

INFORME DEL PROYECTO REF.SV-24-GIJÓN-1-15

Sistema de detección de fallos y predicción del rendimiento energético en un motor diésel marino

Fechas inicial y final del proyecto:

01/01/2024 al 31/12/2024

Investigador/a Principal:

Raquel Martínez Martínez.

Otros investigadores:

Luis Alfonso Díaz Secades, José Ramón Quevedo Pérez y Elena Montañés Rocés.

Personal contratado:

Mateo Rodríguez Suárez.

Fechas inicial y final de contratación:

01/09/2024 al 31/12/2024

Empresas o instituciones colaboradoras:

Ership Alvargonzález, delegación en Gijón de Ership, S.A.U.; CTIC Centro Tecnológico; TWave, S.L.; Centro de Excelencia del Sector Naval (CESENA) – SIEMENS; AVL Ibérica, S.A.

Redes sociales de investigadores y empresas:

<https://mateors6.github.io/>

<https://www.linkedin.com/in/rakelmarmar/>

<https://www.linkedin.com/in/alfonso-diaz-secades/>

https://scholar.google.es/JR_Quevedo

<https://www.linkedin.com/in/elena-montañés>

www.ership.com

www.fundacionctic.org

www.twave.io/es

<https://www.siemens.com/es/es/sectores-industriales/cesena.html>

www.avl.com

Resumen Gráfico

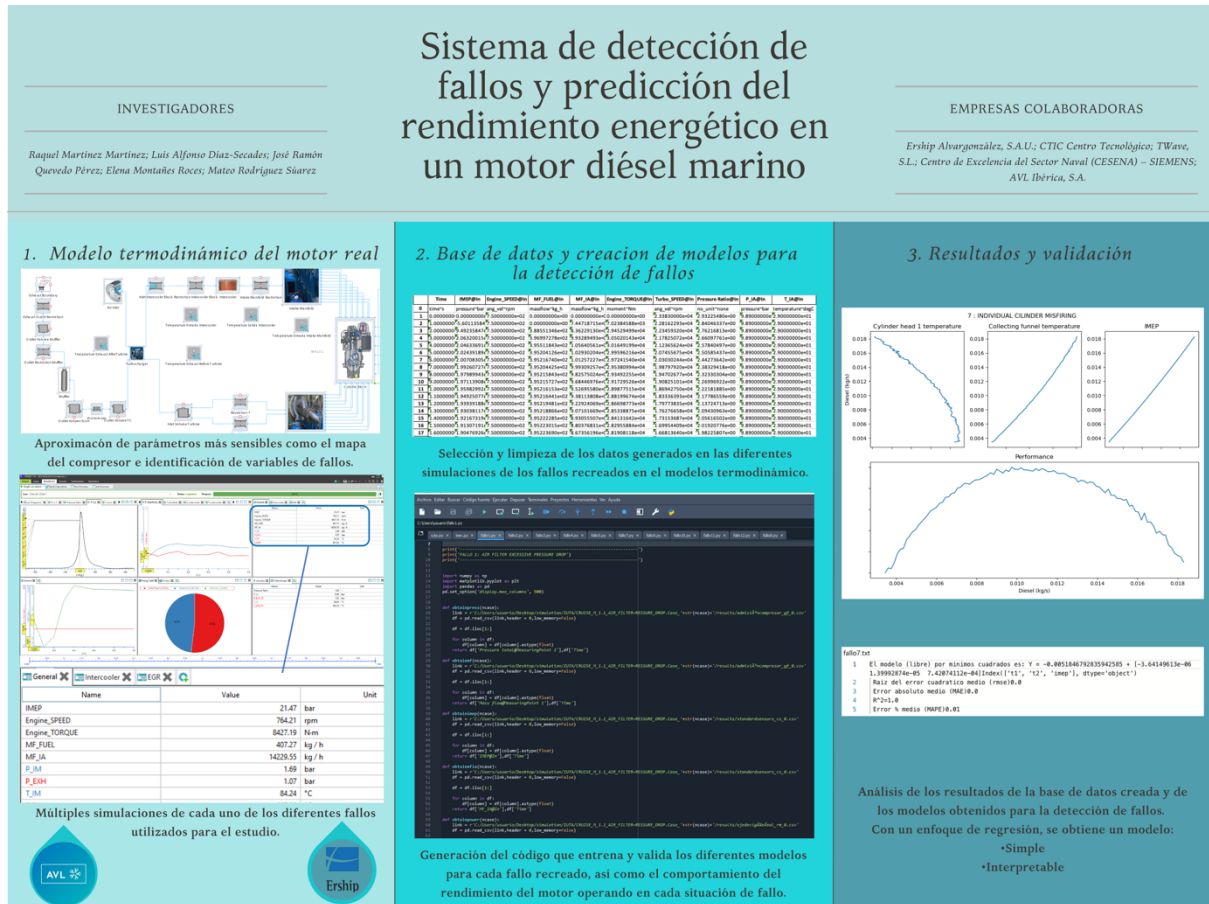


Figura 1. Resumen gráfico.

Memoria descriptiva del proyecto

1. Resumen ejecutivo

Los motores diésel marinos representan una pieza clave en el transporte marítimo global, proporcionando una fuente de propulsión confiable y eficiente capaz de manejar cargas pesadas. Esta relevancia se traduce en una creciente necesidad de mantener su operatividad y prevenir fallos que puedan comprometer la seguridad, aumentar los costes operativos y afectar el cumplimiento normativo [1]. La investigación en diagnóstico de fallos y predicción de rendimiento ha evolucionado significativamente, impulsada por la incorporación de técnicas avanzadas como el aprendizaje automático y la modelización termodinámica [2], [3]. El diagnóstico temprano de fallos no solo minimiza riesgos de daños catastróficos, sino que optimiza el mantenimiento preventivo, mejorando así la eficiencia global del motor. Los modelos basados en datos, como las redes neuronales artificiales (ANN) y las máquinas de soporte vectorial (SVM), han demostrado ser herramientas eficaces en este campo, proporcionando mapas completos de rendimiento y permitiendo la detección de anomalías con alta precisión [4], [5], [6]. Además, el desarrollo de modelos termodinámicos 0D y 1D ha facilitado la simulación de fallos, sirviendo como base para entrenar algoritmos de aprendizaje automático capaces de identificar patrones en condiciones variables [7], [8].

En términos de impacto, el análisis termoeconómico ofrece una perspectiva integral al cuantificar el efecto de los fallos en el consumo de combustible y la eficiencia operativa. Este enfoque, junto con la simulación de datos mediante herramientas como AVL Boost o Cruise M, proporciona un marco robusto para el entrenamiento de modelos predictivos, contribuyendo a la optimización energética y la reducción de costes [2].

El creciente volumen de datos generado por los motores diésel marinos ha impulsado el desarrollo de técnicas avanzadas de preprocesamiento y aumento de datos, mejorando la robustez de los modelos de diagnóstico [9], [10], [11]. La combinación de enfoques tradicionales con innovaciones como las redes neuronales convolucionales (CNN) y la inferencia bayesiana está redefiniendo los estándares de predicción y mantenimiento, permitiendo una gestión proactiva y eficiente de los motores diésel marinos [5], [12].

El presente proyecto pretende desarrollar un sistema integral para la detección de fallos en un motor diésel marino, al mismo tiempo que calcula su rendimiento energético. A través de un análisis continuo de datos en tiempo real, este sistema generará predicciones de posibles fallos, permitiendo la implementación de medidas correctivas de manera oportuna. La aplicación de estudios estadísticos en el histórico del motor proporcionará las herramientas necesarias para identificar los diferentes fallos. Simultáneamente, otro análisis estadístico proporcionará datos esenciales para evaluar el rendimiento del motor. La prevención de fallos no solo aumentará la disponibilidad del motor, sino que también maximizará la vida útil de los componentes, reduciendo así el consumo de partes. El avance en los procesos de aprovechamiento energético no solo se traducirá en ahorros en costes, sino también en una disminución de las emisiones.

Para la elaboración del sistema y su aplicación se ha dividido el proyecto en cuatro fases:

- Fase 1: Elaboración de la base de datos para la creación y validación del sistema. En un primer paso, se lleva a cabo una exhaustiva búsqueda bibliográfica con el fin de identificar el estado actual en cuanto a fallos característicos de motores diésel marinos. Este análisis se centra en destacar las averías más relevantes y recurrentes, estableciendo un listado priorizado que oriente las futuras investigaciones. Además, se aborda el estudio termodinámico de la instalación, así como los avances en optimización energética y predicción de fallos basados en condiciones operativas. Se presta especial atención a las últimas investigaciones relacionadas con la Industria 4.0 y el gemelo digital en el ámbito de los motores diésel marinos. Con los datos recopilados, se construye una base de datos integral que consolide toda la información necesaria para la creación y validación subsiguiente del sistema.
- Fase 2: Desarrollo y validación del sistema aplicado al modelo termodinámico del motor real.

En esta etapa, una vez completada la base de datos, se procede a la creación de modelos para la detección de posibles fallos, utilizando las variables recopiladas. Estos modelos se integran en un modelo termodinámico preexistente del motor real. Los resultados obtenidos se contrastan con las mediciones reales, realizando ajustes necesarios si fuera preciso. Finalmente, se lleva a cabo un análisis exhaustivo y validación de los resultados, considerando diversas condiciones para perfilar un funcionamiento óptimo del sistema.

- Fase 3: Simulación de fallos en el modelo termodinámico del motor real.
En la última fase del proyecto, se procede a simular situaciones en las cuales las condiciones técnicas del motor podrían desencadenar o resultar de una avería, tales como estrangulamiento del aire de carga, pérdida de eficiencia en el enfriador de aire de carga, reducción de combustible inyectado, entre otros. Todo ello se lleva a cabo para evaluar la capacidad de respuesta del sistema creado. Se generan suficientes datos como para entrenar y probar el modelo procediendo así a su validación.
- Fase 4: Difusión de resultados.
En esta etapa final, se redactarán y difundirán los resultados obtenidos mediante la publicación de artículos en revistas internacionales, la participación en congresos internacionales, y la cobertura en medios de prensa y televisión a nivel local.

2. Objetivos iniciales del proyecto y grado de consecución

El proyecto tiene como objetivo principal la creación de un sistema de detección de fallos en un motor diésel marino en tiempo real. Este sistema, integrado con un modelo termodinámico del motor diésel real, está alineado con las filosofías de Industria 4.0, Digitalización y Gemelo Digital.

El sistema resultante será válido para el análisis de eficiencia energética, la predicción de operaciones y fallos, y el estudio del mantenimiento a través de la recopilación de datos en tiempo real. Se plantean los siguientes objetivos específicos:

- Crear un sistema de detección de fallos en un motor diésel marino y calcular su rendimiento en tiempo real.
- Validar el sistema mediante datos obtenidos en situaciones reales.
- Realizar pruebas significativas con el sistema y difundir los resultados.

Se espera que los resultados incluyan una plataforma fiable para realizar estudios orientados a aumentar la sostenibilidad. El sistema será capaz de prever condiciones que no son fácilmente obtenibles en el activo real, como sobrecargas o averías. Posteriormente, este sistema puede extenderse para mejorar la gestión del mantenimiento, optimizar costes y recursos humanos y minimizar las pérdidas, permitiendo una planificación más efectiva de los mantenimientos y reduciendo paradas no programadas.

Tipo	Objetivo	Grado de consecución
Principal	Creación de un sistema de detección de fallos y predicción del rendimiento	80%
Secundario	Validación del sistema	50%
Secundario	Difusión de resultados	50%

Figura II. Consecución de objetivos.

3. Tareas realizadas:

- **Fase 1: Elaboración de base de datos para la creación y validación del sistema.**

En primer lugar, se ha hecho una revisión sistemática y exhaustiva de la bibliografía acerca de: bases de datos de fallos, detección de fallos y predicción de fallos en motores diésel marinos.

Resumidamente:

- Se ha encontrado únicamente una base de datos en abierto, 3500-Default [13]: es un conjunto de datos compuesto por 3500 escenarios de fallos, obtenidos a partir de un modelo de motor diésel de 4 tiempos y 6 cilindros en línea.
- Existen multitud de referencias acerca de bases de datos de fallos, en las que detallan las variables y fallos a tener en cuenta. No obstante, no se hacen públicas las bases de datos.

Considerando todo ello, se ha decidido elaborar, *Figura III*, una base de datos de fallos propia a partir de un modelo termodinámico ya creado [14]. Han sido de gran utilidad referencias como [3], [15], [16], [17].

A esta fase se ha dedicado un porcentaje alto de tiempo, tanto para optimizar el funcionamiento del modelo termodinámico, *Figura IV*, como para la creación de la base de datos. Queda pendiente, no obstante, la mejora del modelo termodinámico: se ha utilizado un mapa de compresor que, debido a la ausencia de información, no devuelve resultados del todo satisfactorios.

	Time	IMEP@In	Engine_SPEED@In	MF_FUEL@In	MF_IA@In	Engine_TORQUE@In	Turbo_SPEED@In	Pressure_Ratio@In	P_IA@In	T_IA@In
0	time~s	pressure~bar	ang_vel~rpm	massflow~kg_h	massflow~kg_h	moment~Nm	ang_vel~rpm	no_unit~none	pressure~bar	temperature~degC
1	0.0000000	0.0000000e+00	7.5000000e+02	0.0000000e+00	0.0000000e+00	0.0000000e+00	2.3383000e+04	2.9322548e+00	9.8900000e+00	2.9000000e+01
2	1.0000000	5.6011358e+01	7.5000000e+02	0.0000000e+00	7.4471871e+03	7.0238458e+03	2.2816229e+04	2.8404633e+00	9.8900000e+00	2.9000000e+01
3	2.0000000	9.4923584e+01	7.5000000e+02	3.8855134e+02	8.3622913e+03	2.9452949e+04	2.2345932e+04	2.7621681e+00	9.8900000e+00	2.9000000e+01
4	3.0000000	2.0632001e+02	7.5000000e+02	3.9699727e+02	9.9328949e+03	3.0502014e+04	2.1782507e+04	2.6609776e+00	9.8900000e+00	2.9000000e+01
5	4.0000000	2.0463369e+02	7.5000000e+02	3.9551184e+02	1.0564056e+04	3.0164919e+04	2.1236562e+04	2.5784049e+00	9.8900000e+00	2.9000000e+01
6	5.0000000	2.0243918e+02	7.5000000e+02	3.9520412e+02	1.0293020e+04	2.9959621e+04	2.0745567e+04	2.5058543e+00	9.8900000e+00	2.9000000e+01
7	6.0000000	2.0070830e+02	7.5000000e+02	3.9521674e+02	1.0125727e+04	2.9724154e+04	2.0303024e+04	2.4427364e+00	9.8900000e+00	2.9000000e+01
8	7.0000000	1.9926072e+02	7.5000000e+02	3.9520442e+02	9.9930925e+03	2.9538099e+04	1.9879792e+04	2.3832941e+00	9.8900000e+00	2.9000000e+01
9	8.0000000	1.9798994e+02	7.5000000e+02	3.9521584e+02	9.8257502e+03	2.9349225e+04	1.9470267e+04	2.3233030e+00	9.8900000e+00	2.9000000e+01
10	9.0000000	1.9711390e+02	7.5000000e+02	3.9521572e+02	9.6844697e+03	2.9172952e+04	1.9082510e+04	2.2699692e+00	9.8900000e+00	2.9000000e+01
11	1.0000000	1.9598299e+02	7.5000000e+02	3.9521615e+02	9.5269558e+03	2.8987751e+04	1.8694275e+04	2.2218188e+00	9.8900000e+00	2.9000000e+01
12	1.1000000	1.9492507e+02	7.5000000e+02	3.9521644e+02	9.3811380e+03	2.8819967e+04	1.8333639e+04	2.1778559e+00	9.8900000e+00	2.9000000e+01
13	1.2000000	1.9393918e+02	7.5000000e+02	3.9521948e+02	9.2292406e+03	2.8669877e+04	1.7977383e+04	2.1372471e+00	9.8900000e+00	2.9000000e+01
14	1.3000000	1.9303811e+02	7.5000000e+02	3.9521886e+02	9.0710166e+03	2.8533887e+04	1.7627665e+04	2.0943096e+00	9.8900000e+00	2.9000000e+01
15	1.4000000	1.9216731e+02	7.5000000e+02	3.9522228e+02	8.9305507e+03	2.8413164e+04	1.7315368e+04	2.0561650e+00	9.8900000e+00	2.9000000e+01
16	1.5000000	1.9130719e+02	7.5000000e+02	3.9522301e+02	8.8037683e+03	2.8295588e+04	1.6995440e+04	2.0192077e+00	9.8900000e+00	2.9000000e+01
17	1.6000000	1.9047692e+02	7.5000000e+02	3.9522369e+02	8.6735619e+03	2.8190811e+04	1.6681364e+04	1.9822580e+00	9.8900000e+00	2.9000000e+01

Figura III. Parte de la base de datos obtenida con las simulaciones del modelo.

A esta fase se ha dedicado un porcentaje alto de tiempo, tanto para optimizar el funcionamiento del modelo termodinámico como para la creación de la base de datos. Queda pendiente, no obstante, la mejora del modelo termodinámico: se ha utilizado un mapa de compresor que, debido a la ausencia de información, no devuelve resultados del todo satisfactorios.





Figura IV. Ajustes del mapa del compresor como ejemplo de los diferentes ajustes realizados.

- **Fases 2 y 3: Desarrollo y validación del sistema aplicado al modelo termodinámico del motor real. Simulación de fallos en el modelo termodinámico del motor real.**

A partir de la base de datos creada, se ha desarrollado y validado un modelo de predicción de los fallos considerados basado en la simplicidad. Además, se ha calculado el rendimiento del motor para cada uno de los casos. El enfoque utilizado es de un problema de regresión, en vez de clasificación, que suele ser lo habitual en este tipo de estudios.

Los fallos considerados han sido: caída de presión excesiva en el filtro de aire, caída de eficiencia del enfriador de aire, caída de presión excesiva en el enfriador de aire, fallo del compresor de aire, fuga de aire en el colector de admisión, fallo de la inyección de combustible en todos los cilindros, fallo de la inyección en un subconjunto de cilindros, fallo de la turbina, reducción de la ratio de compresión, fallo en las válvulas.

Se integra, por tanto, un modelo capaz de detectar los fallos mencionados a partir de variables de interés en el motor, a la par que calcula el rendimiento.



```

7
8 print('-----')
9 print('FALLO 1: AIR FILTER EXCESSIVE PRESSURE DROP')
10 print('-----')
11
12
13 import numpy as np
14 import matplotlib.pyplot as plt
15 import pandas as pd
16 pd.set_option('display.max_columns', 500)
17
18
19 def obtainpress(ncase):
20     link = r'C:/Users/usuario/Desktop/simulation/IUTA/CRUISE_M_1.1_AIR_FILTER~RESSURE_DROP.Case_'+str(ncase)+'results/admisiÃ³ncompresor_gf_0.csv'
21     df = pd.read_csv(link, header = 0, low_memory=False)
22
23     df = df.iloc[1:]
24
25     for column in df:
26         df[column] = df[column].astype(float)
27     return df['Pressure total@MeasuringPoint 1'], df['Time']
28
29 def obtainmf(ncase):
30     link = r'C:/Users/usuario/Desktop/simulation/IUTA/CRUISE_M_1.1_AIR_FILTER~RESSURE_DROP.Case_'+str(ncase)+'results/admisiÃ³ncompresor_gf_0.csv'
31     df = pd.read_csv(link, header = 0, low_memory=False)
32
33     df = df.iloc[1:]
34
35     for column in df:
36         df[column] = df[column].astype(float)
37     return df['Mass flow@MeasuringPoint 1'], df['Time']
38
39 def obtainimep(ncase):
40     link = r'C:/Users/usuario/Desktop/simulation/IUTA/CRUISE_M_1.1_AIR_FILTER~RESSURE_DROP.Case_'+str(ncase)+'results/standardensors_cs_0.csv'
41     df = pd.read_csv(link, header = 0, low_memory=False)
42
43     df = df.iloc[1:]
44
45     for column in df:
46         df[column] = df[column].astype(float)
47     return df['IMEP@In'], df['Time']
48
49 def obtainmfia(ncase):
50     link = r'C:/Users/usuario/Desktop/simulation/IUTA/CRUISE_M_1.1_AIR_FILTER~RESSURE_DROP.Case_'+str(ncase)+'results/standardensors_cs_0.csv'
51     df = pd.read_csv(link, header = 0, low_memory=False)
52
53     df = df.iloc[1:]
54
55     for column in df:
56         df[column] = df[column].astype(float)
57     return df['MF_IA@In'], df['Time']
58
59 def obtainpower(ncase):
60     link = r'C:/Users/usuario/Desktop/simulation/IUTA/CRUISE_M_1.1_AIR_FILTER~RESSURE_DROP.Case_'+str(ncase)+'results/ejedecigÃ³neÃ±al_rm_0.csv'
61     df = pd.read_csv(link, header = 0, low_memory=False)
62
63     df = df.iloc[1:]

```

Figura IV. Ajustes del mapa del compresor como ejemplo de los diferentes ajustes realizados

- **Fase 4: Difusión de resultados.**

Se difundirán los resultados obtenidos en el 5º Congreso Anual de Estudiantes de Doctorado de la Universidad Miguel Hernández (ponencia aceptada), 14th National and 5th International Conference in Engineering Thermodynamics (ponencia aceptada) y en las Jornadas de Proyectos del IUTA.

Queda pendiente la publicación de artículos en revistas internacionales.

4. Resultados obtenidos:

El principal resultado obtenido es la obtención de un modelo capaz de predecir fallos y calcular el rendimiento de un motor diésel marino. Se han obtenido resultados satisfactorios para 9 de los 10 fallos considerados: los datos para el fallo 4 no son aceptables. Esto es debido a los problemas que ha habido a lo largo del proyecto, como ya se ha mencionado, con respecto al mapa del compresor. La ausencia de datos y la negación de las compañías a aportarlos provoca que el modelo termodinámico no sea óptimo.

Para el cálculo del rendimiento, en 7 de los 10 fallos ha sido posible obtener un comportamiento cualitativo satisfactorio.

Como ya se ha dicho, nuestro método es opuesto a lo habitual en la bibliografía, ya que hemos decidido plantear el problema mediante un enfoque de regresión, en vez de clasificación: predecimos determinados parámetros en función de las condiciones del motor en ese instante, para que así el técnico pueda evaluar si se está produciendo un fallo o no; en otros estudios, el propio modelo clasifica la situación del motor e indica qué fallo se produce. Pero este método aumenta la complejidad que debe tener el modelo, a la par que simplifica la casuística. Pero en un motor real se deben considerar casos intermedios, y nuestro método permite precisamente hacer eso mismo. Además, veremos a continuación que en muchos casos no hace falta más que una 'simple' regresión lineal para predecir el parámetro que nos indica que un fallo está ocurriendo.

En las Figuras V, VI y VII se exponen tres casos satisfactorios de la base de datos de fallos creada. Para cada caso, las gráficas en serie superiores muestran en el eje vertical el parámetro que representa el fallo, mientras que en el eje horizontal cada una de las variables que hemos considerado pueden ser representativas de la situación del motor con respecto a ese fallo. En la gráfica inferior de cada caso se representa el cálculo del rendimiento del motor con respecto al parámetro que varía.




Figura V. Resultados Fallo 1(Caída de presión en el filtro de aspiración del turbocompresor).




Figura VI. Resultados Fallo 3 (Caída de presión en el enfriador de aire).




Figura VII. Resultados Fallo 7 (Reducción de combustible en un cilindro).

Como se puede observar, en los tres casos tenemos una variable que permite predecir, mediante una regresión lineal, el valor del parámetro que estamos variando y que representa un fallo en el motor. Si se quiere aumentar la fiabilidad del modelo, se puede utilizar una regresión multilineal, o bien una regresión polinómica. No obstante, la importancia de nuestro enfoque es la simplicidad y la interpretabilidad del modelo frente a otras opciones más potentes que se tendrían que utilizar si se quiere plantear un método de clasificación.

5. Trabajos o necesidades futuras

Una mejora necesaria para el modelo es el ya mencionado mapa del compresor. Confiamos obtener más documentación y datos en futuras investigaciones para así obtener un modelo más fiable y realista.

Además, falta implementar y validar el modelo en un entorno real como sería un motor en funcionamiento.

6. Divulgación de los resultados

Título	Autores	PTT	Congreso	Lugar y fecha
Sistema de detección de fallos y predicción del rendimiento energético en el modelo termodinámico de un motor diésel marino	Raquel Martínez Martínez, Noelia Rivera Rellán, Luis Alfonso Díaz-Secades, Mateo Rodríguez Suárez	PPT Oral	<i>Congreso Anual Internacional de Estudiantes de Doctorado (V CAEID)</i>	Universidad Miguel Hernández (celebración online), 6-7 febrero 2025
Sistema de detección de fallos y predicción del rendimiento energético en un motor diésel marino	Raquel Martínez Martínez, Mateo Rodríguez Suárez	PPT Oral	<i>Jornadas de Proyectos IUTA</i>	Gijón (Spain), 2025
Real-Time Fault Detection and Energy Efficiency Optimization for Marine Diesel Engines: A Model-Based Approach	Raquel Martínez Martínez, Noelia Rivera Rellán, Aitor Nicolas Fernández Álvarez, Luis Alfonso Díaz-Secades	PPT Oral	<i>14th National and 5th International Conference in Engineering Thermodynamics (14CENIT)</i>	Zaragoza (Spain), 4-6 junio 2025

Figura VIII. Divulgación de los resultados.

Memoria económica:

1. Gastos:

Concepto	Gasto
Personal (IUTA)	3400 €
Fungibles	0 €
Amortización (Workstation)	625 €
Otros (Reunión en TWave, Congreso 14CNIT)	338,52 €
TOTAL GASTOS	4363,52 €

Figura IX. Gastos.

2. Ingresos:

Entidad/Empresa financiadora Ref. Proyecto/Contrato	Concepto	Ingreso
IUTA	Ayuda IUTA: Contratación de personal	3400 €
Otras entidades / empresas financiadoras	Departamento de Ciencia y Tecnología Náutica: Workstation y Congresos	900 €
Financiación propia	Kilometraje para reunión en TWave	13,52 €
TOTAL INGRESOS		4363,52 €

Figura X. Ingresos.

Bibliografía:

- [1] A. Vorkapić, R. Radonja, K. Babić, and S. Martinčić-Ipšić, "Machine learning methods in monitoring operating behaviour of marine two-stroke diesel engine," *Transport*, vol. 35, no. 5, pp. 474–485, 2020, doi: 10.3846/transport.2020.14038.
- [2] N. Xu, G. Zhang, L. Yang, Z. Shen, M. Xu, and L. Chang, "Research on thermoeconomic fault diagnosis for marine low speed two stroke diesel engine," *Mathematical Biosciences and Engineering*, vol. 19, no. 6, pp. 5393–5408, 2022, doi: 10.3934/mbe.2022253.
- [3] J. A. Pagán Rubio, F. Vera-García, J. Hernandez Grau, J. Muñoz Cámara, and D. Albaladejo Hernandez, "Marine diesel engine failure simulator based on thermodynamic model," *Appl Therm Eng*, vol. 144, pp. 982–995, 2018, doi: 10.1016/j.applthermaleng.2018.08.096.

- [4] M. A. Atoui, S. Verron, and A. Kobi, "Fault detection and diagnosis in a Bayesian network classifier incorporating probabilistic boundary," *IFAC-PapersOnLine*, vol. 28, no. 21, pp. 670–675, Sep. 2015, doi: 10.1016/J.IFACOL.2015.09.604.
- [5] R. Wang, H. Chen, and C. Guan, "A Bayesian inference-based approach for performance prognostics towards uncertainty quantification and its applications on the marine diesel engine," *ISA Trans*, vol. 118, pp. 159–173, Dec. 2021, doi: 10.1016/J.ISATRA.2021.02.024.
- [6] M. Cheliotis, I. Lazakis, and A. Cheliotis, "Bayesian and machine learning-based fault detection and diagnostics for marine applications," *Ships and Offshore Structures*, vol. 17, no. 12, pp. 2686–2698, 2022, doi: 10.1080/17445302.2021.2012015/ASSET/B2A50A6B-9108-48FE-A46A-60D1ACAC8A97/ASSETS/IMAGES/TSOS_A_2012015_F0011_OC.JPG.
- [7] J. Castresana, G. Gabiña, L. Martín, A. Basterretxea, and Z. Uriondo, "Marine diesel engine ANN modelling with multiple output for complete engine performance map," *Fuel*, vol. 319, 2022, doi: 10.1016/j.fuel.2022.123873.
- [8] Z. Chen and Y. F. Li, "Anomaly detection based on enhanced DBScan algorithm," *Procedia Eng*, vol. 15, pp. 178–182, 2011, doi: 10.1016/j.proeng.2011.08.036.
- [9] C. Patil and G. Theotokatos, "Comparative Analysis of Data-Driven Models for Marine Engine In-Cylinder Pressure Prediction," *Machines*, vol. 11, no. 10, 2023, doi: 10.3390/machines11100926.
- [10] P. Theodoropoulos, C. C. Spandonidis, F. Giannopoulos, and S. Fassois, "A Deep Learning-Based Fault Detection Model for Optimization of Shipping Operations and Enhancement of Maritime Safety," *Sensors 2021, Vol. 21, Page 5658*, vol. 21, no. 16, p. 5658, Aug. 2021, doi: 10.3390/S21165658.
- [11] Z. Ji, H. Gan, and B. Liu, "A Deep Learning-Based Fault Warning Model for Exhaust Temperature Prediction and Fault Warning of Marine Diesel Engine," *Journal of Marine Science and Engineering 2023, Vol. 11, Page 1509*, vol. 11, no. 8, p. 1509, Jul. 2023, doi: 10.3390/JMSE11081509.
- [12] C. Li and D. Cui, "Fault Diagnosis of Marine Diesel Engine Based on Multi-scale Time Domain Decomposition and Convolutional Neural Network," *Polish Maritime Research*, vol. 31, no. 3, pp. 85–93, Sep. 2024, doi: 10.2478/POMR-2024-0038.
- [13] D. Pestana, "Diesel Engine Faults Features Dataset (3500-DEFault)," vol. 1, 2020, doi: 10.17632/K22ZXZ29KR.1.
- [14] R. Martínez Martínez and N. Rivera Rellán, "Desarrollo de modelo digital de motor diésel marino a partir de medidas reales," Gijón, Jun. 2023.
- [15] F. Vera-García, J. A. P. Rubio, J. H. Grau, and D. A. Hernández, "Improvements of a Failure Database for Marine Diesel Engines Using the RCM and Simulations," *Energies 2020, Vol. 13, Page 104*, vol. 13, no. 1, p. 104, Dec. 2019, doi: 10.3390/EN13010104.
- [16] J. A. Pagán Rubio, F. Vera García, and J. Hernandez Grau, "Proceso de obtención de medidas experimentales y tratamiento de datos para modelado de motor diésel marino," Mar. 2015, doi: 10.31428/10317/9813.
- [17] J. Antonio Pagán Rubio, "Sistema de diagnóstico de motor diésel marino basado en el modelo termodinámico y de inteligencia artificial," 2017.



Instituto Universitario de Tecnología Industrial de Asturias (IUTA)

Institutu Universitariu de Teunoloxía Industrial d'Asturies
University Institute of Industrial Technology of Asturias



En Gijón, a 30 de diciembre de 2024

Fdo.: Prof. Raquel Martínez Martínez
Investigadora del IUTA