimation, por sus siglas en inglés*).

En la primera etapa de la simulación se considera un modelo vacío de tipo *Sequential*. Este modelo se refiere a crear una serie de capas de neuronas secuenciales, las cuales se posicionan una delante de otra. Después, se agregan 3 capas *Dense*, las cuales consideran una capa de entrada con 13 neuronas y dos capas ocultas con 32 neuronas cada una. Además, se utiliza como función de activación la tangente hiperbólica (\tanh). Finalmente, se agrega una capa a la salida con una neurona y una función de activación lineal. En la Figura 3 se ilustra la estructura de la red neuronal descrita.

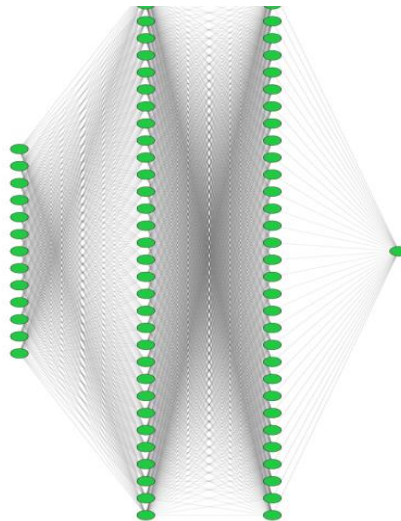


Figura 3. Estructura de la red neuronal utilizada.

En el segundo experimento, se implementa un modelo *Random Forest Regressor* utilizando la paquetería *sklearn* en Python. Este modelo requiere la configuración de algunos parámetros tales como el número de estimadores ($n_estimators$), el criterio utilizado para medir la calidad de las divisiones (*criterion*), la profundidad de los árboles de decisión (max_depth), el mínimo número de muestras necesarias para la partición

(*min_samples_split*), el mínimo número de muestras necesarias para un nodo de hoja (*min_samples_leaf*) y el número máximo de características a considerar para la división de las ramas (*max_features*). Para cada uno de estos parámetros se eligieron los valores que se muestran en la Tabla 7.

Tabla 7. Parámetros seleccionados para el modelo *Random Forest Regressor*.

Parámetro	Valor
n_estimators	100
criterion	squared_error
max_depth	None
min_samples_split	2
min_samples_leaf	1

Los valores de los parámetros mostrados en la Tabla 7 se seleccionaron de acuerdo con los valores por defecto que ofrece la función.

3. RESULTADOS Y DISCUSIÓN

3.1. *Resultados y discusión*

Debido a que se realizaron experimentos con dos modelos, uno basado en redes neuronales recurrentes y otro basado en árboles de decisión, los resultados y su discusión se abordarán por separado. Sin embargo, al final se hará un análisis comparativo entre los resultados obtenidos con cada modelo para comparar su desempeño.

3.1.1. Resultados del modelo basado en una red neuronal recurrente

Para visualizar los resultados que se obtuvieron con el modelo basado en una red neuronal recurrente, se han graficado 9 predicciones contra las salidas reales correspondientes a 9 motores seleccionados de forma aleatoria del conjunto de datos FD001. Estas gráficas se aprecian en la Figura 4.

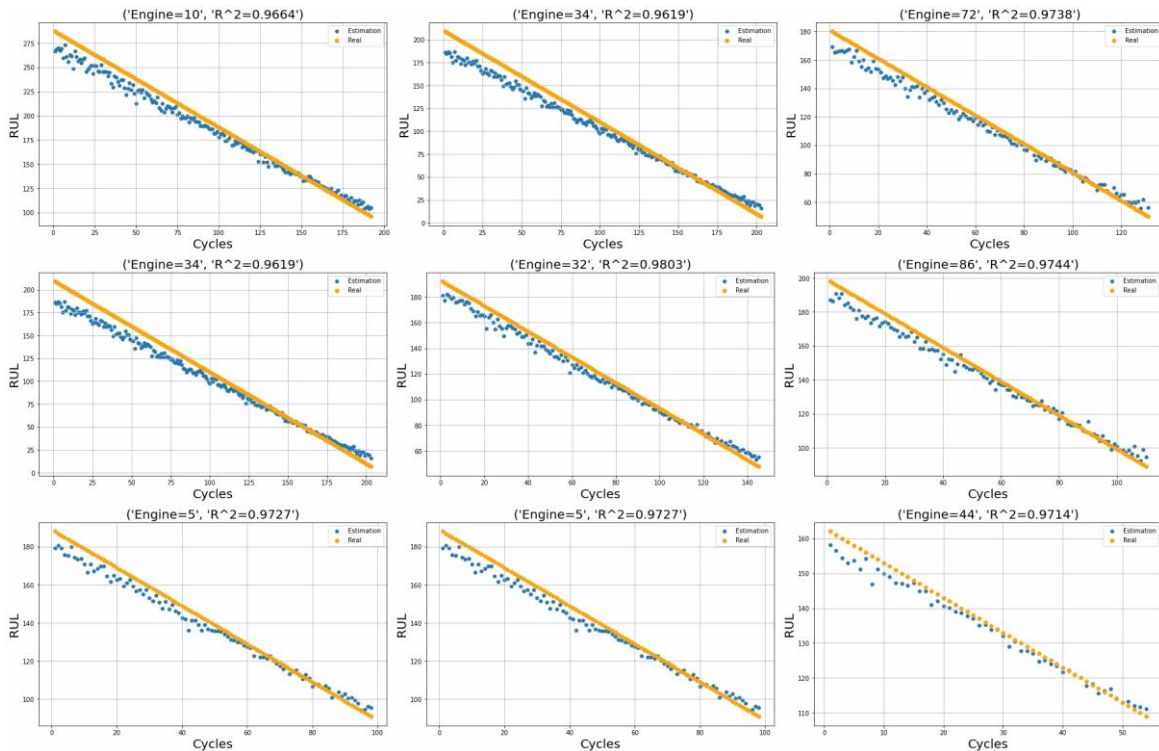


Figura 4. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD001.

Las gráficas de la Figura 4 muestran los ciclos en el eje horizontal y el RUL en el eje vertical, indicando cuánto tiempo de vida le queda al motor en un cierto número de ciclos. Por ejemplo, en la primera gráfica de la Figura 4, que corresponde al motor 10 (Engine=10), la línea amarilla indica el número de ciclos reales del motor y, con puntos azules, se indica la estimación del modelo. En este gráfico se puede observar que, a los 187 ciclos, a este motor le restan casi 97 RUL para presentar una falla. En contraste, en la gráfica correspondiente al motor 34 (Engine=34), a los 200 ciclos, el motor tiene menos de 25 RUL antes de presentar una falla. Por tal motivo, se puede concluir que, en el segundo caso, el motor tiene una degradación más rápida. Además, se comprueba que el número de ciclos no necesariamente determina la salud de un motor, sino que las variables de los sensores de funcionamiento también influyen en el tiempo restante de vida del motor.

De forma similar, las Figuras 5, 6 y 7 muestran los resultados de las predicciones contra la salida correcta considerando el modelo de redes neuronales recurrentes para 9 motores seleccionados de forma aleatoria de los subconjuntos FD002, FD003 y FD004.

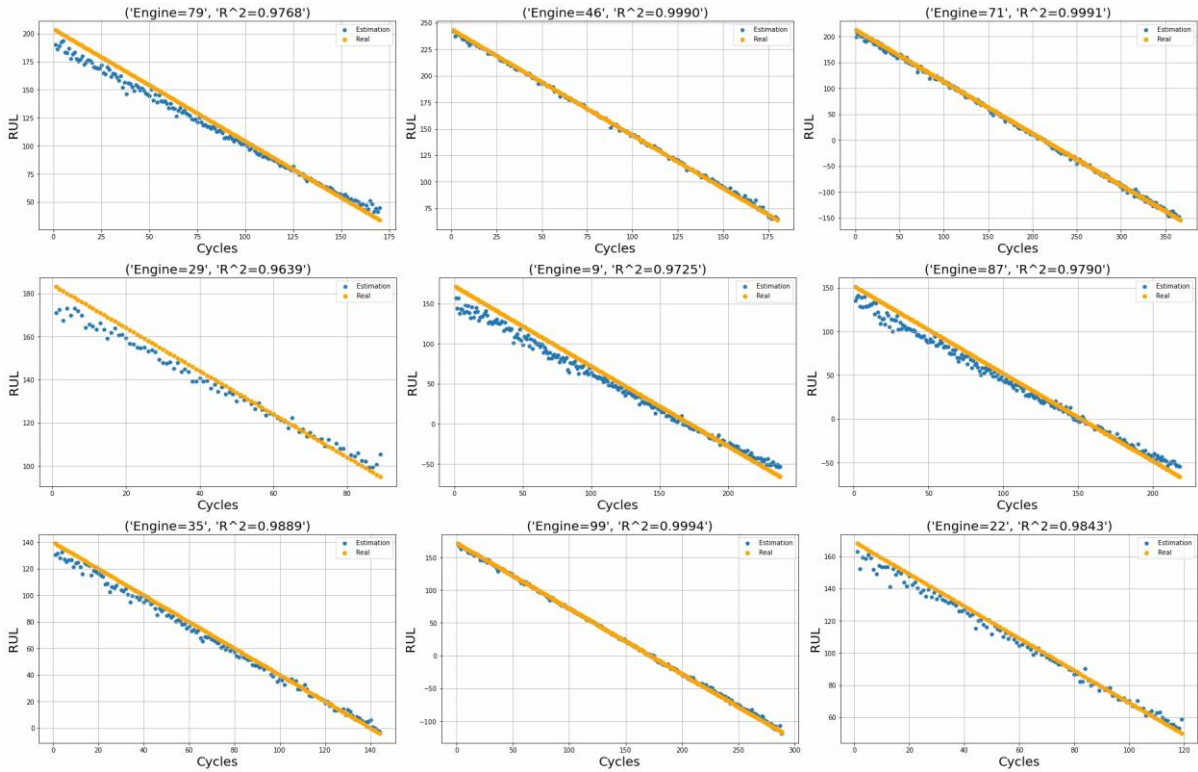


Figura 5. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD002.

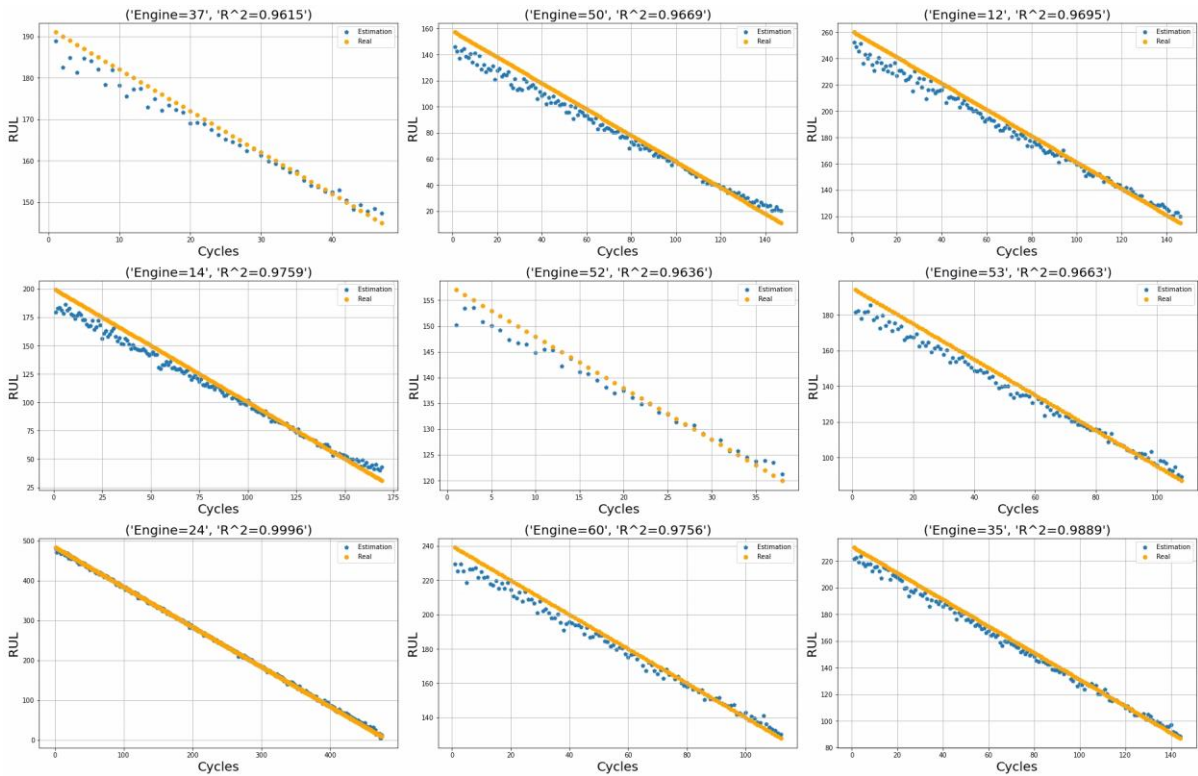


Figura 6. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD003.

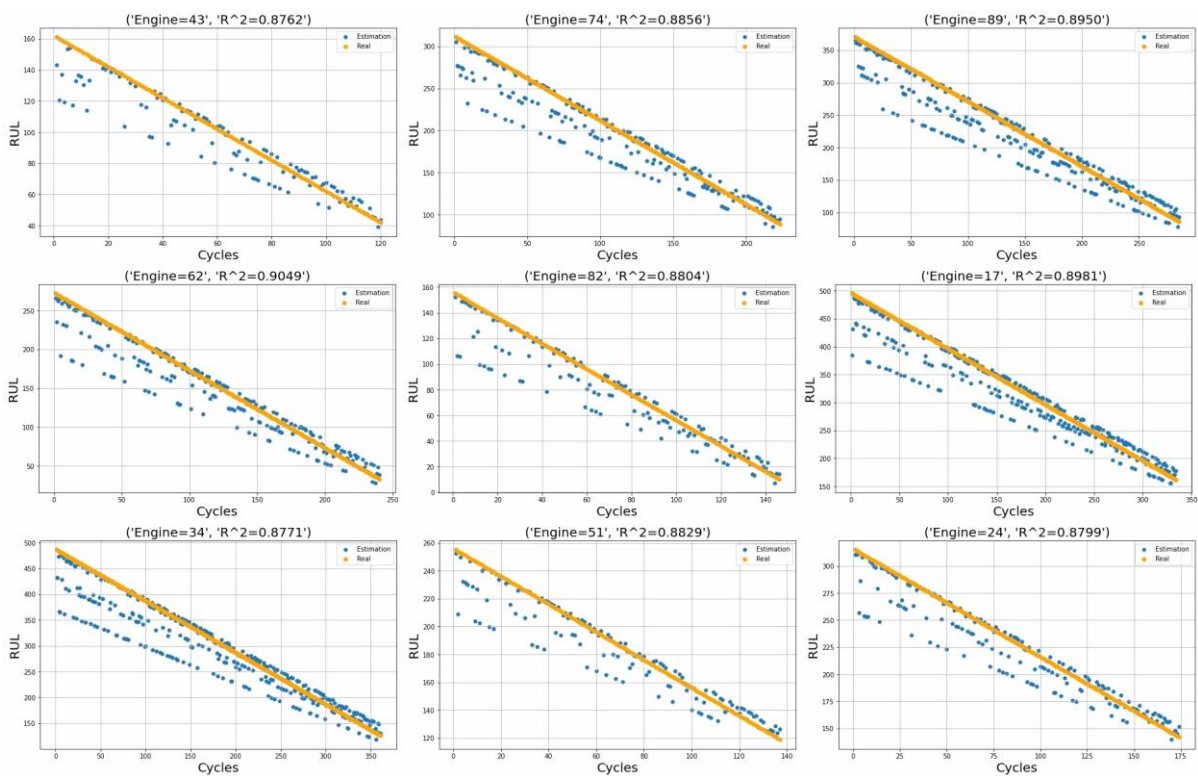


Figura 7. Predicción vs salida real considerando los resultados obtenidos del modelo basado en redes neuronales recurrentes para 9 motores seleccionados aleatoriamente del subconjunto FD004.

Al observar los resultados obtenidos en la Figura 7, es claramente visible que el modelo no logró ajustarse a la tendencia de los datos tan bien como lo hizo en las gráficas de las Figuras 4, 5 y 6 correspondientes a los subconjuntos FD001, FD002 y FD003, respectivamente. Esto se puede apreciar en el abanico de puntos que se forma en las gráficas de la Figura 7, el cual aumenta su error a medida que los ciclos disminuyen. Por lo que los resultados no son tan favorables ya que, en ciclos bajos, el modelo no realiza una buena predicción. Esto se debe a un sesgo muy evidente en los resultados de predicción, el cual genera predicciones de 50 ciclos menos de lo real, que, para casos prácticos, este error de predicción no generaría un paro anticipado, pero sí ocasionaría un mantenimiento innecesario ya que se programaría más pronto de lo que debería.

En la Figura 8 se reporta un análisis del comportamiento del error durante el entrenamiento del modelo basado en redes neuronales recurrentes. La Figura 8 muestra 2 gráficas en las cuales se reporta el comportamiento del error a través de las épocas en términos de la función de costo (*Loss*) y del error cuadrático medio (MSE). Cada gráfica reporta el comportamiento del error en el conjunto de entrenamiento (*train*) y el de prueba (*test*). Al analizar estas gráficas, es posible observar que, tanto en el entrenamiento como en la validación, se obtuvieron comportamientos similares. Además, se logró reducir el error a 0.0001 tanto en la función de costo como en el MSE.




Figura 8. Comportamiento del error durante el entrenamiento del modelo basado en redes neuronales considerando el costo y MSE para el conjunto de datos de entrenamiento y de prueba.

En el análisis de los resultados también se considera la precisión (*accuracy*) del modelo basado en redes neuronales recurrentes. En la Tabla 8 se reportan los resultados de la precisión para 30 muestras aleatorias de cada uno de los subconjuntos de datos FD001, FD002, FD003 y FD004.

Tabla 8. Precisión (*accuracy*) en 30 muestras aleatorias para cada subconjunto de datos del modelo de redes neuronales recurrentes.

FD001	FD002	FD003	FD004
0.966	0.967	0.973	0.896
0.97	0.984	0.973	0.883
0.964	0.974	0.97	0.88
0.97	0.992	0.964	0.898
0.962	0.961	0.964	0.915
0.97	0.954	0.989	0.883
0.964	0.973	0.973	0.903
0.974	0.971	0.969	0.872
0.972	0.992	0.974	0.88
0.953	0.975	0.972	0.878
0.973	0.964	0.968	0.911
0.964	0.976	0.974	0.887
0.963	0.996	0.961	0.886
0.973	0.984	0.968	0.884
0.972	0.972	0.973	0.901
0.971	0.999	0.987	0.899
0.953	0.976	0.988	0.903
0.963	0.974	0.979	0.891
0.966	0.965	0.964	0.872
0.965	0.985	0.962	0.887
0.966	0.966	0.976	0.885
0.973	0.987	0.979	0.889
0.953	0.964	0.993	0.895
0.972	0.988	0.978	0.906

0.959	0.975	0.975	0.903
0.974	0.978	0.993	0.903
0.958	0.998	0.954	0.893
0.967	0.961	0.973	0.89
0.971	0.984	0.972	0.861
0.967	0.984	0.999	0.899

La Tabla 8 muestra resultados de precisión arriba de 0.9 en la mayoría de los casos, lo cual demuestra la confiabilidad de los resultados generados con el modelo. Sin embargo, es notorio que el subconjunto de datos FD004 es el que muestra los resultados de precisión más bajos. Para tener una mejor visibilidad de estas métricas, la Tabla 9 reporta los estadísticos básicos aplicados a la Tabla 8, los cuales consideran la mediana, la desviación estándar y la media.

Tabla 9. Estadísticos básicos aplicados a los resultados de la Tabla 8.

Métrica	FD001	FD002	FD003	FD004
Mediana	0.9665	0.9755	0.973	0.8905
Desviación estándar	0.006186	0.011639	0.010226	0.01212
Media	0.966267	0.9773	0.974567	0.8911

En la Tabla 9 se puede apreciar un resumen de la información presentada en la Tabla 8. En la Tabla 9 se puede ver que la media de la precisión obtenida para el subconjunto FD004 es 0.8911, mientras que en FD001, FD002 y FD003 se obtuvo un valor superior a 0.96. Estos resultados corroboran el pobre desempeño del modelo, observable en la Figura 7, para el subconjunto FD004. Por tal motivo, se decide generar un nuevo modelo particularmente para este subconjunto de datos FD004. Los resultados que se obtuvieron para estos datos en específico se muestran en la Figura 8.

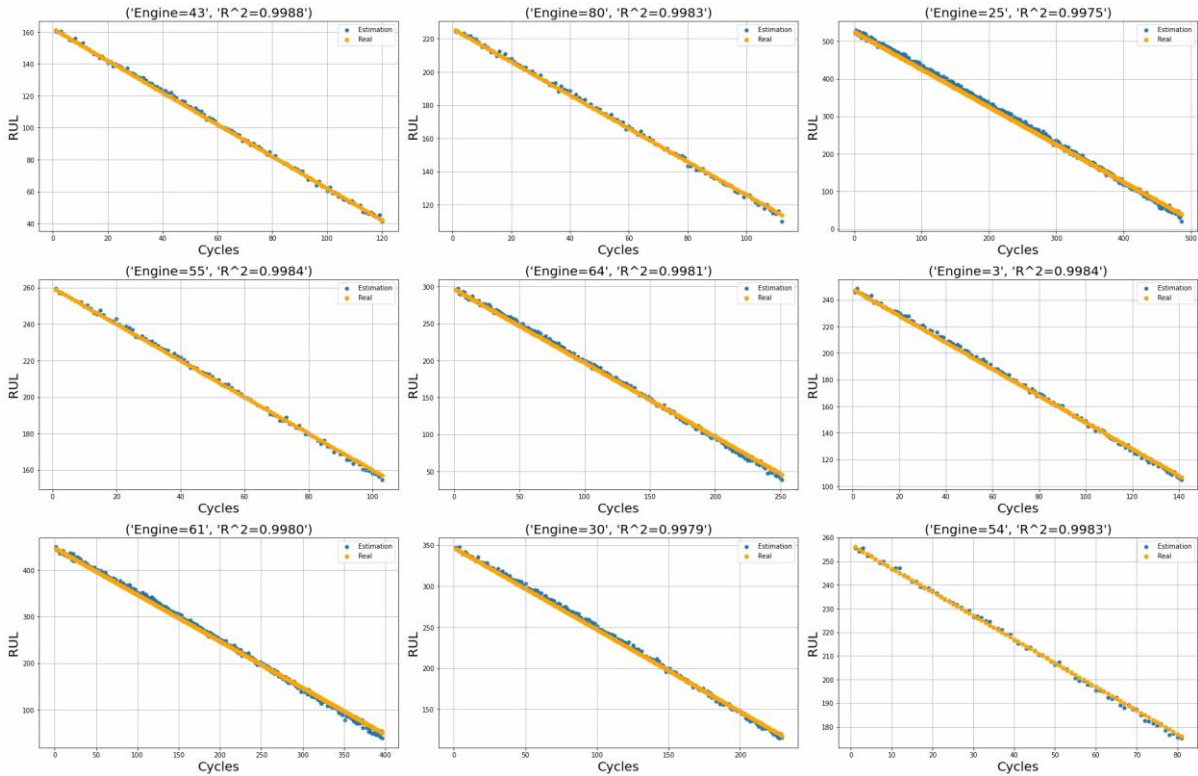


Figura 9. Resultados generados con el nuevo modelo para el subconjunto de datos FD004.

En la Figura 8 se observa que, con el nuevo modelo, se logra ajustar mejor la tendencia de los datos y por lo tanto generar mejores predicciones para el subconjunto de datos FD004.

Además de la precisión, se calcularon otras métricas para evaluar el desempeño del modelo RNN en cada uno de los subconjuntos de datos. Estas métricas incluyen el coeficiente de determinación (R^2), el MSE y el RMSE. De forma ilustrativa, los resultados obtenidos para una muestra aleatoria de 30 motores del subconjunto FD001 se muestran en la Tabla 10.

Tabla 10. Métricas de evaluación del modelo RNN considerando una muestra aleatoria de 30 motores del subconjunto FD001.

Muestras	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
R2	0.899	0.855	0.898	0.924	0.907	0.876	0.899	0.908	0.905	0.897	0.900	0.903	0.895	0.895	0.880	0.899	0.883	0.893	0.890	0.901	0.876	0.886	0.895	0.905	0.880	0.898	0.877	0.883	0.880	0.878
MSE	0.009	0.012	0.009	0.006	0.008	0.010	0.009	0.008	0.008	0.009	0.008	0.008	0.009	0.009	0.010	0.009	0.010	0.009	0.009	0.008	0.010	0.010	0.009	0.008	0.010	0.009	0.010	0.010	0.010	0.010
RMSE	0.092	0.111	0.093	0.080	0.088	0.102	0.092	0.088	0.089	0.094	0.092	0.090	0.094	0.094	0.101	0.092	0.099	0.095	0.096	0.092	0.102	0.098	0.094	0.089	0.101	0.092	0.101	0.100	0.101	0.101

Para analizar mejor los resultados de estas métricas, se presenta un resumen estadístico en las Tablas 11, 12, 13 y 14 para una muestra aleatoria de 30 motores de los subconjuntos FD001, FD002, FD003 y FD004, respectivamente. Este resumen considera la media y la desviación estándar de las 30 muestras tomadas. Además, el resumen considera los mínimos, máximos y los percentiles.

Tabla 11. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD001.

FD001	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.00	0.970	0.006	0.959	0.967	0.970	0.970	0.006

MSE	30.00	0.003	0.000	0.001	0.002	0.003	0.003	0.000
RMSE	30.00	0.970	0.006	0.959	0.967	0.970	0.970	0.006

Tabla 12. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD002.

FD002	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.980	0.012	0.961	0.971	0.978	0.988	0.999
MSE	30.000	0.002	0.001	0.000	0.001	0.002	0.002	0.003
RMSE	30.000	0.038	0.016	0.007	0.031	0.043	0.050	0.059

Tabla 13. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD003.

FD003	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.978	0.013	0.961	0.967	0.973	0.988	1.000
MSE	30.000	0.002	0.001	0.000	0.001	0.002	0.003	0.003
RMSE	30.000	0.040	0.017	0.005	0.031	0.047	0.052	0.058

Tabla 14. Resumen estadístico de las métricas para 30 muestras aleatorias del subconjunto FD004.

FD004	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.892	0.014	0.855	0.881	0.895	0.900	0.924
MSE	30.000	0.009	0.001	0.006	0.008	0.009	0.010	0.012
RMSE	30.000	0.095	0.006	0.080	0.092	0.094	0.100	0.111

Analizando estas tablas, es evidente que el modelo RNN proporciona predicciones con un alto grado de precisión, así como métricas con resultados satisfactorios en cuanto a los valores R^2 , MSE y RMSE. A manera de ejemplo, podemos ver que en la Tabla 12, la métrica R^2 tiene como mínimo un valor de 0.961 y una media de 0.98, lo cual indica un buen desempeño del modelo.

Es un hecho que el modelo RNN se ajustó de manera adecuada a la tendencia de los datos, generando resultados favorables en 3 de los 4 subconjunto de datos. Sin embargo, una solución a este problema fue entrenar un nuevo modelo para el subconjunto FD004. Lo cual no debe representar un problema ya que la diferencia entre estos sólo era el modo de operación y las condiciones de trabajo.

3.1.2. Resultados del modelo basado en árboles de decisión

Para visualizar los resultados que se obtuvieron con el modelo basado en árboles de decisión (*Random Forest Regressor*), se han graficado 9 predicciones contra las salidas reales correspondientes a 9 motores seleccionados de forma aleatoria del conjunto de datos FD002. Estas gráficas se aprecian en la Figura 10.

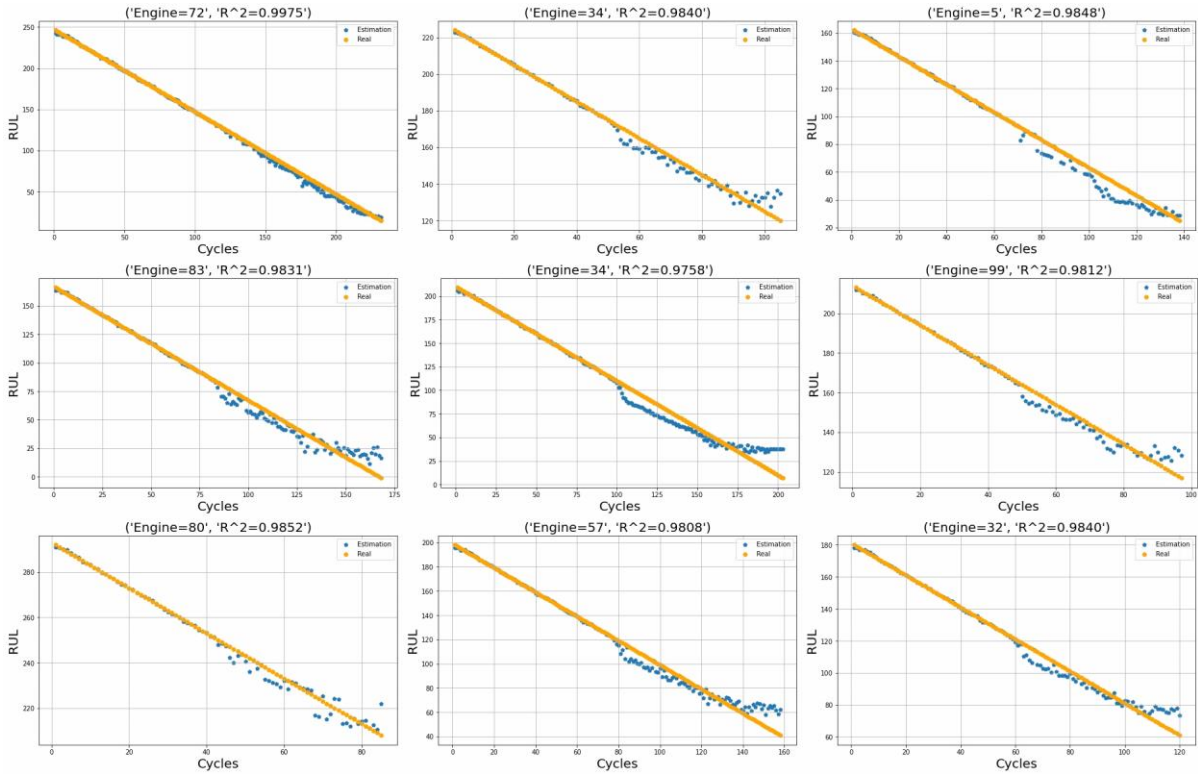


Figura 10. Predicción vs salida real considerando los resultados obtenidos del modelo basado en árboles de decisión para 9 motores seleccionados aleatoriamente del subconjunto FD002.

De la Figura 10 se puede observar que, en general, se logran buenas predicciones del RUL. Sin embargo, la predicción comienza a ser imprecisa a medida que se incrementan los ciclos, lo cual generaría estimaciones no muy acertadas del RUL a medida que se acerca el final del tiempo de vida del motor. El comportamiento de las predicciones para los otros subconjuntos de datos es similar, por tal motivo, se decidió no reportarlas.

Para este modelo también se calcularon métricas para evaluar su desempeño en cada uno de los subconjuntos de datos. Estas métricas incluyen el coeficiente de determinación (R^2), el MSE y el RMSE. De forma ilustrativa, los resultados obtenidos para una muestra aleatoria de 30 motores del subconjunto FD001 se muestran en la Tabla 15.

Tabla 15. Métricas de evaluación del modelo *Random Forest* considerando una muestra aleatoria de 30 motores del subconjunto FD001.

Muestras	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29
R2	0.973	0.984	0.975	0.979	0.984	0.984	0.984	0.979	0.972	0.978	0.970	0.976	0.979	0.981	0.981	0.965	0.981	0.980	0.980	0.974	0.978	0.989	0.976	0.978	0.979	0.989	0.989	0.978	0.979	0.986
MSE	0.002	0.001	0.002	0.002	0.001	0.001	0.001	0.002	0.003	0.002	0.003	0.002	0.002	0.002	0.002	0.003	0.002	0.002	0.002	0.002	0.002	0.001	0.002	0.002	0.002	0.001	0.001	0.002	0.002	0.001
RMSE	0.048	0.037	0.046	0.042	0.037	0.037	0.037	0.042	0.050	0.043	0.051	0.045	0.042	0.041	0.041	0.057	0.040	0.042	0.041	0.047	0.043	0.031	0.045	0.044	0.042	0.031	0.031	0.043	0.042	0.035

Para analizar mejor los resultados de estas métricas, se presenta un resumen estadístico en las Tablas 16, 17, 18 y 19 para una muestra aleatoria de 30 motores de los subconjuntos FD001, FD002, FD003 y FD004, respectivamente. Este resumen considera la media y la desviación estándar de las 30 muestras tomadas. Además, el resumen considera los mínimos, máximos y los percentiles.

Tabla 16. Resumen estadístico de las métricas de evaluación del modelo *Random Forest* para 30 muestras aleatorias del subconjunto FD001.

FD001	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.981	0.003	0.976	0.978	0.980	0.984	0.988
MSE	30.000	0.002	0.000	0.001	0.001	0.002	0.002	0.002
RMSE	30.000	0.040	0.003	0.032	0.038	0.041	0.043	0.045

Tabla 17. Resumen estadístico de las métricas de evaluación del modelo *Random Forest* para 30 muestras aleatorias del subconjunto FD002.

FD002	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.987	0.008	0.977	0.981	0.984	0.996	1.000
MSE	30.000	0.001	0.001	0.000	0.000	0.001	0.002	0.002
RMSE	30.000	0.030	0.014	0.005	0.019	0.037	0.040	0.044

Tabla 18. Resumen estadístico de las métricas de evaluación del modelo *Random Forest* para 30 muestras aleatorias del subconjunto FD003.

FD003	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.988	0.008	0.976	0.982	0.985	0.997	1.000
MSE	30.000	0.001	0.001	0.000	0.000	0.001	0.002	0.002
RMSE	30.000	0.028	0.014	0.005	0.015	0.035	0.039	0.045

Tabla 19. Resumen estadístico de las métricas de evaluación del modelo *Random Forest* para 30 muestras aleatorias del subconjunto FD004.

FD004	Cantidad	Media	std	min	0.25	0.5	0.75	max
R2	30.000	0.979	0.005	0.965	0.977	0.979	0.983	0.989
MSE	30.000	0.002	0.000	0.001	0.001	0.002	0.002	0.003
RMSE	30.000	0.042	0.006	0.031	0.038	0.042	0.045	0.057

Analizando estas tablas, es evidente que el modelo de *Random Forest* proporciona predicciones con un alto grado de precisión, así como métricas con resultados satisfactorios en cuanto a los valores R^2 , MSE y RMSE. A manera de ejemplo, podemos ver que en la Tabla 16, la métrica R^2 tiene como mínimo un valor de 0.976 y una media de 0.981, lo cual indica un buen desempeño del modelo. Sin embargo, el sesgo que se observó en las gráficas de la Figura 10, el cual se genera en los ciclos altos, indica un posible sobre entrenamiento ya que se le está dando más peso al factor de ciclos que a las demás variables correspondientes a los sensores del motor.

Para concluir el análisis de este modelo, en la Figura 11 se visualiza la importancia de las variables restantes considerando el subconjunto de datos FD001. De esta figura se aprecia que el sensor 11 y el número de ciclos tienen la mayor importancia, este análisis fue realizado con la opción para revisar la importancia de las variables de un árbol de regresión.




Figura 11. Importancia de las variables del subconjunto de datos FD001.

De forma similar, en la Figura 12 se reporta el orden de importancia de las variables del subconjunto de datos FD002.




Figura 12. Importancia de las variables del subconjunto de datos FD002.

En la Figura 12 se puede notar que nuevamente el sensor 11 es una de las variables con mayor importancia. Por tal motivo, se considera pertinente analizar la información que proporciona este sensor ya que puede revelar información valiosa que ayude a determinar la degradación del motor. Debido a que la importancia del sensor 11 predomina en el subconjunto FD002, se analizará entonces la serie de tiempo generada por este sensor.




Figura 13. Serie de tiempo del sensor 11 en el subconjunto de datos FD002.

La Figura 13 muestra la serie de tiempo que genera el sensor 11 para el subconjunto de datos FD002, en el que su importancia es predominante. En esta serie de tiempo se puede ver un cambio estacional en la tendencia de manera positiva, la cual indica que se genera un evento negativo aproximadamente desde el ciclo 65. Por tal motivo, se puede concluir que la variable correspondiente al sensor 11 puede ser clave en la generación de una alerta temprana en la degradación del motor.

Al hacer un análisis general del modelo *Random Forest*, se considera que no es el más adecuado debido a la tendencia que muestra al priorizar los ciclos y despreciar la importancia de las demás variables, las cuales también son importantes para determinar el comportamiento del motor.

4. CONCLUSIONES

4.1. Conclusiones

En este trabajo se ha modelado el comportamiento de las turbinas aeroespaciales con el objetivo de comprender su degradación y así crear un modelo que permita predecir su tiempo de vida restante. En el proceso se realizó una exploración y limpieza de los datos, en donde se descartaron variables no relevantes y variables con datos faltantes. Para el modelado se implementaron dos modelos de regresión, uno basado en redes neuronales recurrentes y otro basado en árboles de decisión. La selección de los modelos se realizó considerando que fueran capaces de manejar datos que corresponden a series de tiempo.

El modelo basado de redes neuronales recurrentes generó resultados satisfactorios al lograr predicciones del RUL con un alto grado de precisión. Las métricas calculadas para medir el desempeño de este modelo mostraron resultados positivos, por lo que se concluye que el modelo RNN puede realizar predicciones del RUL con un alto grado de certeza, permitiendo tomar una acción temprana para evite fallos en las turbinas, así como evitar costos de reparación altos. Cabe mencionar que no fue posible utilizar un solo modelo para los cuatro subconjuntos de datos ya que sólo funcionó bien para tres de los cuatro subconjuntos. Sin embargo, esto es un indicador de que se debe crear un modelo para cada uno de los diferentes modos de operación de los motores, lo cual no afectaría el modelado y seguiría siendo viable.

El modelo basado en árboles de decisión también mostró un buen desempeño, las métricas que se obtuvieron fueron positivas. Sin embargo, al analizar los gráficos, se considera que estos buenos resultados se obtuvieron debido a un sobre entrenamiento. Los gráficos revelaron que las predicciones estaban sesgadas ya que el modelo tiende a dar mayor peso a los ciclos, desestimando las otras variables, las cuales proporcionan información sobre el correcto o incorrecto funcionamiento del motor y también juegan un papel importante en determinar el tiempo de vida de las turbinas. Por tal motivo, se concluye que el modelo que mejor logró capturar la tendencia de los datos fue el basado en redes neuronales recurrentes.

4.2. *Trabajo Futuro*

Este trabajo abre una ventana a una amplia gama de aplicaciones en industrias manufactureras, en las cuales se pueden aplicar los métodos de mantenimiento predictivo. Las industrias de este tipo cuentan con múltiples procesos que pudieran ser monitoreados y registrados, con el fin de capturar información que pueda ser procesada y analizada para la toma de decisiones. No obstante, esta práctica no es común. Por ejemplo, las empresas de este tipo manejan equipos que cuentan con partes mecánicas, las cuales tienen un desgaste y tiempo de vida especificado por el fabricante. Sin embargo, estas piezas usualmente fallan antes de lo previsto ya que depende de las diferentes variables del proceso. Entonces, nadie puede anticiparse a esas fallas ya que actualmente se tienen sistemas que capturan las mediciones de estas partes mecánicas, pero sólo son para monitoreo, no para utilizar esa información en un mantenimiento predictivo.

5. REFERENCIAS

- Ahmadzadeh, F., & Lundberg, J. (2013). Remaining useful life estimation: review. *International Journal of System Assurance Engineering and Management*, 461-474.
- Anonimo. (Febrero de 2023). *ptchronos*. (ptchronos) Obtenido de <https://www.ptchronos.com/es/blog/la-importancia-del-mantenimiento-preventivo>
- Botero, C. (1991). Capítulo 5: Mantenimiento preventivo. En C. Botero, *Manual de mantenimiento* (pág. 316). Bogotá Colombia: SENA.
- C., W. O., Botero A., M., & Cañon A., B. (2010). TÉCNICAS DE MANTENIMIENTO PREDICTIVO UTILIZADAS EN LA INDUSTRIA. *Scientia et Technica*, 223-226.
- Cichosz, P. (2015). *Data Mining Algorithms Explained Using R*. Wiley.
- Ellefsen, A. L. (March de 2019). *Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture*. (sciencedirect) Recuperado el Mayo de 2023, de <https://www.sciencedirect.com/science/article/pii/S0951832018307506>
- Fernández Álvarez, E. (JULIO de 2018). *Universidad de Oviedo*. Recuperado el Agosto de 2023, de <https://digibuo.uniovi.es/dspace/bitstream/handle/10651/47868/Gesti%F3n%20de%20Mantenimiento.%20Lean%20Maintenance%20y%20TPM.pdf;jsessionid=CDCC5E14CE5619624EFD78B1269B84C4?sequence=1>
- Flores, C. A., gastelu Pinedo, Y., Méndez Orellana, G., Minaya Luna, C., Pineda Ocas, B., Prieto Gilio, K., . . . Moreno Rojo, C. (2016). Gestión de mantenimiento preventivo y su relación con la disponibilidad de la flota de camiones 730e Komatsu-213. *Ingeniería Industrial*, 11-26.
- Gómez, A. M. (2017). *Técnicas de mantenimiento preedictivo: metodología de aplicación en las organizaciones*. Obtenido de Repositorio Institucional Universidad Católica de Colombia - RIUCaC: <https://repository.ucatolica.edu.co/entities/publication/eb3b87c2-0eeb-4d4a-aeba-192f6d73b7c2>
- Hyndman, R. &. (2021). *Forecasting: principles and practice*. Melbourne: OTexts.
- Jehad, A., Khan, R., Ahmad, N., & Maqsood, . (2012). Random Forests and Decision Trees. *International Journal of Computer Science* , 9(5) 272.
- Juárez, C. (27 de abril de 2022). *Cómo el machine learning puede impulsar el crecimiento de las empresas*. Obtenido de The Logistics World: <https://thelogisticsworld.com/tecnologia/como-el-machine-learning-puede-impulsar-el-crecimiento-de-las-empresas/>
- Luis. (2023). *Web*. Obtenido de <http://jdidi.com>
- M. Chao, C. K. (Enero de 2019). *Prognostics Center of Excellence Data Repository*. (Nasa) Obtenido de <https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>

- Medsker, L., & Jain, L. (1999). *Recurrent neural networks: design and applications*. CRC press.
- Montalvo, J. G. (Abril de 2016). *Mantenimiento predictivo*. Obtenido de Repositorio Institucional de Investigación Universidad Tecnológica del Centro de Veracruz: <http://reini.utcv.edu.mx/handle/123456789/738>
- NASA. (2024). Obtenido de <https://www.nasa.gov/>
- Raya, F. J. (2015). *Mantenimiento preventivo de sistemas de automatización industrial*. IC Editorial.
- Razali, N., & Wah, Y. (2011). Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. *Journal of statistical modeling and analytics*, 2(1), 21-33.
- Rivera, F. (Agosto de 2023). *Forbes*. (Forbes) Obtenido de <https://www.forbes.com.mx/estos-son-los-retos-de-mexico-frente-a-la-cuarta-revolucion-industrial-o-industria-4-0/>
- Sacristán, F. R. (2014). Elaboración y optimización de un plan de mantenimiento preventivo. *Technical Industrial*, 30-41.
- Saxena, A., & Goebel, K. (2008). *Turbofan Engine Degradation Simulation Data Set*. Obtenido de NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field, CA: https://data.nasa.gov/Aerospace/CMAPSS-Jet-Engine-Simulated-Data/ff5v-kuh6/about_data
- Shinde, P. P., & Shah, S. (2018). A review of machine learning and deep learning applications. *2018 Fourth international conference on computing communication control and automation (ICCUBEA) IEEE*, 1-6.