



Análisis de metodologías de modelado de motores diésel marinos para su diagnosis y mantenimiento basado en condiciones



Joseba Castresana Larrauri

Codirigida por:

Dr. Zigor Uriondo Arrue

Dr. Leopoldo Martín Gómez

Bilbao, septiembre 2022

Análisis de metodologías de modelado de motores diésel marinos para su diagnosis y mantenimiento basado en condiciones

Tesis presentada por:

Joseba Castresana Larrauri

Codirigida por:

Dr. Zigor Uriondo Arrue

Dr. Leopoldo Martín Gómez

Programa de doctorado de la UPV/HU:

**Eficiencia Energética y Sostenibilidad en Ingeniería y
Arquitectura**



Ingeniaritza
Energetikoa
Saia
Departamento
de Ingeniería
Energética



La presente tesis doctoral ha sido financiada por el departamento de Desarrollo Económico, Sostenibilidad y Medio Ambiente del Gobierno Vasco. El autor de la tesis Joseba Castresana Larrauri se ha beneficiado de una beca predoctoral del programa *“Ayudas de formación a personal investigador y tecnólogo para 2019, en el entorno científico-tecnológico y empresarial del sector agropesquero y alimentario vasco”*, trabajando en el centro tecnológico AZTI-BRTA desde el año 2019.



GRACIAS.

Quiero empezar agradeciendo a mis directores de tesis Gorka Gabiña, Zigor Uriondo y Leopoldo Martín por todo el tiempo y la paciencia que han dedicado a transmitirme su experiencia en el mundo de los motores, tanto a nivel teórico como práctico. Y es que, en estos años he tenido la suerte de aprender muchas cosas que no estaban en aquellos apuntes de la universidad, desde arreglar un caudalímetro hasta achicar un taller inundado. Eskerrik asko también a Aingeru, por esos días de ensayos en Portugalete, en los que he aprendido mucho de vuestra experiencia en el mar y he tenido también la suerte de compartir cafés y ruido de motor.

También quiero agradecer a las personas de AZTI por haberme hecho sentir como en casa en los últimos tres años. Al equipo de Tecnologías Pesqueras Sostenibles, Elsa, Mikel, Angel, Jose Mari, Iñaki, Peli, Esteban, Oihane, Xabi, Iñigo. Día a día he tenido la suerte de aprender no sólo sobre motores, sino también de otros proyectos de esta área que son para mí algo completamente nuevo y muy interesante. Eskerrik asko a la gente de Sukarrieta, Itsaso, Antonio, Maite, Ane, Maria, Imanol, Iker, Carla, Xavi, Cris, Aitor, Uxue, Isa, Raquel, Xabi, Natalia, Iraide, Oriol, Rebe, Arka, Dani, Iñaki, Mónica, Txeli, Aitzi, Jose Angel, Irati, Ibai, Cesar... y a todas las personas que habéis hecho de este proyecto una experiencia.

También agradecer a la cuadrilla, y a toda la gente con la que he compartido estos años en Mundaka, es una suerte vivir aquí. Especialmente, eskerrik asko Gontzal, porque desde “nire errekorra” de andereño Mertxe he podido compartir contigo hasta las siestas en la universidad. Eskerrik asko también al grupo del agua, Pelot, Txani, Txente, Ibai, Gaizki, Ando, Illan, Maiki, Sisko, Craig, Mutri, porque hemos pasado muchos mares juntos y habéis tenido que aguantar los peores maretones de esta tesis.

A la familia, aita eta ama, anai, eskerrik asko por enseñarme tanto. Sois un ejemplo a seguir, un referente del que he tenido la suerte de aprender y sigo aprendiendo constantemente. Eskerrik asko por todo vuestro apoyo y cariño, desde las regatas de Sestao con Sabino y presi, hasta las sobremesas de “en mi viejo San Juan” con la guitarra de ama. Eskerrik asko también a Igontxu, por tu alegría y tu constante sonrisa.

Eta zelan ez, zuri Batir, eskerrik asko urte guzti honetan albuen egotiegaitzik, Berlinetik eta Bakiora hau beste pasarte bat izen dalako, eta gauzen lekuen egonda, zorioneko sentitzen nazelako zure onduen egotiez. Eskerrik asko.

ÍNDICE

ÍNDICE DE FIGURAS	1
ÍNDICE DE TABLAS	5
EXTRACTO.....	9
RESUMEN	15
INTRODUCCIÓN	23
Contexto	26
Estado del arte	36
Hipótesis.....	49
Objetivos	49
Estructura de la tesis.....	51
CONTRIBUCIONES CIENTÍFICAS.....	53
CAPÍTULO 1. Comparación de modelos termodinámicos y de redes neuronales artificiales para la predicción de parámetros de funcionamiento y emisiones en un motor diésel de un cilindro	57
1- Resumen	60
2- Material y métodos.....	63
3- Resultados.....	96
4- Discusión	105
5- Conclusiones	109
CAPÍTULO 2. Modelado de motor diésel marino mediante redes neuronales artificiales para el cálculo de múltiples parámetros de operación en su mapa de funcionamiento completo	113
1- Resumen	116
2- Material y métodos.....	119
3- Resultados.....	134
4- Discusión	145
5- Conclusiones	150
CAPÍTULO 3. Caracterización de valores límite de desviaciones de múltiples parámetros de funcionamiento de un motor diésel a bordo de un buque atunero mediante redes neuronales artificiales y funciones de densidad de probabilidad.....	153
1- Resumen	156
2- Material y métodos.....	158
3- Resultados.....	175
4- Discusión	186
5- Conclusiones	192
DISCUSIÓN GENERAL.....	195

CONCLUSIONES Y TESIS.....	213
1- Conclusiones	215
2- Tesis.....	219
TRABAJO FUTURO	221
REFERENCIAS BIBLIOGRÁFICAS	227
ANEXOS I: Regresiones para parámetros del motor YANMAR 6HYM-WET (Capítulo 2)	243
ANEXOS II: Contribuciones científicas	249

ÍNDICE DE FIGURAS

INTRODUCCIÓN

Figura In. 1 Demanda global de petróleo y gasoil y proyección a futuro según IEA.....	28
Figura In. 2 Número de incidentes de la flota de la UE entre 2014-2020.....	30
Figura In. 3 Número de buques de las flotas pesqueras de la UE y España 2012-2021	33
Figura In. 4 Decremento porcentual de las flotas pesqueras de la UE y España 2013-2021	34
Figura In. 5 Porcentaje de artículos presentados en torno al modelaje de motores diesel [57]	37
Figura In. 6 N ^o publicaciones AVL Boost 2008-2020 [87].....	41
Figura In. 7 Modelo desarrollado para motor YANMAR-6HYM WET.....	42
Figura In. 8 Esquema de una red neuronal artificial	44

CAPÍTULO 1

Figura C1. 1 Imagen del banco de pruebas con motor Minsel430a.....	64
Figura C1. 2 Esquema de banco de ensayos con equipamiento de monitorización.....	65
Figura C1. 3 Proceso de adquisición de datos de ensayos con el Minsel430a.....	66
Figura C1. 4 Esquema del Minsel430a en AVL Boost™	67
Figura C1. 5 Esquema del sistema considerado como cilindro	69
Figura C1. 6 Asignación de variable RPM a la velocidad de giro del modelo termodinámico	74
Figura C1. 7 Curva de apertura de válvula de modelo de motor Minsel430a	76
Figura C1. 8 Imagen del sistema de adquisición y representación de las curvas de presión de combustión.....	78
Figura C1. 9 Filtrado de curva de presión de combustión mediante filtro de Butterworth	78
Figura C1. 10 Esquema de red neuronal propuesta para Minsel430a.....	79
Figura C1. 11 Esquema de una neurona	81
Figura C1. 12 Función de coste C	85
Figura C1. 13 Actualización de factores de peso.....	86
Figura C1. 14 Efecto del offset del punto muerto superior	98
Figura C1. 15 Curvas de presión de combustión.....	99
Figura C1. 16 Regresiones de cálculos de entrenamiento para BSFC, Texh, CO y NOx	100
Figura C1. 17 Resultados de modelos termodinámico, redes neuronales y valores experimentales.....	102
Figura C1. 18 Evolución de MAPE respecto a la potencia del motor	103

CAPÍTULO 2

Figura C2. 1 Buques de pesca de mediano porte, representativos del caso de estudio	119
Figura C2. 2 Imagen del motor YANMAR 6HYM-WET	120
Figura C2. 3 Esquema sensorización motor YANMAR 6HYM-WET	122
Figura C2. 4 Cúbicas del motor y mapa de funcionamiento	127
Figura C2. 5 Ensayos experimentales y adquisición de datos	129
Figura C2. 6 Esquema de la red neuronal artificial desarrollada para el YANMAR 6HYM-WET	130
Figura C2. 7 Resultados de R y MSE de validación para diferentes números de neuronas en la capa oculta	132
Figura C2. 8 Regresión de parámetros calculados para T01 en los registros de test.....	135

Figura C2. 9 Regresiones de 16 parámetros representativos calculados para los 24 registros de test	136
Figura C2. 10 Resultados de test para el consumo de fuel, P03, T16 y NOx.....	139
Figura C2. 11 Valores de MAPE para registros de test de cúbicas y puntos aleatorios	141
Figura C2. 12 Resultados de errores MAPE para el test en puntos aleatorios de funcionamiento	144

CAPÍTULO 3

Figura C3. 1 Buque cerquero atunero congelador de similares características al empleado en el estudio. Fuente: Industrias Pesqueras	158
Figura C3. 2 Esquema de adquisición de datos a bordo de buque atunero	160
Figura C3. 3 Esquema de bomba de combustible y cremallera instalados en un motor diésel marino [205].....	162
Figura C3. 4 Planteamiento del problema ATE-HEFAT2021.....	165
Figura C3. 5 Errores obtenidos para la comparación de ANN inicial y ANN reducido	166
Figura C3. 6 Desviaciones relativas vs coeficientes de correlación de parámetros.....	168
Figura C3. 7 Clasificación de parámetros por estrategias de modelado.....	170
Figura C3. 8 Proceso de ajuste de funciones de densidad de probabilidad.....	172
Figura C3. 9 Redes neuronales propuestas para los diferentes subsistemas del motor	174
Figura C3. 10 Resultados de MAPE para cálculos de ANN con datos de test de 2020	178
Figura C3. 11 Predicciones para 50 registros de test de Texh_TCut y FORACK	180
Figura C3. 12 Validación de valores límite establecidos por las funciones de densidad de probabilidad	183
Figura C3. 13 Valores de MAPE para predicciones de ANN en 2020 y 2021.....	184
Figura C3. 14 Valores límite de los 57 parámetros del motor estudiados.....	191

DISCUSIÓN, CONCLUSIONES Y TESIS Y TRABAJO FUTURO

Figura D. 1 Modelo de AVL Boost y resultados de sus cálculos	200
Figura D. 2 Desarrollo de la tesis doctoral. Motores analizados y bases de datos utilizadas ...	210
Figura D. 3 Ensayo y medición de obstrucción de filtro de aire.....	225

ÍNDICE DE TABLAS

CAPÍTULO 1

Tabla C1. 1 Características del motor Minsel430.....	63
Tabla C1. 2 Lista de variables registradas y sensores utilizados con niveles de incertidumbre de cada sensor.....	65
Tabla C1. 3 Reacciones químicas consideradas para cálculo de emisiones de NOx	71
Tabla C1. 4 Reacciones químicas consideradas para cálculo de emisiones de CO	72
Tabla C1. 5 Funciones de activación más comunes	83
Tabla C1. 6 Estructuras de ANN, algoritmos de optimización y funciones de transferencia.....	93
Tabla C1. 7 Valores de error de predicción para diferentes números de neuronas y algoritmos de entrenamiento	95

CAPÍTULO 2

Tabla C2. 1 Características principales del motor YANMAR 6HYM-WET	120
Tabla C2. 2 Sensores utilizados en el motor YANMAR 6HYM-WET	123

CAPÍTULO 3

Tabla C3. 1 Características del motor estudiado.....	159
Tabla C3. 2 Instrumentación de adquisición de datos e incertidumbres.....	161
Tabla C3. 3 PDFs, intervalos de confianza, valores límite y sus desviaciones límite correspondientes	176

EXTRACTO

Extracto

La presente tesis doctoral analiza las diferentes estrategias de modelado de motores diésel marinos existentes en el marco de su diagnóstico y mantenimiento basado en condiciones. Concretamente, tras una fase preliminar en la que se analizan y prueban experimentalmente el modelo termodinámico y el modelo de redes neuronales artificiales en un motor diésel de un cilindro, se concluye que ambos muestran niveles de error relativamente bajos pero que el modelo termodinámico requiere tiempos de cálculo notablemente mayores. Partiendo de esta base, consecutivamente se ha modelado un motor diésel marino de 6 cilindros empleando las redes neuronales artificiales. En este motor, se ha analizado el nivel de precisión de las redes neuronales para cualquier condición del motor dentro de su mapa de funcionamiento completo (considerando el efecto de factores externos como la meteorología o corrientes) para calcular 35 parámetros de funcionamiento y emisiones simultáneamente. Entre los resultados, las redes neuronales han mostrado errores por debajo del 8,5% para todos los parámetros calculados a excepción de las emisiones de CO y NO₂ que debido a sus bajas concentraciones en este tipo de motores han mostrado errores mayores. Se ha demostrado pues, el potencial de este tipo de metodología para mostrar la imagen completa del estado de un motor marino para cualquier punto dentro de su mapa de funcionamiento y con tiempos de cálculo admisibles para procesos de modelado en tiempo real (0,109 segundos). Por último, se ha analizado la actividad de un motor diésel de 9 cilindros a bordo de un buque atunero operativo durante los años 2020 y 2021, procesando hasta 5.181 horas de funcionamiento sin ningún fallo. Por consiguiente, se han calculado los valores límite de las desviaciones que puedan sufrir 57 parámetros diferentes del motor dentro de su funcionamiento correcto, con objeto de proveer una referencia útil para establecer límites de desviaciones representativas de fallos en futuros trabajos de investigación en el campo de la diagnosis y el mantenimiento basado en condiciones de los motores diésel marinos.

Abstract

The present doctoral thesis aims to analyse the existent marine diesel engine modelling techniques in terms of their diagnosis and condition-based maintenance. Concretely, after a preliminary comparison between two of the most used modelling techniques which are the thermodynamic model and the artificial neural networks, its concluded that both modelling approaches provide relatively low error levels but that the thermodynamic model needs considerably more time to undertake the calculations. Taking this into account, consecutively a six-cylinder marine diesel engine has been modelled employing artificial neural networks. In this engine, the accuracy level of artificial neural networks to represent any random condition of the engine inside its complete performance map has been further analysed (operating in an environment of variable meteorology or marine currents), predicting 35 different performance and emission conditions simultaneously. Among the results, errors below 8.5% have been reached for all the predicted parameters with exception of CO and NO₂ which showed higher error levels due to their low concentration values in these types of engines. The potential of this kind of methodologies to reproduce a complete image of the state of an engine has been thus demonstrated, even when performing on random conditions of the complete engine performance map and showing low calculation times (0.109 seconds). This low calculation time makes this methodology applicable in real time modelling processes. Finally, the performance of a nine-cylinder marine diesel engine working on an operative tuna fishing vessel has been analysed through 2020 and 2021 years, processing up to 5,181 engine working hours without any fault occurrence. Hence, threshold deviation values have been determined for 57 different engine parameters considering healthy engine condition, aiming to provide a source of reference to establish faulty condition threshold deviations in future studies in the field of marine diesel engine diagnosis and condition-based maintenance.

Laburpena

Doktorego tesi honetan, gasoliozko itsas motorren modelatze estrategia desberdinak aztertzen dira, hauen diagnosi eta kondizioetan oinarritutako mantenuaren ikuspegitik. Tesiko lehenengo fase baten, modeloak sortzeko metodologia erabilienetako bi aztertu eta konparatu dira zilindro bakarreko motor bat simulatuz: modelo termodinamikoak eta sare neuronal artifizialak. Konparaketa honetatik, bien zehaztasun maila altua ondoriozta daiteke, baina betiere modelo termodinamikoak denbora nabarmen gehiago behar izanik kalkuluak burutzeko. Guzti hau kontuan izanda, bigarren fasean sei zilindroko gasoliozko itsas motor bat simulatu da sare neuronal artifizialak erabiliz. Motor honetan, bere funtzionamendu mapako edozein puntutan 35 operazio eta emisio parametro iragarri dira aldi berean, iragarpenen zehaztasun maila analizatuz (motorrak eguraldi eta korrante aldakorren eragina pairatuz). Eraitzen artean, parametro guztiak 8,5% errorearen azpitik kalkulatu direla ondoriozta daiteke, CO eta NO₂ parametroak izan ezik, hauen kontzentrazio baxuen ondorioz errore handiagoak aurkeztu baitituzte. Beraz, motorraren egoera osotasunez erakusten duen irudia iragarri ahal izateko, sare neuronalek daukaten ahalmena frogatu da, motorraren funtzionamendu mapa osoko edozein punturako eta kalkulu denbora baxuetan (0,109 segundo). Azkenik, atunontzi batean instalatuta dagoen 9 zilindroko motor baten operazioa aztertu da 2020 eta 2021 urteetan zehar, motorraren hutsegite gabeko 5.181 funtzionamendu ordu aztertuz. Honela, motorreko 57 aldagai desberdinentzako desbiderapen mugak kalkulatu dira, etorkizunean hutsegiteak adierazten dituzten desbiderapenak behar bezala ezartzeko erreferentzia bat eskainiz, betiere diagnosi eta kondizioetan oinarritutako mantenuaren ikuspegitik.

RESUMEN

Resumen extendido

El transporte marítimo ha sido el medio de transporte de bienes más utilizado a nivel mundial en las últimas dos décadas, suponiendo el 80% de bienes transportados en 2020. En este aspecto, existen ya varias medidas como el Plan del Objetivo Climático para 2030 de la Comisión Europea para reducir los gases de efecto invernadero tanto en el medio marino como en los demás medios, con el último objetivo de eliminar las emisiones para el año 2050. En este marco, se espera que en un futuro los combustibles alternativos como el Gas Natural Licuado (LNG) o los sistemas de propulsión alternativos como el sistema híbrido-eléctrico jueguen un papel muy importante. Sin embargo, lo cierto es que, a día de hoy, la demanda de gasoil y de petróleo a nivel mundial es cada año mayor, lo que hace pensar que este combustible y los sistemas de propulsión marinos que lo emplean sigan utilizándose al menos a corto medio plazo.

En este marco, pese a que el transporte marítimo es un pilar fundamental del transporte de bienes global, lo cierto es que los incidentes marinos se siguen produciendo en la actualidad. Respecto a estos incidentes, la pérdida de propulsión de los buques ha sido la principal causa de pérdida de operación del buque desde el año 2014, ocasionando una media del 22% de los incidentes anuales de la flota europea. Además, este hecho viene dado en un contexto en el que la flota pesquera española decrece en torno a un 2% año a año, sufriendo un decremento mayor que la media europea. Por tales razones, la implementación de estrategias de diagnóstico y mantenimiento basado en condiciones en los sistemas de propulsión marinos podría llegar a reducir tales números de incidentes dados por la pérdida de propulsión en los buques y ayudar a incrementar la seguridad en un tipo de transporte ya de por sí considerado muy seguro.

En el marco del mantenimiento preventivo de buques, las metodologías de modelado de motores y desarrollos de gemelos digitales han provocado un creciente interés en los últimos años. Y es que, mediante la creación de un modelo que imite con gran precisión el funcionamiento del motor, los fallos o anomalías pueden identificarse después observando las desviaciones entre los parámetros modelados y los parámetros reales. Por ello, la presente tesis aborda el análisis de diferentes metodologías de modelado de motores diésel, centrándose en los motores diésel marinos. En una primera fase de la tesis, se ha realizado una revisión bibliográfica de las diferentes metodologías de modelado de motores. Entre las estrategias, en las últimas dos décadas se ha observado una tendencia hacia el uso de ordenadores para resolver los cálculos de los modelos. Hasta finales de los años 90, la metodología predominante fue el modelado termodinámico mediante la resolución de ecuaciones de conservación puramente teóricas. En estos modelos se llegaban a predecir algunos pocos parámetros como

velocidad de giro o consumo de combustible del motor. Más adelante, desde comienzos de la década del año 2000 se ha visto una tendencia hacia el uso de otros simuladores basados en softwares de simulación como Ricardo Wave, AVL Boost o Matlab/Simulink. En estos softwares, es necesario introducir características físicas del motor, para que el software utilice estos datos en combinación con las ecuaciones de conservación para calcular los parámetros del motor. Más recientemente, se ha apreciado una clara tendencia hacia las herramientas basadas en datos. Muchos trabajos de investigación agrupan estas herramientas dentro del término Machine Learning, que no es sino una forma de denominar estas metodologías basadas en enfoques matemáticos. Entre ellas se encuentran los Support Vector Machine en su mayoría utilizado como clasificador para identificar diferentes situaciones del motor (entre ellas situaciones de fallos), los enfoques de Análisis de componentes principales que junto con otros clasificadores (K-nearest neighbour, algoritmo de Naive Bayes) logran también identificar distintas situaciones del motor, y las redes neuronales artificiales, que en términos de regresión y cálculo de parámetros son la herramienta más utilizada en el campo del modelado de motores. Se concluye pues, de una revisión bibliográfica preliminar que las dos metodologías más empleadas para modelar motores diésel son: modelos termodinámicos desarrollados en softwares y redes neuronales artificiales.

Con objeto de cuantificar las ventajas y desventajas presentadas por cada enfoque, se ha simulado un motor diésel de un cilindro Minsel430a mediante un modelo termodinámico desarrollado en el software AVL Boost, y también mediante un modelo de redes neuronales artificiales. Este motor relativamente pequeño ofrecía la posibilidad de adquirir experiencia en las diferentes estrategias de modelado, a la vez que permitía cuantificar la efectividad de cada metodología de forma experimental y sin alto coste. De hecho, su rango de consumo de combustible alcanza como máximo los 5 l/h que resulta relativamente bajo en comparación a los consumos de otros motores utilizados más adelante en la presente tesis. En cuanto al ajuste del modelo termodinámico, se han introducido primero las características físicas de los diferentes elementos del motor (ratio de compresión, características de los cilindros, curvas de apertura y cierre de válvulas etc.). Consecutivamente, se ha definido el modelo de combustión utilizando el modelo "Multiple Vibe 2-Zone" que tiene como base la suma ponderada de varias funciones Vibe para definir la curva de tasa de liberación de calor (curva ROHR). Este modelo ha sido después validado comparando las curvas de presión de combustión modeladas y las curvas de presión de combustión reales para diferentes puntos de carga del motor.

Por otro lado, el modelo de redes neuronales ha sido desarrollado en la librería Keras del entorno de programación Python. Se ha realizado una comparación innovadora entre diferentes algoritmos de optimización en el campo del modelado de motores diésel, ya que se han comparado el algoritmo de optimización Adam (soportado en la librería Keras de Python) y el algoritmo de optimización Levenberg-Marquardt (soportado en Matlab) que hasta el momento no habían sido comparados en este tipo de aplicaciones. Tras desarrollar una red neuronal en cada software y analizar el error de entrenamiento al emplear estos dos algoritmos de optimización, el algoritmo Levenberg-Marquardt ha demostrado ser más eficaz en términos de niveles de precisión. Al mismo tiempo, se ha aprovechado esta comparación y análisis de error para determinar el número óptimo de neuronas en la capa oculta del modelo de redes neuronales.

Para comparar el rendimiento de cada metodología, tras el ajuste de cada modelo, se han calculado cuatro parámetros del motor para 20 situaciones diferentes; estos parámetros son: consumo específico de combustible, temperatura de gases de escape y emisiones de NO_x y de CO. De esta comparación, se concluye principalmente que el modelo termodinámico y el de redes neuronales han ofrecido niveles de error similares, pero que el modelo termodinámico requiere un tiempo de cálculo mucho mayor. Mientras que las redes neuronales han calculado los cuatro parámetros en 20 situaciones diferentes en 0,52 segundos, el modelo termodinámico ha necesitado 1.234,29 segundos. En cuanto al nivel de precisión, cada modelo ha sido mejor (en términos de error de cálculo) para algunos parámetros y rangos de carga concretos. Para el consumo específico de combustible se ha logrado un nivel de exactitud más alto en las redes neuronales artificiales, para todo el rango de carga del motor. En cuanto a la temperatura de gases de escape, el modelo termodinámico ha mostrado errores más bajos para cargas medias bajas mientras que para cargas muy bajas y cargas medias altas las redes neuronales han ofrecido mejores resultados. No obstante, los niveles de errores alcanzados por ambos modelos para estos dos parámetros han sido relativamente bajos, con errores por debajo de 6% para el consumo específico de combustible y por debajo de 2% para la temperatura de gases de escape.

Para los parámetros de emisiones, las emisiones de CO han sido calculadas con mayores niveles de precisión por el modelo termodinámico para todo el espectro de carga del motor exceptuando las cargas más altas, en las que parece que el modelo termodinámico no ha sido capaz de reproducir el incremento de este parámetro. Por último, las emisiones de NO_x han sido calculadas con altos niveles de precisión por ambos modelos (por debajo de 4%), exceptuando las cargas más bajas del motor.

Se concluye pues, que pese a que los niveles de precisión ofrecidos por ambos modelos son notablemente altos, el tiempo de cálculo requerido por el modelo termodinámico es demasiado alto para ser aplicado en procesos de modelado en tiempo real. Por ello y porque la cantidad de variables disponibles en el segundo motor de la tesis es relativamente grande, se ha decidido emplear las redes neuronales artificiales para modelar este segundo motor diésel marino de 6 cilindros. Este es un motor YANMAR 6HYM-WET con una potencia nominal de 400kW y 2.100 rpm de velocidad de giro nominal y es empleado en buques de pesca o transporte de medio porte (250-400 GT). Tras profundizar en la literatura existente del modelado de motores diésel mediante redes neuronales artificiales, se ha observado que como mucho los modelos desarrollados hasta el momento calculan un máximo de 8-10 parámetros simultáneamente, mostrando únicamente una imagen parcial del estado del motor. Por ello, y aprovechando la gran cantidad de variables registradas en este nuevo motor, se ha propuesto predecir 35 parámetros de funcionamiento y emisiones del motor utilizando 8 variables como inputs: potencia y velocidad de giro, condiciones ambientales, temperatura del agua de alta temperatura a la entrada del motor, temperatura del aceite a la entrada del motor y temperatura del agua de baja temperatura a la entrada del enfriador de aire. De esta forma se pretende estudiar la aplicabilidad de las redes neuronales para calcular la imagen completa del estado de un motor diésel marino en tiempo real. Además, se ha observado que la mayoría de los estudios se limitan a puntos de operación concretos de los motores a la hora de modelarlos. Por tal razón, se ha considerado el mapa de funcionamiento completo de este motor de 6 cilindros, incluyendo diferentes funciones cúbicas de “potencia vs velocidad de giro” representando condiciones dadas por factores externos como la meteorología o las corrientes marinas. Tras determinar el número óptimo de neuronas en la capa oculta del modelo mediante el estudio del error de validación, se ha entrenado y validado el modelo de redes neuronales artificiales. Para la fase de testeo de la red, se han escogido puntos provenientes de las funciones cúbicas del motor (de las cuales se espera un bajo error de cálculo) y puntos aleatorios del mapa de funcionamiento completo del motor.

Entre los resultados, se observa que las redes neuronales artificiales son capaces de calcular 35 parámetros de funcionamiento y emisiones del motor para cualquier punto aleatorio de su mapa de funcionamiento (incluyendo factores meteorológicos u otro tipo de factores externos) con un error de cálculo por debajo del 8,5% a excepción de dos parámetros: CO y NO₂. Estos dos parámetros han mostrado errores de 25,60% y 48,84% posiblemente causados por sus bajas concentraciones en este tipo de motores. Sin embargo, el resto de los parámetros han mostrado errores relativamente bajos, demostrando que es posible representar la imagen completa de un

motor en cualquier punto de su funcionamiento. Es más, los parámetros pertenecientes a algunos subsistemas han mostrado errores de cálculo considerablemente bajos. Concretamente, los parámetros pertenecientes a los subsistemas de agua de baja y alta temperatura, circuito de aceite y circuito de gases de escape han mostrado errores por debajo de 4,3% para los puntos aleatorios del mapa de funcionamiento del motor.

Por último, una vez demostrada la capacidad de simulación de las redes neuronales artificiales aun considerando cualquier condición de los motores diésel marinos, es necesario cuantificar qué desviaciones entre modelo y realidad son representativas de una anomalía y cuáles no lo son. En algunos estudios se establecen distintas desviaciones porcentuales para situaciones de fallo concretas del motor. Por ejemplo, en caso de que la presión diferencial del filtro de aire dada por el modelo se desvíe más de un 10% de la presión diferencial real, se considera que el filtro pueda estar obstruido. Sin embargo, dichas desviaciones límite no están debidamente justificadas, por lo que se estima necesario un estudio riguroso de estas desviaciones para los distintos parámetros medidos en los motores diésel marinos. Por ello, se ha estudiado el funcionamiento de un motor diésel de 9 cilindros a bordo de un buque atunero operativo durante los años 2020 y 2021.

En una primera fase de este estudio, se ha realizado un análisis de desviaciones y correlaciones de todas las variables medidas en el motor durante el año 2020. Y es que, en el caso de las redes neuronales artificiales, en el estudio presentado en el congreso internacional ATE-HEFAT 2021 se demostró que la inclusión de variables con bajas correlaciones como inputs en un modelo de redes neuronales perjudican el nivel de precisión de dicho modelo. De esta forma, mediante este análisis de desviaciones y correlaciones se ha determinado qué parámetros podrían modelarse empleando redes neuronales y cuáles deberían modelarse empleando técnicas de modelado alternativas. Precisamente, aquellos parámetros que han presentado valores bajos de desviaciones y correlaciones durante 2020, mostrando tendencias constantes, han sido modelados mediante funciones de densidad de probabilidad. De esta manera, se ha representado la distribución de cada variable con una función de densidad de probabilidad diferente, escogiendo la función óptima para cada variable entre 94 funciones diferentes. Tras ajustar cada variable con una función, se han establecido intervalos de confianza del 98% para determinar los límites de desviación de cada variable respecto a su media. Por otro lado, las variables con altos niveles de desviación y correlación se han modelado empleando redes neuronales artificiales, diseñando una red distinta para cada subsistema del motor. Tras entrenar, validar y testear la red con 299.052 registros provenientes del año 2020, se han establecido los errores límite del modelo para cada parámetro. Por último, los datos de 2021 se

han utilizado para validar los límites calculados tanto por las funciones de densidad de probabilidad como por las redes neuronales artificiales. En el caso de los límites establecidos con funciones de densidad de probabilidad, se ha obtenido un ratio máximo de fallo de 1,21%. Para los parámetros modelados con redes neuronales, se han obtenido errores máximos de 1,1%, 1,22% y 1,95% para los subsistemas de funcionamiento, refrigeración y cilindros. Como resultado de este último estudio se proporcionan valores límite de desviaciones de 57 parámetros del motor considerando el funcionamiento correcto de este. Para los parámetros con tendencias constantes, estas desviaciones son las desviaciones máximas respecto a sus medias, y para los parámetros variables y con altos niveles de correlación estas desviaciones son las desviaciones máximas vistas entre modelo y realidad en los años 2020 y 2021. De esta forma, se proporciona una lista de desviaciones límite contrastada que se espera sirva como punto de referencia a la hora de establecer límites para distintos fallos del motor en futuros trabajos en torno a la identificación de fallos en motores diésel marinos.

En conclusión, la presente tesis demuestra el potencial de las redes neuronales artificiales para simular el funcionamiento de los motores diésel marinos con altos niveles de precisión, mostrando tiempos de cálculo asumibles en procesos de modelado en tiempo real en comparación a los elevados tiempos de cálculo requeridos por los modelos termodinámicos. No obstante, el modelo termodinámico es capaz de simular también los procesos internos de la combustión, en caso de que fueran necesarios. Por otro lado, también se muestra la aplicabilidad de las redes neuronales artificiales en condiciones reales de un motor marino, considerando su mapa de funcionamiento completo. Por último, aplicando las estrategias de modelado estudiadas durante la tesis, se establecen valores límite de desviaciones para un total de 57 parámetros del motor, que servirán como punto de referencia en futuros trabajos en torno a la diagnosis y el mantenimiento basado en condiciones de motores diésel marinos.

INTRODUCCIÓN

Nomenclatura

Acrónimos

0D	Modelos cero dimensionales	IOS	Inter-organizational systems
1D	Modelos de una dimensión	MSC	Maritime safety comitee
2D	Modelos de dos dimensiones	NO_x	Óxidos de nitrógeno
3D	Modelos de tres dimensiones	OCDE	Organización para la cooperación y el desarrollo económicos
ANN	Redes neuronales artificiales	OMI	Organización marítima internacional
AVL	Anstalt für Verbrennungskraft maschinen List	ORC	Ciclo orgánico de Rankine
BSFC	Consumo específico de combustible	PCA	Análisis de componentes principales
CO	Monóxido de carbono	P_{max}	Presión máxima
CO₂	Dióxido de carbono	ROHR	Tasa de transferencia de calor
EMSA	European maritime safety agency	SPA	Sistema pesquero alimentario
EU	Unión Europea	SVM	Support vector machine
GEI	Gases de efecto invernadero	T_{aceite}	Temperatura del aceite
HC	Hidrocarburos	TDC	Punto muerto superior
IEA	International energy agency	T_{exh}	Temperatura de gases de escape
IMEP	Presión media efectiva indicada	WoS	Web of science

Contexto

Transporte marítimo y combustibles fósiles

El transporte marítimo es el medio de transporte de bienes más utilizado a nivel mundial, representando el 80% del total de bienes transportados en medidas de volumen [1]. Esta tendencia también se ve reflejada en la Unión Europea, en la que el 81% de bienes medidos en volumen fueron transportados por vía marítima en 2020 [2]. Según Eurostat, el porcentaje de bienes importados y exportados de la EU por mar se ha incrementado en las últimas dos décadas. De hecho, en 2002 el 69.3% de las exportaciones se dieron por mar, mientras que en 2020 este medio de transporte sumó el 74.1% de las exportaciones. Del mismo modo, el porcentaje de importaciones aumentó 3 puntos desde 2002 hasta 2020. Por lo tanto, el transporte marítimo no sólo es un pilar fundamental del transporte de bienes a nivel mundial, sino que su popularidad crece año tras año. En este aspecto, los países miembros de la EU con mayores porcentajes de transporte marítimo son Grecia, España y Portugal, mientras que Austria, Letonia y República Checa son los países con menores porcentajes de transporte marítimo. En parte, su localización geográfica es una de las mayores razones por las que emplean otros medios de transporte, como en el caso de República Checa que en 2020 transportó en torno al 75% de sus bienes por carretera.

En este contexto, de acuerdo a la International Energy Agency (IEA), el transporte marítimo produjo en torno al 2% de las emisiones globales de CO₂ en 2020 [3]. Respecto a las emisiones de NO_x, según la Organización para la Cooperación y el Desarrollo Económicos (OCDE), aproximadamente el 30% de las emisiones a nivel mundial fueron producidas por el transporte marítimo [4]. Y más aún, la OCDE estima que para 2050 este transporte y sus correspondientes emisiones de gases contaminantes se tripliquen debido a la creciente demanda de transporte de bienes a nivel global. Con objeto de reducir dichos niveles de gases de efecto invernadero (GEI), la Comisión Europea estableció el llamado Plan del Objetivo Climático para 2030 [5]. Concretamente, este plan representa el objetivo de la EU de reducir los niveles de gases de efecto invernadero en un 55% respecto a los niveles de 1990 para 2030, lo que supone una reducción considerable respecto a los anteriores objetivos que establecían una reducción del 40%. El objetivo final de dicho plan es conseguir la neutralidad climática para 2050, lo que por definición induciría cero emisiones netas de gases de efecto invernadero. Esta medida está también directamente alineada con el acuerdo de París [6], tratando de mantener el incremento

de la temperatura global por debajo de 2°C e incluso estableciendo objetivos de mantenerlo por debajo de 1.5°C.

Para ello, la IEA considera que los combustibles de bajo o cero contenidos de carbono jugarán un papel esencial en la descarbonización de la industria marítima internacional. Según un estudio reciente llevado a cabo por Tristan Smith [7], estos son algunos de los mayores recursos energéticos con cero carbono: Hidrógeno, fueles sintéticos de cero carbono (amoníaco) y energía derivada de baterías cargadas con energía de cero carbono como solar, eólica, hidroeléctrica o nuclear. Por otro lado, según Smith los fueles derivados de la biomasa podrían ser considerados fueles de cero emisiones netas; y es que, aunque en la combustión de los biocombustibles se liberen emisiones de CO₂ a la atmósfera, la producción de la biomasa también toma CO₂ de la atmósfera, por lo que el resultado de este balance es una pequeña cantidad de emisión de carbono liberada a la atmósfera. Sin embargo, en lo que respecta a combustibles de bajo o cero contenidos de carbono, la IEA estima que en términos generales los biocombustibles son el único combustible no-fósil utilizado hasta la fecha, representando únicamente el 0.1% de la energía consumida en el transporte marítimo [3]. Por otro lado, de acuerdo con el marco de política actual respecto a los combustibles utilizados en el transporte marítimo, la IEA proyecta porcentajes de uso de 2% y 5% para los combustibles de bajo o cero contenidos en carbono para 2030 y 2050 respectivamente, resultando notablemente menores que el 15% y 83% establecidos para 2030 y 2050 con objeto de alcanzar la neutralidad climática en 2050. Además, según Smith no existe ningún reconocimiento respecto a que el coste de producción de los combustibles de bajo o cero contenidos en carbono sea menor que el de los combustibles fósiles convencionales. Recientemente, el Parlamento Europeo ha votado en una sesión plenaria a favor de reducir 100% las emisiones de los motores de combustión interna [8], prohibiendo la venta de este tipo de motores a partir de tal año. Sin embargo, de acuerdo con el estudio de Smith, para asegurar una transición exitosa hacia nuevos recursos energéticos de bajo o cero contenido de carbono, deberían modificarse tanto la regulación como el modelo de negocio de la producción de dichos combustibles. De hecho, a día de hoy y según el último “Oil Market Report” (OMR) emitido por la IEA [9], la demanda de combustibles fósiles a nivel mundial es cada vez mayor, y a corto plazo proyectan una tendencia creciente como puede observarse en la Figura In. 1.




Figura In. 1 Demanda global de petróleo y gasoil y proyección a futuro según IEA

Según lo concluido por la IEA en este reporte, la proyección es que no sólo la demanda del petróleo crezca en los próximos años, sino que la demanda del gasoil también crecerá. Por lo que, a medio corto plazo parece que este combustible fósil se seguirá utilizando. Por otro lado, también se puede observar el efecto que tuvo la pandemia del COVID-19 en la demanda de gasoil, recogiendo valores notablemente menores que en años anteriores. Esto puede observarse en la Figura In. 1 en torno a los años 2020 y 2021. Sin embargo, la demanda se ha restablecido, cumpliendo incluso proyecciones ascendentes para próximos años conforme a cálculos de la IEA. Por lo tanto, parece que a corto-medio plazo este tipo de combustibles se seguirá utilizando. Por otro lado, pese a que los elementos de los motores de combustión interna que emplean este tipo de combustibles tienen altos niveles de fiabilidad, su uso continuando en el tiempo puede llevar al fallo de dichos elementos, provocando incidencias en alta mar. Por ello, a continuación, se introducirá el contexto de las estrategias de mantenimiento de los sistemas de propulsión del ámbito marino.

Mantenimiento de sistemas de propulsión marinos

En este marco, pese a ser el sistema de transporte más utilizado globalmente, los incidentes en el medio marino son un problema en el que aún queda mucho que profundizar. Bajo el amparo del artículo 94 de la Convención de las Naciones Unidas sobre el Derecho del Mar [10], todo estado miembro del comité está obligado a llevar a cabo una investigación en aquellos incidentes marinos en los que se sufran daños humanos o daños en los buques, y dicha investigación deberá llevarse a cabo por personas cualificadas. Por otro lado, la Organización Marítima Internacional (OMI) es el organismo de Naciones Unidas responsable de la seguridad y protección de la navegación y de prevenir la contaminación del mar por los buques. Mediante su comité “Marine Safety Committee” (MSC) también regula las buenas prácticas para la seguridad entorno a incidentes en el ámbito marino [11].

Para ello, la UE dispone de un organismo llamado European Maritime Safety Agency (EMSA), que registra y analiza los incidentes ocurridos en la flota marítima de la UE. Según el último reporte emitido por la EMSA [12] el mayor causante de los incidentes ocurridos en los buques entre los años 2014 y 2020 es la pérdida de propulsión de los buques, ocasionando el 22% de los incidentes comprendidos entre estos años, con una media de 503 pérdidas de propulsión anuales en toda la flota de la UE. En la Figura In. 2 se muestran los diferentes tipos de incidentes ocurridos en dicho periodo de tiempo; cada año está representado por un color.

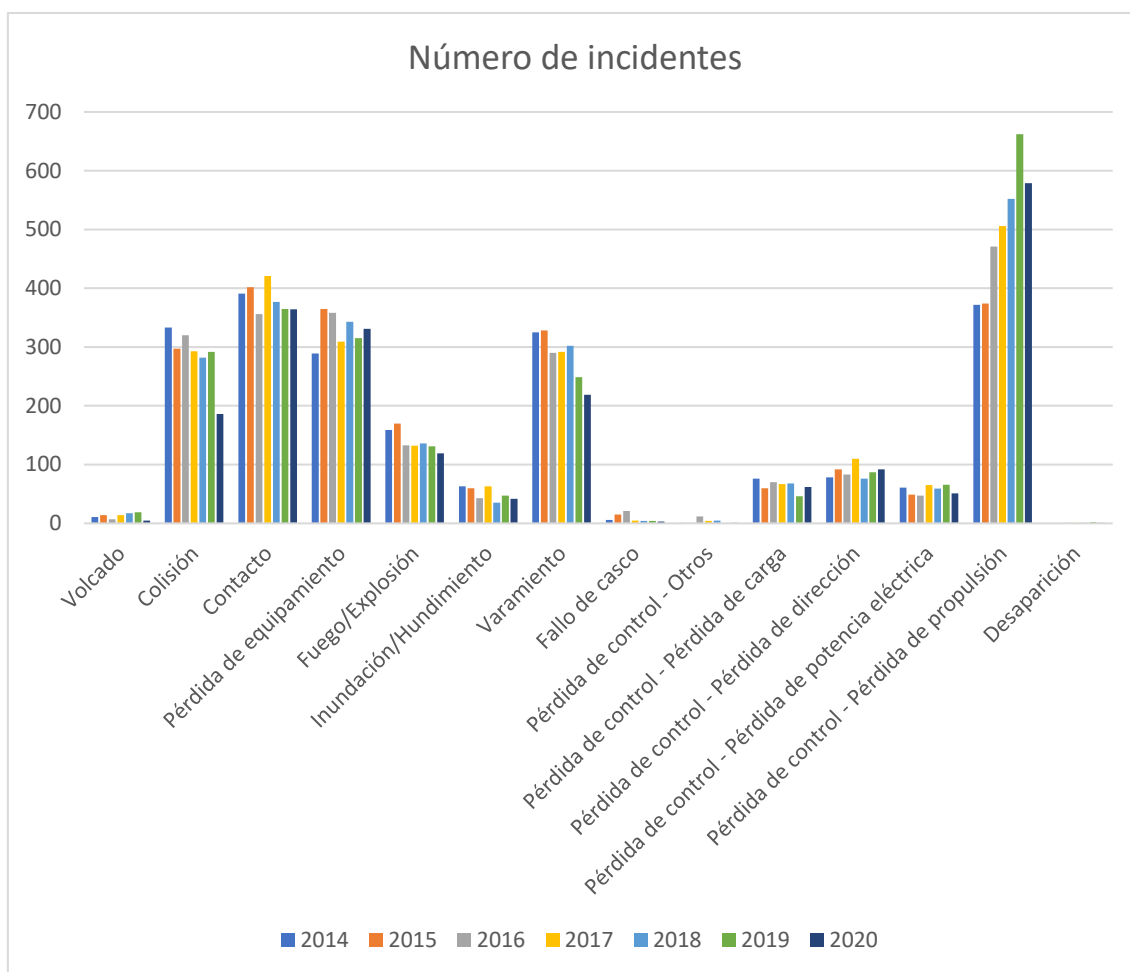


Figura In. 2 Número de incidentes de la flota de la UE entre 2014-2020

Además de la pérdida de propulsión, se puede observar que incidentes como la colisión, el contacto con otros buques o superficies, la pérdida de equipamiento y el varamiento son unas de las razones más frecuentes de las incidencias. Sin embargo, puede observarse que en casi todos los años las pérdidas de propulsión han sido la razón de incidencia más frecuente. Otro aspecto interesante es la tendencia creciente de dichos incidentes hasta el 2019. En la Figura In. 2 puede observarse cómo año tras año el número de casos ha ido incrementándose, exceptuando el año 2020. Este resultado podría tener una gran correlación con el estado de la pandemia del COVID 19 en los años 2019-2020, en el que la industria marítima, así como otras industrias se vieron ralentizadas, lo que pudo en este caso suponer una reducción de incidencias debida a una movilidad marítima reducida. Por lo que, se espera que en 2021 este número de incidencias causadas por pérdida de propulsión aumente con la nueva normalidad y el restablecimiento de la industria marítima.

En este aspecto, una estrategia de mantenimiento adecuada podría ayudar a reducir el número de incidentes dados por una pérdida de propulsión. Y es que, con el paso del tiempo las estrategias de mantenimiento aplicadas en las máquinas han ido evolucionando y cambiado de carácter. Según Cooke [13], desde 1940 el mantenimiento ha pasado por tres fases diferentes. En la década de los 40, se apostaba por un mantenimiento correctivo, esperando al fallo de la máquina para su reparación o sustitución. Desde 1950 hasta 1980 se introdujo el mantenimiento preventivo basado en revisiones periódicas, por lo que si en alguna revisión algún elemento fallaba se cambiaba. Desde 1980 en adelante Cooke identificó una tercera fase del mantenimiento, conocida con el nombre de mantenimiento basado en condiciones. De esta forma, la periodicidad de las revisiones se redujo, teniendo constante conocimiento de la condición de la máquina. Según su estudio, tras analizar las estrategias de mantenimiento de cuatro empresas diferentes en Reino Unido concluyó que la atención que se prestaba a las nuevas estrategias de mantenimiento era escasa. Sin embargo, Arunraj et al. [14] posteriormente identificaron una última fase conocida como mantenimiento basado en riesgos. Esta última fase comenzó a implementarse en torno al año 2000 y en ella se estudian los valores de diferentes parámetros de la máquina para anteponerse a posibles fallos. Si bien es cierto que este término no es aún muy conocido en el mundo empresarial, muchas compañías están apostando por la digitalización, que además de la optimización de procesos y reducción de costes, tiene como objetivo principal la identificación de posibles fallos en los sistemas.

Esta integración de nuevas tecnologías como el Internet of Things o la implementación de modelos de Machine Learning en procesos industriales es ya considerada como la cuarta revolución industrial [15]. Es por ello que muchas industrias como la siderúrgica [16, 17], la automovilística [18, 19] o el sector energético [20-22] apuestan por la aplicación de dichos procesos. Para ello, la adquisición de múltiples variables del sistema es vital para poder aplicar diferentes metodologías de optimización o mantenimiento, ya sea un automóvil o una planta de producción. Este hecho en parte ha causado un retraso en la aplicación de la digitalización en el ámbito marítimo, ya que la adquisición de diferentes variables a bordo de un barco y su comunicación con el exterior requieren un alto nivel de sofisticación en la instrumentación. A modo de ejemplo, Elbert et al. [23] estudiaron un aspecto básico de la digitalización llamado "inter-organizational systems" (IOS) que representa la información compartida entre diferentes organizaciones (en este caso de transporte) para una posible optimización del transporte. Mientras que en la vía terrestre llegaban a niveles de 70% de IOS compartido, en la vía marítima no alcanzaban el 25%. Y es que, pese a que el transporte marítimo es el más utilizado a nivel mundial, aún necesita una gran inversión en términos de digitalización. De hecho, según un

estudio llevado a cabo por Deloitte en el año 2017 [24], la prioridad de invertir en digitalización para contribuir a la competitividad del transporte marítimo de la EU debería ser baja. En otras palabras, según Deloitte en 2017 la digitalización de la flota de la EU no era una prioridad. Sin embargo, el número de estudios relacionados con la digitalización en el ámbito marítimo a nivel mundial ha crecido notablemente desde el año 2002 [25], lo que implica un creciente interés en esta temática. Ejemplo de ello es el proyecto europeo SustunTech [26] en el que participa AZTI BRTA. Este proyecto ofrece un sistema compacto y eficiente en términos económicos, que tiene como objetivo mejorar en un 25% la eficiencia energética de las prácticas de pesca futuras respecto a las prácticas actuales. Para ello se combinan monitorización de abordaje, datos de Copernicus (programa de observación de la Tierra para la vigilancia de nuestro planeta y medioambiente) y diferentes técnicas de machine learning.

Por lo tanto, una correcta estrategia de mantenimiento predictivo debería ir directamente unida con una correcta estrategia de digitalización de la flota. Para ello, es necesario un alto nivel de sofisticación en términos de adquisición de datos y monitoreo de los buques. Aunque se estima que la inversión inicial de las estrategias de mantenimiento predictivo es mayor que la inversión de las estrategias correctivas, el coste total del mantenimiento predictivo es mínimo en comparación al coste del mantenimiento correctivo [27]. De hecho, en otros casos como el de los aerogeneradores eólicos se ha demostrado que una estrategia efectiva de mantenimiento basado en condiciones podría reducir el coste del mantenimiento en un 32.46% respecto al mantenimiento preventivo y un 39.24% respecto al mantenimiento correctivo [28]. Una forma de conocer en todo momento en qué condición se encuentra el sistema de propulsión o motor de un buque es desarrollando lo que se denomina como un “gemelo digital” [29, 30]. Es decir, mediante el desarrollo de un modelo que simule con gran exactitud el funcionamiento del motor, pueden identificarse situaciones de fallo estudiando las desviaciones entre modelo y motor real. Este concepto no es sino una forma de denominar las estrategias de modelado de los motores diésel, que han sido objeto de estudio durante las últimas dos décadas y serán descritas en el siguiente apartado. Por ejemplo, la empresa de astilleros Navantia, que a día de hoy es la empresa de construcción de buques con mayor facturación en España [31], ya tiene una línea de investigación llamada Navantia 4.0. En esta línea apuestan por la digitalización de sus astilleros, siendo el desarrollo de gemelos digitales uno de los ejes de esa digitalización [32].

Buques de pesca

En la presente tesis, se ha tenido la oportunidad de trabajar con diferentes motores, principalmente de barcos de pesca. No obstante, los modelos desarrollados no solo son aplicables en este tipo de barcos, sino que son fácilmente extrapolables a otros motores más grandes. De hecho, el centro de investigación AZTI BRTA y más concretamente el departamento de Tecnologías Pesqueras Sostenibles llevan más de una década estudiando la eficiencia energética y el mantenimiento de los buques de pesca de la flota española. Ejemplo de ello son las publicaciones tanto de combustibles alternativos provenientes de aceites lubricantes reciclados [33, 34] como estudios de eficiencia energética en buques de pesca [35] o identificación de algunas situaciones de fallo de la propulsión de buques de pesca [36].

En 2018, el Sistema Pesquero Alimentario (SPA) generó el 0.75% del producto interior bruto de España [37]. Pese a ser un pilar fundamental para la economía, lo cierto es que tanto la flota de pesca española como la europea han sufrido un decremento en los últimos años. En la Figura In. 3 se muestran el número de barcos de pesca de las flotas de la UE y de España; la Figura In. 4 muestra el decremento porcentual anual. Los datos de ambas figuras se han extraído de la agencia estadística de la UE Eurostat [38].

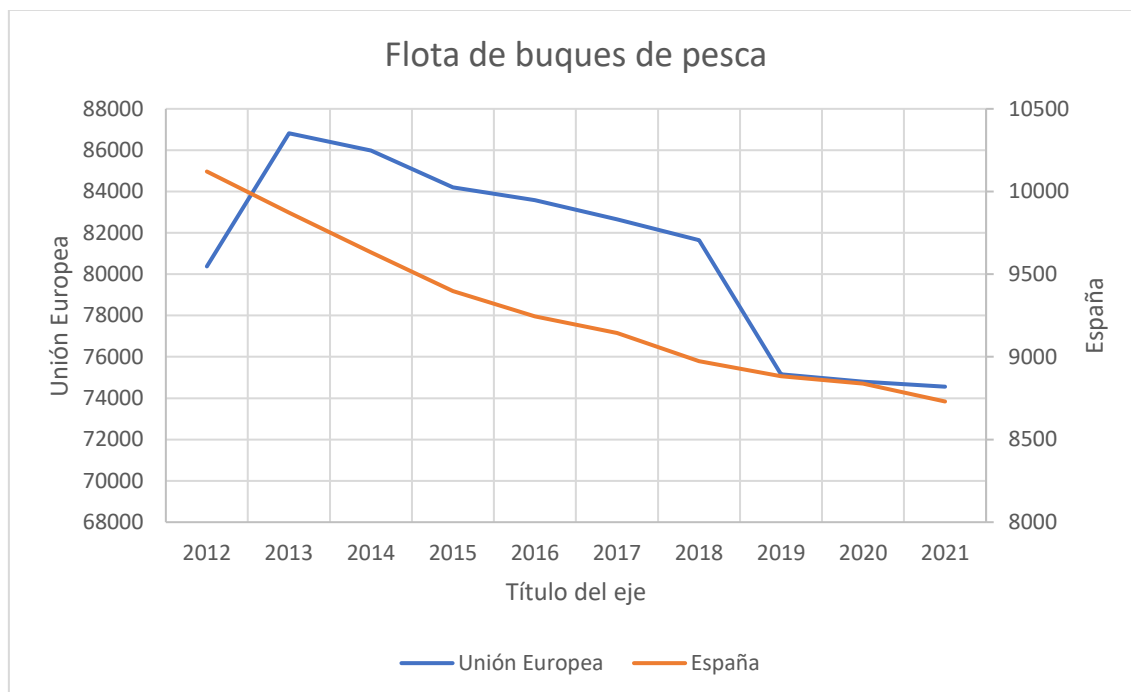


Figura In. 3 Número de buques de las flotas pesqueras de la UE y España 2012-2021

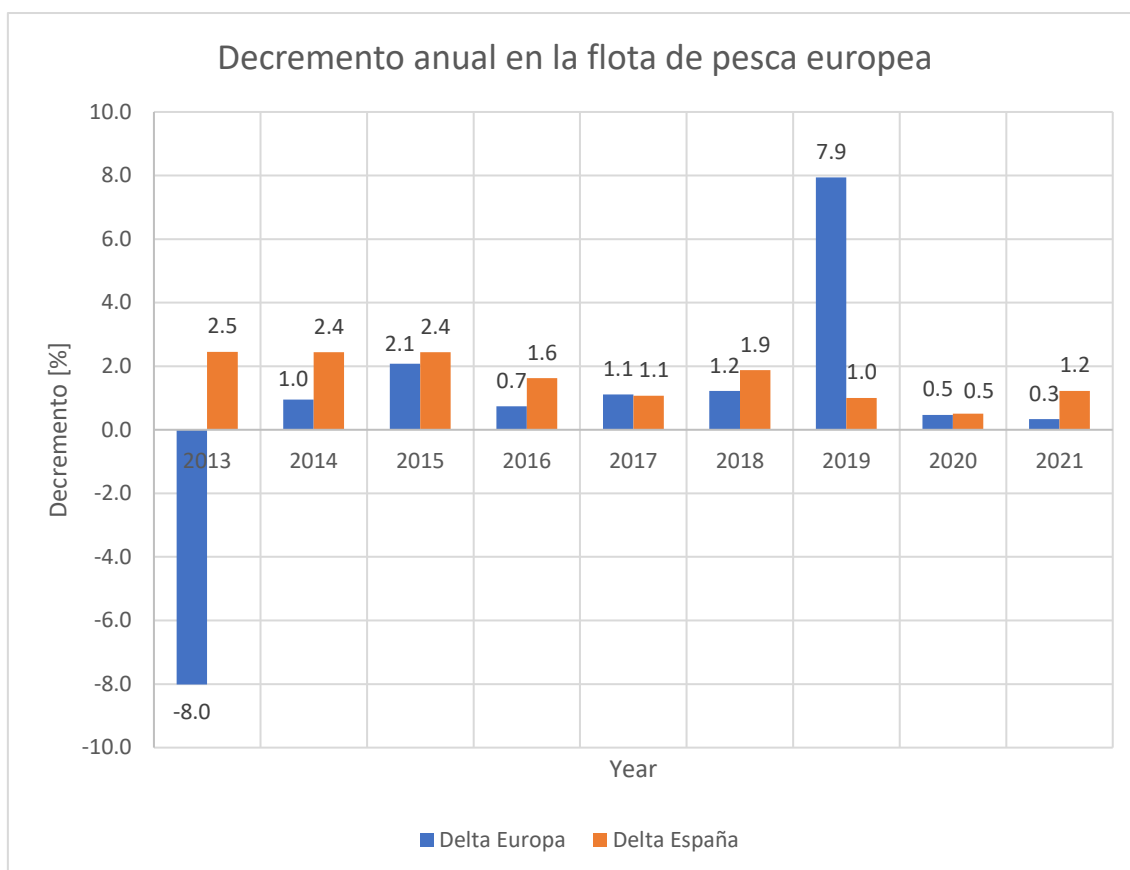


Figura In. 4 Decremento porcentual de las flotas pesqueras de la UE y España 2013-2021

De la Figura In. 3 se concluye que el número de buques de pesca tiene una clara tendencia descendente. En la última década la flota de la UE se ha reducido de 80374 buques en 2012 a 74556 buques en 2021, mientras que España ha pasado de tener 10121 buques en 2012 a tener 8730 en 2021. Esto supone un descenso considerable en ambas flotas. Concretamente, en la Figura In. 4 puede observarse que, exceptuando dos años, el resto de los años ambas flotas se han reducido entre 0.3 y 2.5%. Llamamos la atención al incremento del 8% que se dio en 2013 y el decremento del 7.9% dado en 2019. Estos números corresponden a la anexión de Croacia a la UE en 2013, fecha tras la cual la flota de Croacia se añadió a la de la UE, y por otro lado la desanexión de Reino Unido de la UE en 2020. De hecho, pese a salir de la UE en 2020, la flota de Reino Unido dejó de contabilizarse en la flota de la UE en 2019. Por último, cabe destacar que en todos los años (exceptuando estos dos eventos), la reducción de la flota española ha sido notablemente mayor que la reducción de la flota de la UE. En otras palabras, la flota española está reduciéndose más rápido que la flota de la UE.

Motivación

El contexto actual de los sistemas de propulsión de buques ha provocado un creciente interés de diferentes centros de investigación y universidades en múltiples campos de estudio. En este caso, se han identificado varios motivos por los que estudiar tanto los sistemas de propulsión marinos como sus estrategias de modelado. Sintetizando la situación actual de los combustibles utilizados, del mantenimiento de los sistemas de propulsión y de los buques de pesca, se concluye lo siguiente:

- La Unión Europea planea alcanzar la neutralidad climática para 2050. Sin embargo, los índices de demanda de petróleo y de gasoil presentados por la Agencia de Energía Internacional indican una proyección de demanda ascendente para los próximos años. Por ello, se estima que a corto-medio plazo el gasoil y los sistemas de propulsión de gasoil sigan empleándose, al menos en el ámbito de la industria marítima.
- El mantenimiento basado en condiciones es una estrategia que identifica los fallos en la máquina antes de que ocurran. Dado que la mayoría de los incidentes en buques de la flota de la UE son causados por pérdida de propulsión, este tipo de mantenimiento podría ayudar a reducir dicho número de incidentes. Además, se ha demostrado que puede suponer ahorros en costes de mantenimiento de en torno a 30-40% respecto a otras estrategias de mantenimiento. Una forma de llevar a cabo el mantenimiento basado en condiciones es desarrollando modelos de los motores de los barcos, para después anteponerse a los fallos del motor observando desviaciones entre modelo y motor real. Por ello, los trabajos en torno al modelado de motores marinos han causado un creciente interés en las últimas décadas. Este interés crecerá aún más con la reciente atención prestada a la digitalización de la industria marítima. Existirán más trabajos de monitoreo, lo que facilitará el desarrollo de modelos mediante el análisis de las variables monitoreadas en el buque.
- El número de buques de pesca de las flotas de la UE y de España se ha reducido considerablemente desde 2012. Además, esta reducción es más acentuada en el caso de España, es decir, el decremento de la flota de España es mayor que el decremento de la flota europea. Aquellas acciones que ayuden a evitar posibles incidentes relacionados con la propulsión de dichos buques y hacerlos más fiables podría junto con otras medidas contribuir a frenar dicho decremento.

Estado del arte

Modelizado de motores diésel

Los gemelos digitales son un concepto que ha ganado el interés de empresas de motores marinos muy importantes en los últimos años [39-41]. Según las definiciones dadas por dichas compañías, son réplicas que simulan el funcionamiento de las máquinas con altos niveles de exactitud, proporcionando el cálculo de los parámetros de los motores con objetivos de mejora de eficiencia, minimización de emisiones, incremento de seguridad y reducción de costes. Esta no es sino otra forma de denominar el campo de estudio del modelado de los motores, un fondo que históricamente se ha tratado de varias formas diferentes. Desde la década de los 70, algunos autores han desarrollado simuladores para motores de diferentes características. En 1971, Streit y Borman [42] desarrollaron un simulador para un motor diésel de dos tiempos. Para ello se basaron en las ecuaciones matemáticas de los diferentes submodelos del motor (modelo de combustión, modelo de transferencia de calor etc.). Dos años después, Benson et al. [43] desarrollaron un simulador para predecir las respuestas transitorias de diferentes parámetros de un motor como el consumo de combustible o la velocidad angular del turbocompresor. Pese a que el modelaje de motores diésel estaba en sus primeras etapas en la historia, también se desarrollaron trabajos en torno a otros aspectos como la simulación de emisiones de gases contaminantes [44], el ruido [45] o la eficiencia térmica del motor [46]. Hasta este momento, los modelos estaban basados en metodologías puramente matemáticas, en las que se resolvían algunas ecuaciones termodinámicas del motor para calcular los parámetros simulados.

En la década de los 80 y 90, los estudios comenzaron a centrarse en elementos o parámetros más concretos del motor, sin embargo, la metodología de modelado predominante seguía siendo el modelado termodinámico. Ford [47] desarrolló un modelo simplificado de un motor diésel marino con sobrealimentación mediante turbocompresores, prediciendo la velocidad de giro del motor y la posición de la bomba de gasoil (indicativo del consumo de combustible). Para ello basó su modelo simplificado en otro modelo termodinámico previamente desarrollado por Smith et al. [48] y comparó ambos modelos concluyendo una mejoría en cuanto a error de predicción con el nuevo modelo simplificado. Similarmente, Goering y Ho [49] desarrollaron un modelo matemático basado en ecuaciones termodinámicas para el cálculo del consumo específico de combustible (BSFC) en diferentes estados de par y velocidad de giro del motor. Otros trabajos de investigación se centraron más en la parte de la combustión, tanto para motores de inyección directa [50] como en motores de premezcla [51]. A finales de la década

de los 90 comenzaron a desarrollarse los primeros simuladores de motores diésel para control y diagnóstico [52] y también para analizar el efecto de diferentes modificaciones en elementos del motor, que de otra forma requerirían una modificación del motor real en el taller. Entre estos trabajos se encuentran el análisis mediante simulación de la modificación del tren de válvulas [53] o el efecto de la velocidad de giro en las emisiones de gases contaminantes de la combustión del motor [54]. En términos generales, puede observarse que hasta el año 2000, la técnica de modelado preponderante resultó ser el modelo termodinámico, también conocido como el modelado matemático que en su base contenía ecuaciones termodinámicas. Sin embargo, y sobre todo en investigaciones en torno al proceso de combustión en los cilindros, también se desarrollaron algunos modelos basados en dinámica de fluidos computacional [55, 56].

A partir del año 2000, el número de artículos publicados en torno al modelaje de los motores diésel se fue incrementando. En la Figura In. 5 se muestra una gráfica de los porcentajes de trabajos realizados en torno al modelaje de motores diésel desde el año 2002 hasta el año 2017 [57].




Figura In. 5 Porcentaje de artículos presentados en torno al modelaje de motores diesel [57]

Y es que, a partir del comienzo esta década, junto con el desarrollo tecnológico y la mejora de la capacidad computacional de los ordenadores, comenzaron a utilizarse otro tipo de herramientas matemáticas para el modelado de los motores. Estas herramientas matemáticas y estadísticas están en su mayoría comprendidas dentro del término “Machine Learning”, que representa varios algoritmos y modelos estadísticos, muchos de los cuales comenzaron a

aplicarse en modelos de motores a comienzos de los 2000. Por un lado, el análisis de componentes principales, conocido por PCA, ha sido utilizado en muchos trabajos de investigación con objeto de clasificar diferentes estados del motor. Esta herramienta obtiene los vectores que caracterizan mejor a todas las variables de una base de datos concreta, después pudiendo proyectar la base de datos sobre estos vectores principales para clasificar situaciones diferentes del motor [58]. Entre ellos, pueden observarse modelos para identificación de pérdida de aire en el colector de entrada [59, 60], identificación de falta de refrigeración del aire de entrada y obstrucción del escape [61] o modelos para analizar el efecto de la composición del combustible en las emisiones del motor [62]. Por otro lado, los Support Vector Machine (SVM) también han tenido un papel importante en el ámbito del modelado de motores diésel, concretamente en torno a la clasificación de diferentes situaciones del motor. Esta es una herramienta de clasificación que trata categorizar puntos de diferentes clases, ya sea este un problema de clasificación lineal o no lineal mediante el uso de las funciones de transformación conocidas como kernels [63]. Cai et al. [64] utilizaron esta herramienta para la clasificación fallos en diferentes subsistemas del motor (ej. Fallo del subsistema de combustible, fallo del subsistema de aire de entrada y gases de escape etc.). Lazakis et al. [65] entrenaron un modelo de SVM con datos de un motor diésel marino sano para después clasificar las situaciones de fallo del motor basándose en desviaciones entre modelo y motor real. Este tipo de estrategias también se han utilizado con objeto de predecir diferentes parámetros del motor como emisiones de NO_x [66] o el par y el consumo específico de combustible entre otros [67]. En algunos casos, estas metodologías se han utilizado en combinación, por ejemplo para el desarrollo de un sistema de identificación de fallos del subsistema de combustible de un motor marino [68]. También se han comparado varias herramientas de Machine Learning para identificar cuál es la más efectiva en términos de clasificación. Flett y Bone [69] compararon cinco estrategias diferentes de clasificación para identificar situaciones de fallo en el tren de válvulas de un motor diésel, concluyendo que Naïve Bayes ofrecía el nivel más alto de exactitud en términos de clasificación e identificación de situaciones de fallo. También se han utilizado otro tipo de herramientas estadísticas para el modelado y la optimización de diferentes parámetros del motor, como por ejemplo determinar el porcentaje óptimo de biodiesel a incluir en un motor para minimizar emisiones de gases contaminantes, para ello utilizando una herramienta estadística conocida como Response Surface Methodology [70, 71].

Si bien es cierto que estas herramientas se han utilizado ampliamente en estudios relacionados con la clasificación de diferentes situaciones y optimización de los motores diésel, su uso en estudios de predicción de parámetros tanto de funcionamiento como de emisiones de gases

contaminantes es relativamente reducido. En este contexto, la herramienta de Machine Learning más utilizada hasta el momento para el cálculo de múltiples parámetros en motores de combustión interna son las Redes Neuronales Artificiales, que en comparación con otras herramientas de Machine Learning han mostrado mayor rendimiento [72]. Estas, por definición, son estructuras de elementos procesadores capaces de adaptarse (conocidos como neuronas) conectados entre sí con capacidad de resolver ecuaciones complejas no lineales [73]. Su definición y posibles aplicaciones serán analizadas más a fondo en los siguientes capítulos. Esta herramienta se ha convertido muy popular debido a algunas ventajas que contiene como su adaptabilidad, su robustez ante todo tipo de problemas matemáticos o su capacidad de aprendizaje [74].

Tras una revisión bibliográfica exhaustiva, se observa pues, la predominancia de dos herramientas de modelado sobre el resto de las herramientas en cuanto a predicción de parámetros de funcionamiento de motor:

- El clásico modelo termodinámico, basado en las ecuaciones físicas de conservación de masa, momento y energía de los diferentes elementos del motor.
- El innovador método basado en datos conocido como las Redes Neuronales Artificiales, capaces de aprender de los datos para resolver problemas matemáticos complejos.

Es por ello que, a lo largo de los años de investigación dedicados a esta tesis, se ha profundizado en estas dos estrategias de modelado de motores, con el objetivo de entender las ventajas y desventajas de ambas estrategias y ofrecer un resultado válido para futuras aplicaciones de modelado de motores marinos como la creación de modelos “digital twin” o el mantenimiento basado en condiciones de los sistemas de propulsión de buques.

Modelos termodinámicos

Históricamente, el modelo termodinámico ha sido la metodología más utilizada hasta entrados los años 2000. Pese a que en torno a este año comenzaron a emplearse otras metodologías basadas en datos, algunos trabajos de investigación aún han seguido utilizando el modelo termodinámico teórico como base de sus estudios. Payri et al. [75] desarrollaron un modelo 0-dimensional prediciendo después múltiples parámetros de funcionamiento (ej. IMEP, P_{max}) basándose en ecuaciones termodinámicas y considerando submodelos para diferentes sistemas del motor como el escape de aire por blow-by, la deformación de la cámara de combustión o la transferencia de calor. Este estudio fue después utilizado para analizar el efecto de diferentes

parámetros del motor (ej. ratio de compresión, posición del TDC etc.) en el error de modelado de la tasa de liberación de calor (ROHR) y de la presión de combustión [76]. Algunos autores han utilizado estos modelos termodinámicos teóricos para después validarlos experimentalmente. Por ejemplo, Gonca y Dobrucalli [77] analizaron el efecto de la carga relativa del motor y el porcentaje de biodiesel en el funcionamiento del motor, primero planteando el modelo teórico y después validándolo experimentalmente. Este tipo de modelos también pueden verse en estudios recientes, como el desarrollado por Jiaqiang et al. [78] que llevaron a cabo un análisis de entropía y exergía junto con un modelo termodinámico teórico para analizar el funcionamiento de un motor diésel durante su arranque en frío.

Pese a que el modelo termodinámico analítico siga utilizándose a día de hoy, en las últimas dos décadas se ha observado un creciente interés en diferentes softwares para el modelado de motores. Algunos de ellos tienen por base ecuaciones termodinámicas teóricas introducidas en diferentes bloques representando distintos subsistemas del motor, como en el caso de los modelos implementados en Matlab/Simulink™ [79, 80]. Otros, incorporan modelos físicos basados en ecuaciones termodinámicas en combinación con modelos que se pueden ajustar a las características de cada motor, sin tener que resolver las complejas ecuaciones físicas de la cámara de combustión [81]. Otros softwares permiten el desarrollo de los modelos en un entorno de programación gráfico. Para ello, se escogen los diferentes elementos del motor y se conectan mediante tubos, reproduciendo el motor real en el ordenador. Dos de los programas más utilizados con este fin son: Ricardo Wave™ y AVL Boost™. Entre los trabajos que emplean Ricardo Wave para sus modelos puede verse el análisis del efecto de la contrapresión en la temperatura de gases de escape de un motor diésel [82]. También se han llevado a cabo simulaciones mediante Ricardo Wave para modelado de emisiones de un motor diésel marino [83], evaluación de ahorro de combustible por uso de ORC en un motor diésel marino de dos tiempos [84] o para el cálculo de parámetros de funcionamiento y emisiones de motores marinos con objeto de diseño conceptual de la propulsión de un buque [85]. Sin embargo, tras comparar Ricardo Wave™ y AVL Boost™ en la simulación de un motor de gasolina y otro diésel (ambos de un cilindro), Alqahtani et al. [86] concluyeron que AVL Boost™ contenía recursos de simulación más complejos que Ricardo Wave™ en términos de diseño de motores y simulación de ciclo termodinámico.

Esta capacidad de crear modelos complejos en un entorno de programación gráfico es en parte el causante de que numerosos trabajos de investigación en estas dos últimas décadas hayan desarrollado modelos de motores mediante el uso de AVL Boost™, y de que la tendencia a usar este software sea ascendente en los últimos años. En la Figura In. 6 se muestra el número de

artículos que reportan el uso de AVL Boost al año, tanto en la bases de datos de Scopus como en la de Web of Science [87].




Figura In. 6 Nº publicaciones AVL Boost 2008-2020 [87]

Este es un software para el diseño de modelos de motores en el que se conectan los diferentes elementos del motor mediante tubos, pudiendo crear simulaciones de todo tipo de motores desde el motor de una motocicleta hasta grandes motores marinos [88]. Su funcionamiento y ajuste se explicarán más extensamente en los siguientes capítulos de la tesis. Entre los modelos desarrollados de estas publicaciones pueden encontrarse modelos tanto de motores de gasolina [89-92] como de motores diésel [93-95]. La mayoría de los buques de mediano o gran porte como pueden ser los buques pesqueros o los mercantes utilizan combustible diésel para sus motores. Por ello, parte de la presente tesis se ha enfocado en la simulación mediante AVL Boost™ de motores diésel. En la literatura existente, el modelado de motores diésel mediante AVL Boost™ se ha desarrollado con distintos fines. Algunos trabajos se han centrado en la predicción de parámetros de funcionamiento del motor como las presiones y temperaturas dentro del cilindro [96] o el modelado de subsistemas concretos del motor (ej. colectores de entrada y escape) [97]. Otros, han utilizado esta herramienta en el ámbito del mantenimiento basado en condiciones. Rubio et al. [98] analizaron el efecto de varios fallos del motor (ej. fallo en el avance de la inyección, fallo de la turbina, pérdida en el colector de escape etc.) en diez parámetros de interés del motor (ej. presión de sobrealimentación, flujo másico de aire, IMEP

etc.). Vera-García et al. [99] Combinaron AVL Boost™ y mantenimiento basado en fiabilidad para evaluar y optimizar una base de datos con 15 fallos diferentes de un motor diésel marino de cuatro cilindros. Este software permite también la caracterización del combustible utilizado en la simulación, lo que ha llevado a muchos autores a utilizar este software para analizar el efecto de varios combustibles alternativos como biocombustibles [100, 101], hidrógeno [102, 103] u otros combustibles alternativos [104, 105]. A modo de tener una primera impresión visual del funcionamiento de este tipo de modelado en entorno de programación gráfica, en la Figura In. 7 se muestra el esquema de un modelo desarrollado para un motor diésel marino de 6 cilindros YANMAR-6HYM WET. En ella se pueden observar los diferentes elementos del motor como el filtro de aire, los turbocompresores o los cilindros, que se conectan mediante los tubos que después se caracterizan introduciendo sus características físicas y termodinámicas.

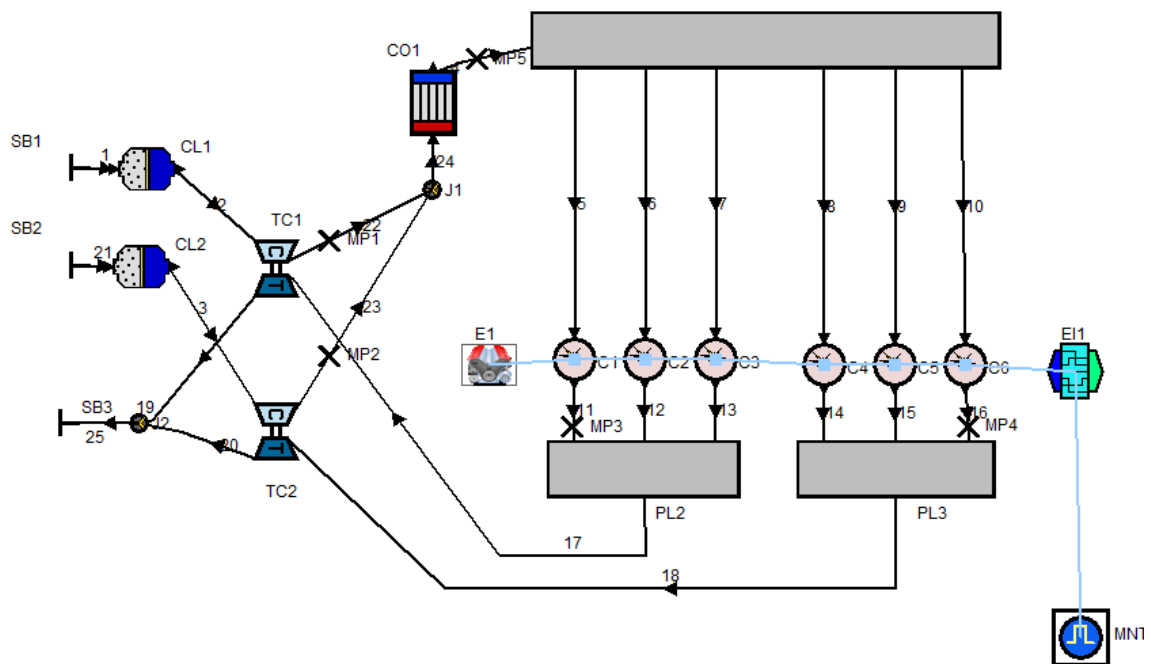


Figura In. 7 Modelo desarrollado para motor YANMAR-6HYM WET

Por lo tanto, se observa que pese a seguir utilizándose como método el uso directo de las ecuaciones termodinámicas y su resolución analítica, el clásico modelo termodinámico ha desembocado en la utilización de distintos softwares de modelización y simulación de motores que ya tienen incorporadas dichas ecuaciones y automatizan su resolución. En este marco, se observa que uno de los softwares más completos y capaces de crear simulaciones complejas como la mostrada en la Figura In. 7 es AVL Boost™.

Modelos de redes neuronales artificiales

Esta es una de las herramientas comprendidas dentro de las metodologías del Machine Learning. Básicamente, estos modelos primero se entrenan con datos de situaciones diferentes del motor, aprenden las relaciones entre inputs y outputs, y finalmente tratan de calcular los outputs en base a los inputs y las relaciones entre input/output establecidas en el entrenamiento. Los primeros trabajos en torno al modelado de motores mediante redes neuronales se llevaron a cabo a finales de la década de los 90 [106-109]. A modo introductorio y sin entrar en detalle ya que estas herramientas de modelado se explicarán en los posteriores capítulos más extensamente, en la Figura In. 8 se muestra el esquema de una red neuronal. Esta contiene tres capas: capa de input, capa oculta y capa de output. En el caso de la Figura In. 8, los inputs son el par del motor, el caudal de combustible y la temperatura del aceite; los outputs son la potencia entregada por el motor, la temperatura de gases de escape y las emisiones de NO_x. En la fase de entrenamiento, la red aprenderá las relaciones existentes entre los inputs y los outputs, y para ello se le proporcionan tanto los inputs como los outputs que debería calcular con esos inputs e iterativamente se ajustan las conexiones entre neuronas. Una vez entrenada con suficientes datos, la red será validada y testada solamente introduciendo los inputs, y comparando los outputs calculados con los valores reales de los parámetros de output. Este proceso de entrenamiento, validación y testeo se explicará más extensamente en el Capítulo 1.

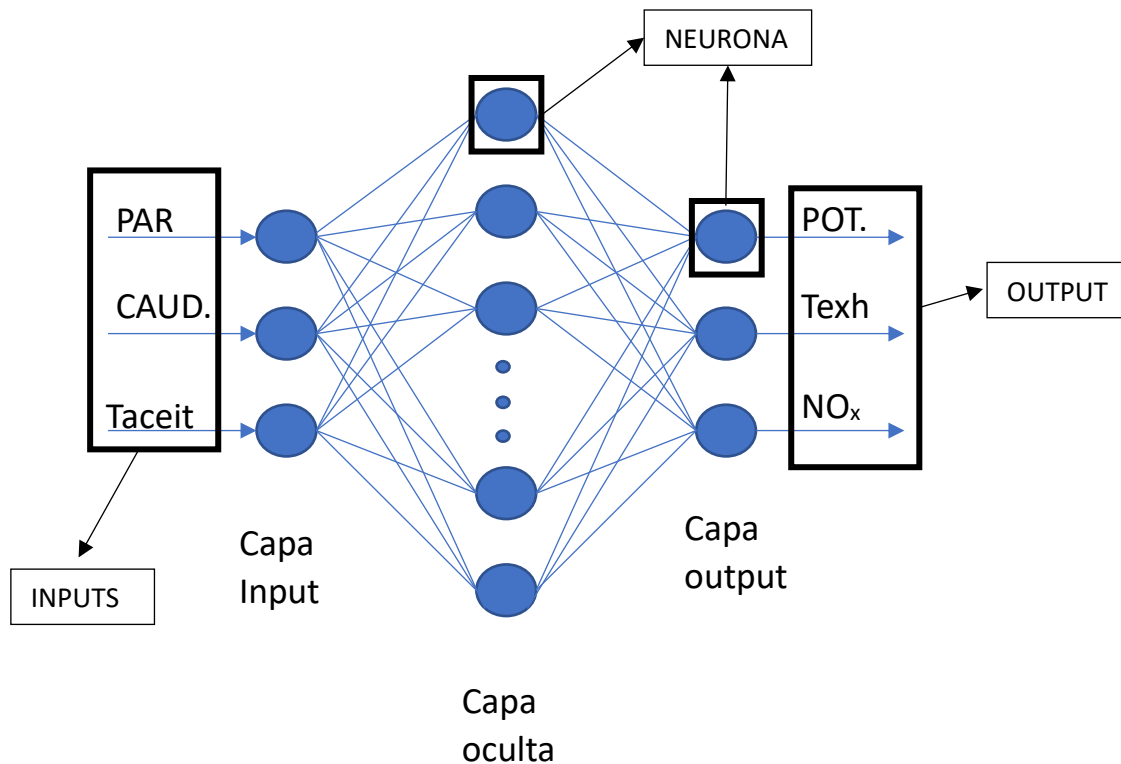


Figura In. 8 Esquema de una red neuronal artificial

En las primeras contribuciones que incluían las redes neuronales para el modelado de motores, ya se mencionaba la rapidez de estas herramientas para adaptarse y aprender las relaciones entre los parámetros modelados [110]. De hecho, se postulaba como una herramienta capaz de reproducir asociaciones complejas, no lineales, cambiantes en el tiempo y multidimensionales en tiempo real [111]. Por ello y por sus ventajas comparativas como la adaptabilidad, la robustez o la capacidad de aprendizaje y autoajuste [74] atrajeron el interés de muchos equipos de investigación, lo que en las siguientes dos décadas se vio reflejado en numerosos artículos en torno al modelado de motores de combustión interna mediante el uso de redes neuronales.

Por un lado, se encuentran los trabajos que han empleado las redes neuronales artificiales como herramienta de clasificación e identificación de diferentes situaciones de fallo del motor. Srihari et al. [112] identificaron el desgaste en la caja de cambios y la ruptura o desgaste de los engranajes mediante el uso de las Feed Forward Neural Networks introduciendo a la red neuronal diferentes variables relacionadas con las vibraciones del motor. Mofleh et al. [113] desarrollaron un sistema de detección de fallos mediante el uso de las redes neuronales artificiales, utilizando como inputs las señales acústicas del motor. Entre las situaciones que el sistema clasificaba se encuentran la situación de motor sano, la combustión defectuosa en un cilindro y la combustión defectuosa en dos cilindros simultáneamente. Liu et al. [114] también desarrollaron un modelo de clasificación para identificar el fallo en la combustión de un motor

diésel de 6 cilindros. Para ello, utilizaron las redes neuronales artificiales introduciendo 7 parámetros diferentes de funcionamiento del motor como inputs al modelo (ej. velocidad de giro, temperatura de gases de escape, consumo de combustible etc.). Entre las conclusiones, demostraron que la inclusión de la variación de la velocidad de giro respecto al ciclo de cada cilindro podía mejorar la capacidad de identificación del fallo de la red neuronal.

Además de la clasificación e identificación de situaciones de fallo en los motores, las redes neuronales se han empleado en numerosos estudios para la predicción de parámetros de funcionamiento del motor. Alonso et al. [115] Combinaron ANN y Algoritmos genéticos para primero predecir diferentes parámetros de emisiones de gases contaminantes y consumo específico y para después tratar de minimizar dichos parámetros en un motor diésel. Entre los resultados, alcanzaron una reducción del 36% y de entre el 3- 6% para las emisiones de hidrocarburos no combustionados (HC) y el consumo específico de combustible respectivamente. Basurko et al. [36] predijeron 15 parámetros diferentes de un motor diésel marino para después identificar fallos del motor (ej. obstrucción en la turbina, fallo en la inyección etc.) basándose en desviaciones entre parámetros modelados y medidos en el motor real. Parlak et al. [116] Desarrollaron un modelo mediante redes neuronales artificiales para predecir la temperatura de los gases de escape y el consumo específico de fuel para diferentes avances de la inyección en un motor diésel de un cilindro. Entre las conclusiones, recalcaron que una red neuronal suficientemente entrenada es suficientemente rápida y exacta como para simular los parámetros de los motores diésel. Con objeto de optimizar parámetros de funcionamiento como el rendimiento térmico del motor o el consumo de combustible, Aydin et al. [117] emplearon el modelado de redes neuronales para predecir 7 parámetros diferentes del motor (ej. T_{exh} , consumo específico de combustible, NO_x etc.). Entre las cualidades de este tipo de metodologías, está la capacidad de capturar relaciones de todo tipo entre los parámetros, siendo capaz de modelar rápidamente y con gran nivel de exactitud fenómenos físicos que de otra forma serían muy complejos de resolver [118]. Es por ello que muchos trabajos de investigación relacionados con el uso de combustibles alternativos han optado por el uso de las redes neuronales [119-121]. De otro modo, tendría que establecerse la relación de estos combustibles alternativos y el funcionamiento del motor mediante ecuaciones químicas y termodinámicas complejas. Del mismo modo, sin necesidad de resolver complejas ecuaciones como las del conocido mecanismo de Zeldovich [122], mediante el uso de redes neuronales artificiales muchas contribuciones han conseguido modelar las emisiones de distintos motores con altos niveles de exactitud [123-125].

Definición de la problemática

Tanto el modelado termodinámico como las redes neuronales artificiales se han estudiado en numerosos trabajos de investigación hasta el momento. Sin embargo, se ha observado que en la literatura existente quedan algunas líneas de investigación en las que ahondar con el objetivo de alcanzar metodologías de modelado de motores útiles para lograr una imagen completa del estado del motor en tiempo real. Es por ello por lo que, a lo largo de la presente tesis doctoral, se han tratado los siguientes problemas presentados de forma general en este apartado, mediante varios estudios que finalmente han desencadenado en numerosas publicaciones científicas y han aportado un gran valor añadido al campo del modelado de los sistemas de propulsión marinos.

Pese a que ambas estrategias han demostrado ser las más utilizadas por separado en el campo de estudio del modelado de motores marinos, pocos trabajos de investigación han planteado una comparativa de ambas metodologías con el fin de cuantificar las ventajas presentadas por cada estrategia en términos de exactitud y tiempo de cálculo. Algunos autores han llevado a cabo comparativas entre modelos termodinámicos y redes neuronales pero en puntos de operación específicos (ej. a una velocidad de giro constante) [126]. Los modelos termodinámicos han demostrado ser una herramienta de modelado muy fiable, y con el uso reciente de diferentes softwares para su desarrollo, se ha reducido el tiempo de cálculo de los mismos. Estos modelos pueden ser de tres tipos [127]: i) modelos 0-dimensionales (modelos termodinámicos o físicos), ii) modelos 1D o cuasi dimensionales, iii) modelos multidimensionales 2D y 3D que incluyen dinámica de fluidos computacional. Los software utilizados para el desarrollo de modelos termodinámicos implementan en su mayoría modelos 0D o 1D, que de acuerdo a Albrecht et al. [128] requieren menor tiempo de cálculo que los modelos multidimensionales. Sin embargo, el tiempo de cálculo de este tipo de modelos sigue siendo relativamente elevado como concluyeron Baldi et al. [129], que combinaron la estrategia de modelado termodinámico con el modelado de valor medio para reducir el tiempo de cálculo. Por lo tanto, aún no se ha comparado y validado experimentalmente el tiempo necesario por ambas metodologías (termodinámica y de redes neuronales) para el modelado de un mismo motor.

Por otro lado, las redes neuronales artificiales han tomado un papel muy importante en la simulación de los motores diésel, ofreciendo una solución rápida y eficiente en diversos campos de aplicación de los motores diésel. Sin embargo, los modelos de redes neuronales vistos hasta el momento en la literatura incluyen en su mayoría una cantidad reducida de outputs. Ejemplo de ello son trabajos como el de Lazakis et al. [130] que desarrollaron un sistema de detección de fallos basado solamente en la predicción de la temperatura de gases de escape. Similarmente, Shailaja et al. [124] predijeron emisiones de CO, NO_x y HC únicamente incluyendo estos tres outputs en su modelo. Dimensiones mayores de outputs pueden encontrarse en [120, 131] con 4 outputs, [132] con 5, [133] con 6 y [134] con 8 outputs. Por lo general, ninguno de los estudios citados hasta el momento contienen más de 10 outputs, con algunas excepciones [36]. Algunas contribuciones incluso decidieron diseñar una única red neuronal para cada output a predecir [135]. En el marco del mantenimiento basado en condiciones, si se desea observar el estado de un motor mediante un modelo, una cantidad reducida de outputs solo mostraría una imagen parcial del motor, por lo que sería de gran interés analizar estrategias de modelado de múltiples outputs. En este caso, hasta el momento no se ha estudiado la posibilidad de mostrar la imagen completa de un motor mediante un gemelo digital diseñado con redes neuronales artificiales de múltiples outputs.

Además, los modelos desarrollados han de ser aplicables en condiciones de funcionamiento reales, es decir, en condiciones en las que pueda estar el sistema de propulsión de un buque en alta mar. En este aspecto la literatura existente se centra en su mayoría en puntos de operación de carga y velocidad de giro muy concretos y limitados. Algunos trabajos mantienen la velocidad de giro constante y varían la carga del motor y el porcentaje de combustibles alternativos [117, 134]. Otros sin embargo, solo modifican algunos parámetros específicos del motor como la presión de inyección de combustible [136] o el ratio de compresión del motor junto con la carga del mismo [124]. Alternativamente, en algún trabajo se han variado tanto la carga del motor como su velocidad de giro, pero solamente en pequeños rangos (0%-30%) [131]. Sin embargo, la operativa real de un buque puede verse afectada por factores externos como las condiciones meteorológicas, lo que puede variar la relación entre la carga del motor y su velocidad de giro [137]. Es más, según Guo et al. [138], el estado del mar y la dirección de las olas (ej. dirección oblicua a la dirección del buque) podrían provocar variaciones en el par entregado en la hélice del buque para una misma velocidad de giro. Por todo ello, es necesario introducir este tipo de variaciones en el funcionamiento del motor a la hora de simular su funcionamiento. En otras palabras, estrategias como el modelado de redes neuronales deberían probarse considerando este tipo de variaciones tan comunes en la operativa real de un buque.

Por último, se observa que, pese a que muchos estudios (sobre todo los que emplean redes neuronales artificiales) incluyen parámetros del motor de varios tipos como inputs/outputs en sus modelos, sólo unos pocos proporcionan una debida justificación a la selección de dichos parámetros. Porteiro et al. [139] utilizaron la prueba y error para descartar la temperatura del aceite lubricante y la temperatura del refrigerante como inputs para su modelo tras realizar numerosas pruebas y ver que no proporcionaban información útil a su modelo. Alternativamente, Roy et al. [136] calcularon el coeficiente de correlación de Pearson para identificar la relación entre parejas de parámetros del motor e identificar parámetros con mayor correlación. Más recientemente, Jafari et al. [140] combinaron la matriz de correlación, el análisis de componentes principales y el clustering jerárquico para calcular las correlaciones entre parámetros de distintos subsistemas de un motor diésel marino de 6 cilindros. Es por ello que, para primero proponer una metodología como las redes neuronales artificiales, es necesario un preprocesado de los datos y un proceso de cálculo de correlaciones para identificar los parámetros que encajen mejor con esta herramienta de modelado. Además, en la mayoría de las investigaciones, las desviaciones entre modelo y realidad para las cuales se considera que algún elemento está fallando no están debidamente justificadas. Esto ocurre tanto en el caso de modelos termodinámicos como en el caso de modelos de redes neuronales artificiales. En algunos estudios se definen como valores de fallo del motor los errores máximos de las predicciones del modelo [141]. Otros presentan desviaciones representativas de fallos en estudios que incluyen dimensiones reducidas (ej. mediante análisis de componentes principales) [142] u otros directamente presentan las desviaciones sin evidenciar su origen [143]. Es por ello que, se observa la necesidad de caracterizar a gran escala los valores límite de las desviaciones entre modelo y realidad de los diferentes parámetros que determinen el funcionamiento normal y el de fallo de un motor diésel marino. Para ello, debería estudiarse un motor en operativa real, para considerar también las desviaciones que puedan sufrir los parámetros del motor a consecuencia no de un fallo sino de factores externos como la meteorología.

Hipótesis

Tras un estudio del contexto, el estado del arte y la definición de la problemática existente, se establece la siguiente hipótesis:

“Las herramientas de inteligencia artificial pueden ser una solución efectiva para crear gemelos digitales de los motores diésel marinos, en aplicaciones de mantenimiento basado en condiciones y diagnosis de motores.”

Objetivos

El objetivo principal de la presente tesis es identificar diferentes estrategias de modelado de motores diésel marinos, tratando de caracterizar las ventajas comparativas de cada una de ellas mediante su aplicación en un motor real como fase preliminar. Una vez entendidas las ventajas comparativas que ofrecen las redes neuronales artificiales, se pretende obtener una imagen completa de un motor diésel marino similar a los utilizados en buques de pesca de medio porte, para ello prediciendo múltiples parámetros en condiciones del motor cambiantes, emulando condiciones meteorológicas variables. Por último, se pretende caracterizar los valores límite de diferentes parámetros del motor para situaciones de fallo, para ello empleando datos de buques en operativa real con objeto de proveer un punto de referencia para futuros trabajos de identificación y clasificación de fallos en motores marinos. Por consiguiente, se identifican los siguientes objetivos específicos para la presente tesis:

- 1- Análisis de la situación actual de los motores diésel marinos e investigación del contexto del transporte marítimo a nivel global y de la flota pesquera de la Unión Europea.
- 2- Estudio y revisión bibliográfica de las diferentes estrategias de modelado de motores diésel marinos, identificando posibles soluciones para la creación e implementación de modelos que muestren una imagen completa del estado de los motores, con aplicaciones de mantenimiento basado en condiciones y diagnosis de la máquina.

- 3- Cuantificar las ventajas que ofrecen los modelos termodinámicos y los modelos de redes neuronales artificiales en una primera fase preliminar, modelando un motor diésel de un cilindro. Testear diferentes algoritmos de optimización en el caso de las redes neuronales artificiales, para ver la efectividad y rapidez de cada algoritmo.
- 4- Validar ambos modelos mediante ensayos experimentales. Discutir posibles aplicaciones de ambas estrategias de modelado en motores de mayor porte, tratando el nivel de exactitud de cada metodología y el tiempo de cálculo requerido.
- 5- Analizar la capacidad de adaptación y robustez de las redes neuronales artificiales para predecir múltiples parámetros de funcionamiento y emisiones de gases contaminantes simultáneamente en motores diésel marinos, mostrando así una imagen completa del estado del motor (conocida como gemelo digital).
- 6- Estudiar la capacidad de predicción y el nivel de exactitud de las redes neuronales artificiales para predecir múltiples parámetros de funcionamiento y emisiones considerando el mapa completo de funcionamiento del motor. Es decir, analizar las predicciones de las redes neuronales para cualquier punto de funcionamiento del motor, en el que se pueda encontrar debido a factores externos como la meteorología o las corrientes.
- 7- Validar experimentalmente los modelos construidos mediante ensayos con un motor diésel marino de seis cilindros, analizando el error de predicción del modelo tanto en puntos normales de funcionamiento del motor como en puntos aleatorios del mapa de funcionamiento del motor simulando condiciones reales de funcionamiento de este en alta mar.
- 8- Analizar las correlaciones y desviaciones de múltiples parámetros de un motor diésel marino instalado a bordo de un buque pesquero de gran porte. Analizar qué parámetros son recomendables para modelar mediante redes neuronales, y cuáles (si los hubiera) deberían modelarse con métodos alternativos.
- 9- Estudiar métodos alternativos de modelado para aquellos parámetros de los sistemas de propulsión que tengan tendencias constantes y no sean modelables mediante redes neuronales artificiales.
- 10- Caracterizar los valores límite de errores entre modelo y motor real en los que se trabaja un motor sano instalado en un buque pesquero en operativa real. Caracterización de desviaciones para futuros trabajos de identificación de fallos que quieran considerar desviaciones representativas de fallos en el motor. Estudio en buque pesquero real en operativa durante 2020 y 2021.

Estructura de la tesis

Tabla In. 1 Estructura de la tesis

Apartado	Descripción	Objetivos específicos	Contribución científica
Introducción	Estudio del estado del arte de los sistemas de propulsión marinos, en el marco del transporte marítimo global y la flota pesquera de la Unión Europea. Análisis de las metodologías de modelado de motores diésel marinos existentes e identificación de soluciones aplicables para el mantenimiento basado en condiciones.	1,2	-
Capítulo 1	Comparación de sistemas de modelado termodinámico y de redes neuronales artificiales en la simulación de un motor diésel de un cilindro. Estudio y comparativa de los algoritmos de optimización más rápidos y eficaces para el entrenamiento de redes neuronales artificiales de la actualidad. Validación y cuantificación de las ventajas/desventajas presentadas por cada estrategia de modelado mediante ensayos experimentales con el motor diésel de un solo cilindro.	3,4	I
Capítulo 2	Estudio de la capacidad de adaptación y robustez de las redes neuronales artificiales para predecir simultáneamente numerosos parámetros de funcionamiento y emisiones de un motor diésel de 6 cilindros. Estudio de la capacidad de regresión de esta herramienta para predecir dichos parámetros en cualquier punto aleatorio del mapa de funcionamiento del motor, simulando condiciones externas cambiantes como la meteorología o las corrientes marinas.	5,6,7	II
Capítulo 3	Análisis de las correlaciones y desviaciones de múltiples parámetros de un motor diésel marino instalado a bordo de un buque pesquero. Propuesta de sistemas de modelado alternativos para los parámetros con tendencias constantes. Caracterización de valores límite de múltiples parámetros de un motor sano para proveer desviaciones contrastadas a futuros trabajos sobre identificación de fallos.	8,9,10	III

CONTRIBUCIONES CIENTÍFICAS

Artículos presentados en revistas

- I- J. Castresana, G. Gabiña, L. Martin, Z. Uriondo, Comparative performance and emissions assessments of a single-cylinder diesel engine using artificial neural network and thermodynamic simulation, *Applied Thermal Engineering*, (2020) 116343.
- II- J. Castresana, G. Gabiña, L. Martin, A. Basterretxea, Z. Uriondo, Marine diesel engine ANN modelling with multiple output for complete engine performance map, *Fuel*, 319 (2022) 123873.
- III- G.G. J.Castresana, I.Quincoces, Z.Uriondo, Healthy Marine Diesel Engine Threshold Characterization with Probability Density Functions and ANN, *Reliability Engineering & System Safety* (Submitted to journal), (XXXX) (2022).

Artículos presentados en congresos internacionales

- J. Castresana, G. Gabiña, L. Martin, Z. Uriondo, Diesel engine performance prediction using Artificial Neural Networks with low correlation inputs, in: 15th International Conference on Heat Transfer, Fluid Mechanics and Thermodynamics, 2021.
- J. Castresana, G. Gabiña, A. Basterretxea, Z. Uriondo, Artificial Neural Network based marine diesel engine modelling, in: International Heat Powered Cycles Conference 2021, Bilbao, 2021.
- J. Castresana, G. Gabiña, A. Basterretxea, Z. Uriondo, Marine diesel engine multiple performance parameter characterization in variable conditions with thermodynamic modelling, in: 16th International Conference on Heat Transfer, Fluid Mechanics and Thermodynamics, 2022.

Otras contribuciones

- G. Lopez-Ruiz, J. Castresana-Larrauri, J.M. Blanco-Ilzarbe, Thermodynamic Analysis of a Regenerative Brayton Cycle Using H₂, CH₄ and H₂/CH₄ Blends as Fuel, *Energies*, 15 (2022) 1508.
- J. Castresana, G. Gabiña, L. Martin, Z. Uriondo, Herramientas para la predicción de fallos en motores marinos, *Ruta Pesquera & Naval*, (2021).
- J. Castresana, G. Gabiña, A. Basterretxea, Z. Uriondo, Inteligencia artificial para la predicción del funcionamiento en motores marinos, *Ruta Pesquera & Naval*, (2022).

CAPÍTULO 1. Comparación de modelos termodinámicos y de redes neuronales artificiales para la predicción de parámetros de funcionamiento y emisiones en un motor diésel de un cilindro

Nomenclatura

<i>Acrónimos</i>			
1D	Modelo de una dimensión	NO	Monóxido de nitrógeno
ANN	Red neuronal artificial	NO₂	Dióxido de nitrógeno
AVL	Anstalt für Verbrennungskraft maschinen List	NO_x	Óxidos de nitrógeno
BMEP	Presión media efectiva al freno	O₂	Oxígeno
CO	Monóxido de carbono	OH	Hidróxido
CPU	Unidad central de procesamiento	R	Coefficiente de regresión
ETSIB	Escuela técnica superior de ingeniería de Bilbao	RAM	Memoria de acceso aleatorio
FMEP	Presión efectiva media de fricción	ROHR	Tasa de liberación de calor
IDLE	Integrated development and learning environment	RSM	Response surface methodology
LM	Levenberg-Marquardt	SB	Límite del modelo termodinámico
Log	Logaritmo	Sig	Sigmoide
MAPE	Error porcentual medio absoluto	Tan	Tangente
MSE	Error cuadrático medio	TDC	Punto muerto superior
N₂	Nitrógeno	T_{exh}	Temperatura de gases de escape
N₂O	Óxido nitroso		

1- Resumen

El modelado y simulación de los motores diésel se ha convertido en foco de estudio en los últimos años junto con el desarrollo de nuevas estrategias de mantenimiento basado en condiciones, convirtiéndose en una de las herramientas clave para la diagnosis de los motores diésel. En este capítulo, tras la revisión bibliográfica de las diferentes estrategias de modelado empleadas en las últimas décadas, se han comparado dos de las metodologías de simulación más utilizadas: el modelo termodinámico y las redes neuronales artificiales. Esta comparación se ha llevado a cabo en el caso de estudio de un motor diésel de un cilindro. Para ello, el modelo termodinámico ha sido desarrollado empleando el software de simulación de motores AVL Boost™. Primero, se han introducido todos los elementos y conexiones del motor, incluyendo todas las características físicas requeridas por el programa (diámetro de cilindro, carrera, curvas de apertura y cierre de válvulas etc.). Después, se han escogido los submodelos de transferencia de calor, modelos de combustión y demás características de funcionamiento para hacer coincidir las curvas de presión de combustión modeladas con las curvas reales.

Por otro lado, el modelo de redes neuronales artificiales se ha desarrollado comparando dos de los algoritmos de optimización más potentes y utilizados en trabajos de modelado de motores: Adam y Levenberg-Marquardt. La decisión del algoritmo de optimización, junto con la determinación del número de neuronas en la capa oculta de la red se han llevado a cabo mediante el análisis de error de predicción de la red durante su entrenamiento. Una vez ajustadas, se ha estudiado la adaptabilidad y robustez de ambas metodologías de modelado para todo el espectro de carga del motor, comparado valores calculados por los modelos con valores reales extraídos de ensayos experimentales. Tanto el modelo termodinámico como el modelo de redes neuronales artificiales han demostrado ser herramientas fiables para la predicción de parámetros de funcionamiento y emisiones de un motor diésel. Para su comparación, se han introducido como inputs la velocidad de giro y la presión media efectiva (BMEP), y se han calculado el consumo específico de combustible, la temperatura de gases de escape y las emisiones de CO y de NO_x.

Las redes neuronales muestran mayores niveles de exactitud para las predicciones del consumo específico de combustible para cualquier carga del motor. Para las temperaturas de gases de escape, las redes neuronales muestran mayor exactitud para cargas medias-altas mientras que el modelo termodinámico muestra mejores resultados para cargas medias-bajas del motor. Las emisiones de CO muestran menores niveles de error para el modelo termodinámico en todo el rango de carga del motor exceptuando las cargas más altas. En cuanto a las emisiones de NO_x

ambos modelos presentan altos niveles de exactitud, excluyendo las cargas más bajas. En términos generales, se ha percibido una mayor dificultad para el modelo termodinámico de representar la evolución del funcionamiento del motor para el espectro completo de carga de este, concretamente para las cargas más altas (ej. no pudiendo emular con bajo error el incremento de emisiones de CO o de la temperatura de gases de escape a partir del 70-80% de carga del motor). El tiempo de cálculo es menor para las redes neuronales artificiales, pero el modelo termodinámico provee varios parámetros de funcionamiento adicionales (ej. curvas de presión de combustión, temperatura de cilindros, etc.)

Abstract

Diesel engine parameter prediction became a topic of interest in recent years, along with the development of condition-based maintenance, and is now considered a key instrument for engine diagnosis research. This contribution compares two different approaches for diesel engine performance prediction: thermodynamic modelling and artificial neural networks (ANNs). The thermodynamic modelling was developed using AVL Boost™ software simulating a single-cylinder diesel engine with different engine loads and operating conditions. The ANN modelling was conducted by comparing two efficient training algorithms to achieve the best prediction performance, with the ANN structure parameters determined by network error analysis. Both models' prediction accuracy was verified by a single-cylinder engine test bench operating under real conditions. The adaptability and robustness of the two approaches was studied for the whole engine load spectrum, comparing predicted values to experimental measurements. Both prediction tools, ANN and thermodynamic modelling, proved to be reliable for engine performance and emissions prediction. In both models brake-specific fuel consumption (BSFC), exhaust gas temperature (T_{exh}), carbon monoxide (CO) and nitrogen oxides (NO_x) were predicted using brake mean effective pressure (BMEP) and engine speed as inputs. ANN show higher accuracy for BSFC prediction in all engine loads, and T_{exh} prediction accuracy is better for ANN when dealing with medium to high loads, while the thermodynamic model shows better results when dealing with medium to low loads. CO is better predicted by the thermodynamic model except for the highest engine loads, and NO_x predictions present high accuracy in both models, except for the lowest loads. Calculation time is lower for ANN, but the thermodynamic model provides additional performance results (i.e. combustion pressure tracing and associated values).

2- Material y métodos

2.1 Banco de pruebas y equipamiento

El banco de pruebas utilizado para los ensayos experimentales del presente capítulo está situado en la Escuela Técnica Superior de Ingeniería de Bilbao (ETSIB). Este banco contiene un motor diésel de un cilindro de modelo Minsel430a acoplado a un freno hidráulico (bomba hidráulica SKF). Este es un motor muy adecuado para una fase preliminar de la tesis, ya que en comparación a otros motores de mayores dimensiones y múltiples cilindros tiene un consumo de combustible notablemente menor, lo que permite realizar numerosos ensayos a bajo coste. Este motor emplea la aspiración natural (sin turbocompresores), y está refrigerado por aire. Sus características se muestran en la Tabla C1. 1. En la Figura C1. 1 se muestra una imagen general del banco de pruebas.

Tabla C1. 1 Características del motor Minsel430

Parámetro	Valor	Unidad
Número de cilindros	1	[-]
Tipo de ciclo	4-tiempos alta velocidad	[-]
Ratio de compresión	19,3:1	[-]
Diámetro	85	mm
Carrera	75	mm
Velocidad nominal	3000	rpm
Potencia nominal	5	kW
Carga de aire	Aspiración natural	[-]



Figura C1. 1 Imagen del banco de pruebas con motor Minsel430a

Para poder testear los modelos a lo largo del rango completo de carga del motor, se han realizado diferentes ensayos experimentales cambiando la carga mediante un freno hidráulico. A su vez, el sistema de adquisición utilizado para visualizar y registrar varios parámetros del motor en tiempo real es el DEWETRON 2600. Esta herramienta registra parámetros con altas frecuencias de adquisición, lo que permite registrar parámetros respecto al ángulo del cigüeñal como la presión de combustión dentro del cilindro. Después de registrar varias variables a lo largo de los diferentes ensayos, estos datos han sido filtrados y preparados para su introducción en los modelos mediante Python3. La Figura C1. 2 muestra un esquema de este banco de ensayos y la Tabla C1. 2 muestra los diferentes instrumentos de adquisición utilizados para registrar las variables del motor.




Figura C1. 2 Esquema de banco de ensayos con equipamiento de monitorización

Tabla C1. 2 Lista de variables registradas y sensores utilizados con niveles de incertidumbre de cada sensor

ID	Parámetro	Unidad	Instrumento	Incertidumbre
1	Temperatura de aire de entrada	[°C]	Termopar tipo K	± 4%
2	Temperatura de gases de escape	[°C]	Termopar tipo K	± 4%
3	Temperatura de gasoil	[°C]	Termopar tipo K	± 4%
4	Peso del tanque de gasoil	[kg]	Célula de carga HBM class 3	± 0,03%
5	Temperatura de aceite	[°C]	Termopar tipo K	± 4%
6	Velocidad de giro	Rpm	Encóder Kistler tipo 2614B	± 0,05%
7	Posición del cigüeñal	°	Encóder Kistler tipo 2614B	± 0,02°
8	Par	Nm	Kistler 4502A50RA	< 0,07%
9	Presión de combustión	Bar	Sensor piezoeléctrico KISTLER 6013 CA	sensibilidad: 21 pC/bar max. presión: 250 bar
10	Emisiones de gases contaminantes	Ppm	Analizador TESTO 350XL MARITIME	Según MARPOL Annex VI y código técnico de NO _x

Con objeto de cubrir el espectro completo de carga del motor, se han llevado a cabo 7 ensayos diferentes, cubriendo cargas del motor desde el 0% hasta el 100%. Para ello, cada punto de funcionamiento se establece modificando la carga mediante el freno hidráulico. Este freno contiene una válvula manual que a medida que se va cerrando va aumentando el par de resistencia del freno hidráulico. Así pues, girando gradualmente la válvula se han establecido los 7 puntos de operación diferentes de los ensayos. Tras instaurar cada punto de operación, el motor se ha dejado en funcionamiento en este punto durante 30 minutos, para asegurar el estado estacionario del motor en dicha situación de carga. Durante estos 30 minutos, se ha

medido la diferencia de peso del tanque de combustible mediante la célula de carga. Con esta diferencia se calcula después el consumo específico de combustible de cada estado del motor. Tras este tiempo, se adquieren el resto de los parámetros que principalmente se agrupan en dos tipos: i) parámetros registrados a alta frecuencia; ii) parámetros registrados a baja frecuencia. En el primer grupo se encuentran aquellas variables que han de representarse respecto al ángulo del cigüeñal, que son en su mayoría los parámetros del interior de la cámara de combustión como la presión de combustión o el par respecto al ángulo del cigüeñal. Estos parámetros se miden con una frecuencia de adquisición de hasta 1 MHz, siendo después registrados con una resolución de 0,1°. El segundo tipo corresponde a los parámetros cuyo desarrollo en el tiempo no requiere de una frecuencia de adquisición tan alta y son por lo tanto registrados con una frecuencia de 1 registro/segundo. Pese a adquirirse a frecuencias diferentes, todos los parámetros se registran simultáneamente, acoplándolos después para conseguir una base de datos única.

El tiempo de adquisición en cada punto de operación es de 1,5 minutos, y se realizan dos tomas de datos para asegurar que la toma de datos en cada punto de operación se realiza correctamente. Por lo tanto, de cada punto se obtienen dos archivos de 1,5 minutos. Aunque el motor se encuentre en estado estacionario tras los 30 minutos de espera, algunos parámetros cambian ligeramente de valor debido al funcionamiento del motor, por ello, de cada archivo de 1,5 minutos se toman 10 registros diferentes. Resumiendo, la base de datos contiene $7 \times 2 \times 10 = 140$ registros de todas las variables mencionadas en la Tabla C1. 2. Esta base de datos, junto con las curvas de presión de combustión medidas a alta frecuencia se han utilizado para ajustar y testear el modelo termodinámico y el modelo de redes neuronales artificiales desarrollados para el Minsel430a. El proceso de adquisición se muestra en la Figura C1. 3. Ambos modelos tienen como inputs la presión media efectiva (BMEP, representativa de la carga del motor) y la velocidad de giro, y los outputs a calcular son el consumo específico, la temperatura de gases de escape y las emisiones de CO y NO_x.




Figura C1. 3 Proceso de adquisición de datos de ensayos con el Minsel430a

2.2 Modelo termodinámico

En este caso de estudio, para el modelado termodinámico del motor de un cilindro Minsel430a se ha utilizado el software de simulación de motores AVL Boost™. Como ya se ha visto en el estudio del estado del arte, este es un software por el que se ha apostado en muchos trabajos de investigación en torno al modelado de motores diésel recientemente. Mediante este programa se desarrollan modelos termodinámicos 1D en los que se seleccionan diferentes elementos para después unirlos con tuberías de distintas tipologías [88]. Para ajustar el modelo al motor real, se han comparado las curvas de presión de combustión modeladas y las curvas reales para distintas cargas del motor. Este tipo de ajustes pueden verse en varios estudios [86, 98]. Cabe mencionar que en este estudio un único modelo deberá predecir cuatro parámetros de funcionamiento del motor a lo largo de todo el espectro de carga del motor, desde 0% hasta 100% de carga. Por lo tanto, el ajuste del modelo no sólo se ha realizado en un punto de operación único, sino que este necesita estar correctamente ajustado en varios puntos de operación distintos del motor. En la Figura C1. 4 se muestra el esquema del modelo termodinámico desarrollado en este apartado.

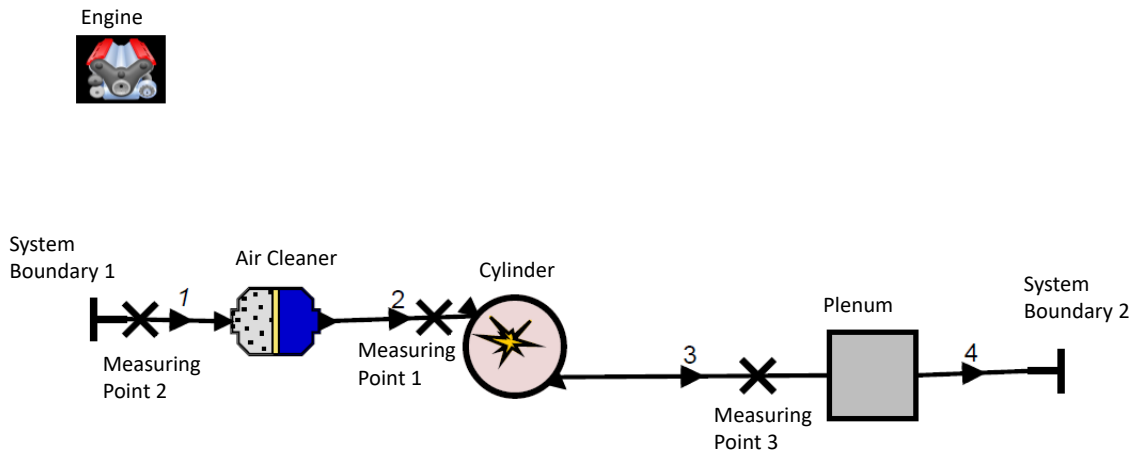


Figura C1. 4 Esquema del Minsel430a en AVL Boost™

Este software consiste en un entorno de programación gráfica en el que los elementos del motor son seleccionados manualmente. Una vez se han introducido todos los elementos, se realizan las conexiones entre ellos mediante tubos, y el modelo está listo para ser ajustado al motor real. Cabe destacar que, tanto en los elementos del motor como en los tubos, después habrá que introducir todas las características del motor real, desde los diámetros de los tubos que conectan los distintos elementos hasta el modelo de combustión seleccionado para el cilindro. Todos estos datos se han introducido de acuerdo con los diferentes manuales y trabajos de

investigación encontrados sobre AVL, siguiendo un orden específico para introducir dichas características del motor en el modelo [144-147]. A continuación, se explicará primero el marco teórico en el que está basado el programa, concretamente centrándolo en los cuatro outputs que se quieren calcular. Después, se explicará el ajuste realizado en los diferentes elementos del modelo.

2.2.1 Marco teórico

El software de AVL Boost™ calcula las propiedades del gas (i.e constante del gas, valores de calor específico, etc.) en cada unidad de tiempo basándose en la temperatura, la presión y la composición del gas en ese momento. Para calcular dichas propiedades, se aplican las ecuaciones de conservación en los diferentes elementos y tubos del modelo. En este aspecto, a modo de entender el origen de los cálculos necesarios para simular los cuatro outputs seleccionados en este modelo, se presentarán algunas ecuaciones que utiliza el software para su cálculo.

Cilindro

El elemento del cilindro (en el caso del Minsel430a sólo uno), se considera como un único sistema, y se realizan balances tanto de masa como de energía aplicando las correspondientes ecuaciones de conservación en este sistema. En la Figura C1. 5 se muestra un esquema del sistema considerado como cilindro. Para caracterizar el cilindro, se requieren múltiples parámetros físicos (diámetro, carrera etc.) y también otros relacionados con parámetros termodinámicos (modelo de transferencia de calor etc.). Esto se explicará en el siguiente apartado, pero primero se pretende mostrar la base teórica de la cual parten los cálculos después con toda la información introducida. Por lo tanto, se utilizan los siguientes dos balances:




Figura C1. 5 Esquema del sistema considerado como cilindro

Balance másico:

$$\frac{dm_{cylinder}}{d\alpha} = \frac{dm_{in}}{d\alpha} - \frac{dm_{out}}{d\alpha} + \frac{dm_{fuelevap.}}{dt} \quad (1)$$

$$\frac{dm_{cylinder}}{d\alpha} = \frac{dm_{int}}{d\alpha} - \frac{dm_{exh}}{d\alpha} - \frac{dm_{blowby}}{d\alpha} + \frac{dm_{fuelevap.}}{dt}$$

Donde $\frac{dm_{cylinder}}{d\alpha}$ representa el cambio másico en el cilindro, $\frac{dm_{int}}{d\alpha}$ y $\frac{dm_{exh}}{d\alpha}$ representan el cambio de masa en el colector de entrada del motor y el cambio de masa en el colector de escape del motor respectivamente, $\frac{dm_{blowby}}{d\alpha}$ las pérdidas de aire debidas al blow-by en el cilindro y $\frac{dm_{fuelevap.}}{dt}$ el cambio de masa debido a la evaporación del fuel.

Balance de energía:

$$\frac{dU}{d\alpha} = \frac{dQ}{d\alpha} - \frac{dW}{d\alpha}$$

$$\begin{aligned} \frac{d(m_{cylinder} \cdot u)}{d\alpha} = & \frac{dQ_{fuel}}{d\alpha} + \frac{dm_{int}}{d\alpha} h_{int} - \frac{dm_{exh}}{d\alpha} h_{exh} - \frac{dm_{blowby}}{d\alpha} h_{blowby} - \\ & - \sum \frac{dQ_{loss}}{d\alpha} - qf \frac{dm_{fuelevap.}}{dt} - p_{comb.} \frac{dV}{d\alpha} \end{aligned} \quad (2)$$

$\frac{dQ_{fuel}}{d\alpha}$ representa el calor introducido mediante el fuel. $h_{int}, h_{exh}, h_{blowby}$ son las entalpías de los fluidos de entrada, escape y blow-by respectivamente. q es el calor de evaporación, f la fracción de evaporación de la carga del cilindro. $p_{comb.} \cdot \frac{dV}{d\alpha}$ representa el trabajo del pistón. Mediante la resolución de las ecuaciones (1) y (2) y junto con la asunción y correspondiente ecuación de gas ideal se pueden calcular la temperatura y presión en el cilindro. Este último es un parámetro muy importante en el presente estudio, ya que se utilizará para analizar si el modelo está suficientemente ajustado comparando curvas de presión de combustión modeladas y reales en diferentes cargas del motor.

[Parámetros de emisiones de gases contaminantes](#)

[Formación de NO_x](#)

El cálculo de la formación de NO_x está basado en un estudio desarrollado por Pattas y Haefner [148] que utilizó las siguientes 6 ecuaciones del método extendido de Zeldovich [149]:

Tabla C1. 3 Reacciones químicas consideradas para cálculo de emisiones de NOx

	Reacciones	Velocidad [mol/cm ³ s]	k ₀ [cm ³ ,mol,s]	a [-]	T _A [K]
R1	N ₂ + O = NO + N	$r_1 = k_1 \cdot C_{N_2} \cdot C_O$	4,93E13	0,0472	38048,01
R2	O ₂ + N = NO + O	$r_2 = k_2 \cdot C_{O_2} \cdot C_N$	1,48E08	1,5	2859,01
R3	N + OH = NO + H	$r_3 = k_3 \cdot C_{OH} \cdot C_N$	4,22E13	0,0	0,0
R4	N ₂ O + O = NO + NO	$r_4 = k_4 \cdot C_{N_2O} \cdot C_O$	4,58E13	0,0	12130,6
R5	O ₂ + N ₂ = N ₂ O + O	$r_5 = k_5 \cdot C_{O_2} \cdot C_{N_2}$	2,25E10	0,825	50569,7
R6	OH + N ₂ = N ₂ O + H	$r_6 = k_6 \cdot C_{OH} \cdot C_{N_2}$	9,14E07	1,148	36190,66

Las constantes k utilizadas para calcular las velocidades de las distintas reacciones se calculan con la ecuación (3). Las concentraciones indicadas son aquellas logradas en condiciones de equilibrio con unidades [mol/cm³].

$$k_i = k_{0,i} * T^a * e^{\left(\frac{-T A_i}{T}\right)} \quad (3)$$

De esta forma, la creación de NO, se calcula con la siguiente fórmula:

$$r_{NO} = C_1 \cdot C_2 \cdot 2 \cdot (1 - \alpha^2) \cdot \left(\frac{r_1}{1 + \alpha \cdot \frac{r_1}{r_2 + r_3}} + \frac{r_4}{1 + \alpha \cdot \frac{r_4}{r_5 + r_6}} \right) \quad (4)$$

$$\alpha = \frac{C_{NO}}{C_{NOeq}} \cdot \frac{1}{C_2}$$

C₁ y C₂ son multiplicadores cinéticos y de postproceso respectivamente, estos se utilizan para el ajuste de la velocidad de creación de NO durante el modelado de la combustión en AVL. C_{NO} y C_{NOeq} representan la concentración y la concentración de equilibrio de NO respectivamente, y r_i son las velocidades de reacción de las 6 reacciones diferentes consideradas en este método. Estas velocidades dependen de la temperatura de los gases, las concentraciones de los diferentes compuestos de la reacción y de las constantes empíricas k₀, a y T_A.

Formación de CO

El cálculo de la formación de CO está basado en las reacciones mencionadas por Onorati et al. [150] que calcularon la velocidad de formación/destrucción de CO basándose en el clásico submodelo cinético descrito por Heywood [151]. Se consideran las siguientes dos ecuaciones:

Tabla C1. 4 Reacciones químicas consideradas para cálculo de emisiones de CO

	Reacciones	Velocidad
R1	$\text{CO} + \text{OH} = \text{CO}_2 + \text{H}$	$r_1 = 6,76 \cdot 10^{10} \cdot e^{\left(\frac{T}{1102.0}\right)} \cdot c_{\text{CO}} \cdot c_{\text{OH}}$
R2	$\text{CO} + \text{O}_2 = \text{CO}_2 + \text{O}$	$r_2 = 2,51 \cdot 10^{12} \cdot e^{\left(\frac{-24055.0}{T}\right)} \cdot c_{\text{CO}} \cdot c_{\text{O}_2}$

La fórmula final para esta formación/destrucción de CO utilizada por AVL se muestra en la ecuación (5):

$$r_{\text{CO}} = C_3 \cdot (r_1 + r_2) \cdot (1 - \alpha)$$

$$\alpha = \frac{C_{\text{CO}}}{C_{\text{COeq}}} \tag{5}$$

C_3 es una constante de postproceso utilizada por AVL Boost™ para un mejor ajuste de las emisiones de CO.

Cálculo de consumo específico (BSFC)

AVL Boost™ ofrece la posibilidad de controlar el valor de BMEP introduciendo un controlador integral a uno de estos parámetros del motor: cantidad de combustible inyectado por ciclo, ángulo de válvula de paso de aire al motor o alguna restricción de paso de flujo de gases en algún punto concreto del motor. En este caso de estudio, como variable de control se escogió el fuel inyectado por ciclo para controlar el BMEP del modelo. De esta forma, dado un BMEP concreto, el modelo controlará el flujo de combustible, convergiendo para cada valor de BMEP a un valor distinto de flujo de combustible. Por lo tanto, a la vez que controla la variable BMEP, también nuestro modelo calculará el valor correspondiente de flujo de combustible (y por lo tanto de BSFC) a ese BMEP. Por lo que, finalmente, podremos calcular los flujos de combustible

para distintas cargas (o valores BMEP) del motor. Para ello, la expresión matemática utilizada del controlador integral se muestra en la ecuación 6:

$$m_f = m_{f,guess} + (m_{f,upper} - m_{f,lower}) \cdot \frac{i}{t_{cycle\ dur}} \cdot \int_0^t (BMEP_{des} - BMEP) \cdot dt \quad (6)$$

m_f representa el combustible inyectado por ciclo (en masa), $m_{f,guess}$ es un valor inicial para el flujo másico de combustible controlado, y $m_{f,upper}$ y $m_{f,lower}$ son valores superior e inferior de flujo másico de combustible para establecer límites al controlador. i representa la ganancia del controlador, $t_{cycle\ dur}$ es la duración del ciclo y $BMEP_{des}$ y $BMEP$ son valores objetivo y real del BMEP respectivamente.

2.2.2 Marco experimental

En este apartado se explicará el proceso de creación del modelo desarrollado para el Minsel430a. Como ya se ha mencionado, primero se seleccionan los elementos necesarios del motor, y después se realizan las conexiones entre los elementos seleccionados. A continuación, se explicarán los elementos más significativos del modelo planteado para el Minsel430a.

Elemento motor

En la Figura C1. 4, además de los elementos pertenecientes al motor, se puede ver un elemento añadido en la parte superior izquierda del esquema. Este es el elemento Engine o elemento motor, que representa un elemento con las características generales del motor. Primero, en este elemento se introduce la velocidad de giro a la que trabajará el modelo. Este puede ser un valor único, o también puede ser una variable que vaya cambiando según cada punto de funcionamiento al que se desee trabajar en el modelo. En el presente caso de estudio, puesto que la velocidad de giro es uno de los dos inputs introducidos tanto en el modelo termodinámico como en el de redes neuronales, se establece la velocidad de giro como una variable en el modelo de AVL Boost™, para poder ir cambiando su valor según la situación del motor que se quiera simular. En la Figura C1. 6 se muestra la ventana en la que se le asigna una variable llamada RPM a la velocidad de giro del motor.

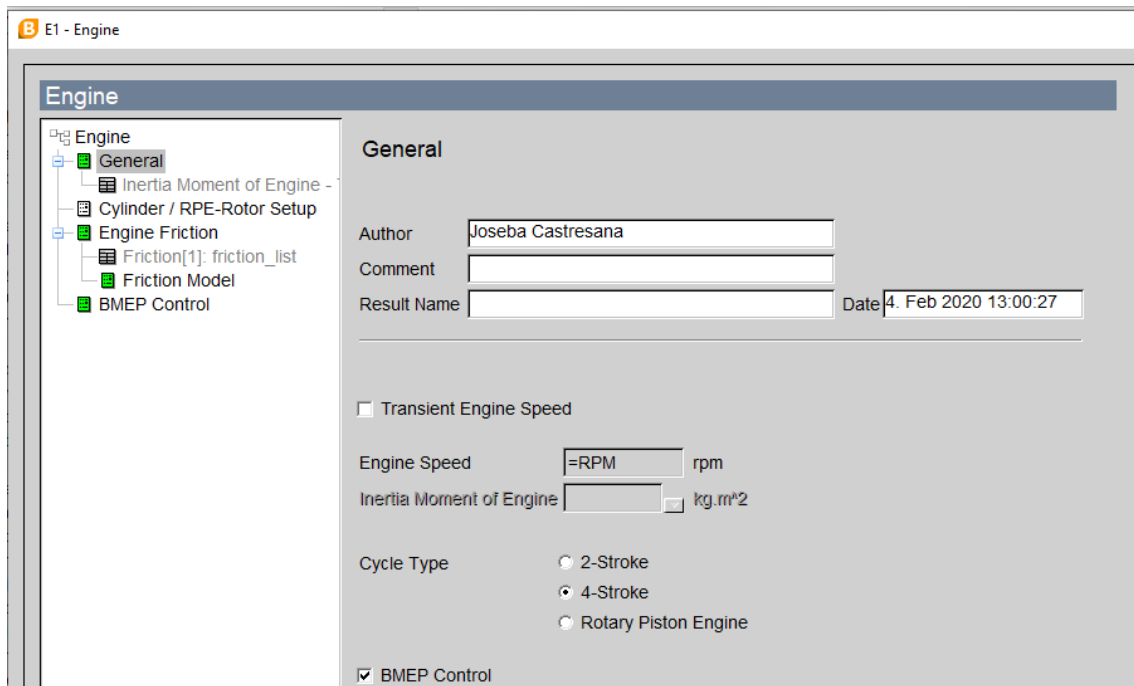


Figura C1. 6 Asignación de variable RPM a la velocidad de giro del modelo termodinámico

La fricción del motor es otro parámetro introducido en este elemento; este fenómeno se introduce al modelo mediante la variable FMEP, que tendrá después una influencia directa a la hora de calcular la potencia entregada por el motor. Para su cálculo, se utiliza el modelo de Patton et al. [152], modelo utilizado en otros trabajos de investigación relacionados con motores diésel [105]. Finalmente, el BMEP también se introduce en este elemento. Para ello, se establece el valor deseado de BMEP, y los parámetros límite y deseados mencionados previamente en la ecuación (6). De forma análoga a la definición de la velocidad de giro, se declara una nueva variable para el BMEP, de forma que dependiendo del punto de operación que queramos simular esta variable pueda ir cambiando de valor.

Cilindro

Este es el elemento en el que se caracteriza gran parte del funcionamiento del motor. Primero, se introducen las características geométricas indicadas en la Tabla C1. 1. Entre ellas, está el hueco considerado para el blow-by de los gases del interior del cilindro. Este hueco es muy complicado de medir en el motor real, y requeriría del desmontaje del motor para poder medirlo rigurosamente. Sin embargo, es un parámetro con una correlación directa respecto a la presión de compresión del motor. Y es que, sabida la relación de compresión del motor y teniendo la curva de presión de compresión, el ajuste de este parámetro se ha llevado a cabo mediante numerosas iteraciones hasta hacer coincidir la presión de compresión modelada con la real. Es

un parámetro importante ya que según lo concluido por Hountalas et al. [153], un fenómeno de blow-by elevado puede llevar a reducciones tanto en el valor máximo de la presión de combustión como en su posición respecto al cigüeñal, por lo que en cualquier modelo debería estar debidamente ajustado.

Respecto a la combustión, se ha utilizado el modelo de "Multiple Vibe 2-zone" para simular el proceso de combustión en el interior del cilindro. La primera parte o la parte "Multiple Vibe" representa un modelo de combustión que considera la suma ponderada de varias funciones Vibe [154] que son un tipo de función con forma de campana utilizado para representar la curva ROHR del motor. La ponderación de la suma de estas funciones se basa en la fracción de combustible quemado en cada una de ellas. Esto hace que el cálculo de la curva de ROHR y la caracterización de la combustión sea más precisa que considerando una única curva Vibe (Single vibe). El estudio del nivel de ajuste de cada tipo de función Vibe, double-Vibe etc. puede observarse en [155]. La segunda parte "2-zone" representa la asunción de que la zona quemada y la inquemada de la cámara de combustión no tienen la misma temperatura [156]. Es más, según Kumar et al. [157], la necesidad de lograr predicciones exactas y un estudio riguroso de las emisiones de gases contaminantes condujo a varios equipos de investigación a desarrollar modelos de combustión two zone ya que proporcionaban resultados notablemente más exactos que los logrados con modelos single zone [158-161]. Para el modelo de transferencia de calor se ha utilizado el conocido modelo Woschni [162], introduciendo especificaciones geométricas del interior del cilindro así como las temperaturas del pistón, culata y paredes de la camisa del motor. Por último, con objeto de modelizar debidamente el intercambio de gases en la cámara de combustión, se han introducido las curvas de apertura de las válvulas de admisión y de escape, junto con las curvas de coeficiente de flujo de ambas válvulas. En la Figura C1. 7 se muestra la curva de apertura mencionada para la válvula de admisión.

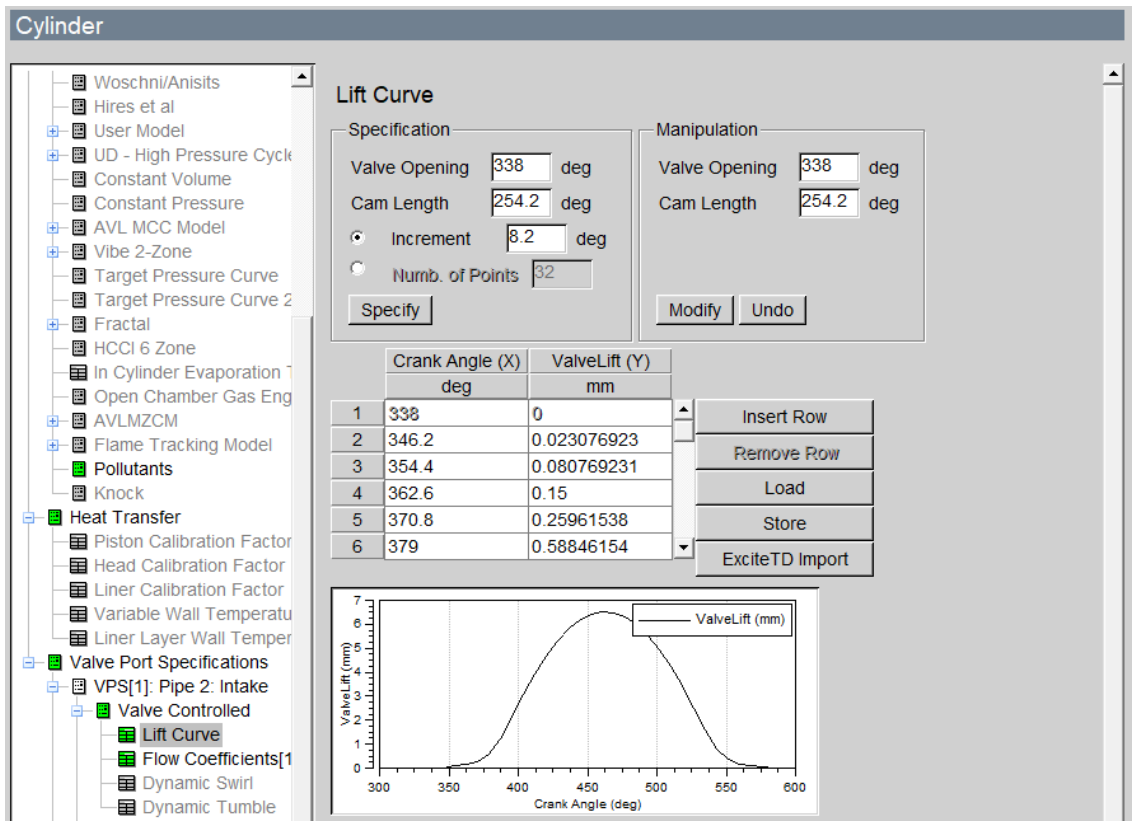


Figura C1. 7 Curva de apertura de válvula de modelo de motor Minsel430a

Por último, como se ha mencionado en el apartado de marco teórico, tanto la fórmula de creación de NO_x como la de CO contienen constantes empíricas, que han tenido que ser ajustadas para proporcionar cálculos de emisiones de estos gases con altos niveles de exactitud.

Filtro de aire

El motor diésel estudiado en esta primera fase de la tesis contiene aspiración natural, sin turbocompresores. Por lo tanto, el filtro de aire ha sido ajustado con rigor para proporcionar una entrada de aire al motor modelada correctamente. Para ello, se han introducido la temperatura y flujo del aire de entrada y la caída de presión objetivo en el filtro al programa. Con esta información el software calcula la curva de caída de presión respecto al flujo másico del aire. Esta curva ha sido validada con mediciones posteriores de la caída de presión en el filtro.

Colectores, tubos y límites

En el banco de pruebas del motor Minsel430a, el conducto de escape contiene un colector en medio que se emplea para la medición de emisiones de gases contaminantes (Figura C1. 1 parte inferior derecha). Con objeto de garantizar el máximo nivel de exactitud del modelo, este elemento también se ha incluido en el modelo mediante un elemento colector. Para caracterizarlo, no hay más que introducir el volumen de dicho colector y las condiciones iniciales de temperatura y presión de gases como punto de partida de los cálculos posteriores. Por otro lado, en cualquier modelo de AVL Boost™ es necesario caracterizar el entorno en el que trabaja el motor. Para ello existen los elementos llamados “system boundary” o límites. En este caso tenemos el límite de la entrada SB1 y el límite de la salida SB2. Mediante el SB1, se introducen las condiciones del aire a la entrada del filtro, es decir, las condiciones ambientales del aire. El SB2 en cambio representa las condiciones del exterior a la salida de los gases de escape. Este parámetro es muy relevante ya que dependiendo de los valores ambientales que se introduzcan en él, pueden simularse efectos dados en el motor real como la contrapresión. Según Hield [82], la contrapresión puede causar temperaturas de gases de escape elevadas, por lo que es necesario establecer los valores correctos de presión a la salida de los gases de escape para poder realizar una predicción exacta de la temperatura de gases de escape. En este caso, el banco de ensayos contiene un sistema de extracción para extraer los gases de escape del motor, por lo que se ha considerado dicha presión negativa también en el modelo. Por último, la caracterización de los tubos se ha llevado a cabo introduciendo la geometría de cada tubo que conecta los distintos elementos del motor, así como la temperatura de dichos tubos a efectos de calcular pérdidas de calor en ellos.

Filtrado de las curvas de presión de combustión reales

Las curvas de presión de combustión se han utilizado para ajustar y validar el modelo desarrollado a lo largo de su espectro de carga. Para un adecuado uso de dichas curvas, primero se han filtrado utilizando un filtro de Butterworth [163] desarrollado en Python. Este filtro es de orden 3, y la frecuencia de corte se ha establecido en 0,05 Hz. Por último, también se ha ajustado el offset del punto muerto superior para hacer coincidir las curvas modeladas y las reales en el dominio del ángulo del cigüeñal. La Figura C1. 8 muestra las curvas de presión de combustión en tiempo real mostradas en el DEWETRON2600 y la Figura C1. 9 muestra el proceso de filtrado de dichas curvas.




Figura C1. 8 Imagen del sistema de adquisición y representación de las curvas de presión de combustión

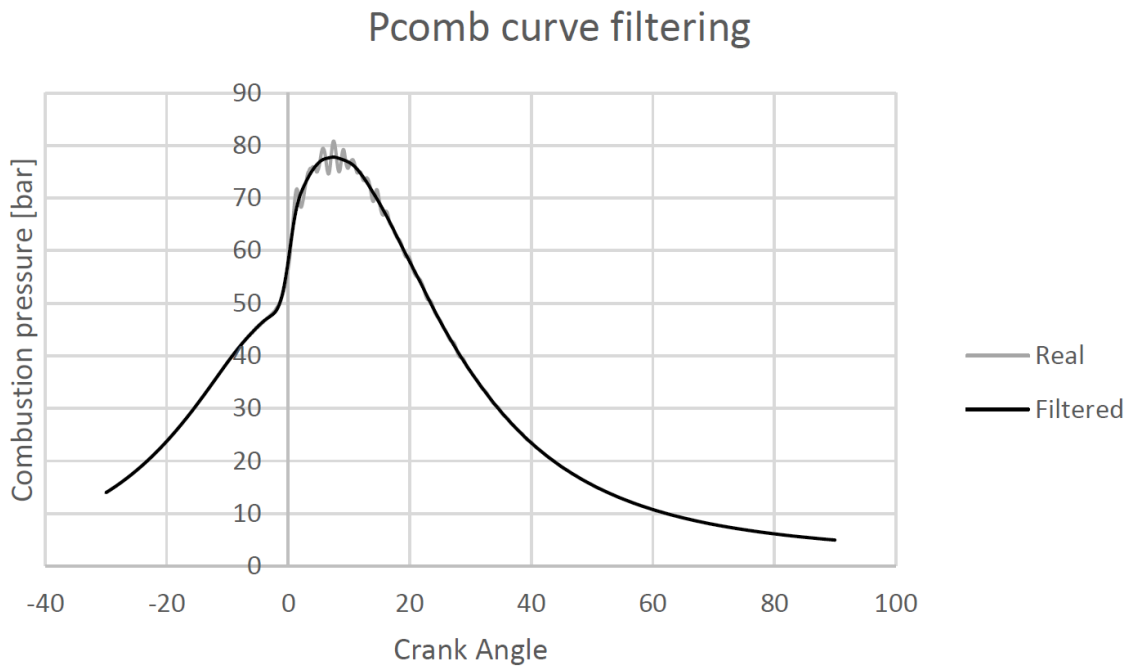


Figura C1. 9 Filtrado de curva de presión de combustión mediante filtro de Butterworth

2.3 Modelo de redes neuronales artificiales

Las redes neuronales artificiales son estructuras de unidades simples o elementos procesadores adaptables (conocidas como neuronas) interconectados entre sí capaces de realizar computaciones muy complejas para procesamiento de datos y representación de aprendizaje [73]. Operan de forma similar a un sistema de neuronas humano, ya que son capaces de aprender de situaciones diferentes para después solventarlas en un futuro. Existen múltiples tipos de redes neuronales artificiales según su estructura y las conexiones entre las neuronas. En este caso de estudio en concreto, se han seleccionado las Feed Forward Neural Networks por su capacidad de generalización y relativa simpleza en comparación con otras estructuras neuronales [164]. Para el motor Minsel430a, se han escogido dos inputs y cuatro outputs para ambos modelos, para poder comparar el nivel de exactitud de cada uno de ellos y discutir sus respectivas ventajas/desventajas. La Figura C1. 10 muestra un esquema de la estructura del modelo de redes neuronales planteado para este estudio.




Figura C1. 10 Esquema de red neuronal propuesta para Minsel430a

Para el desarrollo de este tipo de modelo, se han utilizado dos softwares diferentes: i) IDLE Spyder de Anaconda que soporta la programación en Python con librerías de Keras y Tensorflow; ii) Matlab Neural Network Toolbox. La razón de utilizar dos softwares diferentes para el diseño del modelo es que dos de los algoritmos de optimización más potentes de las redes neuronales no están soportados en un único Software. Por un lado, existe el algoritmo de optimización Adam que está soportado en Keras (Python) pero no en Matlab, y por otro está el algoritmo de optimización Levenberg-Marquardt que está soportado en Matlab, pero no en Keras. Sus

principios teóricos se explicarán en el siguiente apartado, después mostrando cómo se ha seleccionado el algoritmo más adecuado y los parámetros de la estructura de la red más adecuados para este modelo en concreto.

2.3.1 Marco teórico

En este apartado se explicará la base teórica de las redes neuronales utilizadas tanto en este estudio como en los siguientes trabajos de investigación realizados en el marco de la presente tesis. Las redes neuronales elegidas para desarrollar los modelos de los diferentes motores marinos de esta tesis son las Feed Forward Artificial Neural Networks. Según Svozil et al. [165], a finales de los años 90 ya eran la estructura de redes neuronales más utilizada. Si bien es cierto que existen otras estructuras más complejas (ej. redes neuronales convolucionales, redes neuronales recurrentes etc.), las redes neuronales feed forward son capaces de solventar problemas no lineales complejos, según Bebis y Georgiopoulos [166] siendo capaces de aproximar cualquier función de interés con niveles altos de exactitud. En este tipo de redes, todas las neuronas entre dos capas están conectadas entre sí. Así, para el cálculo de los outputs se parte desde los inputs y a través de las neuronas de la capa oculta se calculan dichos outputs. Las relaciones entre neuronas siempre van de input a output, y en ningún caso existen conexiones hacia atrás. Una vez calculados los outputs, la propagación del error hacia atrás para optimizar los parámetros de la red se conoce como “backpropagation”, y será explicada más a fondo en este apartado. Para entender el funcionamiento de estas redes, primero se explicará cómo funciona una neurona, para después entender cómo “aprende” una red neuronal a entender las relaciones entre inputs y outputs.

Funcionamiento de una neurona

El uso de una sola neurona no proporciona resultados exactos para problemas matemáticos complejos, sin embargo, la combinación de múltiples neuronas es lo que añade gran capacidad de resolución a las redes neuronales. En la Figura C1. 11 se muestra el esquema de una neurona.

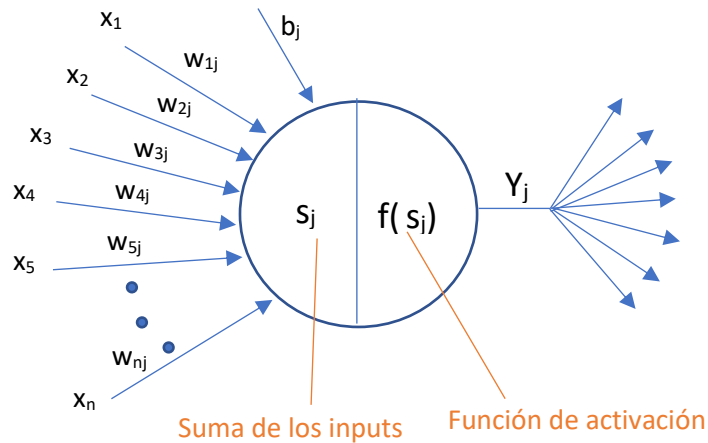


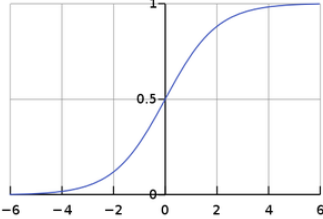
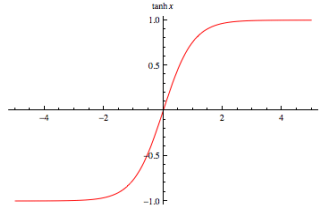
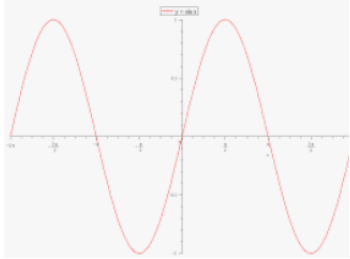
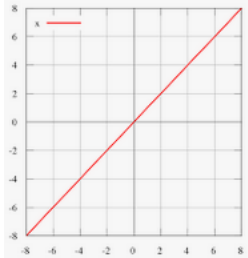
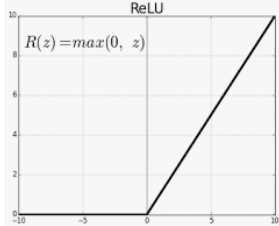
Figura C1. 11 Esquema de una neurona

Una neurona recibe varios inputs ($x_1, x_2, x_3, \dots, x_n$), y devuelve un output (y_j). Normalmente, los inputs que entran a una red neuronal suelen ser normalizados, para manejarlos con valores entre $[0,1]$. Cada input que se introduce a la neurona tiene un factor de peso asociado; en la Figura C1. 11 estas están representadas por ($w_{1j}, w_{2j}, w_{3j} \dots w_{nj}$). Este número determina la influencia que tiene una neurona en otra. Es decir, si el input proveniente de una neurona tiene un factor de peso alto, la influencia de esa neurona en la otra es directa. Si este factor de peso es cercano a 0 no habrá relación entre las dos neuronas. Y si es negativo, la relación será inversa. Es una forma de ponderar la importancia de cada input en una neurona determinada. En el caso de las redes neuronales Feed Forward, cada neurona recibe un input por cada neurona de la capa anterior. En la Figura C1. 10, cada neurona de la capa oculta recibirá un input de la neurona de la variable Engine Speed y otro input de la variable BMEP. Cada una de esas dos conexiones tendrá un factor de peso diferente, y además, para cada neurona de la capa oculta esos factores de peso serán diferentes también. Por lo tanto, en cada neurona se realiza la suma ponderada de los inputs para lograr el número S_j (parte izquierda de la neurona en Figura C1. 11). La ecuación (7) muestra la expresión utilizada para esta suma en todas las neuronas.

$$s_j = \sum_{i=1}^n w_{ij}x_j + b_j \tag{7}$$

En esta ecuación, además de la suma ponderada de los inputs representada por el sumatorio de $w_{ij}x_j$, se añade un término independiente b_j llamado bias, que añade un grado de libertad a la función de s_j , incrementando la capacidad de regresión de una sola neurona y de toda la red. Una vez que se consigue s_j , para calcular el output de cada neurona se introducirá este número a una función conocida como función de transformación o de activación. En la literatura presente, existen muchas funciones de activación; en la Tabla C1. 5 se muestran las funciones de activación más utilizadas. Normalmente, todas las neuronas de cada capa utilizan la misma función de activación. Es decir, se utiliza una función de activación para las neuronas de la capa input, otra para las neuronas de la capa (o capas) oculta y otra para las neuronas de la capa output. De esta forma, el output calculado con la función de transformación introduciendo a esta s_j , será enviado como input a todas las neuronas de la capa siguiente. Los últimos outputs serán los de las neuronas de la capa output, que representarán los resultados calculados por la red neuronal artificial.

Tabla C1. 5 Funciones de activación más comunes

FUNCIÓN	ECUACIÓN	REPRESENTACIÓN
Sigmoides (logistic)	$f(x) = (1 + \exp(-x))^{-1}$	
Tangente hiperbólica (tanh)	$f(x) = (\exp(x) - \exp(-x))/(\exp(x) + \exp(-x))$	
Seno/Coseno	$f(x) = \sin(x); f(x) = \cos(x)$	
Lineal	$f(x) = x$	
Relu	$f(x) = \max(0, x)$	

Redes Neuronales Artificiales

Las redes neuronales artificiales (en nuestro caso las Feed Forward Artificial Neural Networks), se componen de la conexión de múltiples neuronas. En el presente caso de estudio, se utilizan redes neuronales de aprendizaje supervisado, es decir, en la fase de entrenamiento se introducen los valores de inputs y de sus respectivos outputs. De esta forma, la red toma los inputs, calcula los outputs y los compara con los valores reales de output. Una vez calculado el error entre la predicción de la red y el output real, se trata de minimizar ese error, y en ese contexto entran los algoritmos de entrenamiento u optimización de la red. Dependiendo del algoritmo escogido, la red se optimizará de una forma u otra, siempre con el objetivo de minimizar el error. A continuación, se explicará un algoritmo de entrenamiento llamado “Gradient Descent” de forma general, y después se mencionarán los diferentes algoritmos utilizados para el entrenamiento de las redes neuronales del presente estudio.

En el caso del Minsel430a, el modelo de redes neuronales contiene dos inputs (velocidad de giro y BMEP) y cuatro outputs (T_{exh} , BSFC, CO y NO_x). La base de datos obtenida en los ensayos experimentales contiene 140 registros (o situaciones diferentes del motor) de estas seis variables. En la fase de entrenamiento, se irán pasando estos registros al modelo, proporcionándole los valores de los inputs y los valores de los outputs también. La red calculará los outputs, y después se calculará el error entre los valores calculados y los outputs reales mediante la siguiente función de coste, representada en la ecuación (8).

$$C = \sum_{j=1}^M (a_j - y_j)^2 \quad (8)$$

a_j representa el valor calculado por el modelo para el output j , y_j es el valor real correspondiente al output calculado y M es el número de outputs de la capa output. A modo explicativo se expone el siguiente ejemplo: Al comienzo del entrenamiento se introduce el primer registro al modelo. Este registro contiene dos inputs y cuatro outputs. La red, calculará los cuatro inputs con los inputs proporcionados, y después se calculará C de la siguiente forma:

$$C = \sum_{j=1}^M (a_j - y_j)^2 =$$

$$= (T_{exhANN} - T_{exhREAL})^2 + (BSFC_{ANN} - BSFC_{REAL})^2 + (CO_{ANN} - CO_{REAL})^2 + (NO_{xANN} - NO_{xREAL})^2$$

Se suman los errores cuadráticos de los cuatro outputs calculados. De esta forma, se obtiene el coste o error conocido como “loss function” para el primer registro. El objetivo del descenso de gradiente es minimizar dicha función de coste. Para ello, tras pasar el primer registro se actualizan los factores de peso de entre las neuronas con el objetivo de minimizar la función de coste. Es decir, se van actualizando las relaciones entre neuronas, y por lo tanto las relaciones entre inputs y outputs del modelo, con el objetivo de minimizar la función C. A modo representativo, considérese la función de coste de la Figura C1. 12.

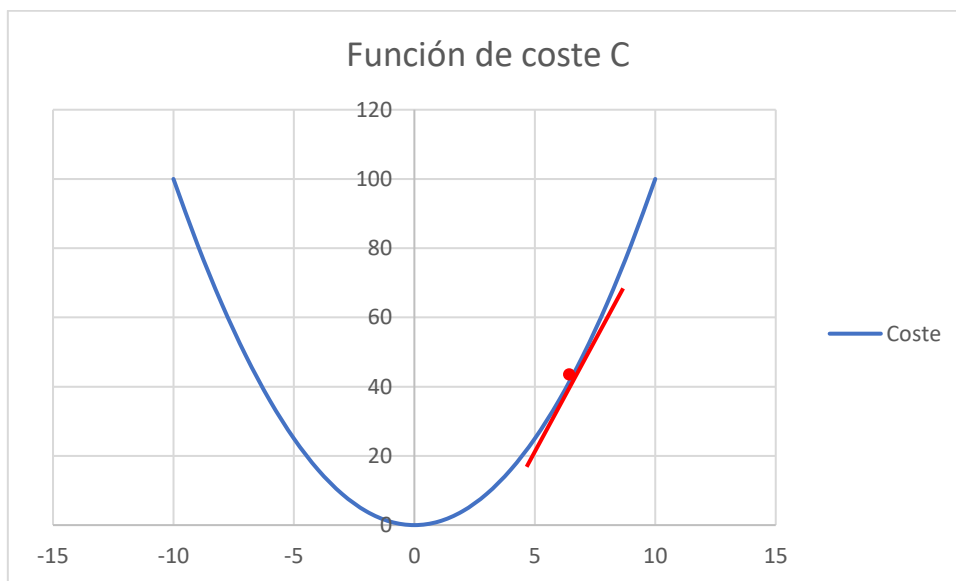


Figura C1. 12 Función de coste C

El objetivo del entrenamiento es ir actualizando los factores de peso de las conexiones entre las neuronas para lograr llegar al mínimo de C. Para ello, tras pasar un registro por la red, se calcula C y se actualizan las w_{ij} para dar un paso hacia abajo en la función de la Figura C1. 12. Esta actualización se realiza derivando la función C y dando un paso hacia debajo en la derivada. La ecuación 9 muestra la expresión utilizada para dicha actualización.

$$w_{ij}^{e+1} = w_{ij}^e - \alpha * \frac{dCoste}{dw_{ij}} \quad (9)$$

w_{ij}^{e+1} representa el valor actualizado de w_{ij}^e . $(-\alpha * \frac{dCoste}{dw_{ij}})$ representa el paso hacia el mínimo de la función de coste C. En concreto, el parámetro α se denomina “learning rate”, que en términos generales representa la dimensión del cambio de w_{ij}^e en cada actualización. Si α es demasiado pequeño, los pasos hacia el mínimo de C en cada actualización serán pequeños y el modelo tardará en encontrar el mínimo de C. Si α es demasiado elevado, puede que el modelo no converja al mínimo de C porque los pasos que da hacia el mínimo son demasiado grandes. Para ello, para cada factor de peso de toda la red neuronal, es necesario derivar la función de coste respecto al factor de peso que se quiera actualizar. En algunos casos (capa output) será una derivación simple, pero en otros esta derivación será más complicada. Por ejemplo, para actualizar el factor de peso resaltado en la Figura C1. 13, es necesario derivar la función de coste respecto a ese factor de peso.

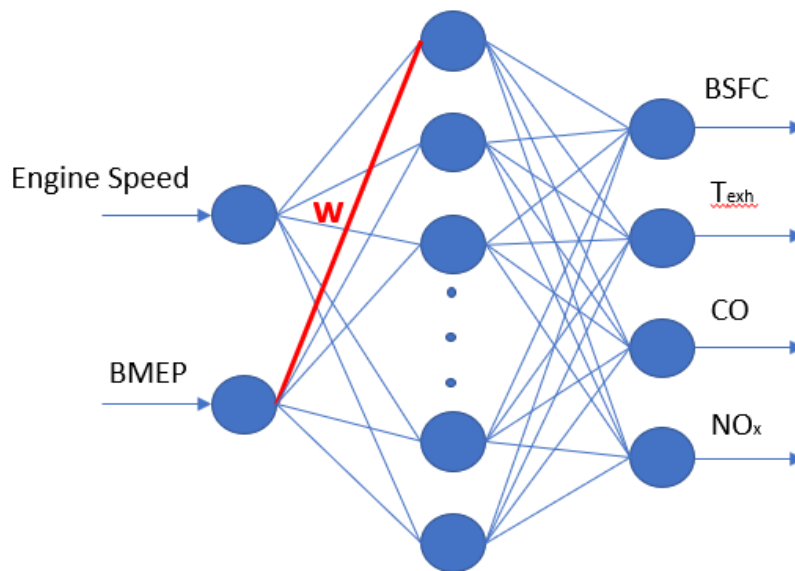


Figura C1. 13 Actualización de factores de peso

Por lo tanto, se deriva la función C de acuerdo a la siguiente expresión:

$$\mathbf{w}^{e+1} = \mathbf{w}^e - \alpha * \frac{dC}{d\mathbf{w}} \quad // \quad C = \sum_{j=1}^M (a_j - y_j)^2 \quad (10)$$

Por lo que habrá que lograr la función C en función de \mathbf{w} . Para ello, habrá que conseguir las expresiones de las a_j respecto a \mathbf{w} . En otras palabras, se deben representar BSFC, T_{exh} , CO y NO_x respecto a \mathbf{w} y después derivar C respecto a dicho \mathbf{w} . Para ello, esta representación de la función de coste respecto a cualquier factor de peso de la red, es decir, la representación de la función de error respecto a parámetros de anteriores capas de la red se conoce como la retro propagación o “backpropagation” en inglés. De esta forma, tras pasar todos los registros y realizar las actualizaciones correspondientes se finaliza una iteración o “epoch”. La fase de entrenamiento consiste en realizar tantas iteraciones como sea necesario para que el error de los outputs calculados sea el mínimo posible (para que C sea el mínimo posible). Por último, cabe mencionar que en la ecuación 7 se incluía un término independiente llamado bias. Este término se actualiza de forma análoga a los factores de peso.

En los últimos años, se han desarrollado varios métodos basados en el método del descenso de gradiente. Estos nuevos métodos incluyen pequeñas modificaciones en la ecuación de actualización de los factores de peso y los bias, modificando ligeramente la expresión vista en la ecuación (9). Por un lado existe el método del descenso de gradiente con momento [167]. Y es que, en realidad, la función de coste puede ser mucho más compleja que la mostrada en la Figura C1. 12. De hecho, puede tener varios mínimos locales en los que el método ordinario de descenso de gradiente podría estacionarse, no encontrando el mínimo total de la función de coste y no proveyendo los resultados más exactos en el cálculo de los outputs. Para solucionar esto, este método incluye un término que hace que a medida que se realicen actualizaciones de los factores de peso, el learning rate aumente (tome más inercia), siendo cada vez los pasos más grandes como puede verse en la ecuación (11).

$$w_{ij}^{e+1} = w_{ij}^e - \alpha * z^{e+1}$$

$$z^{e+1} = \beta * z^e + \frac{dCoste}{dw_{ij}} \quad (11)$$

De esta manera, en vez de realizar las actualizaciones con un learning rate constante, este irá aumentando a medida que aumente el término z^{e+1} por lo que los “pasos” hacia el mínimo de la función de coste serán cada vez más grandes evitando convergir en mínimos locales. Para regular el incremento del learning rate, este método incluye el parámetro β . Nótese que cuando $\beta = 0$ el método se convierte en el método del descenso de gradiente convencional.

Además de este, existen otros métodos basados en modificaciones del descenso de gradiente como Adagrad [168], que incluye una modificación del learning rate o RMSprop [169] que implementa un método similar al Adagrad pero basado en medias de anteriores épocas para adaptar el learning rate. A lo largo de los años, han ido desarrollándose diferentes algoritmos de optimización basados en el descenso de gradiente a fin de mejorar algunos problemas que se encontraban los métodos desarrollados anteriormente. En este marco, uno de los métodos más recientes es conocido con el nombre Adam [170]. Este método es una extensión del método RMSprop, que incluye a su vez un variable de momento para la actualización de los parámetros. Las expresiones para la actualización de factores de peso se muestran en la ecuación (12).

$$w^{e+1} = w^e - \frac{\alpha * z^{e+1}}{\sqrt{G^e + \epsilon}}$$

$$z^{e+1} = \beta_1 * z^e + (1 - \beta_1) * \frac{df}{dw^e} \quad (12)$$

$$G^e = \beta_2 * G^{e-1} + (1 - \beta_2) * \left(\frac{df}{dw^e}\right)^2$$

En este método se incluye por un lado el término z^{e+1} relacionado con el momento. Sin embargo, en este caso z^{e+1} no es un término que se va incrementando en cada actualización, sino que es una suma ponderada del z^e de la anterior época y del gradiente de la función de coste. Esta suma ponderada está regulada por el parámetro β_1 según el cual se regulará si darles más importancia a las actualizaciones anteriores (z^e) o al nuevo gradiente de la función de coste

$(\frac{df}{dw^e})$. Por otro lado, también se incluye el término G^e mediante el cual se regula el valor del learning rate o del paso que se da en la función de coste hacia el mínimo. Nótese que este parámetro también se actualiza mediante una suma ponderada del G^e en la anterior actualización y el gradiente de la función de coste respecto a cada factor de peso, lo que hace de este método una extensión del método RMSprop. Por último, ϵ es un valor muy pequeño (del orden de 10^{-8}) para evitar la división por 0 en la actualización de los factores de peso. Según Ruder et al. [171], tras realizar una revisión exhaustiva de los diferentes algoritmos de optimización basados en el descenso de gradiente, Adam podría ser la mejor opción, ya que combina métodos de otros algoritmos previamente desarrollados.

Estos algoritmos basados en el descenso del gradiente computan derivadas de primer orden de la función de coste. Sin embargo, existen otros métodos de orden superior, que consideran derivadas de mayor orden para hallar el mínimo de la función de coste. Entre ellos se encuentran el método de optimización de Newton o el de Gauss-Newton. Estos utilizan derivadas de segundo orden para hallar el mínimo de la función de coste, lo que hace estos unos algoritmos muy rápidos a la hora de buscar el mínimo de la función. No obstante, según Yu y Williamowski [172], estos algoritmos podrían presentar inestabilidades y no siempre convergir al mínimo de la función de coste. Por ello, el método de optimización de Levenberg-Marquardt [173, 174] es una combinación entre el método del descenso de gradiente y el método de orden superior de Gauss-Newton. Este método se basa en la aproximación de la matriz Hessiana a una representación mediante matrices jacobianas de acuerdo con la ecuación (13). Para la actualización de parámetros, este método computa las matrices jacobianas que contienen las derivadas de los errores de la red respecto a todos los factores de peso y términos bias de la misma. La expresión utilizada para la actualización de dichos parámetros se muestra en la ecuación (13).

$$H \approx J_k^T J_k + \mu I$$

(13)

$$w^{k+1} = w^k - (J_k^T J_k + \mu I)^{-1} J_k e_k$$

J_k y J_k^T representan la matriz jacobiana y la transpuesta de dicha matriz respectivamente. Para entender esta matriz, primero se calcula cuantas conexiones existen en la red neuronal; de esta forma se calculará el número de factores de peso que habrá que actualizar en cada actualización. En el caso de la red neuronal del Minsel430a el número de conexiones entre las neuronas se

calcula multiplicando el número de neuronas entre capas sumando estos múltiplos y se conocerá como N. En el caso del Minsel430a, en la capa oculta la red contiene 17 neuronas. Este número ha sido seleccionado mediante una metodología que se explicará en el siguiente apartado de marco práctico.

$$N_{conexiones} = N_{input}N_{oculta} + N_{oculta}N_{output}$$

$$N_{conexiones} = 2 * 17 + 17 * 4 = 102 \quad (14)$$

Por lo tanto, en el caso del Minsel430a el método de Levenberg-Marquardt actualizará 102 factores de peso. Además, se tienen 140 registros diferentes en la base de datos (supongamos que todos los registros serán utilizados en el entrenamiento de la red). En el caso de este método de optimización, los factores de peso se actualizarán una vez pasados todos los registros por ella, por lo que la función de coste esta vez se calculará de acuerdo con la ecuación (15).

$$E = \frac{1}{2} \sum_{i=1}^P \sum_{j=1}^M (a_{i,j} - y_{i,j})^2 \quad (15)$$

En este caso, el error total es la suma de los errores realizados en todos los registros en las predicciones de cada neurona, a diferencia de la función de coste C de la ecuación (8) que considera la suma de los errores de cada neurona de un único registro. El término $(a_{i,j} - y_{i,j})^2$ que corresponde al error realizado en cada neurona output j en cada registro i se representa con el término de error $e_{i,j}$. Por lo tanto, el método Levenberg-Marquardt asigna una matriz jacobiana a cada registro, derivando todos los errores $e_{i,j}$ respecto a todos los factores de peso de acuerdo con la ecuación (16).

$$j = \begin{bmatrix} \frac{\delta e_{1,1}}{\delta w_1} & \dots & \frac{\delta e_{1,M}}{\delta w_1} \\ \vdots & \ddots & \vdots \\ \frac{\delta e_{1,1}}{\delta w_N} & \dots & \frac{\delta e_{1,M}}{\delta w_N} \end{bmatrix} \quad (16)$$

Esta matriz jacobiana construida para el primer registro de la base de datos tiene N filas (tantas filas como factores de peso a actualizar) y M columnas, en el caso del Minsel430a su dimensión es 102x4. La matriz jacobiana de todos los registros de la base de datos (nótese que se incluyen todos los registros de la base de datos en cada actualización) se construye concatenando las

matrices transpuestas de las matrices jacobianas \mathbf{j} de cada registro. Por lo tanto, \mathbf{J}_k se muestra de la siguiente forma:

$$\mathbf{J}_k = \begin{bmatrix} \frac{\delta e_{1,1}}{\delta w_1} & \dots & \frac{\delta e_{1,1}}{\delta w_N} \\ \vdots & \ddots & \vdots \\ \frac{\delta e_{1,M}}{\delta w_1} & \dots & \frac{\delta e_{1,M}}{\delta w_N} \\ \vdots & & \vdots \\ \frac{\delta e_{P,1}}{\delta w_1} & \dots & \frac{\delta e_{P,1}}{\delta w_N} \\ \vdots & \ddots & \vdots \\ \frac{\delta e_{P,M}}{\delta w_1} & \dots & \frac{\delta e_{P,M}}{\delta w_N} \end{bmatrix} \quad (17)$$

Esta matriz tiene $M \times N = 4 \text{ outputs} \times 102 \text{ registros} = 408$ filas y $N = 102$ columnas. En cuanto al vector de errores \mathbf{e}_k de la ecuación (13), este se obtiene concatenando los errores de los diferentes outputs a lo largo de los diferentes registros. Es decir, en el caso del Minsel430a, primero se posicionan los cuatro errores realizados para los cuatro outputs del primer registro. Segundo se introducirán los cuatro errores del Segundo registro, y así sucesivamente hasta el registro P, resultando en la siguiente expresión.

$$\mathbf{e}_k = \begin{bmatrix} e_{1,1} \\ \vdots \\ e_{1,M} \\ \vdots \\ e_{P,1} \\ \vdots \\ e_{P,M} \end{bmatrix} \quad (18)$$

Por último, el término μ es conocido como el “damping factor”. En caso de que después de la actualización el error total E no haya descendido, la nueva actualización se descartará, y μ se aumentará, ya que no se está convergiendo al mínimo de E. En caso de que E haya decrecido con la nueva actualización de los parámetros de la red, μ se disminuirá ya que se considera que se está convergiendo hacia el mínimo de E.

2.3.2 Marco experimental

En el presente estudio, se han utilizado dos de los algoritmos más rápidos y eficaces para el entrenamiento del modelo de la red neuronal artificial del motor Minsel430a. El primero es el algoritmo llamado Adam, que proviene de la combinación de otros algoritmos basados en el descenso de gradiente y aúna sus ventajas. El segundo algoritmo proviene de los métodos de optimización de orden superior que incluyen derivadas de segundo orden. Esta comparativa se ha realizado no solo para conseguir el algoritmo más eficaz para este motor de un cilindro, sino también para entender cuál puede ser el mejor algoritmo en futuros estudios de modelado de motores diésel marinos. Previamente, se ha llevado a cabo una revisión bibliográfica para ver qué algoritmo se utiliza en el campo de estudio de modelado de motores diésel mediante redes neuronales. De acuerdo con la Tabla C1. 6, se observa que la mayoría de los estudios utilizan el método de Levenberg-Marquardt para entrenar sus modelos. Las razones de ser el método más utilizado son su rapidez y su capacidad de lograr niveles de exactitud más altos que otros algoritmos. Por ejemplo, Rezaei et al. [175] compararon 12 algoritmos de optimización diferentes, concluyendo que LM era el método más eficaz para las Feed Forward Neural Networks. Por otro lado, Shailaja et al. [124] observaron que el método LM necesitaba notablemente menos tiempo que el método de descenso de gradiente para ser entrenado (0,663 segundos con LM vs 498 segundos con descenso de gradiente). Javed et al. [134] Compararon 7 algoritmos de optimización diferentes con 5 funciones de transferencia distintas para predecir parámetros de funcionamiento y emisiones en un motor dual. Entre otros resultados, advirtieron que el algoritmo de LM junto con las funciones sigmoide logarítmica y tangente sigmoide hiperbólica ofrecían los mejores resultados.

Tabla C1. 6 Estructuras de ANN, algoritmos de optimización y funciones de transferencia

Referencia	Estructura ANN	Algor. entrenamiento	Funciones de transf.
[36]	6 – 49 – 15	Backpropagation	Sigmoide
[130]	1 – 8 – 1	Regularización Bayesiana	Capa oculta: Tangente hiperbólica Capa output: Lineal
[135]	5 – (5-7) * - 1 *Depende de la variable calculada	Levenberg - Marquardt & Scaled Conjugate Gradient	Sigmoide logística
[131]	4 – 22 – 4	Levenberg – Marquardt	Tangente-sigmoide
[176]	2 – (8-15) – 3	Levenberg – Marquardt	Utiliza varias: $f(x) = \exp(-x^2)$ $f(x) = 1 - \exp(-x^2)$
[133]	3 – 22 – 6	Levenberg – Marquardt	Logística sigmoide Lineal
[116]	3 – 7 – 2	Levenberg - Marquardt	Logística sigmoide
[177]	2 – 22 – 9 (Dos capas ocultas)	Levenberg - Marquardt	TanhAxon
[136]	4 – 10 – 10 – 5	Levenberg - Marquardt	Logística sigmoide
[124]	4 – 17 – 3	Levenberg-Marquardt	Capa oculta: Tan - Sig Capa output: Lineal
[132]	3 – 8 – 8 – 5	Levenberg - Marquardt	Logística- sigmoide
[125]	6 – 18 – 3	Levenberg – Marquardt	Logística - sigmoide (No específicamente dicho)
[114]	6 – 18 – 3x1	Levenberg - Marquardt	Capa oculta: Tan - Sig Capa output: Log - Sig
[120]	2 – 25 – 4	Levenberg – Marquardt	Capa oculta: Log - Sig Capa output: Lineal

Para definir completamente la red, además de concretar los parámetros a introducir en las capas input y output, es necesario definir el número de neuronas a utilizar en la capa oculta. En el presente estudio, este número se ha definido mediante el estudio del error de predicción de la red en la fase de entrenamiento. Además, este estudio se ha utilizado para observar cuál de los dos algoritmos de optimización planteados (Adam y LM) presenta mejores resultados. Este tipo de análisis del error de predicción se ha utilizado en diversos estudios de modelado de motores mediante redes neuronales para definir parámetros de la red como el número de neuronas en la capa oculta [131] o el learning rate [178]. En la literatura existente, el mínimo de neuronas utilizadas para la capa oculta que se encuentra en términos generales está en torno a 7-8 [135]. Por lo tanto, para el caso de estudio del motor Minsel430a, el número mínimo de neuronas considerado para la capa oculta será 7. Para el estudio del error en la fase del entrenamiento, se han utilizado dos parámetros: i) Error cuadrático medio (MSE) calculado con la ecuación (19); ii) R^2 calculado a partir del coeficiente de regresión entre parámetros calculados y reales mediante la ecuación (20). Manteniendo la nomenclatura del apartado de marco teórico, a representa los valores calculados por el modelo, e y sus valores reales correspondientes (targets). En la Tabla C1. 7 se muestran los valores de R^2 y error cuadrático medio (MSE) presentados por cada número de neuronas utilizado con cada algoritmo de entrenamiento.

$$MSE = \frac{1}{n} \sum_{i=1}^n (a_i - y_i)^2 \quad (19)$$

$$R = \frac{(a - \bar{a})(y - \bar{y})^T}{\sqrt{(a - \bar{a})(a - \bar{a})^T} \sqrt{(y - \bar{y})(y - \bar{y})^T}} \quad (20)$$

Tabla C1. 7 Valores de error de predicción para diferentes números de neuronas y algoritmos de entrenamiento

Nº Neuronas	ADAM		Levenberg-Marquardt	
	R ²	MSE	R ²	MSE
7	0,9515	0,0048	0,99864	0,000291
8	0,9539	0,0045	0,9988	0,000256
9	0,9466	0,0053	0,9989	0,00024
10	0,9462	0,0053	0,9988	0,000253
11	0,952	0,0047	0,9991	0,000196
12	0,9477	0,0052	0,999	0,00022
13	0,9463	0,0053	0,9992	0,000178
14	0,9462	0,0053	0,9991	0,000185
15	0,9458	0,0054	0,9991	0,0002
16	0,9459	0,0054	0,9992	0,000162
17	0,9467	0,0053	0,9993	0,000158
18	0,9616	0,0037	0,9991	0,000192
19	0,959	0,004	0,9992	0,000163
20	0,9575	0,0041	0,9992	0,00017
21	0,9605	0,0038	0,9992	0,000164
22	0,9531	0,0046	0,9992	0,000162

Para el presente caso de estudio, el número de neuronas que muestra mayores valores de R² y menores valores de MSE es 17, junto con el algoritmo de optimización de LM. Es por ello que estas son la configuración y el algoritmo de optimización utilizadas en este análisis. Además, de la Tabla C1. 7 se concluye que el algoritmo de Levenberg-Marquardt muestra mayores valores de R² y menores valores de MSE que el algoritmo Adam para cualquier número de neuronas en la capa oculta, induciendo una mayor efectividad del algoritmo de LM para el entrenamiento del modelo. Además, LM ha necesitado 6,8 segundos para finalizar la fase de entrenamiento, mientras que Adam ha necesitado 11,3 segundos. La CPU utilizada para los cálculos es un Intel Core i5-8250U, con velocidades de hasta 3,40 GHz, 4 núcleos, 8 hilos y 8 GB de RAM. De la Tabla C1. 6, además de observar que el algoritmo más utilizado es LM, se concluye que el número de neuronas seleccionado en el presente estudio está en el rango de otros estudios con dimensiones de inputs y outputs similares [120, 176]. Las funciones de transferencia utilizadas para la capa oculta y la capa output han sido tangente-sigmoide-hiperbólica y función lineal

respectivamente. Por lo tanto, para el entrenamiento del presente modelo se han utilizado 120 registros y la red neuronal artificial se ha entrenado utilizando el algoritmo Levenberg-Marquardt en Matlab. Los 20 registros restantes se han reservado para testear la red manualmente y analizar el nivel de exactitud presentado por el modelo y compararlo con los resultados del modelo termodinámico. El objetivo de mejora del entrenamiento se ha establecido en 10^{-5} . Mientras que la diferencia de error de una iteración a la siguiente no sea menor que ese objetivo, seguirán realizándose iteraciones hasta un máximo de iteraciones de 400.

3- Resultados

Tanto el modelo termodinámico como el modelo de redes neuronales se han ajustado al motor Minsel430a para simular su funcionamiento con el mínimo error de predicción. Por un lado, el modelo termodinámico se ha ajustado introduciendo todas las características físicas del motor, desde las medidas geométricas de los distintos elementos hasta la curva de apertura de las válvulas. Después, se ha escogido el modelo de combustión de acuerdo con los utilizados en la literatura existente y para representar las curvas de presión de combustión reales con el máximo nivel de exactitud. Por otro lado, el modelo de redes neuronales se ha entrenado utilizando dos algoritmos de entrenamiento diferentes: Adam y Levenberg-Marquardt. En este caso de estudio se ha constatado el potencial del algoritmo de optimización Levenberg-Marquardt que ha necesitado menos tiempo que el algoritmo Adam para ser entrenado y ha presentado mejores resultados. Esto coincide con el hecho de que en la mayoría de los trabajos de investigación revisados LM sea el algoritmo más frecuente ya que proporciona una solución rápida y eficaz para el entrenamiento de las redes neuronales artificiales. Por lo tanto, en la presente sección se expondrá primero el nivel de ajuste logrado en cada modelo. Después, se mostrarán los resultados obtenidos para los 20 registros de la base de datos que se reservaron para el testeo de ambos modelos.

3.1 Ajuste de los modelos

3.1.1 Modelo termodinámico

Tras un primer ajuste mediante la introducción de características físicas y submodelos de combustión y transferencia de calor del modelo termodinámico, la última fase del ajuste del modelo y la validación de su ajuste se han realizado comparando las curvas de presión de combustión reales y las simuladas por el modelo para puntos de operación diferentes del motor. En este caso, para cada una de las 7 posiciones en las que se ha puesto el freno durante los ensayos experimentales, se ha calculado la curva media de presión de combustión para después observar las curvas calculadas por el modelo para dichas 7 situaciones.

Para ello, primero se han comparado las curvas de presión de compresión. Estas curvas representan la presión que alcanzarían los gases del interior de la cámara si no se diera la combustión en ella. Esta curva depende de factores como el blow-by o la relación de compresión del motor. Por otro lado, la curva simulada contiene un offset en el eje horizontal a tener en cuenta. Es decir, la curva de presión de combustión no siempre alcanza su máximo en el punto muerto superior del cilindro. Es por ello que a este parámetro o desplazamiento horizontal de la curva se le conoce como el offset del punto muerto superior. La estimación de este parámetro ha sido objeto de estudio de numerosos trabajos de investigación [179-181]. En el presente estudio, el software utilizado en los ensayos experimentales (Dewesoft7) ya tiene implementado un mecanismo de detección de offset de punto muerto superior. Para ello, se activa esta opción y se mueve manualmente el cigüeñal para que el programa recoja la curva de compresión y calcule el offset del punto muerto superior. En caso de motores de varios cilindros, se extrae el inyector del cilindro en el que está introducido el sensor de presión y se arranca el motor para calcular dicho offset. Al mismo tiempo, el programa AVL Boost™ calcula sus curvas de presión de combustión con un offset, sin embargo, es necesario hacer coincidir este offset con el de las curvas de combustión reales. En la Figura C1. 14 se muestra el efecto del offset el punto muerto superior en el posicionamiento de la curva de presión de combustión respecto al ángulo del cigüeñal.

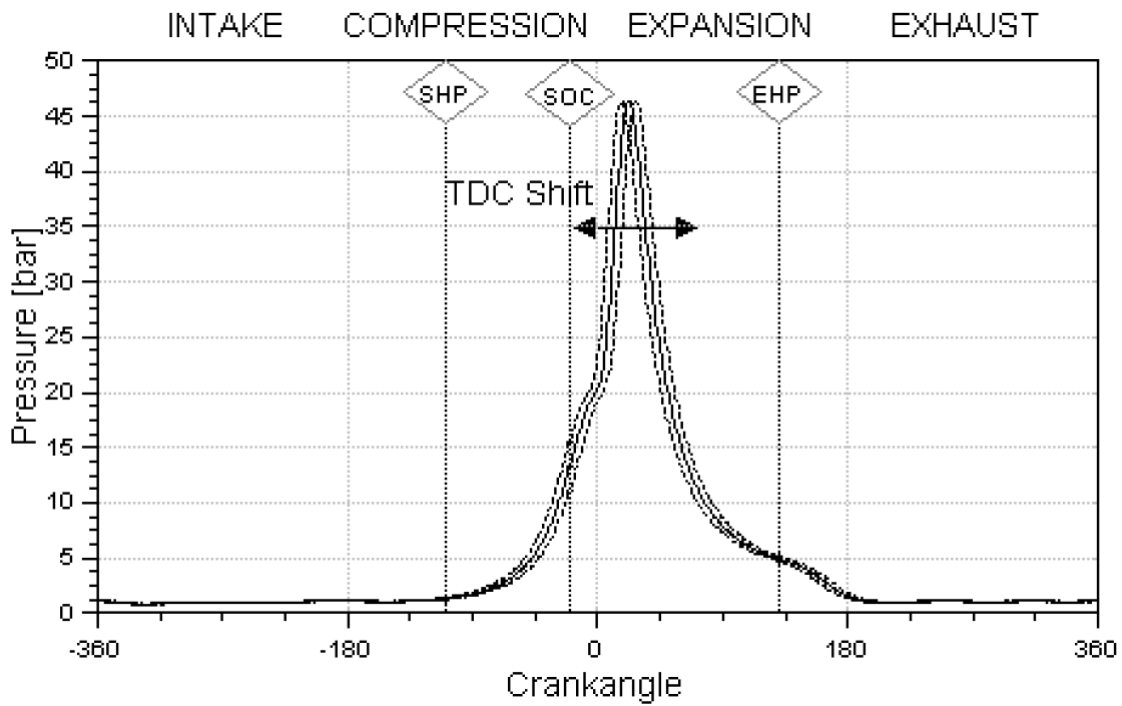


Figura C1. 14 Efecto del offset del punto muerto superior

Para realizar dicho ajuste, se han comparado las curvas de compresión modeladas y reales haciendo coincidir ambas para que el offset del punto muerto superior del modelo sea el mismo que el de las curvas reales. En la Figura C1. 15 se muestran las curvas de presión de combustión de 3 situaciones de carga diferentes del motor: 15%, 50% y 100%. Hasta la fase de la combustión se observa un nivel de ajuste muy alto, concluyendo una correcta aproximación del offset del punto muerto superior.

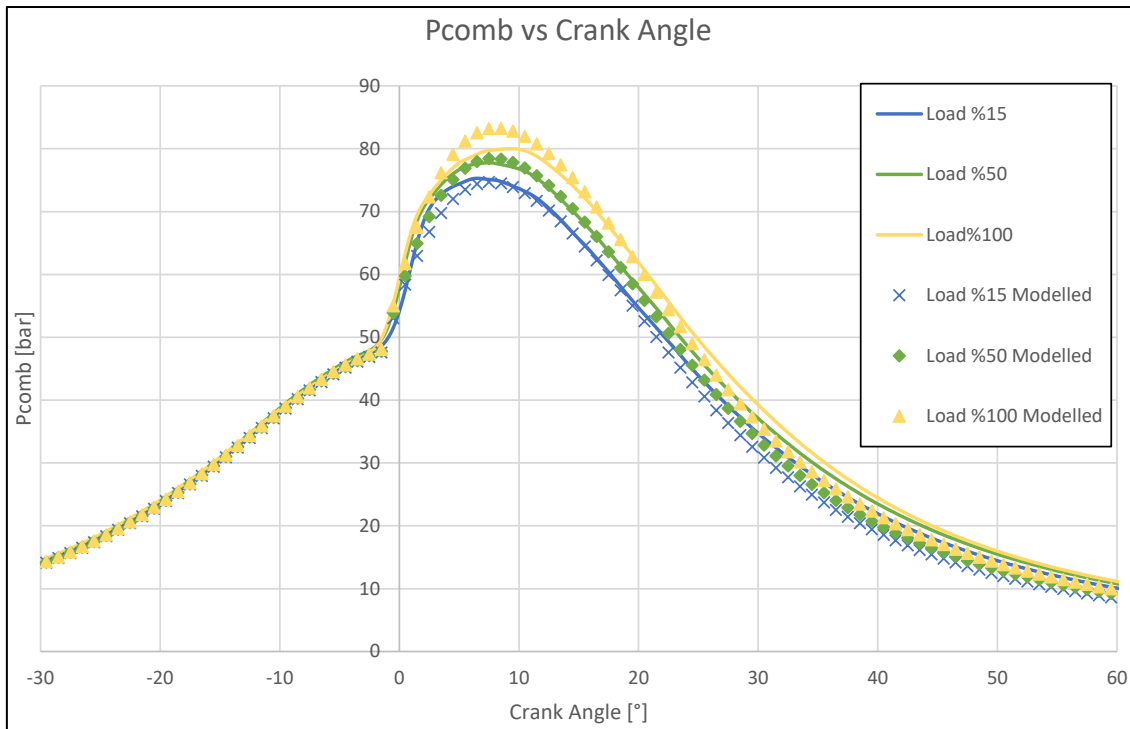


Figura C1. 15 Curvas de presión de combustión

Tras ajustar las curvas de presión de compresión, para adecuar las curvas calculadas por el modelo a las curvas reales en la fase de alta presión, se han modificado parámetros de la combustión. De la Figura C1. 15, tras el comienzo de la combustión se percibe un cambio en el nivel de exactitud de las curvas modeladas. La curva de baja carga (%15) parece estar mejor ajustada que las curvas de cargas superiores. De hecho, se aprecia una sobreestimación de la presión máxima de combustión a cargas altas, mientras que a cargas bajas el máximo de la curva de presión de combustión parece estar subestimado. Sin embargo, estas diferencias son relativamente pequeñas por lo que el alto nivel de ajuste del modelo queda validado. Algunos estudios en torno al modelado de motores también han utilizado metodologías análogas basadas en la comparación de curvas de presión de combustión simuladas y reales para validar sus modelos [86, 98]. Cabe mencionar que en este caso de estudio se requiere a un único modelo calcular curvas de presión de combustión (así como otros parámetros) a lo largo de todo el espectro de carga del motor. Esto supone una dificultad añadida porque no sólo se requiere un alto nivel de exactitud de cálculo en una carga, sino que se le requiere al modelo la comprensión de la evolución del funcionamiento del motor junto con el cambio de carga de este. El nivel de exactitud del ajuste se verá reflejado después en los resultados presentados más adelante para parámetros de funcionamiento y emisiones calculados por el modelo, y será discutido en la siguiente sección.

3.1.2 Modelo de redes neuronales artificiales

La calidad del ajuste del modelo de redes neuronales artificiales ha sido medida mediante el estudio del error en las predicciones del modelo en la fase de entrenamiento. Primero, se ha escogido el número de neuronas óptimo para la capa oculta de la red observando los parámetros R^2 y MSE de la red durante el entrenamiento. Este análisis ha servido también para determinar qué algoritmo de entrenamiento presenta un ajuste más fino del modelo. La fase de entrenamiento de la red se ha llevado a cabo con 120 de los 140 registros que se obtuvieron en las pruebas experimentales; los 20 registros restantes se han reservado para llevar a cabo el testeo de la red y comparar sus resultados con los resultados obtenidos del modelo termodinámico. La Figura C1. 16 muestra las regresiones obtenidas para el cálculo de los outputs calculados en el presente estudio: BSFC, T_{exh} , CO y NO_x .

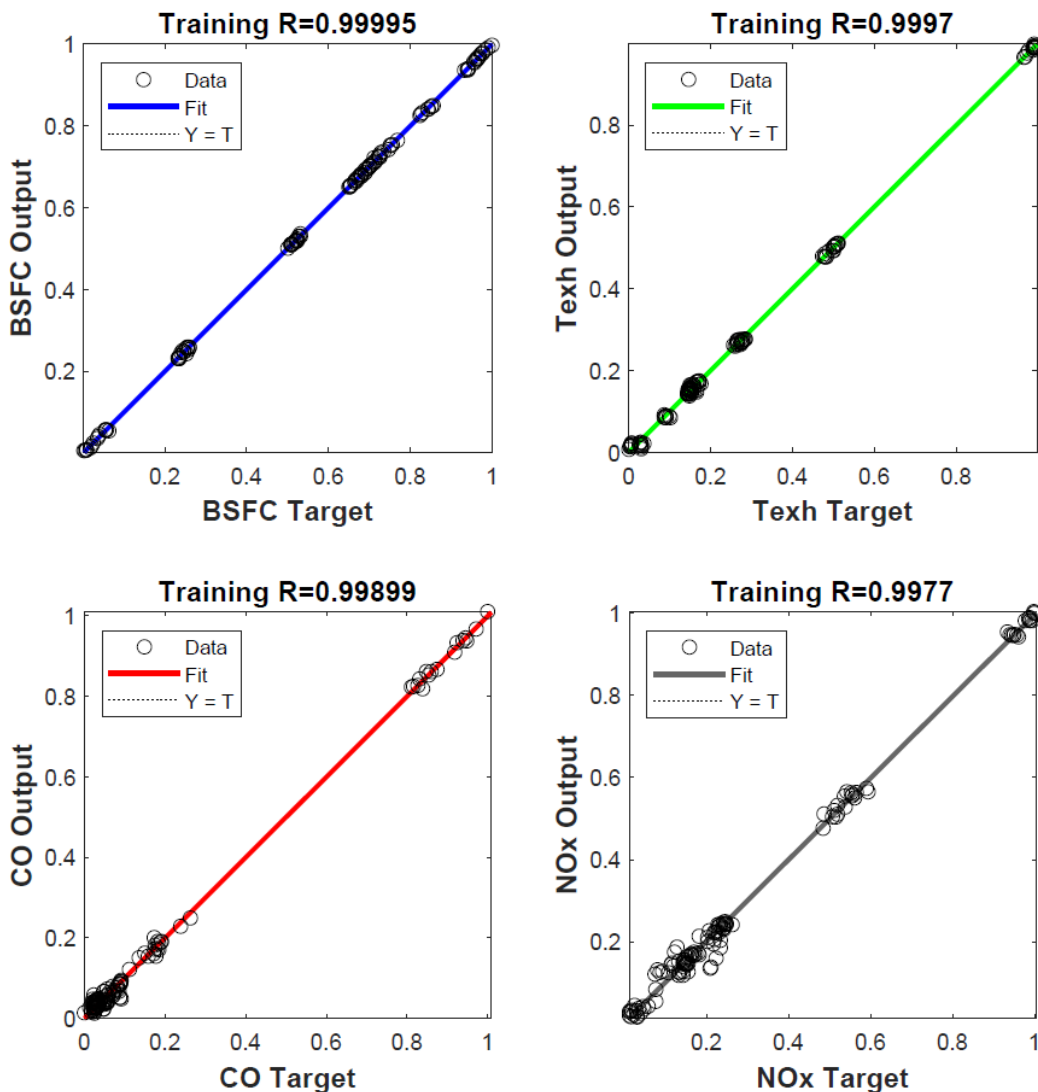


Figura C1. 16 Regresiones de cálculos de entrenamiento para BSFC, Texh, CO y NO_x

Estas regresiones representan la relación entre los outputs calculados de la red y los outputs reales que les corresponden al final de la fase de entrenamiento. Es decir, representa la relación entre a_j y y_j para los 120 registros utilizados en la fase de entrenamiento después de la última actualización de la fase de entrenamiento. Si la red calculara perfectamente los 120 outputs devolviendo los valores reales que les corresponden, el valor de R sería 1. En este caso, puesto que los valores de R son muy próximos a 1, se concluye que los valores calculados por el modelo son muy cercanos a los valores reales que les corresponden (valores medidos en el motor), como se puede observar en la Figura C1. 16. Por ello, se prevé que la red neuronal está lista para la fase de testeo.

3.2 Predicciones de los modelos

En este trabajo de modelado del motor Minsel430a, se han entrenado y ajustado dos modelos con estrategias de modelado completamente diferentes: modelo termodinámico y modelo de redes neuronales artificiales. Cada modelo se ha ajustado de forma independiente para después introducir en ambos la velocidad de giro y el BMEP del motor y que ambos modelos calculen el consumo específico, las temperaturas de gases de escape y las emisiones de CO y de NO_x de este. Este cálculo de testeo se ha llevado a cabo con 20 registros de la base de datos que se han reservado para esta tarea y que han sido aleatoriamente escogidos con la intención de ofrecer una comparativa no sesgada entre ambas estrategias de modelado. El tiempo de cálculo es primordial a la hora de estudiar metodologías aplicables a procesos en tiempo real, por lo que se ha medido el tiempo de cálculo de ambos modelos para predecir dichos cuatro parámetros en las 20 situaciones diferentes de testeo. En este aspecto, el modelo termodinámico ha necesitado 1.234,29 segundos, mientras que el modelo de redes neuronales ha necesitado 0,52 segundos. Sus implicaciones y posibles ventajas/desventajas frente a procesos de modelado en tiempo real serán analizadas en la sección de discusión.

Pese a que en los anteriores apartados se ha observado un nivel de ajuste relativamente alto de ambos modelos, en la Figura C1. 17 se muestran los resultados de ambos modelos para las 20 situaciones diferentes de testeo, con ánimo de proveer un análisis más profundo del nivel de exactitud de ambos. Junto con las predicciones de los modelos, también se muestran sus respectivos valores reales medidos en el motor. Ambos parámetros calculados y los medidos en el motor se han representado respecto a la potencia del motor. Por otro lado, en la Figura C1. 18 se muestra la evolución del error medio porcentual (MAPE) que representa el error relativo medio realizado en N observaciones. Su expresión se muestra en la ecuación (21).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - a_i}{y_i} \right| * 100 \quad (21)$$

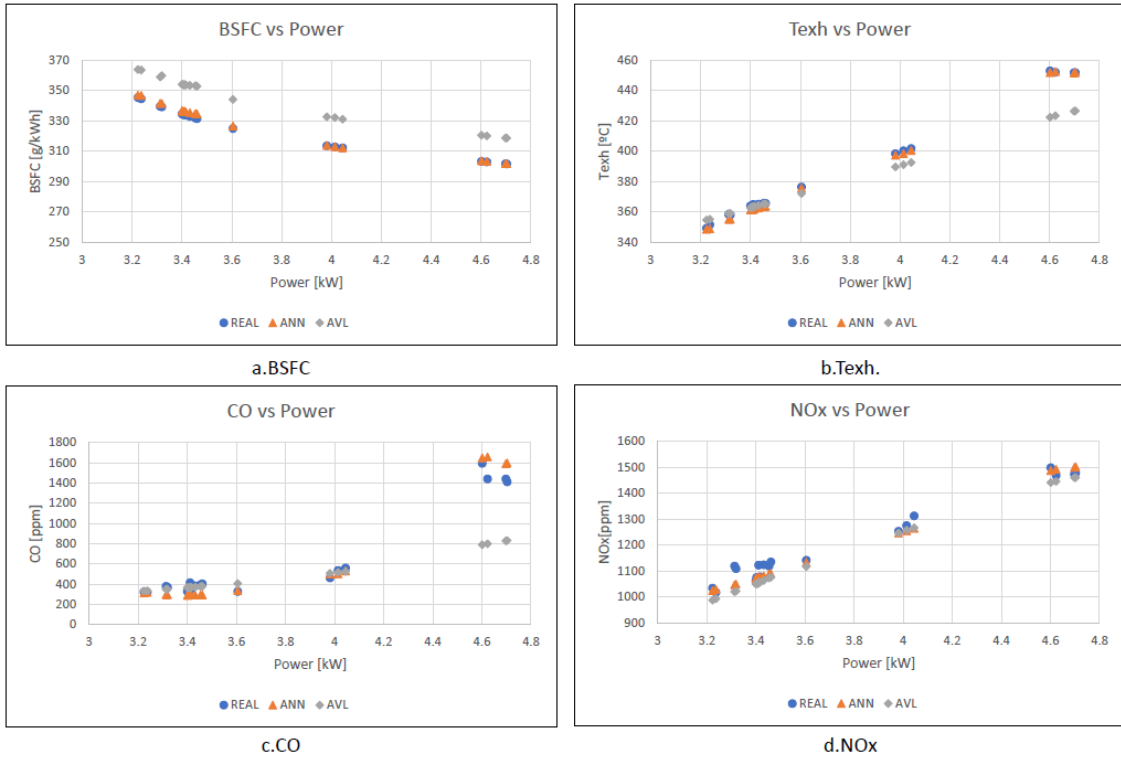


Figura C1. 17 Resultados de modelos termodinámico, redes neuronales y valores experimentales

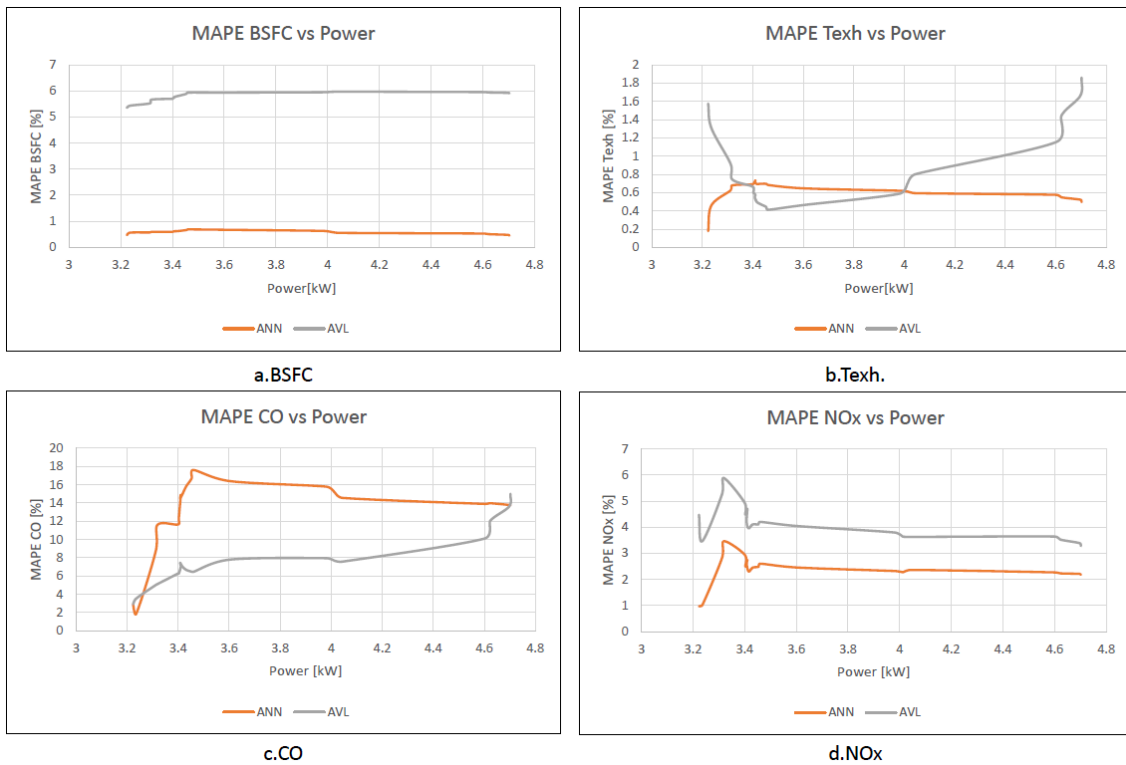


Figura C1. 18 Evolución de MAPE respecto a la potencia del motor

En la Figura C1. 17a se aprecia que el modelo termodinámico de AVL predice mayores valores de BSFC que los valores reales para todo el rango de potencia del motor. El error se mantiene constante a lo largo de las diferentes potencias. Por ello, parece que el modelo termodinámico ha creado una relación correcta entre el consumo específico y la potencia del motor, pero no ha determinado bien el término independiente de dicha ecuación. Por otro lado, las redes neuronales artificiales además de seguir estrechamente la tendencia del consumo específico respecto a la potencia del motor muestran valores muy próximos en todas las predicciones de este parámetro. Los valores finales de MAPE alcanzados para las predicciones de BSFC son 0,46% y 5,91% para ANN y AVL respectivamente. La Figura C1. 18a muestra la evolución del valor de MAPE respecto a la potencia. En este aspecto, los valores de MAPE alcanzados por AVL (modelo termodinámico) son notablemente mayores que los alcanzados por las redes neuronales artificiales para todo el rango de potencia.

En lo que respecta a la temperatura de gases de escape (T_{exh}), el nivel de exactitud de las predicciones de ambos modelos cambia con respecto a la potencia del motor. De hecho, en el rango de potencia correspondiente a cargas medias-bajas, el modelo de AVL provee mejores resultados que las ANN. Fuera de este rango, tanto en las potencias más bajas como a partir de cargas medias-altas las redes neuronales ofrecen resultados más exactos (Figura C1. 18b). De hecho, en la Figura C1. 17b se observa que a partir de cargas superiores a 4,5 kW los resultados calculados por AVL divergen considerablemente de los valores reales. Los valores totales de MAPE logrados para T_{exh} son 0,50% y 1,86% para ANN y AVL respectivamente, resultando ser de media los valores de MAPE más bajos de todos los parámetros calculados en el presente estudio.

En cuanto a las emisiones de CO, los cálculos de CO del modelo termodinámico son más exactos que los cálculos de ANN para cargas muy bajas (Figura C1. 18c). A medida que se aumenta la carga, el error de predicción de las redes neuronales decrece mientras que el del modelo termodinámico se incrementa hasta el punto en el que el error del modelo termodinámico supera al error de las redes neuronales artificiales. Esto ocurre en las cargas más altas del motor, en las que si se observa la Figura C1. 17c se puede ver que el modelo termodinámico subestima notablemente los valores de CO. Es más, las emisiones de CO padecen un incremento brusco en altas cargas del motor que es representado correctamente por las redes neuronales artificiales, pero que sin embargo no se ve reflejado en el modelo termodinámico. Los valores totales de MAPE para las predicciones de redes neuronales y modelo termodinámico son 13,75% y 14,99% respectivamente.

Por último, las emisiones de NO_x presentan mayores niveles de exactitud en el modelo de redes neuronales artificiales en el espectro completo de carga del motor (Figura C1. 17d y Figura C1. 18d). Los valores totales de MAPE alcanzados para los cálculos de NO_x son 2,18% y 3,28% respectivamente para las predicciones de redes neuronales artificiales y modelo termodinámico respectivamente. Curiosamente, los valores de carga más altos no afectan al error de cálculo del modelo termodinámico como ocurre con las emisiones de CO. De hecho, la diferencia de error entre el modelo termodinámico y el modelo de redes neuronales artificiales es prácticamente constante con respecto a la carga del motor, induciendo una mejor capacidad de predicción para el caso de las redes neuronales artificiales.

4- Discusión

En este trabajo de investigación se ha simulado un motor de un cilindro mediante dos de las metodologías de modelado más utilizadas en la presente literatura: el modelo termodinámico y el modelo de redes neuronales artificiales. Se ha analizado la adaptabilidad de cada metodología para calcular múltiples parámetros de funcionamiento y emisiones del motor a lo largo de su rango completo de funcionamiento en cuanto a carga del motor. El objetivo del presente estudio era analizar las ventajas/desventajas propuestas por cada estrategia de modelado, mediante un caso de estudio basado en datos experimentales de un motor diésel real. De acuerdo con los valores de error vistos en la sección 3.2, ambos modelos han demostrado un gran potencial para simular un motor diésel de un cilindro operando en varias condiciones de funcionamiento diferentes. Sin embargo, tras una inspección más rigurosa de los resultados obtenidos, se concluye que cada modelo ha mostrado mejores/peores resultados dependiendo del parámetro calculado y la carga a la que se encuentra el motor. Hasta el momento, algunos trabajos de investigación se han centrado en puntos específicos de operación del motor [90, 126]. Otros [123] han cubierto espectros de funcionamiento más amplios, pero diseñando una red neuronal artificial por cada output seleccionado para su modelo, lo que debería inducir un mayor nivel de exactitud, pero también un notable incremento del coste computacional y menor robustez ya que cada red es solamente específica de un output, no representando múltiples variables del motor con objeto de conseguir una imagen de su estado. En este estudio, además de analizar el tiempo y el nivel de exactitud de cada metodología de modelado, se ha propuesto simular un motor diésel de un cilindro en el total de su rango de funcionamiento, para ver el potencial de ambas estrategias para procesos de mantenimiento basado en condiciones en tiempo real.

Respecto al cálculo de BSFC, las redes neuronales artificiales han demostrado tener un mayor nivel de exactitud en todo el rango de potencia del motor. Esto en parte puede haber sido causado por el relativamente alto nivel de regresión mostrado por la red neuronal en la fase de entrenamiento (Figura C1. 16). Por otro lado, el modelo de AVL muestra una mayor desviación respecto a los valores reales, manteniendo una desviación constante a lo largo de diferentes potencias del motor. Esto lleva a la conclusión de que el modelo termodinámico ha podido crear una relación que represente adecuadamente la evolución de BSFC respecto a la potencia (Figura C1. 17a) pero que el término independiente de esta relación esté mal calculado. Pese a que los cálculos de BSFC estén ligeramente desviados de los valores reales, ambos modelos han presentado valores totales de MAPE relativamente reducidos (ANN 0,45% y AVL 5,91%). Roy et al. [136] incluyeron BSFC entre los parámetros calculados por su red neuronal artificial,

basándose en un estudio previo de correlación que mostró una correlación fuerte entre la carga del motor y el BSFC. Esta podría ser una de las razones por las que el BSFC predicho por las redes neuronales artificiales haya alcanzado el MAPE total más bajo de todos los parámetros del presente estudio. Noor et al. [133] alcanzaron valores de MAPE de 4,45% y 28,35% respectivamente para los modelos de redes neuronales y matemático respectivamente en el cálculo de BSFC. Javed et al. [134] obtuvieron valores MAPE de 4,86% para diferentes parámetros de funcionamiento y emisiones entre los cuales se incluía BSFC, utilizando una red neuronal artificial entrenada con el algoritmo de Levenberg-Marquardt como en el presente estudio. Los resultados obtenidos hacen concluir que, pese a que el modelo termodinámico haya presentado errores mayores que las redes neuronales para la predicción de BSFC, estos errores están en el rango de los errores obtenidos en otros estudios de la temática.

En cuanto a T_{exh} , de acuerdo con lo esperado este parámetro ha mostrado una clara correlación o dependencia con respecto a la carga del motor. En el caso de potencias medias-bajas el modelo de AVL ha mostrado mejores resultados, mientras que para potencias medias-altas las redes neuronales artificiales han mostrado mayor exactitud. Esto podría estar ocasionado por un desajuste del modelo termodinámico para cargas altas del motor. Como puede observarse en la Figura C1. 15, las curvas de presión de combustión se han ajustado más a las reales en cargas más bajas que en las altas; este peor ajuste podría ser una de las razones por las que en altas cargas muestra mayores errores. En cuanto a otros estudios, debido a la gran correlación que guarda este parámetro con la condición de funcionamiento del motor, varios estudios han incluido la temperatura de gases de escape entre los parámetros predichos por sus modelos. Parlak et al. [116] y Cay et al. [135] alcanzaron valores de MAPE de 2,36% y 3,14% respectivamente para la predicción de T_{exh} mediante redes neuronales artificiales, lo que hace pensar que la predicción de T_{exh} del presente estudio es relativamente fiable con valores MAPE de 0,5% y 1,86% para ANN y AVL respectivamente. Sin embargo, también existen aproximaciones más exactas de este parámetro con el uso de redes neuronales [131], con una MAPE de 0,58% para la predicción de T_{exh} .

De acuerdo con Ramalingam et al. [182] cuando la carga del motor supera el 70%, las emisiones de CO sufren un fuerte aumento por varias posibles razones (ej. incremento de la fracción de combustible, temperatura dentro del cilindro, posible efecto “knocking” o falta de O_2 desencadenando en una combustión incompleta a altas cargas). Esta puede ser una razón por la que el modelo de AVL presenta mayor exactitud que las redes neuronales a la hora de predecir emisiones de CO, exceptuando las cargas altas del motor. En cuanto a los valores totales de MAPE de los 20 registros de test, ANN y AVL han presentado valores de 13,75% y 14,99%

respectivamente, que son relativamente altos en comparación al 1,3% obtenido mediante Rezaei et al. [175] mediante el uso de redes neuronales artificiales de tipo feed forward. En el caso de observar únicamente los valores totales de MAPE del presente estudio, se concluiría que las redes neuronales presentan mayores niveles de exactitud que el modelo termodinámico. Sin embargo, se ha demostrado que el estudio de la evolución del error con respecto a la carga es importante, ya que el error de predicción del modelo termodinámico solo se convierte mayor cuando se predice CO en cargas muy altas del motor. Hasta ese momento, el modelo termodinámico es más exacto que el de las redes neuronales, como puede observarse en la Figura C1. 18c. Por ello, se concluye que excepto para cargas muy altas, el modelo termodinámico ha demostrado ser más exacto que el modelo de redes neuronales, también teniendo en cuenta que ambos errores son comparativamente altos en consideración con otros estudios previos que han predicho emisiones de CO.

El nivel de exactitud en las predicciones de NO_x ha sido relativamente alto en ambos modelos, independientemente de la carga a la que estuviera el motor. En cuanto a otros trabajos de investigación, el MAPE alcanzado para predicciones de NO_x es de 1,99% en [136, 183], que es ligeramente inferior al 2,18% y 3,28% alcanzados en el presente estudio para las redes neuronales y el modelo termodinámico respectivamente. Por ello, se concluye que los errores obtenidos son suficientemente bajos como para asegurar que ambos modelos pueden ofrecer predicciones de NO_x con altos niveles de exactitud para cualquier carga del motor. Un estudio reciente llevado a cabo por Uslu et al. [184] comparaba la capacidad de predicción de las redes neuronales artificiales y la Response Surface Methodology. Entre los parámetros calculados por sus modelos, NO_x mostraba mayores niveles de error en ambos modelos (9,705% y 6,438% para ANN y RSM respectivamente), mientras que las predicciones de CO de los mismos modelos mostraban errores menores que los alcanzados para CO en el presente estudio (9,365% y 7,894% para ANN y RSM respectivamente). Estos resultados, junto con resultados similares obtenidos en estudios análogos reafirman la hipótesis de que el nivel de exactitud no solo depende del modelo en sí, sino también de cada parámetro y de cada motor. Según lo mostrado en la Figura C1. 17b y Figura C1. 17c, en el caso de los parámetros T_{exh} y CO, cuando el motor alcanza las cargas más altas, las predicciones del modelo termodinámico difieren de los valores reales, por lo que se incrementa notablemente el error de predicción. Esto podría estar causado por un desajuste del modelo termodinámico para las cargas más altas como ya se ha visto en la Figura C1. 15. En futuras vías de investigación, se podrían estudiar la posibilidad de introducir un parámetro de fricción del motor FMEP cambiante con la carga del motor, ajustando mejor las pérdidas de fricción del motor para cargas más altas. También podrían analizarse modelos de

fricción alternativos como el modelo de Shayler et al. [185] disponible en el software AVL Boost™, el clásico modelo de Chen-Flynn [186] o la introducción manual de una tabla de FMEP dependiente de la carga del motor basada en ensayos experimentales.

Por último, tras observar el tiempo de cálculo necesitado por cada modelo, el modelo de redes neuronales artificiales necesita 0,52 segundos para calcular los cuatro outputs en las 20 situaciones de testeo del motor, mientras que el modelo termodinámico necesita 1.234,29 segundos. Según Oguz et al. [187], un modelo de redes neuronales correctamente entrenado opera mucho más rápido que los modelos convencionales de simulación mediante softwares o los modelos matemáticos; esto se ha visto también reflejado en el presente estudio. Similarmente, Rida et al. [126] concluyeron que su modelo de redes neuronales artificiales realizaba los cálculos 80 veces más rápido que el modelo físico que desarrollaron. Esta diferencia de tiempo de cálculo, junto con la diferencia apreciada en el presente estudio suponen que en casos de cálculo en tiempo real las redes neuronales artificiales deberían ser la opción de modelado más recomendable. Sin embargo, además de calcular el BSFC, T_{exh} , CO y NO_x el modelo termodinámico proporciona muchos outputs adicionales. Como se ha visto en el marco teórico, este tipo de modelos resuelven las ecuaciones de conservación en los diferentes elementos del motor, por lo que además de los outputs de interés del presente estudio, el modelo termodinámico ofrece muchas otras variables de interés (ej. curva de presión de combustión, curva de temperatura en la cámara de combustión etc.) que podrían ser de utilidad en procesos de mantenimiento basado en condiciones. No obstante, la adaptabilidad del modelo termodinámico al espectro completo de potencias del motor presenta un reto, ya que debería proveer altos niveles de exactitud para todo el rango de cargas, desde 0% a 100%.

El modelo termodinámico necesita de muchas variables de diseño para su implementación (curvas de apertura de válvulas, coeficientes de descarga, medidas geométricas de los tubos etc.). Todos estos parámetros no están a veces disponibles en el entorno de funcionamiento de un motor diésel (ej. motor diésel marino a bordo de buque pesquero operativo), por lo que sólo la adquisición de las variables necesarias para poder desarrollar un modelo termodinámico robusto presenta un reto per se. No sólo eso, una vez implementado el modelo termodinámico debe ser ajustado mediante la comparación de parámetros del motor real y parámetros del modelo como es el caso del ajuste mediante las curvas de presión de combustión. Por lo contrario, las redes neuronales artificiales sólo requieren datos operacionales para ser entrenados. Una vez se obtiene una buena base de datos, la red es entrenada y el tiempo de cálculo necesitado después para calcular los outputs ha demostrado ser muy reducido. Esto hace que este tipo de metodología sea notablemente más fácil de aplicar en motores operativos.

Teniendo en consideración todos los argumentos presentados, cada modelo presenta sus ventajas específicas y ambos modelos han probado ser herramientas de confianza para la predicción de parámetros de funcionamiento y emisiones considerados en el presente estudio.

5- Conclusiones

En el presente estudio se han comparado dos metodologías diferentes de modelado de motores. Ambas metodologías han sido entrenadas para predecir BSFC, T_{exh} , CO y NO_x introduciendo a ambos modelos el BMEP y la velocidad de giro del motor. Por un lado, el modelo termodinámico ha sido desarrollado empleando el software de simulación de motores AVL Boost™. Primero se ha diseñado un esquema del motor incluyendo todos los elementos del motor real, y tras introducir las características físicas y las variables de operación del motor el modelo se ha ajustado comparando curvas de presión de combustión reales y modeladas y realizando las pertinentes modificaciones. Por otro lado, el modelo de redes neuronales se ha desarrollado analizando el error del modelo en la fase de entrenamiento mediante la comparación de dos de los algoritmos de optimización más eficaces y rápidos.

Ambos modelos han probado ser herramientas con gran capacidad de adaptación para predecir parámetros de funcionamiento y emisiones del motor. Sin embargo, dependiendo del parámetro calculado y el punto de operación en el que se encuentra el motor se han apreciado diferencias en el nivel de exactitud de cada modelo. Del presente estudio, se obtienen las siguientes conclusiones:

- Ambos modelos han sido capaces de predecir los parámetros de funcionamiento del motor con un gran nivel de exactitud (MAPE por debajo de 6% para BSFC y por debajo de 2% de T_{exh}).
- El modelo de redes neuronales artificiales provee mejores resultados que el modelo termodinámico para la predicción de BSFC para cualquier carga del motor.
- Las emisiones de CO han sido calculadas con niveles más bajos de error por el modelo termodinámico en todo el espectro de carga del motor, exceptuando las cargas más altas en las que las redes neuronales han mostrado mayores niveles de exactitud.
- Las emisiones de NO_x se han calculado con altos niveles de exactitud en ambos modelos, excepto en el rango de bajas potencias del motor.

- El tiempo de cálculo es notablemente menor en el caso de las redes neuronales artificiales (0,52 segundos vs 1.234,29 segundos).
- A pesar de su tiempo de cálculo elevado, el modelo termodinámico ofrece resultados adicionales muy útiles para el mantenimiento basado en condiciones de los motores, como son la curva de presión de combustión o la curva de liberación de calor ROHR.

Las redes neuronales artificiales han probado ser una herramienta muy eficaz para la predicción de parámetros de funcionamiento del motor para aplicaciones de detección de anomalías de este, motivando a muchos equipos de investigación a utilizarlas en sus estudios. La ventaja de esta metodología es que es muy flexible y robusta, adaptándose a condiciones de operación diferentes del motor con bajos niveles de error. El modelo termodinámico por otro lado ha demostrado ser más lento en términos de tiempo de cálculo y no se ha conseguido adaptar bien a las cargas más altas del motor. Esto podría corregirse mediante la inclusión de parámetros cambiantes con la carga del motor, como puede ser un parámetro de fricción FMEP variable con respecto a la carga o modelos de fricción alternativos. Por otro lado, el modelo termodinámico requiere de las variables físicas y relacionadas con la combustión que no siempre son accesibles en motores operativos, mientras que las redes neuronales emplean bases de datos medidas en motores ya en operación.

A pesar de que el modelo termodinámico requiere más tiempo de cálculo que las redes neuronales artificiales, este tiempo es mucho menor que el que se necesitaría para conseguir dichos parámetros mediante ensayos experimentales. Según lo concluido en el presente estudio, el modelo termodinámico es capaz de reproducir el funcionamiento del motor en condiciones cambiantes, lo que puede ser una alternativa potencial para reemplazar los ensayos experimentales reales y proveer otros métodos más rápidos (redes neuronales artificiales) de una base de datos robusta. Por ello, en futuros trabajos de investigación se puede estudiar la posibilidad de combinar ambas metodologías, primero ajustando el modelo termodinámico a un motor en concreto y después utilizando dicho modelo termodinámico para crear una base de datos de gran dimensión para las redes neuronales artificiales, evitando los numerosos ensayos que se requerirían para crear dicha base de datos.

Tras estudiar ambas metodologías en este caso de estudio, futuros trabajos en torno al modelado de motores diésel deberán aplicar estos métodos a motores de múltiples cilindros con cantidades de outputs mayores. Al fin y al cabo, se pretende mostrar en tiempo real una

imagen completa del motor, por lo que cuatro outputs serían una cantidad limitada de variables para después aplicar cualquier proceso de mantenimiento basado en condiciones.

CAPÍTULO 2. Modelado de motor
diésel marino mediante redes
neuronales artificiales para el cálculo
de múltiples parámetros de
operación en su mapa de
funcionamiento completo

Nomenclatura

<i>Acrónimos</i>		<i>Temperaturas</i>	
ANN	Artificial neural network	T₀	Temperatura ambiental
AT	Alta temperatura	T₀₁	Agua AT (Salida enfriador agua)
BSFC	Consumo específico de combustible	T₀₂	Aceite (Entrada motor)
BT	Baja temperatura	T₀₃	Agua AT (Entrada motor)
CO	Monóxido de carbono	T₀₄	Agua BT (Entrada enfriador aceite)
CO₂	Dióxido de carbono	T₀₅	Agua BT (Entrada enfriador agua)
CPU	Unidad central de procesamiento	T₀₆	Aire (Salida TC#2)
GT	Gross tonage	T₀₇	Aceite (Entrada motor)
H₀	Humedad Relativa	T₀₈	Aire (Entrada motor)
HC	Hidrocarburos	T₀₉	Combustible (Entrada motor)
IDLE	Integrated development and learning environment	T₁₀	Aire (Entrada enfriador aire)
IMO	Organización marítima internacional	T₁₁	Agua BT (Salida enfriador agua)
ISO	International Organization for Standardization	T₁₂	Aire (Salida TC#1)
k	Multiplicador de función cúbica	T₁₃	Agua BT (Entrada enfriador aire)
k^b	Multiplicador de cúbica blanda	T₁₆	Gases de escape cilindro #1
k^d	Multiplicador de cúbica dura	T₁₇	Gases de escape cilindro #2
kⁿ	Multiplicador de cúbica nominal	T₁₈	Gases de escape cilindro #3
MAPE	Error porcentual absoluto medio	T₁₉	Gases de escape cilindro #4
MSE	Error cuadrático medio	T₂₀	Gases de escape cilindro #5
N	Velocidad de giro	T₂₁	Gases de escape cilindro #6
NO	Monóxido de nitrógeno	T₂₂	Gases de escape (Entrada TC#1)
NO₂	Dióxido de nitrógeno	T₂₃	Gases de escape (Entrada TC#2)
NO_x	Óxidos de nitrógeno	T₂₄	Gases de escape (Salida TC#1)
P^b	Potencia en cúbica blanda	T₂₅	Gases de escape (Salida TC#2)
P^d	Potencia en cúbica dura	T₂₆	Gases de escape (Conducto escape)
P_e	Potencia efectiva	T₂₇	
Pⁿ	Potencia en cúbica nominal	<i>Presiones</i>	
P^{rpm.cte}	Potencia cúbica de velocidad de giro constante	P₀	Presión ambiental
R	Coefficiente de regresión	P₀₁	Agua AT (Entrada motor)
RAM	Memoria de acceso aleatorio	P₀₂	Agua BT (Entrada enfriador agua)
TC	Turbocompresor	P₀₃	Aire (Entrada motor)
T_{exh}	Temperatura de gases de escape	P₀₄	Aire (Salida TC#1)
		P₀₅	Aire (Salida TC#2)
		P₀₆	Aceite (Entrada motor)
		P₀₇	Combustible (Entrada motor)

1- Resumen

Los incidentes marinos dados en los últimos años han sido en parte causados por la pérdida de propulsión de los buques. De hecho, el tipo de incidente más común en el ámbito marino ha sido generalmente la pérdida de control o propulsión del buque, causando una media del 22% de los incidentes anuales desde el año 2014 [12]. En este contexto, los fallos del motor podrían identificarse desarrollando un modelo que simule el motor real con gran exactitud y después observando las desviaciones entre el modelo y el motor real. Es por ello que las técnicas de modelado de motores han sido un campo de estudio que ha ganado un creciente interés en la última década. En este aspecto, en el estudio del estado del arte ya se han visto varias estrategias de modelado de motores, entre las que se encuentran las redes neuronales artificiales, que en el primer capítulo de la tesis han mostrado altos niveles de precisión y bajos tiempos de cálculo en un motor diésel de un cilindro. Sin embargo, hasta el momento la mayoría de los estudios que han simulado el funcionamiento de un motor diésel mediante redes neuronales artificiales se han centrado en calcular cantidades reducidas de parámetros con sus modelos. Por ello, con objeto de analizar la capacidad de generalización de las redes neuronales a la hora de predecir múltiples parámetros del motor, en el presente estudio, se han calculado 35 parámetros de funcionamiento y emisiones simultáneamente empleando las redes neuronales artificiales. Para ello, se han llevado a cabo numerosos ensayos experimentales, registrando las variables del motor a lo largo de su mapa de funcionamiento completo.

Adicionalmente, se han ensayado algunos puntos aleatorios dentro de este mapa de funcionamiento, para después analizar cómo trabaja el modelo en dichos puntos aleatorios. Primero se ha definido la estructura óptima de la red mediante el análisis del error de validación. Después, se ha entrenado y validado la red utilizando una base de datos que contiene 1000 registros, extraídos de los numerosos ensayos experimentales. Finalmente, se ha testeado la red en los puntos aleatorios previamente ensayados, para ver cómo funciona el modelo en puntos en los que un motor real podría encontrarse debido a factores externos como, por ejemplo, la meteorología. Para analizar el nivel de precisión del modelo, se ha utilizado el Error porcentual absoluto medio (MAPE).

Los valores de MAPE obtenidos para los puntos aleatorios de funcionamiento del motor y para los 35 parámetros calculados se han mantenido por debajo del 8,5% a excepción de las emisiones de CO y NO₂ (con errores de hasta 48,84%). Esto podría estar causado por las bajas concentraciones de ambos parámetros para este tipo de motores, en comparación a otros parámetros de emisiones como los NO_x o CO₂. Para los circuitos de agua de alta y baja

temperatura, circuito de aceite y circuito de gases de escape, se han alcanzado errores de MAPE por debajo de 4,3%, lo que demuestra un nivel de precisión muy elevado. El tiempo de cálculo para predecir 35 parámetros del motor en 24 situaciones diferentes de test ha sido de 0,109 segundos, que junto con el alto nivel de exactitud presentado por el modelo posiciona las redes neuronales artificiales como una herramienta muy útil para crear gemelos digitales que muestren una imagen completa del estado del motor en tiempo real.

Abstract

Marine incidents given in recent years have been in part caused by propulsion issues. In this context, incipient propulsion faults may be identified by deviations between real values and healthy engine values provided by an accurate model. Engine modelling techniques have thus become a topic of interest in the last decade. On this basis, Machine learning approaches such as Artificial Neural Networks (ANN) have proved to be accurate and fast in terms of calculation time. However, up to now, most research work has focused on predicting a few parameters for specific operation points. In order to analyse the generalization capability of ANN when predicting multiple outputs in real engine conditions, 35 different performance and emission parameters were simultaneously predicted in this study with an ANN. To do so, different engine operation points were tested in a six-cylinder marine diesel engine, characterizing the whole engine performance map. Additionally, some points from random regions throughout the entire engine performance map were tested to later analyse ANN performance on them. After defining network optimum structure and training, and validating the Artificial Neural Network with 1000 data samples, the ANN was tested with data extracted from unseen random regions of the performance map. Mean Absolute Percentage Errors obtained for testing samples from random points of the engine performance map remained below 8.5% for all parameters with the exception of CO and NO₂ emissions predictions, which presented error levels up to 48,84%. For low temperature and high temperature cooling systems, oil system and exhaust gas system, MAPE values obtained were below 4.3%. Calculation time for 24 testing samples containing 35 parameters was 0.109 s, which along with the high accuracy level obtained demonstrated that ANN can predict multiple outputs throughout the whole engine performance map.

2- Material y métodos

2.1 Banco de pruebas

Para esta segunda fase de la tesis, se planeó utilizar un motor con características similares a los motores instalados en buques de pesca de mediano porte (250-400 GTs) como el mostrado en la Figura C2. 1. A diferencia del caso del motor de un cilindro, este motor guarda una gran similitud con cualquier motor de buques de mayor porte, por lo que los resultados del presente estudio serán directamente extrapolables a cualquier otro tipo de buque operativo que utilice un motor diésel de múltiples cilindros en su propulsión.



Figura C2. 1 Buques de pesca de mediano porte, representativos del caso de estudio

En el presente caso de estudio, se ha utilizado un motor diésel marino de 6 cilindros del modelo YANMAR 6HYM-WET. Este motor se encuentra en la Escuela Técnica Superior de Náutica y Maquinas Navales de la Universidad del País Vasco en Portugalete. El motor está refrigerado por agua, por lo que la instalación de Portugalete cuenta con unos intercambiadores de calor, que mediante el uso de agua de mar refrigeran el circuito de agua dulce de baja temperatura del motor. La entrada de aire se lleva a cabo mediante dos turbocompresores. El motor está acoplado a un freno hidráulico, que permite regular manualmente el par de carga en el motor, desde el 0% hasta el 100% de su capacidad. Por otro lado, la velocidad de giro del motor también está controlada mediante un regulador que fija el acelerador del motor en la posición deseada para establecer la velocidad de giro requerida. De este modo, a un régimen de giro determinado

se carga el motor con un par concreto para obtener la potencia de carga deseada sobre el motor. La Figura C2. 2 muestra una imagen del motor utilizado y en la Tabla C2. 1 se muestran sus características principales.




Figura C2. 2 Imagen del motor YANMAR 6HYM-WET

Tabla C2. 1 Características principales del motor YANMAR 6HYM-WET

Parámetro	Valor	Unidad
Fabricante	YANMAR	[-]
Tipo de ciclo	4 tiempos media velocidad	[-]
N cilindros	6	[-]
Velocidad nominal	2100	Rpm
Potencia nominal	400	kW
Ratio de compresión	15,18	[-]
Diámetro de cilindro	132,9	mm
Carrera	165	mm
Carga de aire	Turbocompresores	[-]

En cuanto a la instrumentación utilizada para la adquisición de parámetros del motor, en este caso la dimensión de los parámetros medidos ha sido mucho mayor que en el primer capítulo de la tesis, necesitando así de varios equipos de adquisición para el registro de datos. Por un lado, los parámetros de funcionamiento del motor como temperaturas o presiones en distintos subsistemas de este se han registrado utilizando una herramienta de adquisición llamada National Instruments Compact FieldPoint. Esta herramienta permite adquirir y acoplar múltiples variables simultáneamente, para después registrarlas en el ordenador. Sin embargo, la velocidad de giro del motor, el par y la posición de ángulo del cigüeñal se han tomado utilizando la herramienta de adquisición DEWETRON 2600 ya utilizada en el motor de un cilindro y que permite registrar variables a altas frecuencias de muestreo. Al mismo tiempo, las emisiones de gases contaminantes se han registrado con el TESTO 350XL Maritime Analyser y exportados mediante su software asociado easyEmission. Para el procesado de datos y acoplamiento de las variables registradas mediante los distintos instrumentos, se ha utilizado el IDLE Spyder de Anaconda y Python3.

En este caso, se han medido variables de funcionamiento y emisiones a lo largo de todo el motor. Por un lado, se ha tomado la temperatura a las entradas y salidas de todos los elementos de este, así como en los conductos de salida de gases de cada cilindro. En algunos puntos de interés, también se han realizado medidas de presiones manométricas. En total, se han registrado 43 parámetros de funcionamiento y emisiones del motor, que pueden agruparse como: 25 medidas de temperatura, 7 medidas de presión, condiciones ambientales (presión, humedad y temperatura ambiente), par del motor, velocidad del motor, consumo de combustible y 5 parámetros de emisiones de gases contaminantes. De estos 43 parámetros, 8 han sido utilizados como inputs y 35 han sido calculados como outputs del modelo desarrollado. En la Figura C2. 3 se muestra un esquema del motor y la sensórica implementada en él y sus subsistemas. En la Tabla C2. 2 se muestran los diferentes sensores utilizados junto con sus correspondientes unidades y niveles de incertidumbre asociados.

Cada subsistema del motor está representado con un color diferente dependiendo del fluido que transcurre por dicho subsistema, de acuerdo con los colores establecidos para los diferentes fluidos en el ámbito marino en la ISO 14726 [188]. En este esquema pueden apreciarse los dos turbocompresores que contiene el motor, junto con los enfriadores de aceite, aire y agua por los que pasa el circuito de baja temperatura. El intercambiador de calor de agua salada (no representado en la Figura C2. 3) toma la salida del agua de baja temperatura (T_{11}) para enfriarla y volver a introducirla al motor (T_{04}).

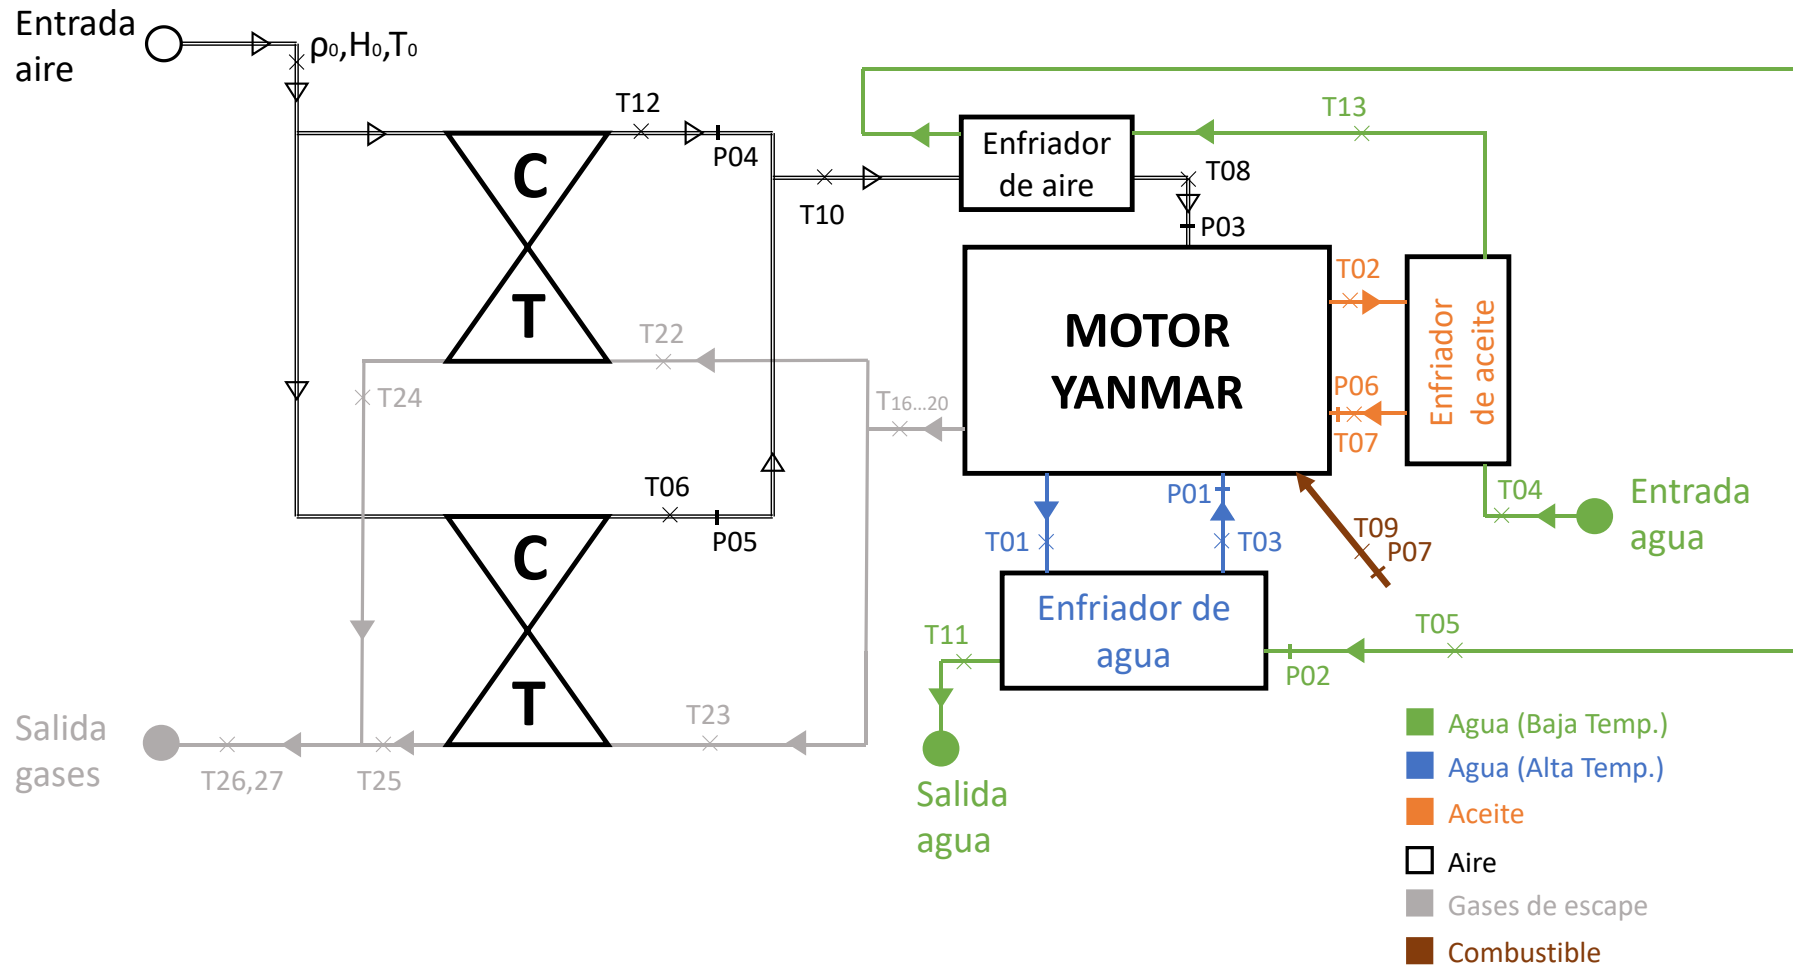


Figura C2. 3 Esquema sensorización motor YANMAR 6HYM-WET

Tabla C2. 2 Sensores utilizados en el motor YANMAR 6HYM-WET

ID	Unidad	Instrumento	Incertidumbre	Frec. muestreo
T ₀₁ , T ₀₅ , T ₀₉ , T ₁₀ , T ₁₃	[°C]	Sensor de temperatura Pt100	± 0,3 °C	1 Hz
T ₀₂ , T ₀₃ , T ₀₄ , T ₀₆ , T ₀₇ , T ₀₈ , T ₁₁ , T ₁₂ , [T ₁₆ ,...,T ₂₇]	[°C]	Termopar tipo K	± 4%	1 Hz
ρ ₀ , H ₀ , T ₀	[kg/m ³], [%], [°C]	HD2001.1 estación meteorológica	T ₀ : ±0,3% H ₀ : ±1,5% ρ ₀ : ±0,5mbar	1 Hz
P ₀₁ , P ₀₂	[bar]	Sensor de presión SEN 9601 B055	±0,5%	1 Hz
P ₀₆ , P ₀₇	[bar]	Sensor de presión SEN 9601 B075	±0,5%	1 Hz
P ₀₃ , P ₀₄ , P ₀₅	[bar]	Sensor de presión KTP-D-F1	±0,25%	1 Hz
Velocidad de giro	[rpm]	Encoder Kistler 2614B	± 0,05%	1 MHz
Posición de pistón	[°]	Encoder Kistler 2614B	± 0,02°	1MHz
Par	[Nm]	Kistler 4502A50RA	< 0,07%	1MHz
Consumo de combustible	[Kg/h]	Caudalímetro: KRAL OME13	± 0,1%	1 Hz
Emisiones de gases	[ppm], [%]	TESTO 350XL MARITIME analyser	NO: ± 5% NO ₂ : ± 5ppm CO: ± 10 ppm CO ₂ : ± 0,3% vol	1 Hz

2.2 Ensayos experimentales

Muchos trabajos de investigación en el campo del modelado de motores han empleado las redes neuronales artificiales para desarrollar sus modelos. Sin embargo, de acuerdo con lo percibido en el estudio del estado del arte, la mayoría de los trabajos se han centrado en puntos específicos de funcionamiento del motor, para cargas y velocidades de giro concretas o rangos de cambio reducidos [117, 124, 131, 134, 136]. Lo cierto es que, para un mismo motor existen múltiples combinaciones de velocidad de giro y potencia a las que puede trabajar. En el caso de los motores diésel marinos, Theotokatos et al. [189] investigaron la relación entre la velocidad de giro y la potencia entregada por un sistema de propulsión de un buque. Entre las conclusiones, determinaron que esta relación debería ser considerada cúbica, ya que los exponentes que calcularon para sus funciones aproximadas oscilaban entre 3,013 y 3,048. Sin embargo, recientemente se ha visto que en la operativa real de un buque la relación entre la velocidad de giro del motor y el par entregado pueden cambiar debido a factores externos (ej. factores meteorológicos) [138]. De hecho, la relación entre la velocidad del buque y la potencia necesaria para ir a esa velocidad también puede aproximarse a una función cúbica, pero este exponente puede variar si se tienen en cuenta factores externos como las condiciones meteorológicas adversas como el oleaje, viento, corriente, etc [190].

Por lo tanto, en la operativa real de un motor diésel marino, la relación entre velocidad de giro y potencia del motor no es única, así como la relación entre estos dos parámetros clave y el resto de los parámetros del motor (temperaturas de circuito de alta, baja, presión de sobrealimentación etc.) tampoco lo es. Es por ello que, en el presente estudio se ha considerado todo el mapa de funcionamiento del motor. Para eso se ha partido de la función cúbica más simple del motor, partiendo de sus valores de potencia y velocidad de giro nominales, indicados en la Tabla C2. 1. Después se han variado estas funciones para representar, dentro de los límites del motor, una curva de funcionamiento más dura y otra curva de funcionamiento más ligera. Los ensayos se han llevado a cabo de acuerdo con el tipo de test E3 (velocidad de giro y potencia variable) de la ISO 8178 y el código técnico de NO_x de la IMO [191, 192]. Por último, también se ha considerado la curva de velocidad constante en la que el motor podría trabajar a diferentes cargas manteniendo su velocidad nominal (test tipo E2). La ecuación (1) muestra la función cúbica inicial considerada para los primeros ensayos experimentales.

$$P_e = k * N^3 \quad (1)$$

P_e representa la potencia efectiva entregada por el motor en kW. La constante k el multiplicador de la función, y N es la velocidad angular del motor en rpm. Partiendo de los valores nominales de potencia y velocidad de giro, se obtiene el multiplicador de esta primera función.

$$k^n = \frac{400 \text{ kW}}{2100 \text{ rpm}} = 4,3192 * 10^{-8} \quad (2)$$

Este multiplicador define la función cúbica nominal del motor. Es decir, en esta curva no está contemplado ningún tipo de factor externo. Para considerar factores externos que pudieran afectar a esta relación y por lo tanto a los parámetros del motor, se han incluido las siguientes dos curvas:

- Cúbica dura: Esta curva representa condiciones externas desfavorables para el buque, entre las que se observan corrientes/olas/viento en contra del buque, ensuciamiento del caso etc. También se pueden considerar aquí operativas de pesca en las que se requiera mover una cantidad de peso adicional a la del buque, como puede ser el caso de la pesca de arrastre en la que el buque tiene que arrastrar por el fondo una red que va cargándose de pescado. En estos casos el motor funcionará generalmente a potencias más altas para las mismas vueltas respecto a la cúbica nominal.
- Cúbica blanda: Esta curva representa condiciones externas favorables. Además, si se dispone de algún tipo de vela o sistema de propulsión auxiliar, la carga exigida al motor será menor, por lo que para las mismas vueltas deberá entregar potencias más bajas, en comparación con la función cúbica nominal.

Para lograr las funciones representativas de estas condiciones, se ha modificado el multiplicador de la ecuación (2). Para ello, se ha provocado el mismo desplazamiento hacia las condiciones de cúbica dura y de blanda, partiendo de la cúbica nominal, y respetando los límites en los que

puede trabajar el motor. Los desplazamientos hacia la curva dura y blanda están representados en las ecuaciones (3) y (4).

$$k^d = k + 8 * 10^{-9} = 5,1192 * 10^{-8} \quad (3)$$

$$k^b = k - 8 * 10^{-9} = 3,5192 * 10^{-8} \quad (4)$$

k^d y k^b representan los multiplicadores de las funciones cúbicas dura y blanda respectivamente. Por lo tanto, se han conseguido tres relaciones entre potencia y velocidad de giro del motor. Adicionalmente, se ha considerado la curva de velocidad constante de acuerdo con el tipo de test E2 y el código técnico de NO_x de la IMO para operativa de hélice de paso variable [191]. Estas cuatro curvas definirán los ensayos experimentales a realizar, acotando el mapa de funcionamiento en el que se puede mover el motor YANMAR 6HYM-WET teniendo en consideración factores externos dados en la operativa real de este tipo de motores. La expresión (5) muestra las 4 funciones que acotan este mapa de funcionamiento, y la Figura C2. 4 muestra este mapa de funcionamiento con las funciones definidas en este apartado. Los puntos representados con triángulos se explicarán en el siguiente apartado.

$$P^n = k^n * N^3 = 4,3192 * 10^{-8} * N^3$$

$$P^d = k^d * N^3 = 5,1192 * 10^{-8} * N^3$$

$$P^b = k^b * N^3 = 3,5192 * 10^{-8} * N^3 \quad (5)$$

$$0 < P^{rpm\ cte} < 400 // N = 2100\ rpm$$




Figura C2. 4 Cúbicas del motor y mapa de funcionamiento

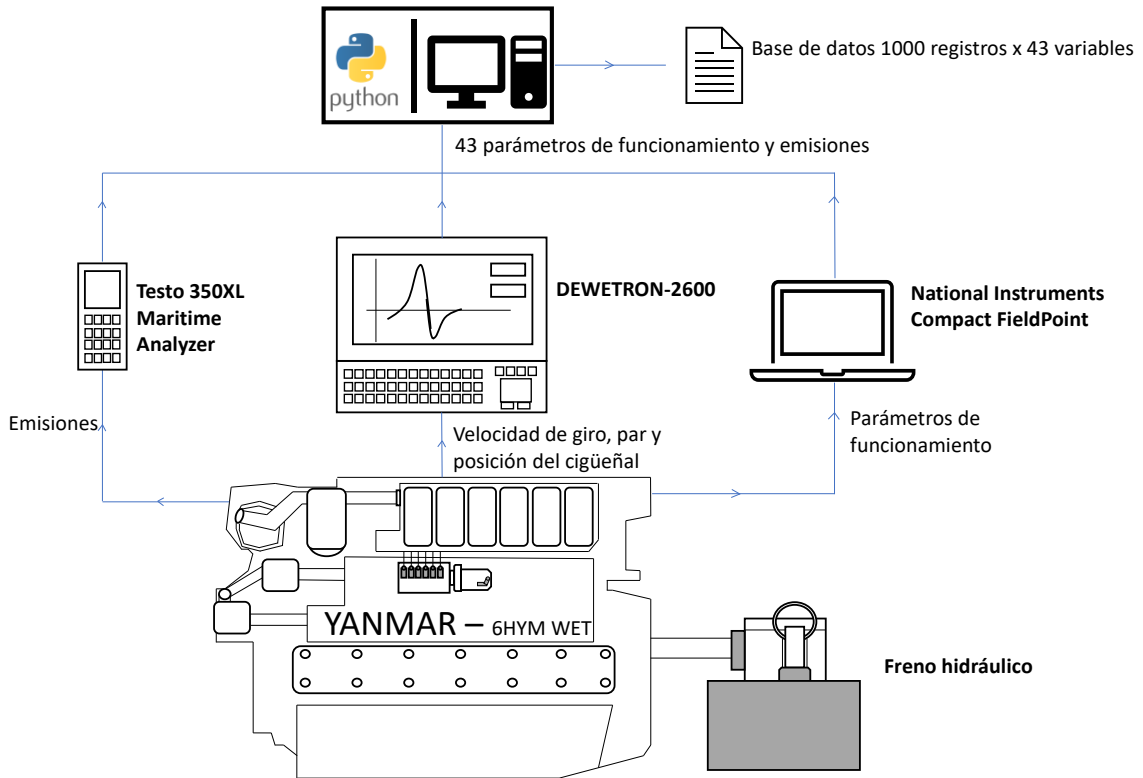
2.3 Adquisición de datos

Los ensayos experimentales se han realizado en múltiples puntos diferentes de las distintas cúbicas del motor para crear una base de datos robusta y poder entrenar el modelo de redes neuronales artificiales con ella. Para ello, se han establecido las siguientes cargas relativas en todas las curvas nominal, dura y blanda del motor: 25, 40, 50, 60, 75, y 100% (excepto en el caso de la cúbica dura en la que el 100% sobrepasa la potencia nominal del motor). Además, se han ensayado los estados de carga relativa de 25, 50, 75 y 100% de la curva de velocidad constante. Todos estos puntos de funcionamiento están representados con círculos en la Figura C2. 4. Tras establecer la carga del motor mediante el freno hidráulico, y ajustar la velocidad de giro del motor a la velocidad deseada mediante el acelerador, una vez alcanzados los valores de cada punto, el motor se ha dejado en marcha en dicho punto de operación durante 20 minutos antes de la toma de datos para asegurar el estado estacionario de la máquina en dicho punto.

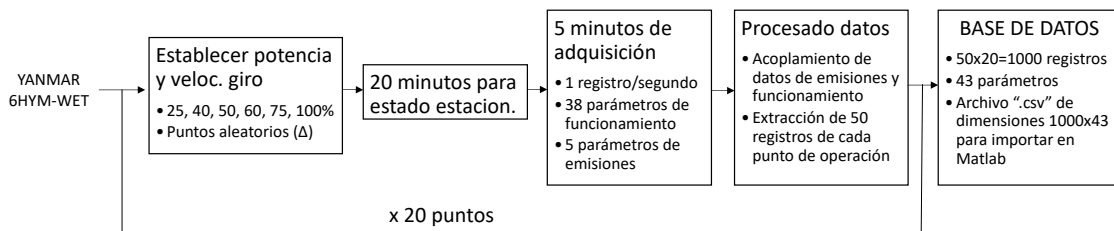
Después, se han tomado los 43 parámetros de funcionamiento y emisiones del motor durante 5 minutos; la frecuencia de muestreo ha sido de 1 registro/segundo (1 Hz). De esta forma, se han establecido todos los puntos de funcionamiento representados por círculos en la Figura C2. 4, en todas las curvas del mapa de funcionamiento del motor. De cada punto de operación, se han extraído 50 registros para introducirlos en la base de datos que se utilizará para entrenar, validar

y testear la red neuronal artificial. Para ello, los datos obtenidos de las diferentes herramientas de adquisición mencionadas en el anterior apartado se han acoplado utilizando el IDLE Spyder de Anaconda y Python3. Por lo tanto, la base de datos obtenida al final de los ensayos experimentales consta de 1000 registros (de los diferentes puntos de operación del mapa de funcionamiento del motor) de 43 variables de funcionamiento y emisiones del motor.

Uno de los objetivos del presente estudio es analizar la capacidad de regresión y adaptabilidad de las redes neuronales artificiales para predecir múltiples parámetros de funcionamiento y emisiones del motor en cualquier punto aleatorio del mapa de funcionamiento de este. Por ello, el testeo del modelo se va a realizar con una pequeña parte de la base de datos utilizada para el entrenamiento y la validación (como se ha hecho en la mayoría de los estudios hasta el momento; se citarán algunos casos en el apartado de redes neuronales), pero además de estos registros de test, se han escogido puntos aleatorios del mapa de funcionamiento del motor para ver su capacidad de simulación en dichos puntos. Estos puntos se han registrado de la misma forma que todos los ensayos para la base de datos (20 minutos para funcionamiento estable, 5 minutos para adquisición). Estos no se han introducido en la base de datos, ya que se pretende analizar y discutir la adaptabilidad de la red neuronal en estos puntos totalmente diferentes a los utilizados en la fase de entrenamiento y validación. La Figura C2. 5a muestra un esquema del proceso de adquisición de datos y la Figura C2. 5b muestra el diagrama de flujo de dicho proceso.



a. Proceso de adquisición de datos



b. Diagrama de flujo de adquisición de datos

Figura C2. 5 Ensayos experimentales y adquisición de datos

2.4 Redes Neuronales Artificiales

En el primer capítulo de la tesis, tras plantear las metodologías más utilizadas hasta el momento para el modelado de motores diésel, las redes neuronales artificiales Feed Forward mostraron un gran potencial en términos de niveles de exactitud y tiempo de cálculo. Es por ello que en el presente caso de estudio también se ha optado por este tipo de redes neuronales para la predicción de los múltiples parámetros de funcionamiento y emisiones del motor YANMAR 6HYM-WET. Este tipo de metodologías son herramientas de aprendizaje supervisado, por lo que en la fase de entrenamiento se le proporcionan tanto los inputs como sus respectivos outputs a la red, para después ir actualizando iterativamente las conexiones de la red con objeto de minimizar el error de cálculo [193]. El algoritmo utilizado para el entrenamiento es Levenberg-Marquardt, que en el caso del Minsel430a demostró ser más rápido y eficaz que el algoritmo Adam. Esto coincide con la conclusión de Sahilaja et al. [124] de que este algoritmo es más rápido que cualquier otro algoritmo basado en el descenso del gradiente (ej. Adam). El software utilizado es Matlab Neural Network Toolbox. El esquema del modelo desarrollado se muestra en la Figura C2. 6.

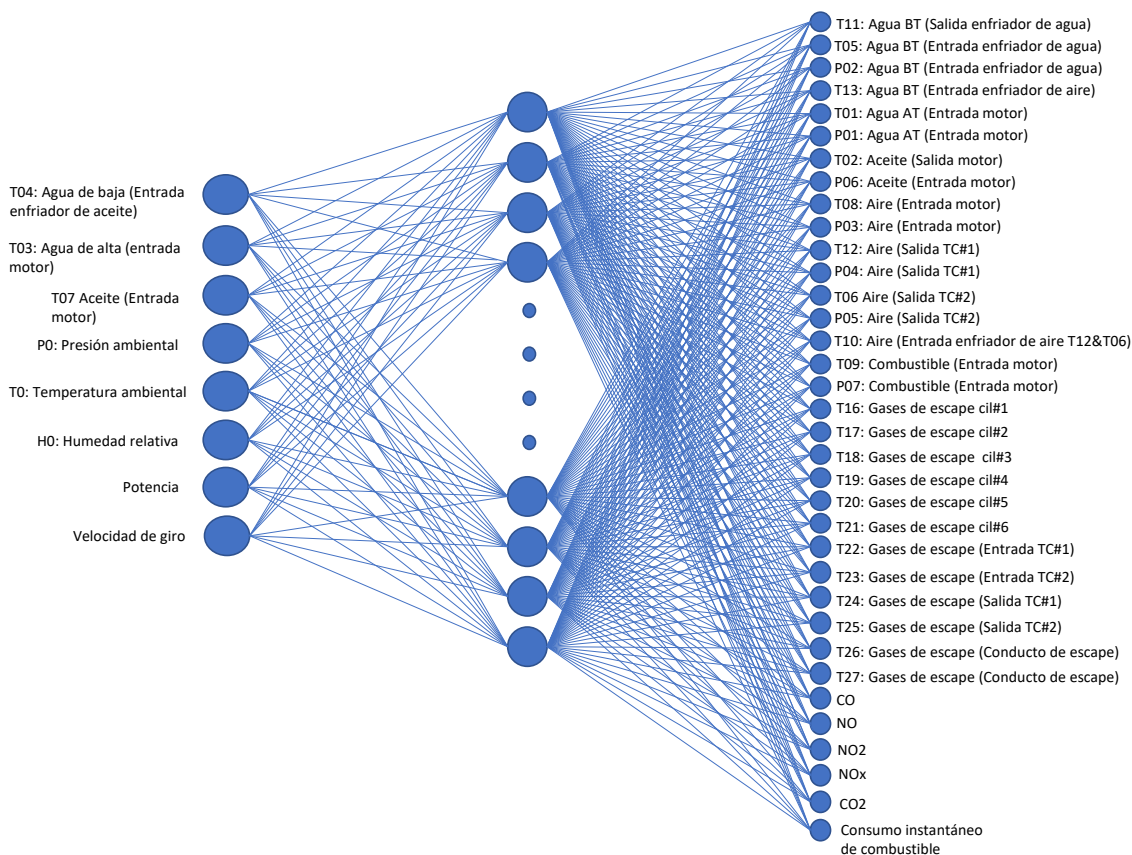


Figura C2. 6 Esquema de la red neuronal artificial desarrollada para el YANMAR 6HYM-WET

En este caso, el modelo contiene 8 inputs y 35 outputs. Entre los inputs se encuentran dos parámetros clave que definen casi en su totalidad el punto de operación en el que trabaja el motor: potencia y velocidad de giro. Además de estos, se han introducido como inputs las variables meteorológicas en las que ha trabajado el motor, ya que dependiendo de esto hay algunos factores de funcionamiento del motor que pueden variar (ej. temperatura del aire de entrada al motor). Por otro lado, se han añadido también las temperaturas de entrada al motor de algunos fluidos como el aceite (T_{07}) o la temperatura del agua del circuito de alta temperatura (T_{03}). Por último, en el apartado de banco de pruebas ya se ha mencionado que el circuito de agua de baja temperatura se refrigera con el agua del mar mediante un intercambiador instalado en el banco de pruebas. Es por ello que, a modo de tener en cuenta la temperatura a la que se encuentra el agua de mar y su posterior efecto en la temperatura del agua de baja temperatura que se utilizará para refrigerar los diferentes elementos del motor, se ha incluido dicha temperatura (T_{04}) como input en la red.

El número de neuronas de la capa oculta se ha establecido mediante el análisis del error de predicción en la fase de validación. Para ello, se han utilizado los términos de MSE y R calculados mediante las ecuaciones (19) y (20) en el Capítulo 1. En este caso, el número de neuronas testeado para la capa oculta es mayor que el testeado para la red neuronal del Minsel430a, ya que la dimensión de las capas input y output también es notablemente mayor. A diferencia del Capítulo 1, esta vez se han utilizado los errores de la fase de validación; así se evita la elección de un número de neuronas que presente bajos niveles de error debido a un sobreentrenamiento o overfitting de la red. Cada número de neuronas de la capa oculta ha sido probado 3 veces, por lo que los valores de R y de MSE presentados en este análisis son resultado de la media de los 3 intentos de entrenamiento realizados con cada número de neuronas. La Figura C2. 7 muestra los resultados obtenidos de este análisis de error.




Figura C2. 7 Resultados de R y MSE de validación para diferentes números de neuronas en la capa oculta

De acuerdo con Yan et al. [178] valores bajos de MSE inducirían una predicción de parámetros de mayor nivel de exactitud, mientras que para las redes neuronales se esperan valores altos de R. Esto es lógico, ya que el MSE representa la diferencia al cuadrado entre los valores calculados por el modelo y los valores reales que les corresponden a esos cálculos. Cuanto menor sea esa diferencia, mayor nivel de exactitud mostrará el modelo en ese cálculo. Por otro lado, R representa la regresión entre valores calculados y valores reales. Cuanto mayor sea esta regresión (más cerca esté de 1), más cerca estarán los valores calculados de los reales. El sentido físico de este término se mostrará en el siguiente apartado junto con los resultados de la red. Según la Figura C2. 7, el número de neuronas que ha presentado mayores valores de R y menores valores de MSE de media en los 3 intentos ha sido 31, por lo que la capa oculta de la presente red neuronal tendrá 31 neuronas. Por otro lado, el tiempo medio necesitado para entrenar la red neuronal en los tres intentos ha sido 400,43 segundos, cantidad notablemente mayor que los 6,8 segundos necesitados para entrenar la red neuronal del Minsel430a. Esto es lógico ya que en el presente caso de estudio la base de datos es notablemente más extensa, y las dimensiones de la red neuronal, junto con el número de factores de peso a actualizar son relativamente grandes. La CPU utilizada para los cálculos es un Intel Core i5-825U, con velocidades de hasta 3,40 GHz, 4 núcleos, 8 hilos y 8GB de memoria RAM.

Las funciones de transferencia utilizadas han sido tangente hiperbólica y lineal para la capa oculta y la capa output respectivamente. En cuanto a la partición de la base de datos para las fases de entrenamiento, validación y testeo, muchos de los trabajos que incluyen redes neuronales artificiales presentan una partición de datos que corresponde al uso del 70% para el entrenamiento, 15% para la validación y 15% para el testeo del modelo [132, 134, 194]. De hecho, en el caso de la herramienta de creación de redes neuronales Matlab Neural Network Toolbox, los valores predeterminados para el entrenamiento, validación y testeo del modelo son 70%, 15% y 15% respectivamente [195], lo que en parte hace que la mayoría de los estudios no cambien dichos ratios y por ello sean muy utilizados. Sin embargo, en casos específicos como en el caso de bases de datos de menores dimensiones, se pueden ver otro tipo de ratios, como 80% para entrenamiento y 20% para validación [120]. En el presente estudio, de los 1000 registros de la base de datos, el 70% ha sido utilizado para el entrenamiento y el 30% para la validación. Para el testeo, se ha pretendido comparar las predicciones de test de la red para registros de la base de datos, y para los puntos aleatorios del mapa de funcionamiento del motor. Por ello, se han tomado dos registros de los puntos de carga de 25% y 75% de las funciones cúbicas, sumando un total de 12 registros extraídos de la base de datos. Estos no se han utilizado en la fase de entrenamiento ni validación de la red.

Por otro lado, de cada uno de los 6 puntos aleatorios ensayados, se han tomado dos registros para testear también la capacidad de predicción del modelo en ellos. De esta forma, de los puntos aleatorios se han obtenido 12 registros de test. Por lo tanto, la base de datos utilizada para el testeo del modelo contiene 24 registros: 12 extraídos de las funciones cúbicas del motor y 12 extraídas de puntos aleatorios del mapa de funcionamiento del mismo. El objetivo del presente estudio es comparar las predicciones realizadas por la red neuronal sobre los puntos de las cúbicas (puntos cercanos a los utilizados en el entrenamiento y la validación) con las predicciones realizadas en puntos totalmente diferentes a los utilizados en el entrenamiento y validación del modelo, y que además representan condiciones aleatorias en las que podría encontrarse un motor operativo en un buque real.

3- Resultados

Una vez definido el mapa de funcionamiento y realizados los ensayos experimentales pertinentes, se ha diseñado el modelo de redes neuronales artificiales. De esta forma, el presente modelo pretende mostrar una imagen completa del motor diésel marino YANMAR 6HYM-WET para cualquier punto de funcionamiento dentro del mapa de operación del motor, considerando factores externos como una meteorología cambiante. Para ello, se ha determinado el número de neuronas en la capa oculta mediante el análisis de error en la fase de validación. El testeo del modelo se ha realizado reservando por un lado 12 puntos de la base de datos de 1000 registros, correspondientes a situaciones de carga de 25% y 75% en las funciones cúbicas del motor, y 12 registros correspondientes a situaciones de funcionamiento aleatorias dentro del mapa de funcionamiento del motor. En el presente apartado se presentarán los resultados obtenidos en la fase de testeo, siguiendo después con un análisis del error para los cálculos en esta fase.

3.1 Predicción de parámetros en fase de test

La red neuronal ha sido entrenada utilizando el ya conocido método de Levenberg-Marquardt. Una vez realizadas la fase de entrenamiento y la fase de validación del modelo, se procede a realizar el test de forma manual, es decir, introduciendo los 24 registros de test a la red de forma independiente a las fases de entrenamiento y validación, y observando cómo se comporta el modelo en esos 24 registros. Para analizar el nivel de exactitud en una fase preliminar, se han estudiado las regresiones entre los cálculos del modelo y sus respectivos outputs reales para los diferentes parámetros calculados en la red a lo largo de los 24 registros de test. Primero, se explicará el sentido de este valor de regresión, que no es sino una relación entre los resultados calculados por la red para un parámetro concreto y sus valores reales correspondientes. En la Figura C2. 8 se muestra la regresión calculada para las predicciones de los 24 registros de test de la temperatura de agua del circuito de alta temperatura a la salida del motor (T_{01}).

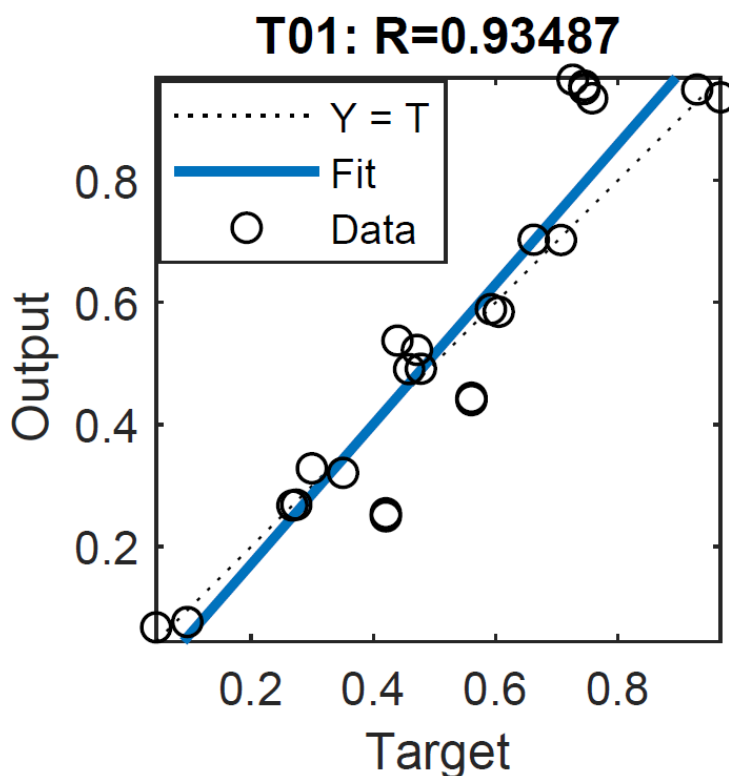


Figura C2. 8 Regresión de parámetros calculados para T01 en los registros de test

En este caso se observa por un lado el eje horizontal llamado “Target”, que representa la coordenada de los valores reales. Por otro lado, el eje vertical representa las coordenadas de los parámetros calculados por la red neuronal. Es decir, en el caso de T_{01} , para cada registro de test, por un lado, estará el valor calculado por la red, y por otro lado estará el valor real que le corresponde a ese cálculo. Si la red fuera perfecta (0 error), para un valor real de 0,2 la red debería devolver el resultado 0,2. Nótese que los valores están normalizados entre 0 y 1. Por lo tanto, si la red calculara perfectamente T_{01} para los 24 registros de test, todos los puntos recaerían en la línea diagonal del gráfico, en este caso representada por una línea discontinua. Como es de esperar, el modelo no es capaz de calcular perfectamente T_{01} para las 24 situaciones de test, por ello, los puntos no recaen exactamente en la diagonal. La línea azul representa la línea extraída de una regresión lineal entre los 24 puntos. El coeficiente de regresión en este caso es 0,93487 que es la relación entre la línea azul y la línea diagonal. Cuanto más se desvíe la línea azul de la línea diagonal, más se alejará el número R de 1. Por lo tanto, números cercanos a 1 representarán resultados calculados relativamente cercanos a sus correspondientes valores reales, lo que inducirá un alto nivel de exactitud. La Figura C2. 9 muestra las regresiones obtenidas para 16 parámetros representativos del motor. Los resultados de las regresiones obtenidas para los 35 parámetros pueden observarse en los anexos. El código de color utilizado para los resultados es el mismo que el código utilizado en la Figura C2. 3, de acuerdo con la ISO 14726 [188] para los diferentes fluidos.

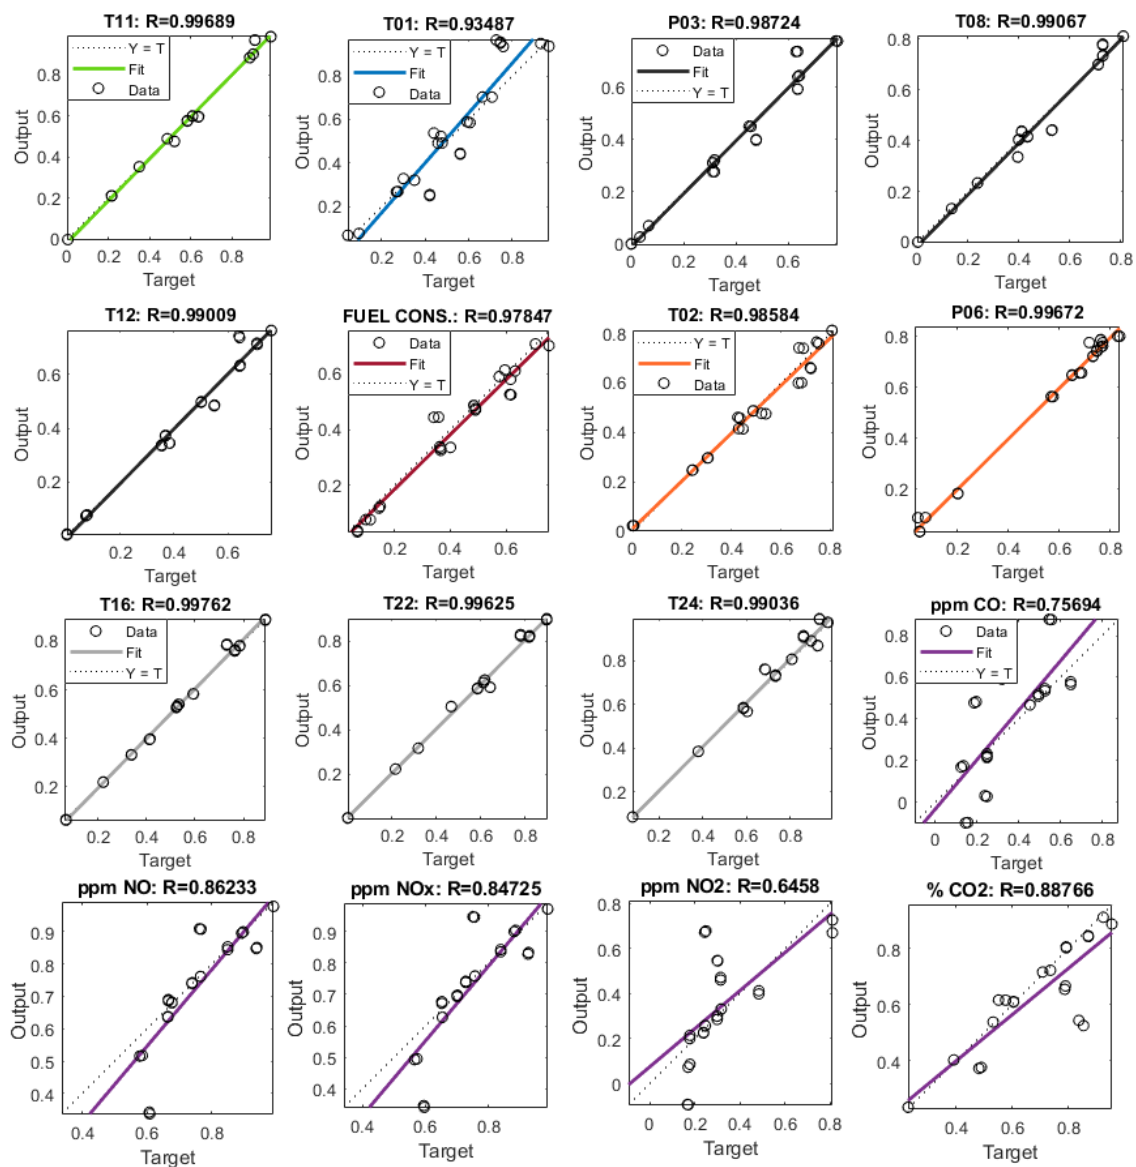



Figura C2. 9 Regresiones de 16 parámetros representativos calculados para los 24 registros de test

A primera vista, puede apreciarse que, dependiendo de cada parámetro, los valores de R para los 24 registros de test son diferentes. En algunos casos, la línea de regresión está más próxima a la diagonal, mostrando valores de R cercanos a 1, y en otros la línea difiere más notablemente, induciendo valores de R más alejados de 1. Las predicciones de temperatura del agua de baja temperatura a la salida del enfriador de agua (T_{11}) y de la temperatura de agua del circuito de alta temperatura a la salida del motor (T_{01}) muestran valores calculados muy próximos a los reales, implicando un alto nivel de exactitud para el cálculo de ambos parámetros. Por otro lado, los parámetros correspondientes al circuito de aire del motor también han mostrado un alto nivel de precisión, resultando en valores de regresión entre cálculos y valores reales cercanos a 1 para los parámetros de temperatura de aire a la salida del turbocompresor #1 (T_{12}), y temperatura (T_{08}) y presión (P_{03}) del aire a la entrada del motor. En cuanto a los circuitos de


combustible y aceite, las predicciones tanto del consumo de gasoil como de la temperatura del aceite a la salida del motor (T_{02}) y la presión del aceite a la entrada del mismo (P_{06}) también han mostrado valores de R relativamente altos, sin embargo, en algunos cálculos de consumo de combustible, puede apreciarse que algunos puntos están más alejados de la diagonal (en torno a 0,3 en eje horizontal), lo que podría acarrear valores de error de predicción más altos para algunos registros concretos de test. Sin embargo, en términos generales las predicciones están notablemente cerca de sus targets.

En muchos trabajos de investigación vistos hasta el momento, la temperatura de gases de escape se trata como un único parámetro [116, 130, 184, 196]. Sin embargo, el subsistema de gases de escape del motor contiene varios elementos a través de los cuales tanto la temperatura de los gases como la presión van cambiando de valor. Es por ello que en el presente estudio se han tomado temperaturas en varios puntos del sistema de escape, y por lo general el modelo ha predicho dichas temperaturas con muy altos niveles de precisión. Ejemplo de ello son los resultados de la temperatura de gases a la salida del cilindro #1 (T_{16}), y las temperaturas de los gases a la entrada (T_{22}) y salida (T_{24}) del turbocompresor #1 mostradas en la Figura C2. 9. El nivel de precisión y el error de cálculo del modelo para el resto de los parámetros del circuito de escape se analizará en el siguiente apartado. Por último, en cuanto a las emisiones de gases contaminantes, el nivel de precisión ha variado dependiendo del parámetro calculado. Mientras que parámetros como el NO, NO_x y CO₂ han mostrado valores de R relativamente altos, las predicciones de NO₂ y CO no han resultado estar tan próximas a los valores reales, mostrando valores de R más bajos, lo que conlleva unas líneas de regresión entre cálculos y targets más alejadas de la diagonal.


Para entender mejor el nivel de exactitud del modelo en los 24 registros de test, se han mostrado en la Figura C2. 10 los cálculos para 4 de los parámetros cuyas regresiones se han mostrado en la Figura C2. 9: consumo de combustible, presión de aire a la entrada del motor (presión de sobrealimentación, P_{03}), temperatura de gases de escape a la salida del cilindro #1 (T_{16}), y las emisiones de NO_x. Los primeros 12 puntos representados por círculos en las gráficas corresponden a los registros de test extraídos de las funciones cúbicas (de los 1000 registros de la base de datos), mientras que los 12 restantes, representados por triángulos, corresponden a los registros extraídos de puntos de operación aleatorios del mapa de funcionamiento del motor.




a. Consumo de combustible



b. P03



c. T16



d. NOx

Figura C2. 10 Resultados de test para el consumo de fuel, P03, T16 y NOx

A primera vista, de las cuatro gráficas puede observarse que el nivel de precisión de los cálculos del modelo es relativamente alto. En cuanto al tipo de registro, se puede ver que los registros extraídos de los puntos 25% y 75% de carga de las curvas cúbicas (círculos) muestran un nivel de exactitud superior a los puntos aleatorios del mapa de funcionamiento del motor. Este hecho es lógico, ya que estos puntos han sido extraídos de las curvas cúbicas del motor, y pese a que no se han utilizado explícitamente en la fase de entrenamiento y validación, los puntos utilizados en dichas fases son cercanos a estos registros de test. Sin embargo, el bajo nivel de error cometido por el modelo para los 12 registros provenientes de puntos de operación aleatorios del motor demuestra el gran potencial y la adaptabilidad de las redes neuronales.

Por otro lado, los valores de regresión logrados en la fase de testeo son valores muy apropiados para obtener una primera impresión del nivel de precisión del modelo. No obstante, es necesario un análisis más profundo para entender los resultados provistos por el modelo. Es decir, los parámetros cuyos valores de R sean los más altos no necesariamente tienen que ser los que ofrezcan menor nivel de error para cualquier punto de operación, pese a que sean de gran utilidad en una fase preliminar y a modo orientativo. Por ejemplo, las emisiones de NO_x calculadas por el modelo han mostrado un valor de R de 0,84725, que es menor que los 0,98724 y 0,97847 obtenidos para el cálculo de P_{03} y del consumo de combustible respectivamente. Esto a primera vista induciría un nivel de error mayor para las emisiones de NO_x , sin embargo, en la Figura C2. 10d puede observarse como el nivel de precisión de los cálculos de NO_x es muy alto exceptuando algunos cálculos erróneos y aislados (véanse los puntos 21 y 22 de la Figura C2. 10d). Por lo que, además de observar los valores de R provistos por el modelo, es necesario observar cómo se comporta éste testeándolo en situaciones reales y analizando su actuación de forma visual y experimental. De todos modos, parámetros cuyos valores de R sean muy cercanos a 1 como la temperatura de los gases de escape a la salida del cilindro #1 (T_{16}), con un valor de R de 0,99762 han mostrado un alto nivel de exactitud como puede verse en la Figura C2. 10c. Para entender mejor el nivel de precisión del modelo en los 35 parámetros diferentes predichos, se ha llevado a cabo un análisis de error para los 24 registros de test.

3.2 Análisis de error

El objetivo de tomar puntos aleatorios del mapa de funcionamiento del motor es analizar la capacidad de las redes neuronales de mostrar una imagen completa del motor (calculando 35 parámetros de funcionamiento y emisiones de este) en cualquier condición de la máquina, teniendo en cuenta factores externos como los meteorológicos. Como se ha mencionado en el apartado 2.4, la mayoría de los trabajos de investigación que emplean redes neuronales separan su base de datos en particiones predeterminadas (ej. 70% entrenamiento, 15% validación, 15% test), sin embargo, para entender la capacidad de regresión en puntos de operación hasta el momento desconocidos, se ha testado la red en dos grupos de registros. El primer grupo de registros contiene datos extraídos de la base de datos de entrenamiento y validación (que no se han introducido en esas fases), como se hace en la literatura existente. El segundo grupo de registros corresponde a los puntos de funcionamiento aleatorios, correspondientes a cualquier condición del motor como ya se ha mencionado previamente. En el presente análisis de error se comparará el funcionamiento de la red neuronal para ambos grupos de registros. Ya se ha visto que como era esperable los registros extraídos de las cúbicas han mostrado mejores resultados,

sin embargo, con objeto de cuantificar la diferencia de exactitud entre registros de cúbicas y aleatorios, se ha utilizado nuevamente el error porcentual absoluto medio (MAPE), cuya expresión se muestra en la ecuación 21 del Capítulo 1. Esta es una expresión ampliamente utilizada para la evaluación de funcionamiento de modelos de redes neuronales artificiales [132, 133, 183]. Por lo tanto, se han calculado dos valores de MAPE para cada uno de los 35 parámetros calculados: i) MAPE correspondiente a los 12 registros de test extraídos de las funciones cúbicas del motor; ii) MAPE correspondiente a los 12 registros de test extraídos de puntos aleatorios del mapa de funcionamiento del motor. El resultado se muestra en la Figura C2. 11.




Figura C2. 11 Valores de MAPE para registros de test de cúbicas y puntos aleatorios

A primera vista, de la Figura C2. 11 puede concluirse que los errores cometidos para las predicciones de los puntos aleatorios son mayores que los errores de los registros de test extraídos de las funciones cúbicas. Pese a que estos puntos de las funciones cúbicas no se han utilizado en la fase de entrenamiento y validación, estos puntos son cercanos a otros utilizados para dichas fases, por lo que es lógico que provean mejores resultados. Por esta razón, el análisis de la Figura C2. 11 se centrará en los errores para los cálculos de los 35 parámetros en dichos puntos aleatorios del mapa de funcionamiento del motor. Una vez más, el código de colores es el mismo utilizado en todo el capítulo, correspondiente a los diferentes fluidos utilizados en los

subsistemas del motor. Respecto a los circuitos de agua de baja y alta temperatura, todos los parámetros de dichos sistemas se han calculado con un alto nivel de precisión. Por un lado, el MAPE máximo alcanzado para el circuito de baja temperatura ha sido 4,22% para la presión del agua en la entrada del enfriador de agua (P_{02}). El resto de los parámetros, T_{11} , T_{05} y T_{13} se han mantenido por debajo del 1,89% de error (visto en T_{05}), lo que implica un alto nivel de exactitud para los parámetros calculados en el circuito de agua de baja temperatura, aun calculando dichos parámetros en puntos aleatorios del mapa de funcionamiento del motor, totalmente desconocidos para la red neuronal. En el circuito de agua de alta temperatura, los errores obtenidos son aún menores, con valores de MAPE de 0,28% y 1,29% para la temperatura del agua a la salida del motor (T_{01}) y la presión del agua a la entrada del motor (P_{01}) respectivamente. De hecho, estos son unos de los niveles de error más bajos encontrados en todo el motor, lo que implica una gran relación entre dichos parámetros y el estado de funcionamiento del motor definido por las variables de la capa input. Similarmente, la temperatura del aceite a la entrada del motor (T_{02}) y la presión a la salida (P_{06}) se han calculado con errores medios de 1,35% y 0,5% respectivamente.

Hasta este punto, los parámetros predichos por el modelo han mostrado niveles de error muy bajos, pese a estar siendo calculados para situaciones totalmente diferentes a las utilizadas para el entrenamiento y validación del modelo. Pese a mostrar errores más altos que los registros extraídos de las cúbicas del motor, estos errores siguen siendo prometedores, demostrando una alta correlación entre los inputs seleccionados y todos los outputs de los circuitos de agua de baja y alta temperatura y del circuito de aceite. Sus posibles aplicaciones en procesos de mantenimiento basado en condiciones serán estudiadas en el apartado de discusión.

Respecto al circuito de aire de entrada al motor, los valores de MAPE obtenidos son más altos que los vistos en otros subsistemas como los mencionados previamente. Concretamente, tres de los errores más altos se han encontrado en cálculos de parámetros de presión; las presiones a la salida de los compresores #1 (P_{04}) y #2 (P_{05}) y la presión a la entrada del motor (P_{03}) han sido calculadas con errores medios de 4,91% , 7,66% y 7,82% respectivamente. Este hecho será más tarde analizado también en la sección de discusión. De forma análoga, los parámetros pertenecientes al circuito de combustible han mostrado errores relativamente altos, con valores de MAPE de 8,38% y 7,97% para la presión del combustible a la entrada del motor (P_{07}) y el consumo de combustible respectivamente. Curiosamente, para el cálculo del consumo de combustible los registros extraídos de las funciones cúbicas también han provisto un nivel de error relativamente alto (6,53%), siendo uno de los errores más altos obtenidos para los registros extraídos de las funciones cúbicas.

Por lo contrario, los parámetros de temperatura calculados para el circuito de gases de escape han mostrado niveles de precisión muy altos, manteniéndose por debajo del 2,35% de error para cualquier variable del circuito de escape del motor y mostrando una gran correlación con respecto al estado de operación del motor. Además, el hecho de predecir las temperaturas de todos los cilindros por separado e individualmente permitiría en un futuro hallar fallos en cilindros concretos, observando las desviaciones del presente modelo. En este caso, el nivel de error obtenido para los diferentes cilindros es bajo y similar para todos ellos, lo que induce un funcionamiento correcto de los 6 cilindros, al menos en términos de combustión. Por último, en el caso de las emisiones predichas por el modelo, el nivel de exactitud depende del parámetro que se trate. Por un lado, se han logrado errores de 25,6% y 48,84% para el cálculo de CO y NO₂ respectivamente. Estos errores no son aceptables si se desea llevar a cabo un proceso de identificación de fallos o el desarrollo de un gemelo digital, ya que no mostrarían valores útiles para representar la evolución de dichos parámetros con respecto al punto de operación del motor. Por otro lado, los valores de MAPE obtenidos para NO, NO_x y CO₂ son 6,51%, 7,32% y 5,71% respectivamente, manteniéndose en el rango de error de otros parámetros del motor. El tiempo de cálculo para los 24 registros de test conteniendo predicciones de los 35 parámetros del motor ha sido de 0,109 segundos. Este puede ser considerado un tiempo de cálculo reducido, lo que hace de este tipo de metodología una alternativa interesante para aplicaciones de detección de fallos en tiempo real.

A modo de resumen, en la Figura C2. 12 se muestran los errores MAPE alcanzados para los registros de test de puntos aleatorios del mapa de funcionamiento del motor. De esta forma, mediante el modelo desarrollado se puede mostrar en tiempo real el error cometido para cada parámetro del motor. Si este error superase un umbral podrían identificarse diferentes fallos en varios subsistemas del motor antes de que ocurran. Alternativamente, en caso de ser necesario, en lugar de mostrar los errores, podrían mostrarse los valores calculados por el modelo en tiempo real, con su error correspondiente al lado. De esta forma, se muestra una imagen completa del motor para cualquier punto operativo dentro de su mapa de funcionamiento (incluyendo factores externos cambiantes), sirviendo como gemelo digital con tiempos de cálculo muy reducidos. En el Capítulo 3 de la presente tesis se analizarán las posibles desviaciones de un motor operativo en un buque de pesca real, en el que se determinarán los valores límite de desviación de un motor sano en funcionamiento. De esta forma, las herramientas de modelado presentadas hasta el momento junto con valores límites basados en buques de pesca operativos completarán lo que se puede llamar una metodología para lograr gemelos digitales capaces de mostrar el estado del motor en tiempo real.

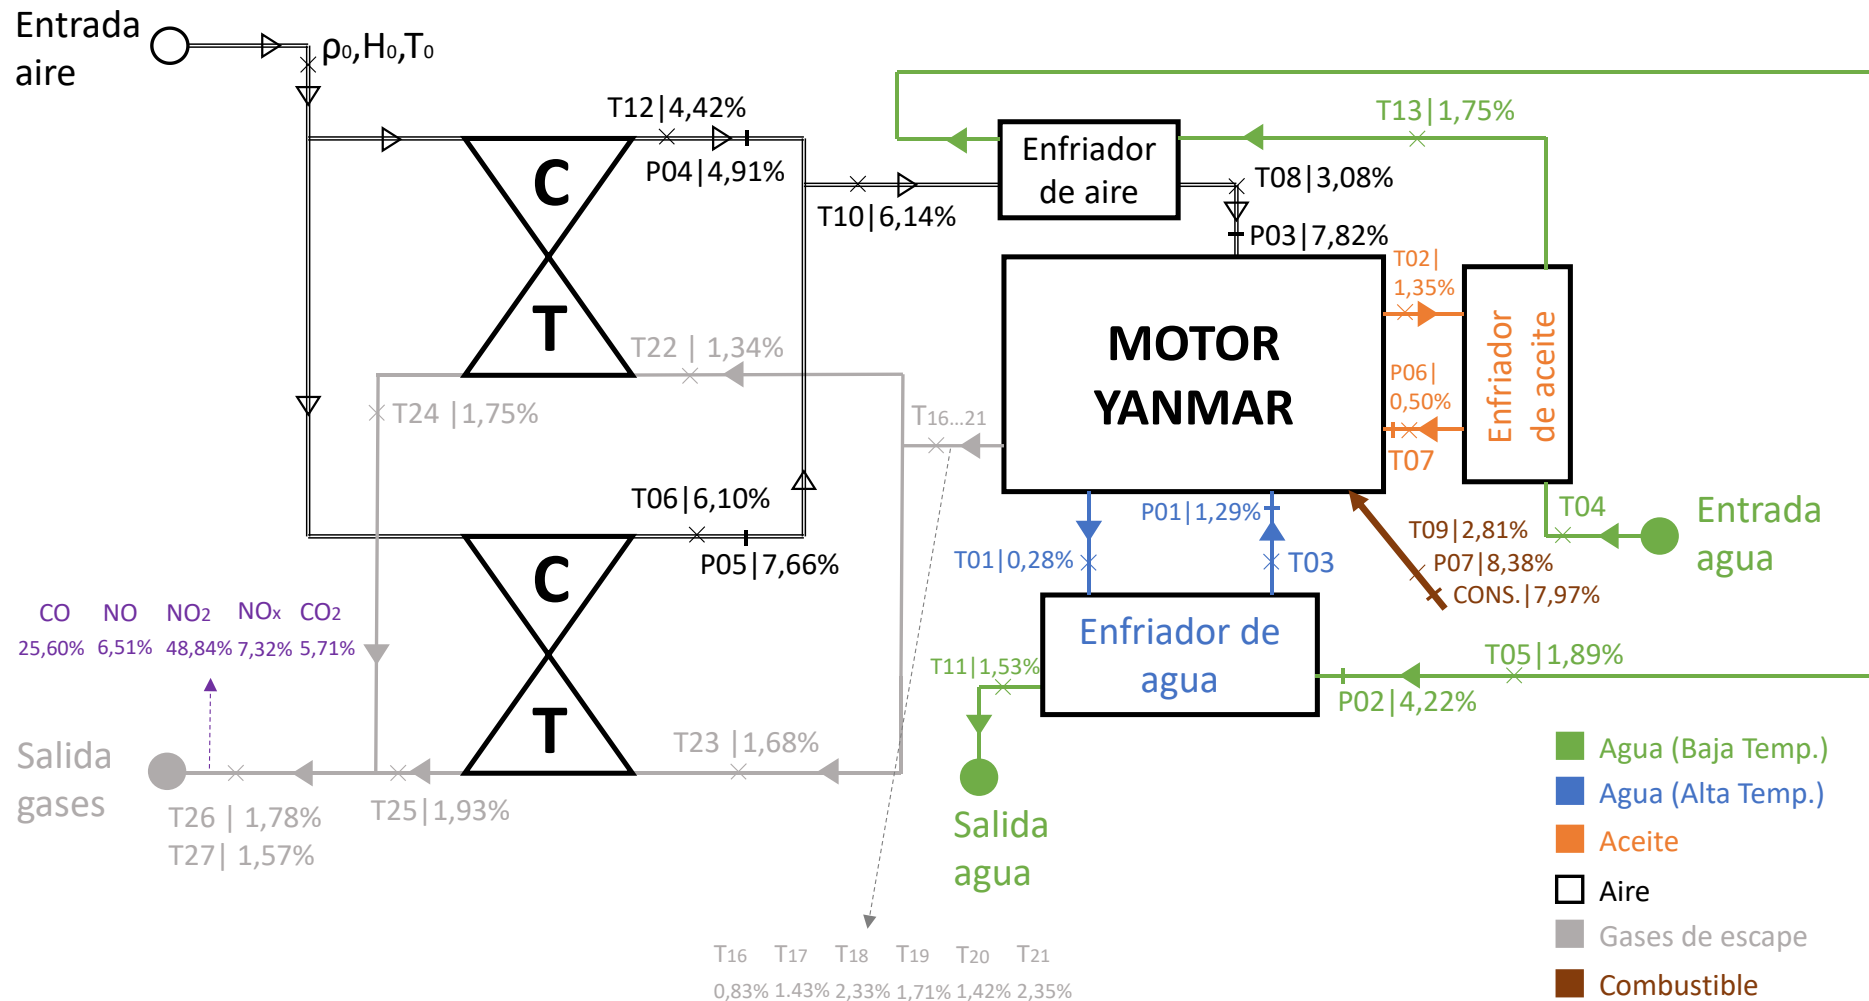


Figura C2. 12 Resultados de errores MAPE para el test en puntos aleatorios de funcionamiento

4- Discusión

En el presente capítulo de la tesis, se ha estudiado la capacidad de generalización y adaptabilidad de las redes neuronales artificiales para mostrar la imagen completa de un motor en cualquier punto aleatorio de su mapa de funcionamiento. Hasta la fecha, se han publicado varios artículos en torno al análisis del overfitting o exceso de entrenamiento de los modelos. Y es que, si un modelo de redes neuronales se entrena con demasiadas iteraciones o la base de datos no contiene dimensiones suficientemente grandes, puede ocurrir que la red neuronal se centre demasiado en los datos de entrenamiento y no muestre altos niveles de exactitud en la fase de testeo. En este aspecto, Wong et al. [197] observaron que las redes neuronales artificiales pueden presentar la desventaja de tender a dicho exceso de entrenamiento o presentar dificultades a la hora de establecer la estructura óptima de la red.

En el presente caso de estudio, la determinación de la estructura de la red se ha llevado a cabo mediante el análisis del error de validación de esta. Por otro lado, Niu et al. [194] compararon el funcionamiento de las redes neuronales artificiales y las Support Vector Machine para predecir 5 parámetros de funcionamiento y emisiones (ej. BSFC, NO_x) concluyendo que las redes neuronales podrían tender a sobre entrenarse si el número de registros utilizado en el entrenamiento es reducido, resultando en niveles de error inestables para las predicciones del modelo. Sin embargo, en el presente estudio se han conducido numerosos ensayos experimentales, resultando en una base de datos de 1000 registros x 43 variables del motor que se han utilizado para el entrenamiento y validación del motor, para después testear el modelo en zonas aleatorias del espectro de funcionamiento completo de este. Es cierto que el tiempo necesitado para el entrenamiento ha sido relativamente alto (400,43 segundos) en comparación a otros estudios que han empleado el algoritmo de Levenberg-Marquardt [124], en parte debido al gran número de outputs incluidos en una misma red. Sin embargo, una vez entrenada la red, el tiempo de cálculo necesitado para calcular los 24 registros de test ha resultado ser muy reducido (0,109 segundos). Esta es una de las razones por la que este tipo de metodologías basadas en los datos resultan muy interesantes, ya que en comparación a otros métodos de modelado basados en ecuaciones físicas muestran altos niveles de exactitud en tiempos de cálculo notablemente menores [126]. Por ello, las redes neuronales artificiales se presentan como una herramienta muy compatible con las aplicaciones de modelado en tiempo real. Es más, mediante el registro de relativamente pocas variables como el par del motor, la velocidad de giro, variables ambientales y algunas más, el modelo es capaz de mostrar la imagen completa

del estado del motor, calculando parámetros de funcionamiento y emisiones a lo largo de todo el motor.

De acuerdo con la Figura C2. 10, los resultados para los registros de test extraídos de las cúbicas del motor han mostrado altos niveles de exactitud. Esto es lógico ya que estos puntos se encuentran próximos a los puntos utilizados para el entrenamiento y validación de la red. Si se siguiera la metodología de separado predeterminada utilizada en otros estudios (ej. 70%, 15% y 15% para entrenamiento, validación y testeo), se obtendrían estos resultados, haciendo parecer que las redes neuronales son capaces de reproducir el funcionamiento del motor con muy altos niveles de exactitud. Sin embargo, esto no sería completamente aplicable a condiciones reales de funcionamiento del motor. En el apartado 2.2 ya se ha mencionado que el mapa de funcionamiento del motor no atiende a una única cúbica, sino a una región de posibles combinaciones entre carga y velocidad de giro del motor, influenciadas por condiciones externas como la meteorología en el caso del ámbito marino. Por ello, se ha pretendido analizar cómo trabaja el modelo en puntos totalmente aleatorios del mapa de funcionamiento del motor. Concretamente, para estos puntos aleatorios se ha observado también un nivel de precisión relativamente alto en el análisis de error. En cuanto a los parámetros, algunos han sido utilizados más habitualmente que otros en trabajos de investigación en torno al modelado de motores diésel. En el caso de las temperaturas de gases de escape, estas han sido utilizadas en numerosos estudios, algunos de los cuales se mencionarán a continuación. No obstante, normalmente este es un parámetro que se considera como uno solo, sin diferenciar entre la temperatura de los gases a lo largo de los diferentes elementos del sistema de escape como en el presente estudio. El error más alto visto en este caso de estudio en el subsistema de gases de escape corresponde a la temperatura de los gases a la salida del cilindro #6 (T_{21}) con 2,35%; aun así, este nivel de error está en el rango de errores visto para la predicción de temperatura de gases de escape en otros estudios que han incluido cantidades de outputs notablemente menores. Por ejemplo, Parlak et al. [116] predijeron el consumo específico de combustible y la temperatura de gases de escape en un motor diésel de un cilindro mediante redes neuronales artificiales, logrando valores de MAPE de 2,36% para la predicción de T_{exh} . Similarmente, Cay et al. [135] lograron valores de MAPE de 3,14% para este parámetro, aun diseñando una red neuronal diferente por cada output a calcular. Se observa pues, que tanto en el presente estudio como en otros estudios relacionados con la predicción de la temperatura de gases de escape, este parámetro es calculado con bajos niveles de error, demostrando una alta correlación con respecto al funcionamiento del motor.

En cuanto a la temperatura y presión del aceite, el error de predicción también ha resultado ser relativamente bajo, con valores de MAPE 1,5% y 0,5% para T_{02} y P_{06} respectivamente. Porteiro et al. [139] desarrollaron un modelo para predecir la carga de potencia del motor y el estado del mismo mediante redes neuronales artificiales. Tras varios intentos, descartaron las temperaturas del refrigerante y del aceite del motor de entre los inputs de su modelo, defendiendo que eran parámetros innecesarios. Sin embargo, según Khelil et al. [141], la temperatura y la presión del aceite del motor pueden ser buenos indicadores de diferentes situaciones de fallo como el derrame de aceite o el desgaste de la bomba de aceite. Por consiguiente, y observando el nivel de precisión logrado en el presente estudio para dichos parámetros, se concluye que podrían ser suficientemente fiables para la identificación de los fallos mencionados.

Como se ha mencionado previamente, algunos parámetros han sido más empleados que otros en los trabajos de investigación de modelado de motores. Por ejemplo, las variables de los circuitos de agua del motor raramente han sido incluidas en los modelos. En algunos pocos estudios han sido consideradas en la capa de input de las redes neuronales artificiales [198, 199]. Pese a no ser frecuentemente utilizados en modelos de redes neuronales, según un estudio reciente realizado por Yao et al. [200], parámetros como la temperatura o la presión del agua guardan una muy alta correlación con los posibles fallos del sistema de refrigeración de los motores diésel marinos. En el presente estudio, todos los parámetros de los circuitos de agua de baja y alta temperatura han mostrado errores por debajo de 4,22%, por lo que estos parámetros podrían ser utilizados para la identificación de fallos mediante la observación de desviaciones entre modelo y valores reales. En cuanto al circuito de aire de entrada del motor, tres de los errores más altos corresponden a los cálculos de presiones manométricas del aire a la salida de los dos turbocompresores (P_{04} , P_{05}) y la presión a la entrada del motor (P_{03}). Tras analizar estos tres parámetros en la base de datos, se ha observado que a lo largo de todas las pruebas su rango de variación ha sido relativamente reducido. Esto no significa que no guarden una alta correlación respecto al funcionamiento de motor, sino que, debido a su tipología, son parámetros cuyo rango de variación se mueve entre dos números relativamente bajos. Por ejemplo, tras observar la presión del aire a la entrada del motor (P_{03}), este parámetro ha variado desde 0,09 hasta 1,63 bar en los diferentes ensayos experimentales. Esto significa que un error de 0,1 bar induciría un error porcentual de 5,81%. Por ello, es conveniente que además de estudiar los errores relativos porcentuales también se observen los errores absolutos, ya que un error de 0,1-0,2 bar podría no ser causa de un fallo en el sistema de aire de entrada.

En cuanto a las emisiones de gases contaminantes, los niveles de error han dependido de cada parámetro. Por ejemplo, el valor de MAPE alcanzado para el cálculo de NO_x es 7,32% para los puntos aleatorios del mapa de funcionamiento, que se mantiene en el rango de otros estudios que también han calculado las emisiones de NO_x mediante redes neuronales artificiales. Tosun et al. [201] alcanzaron errores de 9,53% para la predicción de NO_x en un estudio que comparaba el cálculo mediante regresión lineal con el cálculo mediante redes neuronales artificiales en un motor diésel que empleaba mezclas de biodiésel y alcohol. Noor et al. [133] alcanzaron valores de MAPE de 9,32% tras comparar la predicción de varios parámetros de un motor diésel mediante modelos matemáticos y redes neuronales artificiales en un motor diésel marino. Las emisiones de NO y CO_2 también han mostrado errores relativamente bajos, con valores de MAPE de 6,51% y 5,71% respectivamente. En el caso de las emisiones de CO_2 , algunos trabajos de la literatura existente han logrado alcanzar errores más bajos que el obtenido en el presente estudio. Por ejemplo, Roy et al. [136] alcanzaron un error porcentual de 2,54% para el cálculo de CO_2 tras calcular este parámetro junto con otros 4 como el BSFC o las emisiones de partículas en un motor de un solo cilindro con sistema de inyección Common Rail. Arcaklioglu et al. [202] alcanzaron valores de MAPE de 3,05% también para CO_2 entre 8 parámetros diferentes calculados como el BMEP del motor o el par. Sin embargo, en este caso se diseñó una red neuronal específica para cada output calculado. En este caso, las emisiones de CO_2 han sido calculadas entre otros 35 outputs, por lo que se considera que el error alcanzado es aceptable.

Sin embargo, el cálculo de emisiones de NO_2 y de CO han presentado errores inaceptables para cualquier proceso de modelado. Errores de 25,6% y 48,84% muestran una baja correlación entre el funcionamiento del motor (o al menos los inputs escogidos) y estas dos variables. Por un lado, las emisiones de NO_2 son casi despreciables en el caso de este tipo de motores diésel en comparación a otras emisiones como las NO . Mientras que NO_2 ha variado desde 6,8 a 46,3 ppm en el presente estudio, las emisiones de NO han tomado valores de 497 a 1143 ppm. Es más, atendiendo a la unidad de parte por millón (ppm), 46,3 ppm es una cantidad muy reducida de concentración como para poder calcular este valor con precisión, lo que ha llevado al modelo a mostrar altos errores. Por lo tanto, se recomienda la no inclusión de este parámetro como parámetro único por separado para el mantenimiento basado en condiciones o la identificación de fallos mediante el análisis de desviaciones, ya que podría provocar numerosas falsas alarmas. Además, este parámetro ya está contemplado en las emisiones de NO_x que también han sido calculadas mediante el modelo, con altos niveles de exactitud. Respecto a las emisiones de CO , recientemente se ha llegado a la conclusión de que las emisiones de CO son muy reducidas en comparación a otros parámetros de emisiones, aun cuando se emplean combustibles

alternativos [121]. Este factor podría en parte explicar el alto error en el cálculo de CO, tanto en este estudio como en otros trabajos de investigación que han predicho emisiones de CO [123, 183] de forma análoga al fenómeno ocurrido con NO₂. Este hecho también se ha dado en el Capítulo 1 de la presente tesis, en el que la predicción de emisiones de CO mostró los errores más altos tanto para el modelo termodinámico como para el modelo de redes neuronales. Esto debería ser considerado a la hora de establecer valores límite para las emisiones de CO como indicador de posibles fallos del motor en futuros estudios. Además, la incertidumbre del sistema de adquisición para el registro de CO (± 10 ppm) también podría ser el causante de un error más elevado. Una posible solución para reducir estos niveles de error podría ser la inclusión de otros parámetros adicionales en la capa input, que contengan una gran correlación con respecto a estos parámetros de emisiones, como por ejemplo el avance de la inyección o la estrategia de inyección. Agarwal et al. [203] concluyeron que una inyección avanzada hacía decrecer las emisiones de CO₂ y de HC mientras que incrementaba los NO_x. How et al. [204] probaron que dividir la inyección en varias etapas podría reducir las emisiones de NO_x junto con un ajuste apropiado del avance de la inyección. Por lo tanto, con ánimo de mejorar el nivel de precisión del cálculo de emisiones, podrían considerarse este tipo de parámetros, siempre que estuvieran registrables durante los ensayos experimentales.

Por último, tras observar el circuito de combustible del motor, los cálculos de la temperatura (T_{09}) y presión (P_{07}) del combustible han mostrado niveles de error relativamente altos. Durante los ensayos experimentales, se han variado la potencia y velocidad de giro del motor para testear las diferentes funciones cúbicas del motor, pero la temperatura y presión del combustible no han cambiado notablemente con las diferentes condiciones de la máquina. Esto podría estar causado por una correlación baja entre estos parámetros y la condición del motor, lo que ha podido ocasionar errores mayores. De hecho, hay algunos parámetros cuya tendencia no es cambiante con la condición del motor, sino que están diseñados para mantener una tendencia constante o poco variable. Este tipo de parámetros podrían estudiarse con estrategias de modelado alternativas, como las funciones de densidad de probabilidad como se verá en el último capítulo de la tesis. Por último, el consumo de combustible del motor ha mostrado un error de 7,97% en los puntos aleatorios. Curiosamente, el error de los registros extraídos por las funciones cúbicas recae en el mismo rango con 6,53% de error. Esto hace concluir que no es un problema de baja correlación entre el consumo de combustible y el funcionamiento del motor. De hecho, muchos trabajos de investigación han incluido esta variable debido a su gran relación con el funcionamiento de la máquina, y es que, es lógico que según en la condición que se encuentre el motor, este consumirá más o menos combustible. Ese error ligeramente elevado

tanto en las funciones cúbicas como en los puntos aleatorios ha sido causado por la variabilidad del caudalímetro instalado en el banco de pruebas. Si se tomaran promedios de varios registros, este error debería ir decreciendo, a medida que la señal del consumo de combustible se estabiliza. De todos modos, el error sigue siendo aceptable para tener una imagen próxima al consumo real.

Si se observan valores límite de desviaciones para condiciones de fallo del motor establecidas en otros estudios, la conclusión principal es que los errores presentados en este estudio están en su mayoría por debajo del umbral de estos valores límite, por lo que podrían ser útiles en aplicaciones de detección de fallos en motores. Basurko et al. [36] establecieron valores límite de desviaciones entre red neuronal y valores reales de 5-8% para diferentes situaciones de fallo (ej. mala inyección). Rubio et al. [98] desarrollaron un simulador de situaciones de fallo mediante un modelo, en el que el fenómeno de una mala combustión se representaba mediante una reducción del 25% y 50% en el consumo de combustible, valores notablemente mayores que los errores logrados en este estudio. Por lo tanto, el nivel de precisión logrado para 33 de los 35 parámetros del motor incluso en puntos aleatorios del mapa de funcionamiento de este, demuestran la adaptabilidad y capacidad de generalización de las redes neuronales artificiales, aun considerando grandes dimensiones de outputs a calcular simultáneamente.

5- Conclusiones

En el presente estudio se ha analizado la robustez de las redes neuronales artificiales para predecir simultáneamente múltiples parámetros de funcionamiento y emisiones de un motor diésel marino en su mapa de funcionamiento completo. Para ello, se han calculado 35 parámetros de funcionamiento y emisiones al mismo tiempo, para condiciones de operación diferentes del motor, cubriendo el espectro completo de funcionamiento de este. Primero, se ha propuesto un modelo de redes neuronales, hallando la estructura óptima para después entrenar y validar la red con datos extraídos de numerosos ensayos experimentales. Para ello, se han registrado las variables del motor a lo largo de las diferentes funciones cúbicas de su mapa de funcionamiento, simulando condiciones provocadas por factores externos como la meteorología cambiante. Adicionalmente, se han ensayado algunos puntos de operación aleatorios del motor, para después analizar la capacidad de regresión de las redes neuronales artificiales en dichos puntos aleatorios del mapa de funcionamiento de la máquina.

El nivel de precisión del modelo de redes neuronales artificiales ha demostrado ser notablemente alto para la mayoría de los parámetros calculados por el modelo, aun trabajando en puntos aleatorios del mapa de funcionamiento del motor. De esta forma, se ha creado un modelo capaz de simular un motor diésel marino con altos niveles de precisión y tiempos de cálculo muy reducidos. Del presente estudio, se han extraído las siguientes conclusiones:

- Las redes neuronales artificiales han sido capaces de predecir 35 parámetros de funcionamiento y emisiones del motor (exceptuando dos) con valores de MAPE por debajo de 8,5%, aun prediciendo dichos parámetros en condiciones aleatorias del mapa de funcionamiento del motor.
- Los circuitos de agua de baja y alta temperatura, el circuito de aceite y el de gases de escape han mostrado los niveles de precisión más altos, alcanzado errores de MAPE por debajo de 4,3% para todos sus parámetros. Estos niveles de error remarcan el potencial de las redes neuronales artificiales para crear gemelos digitales de los motores, mostrando una imagen precisa y completa del estado del motor para cualquier condición de este.
- El tiempo de cálculo necesitado para predecir 35 parámetros en 24 situaciones diferentes ha sido de 0,109 segundos, que junto con el alto nivel de exactitud logrado muestra el gran potencial de las redes neuronales artificiales para aplicaciones en tiempo real. Esto, junto con un análisis de desviaciones entre modelo y realidad de diferentes parámetros del motor puede ser una herramienta muy útil para la predicción de fallos del motor en tiempo real.
- En caso de contener una base de datos de dimensiones suficientemente grandes, la capacidad de generalización de las redes neuronales tras ser entrenada con dicha base de datos es notablemente alta, aun trabajando en condiciones aleatorias no vistas hasta el momento. Por lo tanto, se demuestra su gran potencial aun considerando factores externos que podrían variar el funcionamiento de los motores (ej. meteorología).

Por lo tanto, en el presente estudio se ha demostrado que las redes neuronales son una herramienta de modelado fiable, presentando niveles de error relativamente bajos aun calculando múltiples outputs simultáneamente. Futuros trabajos de investigación podrían analizar qué desviaciones son necesarias entre este tipo de modelos y valores reales para identificar situaciones de fallo en el motor. Esto podría llevarse a cabo en buques en operativa real, analizando cómo se comporta el modelo en alta mar. En el presente estudio se ha demostrado la capacidad de estas herramientas para predecir los parámetros del motor en

condiciones cambiantes, por lo que las redes neuronales se postulan como una herramienta muy eficaz para ser utilizada en procesos de mantenimiento basado en condiciones o creación de gemelos digitales.

CAPÍTULO 3. Caracterización de valores límite de desviaciones de múltiples parámetros de funcionamiento de un motor diésel a bordo de un buque atunero mediante redes neuronales artificiales y funciones de densidad de probabilidad

Nomenclatura

<i>Acrónimos</i>		dP_{LO}^{filter}	Presión diferencial del aceite en el filtro
ANN	Red neuronal artificial	T_{LO}	Temperatura del aceite
CO	Monóxido de carbono	P_{LO}^{TCin}	Presión del aceite a la entrada del turbocompresor
GT	Gross tonage	T_{LO}^{TCout}	Temperatura del aceite a la salida del turbocompresor
IMEP	Presión media efectiva indicada	P_{HTCW}	Presión del agua de alta temperatura
MAPE	Error porcentual medio absoluto	P_{LTCW}^{CACin}	Presión del agua de baja temperatura a la salida del enfriador de aire
MSE	Error cuadrático medio	T_{JCW}^{in}	Temperatura del agua de refrigeración a la entrada de camisas
NO₂	Dióxido de nitrógeno	T_{JCW}^{out}	Temperatura del agua de refrigeración a la salida de camisas
PDF	Función de densidad de probabilidad	T_{HTCW}^{CACout}	Temperatura del agua de alta temperatura a la salida del enfriador de aire
\bar{r}	Correlación media	T_{LTCW}^{CACin}	Temperatura del agua de baja temperatura a la entrada del enfriador de aire
R	Coeficiente de regresión	T_{LTCW}^{LOCout}	Temperatura del agua de baja temperatura a la salida del enfriador de aceite
RSD	Desviación estándar relativa	$T_{exh}^{C01-C09}$	Temperatura de gases de escape de cilindros 01-09
RSS	Suma residual de cuadrados	T_{EXH}^{Avg}	Temperatura media de gases de escape
S_d	Desviación estándar	T_{EXH}^{TCin}	Temperatura de gases de escape a la entrada del turbocompresor
T_{exh}	Temperatura de gases de escape	T_{EXH}^{TCout}	Temperatura de gases de escape a la salida del turbocompresor
<i>Parámetros</i>		RPM^{TC}	Velocidad de giro del turbocompresor
FOP	Presión de combustible	T_{AIR}^{CYLin}	Temperatura del aire de entrada a los cilindros
T_{FO}^{in}	Temperatura de combustible a la entrada del motor	T_{COJ}^{00-10}	Temperaturas 0-10 de los cojinetes
T_{FO}^{out}	Temperatura de combustible a la salida del motor	T_{CR}^{01-09}	Temperaturas 1-9 de cigüeñal
P_{LO}	Presión de aceite	T_{CVL}^{01-09}	Temperaturas 1-9 de cilindros
P_{LO}^{filter}	Presión del aceite a la entrada del filtro	FORACK	Posición de cremallera de bomba de combustible
		dTFO	Temperatura diferencial del combustible

1- Resumen

El mantenimiento basado en condiciones de los sistemas de propulsión marinos se ha convertido en un campo de estudio de creciente interés en términos financieros y de seguridad. En este marco, muchos estudios se han centrado en llevar a cabo procesos de mantenimiento o diagnóstico basados en modelos o gemelos digitales de los motores para la identificación de situaciones de fallo. Sin embargo, los valores límite entre un motor en funcionamiento sano y un motor en situación de fallo no han sido analizados en profundidad. En consecuencia, este capítulo tiene como objeto analizar y determinar dichos valores límite en múltiples parámetros de un motor diésel marino en operativa real. Para ello, se ha analizado un buque atunero de pesca en operación, registrando hasta 61 variables diferentes del motor durante el año 2020 y la primera mitad del año 2021, procesando hasta 5.181 horas de funcionamiento de su motor principal sin ningún fallo. El análisis preliminar de correlación y desviación ha proporcionado información valiosa para sugerir modelar algunos parámetros con tendencias constantes empleando técnicas de modelado alternativas. Por ello, dichos parámetros con niveles bajos de desviación relativa y correlación durante el año 2020 se han modelado utilizando funciones de densidad de probabilidad. Utilizando la base de datos del año completo de 2020, se han establecido intervalos de confianza del 98% para estos parámetros. Por otro lado, los parámetros con mayores niveles de correlación y desviación se han modelado con redes neuronales artificiales. Se han propuesto cuatro redes neuronales diferentes, una por cada subsistema a modelar, y se han entrenado, validado y testeado con datos del año completo de 2020, calculando el error porcentual medio absoluto para todos los parámetros calculados. Finalmente, los datos registrados durante el año 2021 se han utilizado para validar, por un lado, los límites establecidos mediante los intervalos de confianza de las funciones de densidad de probabilidad, y por otro lado, los límites establecidos mediante los errores entre redes neuronales y valores reales. Para los datos de 2021, los intervalos de confianza han mostrado un ratio máximo de fallo del 1,21%. Alternativamente, los parámetros modelados mediante redes neuronales artificiales han mostrado errores de 1,1%, 1,22% y 1,95% para los subsistemas de funcionamiento, refrigeración y cilindros respectivamente. Como conclusión, se han resumido todos los valores límite establecidos en el presente estudio, mostrando valores límite de 57 parámetros diferentes basados en año y medio de operativa real de un buque pesquero, y que servirán como punto de referencia para futuros trabajos de detección de fallos de motores para establecer desviaciones representativas de fallos del motor.

Abstract

Condition-based maintenance of marine propulsion systems has increasingly become a focus of interest in safety-related and in financial terms. Many research papers have studied different marine diesel engine modelling and fault identification techniques. However, the thresholds between a healthy engine and a faulty one have not been deeply analysed. This contribution thus aimed to determine healthy engine threshold values for multiple parameters of a marine diesel engine. For that, an operative commercial fishing vessel was considered, measuring multiple engine performance variables through 2020 and the first half of 2021, totalling 5181 operating hours of the main engine without any fault occurrence. Preliminary correlation and relative deviation studies suggested analysing some constant trend parameters with alternative modelling techniques. Hence, Probability density functions (PDF) were used, establishing confidence intervals for such parameters with data from the whole year of 2020. The highest correlation and deviation parameters were alternatively modelled using artificial neural networks (ANN). Four different ANNs were thus trained, validated and tested with data from 2020, calculating mean absolute percentage errors for all predicted parameters. Finally, data from 2021 was used to validate both PDF modelled and ANN modelled parameter thresholds set in 2020. For the 2021 data, confidence intervals set with PDF showed a maximum failure rate of 1.21%. Alternatively, ANN modelled parameters showed maximum percentage errors of 1.1%, 1.22% and 1.95% for engine performance, cooling and cylinder subsystems respectively. Finally, all obtained thresholds were summarized, providing a good source to establish faulty engine threshold values in future fault detection studies.

2- Material y métodos

2.1 Adquisición de datos a bordo de un buque operativo

Para el presente caso de estudio, se ha analizado el funcionamiento de un motor instalado a bordo de un buque cerquero atunero congelador durante el año 2020 y el año 2021. Por causa de términos de confidencialidad, tanto el nombre como las características reales del motor no se desvelarán. Sin embargo, sin pérdida de generalidad, se mostrarán valores aproximados e indicativos de este motor. El motor analizado contiene 9 cilindros en línea, siendo un motor de mayores dimensiones que el motor empleado en el segundo capítulo de la presente tesis, ya que el tipo de buque en el que está instalado es un buque atunero de mayor porte que el tipo de buque en el que se emplea el motor del Capítulo 2 (del orden de 2000-3000 GTs), cuyas dimensiones se asemejan a las del buque mostrado en la Figura C3. 1, mostrado sólo con carácter ilustrativo. Este motor tiene un solo turbocompresor y está refrigerado con agua de mar. Sus características se muestran en la Tabla C3. 1.



Figura C3. 1 Buque cerquero atunero congelador de similares características al empleado en el estudio. Fuente: Industrias Pesqueras

Tabla C3. 1 Características del motor estudiado

Parámetro	Valor	Unidad
Tipo de ciclo	4 tiempos	[-]
Nº de cilindros	9	[-]
Velocidad de giro nominal	750	Rpm
Potencia nominal	4.500	kW
Diámetro	320	mm
Carrera	460	mm
Carga de aire	Turbocompresor	[-]

En este último capítulo de la tesis, se han procesado un total de 61 parámetros pertenecientes al sistema de propulsión de un buque atunero operativo. Para ello, estos parámetros se han registrado durante el año 2020 y la primera mitad del año 2021 con una frecuencia de muestreo de 1 registro/10 segundos. Primero, los datos obtenidos durante el año 2020 han sido filtrados y procesados para después establecer valores límite para todos los parámetros mediante diferentes técnicas de modelado. Una vez establecidos dichos valores límite, los datos registrados en la primera mitad del año 2021 han sido utilizados para validar los valores límite establecidos previamente. El esquema del proceso de adquisición de datos se presenta en la Figura C3. 2.

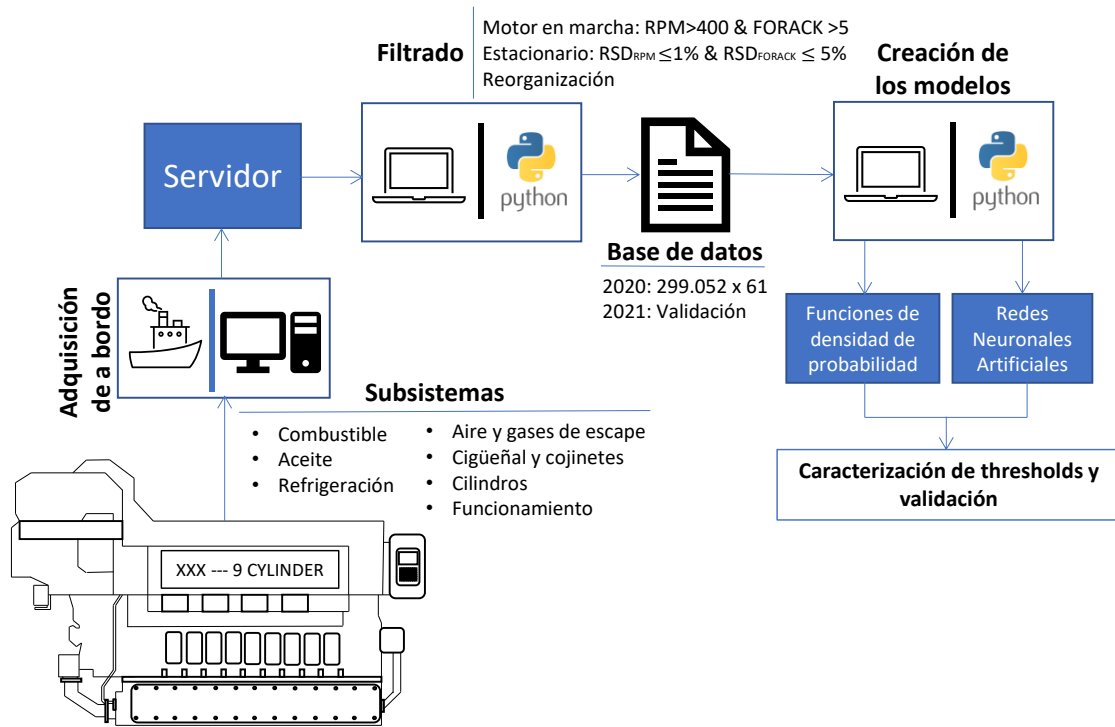


Figura C3. 2 Esquema de adquisición de datos a bordo de buque atunero

Debido a la gran cantidad de variables que se han registrado para este análisis, los parámetros se han separado en 7 subgrupos dependiendo del subsistema del motor al que pertenecen. Esta no es sino una forma de organizar los parámetros para después poder conducir el análisis de una forma más ordenada. Además, los parámetros pertenecientes a un mismo subsistema del motor guardan correlación entre ellos, lo que después será importante a la hora de proponer las redes neuronales artificiales para calcularlos. Como puede verse en la Figura C3. 2, los 7 subgrupos creados para el procesamiento de los datos son: grupo de combustible, grupo de aceite lubricante del motor, grupo de sistema de refrigeración, grupo de aire de entrada al motor y gases de escape de este, grupo de parámetros en torno al cigüeñal y los cojinetes, grupo de parámetros de los cilindros y grupo de parámetros de funcionamiento del motor. En este último subsistema se han añadido los parámetros que de alguna forma caracterizan el funcionamiento del motor. En la Tabla C3. 2 se muestra la instrumentación utilizada para cada parámetro de cada subsistema considerado, junto con la incertidumbre de cada instrumento.

Tabla C3. 2 Instrumentación de adquisición de datos e incertidumbres

Subsistema	ID	Unidad	Instrumento	Incertidumbre
Combustible	FOP	[bar]	Transmisor de presión SEN 9601 B075	±0,5%
	T_{FO}^{in}	[°C]	Pt100 sensor de temperatura	± 0,3 °C
	T_{FO}^{out}	[°C]		
Aceite	P_{LO}	[bar]	Transmisor de presión SEN 9601 B075	±0,5%
	P_{LO}^{filter}	[bar]		
	dP_{LO}^{filter}	[bar]		
	T_{LO}	[°C]	Pt100 sensor de temperatura	± 0,3 °C
	P_{LO}^{TCin}	[°C]		
	T_{LO}^{TCout}	[°C]		
Refrigeración	P_{HTCW}	[bar]	Transmisor de presión SEN 9601	±0,5%
	T_{JCW}^{in}	[°C]	Termopar tipo K	± 4%
	T_{JCW}^{out}	[°C]		
	T_{HTCW}^{CACout}	[°C]		
	T_{LTCW}^{CACin}	[°C]		
	T_{LTCW}^{LOCout}	[°C]		
Aire de entrada y gases de escape	$T_{exh}^{CO1-C09}$	[°C]	Termopar tipo K	± 4%
	T_{EXH}^{Avg}	[°C]		
	T_{EXH}^{TCin}	[°C]		
	T_{EXH}^{TCout}	[°C]		
	T_{AIR}^{CYLin}	[°C]		
Cigüeñal y cojinetes	T_{COJ}^{00-10}	[°C]	Termopar tipo K	± 4%
	T_{CR}^{01-09}	[°C]		
Cilindros	T_{CYL}^{01-09}	[°C]	Termopar tipo K	± 4%
Funcionamiento	Velocidad de giro	[Rpm]	Pick-Up Magnético	±0,5%
	Carga relativa	[%]	Calculado por PLC motor	± 3%
	FORACK	[mm]	Potenciómetro 4-20mA	± 3%
	RPM ^{TC}	[Rpm]	Pick-Up Magnético	±0,5%

En la operativa real de un buque pesquero, el sistema de adquisición registra correctamente todos los parámetros la mayoría del tiempo, pero existen momentos en los que este sistema falla, y algún registro no se guarda correctamente, por lo que existen algunos registros vacíos en la base de datos original directamente obtenida del buque. Además, en los regímenes transitorios del barco, también se dan algunos valores atípicos conocidos como “outliers”, lo que podría llevar a un modelo con un entrenamiento defectuoso y decrementaría su nivel de precisión. Por ello, se han considerado tres criterios de filtrado para depurar la base de datos original y conseguir una base de datos adecuada para ser introducida en los modelos:

- 1- Motor en marcha: A lo largo de las diferentes mareas que realiza un buque atunero durante un año, existen momentos en los que el motor no está propulsando el barco. Es por ello, que como primer criterio de filtrado se ha decidido extraer únicamente aquellos registros correspondientes a condiciones en las que el motor esté arrancado y en marcha. Para ello, se han escogido dos parámetros clave que definen el estado en el que se encuentra el motor: velocidad de giro y la posición de la cremallera de dosificación de combustible de la bomba de inyección que denominamos FORACK (Fuel Oil Rack). Para la velocidad de giro, se ha establecido que como mínimo, un motor de estas características necesita estar a 400 rpm para estar en marcha propulsando el buque. Y es que, una vez se embraga el motor, la velocidad de ralentí de este ya superará los 400 rpm. El segundo parámetro es un indicador directo del consumo de combustible del motor. Esta es la posición de la cremallera de la bomba de inyección de combustible, es decir, cómo de abierta está la bomba de inyección de combustible y cuál es el caudal de combustible que está inyectando a cada momento. La Figura C3. 3 muestra un esquema en el que se observa la cremallera de una bomba de combustible instalada en un motor diésel marino.




Figura C3. 3 Esquema de bomba de combustible y cremallera instalados en un motor diésel marino [205]

En esta imagen se pueden ver las distintas posiciones en las que puede estar una bomba de inyección de combustible dependiendo de la posición de su cremallera. En el centro, un émbolo sube y baja para comprimir y hacer pasar el combustible desde el puerto de entrada (parte izquierda) al puerto de salida (parte derecha). La cantidad de combustible que se ha comprimido y ha pasado desde la entrada a la salida, la definirá la posición del émbolo (posición angular). Este émbolo tiene una ranura vertical y una helicoidal, que dependiendo en qué posición estén dejarán pasar más o menos combustible. Por ejemplo, en el caso de que la ranura vertical esté orientada a la salida del combustible (Figura C3. 3a), la entrada estará tapada y no habrá paso de combustible. La Figura C3. 3b representa un paso de combustible intermedio, en el que la ranura se encuentra entre la entrada y la salida. Finalmente, en la Figura C3. 3c en la que la ranura vertical está orientada a la entrada, el paso de combustible será máximo. Esta orientación de la ranura vertical se la provoca la cremallera dentada que se ve en las tres figuras. A medida que esta cremallera se desplaza, se regula el paso de combustible y por lo tanto el consumo de combustible del motor. La posición de esta cremallera se mide en milímetros y se ha registrado como un parámetro más, y para el proceso de filtrado se ha establecido un mínimo de 5 [mm].

- 2- El segundo criterio de filtrado tiene como objeto la eliminación de los registros que debido al régimen transitorio del motor han mostrado valores atípicos e ilógicos en cualquier parámetro. Para ello, se ha observado la desviación estándar de estos dos parámetros nuevamente: velocidad de giro y FORACK. Concretamente, se ha observado la desviación estándar de los 3 minutos previos a cada registro para todos los registros de la base de datos, utilizando la ecuación (1).

$$RSD_{3min} = \frac{Sd_{3min}}{\overline{x_{3min}}} * 100 = \frac{\sqrt{\frac{\sum_{i=1}^n (x_i - \overline{x_{3min}})^2}{n-1}}}{\overline{x_{3min}}} * 100 \quad (1)$$

Por un lado, RSD_{3min} representa la desviación estándar relativa de los tres minutos anteriores a cada registro. Sd_{3min} es la desviación estándar y $\overline{x_{3min}}$ es la media móvil, ambas calculadas para los 3 minutos anteriores a cada registro. x_i representa el registro i dentro de los minutos considerados y n es el total de registros

considerados en este lapso. Si el sistema de adquisición fuera perfecto, como se ha tomado un registro cada 10 segundos, en 3 minutos n sería 18. Sin embargo, como ya se ha dicho, existen algunos registros no guardados correctamente y también provenientes de situaciones en las que el motor no está en marcha, por lo que n puede cambiar para cada desviación estándar relativa calculada. Por lo tanto, se han establecido los siguientes límites máximos para asegurar que cada registro esté en estado estacionario: $RSD_{RPM} \leq 1\%$ y $RSD_{FORACK} \leq 5\%$.

- 3- Por último, tras el proceso de filtrado, el número de registros en cada minuto era dispar. Es decir, existían minutos en los que había un registro y otros en los que había 6. Por ello, con ánimo de alcanzar una base de datos homogénea se ha llevado a cabo una reorganización o “resample”. Mediante esta reorganización se ha modificado la base de datos para obtener un registro por cada minuto. De este modo, para que en la base final un minuto concreto tenga un registro, como mínimo en el origen debe tener un registro guardado a lo largo de ese minuto, ya que, de otro modo, esa fecha se borra de la base de datos. En el caso de tener varios registros para un minuto, se ha realizado la media de dichos registros, ofreciendo un único registro para cada minuto.

Tras el proceso de filtrado, la base de datos correspondiente al año 2020 tiene 299.052 registros de 61 variables diferentes. En este caso, se observa cómo a medida que ha ido avanzando la tesis, la cantidad de datos manejada ha ido incrementando de manera exponencial. Y es que, la base de datos utilizada en el primer capítulo contiene 140 registros de 6 variables (2 inputs y 4 outputs); la base de datos utilizada en el segundo capítulo contiene 1000 registros de 43 variables (8 inputs y 35 outputs); por último, la base de datos empleada en el presente capítulo de la tesis contiene 299.052 registros de 61 variables.

2.2 Estudio de correlación y desviación

Las grandes dimensiones de la base de datos manejada en el presente capítulo han provocado la necesidad de realizar un estudio previo de la correlación entre parámetros y la desviación que muestra cada parámetro a lo largo de todo el año 2020. Y es que, existen parámetros del motor que no guardan correlaciones tan grandes como lo hacen el consumo de combustible o la temperatura de gases de escape con respecto al funcionamiento del motor. De la misma forma, hay parámetros que están diseñados para no tener una gran variabilidad con respecto al funcionamiento del motor, es decir, que están diseñados para mantener valores semi constantes o de escasa variabilidad (por ejemplo, mediante el empleo de válvulas termostáticas para regular las temperaturas de ciertos fluidos). En este marco, tras publicar el primer trabajo de comparación de modelos expuesto en el Capítulo 1, se realizó un estudio adicional que fue presentado en el congreso internacional ATE-HEFAT2021, analizando el efecto de introducir parámetros de baja correlación en un modelo de redes neuronales [206]. Sin entrar demasiado en detalle, a continuación, se expondrá el problema planteado en el congreso y las conclusiones obtenidas.

En el motor de un cilindro Minsel430a, se realizó un análisis de correlación para ver qué parámetros guardaban una gran correlación respecto al resto y cuáles no lo hacían tanto. Se diseñaron dos redes neuronales artificiales idénticas, pero en la primera se incluyeron los parámetros de menor correlación como inputs (posición del punto máximo de presión, comienzo de la combustión y final de la combustión), y en la segunda se eliminaron dichos parámetros de la red. En la Figura C3. 4 se muestra el planteamiento del problema.

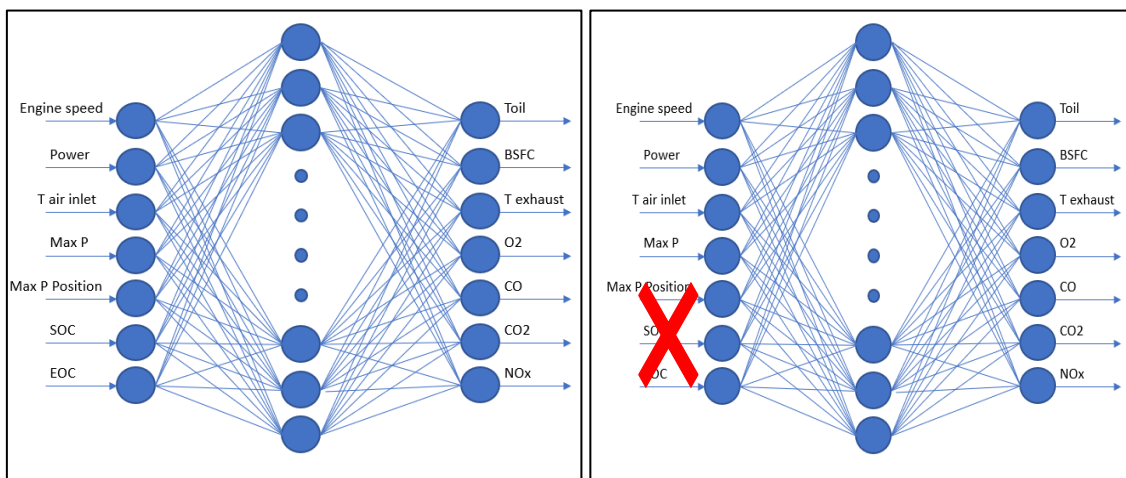


Figura C3. 4 Planteamiento del problema ATE-HEFAT2021

La primera red contenía 7 inputs, mientras que la segunda sólo contenía 4. A primera vista puede parecer que cualquier parámetro adicional en la capa input de una red neuronal puede ser de ayuda a la hora de calcular los outputs, pero en tal estudio se demostró que esto no es cierto, obteniendo los valores de error porcentual absoluto medio mostrados en la Figura C3. 5.




Figura C3. 5 Errores obtenidos para la comparación de ANN inicial y ANN reducido

La red neuronal inicial, la cual incluía los parámetros de baja correlación como inputs, presentó mayores niveles de error que la red neuronal reducida (sin dichos parámetros en la capa input) para todos los outputs calculados. De esta forma, se demostró que la inclusión de parámetros de baja correlación en la capa input de una red neuronal artificial puede hacer decrecer el nivel de precisión de dicha red neuronal. En el presente estudio, motivado por los resultados obtenidos en dicho trabajo y por la gran dimensión de la base de datos manejada, se ha estudiado la correlación entre los 61 parámetros de la base de datos. Existe la posibilidad de que en un análisis de correlación, algunos parámetros muestren bajos niveles de correlación no por no estar relacionados con el funcionamiento del motor, sino porque como ya se ha mencionado, algunos de ellos están diseñados para mantener valores constantes o cuasi constantes. Por ello, primero se ha calculado la desviación estándar relativa de cada parámetro. Para ello, se ha utilizado la ecuación (1), pero en este caso se ha calculado la desviación estándar de cada parámetro para todo el año 2020 (en lugar de para tres minutos). Sucesivamente, se ha calculado el coeficiente de correlación de Pearson para cada parámetro respecto al resto durante todo el año 2020. Finalmente, se ha calculado la media de todos los coeficientes de

correlación de un parámetro respecto al resto. Es decir, qué correlación media tiene cada parámetro respecto a todos los demás. Para ello, se ha utilizado la ecuación (2).

$$\bar{r} = \frac{1}{m} \sum_{j=1}^{m-1} \left| \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \right| \quad (2)$$

x e y son los parámetros entre los cuales se calcula el coeficiente de correlación. \bar{x} e \bar{y} son los valores medios de cada parámetro para el año 2020. n representa el número de registros considerados en el cálculo del coeficiente de correlación, que en este caso es 299.052 ya que se ha contemplado el año completo de 2020. Finalmente, m es el número de parámetros contenidos en la base de datos, en este caso 61, utilizados para el cálculo de la media de coeficientes de correlación. El valor absoluto de la ecuación (2) ha sido introducido en dicha expresión porque el coeficiente de correlación de Pearson varía entre -1 y 1. A la hora de sumar los diferentes coeficientes de un parámetro, podría ocurrir que los valores negativos anularan a los positivos, no mostrando una imagen real del nivel de correlación de cada parámetro. Para finalizar este análisis, se han representado los valores de desviación estándar relativa respecto a los coeficientes de correlación medios de cada parámetro. El objeto de esta representación es decidir qué parámetros serán modelados mediante redes neuronales artificiales, y cuáles serán modelados con otras técnicas alternativas. Como ya se ha mencionado previamente, no sirve sólo con analizar el coeficiente de correlación, ya que la desviación de cada parámetro, junto con la idea aproximada de su correlación respecto al resto nos proveen de una información más completa. En la Figura C3. 6 se muestra el gráfico de la desviación relativa de cada parámetro respecto a sus coeficientes de correlación.




Figura C3. 6 Desviaciones relativas vs coeficientes de correlación de parámetros

En esta imagen se puede apreciar que, dependiendo de cada parámetro, tanto la desviación relativa como la correlación varían notablemente. Aquellos parámetros que hayan tenido una gran variabilidad y coeficientes de correlación altos representarían variables que han cambiado mucho con las diferentes situaciones del motor, pero que también han producido cambios en otras variables (o estos cambios han sido provocados por otras variables). Estos parámetros son firmes candidatos para ser modelados mediante redes neuronales artificiales. Pese a tener correlaciones altas, si estos parámetros estuvieran en rangos muy pequeños de cambio y fueran casi constantes, podría ocurrir el fenómeno acaecido en el Capítulo 2 con las emisiones de NO_2 o CO , resultando en errores de cálculo muy altos. Del mismo modo, si se pretendiera modelar con valores medios u otras estrategias los parámetros con tan altas variabilidades como por ejemplo, la carga relativa del motor, el error de los cálculos sería muy alto debido al gran rango de variación que tienen estos parámetros.

En el presente estudio, aquellos parámetros con valores bajos de desviación estándar relativa y coeficientes de correlación bajos han sido propuestos para ser analizados mediante Funciones Densidad de Probabilidad (PDF). Del mismo modo, los parámetros con valores altos de desviación estándar relativa y coeficientes de correlación altos han sido propuestos para ser modelados mediante redes neuronales artificiales (ANN). En la Figura C3. 6 puede observarse una línea que separa los puntos representativos de cada parámetro. Esta es la línea que

diferencia los parámetros que serán modelados con Funciones de Densidad d Probabilidad de los que serán modelados con redes neuronales artificiales. Sin embargo, los parámetros que han recaído cerca de la línea de separación como por ejemplo la temperatura del combustible a la salida del motor, han sido analizados más profundamente para decidir con qué técnica modelarlos. Concretamente, tras realizar un intento preliminar de modelar la temperatura de combustible a la salida del motor mediante redes neuronales, el error de predicción ha resultado ser relativamente alto, lo que ha hecho descartar este parámetro del modelado mediante ANN. No obstante, esta línea ha servido como una referencia muy útil para entender una base de datos de tan grandes dimensiones antes de desarrollar el proceso de modelado. Por ejemplo, en la Figura C3. 6 se pueden observar tres grandes nubes de puntos. La primera nube recae entre valores de correlación de 0,5 y 0,6. Esta nube de puntos que recae en la parte inferior de la línea, corresponde a las 9 temperaturas tomadas en el cigüeñal. Estos parámetros, pese a presentar valores de correlación medios-altos, no variaron mucho a lo largo del año 2020, lo que provocó su no modelado mediante redes neuronales artificiales. De forma similar, la segunda nube de puntos interesante recae alrededor del valor de correlación 0,7 y corresponde a las 11 temperaturas tomadas en los cojinetes. Estas medidas presentaron valores de desviación bajos, pese a mostrar valores de correlación relativamente altos. Debido a su baja desviación, tanto las temperaturas del cigüeñal como las de los cojinetes han sido propuestas para ser modeladas mediante funciones de densidad de probabilidad. Por último, la tercera nube de puntos que recae entre correlaciones de 0,6 y 0,7 y se posiciona en la parte superior de la línea corresponde a las temperaturas de gases de escape, que presentan valores de correlación relativamente altos junto con desviaciones también altas. Estos parámetros serán modelados mediante redes neuronales artificiales. De hecho, en los Capítulos 1 y 2 este parámetro ya ha demostrado que guarda una gran correlación con el funcionamiento del motor, mostrando siempre niveles de errores de predicción notablemente bajos.

Finalmente, algunos parámetros como el FORACK o la carga relativa del motor han mostrado tanto niveles muy altos de correlación como de desviación. Este hecho es lógico ya que dichos parámetros definen la condición a la que está trabajando el motor, y son muy buenos candidatos para ser modelados mediante redes neuronales artificiales. Basándonos en este estudio, se han separado los parámetros a ser modelados mediante PDF y mediante ANN. El resultado puede observarse en la Figura C3. 7. Nótese que algunos parámetros del subsistema de refrigeración han sido modelados mediante PDF y otros mediante ANN. Esto es lógico ya que pese a pertenecer al mismo subsistema, algunos parámetros están diseñados para sufrir pequeñas variaciones mientras que otros no (ej. algunos parámetros están controlados por válvulas

termostáticas para ser cuasi constantes mientras que otros son dependientes de la condición del motor).

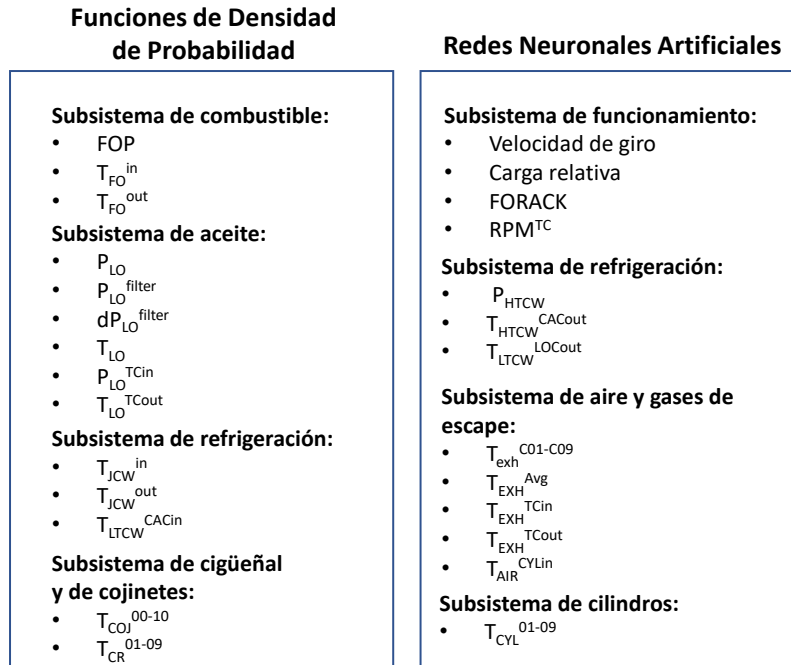


Figura C3. 7 Clasificación de parámetros por estrategias de modelado

2.3 Funciones de densidad de probabilidad

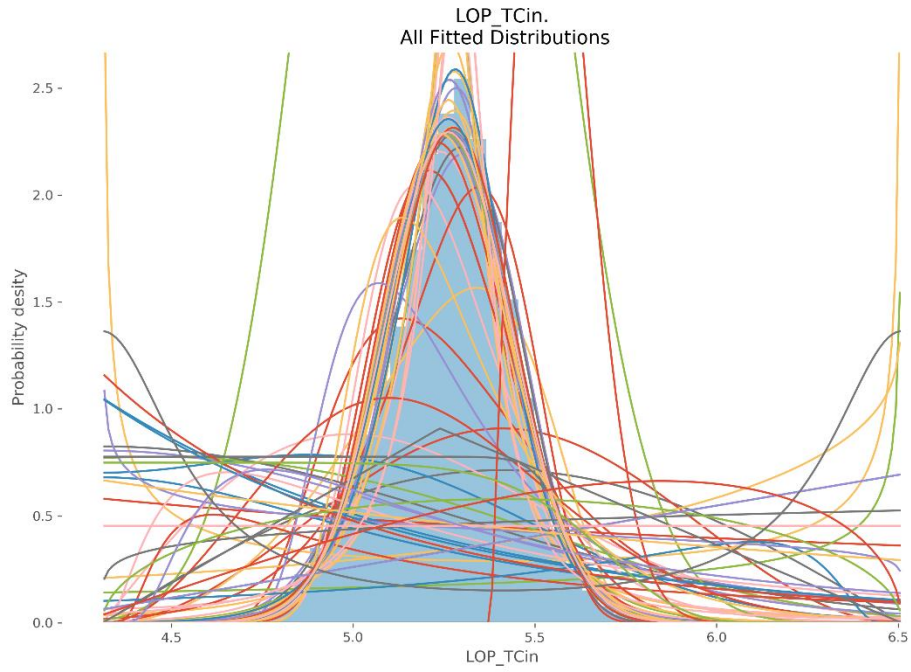
Los parámetros con menores niveles de variabilidad y correlación no han sido modelados mediante redes neuronales artificiales en el presente estudio. En este caso, este tipo de parámetros han mostrado tendencias constantes durante todo el año 2020. Por ello, en el caso de introducir dichas variables con valores repetitivos o similares en el entrenamiento de una red neuronal, esto podría acarrear fenómenos de sobre entrenamiento y decrementar el nivel de precisión del modelo. Por lo cual, se han escogido las funciones de densidad de probabilidad para modelar y definir los valores límite de dichos parámetros. Algunos trabajos de investigación ya han optado por esta herramienta estadística para evaluar parámetros en motores diésel. Ruiz et al. [207] desarrollaron una herramienta de clasificación llamada LAMDA-FAR para categorizar diferentes condiciones de operación de los motores. Este algoritmo novedoso utiliza las funciones de densidad de probabilidad para llevar a cabo un análisis de similitud para después ser utilizado para agrupar condiciones diferentes del motor. Más recientemente, Jamrozik et al. [208] han comparado la estabilidad de la combustión de mezclas de diésel-metanol y diésel-

etanol en un motor dual de un cilindro analizando el IMEP del motor mediante las funciones de densidad de probabilidad.


En este caso de estudio, se ha calculado una función de densidad de probabilidad por cada parámetro para asegurar un cálculo riguroso de valores límite de cada uno de ellos. Por lo tanto, se han comparado 94 tipos de funciones de densidad de probabilidad para cada parámetro con objeto de hallar el que mejor se ajuste a la distribución de cada uno. Dependiendo de cada variable, su distribución a lo largo del año 2020 será diferente, ajustándose a alguno de los 94 tipos de funciones de densidad de probabilidad testeados. Para el ajuste de cada función, se ha computado la suma residual de cuadrados (RSS) para las 94 funciones. Para cada parámetro, la función que provee el valor de RSS mínimo es seleccionada para modelar dicho parámetro. La ecuación (3) muestra cómo se calcula este parámetro:

$$RSS = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (3)$$

y_i es el valor actual de la densidad de la observación i , $f(x_i)$ es el valor calculado por la función de densidad de probabilidad y n es el número de observaciones, que en este caso es 299.052 ya que se ha considerado el año completo de 2020. La Figura C3. 8a muestra un ejemplo del ajuste de las diferentes funciones de densidad de probabilidad a la distribución del parámetro de presión de aceite lubricante a la entrada del turbocompresor. En ella pueden verse varias funciones diferentes y para todas ellas se ha calculado el RSS, para escoger la función que resulte en el mínimo valor de RSS. Por consiguiente, la Figura C3. 8b muestra la función que mejor se ha ajustado a dicha distribución, que en este caso es una función Burr tipo 12 [209].



a. Ajuste de funciones de densidad de probabilidad



b. Representación de función óptima

Figura C3. 8 Proceso de ajuste de funciones de densidad de probabilidad

2.4 Redes neuronales artificiales

Para modelar los parámetros que han presentado valores altos de desviaciones estándar relativas y coeficientes de correlación altos y establecer sus valores límite se han empleado las redes neuronales artificiales. En este caso, se ha optado por una estrategia diferente a la utilizada en el Capítulo 2 de la tesis. En el anterior capítulo, se ha pretendido demostrar el potencial de las redes neuronales artificiales para mostrar una imagen completa del estado de un motor en cualquier punto del mapa de su funcionamiento. De este modo, se han calculado simultáneamente 35 parámetros de funcionamiento y emisiones con una única red neuronal artificial. En el presente capítulo, se ha optado por diseñar una red neuronal artificial específica para cada subsistema del motor. Esto se ha hecho de tal forma, ya que no es necesario obtener la imagen completa del motor al instante, sino que el objetivo es analizar los valores límite de las desviaciones entre modelo y realidad para los parámetros calculados. De esta forma, se han diseñado cuatro redes neuronales para los siguientes subsistemas: funcionamiento, refrigeración, aire y gases de escape y cilindros. Respecto a la capa input, se han utilizado los mismos inputs para las cuatro redes: carga relativa y velocidad de giro. El primer parámetro ha mostrado unos de los niveles más altos tanto de desviación como de correlación durante el análisis previo (Figura C3. 6). Este es un hecho lógico ya que cuando se necesitan velocidades diferentes del buque atunero, esto influye directamente a la carga demandada al sistema de propulsión. Este parámetro, junto con la velocidad de giro definen casi en su totalidad el estado de funcionamiento del motor. Interesantemente, en la Figura C3. 6 se puede apreciar que la velocidad de giro ha presentado valores medios-altos de desviación y correlación, sin ser de los más destacados. Sin embargo, en combinación con la carga relativa (o potencia) proveen a la red de una gran cantidad de información. Ejemplo de ello son previos estudios que han incluido tanto la carga relativa [133, 210] como la velocidad de giro del motor [121, 123] para simular el funcionamiento de motores diésel mediante redes neuronales artificiales. La Figura C3. 9 muestra las cuatro redes neuronales propuestas para el presente estudio.




Figura C3. 9 Redes neuronales propuestas para los diferentes subsistemas del motor

Para la determinación del número de neuronas en la capa oculta, tradicionalmente se ha empleado el ensayo y error para determinar dichos hiper parámetros. Yang et al. [178] observaron valores de MSE y R de su modelo de redes neuronales para establecer el “learning rate” óptimo para el entrenamiento. En el anterior capítulo también se ha llevado a cabo el ensayo y error para la determinación del número de neuronas en la capa oculta, que después fue respaldado con los altos niveles de precisión obtenidos en la fase de testeo. Sin embargo, el ensayo y error presenta el inconveniente de tener que entrenar la red para cada configuración, lo que requeriría mucho tiempo teniendo en cuenta la gran dimensión de la presente base de datos. Como alternativa, algunos trabajos de investigación han desarrollado ecuaciones matemáticas para determinar el número de neuronas óptimo en la capa oculta basándose en otros parámetros de la red [211, 212]. Para el presente análisis, se ha empleado un software de código abierto desarrollado muy recientemente para el ajuste de hiper parámetros de las redes neuronales artificiales, creado por O’Malley et al. [213]. Este software realiza múltiples iteraciones con configuraciones diferentes de la red neuronal para minimizar una función objetivo. Para este caso, se ha escogido el error cuadrático medio de la fase de validación como la función objetivo a minimizar.

Por lo tanto, se han determinado los números de neuronas para las cuatro redes neuronales propuestas, con 8, 10, 18 y 7 neuronas para las capas ocultas de las redes de los subsistemas de funcionamiento, refrigeración, aire y escape y cilindros respectivamente. Con ánimo de utilizar dicho software soportado en la librería Keras de Python, se ha utilizado el algoritmo de optimización Adam [170] descrito por Ruder et al. [171] como la mejor opción entre los algoritmos de descenso de gradiente y que está soportado en dicha librería. Las funciones de transferencia utilizadas en las cuatro redes son la función sigmoide y lineal para las capas oculta y capa output respectivamente. Además, se ha añadido un criterio de parado para la fase de entrenamiento, para evitar el sobre entrenamiento del modelo. En tal sentido, si el valor de R^2 de la validación no mejora un mínimo de 10^{-4} puntos durante 10 iteraciones, el proceso de entreno se para, asumiendo que la red está lista para las siguientes fases. La partición de datos en este caso ha sido 85%-15% para entrenamiento y validación respectivamente. El testeo se ha realizado en dos fases: primero, se han extraído aleatoriamente 1000 datos de la base de datos del año 2020 que no han sido utilizados en el entrenamiento ni en la validación de las redes para observar y establecer los valores límite de desviaciones entre modelo y valores reales para todos los parámetros; una vez establecidos dichos valores límite, los datos de 2021 se han utilizado para testear los valores límite previamente establecidos.

3- Resultados

3.1 Funciones de densidad de probabilidad

Una vez realizado el ajuste de la función óptima para cada parámetro, los valores límites de dichos parámetros se han establecido mediante intervalos de confianza. Para ello, se han establecido intervalos de confianza del 98%, para evitar que posibles valores atípicos (outliers) sean incluidos en el cálculo de los valores límite de cada parámetro. Los resultados obtenidos de dichos intervalos se han listado en la Tabla C3. 3. En esta tabla se muestra la función óptima seleccionada para cada parámetro, los valores límite de dicho parámetro y las desviaciones porcentuales respecto a la media de estos límites establecidos. En otras palabras, en qué porcentaje se desvía cada parámetro de la media tanto por el margen superior como por el inferior.

Tabla C3. 3 PDFs, intervalos de confianza, valores límite y sus desviaciones límite correspondientes

Subsistema	ID	Unidad	Función de densidad de probabilidad	Intervalo de confianza 98%	Desviación máxima de intervalo 98%
Combustible	FOP	[bar]	Skew-Normal	[6,85 , 8,11]	[7,48 , 9,54]
	T _{FO} ⁱⁿ	[°C]	Generalized-Gamma	[32,32 , 40,37]	[13,16 , 8,45]
	T _{FO} ^{out}	[°C]	Left-skewed Gumbel	[41,37 , 51,6]	[13,97 , 7,31]
Aceite	P _{LO}	[bar]	Laplace asymmetric	[5,25 , 6]	[7,97 , 5,11]
	P _{LO} ^{filter}	[bar]	Laplace	[5,79 , 6,65]	[6,92 , 6,92]
	dP _{LO} ^{filter}	[bar]	Burr	[0,44 , 0,56]	[10,59 , 14,47]
	T _{LO}	[°C]	Laplace asymmetric	[61,16 , 63,22]	[1,48 , 1,85]
	P _{LO} ^{TCin}	[bar]	Burr12	[4,79 , 5,67]	[9,05 , 7,65]
	T _{LO} ^{TCout}	[°C]	Log-Laplace	[74,33 , 92,68]	[10,51 , 11,57]
Refrigeración	T _{JCW} ⁱⁿ	[°C]	Laplace	[75,5 , 78,53]	[1,95 , 1,95]
	T _{JCW} ^{out}	[°C]	Laplace Asymmetric	[80,9 , 84,81]	[1,76 , 2,99]
	T _{LTCW} ^{CACin}	[°C]		[32,95 , 34,4]	[1,01 , 3,36]
Cigüeñal y cojinetes	T _{COJ} ⁰⁰	[°C]	Laplace asymmetric	[71,87 , 75,38]	[2,68 , 2,07]
	T _{COJ} ⁰¹	[°C]	Weibull Maximum	[78,22 , 85,3]	[4,78 , 3,85]
	T _{COJ} ⁰²	[°C]	Inverted Gamma	[79,32 , 87,68]	[4,94 , 5,08]
	T _{COJ} ⁰³	[°C]	Laplace asymmetric	[81,48 , 92,41]	[5,68 , 6,97]
	T _{COJ} ⁰⁴	[°C]	Von Mises	[81,66 , 90,02]	[4,87 , 4,87]
	T _{COJ} ⁰⁵	[°C]	Gauss hypergeometric	[81,66 , 89,08]	[4,73 , 3,92]
	T _{COJ} ⁰⁶	[°C]	Von Mises	[80,6 , 88,84]	[4,86 , 4,86]
	T _{COJ} ⁰⁷	[°C]	Generalized extreme	[81,04 , 88,97]	[5,07 , 4,21]
	T _{COJ} ⁰⁸	[°C]	value	[81,78 , 89,43]	[5 , 3,89]
	T _{COJ} ⁰⁹	[°C]	Von Mises	[81,75 , 89,95]	[4,77 , 4,77]
	T _{COJ} ¹⁰	[°C]	Skew-Normal	[77,04 , 83,22]	[4,8 , 2,84]
	T _{CR} ⁰¹	[°C]	Laplace asymmetric	[71,92 , 78,23]	[4,9 , 3,46]
	T _{CR} ⁰²	[°C]	Skew-Normal	[70,55 , 78,21]	[6,94 , 3,16]
	T _{CR} ⁰³	[°C]		[72,55 , 78,58]	[3,56 , 4,45]
	T _{CR} ⁰⁴	[°C]	Laplace asymmetric	[72,08 , 78,41]	[5,51 , 2,79]
	T _{CR} ⁰⁵	[°C]		[71,86 , 78,51]	[5,04 , 3,76]
	T _{CR} ⁰⁶	[°C]	Generalized logistic	[70,21 , 77,2]	[7,16 , 2,08]
	T _{CR} ⁰⁷	[°C]	Laplace asymmetric	[73,2 , 79,13]	[3,02 , 4,84]
	T _{CR} ⁰⁸	[°C]	Mielke	[70,81 , 77,2]	[6,49 , 1,95]
T _{CR} ⁰⁹	[°C]	Mielke	[71,64 , 78,14]	[6,56 , 1,91]	

El hecho de mostrar las desviaciones porcentuales del intervalo de confianza respecto a la media es proveer a futuros estudios de valores orientativos aplicables a sus motores. Es decir, los valores límite de cada parámetro pueden cambiar dependiendo del motor, sin embargo, las desviaciones relativas sufridas en su funcionamiento pueden ser más fácilmente extrapolables

a otros motores. Según lo observado en la Tabla C3. 3, los rangos de desviación no sólo dependen de cada parámetro, sino también muestran una dependencia respecto al subsistema, siendo mayores para algunos subsistemas en concreto. Por ejemplo, los subsistemas de combustible y de aceite han presentado los rangos de variación más extensos de todos los parámetros analizados. Respecto a las variables del subsistema de combustible, mientras que la presión del combustible ha mostrado variaciones relativamente bajas, las temperaturas del combustible a la entrada (T_{FO}^{in}) y a la salida (T_{FO}^{out}) han mostrado desviaciones máximas respecto a la media de 13,16% y 13,97% respectivamente. En cuanto al aceite lubricante, las desviaciones máximas las han presentado la presión diferencial en el filtro de aceite (dP_{LO}^{filter}), la presión del aceite en la entrada del turbocompresor (P_{LO}^{TCin}) y la temperatura del aceite a la salida del turbocompresor (T_{LO}^{TCout}) con desviaciones de 14,47%, 9,05% y 11,57% respectivamente, mientras que las desviaciones del resto de parámetros se han mantenido por debajo del 8%, siendo especialmente bajas para la temperatura del aceite con una desviación máxima del 1,85%. Los parámetros del sistema de refrigeración han presentado los rangos de desviación más bajos, con 1,95%, 2,99% y 3,36% para el agua de refrigeración a la entrada (T_{JcW}^{in}) y salida (T_{JcW}^{out}) de las camisas y la temperatura del agua de baja temperatura a la entrada del enfriador de aire (T_{LTCW}^{CAcin}) respectivamente.

Finalmente, para el subsistema de las temperaturas en el cigüeñal y en los cojinetes de bancada, las desviaciones se han mantenido por debajo de 7,16% (T_{CR}^{06}) y 6,97% (T_{COJ}^{03}) respectivamente. Curiosamente, en relación con la toma de temperatura de los cojinetes de bancada, los rangos de temperatura correspondientes a los cojinetes de las zonas externas del motor (ej. T_{COJ}^{00} , T_{COJ}^{01} , T_{COJ}^{10}) son por lo general más bajos que los rangos de las temperaturas correspondientes a los cojinetes del centro del motor. Esto sucede debido a las mayores pérdidas de calor que puedan sufrir los cojinetes de las zonas externas del motor. Si todas las tomas de temperatura de cojinetes fueran consideradas como una sola, este hecho haría que el rango de desviaciones calculado fuera más extenso para todos los cojinetes, ya que tomaría valores desde los más bajos vistos en los extremos, hasta los más altos vistos en los cojinetes del centro. Esto podría provocar errores de clasificación, ya que los límites de un funcionamiento correcto del motor serían más extensos, pudiendo retrasar la identificación de algún fallo en los cojinetes. Los valores límite de los parámetros mostrados en la Tabla C3. 3, serán después testeados con los datos obtenidos de dichos parámetros durante la primera mitad del año 2021, para ver si dichos límites han sido correctamente establecidos.

3.2 Redes neuronales artificiales

En el presente estudio, se ha empleado la base de datos más extensa de toda la tesis, con 299.052 registros de 61 variables. Este hecho ha imposibilitado calcular la estructura óptima de la red mediante el análisis directo de la fase de validación, por lo que se ha hallado una nueva solución basada en un software de optimización de hiper parámetros de redes neuronales artificiales. Tras la determinación del número de neuronas en la capa oculta de las cuatro redes correspondientes a diferentes subsistemas del motor, dicha base de datos se ha utilizado para entrenar y validar estos modelos. Sin embargo, 1000 registros escogidos aleatoriamente se han reservado para testear las redes y establecer valores máximos de desviaciones entre modelos y valores reales. Para dicho estudio, se ha utilizado nuevamente el error porcentual medio absoluto (MAPE), siguiendo la ecuación 21 del Capítulo 1. Dicha expresión ha sido utilizada tanto en capítulos anteriores de la presente tesis como en otros trabajos de investigación en torno al modelado de motores diésel para evaluar el rendimiento de los modelos [133, 194]. En este caso, el MAPE ha sido calculado para los 1000 registros de test de la base de datos del año 2020. Los resultados obtenidos se muestran en la Figura C3. 10.




Figura C3. 10 Resultados de MAPE para cálculos de ANN con datos de test de 2020

En términos generales, los niveles de precisión alcanzados por los cuatro modelos son notablemente altos. Esto puede estar causado en parte por la gran dimensión de la base de datos que se ha utilizado para entrenar la red neuronal. Por otro lado, la estrategia de separar los parámetros por subsistemas parece que ha resultado en cálculos con niveles de error bajos. Como ya se ha mencionado, estos parámetros modelados mediante redes neuronales artificiales son aquellos que han presentado mayores niveles de desviaciones y correlaciones en el año 2020. En caso de modelar dichos parámetros mediante funciones de densidad de probabilidad, los intervalos de confianza serían muy amplios, no aportando información útil para diferenciar entre una situación de motor sano y una de un motor en condición de fallo. Como ya se ha mencionado previamente, los 1000 datos de test han sido aleatoriamente escogidos de la base de datos del año completo de 2020 por lo que pueden pertenecer a momentos diferentes del año y no a condiciones limitadas del motor.

En cuanto a los resultados, el subsistema de variables de funcionamiento ha mostrado uno de los niveles más altos de exactitud en el cálculo, con errores de 0,78% y 0,90% para cálculos del FORACK y la velocidad de giro del turbocompresor (RPM^{TC}) respectivamente. Los subsistemas de parámetros de refrigeración y cilindros también han mostrado niveles de errores relativamente bajos, manteniéndose por debajo de errores de 1,22% y 1,17% respectivamente, lo que resalta el alto nivel de precisión de las redes desarrolladas. Por último, en el caso del subsistema de aire y gases de escape, se han observado errores ligeramente superiores, con 2,99% y 4,35% para temperatura de gases a la entrada (T_{EXH}^{TCin}) y a la salida del turbocompresor (T_{EXH}^{TCout}) respectivamente. Las posibles razones de que justamente los dos errores más altos se den en torno a un elemento concreto (turbocompresor) y sus implicaciones a la hora de establecer valores límite para estos parámetros serán analizadas más detenidamente en la sección de discusión. Para mostrar de forma visual el nivel de exactitud de los parámetros calculados por las redes neuronales, en la Figura C3. 11 se muestran los cálculos de 50 de los 1000 registros de test para dos parámetros: temperatura de los gases a la salida del turbocompresor (T_{EXH}^{TCout}) y FORACK.




Figura C3. 11 Predicciones para 50 registros de test de T_{EXH_TCout} y FORACK

Se han escogido estos dos parámetros en concreto ya que son los que han ofrecido los niveles de error máximo y mínimo, con ánimo de poder contrastar el nivel de exactitud dado por el modelo en ambos. Como era de esperar, las predicciones de FORACK están en todo momento muy próximas a los valores reales, lo que induce un cálculo muy preciso del consumo de combustible del motor. Por otro lado, pese a que el nivel de exactitud es más bajo para las predicciones de temperatura de gases de escape a la salida del turbocompresor (T_{EXH}^{TCout}), los cálculos del modelo se mantienen cerca de los valores reales para todos los registros de test, demostrando el gran potencial de predicción de las redes neuronales artificiales.

3.3 Validación de los valores límite establecidos


En las secciones 3.1 y 3.2, se han establecido los valores límite para todos los parámetros registrados en el motor a bordo de un buque atunero en condiciones reales de operación. Por un lado, los parámetros que tras el estudio de desviación relativa y coeficientes de correlación han mostrado valores más bajos de desviaciones y correlaciones han sido modelados mediante funciones de densidad de probabilidad. De esta forma, se han calculado los intervalos de confianza de 98% tras hallar la función óptima para representar la distribución de cada parámetro, determinando los valores límite de las desviaciones de cada uno de ellos respecto a sus valores medios durante todo el año 2020. Por otro lado, los parámetros con mayores niveles de desviación y correlación han sido modelados empleando redes neuronales artificiales. Se ha diseñado una red neuronal diferente por cada subsistema del motor, y tras entrenar y validar

las cuatro redes propuestas con todos los registros de 2020, se han testeado las cuatro redes con 1000 datos aleatorios de 2020 no vistos en el entrenamiento. Con estos datos de test, se han establecido los valores límite de desviaciones entre modelo y realidad, analizando el error porcentual medio absoluto para todos los parámetros calculados. Por último, para analizar si los valores límite tanto de los parámetros modelados con PDF como de los modelados con ANN han sido correctamente establecidos, se han utilizado los datos del año 2021 para testear y validar dichos umbrales o “thresholds”.


En este momento, sólo se ha podido acceder a la base de datos de la primera mitad del año 2021 debido a que es un período de tiempo relativamente reciente y no se ha tenido acceso al buque y datos correspondientes a la segunda mitad del año 2021. Para testear y validar los valores límite establecidos mediante ambas estrategias de modelado, se han seleccionado datos de diferentes días. Concretamente, se han seleccionado los datos de entre las 12:00 pm y las 17:00 pm del día 20 de cada mes. Estos datos se han pasado exactamente por el mismo proceso de filtrado por el que se pasó la base de datos de 2020. Tras la reordenación, teniendo un registro por cada minuto y 5 horas de 6 días distintos, se obtendría una base de datos de 60 registros x 5 horas x 6 días = 1800 registros. Sin embargo, como ya se ha mencionado en el apartado 2.1 referente a la adquisición de datos y al filtrado de los mismos, algunos registros correspondientes a situaciones no estacionarias o de motor “parado” se han eliminado. Por ello, la última versión de la base de datos para testear y validar los valores límite establecidos previamente contiene 1647 registros, provenientes de toda la primera mitad del año 2021.

Siguiendo el orden en el que se han explicado tanto los modelos como los resultados de estos, primero se explicará cómo se ha llevado a cabo el testeo de los valores límites establecidos mediante funciones de densidad de probabilidad y después el de los obtenidos mediante redes neuronales artificiales. Para los parámetros con tendencia constante/cuasi constante modelados mediante funciones de densidad de probabilidad, se ha contado cuantas veces cae el valor de un parámetro registrado en 2021 fuera de los límites establecidos en 2020. Es decir, para cada parámetro se ha realizado un conteo para determinar cuántos de los 1647 registros de 2021 caen fuera de los límites establecidos en 2020 (mostrado en la Tabla C3. 3). El resultado es un número para cada parámetro, que representa cuántas veces se han superado los límites establecidos en 2020 con los datos de 2021. Inesperadamente, los registros de temperatura del combustible a la entrada (T_{FO}^{in}) y a la salida (T_{FO}^{out}) del motor del año 2021 han caído fuera de los límites del orden del 50% de las veces. Por tal razón, se ha analizado la evolución de ambos parámetros de manera exhaustiva, tanto en el año 2020 como en el 2021. Tras observar dicha evolución para los dos años, se ha apreciado que, por lo general, en 2021 ambas temperaturas

estaban en rangos de valores más altos que en 2020. Una posible razón es un cambio en la zona geográfica de pesca del buque de un año a otro, afectando directamente a estos dos parámetros. Y es que, dependiendo de cada especie y del buque de pesca, la zona geográfica de pesca puede variar [214]. Para evitar que los intervalos calculados con las PDF se vean afectados por dichos cambios geográficos, se ha propuesto un nuevo parámetro que representa la diferencia entre la temperatura de entrada y la temperatura de salida del combustible. Este nuevo parámetro se ha modelado nuevamente con otra PDF, y se ha calculado el intervalo de confianza para él. El parámetro es denominado dTFO, y su intervalo de confianza de 98% es [9,14, 16,59] [°C]. La Figura C3. 12a muestra las veces que cada parámetro de 2021 ha caído fuera de los límites establecidos en 2020, mientras que la Figura C3. 12b muestra a modo de ejemplo la presión del aceite lubricante registrada en 2021 respecto a los límites establecidos en 2020 para dicho parámetro.



a. Fallos de los límites para los datos de 2021



b. Ejemplo de límites y valores de 2021 respecto a dichos límites

Figura C3. 12 Validación de valores límite establecidos por las funciones de densidad de probabilidad

De la Figura C3. 12a, se concluye que el número de fallos cometidos por los límites establecidos en 2020 para los datos de 2021 es relativamente bajo. En otras palabras, el número de veces que los datos de 2021 han estado fuera de los valores límite presentados en la Tabla C3. 3 es bajo. Concretamente, el número más alto de fallos para un parámetro es 20, para la temperatura del agua de refrigeración de camisas (T_{JcW}^{in}). Teniendo en cuenta que en esta fase de validación de los valores límite se han pasado 1647 registros procedentes del año 2021, este número de fallos corresponde a un 1,21% de los registros, lo que es un error aceptable ya que aún filtrados, siguen existiendo algunos valores atípicos aislados en la operativa real del buque. Por otro lado, de la Figura C3. 12b se concluye de forma visual que todos los registros recaen dentro del rango establecido por los valores límite, exceptuando algunos registros aislados que no se extienden en un periodo de tiempo considerable. De esta forma, la tendencia general es que solamente unos pocos registros aislados han recaído fuera de los valores límite establecidos en 2020, por lo que en caso de que algún parámetro recayera fuera de estos límites durante un periodo de tiempo más extenso, podría decirse que el motor no está funcionando 100% en condiciones de motor sano. Esto es, se consideraría que el motor no está funcionando en condiciones de motor sano si se mantuviera fuera de los límites por un periodo de tiempo prolongado de modo continuado.

En cuanto a los parámetros modelados por las redes neuronales artificiales, se ha utilizado la misma base de datos con registros del 2021 (1647 registros) para validar los valores límite de errores del modelo establecidos en 2020. Tras entrenar, validar y testear la red con la base de datos de 2020, se ha archivado esta red; esto es, sus factores de peso han sido guardados en un archivo para después utilizar estas redes neuronales con los datos del año 2021. De esta forma, en la Figura C3. 13 se muestran los errores cometidos por las redes neuronales para cada parámetro al pasar los registros del año 2021. Junto a estos errores, se muestran también los errores que se obtuvieron con los 1000 registros de test de 2020.




Figura C3. 13 Valores de MAPE para predicciones de ANN en 2020 y 2021

Llegado este punto, podrían haberse establecido como valores límite los errores obtenidos con los 1000 registros de test de 2020. Sin embargo, con objeto de obtener valores límite contrastados y extrapolables a otros estudios, se ha vuelto a testear la misma red con datos de 2021. Como ya se ha mencionado previamente, se han obtenido datos del día 20 de cada mes, por lo que, en estos datos de test de 2021, hay algunos registros obtenidos meses más tarde que aquellos registros utilizados para entrenar las redes neuronales. Por lo tanto, para estos registros de 2021 se ha vuelto a calcular el error porcentual medio absoluto de los outputs calculados, presentándolo en la Figura C3. 13. En esta imagen se puede observar que el nivel de error obtenido para los registros de 2021 está en el rango de los errores obtenidos para los datos de 2020. Nótese que los 1000 registros de test de 2020 pese a estar aleatoriamente escogidos de la base de datos, estaban entre otros datos utilizados para entrenar y validar las redes. Sin embargo, los datos utilizados de 2021 están en algunos casos registrados meses después de los

datos utilizados para entrenar y validar dichas redes. El hecho de lograr niveles de precisión tan altos para los registros de 2021 resalta una vez más la adaptabilidad y la capacidad de regresión de las redes neuronales artificiales para el cálculo de múltiples parámetros del motor.

En el caso del subsistema de funcionamiento del motor, el nivel de error se ha mantenido con respecto a los errores obtenidos en 2020. Para el subsistema de refrigeración, los errores obtenidos en 2021 han sido aún menores que en 2020, manteniéndose por debajo de 1% y mostrando un alto nivel de precisión. En el caso del subsistema de aire y gases de escape, la temperatura del aire a la entrada ha mostrado niveles de error ligeramente superiores que, en 2020, alcanzando un valor de MAPE de 3,70% frente al 1,56% obtenido en 2020. Esto podría estar parcialmente influenciado por el cambio de zona geográfica de pesca y su temperatura ambiental, que ya han tenido un impacto directo en el caso de los límites establecidos para temperaturas de combustible en el apartado anterior. En cuanto a las temperaturas de los gases de escape de los cilindros, los errores de cálculo también han sufrido un incremento con respecto a los datos de 2020. El error más alto se ha visto en la temperatura de los gases de escape a la salida del turbocompresor, con 7,34%. Esto podría estar causado en parte por la gran cantidad de parámetros que tienen un impacto en esta variable (ej. carga del motor y velocidad de giro, velocidad de giro del turbocompresor, temperatura del aire de entrada etc.). Por último, las predicciones para el subsistema de cilindros han mostrado niveles similares a los obtenidos para 2020, manteniéndose por debajo del 2% en todos los cálculos de temperaturas de cilindros. En el siguiente apartado de discusión, todos los valores límite de desviaciones obtenidos serán analizados más a fondo y se resumirán como conclusión los límites obtenidos para todos los parámetros considerados en el estudio.

4- Discusión

En el presente capítulo, se ha estudiado el funcionamiento de un motor a bordo de un buque atunero operativo durante el año 2020 y la primera mitad del año 2021. En el presente periodo de tiempo, el motor ha funcionado sin ningún tipo de incidencia. Como ya se ha mencionado en la definición de la problemática de la presente tesis, los valores límite o “thresholds” considerados en la literatura existente como indicadores de fallos en el motor no están en su mayoría debidamente justificados. En este estudio, se ha pretendido caracterizar dichos valores límite que separan una situación de funcionamiento normal del motor de posibles situaciones de fallo. Para ello, se han analizado hasta 5.181 horas del motor en marcha, proveyendo a los modelos del presente estudio de una base de datos tan extensa hasta el momento no vista en otros estudios. Tras llevar a cabo un análisis de correlación y desviación, los parámetros con tendencias constantes se han modelado mediante funciones de densidad de probabilidad y los parámetros con mayores niveles de correlación y desviación se han modelado mediante redes neuronales artificiales. Los resultados obtenidos de la validación con los datos del año 2021 muestran el gran potencial de ambas estrategias de modelado para definir con un alto nivel de precisión los valores límite de todos los parámetros estudiados.

En el caso de los parámetros modelados mediante funciones de densidad de probabilidad, primero se ha determinado la función óptima para modelar la distribución de cada parámetro, comparando 94 funciones diferentes en cada caso. Después, se ha establecido un intervalo de confianza del 98% y se ha calculado la media de cada variable, utilizando dichas funciones, para finalmente establecer los límites de desviación porcentual de cada parámetro respecto a su media. Según lo mostrado en la Figura C3. 12a, los límites establecidos en 2020 han demostrado ser apropiados, ya que el número de registros de 2021 que han recaído fuera de estos límites es relativamente reducido. En este caso, si todos los parámetros mostraran 0 fallos en los rangos establecidos en 2020, esto haría concluir que los límites establecidos son demasiado amplios. Es decir, es conveniente que en algunos parámetros los límites fallen en registros aislados, para saber que los límites están bien ajustados. Por lo contrario, estaríamos asegurando que el motor funciona correctamente en rangos de parámetros demasiado amplios, pudiendo llegar a infravalorar algún fallo hasta no conseguir desviaciones relativamente grandes de los parámetros. En efecto, el hecho de que un parámetro caiga en un registro concreto fuera de los límites no representa un fallo del motor; para llegar a indicar un fallo, esta desviación debería extenderse en el tiempo, mostrando varios registros seguidos fuera de los valores límite. Es conveniente recalcar que los motores tienen unos límites de operación establecidos para sus

parámetros de funcionamiento más allá de los cuales el motor no debe operar. Estos límites están definidos como valores de alarma y de parada inmediata del motor. Los límites definidos mediante esta metodología son mucho más estrictos que los límites de operación de alarma y parada y superarlos no requerirían de una intervención inmediata sobre el motor, sino de una intervención planificada para mejorar la condición del motor. En el caso de superar los límites de alarma y/o parada del motor, se ha de actuar de forma inmediata en el motor para subsanar el fallo en el motor, ya que si no se hace así, podría dar lugar a un fallo catastrófico del motor.

Pese a que los límites han mostrado algunos pocos fallos tras testarlos con registros del año 2021 para la mayoría de los parámetros, la temperatura del combustible a la entrada y salida del motor han mostrado grandes ratios de fallos, estando hasta el 50% de las veces fuera de los valores límite. Como ya se ha mencionado, esto podría estar ocasionado por un cambio en la zona geográfica de pesca. Recientemente, Issa et al. [215] han analizado el efecto de las variables ambientales en la eficiencia de los motores, concluyendo que la temperatura ambiente tiene un impacto directo en varios parámetros del motor como la eficiencia de este o el consumo de combustible. Por tal razón, en el presente estudio se ha computado la diferencia de ambas temperaturas, declarando una nueva variable (dTFO). Tras hallar la función de densidad de probabilidad óptima para esta variable, el nuevo parámetro ha recaído fuera de sus valores límite sólo 4 veces en 2021, aun en el caso de cambiar la zona geográfica de pesca.

En el marco del mantenimiento basado en condiciones, muchos trabajos de investigación han llevado a cabo procesos análogos al análisis del presente estudio mediante funciones de densidad de probabilidad. Boullosa-Falces et al. [216] calcularon intervalos de decisión para diferentes parámetros del motor como la temperatura del aire de entrada o el consumo específico en un motor diésel marino de dos tiempos, concluyendo que los valores límite provistos por el fabricante eran demasiado altos como para identificar fallos de forma temprana. Por otro lado, Stoumpos y Theotokatos [217] han establecido recientemente desviaciones del 5% y 10% para fallos de velocidad de giro del motor o presión de sobrealimentación respectivamente. Sin embargo, existen parámetros que pueden sufrir desviaciones más grandes sin inducir situaciones de fallo del motor. Por ejemplo, en el presente análisis la presión diferencial en el filtro de aceite y la temperatura del aceite a la salida del turbocompresor han presentado valores de desviación límite de 14,47% y 11,57% respectivamente, no representando ninguna situación de fallo del motor. De hecho, como ya se ha mencionado, el hecho de que un registro en concreto exceda los valores límite en un registro aislado no representa una posible situación de fallo sino más bien un valor atípico registrado, posiblemente causado por la situación real operativa del buque. Además, a la hora de establecer dichos valores

límite, es necesario tener en cuenta las características específicas de cada máquina. Por ejemplo, el motor utilizado en este estudio tiene un gran volumen de aceite lubricante, lo que implica que este opera como un acumulador o buffer térmico con una gran inercia térmica. En otros términos, la temperatura del aceite no cambia tan rápido como la velocidad de giro o la potencia del motor, lo que puede en algún caso causar que esta temperatura caiga fuera de sus valores límite (muy frío antes de llegar a su régimen estacionario y muy caliente cuando el motor disminuye su carga antes de estabilizarse otra vez). Ahora bien, esto solamente se produciría en situaciones concretas y aisladas, volviendo dentro de sus límites una vez se estabiliza. Por otro lado, teniendo en cuenta que la temperatura afecta directamente en la viscosidad del aceite lubricante, esto tendrá un efecto directo en la presión del aceite, que podrá sufrir un efecto parecido que la temperatura en momentos concretos. Según Nahim et al. [218], un incremento en la temperatura del aceite lubricante podría representar fallos de derrame de aceite o deterioro del enfriador de aceite, mientras que una presión de aceite baja podría indicar un desgaste de la bomba de aceite, en los cojinetes del motor o también en el filtro de aceite. Esto, junto con el resto de los parámetros para los cuales se han establecido valores límite, en el presente estudio podrían ser indicadores potenciales de los fallos mencionados en el subsistema de aceite lubricante del motor.

En cuanto al resto de subsistemas, el circuito de refrigeración ha sido el siguiente en mostrar el número más alto de registros que han recaído fuera de los límites establecidos en 2020. En este caso, los rangos establecidos para los parámetros del subsistema de refrigeración han sido muy pequeños pudiendo ocasionar un número mayor de fallos de dichos rangos en 2021, junto con el hecho de que este tipo de fluidos líquidos también presentan una inercia térmica grande. Esto implicará un retraso ante un cambio en la velocidad de giro o de potencia del motor, que son prácticamente instantáneos. El valor máximo de desviación visto en este subsistema es 3,36% para la temperatura del agua de baja temperatura en la entrada del enfriador de aire (T_{LTCW}^{CACin}), que es notablemente más bajo que los valores de desviaciones considerados como límite en los trabajos previamente citados. Sin embargo, el máximo de fallos de los valores límite visto ha sido 20, que induciría un error del 1,21%, resultando un error aceptable. El buque estudiado en el presente estudio, el agua del circuito de baja temperatura introducida en el enfriador de aire proviene directamente de un intercambiador de calor que emplea agua de mar. Teniendo en cuenta que el buque opera en su mayoría en aguas tropicales, un cambio de temperatura en el agua de mar podría tener una ligera influencia en el circuito de agua de baja temperatura y en sus temperaturas. Este también puede ser uno de los causantes del error más elevado de la temperatura del agua de baja a la entrada del enfriador de aire (T_{LTCW}^{CACin}). Gholinia et al. [219]

simularon el sistema de refrigeración de las camisas de un motor diésel de gran porte, concluyendo que una mala refrigeración del sistema de válvulas y de la bujía podrían causar pérdidas de gas y producir un decremento en la potencia del motor. Los valores límite establecidos en el presente estudio podrían ser interesantes para identificar este tipo de fallos. Por último, los límites del subsistema del cigüeñal y cojinetes han superado los límites establecidos solamente en unos pocos registros, lo que parece indicar una correcta determinación de los límites para sus parámetros.

En el caso de los parámetros modelados mediante redes neuronales artificiales, se han observado primeramente los errores obtenidos para los 1000 registros de test extraídos de la base de datos de 2020, para después compararlos con los obtenidos de los registros de 2021. Curiosamente, tras observar los errores porcentuales tanto del año 2020 como del año 2021, se ha observado una relación directa de dichos errores con los valores obtenidos en el análisis de correlación y desviación del apartado 2. Concretamente, los parámetros del subsistema de funcionamiento FORACK y la velocidad de giro del turbocompresor han mostrado dos de los valores más altos de desviaciones relativas y de correlación, que después han resultado en dos de los errores más bajos de todo el motor tanto en 2020 como en 2021, con valores por debajo de 1,10%. Los resultados de predicción de consumo de combustible mediante redes neuronales artificiales muestran en la mayoría de los estudios valores de error relativamente bajos. Niu et al. [194] obtuvieron un error de 1,28% al predecir el consumo específico de combustible entre otros parámetros en un motor diésel marino tras entrenar su red neuronal con una base de datos limitada. Ağbulut et al. [123] han obtenido recientemente un error de 2,078% para el cálculo de este mismo parámetro tras modelar un motor de un solo cilindro utilizando éster metílico. Para el subsistema de refrigeración, se ha obtenido un nivel de precisión relativamente alto para los tres parámetros calculados de este subsistema en los registros de 2021. Para la presión del agua de alta temperatura (P_{HTCW}), la temperatura del agua de alta temperatura a la salida del enfriador de aire (T_{HTCW}^{CACout}) y para la temperatura del agua de baja temperatura a la salida del enfriador de aceite (T_{LTCW}^{LOCout}) se han conseguido errores de 0,96%, 0,57% y 0,83% respectivamente. Según Zhou y Xu [220], estos parámetros pueden resultar útiles a la hora de realizar una diagnosis de posibles fallos como el desgaste de la bomba de agua o una obstrucción de los enfriadores de agua, por lo que las desviaciones entre modelo y realidad obtenidas en el presente estudio podrían ayudar a predecir dichos fallos.

Por otro lado, el subsistema de aire y gases de escape ha mostrado errores relativamente altos en comparación a otros subsistemas, mostrando además mayores errores para los registros de 2021 que para los de 2020. A pesar de ello, los niveles de error obtenidos en ambos años son

relativamente reducidos. Como ya se ha mencionado en el Capítulo 2 de la presente tesis doctoral, pese a que muchos estudios consideran la temperatura de gases de escape como output para sus modelos, pocos de ellos separan las diferentes temperaturas que pueda haber en los varios elementos que contiene el subsistema de gases de escape de un motor. Entre ellos se aprecian el estudio realizado por Basurko y Uriondo [36] y el estudio derivado del segundo capítulo de la presente tesis [210]. En el presente caso de estudio se han considerado todos los parámetros registrados en el circuito de gases de escape del motor. Teniendo en cuenta solamente los errores alcanzados para las temperaturas de gases a la salida de los cilindros, el máximo error alcanzado ha sido 4,09% para la temperatura de gases de escape a la salida del cilindro 8 (T_{ECH}^{08}). Sin embargo, la temperatura media de los gases de escape de todos los cilindros ha sido calculada con un error por debajo del 2%. En cambio, la temperatura de gases de escape a la salida del turbocompresor ha mostrado un error notablemente mayor con 7,34%. Esto en parte puede haber sido causado por la gran cantidad de variables que afectan a este parámetro, en comparación a otros parámetros como la temperatura de gases a la salida de los cilindros, que depende directamente de lo ocurrido durante la combustión. A ello se le suma que durante el análisis de correlación y desviación este parámetro mostró valores bajos de estos indicadores, lo que resalta la importancia de un análisis previo de este tipo para entender cómo podría comportarse cada parámetro al ser modelado. Sin embargo, este es un parámetro muy importante para la identificación de fallos concretos del motor como por ejemplo un incremento de la contrapresión, que según Hield [82] podría acarrear temperaturas de gases de escape elevadas. Por lo que, un incremento superior al 7,34% de este parámetro extendido en el tiempo podría ser un potencial indicador de este tipo de situaciones de fallo.

Con ánimo de proveer a futuros estudios de un punto de referencia a la hora de establecer valores límite para los parámetros de sus motores en trabajos de identificación de fallos, se han resumido todos los límites determinados en el presente estudio en una figura final. Para los parámetros modelados mediante funciones de densidad de probabilidad, se han tomado las desviaciones porcentuales máximas de la Tabla C3. 3 para cada variable. Esto representa el máximo que un parámetro se ha desviado de su media durante todo un año. Por otro lado, para los parámetros modelados mediante redes neuronales se ha tomado el error máximo cometido entre 2020 y 2021. Si se tratara de establecer los valores límite como en otros trabajos de la literatura existente, se hubiera tenido solo en cuenta el error cometido durante el testeo del año 2020. Sin embargo, el presente estudio ha considerado datos del siguiente año, en algunos casos meses después de los datos utilizados para entrenar y validar la red, lo que le da un gran valor añadido ya que se han tomado como valores límite los errores máximos obtenidos entre

los dos años. El presente estudio tiene como objeto presentar valores límite contrastados para múltiples parámetros de un motor diésel marino en operación, considerando hasta 5.181 horas de funcionamiento sin fallos en el motor, con ánimo de servir como punto de referencia para futuros estudios en el ámbito del mantenimiento basado en condiciones. Estos valores límite no tienen por qué ser los mismos en otros motores, pero sí que pueden ser de gran ayuda para establecer dichos límites en otros casos de estudio. La Figura C3. 14 muestra el resumen de los “thresholds” establecidos y validados del presente caso de estudio.




Figura C3. 14 Valores límite de los 57 parámetros del motor estudiados

5- Conclusiones

En el presente capítulo, se ha analizado el sistema de propulsión de un buque atunero en operación, registrando 61 variables de operación del motor durante el año 2020 y la primera mitad del año 2021. Mediante diferentes estrategias de modelado, se han establecido los valores límite para dichas variables. Por un lado, los parámetros de baja variabilidad una vez el motor ha alcanzado su régimen estacionario y que disponen bajos niveles de desviación y correlación se han modelado mediante funciones de densidad de probabilidad. Para establecer sus valores límite, se han calculado intervalos de confianza y desviaciones porcentuales máximas de cada parámetro. Por otro lado, los parámetros que han mostrado mayores niveles de desviación y correlación se han modelado utilizando redes neuronales artificiales. Para estos parámetros, se han comparado los errores de testeo tanto del año 2020 como del año 2021, tomando los errores máximos entre los dos años para establecer valores límite de desviaciones entre modelo y valores reales. Tanto los límites de las funciones de densidad de probabilidad como los de las redes neuronales artificiales se han validado con datos del año 2021. Por primera vez, se han cuantificado los que pueden ser unos límites de desviaciones porcentuales para múltiples parámetros de un motor diésel marino en operativa real, funcionando sin ningún fallo. Para ello, este estudio ha procesado hasta 5.181 horas de funcionamiento del motor. Del presente estudio, se extraen las siguientes conclusiones:

- Las funciones de densidad de probabilidad han demostrado ser una metodología de gran potencial para modelar parámetros con tendencias constantes. Tras la validación, la tasa de fallo más alta ha sido de 1,21%, lo que demuestra el alto nivel de ajuste de los valores límite establecidos. Para considerar un posible fallo, los valores límite han de ser sobrepasados durante un periodo de tiempo prolongado y no sólo de modo puntual.
- Los valores límite dependen de cada subsistema del motor. Mientras que el subsistema de refrigeración ha mostrado desviaciones de 3,36% de la línea base, el subsistema de combustible ha mostrado una máxima desviación del 14,47%. Por lo tanto, para cada parámetro han de calcularse valores límite individualizados.
- Las redes neuronales artificiales han demostrado ser una herramienta de modelado rápida y precisa. Se han calculado 27 parámetros diferentes del motor con errores por debajo de 7,34%, aun cuando se han calculado en registros tomados meses después de los utilizados para el entrenamiento y validación de las redes.

- Para algunos subsistemas del motor, las redes neuronales artificiales han mostrado errores notablemente bajos: 1,1% para el subsistema de funcionamiento, 1,22% para el subsistema de refrigeración y 1,95% para el subsistema de cilindros. Para estos subsistemas, una desviación no muy alta mantenida en el tiempo podría ser un indicador del funcionamiento anómalo de algún elemento de dichos subsistemas.

Los siguientes avances en el presente campo de estudio deberían analizar las desviaciones acaecidas previamente a la ocurrencia de fallos reales en buques en operación, observando si se superaron los valores límite presentados en este estudio. Para ello, es necesario un gran trabajo de monitorización, ya que el fallo de un buque operativo no puede provocarse, y de ocurrir, tiene que coincidir con el hecho de que dicho buque tenga su sistema de propulsión monitorizado. Sin embargo, como ya se ha mencionado en el estudio del estado del arte, en un futuro cercano el trabajo de monitorización en los buques será más intenso en un contexto en el que la digitalización de la flota está tomando un papel esencial. En este momento, este equipo de investigación está trabajando con el motor YANMAR 6HYM-WET utilizado en el segundo capítulo provocando algunos fallos de modo controlado en condiciones de laboratorio para estudiar sus efectos en el funcionamiento del motor. La inclusión de modelos termodinámicos para simular situaciones de fallo de los motores y después entrenar redes neuronales con dichos datos también se está estudiando, sin tener la necesidad de provocar los fallos en el motor real. Para ello, los valores límite establecidos en el presente estudio servirán para establecer desviaciones no correspondientes a un motor sano (representativas de fallos) en dichos modelos termodinámicos.

DISCUSIÓN GENERAL

Contexto de la tesis

El transporte marítimo ha sido el medio de transporte de bienes más utilizado a nivel mundial en las últimas dos décadas [221]. En este marco, se estima que para 2050 el transporte marítimo se triplique a causa de la creciente demanda de transporte de bienes a nivel mundial [4]. Por ello, en los últimos años la Unión Europea ha puesto en marcha varias iniciativas como el Plan del Objetivo Climático para 2030 [5] con el fin de reducir y en última instancia eliminar las emisiones de gases de efecto invernadero para el 2050. Según Naciones Unidas, los compromisos actuales adoptados por los países que integran naciones unidas llevarían a un aumento del 14% en las emisiones de gases de efecto invernadero para 2030 [222], avanzando en dirección opuesta al objetivo de eliminarlas para 2050. En este marco, en la actualidad ya existen combustibles potencialmente útiles para reducir las emisiones de los sistemas de propulsión marinos. El gas natural licuado (LNG) es uno de estos combustibles, que según el ICCT (International Council of Clean Transportation) podría llegar a reducir entre 12-27% las emisiones de gases de efecto invernadero en el transporte marítimo respecto a los combustibles convencionales [223]. Por otro lado, el gas licuado del petróleo (LPG), que consiste en una mezcla de propano y butano, también se postula como firme candidato a ser utilizado en futuros buques, según la asociación mundial del LPG (WLPGA) [224]. Combustibles alternativos como el metanol o el etanol también están siendo objeto de estudio en los últimos años [225, 226]. Pese a que en algunos estudios se consiguen reducir las emisiones de gases contaminantes de NO_x o CO, reduciendo en todos ellos las emisiones de humo, el consumo volumétrico de combustible de dichos combustibles alternativos que incluyen n-butanol o etanol es superior que el del combustible diésel convencional [227, 228]. Por último, en la actualidad existe una fuerte apuesta hacia la electrificación e hibridación de la flota, con proyectos como el ORTZE-CV del programa estratégico Hazitek (ZE-2017/00005) del Gobierno Vasco en el que ha participado AZTI-BRTA, en el que se ha construido el primer buque híbrido en el País Vasco [229].

La presente tesis se plantea pues, en un periodo en el que se está apostando por el reemplazamiento de los combustibles fósiles, tanto a nivel europeo como a nivel estatal y autonómico. Sin embargo, la realidad es que la demanda del gasoil tiene aún una tendencia claramente creciente, esperando valores de demanda superiores para los próximos años [9]. De hecho, de acuerdo con un estudio reciente llevado a cabo por la agencia internacional Statista, tanto en 2019 como en 2020, los combustibles más utilizados a nivel mundial para buques de gran porte (por encima de 5000 GT) son: fueloil pesado, fueloil ligero, diésel y gas natural licuado [230]. Este hecho, demuestra que a medio corto plazo, y en un contexto en el que la Unión

Europea pretende restringir los combustibles fósiles, el ámbito marítimo seguirá apostando por ellos. Por otro lado, en un marco en el que las grandes empresas del ámbito marítimo apuestan por la digitalización, el desarrollo de modelos de los sistemas de propulsión de buques para su diagnóstico y mantenimiento basado en condiciones puede colaborar a reducir los incidentes marinos derivados de pérdidas de propulsión, que a día de hoy son el tipo de incidente más común (independientemente del combustible utilizado) [12].

Además, si bien es cierto que parte de la presente tesis emplea estrategias de modelado basadas en softwares de simulación termodinámicos, gran parte de ella emplea estrategias de modelado basadas en datos. Esto facilita la aplicación de dichas estrategias en otro tipo de sistemas de propulsión como el híbrido o los motores propulsados por combustibles alternativos.

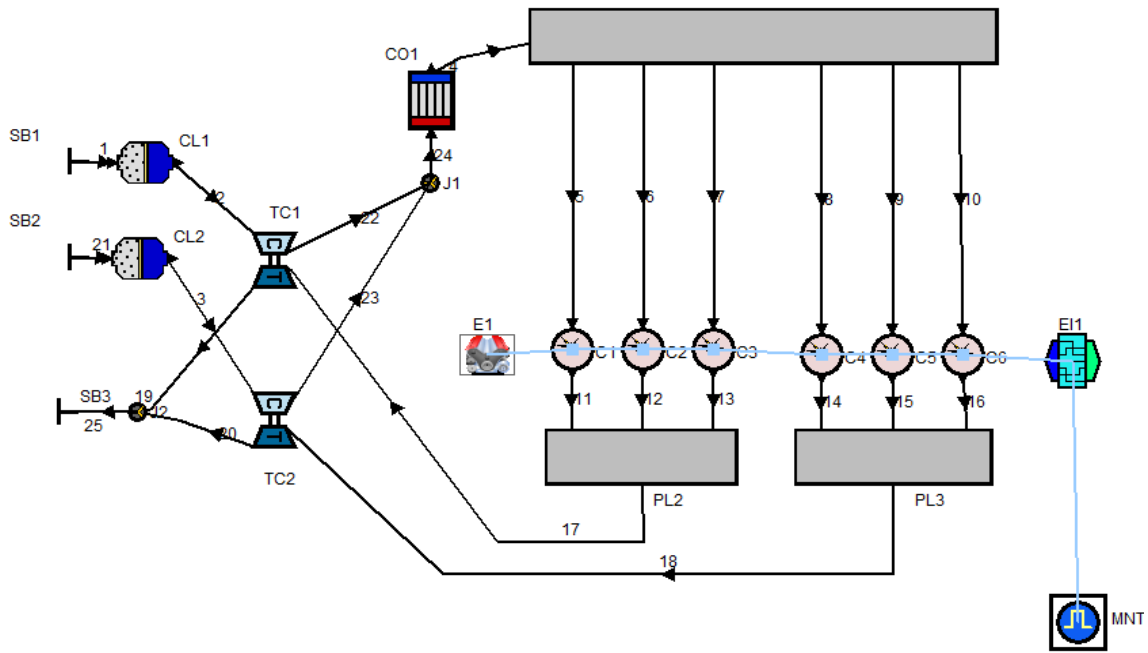
Ventajas y desventajas de las diferentes estrategias de modelado

Tras la revisión bibliográfica preliminar de la tesis, se observa la predominancia de dos metodologías de modelado de motores diésel sobre el resto: los modelos termodinámicos y las redes neuronales artificiales. Para un estudio inicial de ambas estrategias de modelado, se ha empleado el motor Minsel430a de un cilindro. Por un lado, este es un motor relativamente simple, lo que permite un ajuste apropiado del modelo termodinámico, sin la necesidad de incluir elementos más complejos de ajustar como los turbocompresores o grandes cantidades de elementos (enfriadores de aire, colectores con más de 1 cilindro etc.). Por otro lado, el consumo de este tipo de motores es notablemente menor que el que requieren otros motores más grandes, variando en torno a los 2-5 l/h, mientras que el motor YANMAR 6HYM-WET empleado en el Capítulo 2 consume entre 20-120 l/h [231]. Por lo tanto, para cuantificar las ventajas de cada estrategia de modelado y adquirir experiencia suficiente con las diferentes metodologías para el desarrollo de los modelos, se han realizado numerosos ensayos en este primer motor.


Por un lado, primero se ha ajustado el modelo termodinámico al motor real introduciendo todas las características físicas de este, y después ajustando el modelo de combustión mediante una función que contiene dos funciones Vibe para la representación de la curva de tasa de liberación de calor (ROHR). Después, se ha validado el modelo comparando las curvas de combustión modeladas y reales de forma análoga a otros estudios que han desarrollado también modelos termodinámicos de motores diésel [86, 98]. La necesidad de una correcta validación del modelo, previa a cualquier cálculo o predicción con este se considera indispensable. Por ejemplo, algunos

trabajos de investigación han utilizado modelos termodinámicos no validados experimentalmente para analizar el uso de combustibles alternativos en un motor diésel [232], o para analizar el efecto de parámetros concretos como el ratio de compresión o la presión de sobrealimentación en el funcionamiento de un motor marino dual que emplea hidrógeno y diésel [233]. Sin embargo, pese a que estos estudios provean valiosos resultados para entender las interacciones entre elementos del motor o el comportamiento de este frente a combustibles alternativos, se considera que para simular un motor real con un gran nivel de exactitud es necesaria una validación experimental de dicho modelo.

Aprovechando la experiencia adquirida mediante el motor de un cilindro, en la última fase de la tesis se ha modelado el motor YANMAR 6HYM-WET empleando el software AVL Boost. Mediante este modelo se ha pretendido predecir seis parámetros de funcionamiento diferentes a lo largo del espectro de carga completo del motor: presión y temperatura del aire a la entrada del enfriador de aire, presión y temperatura del aire a la entrada del motor, temperatura de gases de escape y consumo de combustible. Los resultados se han presentado en el congreso internacional ATE-HEFAT 2022 [234]. Tras validar el modelo comparando las curvas de combustión modeladas y reales como ya se hizo previamente en el motor de un cilindro, los resultados obtenidos para estos seis parámetros han sido muy favorables, resaltando una vez más el potencial de este tipo de validación. En la Figura D. 1a se muestra el esquema del motor YANMAR 6HYM-WET y en la Figura D. 1b se muestran los resultados para dos de los parámetros calculados: temperatura de gases de escape y presión del aire a la entrada del enfriador (presión a la salida del compresor).



a. Esquema del modelo del YANMAR 6HYM-WET desarrollado en AVL Boost



b. Resultados del modelo para el cálculo de la temperatura de gases de escape de la presión de compresión para Pcomp

Figura D. 1 Modelo de AVL Boost y resultados de sus cálculos

En cuanto a las redes neuronales artificiales, en el Capítulo 1 de la tesis se han estudiado las diferentes técnicas para hallar la red neuronal óptima para modelar el motor diésel de un cilindro, y así entender las ventajas de cada algoritmo de cara a futuros estudios. Para ello, se han empleado diferentes algoritmos de optimización con objeto de hallar aquel algoritmo que ajuste el modelo con la máxima precisión posible. Por un lado, se ha visto que uno de los métodos de descenso de gradiente más recientes es el algoritmo Adam [170]. Este algoritmo está soportado en la librería Keras de Python [235], por lo que se ha desarrollado una red neuronal en este entorno de programación. Por otro lado, también se ha observado que uno de los algoritmos más utilizados para entrenar redes neuronales en este campo es el algoritmo de Levenberg-Marquardt [173]. Este algoritmo no está soportado en Keras, por lo que se ha tenido que desarrollar otra red neuronal independiente en el software matemático Matlab. Del mismo modo, el algoritmo Adam no está disponible entre los algoritmos de entrenamiento de Matlab [236]. Es importante resaltar que, hasta el momento no se han visto otros estudios en torno al modelado de motores que hayan comparado estos dos algoritmos de optimización. Recientemente, Can et al. [237] han comparado tres algoritmos de optimización diferentes para modelizar el funcionamiento de un motor diésel empleando biodiésel: Conjugate Gradient,, Backpropagation with momentum y Levenberg-Marquardt. Entre las conclusiones, se ha observado un mejor rendimiento del algoritmo de Levenberg-Marquardt respecto al resto. Ese hecho concuerda con la conclusión extraída por Rezaei et al. [175], que compararon 12 algoritmos de entrenamiento diferentes concluyendo que Levenberg-Marquardt ofrecía los mejores resultados en cuanto a ajuste con la medición real. Sin embargo, estos estudios no incluyen el algoritmo Adam en sus comparaciones aun habiendo sido considerado el más eficaz en cuanto a algoritmos basados en el descenso de gradiente [126]. Esto puede estar causado en parte por el hecho de que ambos algoritmos no estén soportados en un mismo software y haya que diseñar dos redes neuronales artificiales para llevar a cabo tal comparación.

Por ello, el análisis de ambos algoritmos realizado en el presente estudio ofrece resultados muy significativos y novedosos de cara a futuros estudios en el campo del modelado de motores diésel. Tras el análisis de ambos algoritmos, se ha notado una ligera predominancia del algoritmo Levenberg-Marquardt, que ha sido escogido como el algoritmo de entrenamiento en el caso del motor Minsel430a.

Respecto al tiempo de cálculo de ambas metodologías de modelado, las redes neuronales artificiales son notablemente más rápidas que el modelo termodinámico. Esto se ha probado experimentalmente en el motor de un cilindro Minsel430a; las redes neuronales han necesitado 0,52 segundos para calcular 4 parámetros en 20 situaciones de testeo diferentes, mientras que el modelo termodinámico ha necesitado 1.234,29 segundos para calcular los mismos valores. En algunos casos de estudio se habla de simulaciones en tiempo real [238] sin especificar el tiempo de cálculo necesitado por el modelo, alegando que los tiempos de cálculo necesitados por tales modelos son reducidos. Sin embargo, para demostrar su valía en aplicaciones de tiempo real, es necesario cuantificar el tiempo de cálculo necesitado para presentar los resultados. En el caso del Capítulo 1 de la presente tesis, se concluye que el tiempo necesitado por el modelo termodinámico es demasiado alto para este tipo de aplicaciones. Sin embargo, para parámetros que se obtengan con una frecuencia de muestreo de 1 segundo, el tiempo de cálculo alcanzado por las redes neuronales resultaría suficientemente bajo como para llevar a cabo un análisis de desviaciones entre modelo y valores reales en tiempo real.

Por otro lado, el modelo termodinámico ofrece muchos resultados útiles una vez realizados los cálculos. Por ejemplo, calcula la presión de combustión en el interior del cilindro con altos niveles de exactitud, en comparación a otros modelos descritos como Digital Twin [239]; este parámetro puede ser indicativo de la obstrucción en el inyector de alguno de los cilindros del motor [240] o un exceso de blow-by en el cilindro [241]. Además, una vez realizado el ajuste del modelo termodinámico, este puede ser utilizado para numerosas aplicaciones (ej. análisis de combustibles alternativos [242] o simuladores de fallos [98]). Por otro lado, también se puede utilizar para completar y mejorar bases de datos de motores en situaciones de fallo [99]. Es por ello que, pese a no ser una herramienta suficientemente rápida para su aplicación en procesos de identificación de fallos en tiempo real, esta es una herramienta con múltiples aplicaciones. Es más, este tipo de metodologías son mucho más rápidas que los ensayos experimentales convencionales. Es por ello que, una posible aplicación consistiría en ajustar este modelo conduciendo unos pocos ensayos experimentales (como se ha hecho en los casos presentados en los congresos internacionales HEFAT2021 [206] y HEFAT2022 [234]), para después utilizar dicho modelo para crear una base de datos y entrenar métodos de cálculo más rápidos como las redes neuronales artificiales, como se explicará en el apartado de trabajo futuro.

Simulación en tiempo real de motores diésel marinos en condiciones reales

Tras plantear las diferentes metodologías de modelado de motores, se ha observado que, las redes neuronales ofrecen niveles de precisión similares e incluso mayores que el modelado termodinámico. Esto, junto con su rapidez y adaptabilidad ha atraído el interés de numerosos autores para calcular variables de diferentes tipos simultáneamente (ej. consumo de combustible, emisiones, temperaturas etc.). Sin embargo, en la mayoría de los trabajos de esta índole se han observado cantidades relativamente reducidas de outputs, manteniéndose por debajo de 8-10 parámetros calculados con un solo modelo [131, 132, 134]. En la presente tesis, el motor utilizado en el Capítulo 2 presentaba un alto grado de sofisticación en términos de registro de variables, obteniendo más de 40 variables simultáneamente cada segundo. Por ello, se ha dado un paso adelante en el modelado de motores marinos mediante las redes neuronales artificiales, prediciendo 35 parámetros de funcionamiento y emisiones del motor a partir de 8 parámetros utilizados como inputs del modelo y mostrando una imagen completa del estado del motor.

Por otro lado, también se ha observado una ausencia de trabajos que consideren las auténticas condiciones a las que puede estar expuesto un motor diésel marino. Entre los estudios que han incluido estas condiciones de mar en sus modelos, se denota una tendencia a modelar el sistema de propulsión en condiciones ambientales concretas, sin considerar diferentes situaciones meteorológicas o factores externos cambiantes como puedan ser las corrientes marinas. Por ejemplo, Mocerino et al. [83] calcularon la potencia, el consumo específico y las emisiones considerando las condiciones reales de un buque. Sin embargo, de acuerdo con la Figura 10 de su artículo, la relación entre la potencia del buque y la velocidad de giro atiende a una función única. Como ya se ha mencionado previamente, en el caso de los motores marinos, la relación entre estos dos parámetros que según Theotokatos [189] se aproxima a una función cúbica, puede variar de acuerdo con condiciones externas como los factores meteorológicos o las corrientes marinas. Es por ello que, tras definir el mapa de funcionamiento del motor YANMAR 6HYM-WET mediante varias funciones cúbicas (dentro de los límites del motor), se ha diseñado un modelo de redes neuronales artificiales para mostrar una imagen completa del motor en cualquier punto de su mapa de funcionamiento.

En este aspecto, algunos trabajos de investigación han desarrollado gemelos digitales que calculan múltiples parámetros del motor para compararlos después con los parámetros reales. Stoumpos et al. [217] desarrollaron un modelo para calcular la respuesta transitoria de múltiples parámetros de un motor marino dual (ej. presión de sobrealimentación, velocidad de giro del turbocompresor, consumo de diésel y de gas etc.). De forma análoga, Bondarenko et al. [29] calcularon el desarrollo de varios parámetros de un motor diésel para diferentes cambios en la carga del motor mediante el desarrollo de un gemelo digital (presión del aire a la entrada del motor, temperatura del aire a la entrada del turbocompresor etc.). Pese a que el nivel de precisión logrado en su trabajo es relativamente alto, este es un análisis útil para ver cómo se comporta un motor a lo largo del tiempo, pero no una herramienta útil para detectar desviaciones en tiempo real.

En cuanto al modelo de redes neuronales artificiales desarrollado en el Capítulo 2 de la presente tesis, los 35 parámetros de funcionamiento y emisiones del motor han sido calculados con errores por debajo del 8,5% a excepción de las emisiones de CO y NO₂ que han mostrado errores de 25,60% y 48,84%, respectivamente. Es importante entender que estas predicciones han sido realizadas en situaciones aleatorias del mapa de funcionamiento completo del motor, considerando factores externos existentes en la operativa real de este (meteorología, corrientes, tipo de pesca etc.). En este caso, el tiempo de cálculo para calcular 35 variables en 24 situaciones diferentes ha sido de 0,109 segundos. Nótese que pese a ser una red con dimensiones mucho mayores que la utilizada en el Capítulo 1, el tiempo de cálculo es aún menor (0,109 segundos vs 0,52 segundos). Esto se debe a que la toma de tiempo del Capítulo 1 se realizó promediando 3 tomas manuales de tiempo, mientras que la toma de tiempo del Capítulo 2 se realizó con un script implementado en Matlab para conocer el tiempo exacto de cálculo, por lo que el tiempo de cálculo del Capítulo 1 podría estar ligeramente sobreestimado. En todo caso, el tiempo de cálculo es muy reducido, pudiendo calcular las desviaciones presentadas en la Figura C2. 12 del Capítulo 2 en una décima de segundo.

Ahora bien, teniendo en cuenta el contexto en el que se encuentran los sistemas de propulsión marinos que emplean combustibles fósiles, puede que a medio-largo plazo se necesite implementar este tipo de modelos en sistemas de propulsión híbridos o sistemas que empleen combustibles alternativos. En este aspecto, los modelos termodinámicos pueden cubrir la simulación de motores convencionales empleando combustibles alternativos, pero no incluyen módulos para simular sistemas de propulsión híbridos. En cambio, las redes neuronales por definición adaptan sus conexiones para “aprender de ejemplos” como describieron el proceso de entrenamiento basado en datos Jain y Mao [243]. De hecho, pese a que el modelado de

sistemas híbridos mediante redes neuronales es de momento más común en el campo automovilístico [244-246], ya existen trabajos de investigación en torno al modelado de sistemas de propulsión marinos híbridos [247] con objeto de optimizar la gestión de la energía del buque. Por lo tanto, dada la demostración del presente estudio de las capacidades de las redes neuronales para calcular numerosos parámetros en tiempos de cálculo reducidos y con bajos niveles de error, se espera que su aplicación en el ámbito de los sistemas híbridos de propulsión crezca de forma considerable en las siguientes dos décadas.

En cualquier caso, mediante la medición de 8 parámetros se muestra una imagen completa de lo que sería un funcionamiento correcto de la máquina. La medida de estos parámetros en la mayoría de los buques de mediano o de gran porte se encuentra disponible o en su defecto, es una medida fácil de implementar (3 condiciones ambientales, potencia, velocidad de giro, temperatura de agua y aceite a la entrada del motor y temperatura de agua a la entrada del enfriador de agua). Puede suceder que para registros concretos el error de predicción del modelo sea alto, sin embargo, la identificación de un fallo concreto no se encontrará por una desviación dada en un registro en concreto, sino que se percibirá si la desviación de un parámetro en concreto es demasiado alta durante un periodo de tiempo. Sin embargo, ¿Qué desviaciones pueden observarse entre el modelo y la realidad cuando el motor funciona correctamente, y cuáles podrían ser indicativas del fallo del motor? Esto se ha abordado en el último capítulo de la presente tesis.

Caracterización de los valores límite del sistema de propulsión de un buque atunero operativo

Siguiendo la línea de la tesis, se han estudiado diferentes alternativas de modelado, y tras escoger las redes neuronales se ha analizado su capacidad de mostrar la imagen completa de un motor diésel marino para cualquier situación en la que pueda encontrarse. Esta imagen per se podría ser indicativa de posibles fallos si se supera un umbral o si se da una desviación demasiado alta en alguno de los parámetros del motor. Pero, las desviaciones límite entre el funcionamiento correcto y el funcionamiento anómalo de un motor no están por lo general debidamente justificadas en los trabajos de detección de fallos en los motores. Como ya se ha mencionado en la identificación del problema de la tesis, algunos trabajos muestran directamente los valores límite considerados como indicadores de fallo [143] sin evidenciar debidamente su origen, mientras que otros toman directamente los valores máximos de error

entre modelo y realidad como valores límite de desviaciones [141]. En algunos casos, el análisis de funcionamiento anómalo de un motor se realiza observando las desviaciones de sus parámetros respecto a la línea base (“baseline”) de cada uno de ellos [248]. Sin embargo, existen parámetros como la temperatura de gases de escape que tienen altos niveles de variabilidad dependiendo de la condición en la que se encuentra el motor (ej. dependiendo de la potencia que esté entregando, la velocidad a la que esté girando etc.), cuya línea base es cambiante y la desviación respecto a esa línea base podría ser variable.

Por ello, en el último capítulo de la presente tesis se ha pretendido analizar los valores límite de múltiples parámetros en un motor a bordo de un buque de pesca operativo, para calcular las desviaciones que se pueden dar en este motor en funcionamiento correcto durante año y medio. Por otro lado, se ha estudiado la variabilidad y la correlación de todos los parámetros analizados, modelando aquellos con tendencias constantes con funciones de densidad de probabilidad (método alternativo a estudio de desviaciones respecto a línea base), y modelando los parámetros con altos niveles de variabilidad y correlación con redes neuronales artificiales. El resultado es una tabla de desviaciones de 57 parámetros que representa las desviaciones que ha podido sufrir cada parámetro sin ningún tipo de fallo durante el año 2020 y la primera mitad del año 2021. En otras palabras, se han mostrado las desviaciones límite de un motor en funcionamiento sano para 57 parámetros diferentes del motor durante un prolongado tiempo de operación.

Para este estudio, se han procesado hasta 5.181 horas de funcionamiento del buque a lo largo de año y medio. Eso ha desencadenado en una base de datos (previamente filtrada) de 299.052 registros de 61 variables. Para los parámetros con tendencias constantes, se han establecido desviaciones porcentuales máximas respecto a sus valores medios, y para los parámetros modelados con redes neuronales se han establecido las desviaciones entre modelo y valores reales. Para el caso de los parámetros modelados mediante funciones de densidad de probabilidad, todos los parámetros, independientemente del subsistema al que pertenezcan, se han desviado por debajo de un 10% de su valor medio, exceptuando la presión diferencial en el filtro de aceite y la temperatura del aceite a la salida del turbocompresor. Por ejemplo, en el caso de la temperatura del aceite a la salida del turbocompresor, se estima una desviación máxima de 11,57 % respecto a su media. Según Giakoumis [249], una temperatura de aceite demasiado baja, con su correspondiente incremento en la viscosidad, podría acarrear un incremento en la fricción de los elementos del motor, causando finalmente un crecimiento en el consumo de combustible entre otras consecuencias. Por otro lado, el filtro de aceite es un elemento crítico del motor, ya que en caso de estar obstruido podría dificultar la lubricación de

los diferentes elementos del motor y generar un desgaste prematuro del mismo [250]. Por otra parte, uno de los subsistemas con menores desviaciones es el sistema de refrigeración. Teniendo en cuenta que un fallo en el sistema de refrigeración puede afectar a múltiples parámetros como la temperatura dentro de la cámara de combustión, la tasa de liberación de calor o las emisiones de gases contaminantes (NO_x , CO etc.) [251], un incremento de la desviación porcentual en parámetros como la temperatura del agua de refrigeración a la salida de las camisas o en la temperatura del agua de refrigeración a la entrada del enfriador de aire podrían ser indicativas de un funcionamiento atípico del motor, acompañado de los correspondientes síntomas previamente mencionados. En conclusión, los valores límite establecidos mediante los intervalos de confianza de los parámetros con tendencias constantes pueden ser un adecuado punto de referencia para futuros trabajos en el campo de la identificación de fallos de los motores diésel. Y es que, en otros casos, las desviaciones respecto a valores normales (o medias) para considerar un fallo del motor son muy altas (ej. desviación del 150% en temperatura de camisas para considerar una incorrecta refrigeración de las camisas en [252]), lo que podría inducir una identificación postergada del fallo.

Por otro lado, los parámetros modelados mediante redes neuronales artificiales han mostrado errores porcentuales notablemente bajos. Nótese que los errores presentados como errores límite en el Capítulo 3 son los máximos errores vistos entre los registros de testeado de 2020 y los registros de testeado de 2021. Si solo se hubieran testeado las redes neuronales con datos del 2020, algunos parámetros mostrarían errores demasiado bajos. Para asegurar que los errores presentados se ajustaban a la realidad, se decidió testear las redes con datos del año 2021, que en algunos casos estaban tomados meses después de aquellos que se han utilizado para entrenar las redes. En conclusión, pese a testear la red con todo tipo de registros provenientes de los años 2020 y 2021, los errores porcentuales alcanzados son relativamente bajos. Por un lado, se observa la alta correlación entre los parámetros de funcionamiento (FORACK y velocidad de giro del turbocompresor) con el funcionamiento del motor. Este hecho se puede ver reflejado en los trabajos de investigación que han calculado el consumo de combustible (relacionado directamente con el FORACK) con niveles muy bajos de error [123, 194]. Concretamente, Wang et al. [253] resaltaban la gran relación entre la presión del sistema “common rail”, la velocidad de giro del motor, la carga del motor y el parámetro FORACK, tras desarrollar un controlador de la presión en este tipo de sistema de inyección en un motor diésel marino.

En cuanto al sistema de refrigeración, los errores obtenidos son muy bajos para todos los parámetros de este subsistema. El hecho de que este subsistema presente errores por debajo del 1,22% requiere de dos matizaciones: i) se observa el alto nivel de correlación de los parámetros de los sistemas de refrigeración del motor que ya acarrearón errores muy bajos en el estudio del motor YANMAR del Capítulo 2 con errores por debajo de 4,22%; ii) el hecho de que en el presente estudio se hayan alcanzado errores tan bajos no implica directamente que para cualquier otro motor se hubieran conseguido estos errores. Estos son valores orientativos y cada motor debería estudiarse considerando sus características. Sin embargo, estas desviaciones podrían servir como referencia para saber que un error no demasiado alto en el sistema de refrigeración podría estar causado por el comportamiento anómalo de algún elemento del motor, sin tener que llegar a desviaciones de 55,55% presentadas por Hu et al. [252] para considerar una temperatura anómala del agua de alta temperatura.

Por último, se observa que en algunos parámetros del sistema de aire y gases de escape los errores alcanzados son ligeramente superiores que en el resto del motor. En el caso de la temperatura de gases de escape a la salida del turbocompresor, se ha establecido una máxima desviación entre modelo y realidad del 7,34%. Sin embargo, este no es un nivel de desviación muy alto si se tienen en consideración otros estudios como el llevado a cabo recientemente por Aiello et al. [254], en el que se defiende que una desviación de $\pm 80^{\circ}\text{C}$ respecto al valor medio de la temperatura de gases de escape es considerada normal. Suponiendo una temperatura de 350°C para los gases de escape, este valor de “desviación normal” induciría una desviación porcentual del 22,86%, que es notablemente superior que las desviaciones alcanzadas en el presente estudio. Finalmente, tras observar las desviaciones dadas en otros estudios para situaciones de fallo distintas del motor [36, 98] se concluye que los valores límite establecidos en el presente estudio son apropiados y extrapolables a otros casos, siempre teniendo en cuenta las características específicas de cada motor.

Desarrollo de la tesis: desde un motor monocilíndrico hasta un motor (policilíndrico) de un buque atunero en condiciones reales de operación

Llegado este punto, conviene mostrar el desarrollo que ha seguido la presente tesis doctoral, tanto por los motores utilizados como por las dimensiones de las bases de datos utilizadas. En este aspecto, los recursos físicos proporcionados tanto por la Universidad del País Vasco como por el centro de investigación AZTI-BRTA han facilitado el desarrollo progresivo del presente trabajo de investigación a lo largo de 3 años. A medida que se ha ido adquiriendo experiencia en el campo del modelado y creación de gemelos digitales de motores, se ha ido avanzando hacia motores de mayores dimensiones, utilizados en buques de pesca y de transporte marítimo en la actualidad. En la Figura D. 2 se muestra un esquema del desarrollo de la tesis en estos términos.

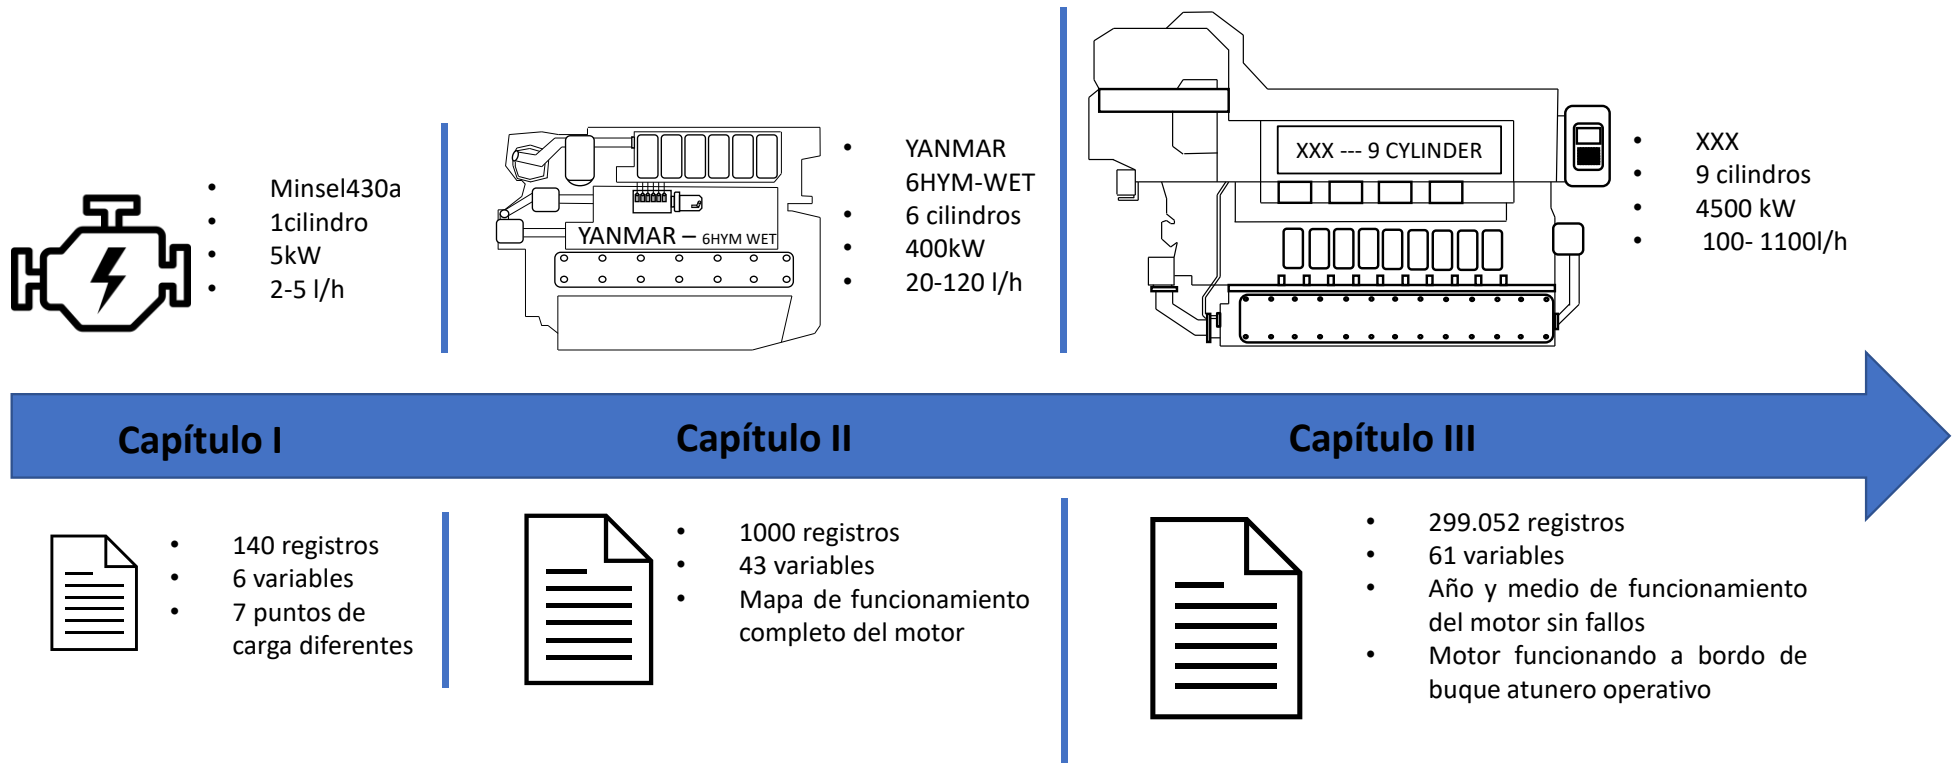


Figura D. 2 Desarrollo de la tesis doctoral. Motores analizados y bases de datos utilizadas

En una primera fase de la tesis y tras realizar una revisión bibliográfica exhaustiva, se ha trabajado con un motor relativamente pequeño, no llegando a representar a un motor marino, pero sirviendo como punto de referencia para entender las técnicas de modelado más utilizadas e implementarlas experimentalmente sin un coste de ensayos demasiado alto. Tras observar el potencial de las redes neuronales, se planteó implementar esta técnica de modelado en un motor más grande, el YANMAR 6HYM-WET, el cual es utilizado en buques de mediano porte (250-400 GT). Por ello, se han llevado a cabo numerosos ensayos con objeto de caracterizar el mapa de funcionamiento de este motor. Como resultado, tanto el número de registros como el número de variables empleados en este nuevo análisis han sido notablemente superiores, finalmente testeando el modelo en puntos aleatorios del mapa de funcionamiento del motor y obteniendo resultados muy positivos en términos de precisión y rapidez. Por último, el Capítulo 3 ha tenido como base de estudio un año y medio de operación de un motor instalado a bordo de un buque atunero operativo. De esta forma, los datos provenientes del año 2020 con los que se han diseñado los modelos de redes neuronales y funciones de densidad de probabilidad contienen 299.052 registros de 61 variables. Esta es la dimensión de la base de datos ya filtrada; y es que, en este último capítulo de la tesis, se han desarrollado también diferentes scripts para el filtrado de bases de datos crudas provenientes directamente del sistema de adquisición del buque. Se observa pues, que desde el comienzo en un motor pequeño con una cantidad de registros reducida, se ha finalizado la tesis con datos experimentales directamente provenientes de un buque operativo, proporcionando un gran valor añadido al estudio realizado y manejando bases de datos de dimensiones no vistas en la literatura existente en el ámbito de esta tesis.

CONCLUSIONES Y TESIS

1- Conclusiones

La presente tesis doctoral está centrada en el desarrollo de diferentes estrategias de modelado o gemelos digitales de los motores diésel marinos. Tras realizar una revisión bibliográfica preliminar, como fase inicial de la tesis se plantearon dos de las metodologías de modelado más utilizadas en la literatura existente, con objeto de cuantificar las ventajas y desventajas presentadas por cada una de ellas experimentalmente. Tras observar las ventajas comparativas de las redes neuronales artificiales para alcanzar altos niveles de precisión en bajos tiempos de cálculo, se pasó a modelar un motor diésel marino de 6 cilindros con esta metodología. Con ánimo de estudiar la viabilidad de calcular en tiempo real la imagen completa del estado un motor, se diseñó un modelo capaz de predecir 35 parámetros del motor en cualquier punto del mapa de funcionamiento del mismo, considerando cualquier tipo de factor externo existente en el medio marino (meteorología, corrientes etc.). Por último y para cerrar la presente tesis, se ha estudiado el funcionamiento de un motor de 9 cilindros a bordo de un buque atunero, con objeto de establecer los valores límite que pueden alcanzar 57 parámetros diferentes del motor sin haber sufrido ningún fallo durante un año y medio. De esta forma, se han propuesto los límites de desviaciones entre funcionamiento normal y anómalo de todos estos parámetros, para servir como punto de referencia en futuros estudios de detección de fallos en motores. De esta forma, se completa lo que se considera un proceso aplicable para la diagnosis y el mantenimiento basado en condiciones de cualquier motor diésel marino, primero creando un modelo rápido y preciso, y después analizando sus desviaciones teniendo en cuenta los resultados obtenidos en el último capítulo de la tesis. De acuerdo con la definición de la problemática planteada al comienzo de la tesis y los objetivos establecidos, se presentan las siguientes conclusiones:

- 1- El transporte marítimo es el medio de transporte más utilizado a nivel mundial, habiendo representado el 69,3% de las exportaciones y el 74,1% de las importaciones de la Unión Europea en 2020. En este contexto, pese a que la Unión Europea esté estableciendo numerosas restricciones para eliminar las emisiones provenientes de combustibles fósiles para 2050 en el marco del plan Net-zero 2050, la demanda de combustibles fósiles como el gasoil es cada año mayor. Por ello, se espera que a corto-medio plazo los sistemas de propulsión marinos sigan empleando los combustibles fósiles. No obstante, alternativas como el gas licuado natural o la hibridación de los sistemas de propulsión deberán jugar un papel importante en los siguientes años para tratar de cumplir los objetivos de la Unión Europea.

- 2- El tipo de incidente marino más común es la pérdida de propulsión de los buques. En este aspecto, el número de incidentes reportados a causa de este tipo de fallo podría reducirse si se plantea una correcta estrategia de mantenimiento basado en condiciones en un contexto en el que la flota pesquera española decrece año tras año, con un decrecimiento anual por encima de la media europea. Este tipo de mantenimiento es beneficioso en términos financieros y de seguridad a bordo. Una de las vías para llevar a cabo este tipo de mantenimiento es el desarrollo de un modelo preciso del sistema de propulsión y la observación de las desviaciones entre modelo y motor real para identificar anomalías en el motor. En este marco, entre todas las metodologías que han provocado un creciente interés en las últimas décadas, se observa la predominancia de dos de ellas para el cálculo de parámetros de los motores: modelo termodinámico y modelo de redes neuronales artificiales.
- 3- Para un correcto ajuste del modelo termodinámico, es necesario introducir las características físicas de los diferentes elementos del motor, y después ajustar adecuadamente su modelo de combustión para alcanzar un nivel alto de precisión en la simulación. En este marco, la validación mediante la comparación de curvas de combustión modeladas y reales ha demostrado ser una técnica eficaz, tanto en el motor diésel de un cilindro Minsel430a como en el motor diésel marino de 6 cilindros YANMAR 6HYM-WET. En cuanto a las redes neuronales, el algoritmo de optimización Levenberg-Marquardt ha demostrado ser más rápido y preciso que el método Adam basado en los métodos de descenso del gradiente. Además, para pequeñas bases de datos la determinación de la estructura de la red mediante el análisis de error en las fases de entrenamiento y validación ha demostrado un gran potencial, proveyendo finalmente altos niveles de precisión en la fase de testeo.
- 4- Tras la validación experimental de las metodologías de modelado termodinámico y redes neuronales artificiales, los niveles de error de cada modelo han sido mejores o peores dependiendo de la carga del motor y el parámetro calculado. Para el consumo específico de combustible, las redes neuronales han ofrecido mayores niveles de precisión para todo el espectro de carga del motor. Sin embargo, para la predicción de la temperatura de gases de escape, el modelo termodinámico ha mostrado mejores resultados a cargas medias-bajas, mientras que las redes neuronales han sido más precisas a cargas muy bajas y a cargas medias-altas. No obstante, ambos modelos han mostrado altos niveles de precisión, con errores por debajo del 6% para el consumo

específico de combustible y por debajo del 2% para la temperatura de gases de escape. En cuanto al monóxido de carbono, las emisiones de CO han sido calculadas con mejores niveles de precisión por el modelo termodinámico para todo el espectro de carga del motor, exceptuando las cargas más altas en las que el modelo termodinámico no ha sido capaz de simular el incremento de estas emisiones, mientras que las redes neuronales si lo han hecho. Las emisiones de NO_x han sido calculadas con altos niveles de precisión por ambos modelos, exceptuando las cargas más bajas del motor.

- 5- El tiempo de cálculo necesitado por el modelo termodinámico para calcular 4 parámetros en 20 situaciones diferentes ha sido 1.234,29 segundos, mientras que las redes neuronales han necesitado 0,52 segundos. Este hecho prueba la valía de las redes neuronales artificiales para procesos de mantenimiento en tiempo real, mientras que el modelo termodinámico necesita demasiado tiempo como para ser empleado en este tipo de aplicaciones. Sin embargo, una vez realizados los cálculos el modelo termodinámico ofrece muchos parámetros adicionales (ej. presión de combustión, tasa de liberación de calor etc.) que pueden ser de gran utilidad para la diagnosis de los motores.
- 6- Las redes neuronales artificiales han confirmado su capacidad de adaptación y robustez para mostrar la imagen completa de un motor diésel marino de 6 cilindros (YANMAR 6HYM-WET), calculando simultáneamente 35 parámetros de funcionamiento y emisiones con un alto nivel de exactitud. Concretamente, se han calculado todos los parámetros con un error porcentual por debajo de 8,5%, exceptuando las emisiones de CO y NO₂ que debido a sus reducidas concentraciones en este tipo de motores han mostrado errores de cálculo elevados (25,60% y 48,84% respectivamente).
- 7- La capacidad de regresión de las redes neuronales artificiales ha permitido calcular la imagen completa de un motor diésel marino con altos niveles de precisión para cualquier condición dentro de su mapa de funcionamiento completo, trabajando bajo factores externos existentes en el medio marino (meteorología, corrientes etc.). Los parámetros pertenecientes a los subsistemas de agua de baja y alta temperatura, circuito de aceite y circuito de gases de escape han mostrado errores por debajo de 4,3%, aun siendo calculados en condiciones aleatorias dentro del mapa de funcionamiento del motor. El tiempo registrado por Matlab para el cálculo de 35 parámetros de funcionamiento y emisiones en 24 situaciones diferentes ha sido 0,109

- segundos, demostrando una vez más la aplicabilidad de este tipo de metodologías a procesos de simulado de motores o en tiempo real.
- 8- La determinación de la estructura óptima de una red neuronal es viable mediante el software de uso abierto KerasTuner, evitando así entrenar y validar el modelo para cada configuración en los casos de estudio que manejen grandes dimensiones de datos. Se ha establecido la estructura óptima de cuatro redes neuronales artificiales para un base de datos de 299.052 registros extraídos de dos años de funcionamiento de un motor diésel marino, proveyendo bajos niveles de error para todos los parámetros calculados tras establecer las estructuras de las cuatro redes con este programa.
 - 9- Los parámetros con tendencias constantes pueden incrementar el nivel de error de cálculo de las redes neuronales. Esto ha sido validado experimentalmente en un motor diésel de un cilindro, demostrando que la eliminación de parámetros de baja correlación del vector input del modelo mejora su nivel de precisión. Por ello, se considera indispensable un estudio previo de desviación y correlación de los parámetros a modelar, para entender el comportamiento de cada variable de forma preliminar y decidir las estrategias de modelado para cada una de ellas.
 - 10- Las funciones de densidad de probabilidad han demostrado ser una alternativa eficaz para modelar los parámetros con tendencias constantes de los motores y estudiar sus rangos de variación. El cálculo de intervalos de confianza ha permitido establecer los límites de desviaciones para múltiples parámetros de un motor diésel marino a bordo de un buque atunero operativo, utilizando datos registrados durante todo el año 2020. Tras probar dichos límites con registros provenientes de la primera mitad del año 2021, se ha obtenido un ratio máximo de error del 1,21%, observando un máximo de 20 fallos de los límites establecidos para los 1.647 registros probados en 2021. Estos fallos provienen de registros aislados que no se extienden en el tiempo, por lo que también se observa que, para considerar un funcionamiento anómalo del motor, los límites deberían sobrepasarse durante un tiempo prolongado.

- 11- Las redes neuronales artificiales han mostrado altos niveles de precisión para registros tomados incluso meses después de los utilizados para su entrenamiento. Los parámetros de los subsistemas de funcionamiento, refrigeración y cilindros han sido calculados con errores de 1,1%, 1,22% y 1,95% respectivamente. Esta metodología ha demostrado nuevamente su capacidad de adaptación al funcionamiento cambiante de un motor a bordo de un buque operativo expuesto a los factores externos del medio marino.

2- Tesis

“Las redes neuronales artificiales son una solución efectiva para crear gemelos digitales de los motores diésel marinos, en aplicaciones de mantenimiento basado en condiciones y diagnosis de motores, pese a que en algunos casos requieran de modelos termodinámicos para emular procesos internos de la combustión. Las redes neuronales son capaces de mostrar una imagen completa de un motor diésel marino con un tiempo de cálculo reducido, aun considerando factores externos existentes en la operativa real de los buques, también sirviendo como herramienta para caracterizar valores límite de parámetros del motor para identificar situaciones de fallo.”


TRABAJO FUTURO

La presente tesis doctoral ha analizado varias metodologías de modelado de motores diésel marinos para procesos de diagnóstico y mantenimiento basado en condiciones. Los estudios llevados a cabo en este trabajo dejan varias vías de investigación abiertas. Por un lado, se ha visto que los modelos termodinámicos requieren mayores tiempos de cálculo que los modelos basados en inteligencia artificial. Sin embargo, el hecho de que el modelo termodinámico sea notablemente menos costoso que los ensayos experimentales, hace de este tipo de metodologías una alternativa interesante a las numerosas pruebas experimentales necesarias para entrenar correctamente una red neuronal. Por otro lado, las estrategias de modelado basadas en datos no necesitan resolver ecuaciones de conservación de masa, momento y energía para calcular los outputs. Es por ello que la aplicación de este tipo de metodologías no se limita únicamente a los motores alternativos de combustión interna, sino que son aplicables en muchos otros campos hacia los que camina la propulsión de los buques del futuro. Por ello, en el presente apartado se muestran algunos campos en los que trabajar tomando como punto de partida los desarrollos llevados a cabo en la presente tesis:


- Cálculo de múltiples parámetros de un motor diésel marino con redes neuronales artificiales entrenadas por modelos termodinámicos. A medida que se han ido modelando motores más grandes en los Capítulos de la presente tesis, se han necesitado muchos días de ensayos experimentales para poder generar una base de datos suficientemente grande para ajustar los modelos. Por ejemplo, para caracterizar el mapa de funcionamiento del motor YANMAR 6HYM-WET del Capítulo 2, se han tenido que ensayar numerosos puntos de funcionamiento diferentes del motor, necesitando para ello más de 20 días de ensayos con él. Sin ánimo de concreción y para mostrar una imagen del costo de ello, suponiendo que por día se ha tenido el motor 3 horas en marcha (realmente han sido muchas más horas) y suponiendo también un consumo medio de 60 l/h, se han gastado un total de 3600 litros de combustible para caracterizar el mapa de funcionamiento del motor. Como ya se ha visto en el trabajo presentado en el congreso internacional ATE-HEFAT2022 [234], los software de modelado termodinámico como AVL Boost son capaces de reproducir el funcionamiento del motor calculando múltiples parámetros de este con altos niveles de precisión, necesitando algunos pocos ensayos experimentales para ser ajustados y validados. Si bien es cierto que estos softwares necesitan demasiado tiempo de cálculo para ser utilizados en tiempo real, son una alternativa muy interesante para reemplazar a los numerosos ensayos experimentales necesarios para ofrecer una base de datos suficientemente extensa a las redes

neuronales. Por ello, sería interesante analizar si las redes neuronales artificiales entrenadas por modelos termodinámicos son capaces de simular el funcionamiento de un motor con altos niveles de precisión, probando estas redes en puntos aleatorios del mapa de funcionamiento del motor y analizando el error de cálculo.

- Desarrollo y validación experimental de simulador de fallos de motores diésel basado en modelos termodinámicos. En el desarrollo del modelo termodinámico de un motor diésel marino, el ajuste del modelo es el trabajo más complicado y requiere de un alto nivel de conocimiento de los diferentes elementos del motor. Estos motores contienen múltiples elementos que es necesario caracterizar al detalle para después lograr un alto nivel de precisión en los parámetros calculados. Una vez se logra este ajuste, el modelo termodinámico ofrece varias ventajas. Entre ellas, existe la posibilidad de introducir un cambio en algún parámetro del motor para simular un fallo. Por ejemplo, si se necesita simular un fallo de obstrucción en el filtro del aire de entrada, se incrementará la pérdida de presión en el elemento de filtro de aire del modelo. Hasta el momento, algunos trabajos de investigación han logrado desarrollar este tipo de simuladores de fallos. Uno de los trabajos más interesantes en este campo es el simulador desarrollado por Rubio et al. [98] utilizando como base un modelo termodinámico desarrollado con el software AVL Boost. Sin embargo, en este campo de estudio sería interesante que después de simular los fallos con el modelo, se pudieran comparar los parámetros calculados por el modelo ante situaciones de fallo con los parámetros reales dados por el motor en dichas situaciones. En este marco, el presente equipo de investigación ha puesto en marcha ya la simulación de diferentes fallos como la obstrucción de filtros de aire mencionada previamente. En la Figura D. 3a se muestra el filtro del aire de uno de los turbocompresores del motor YANMAR 6HYM-WET obstruido, mientras que en la Figura D. 3b se muestra la medición de la presión diferencial en dicho filtro mediante columnas de agua.



a. Obstrucción de filtro



b. Medición de presión diferencial

Figura D. 3 Ensayo y medición de obstrucción de filtro de aire

- Simulación de sistema de propulsión híbrido mediante redes neuronales artificiales.
Como ya se ha mencionado previamente, recientemente se ha construido el primer buque híbrido construido en el País Vasco en el marco del proyecto ORTZE-CV del programa estratégico Hazitek (ZE-2017/00005) del Gobierno Vasco y en el que ha participado AZTI-BRTA [229]. A lo largo de la presente tesis se ha resaltado una y otra vez la adaptabilidad de las redes neuronales artificiales a todo tipo de problemas y situaciones, incluyendo el modelado de diferentes motores aun empleando combustibles alternativos. En este caso, futuros trabajos deberían estudiar la viabilidad de este tipo de metodologías para simular sistemas de propulsión híbridos. En concreto, el presente equipo de investigación tiene registradas más de 40 variables en el buque ORTZE, y ha registrado ya los parámetros a lo largo de múltiples salidas. Uno de los cometidos de AZTI-BRTA en el proyecto ORTZE-CV era realizar una auditoría energética del sistema de propulsión antiguo y del nuevo sistema de propulsión híbrido. En este aspecto, para realizar la auditoría del sistema antiguo se realizaron unas pruebas de mar, recorriendo una milla a diferentes regímenes del motor. En este caso no hemos podido repetir dichas pruebas con el nuevo sistema para comparar ambos sistemas de propulsión. Sin embargo, teniendo registros de diferentes salidas realizadas con el nuevo sistema y modelando el sistema de propulsión mediante redes neuronales artificiales, se pretenderá simular dichas pruebas de mar con el modelo ajustado para después comparar ambos sistemas de propulsión.

REFERENCIAS BIBLIOGRÁFICAS

- [1] United Nations Conference on Trade and Development UNCTAD, Review of maritime transport 2021, United Nations Publications, (2021).
- [2] Eurostat, International trade in goods by mode of transport, in, 2022.
- [3] International Energy Agency IEA, International Shipping in: P. IEA (ed.), 2021.
- [4] Organisation for Economic Co-operation and Development OECD, Decarbonising maritime transport, in, 2022.
- [5] European-Commission, Stepping up Europe's 2030 climate ambition, in: 2030 Climate Target Plan, Brussels, 2020.
- [6] United-Nations, Paris Agreement, (2015).
- [7] D.T. Smith, Definition of zero carbon energy sources, GETTING TO ZERO COALITION, (2019).
- [8] E. Parliament, CO2 emission standards for cars and vans in: L. Observatory (ed.), 2022.
- [9] International Energy Agency IEA, Oil Market Report, Analysis and Forecast to 2025, in, 2020.
- [10] United-Nations General Assembly, UN Convention on the Law of the Sea in, 1982.
- [11] IMO - Marine Safety Committee MSC, Code of the International Standards and Recommended Practices for a Safety Investigation into a Marine Casualty or Marine Incident in, 2008.
- [12] European Maritime Security Agency EMSA, Annual Overview of Marine Casualties and Incidents in, 2021.
- [13] F.L. Cooke, Plant maintenance strategy: evidence from four British manufacturing firms, Journal of Quality in Maintenance Engineering, (2003).
- [14] N. Arunraj, J. Maiti, Risk-based maintenance—Techniques and applications, Journal of hazardous materials, 142 (2007) 653-661.
- [15] L.D. Pop, Digitalization of the system of data analysis and collection in an automotive company, Procedia Manufacturing, 46 (2020) 238-243.
- [16] T.A. Branca, B. Fornai, V. Colla, M.M. Murri, E. Streppa, A.J. Schröder, The challenge of digitalization in the steel sector, Metals, 10 (2020) 288.
- [17] J. Salo, T.M. Tan, H. Makkonen, Digitalization of the buyer–seller relationship in the steel industry, Journal of Business & Industrial Marketing, (2020).
- [18] K. Felser, M.G. Wynn, Digitalization and Evolving IT Sourcing Strategies in the German Automotive Industry, International Journal on Advances in Intelligent Systems, 13 (2020) 212-225.
- [19] J. Wittmann, Electrification and digitalization as disruptive trends: new perspectives for the automotive industry?, in: Phantom Ex Machina, Springer, 2017, pp. 137-159.
- [20] J. Światowiec-Szczepańska, B. Stępień, Drivers of Digitalization in the Energy Sector—The Managerial Perspective from the Catching Up Economy, Energies, 15 (2022) 1437.
- [21] S. Baidya, V. Potdar, P.P. Ray, C. Nandi, Reviewing the opportunities, challenges, and future directions for the digitalization of energy, Energy Research & Social Science, 81 (2021) 102243.
- [22] M. Brown, S. Woodhouse, F. Sioshansi, Digitalization of energy, Consumer, prosumer, prosumer: How service innovations will disrupt the utility business model, (2019) 3-25.
- [23] R. Elbert, H. Pontow, A. Benlian, The role of inter-organizational information systems in maritime transport chains, Electronic Markets, 27 (2017) 157-173.
- [24] Deloitte, EU Shipping Competitiveness Study. International Benchmark Analysis. Study Commissioned by the European Community Shipowners' Associations., in, 2017.
- [25] P.-L. Sanchez-Gonzalez, D. Díaz-Gutiérrez, T.J. Leo, L.R. Núñez-Rivas, Toward digitalization of maritime transport?, Sensors, 19 (2019) 926.

- [26] Marine Instruments, AZTI, Newcastle University, Zephyr, Maridis, Sintef, EHU, Echebaster,, Sustainable tuna fisheries through advanced earth observation technologies. SUSTUNTECH, in: E.U.H. 2020. (ed.), 2022.
- [27] A. Prajapati, J. Bechtel, S. Ganesan, Condition based maintenance: a survey, *Journal of Quality in Maintenance Engineering*, (2012).
- [28] P. Zhou, P. Yin, An opportunistic condition-based maintenance strategy for offshore wind farm based on predictive analytics, *Renewable and sustainable energy reviews*, 109 (2019) 1-9.
- [29] O. Bondarenko, T. Fukuda, Development of a diesel engine's digital twin for predicting propulsion system dynamics, *Energy*, 196 (2020) 117126.
- [30] D.-J. Cheng, J. Zhang, Z.-T. Hu, S.-H. Xu, X.-F. Fang, A digital twin-driven approach for on-line controlling quality of marine diesel engine critical parts, *International Journal of Precision Engineering and Manufacturing*, 21 (2020) 1821-1841.
- [31] e. Economista, Ranking de Empresas del sector Construcción de barcos y estructuras flotantes, in, 2022.
- [32] Navantia, Hacia la Industria 4.0 - Gemelo Digital, in, 2022.
- [33] G. Gabiña, L. Martin, O.C. Basurko, M. Clemente, S. Aldekoa, Z. Uriondo, Waste oil-based alternative fuels for marine diesel engines, *Fuel Processing Technology*, 153 (2016) 28-36.
- [34] G. Gabiña, L. Martin, O.C. Basurko, M. Clemente, S. Aldekoa, Z. Uriondo, Performance of marine diesel engine in propulsion mode with a waste oil-based alternative fuel, *Fuel*, 235 (2019) 259-268.
- [35] O.C. Basurko, G. Gabiña, Z. Uriondo, Energy performance of fishing vessels and potential savings, *Journal of cleaner production*, 54 (2013) 30-40.
- [36] O.C. Basurko, Z. Uriondo, Condition-Based Maintenance for medium speed diesel engines used in vessels in operation, *Applied Thermal Engineering*, 80 (2015) 404-412.
- [37] Secretaría General de ANÁLISIS COORDINACIÓN Y ESTADÍSTICA, CONTRIBUCIÓN DEL SISTEMA PESQUERO ALIMENTARIO A LA ECONOMÍA ESPAÑOLA. Actualización datos 2018, in, 2020.
- [38] Eurostat, Fishing fleet by age, length and gross tonnage, in, 2022.
- [39] MAN Energy Solutions, Making the benefits of digitization work for you - Optimization by digital twinning, in, 2022.
- [40] David J. Cord - WÄRTSILÄ, It's easy to tell these twins apart, in, 2021.
- [41] Caterpillar, Digital Twin Reveals the Magic of Physics, in, 2021.
- [42] E.E. Streit, G.L. Borman, Mathematical simulation of a large turbocharged two-stroke diesel engine, *SAE Transactions*, (1971) 733-768.
- [43] R.S. Benson, J. Ledger, N.D. Whitehouse, S. Walmsley, Comparison of experimental and simulated transient responses of a turbocharged diesel engine, *SAE Transactions*, (1973) 2424-2447.
- [44] S. Shahed, P. Flynn, W. Lyn, MODEL FOR THE INFORMATION OF EMISSIONS IN A DIRECT-INJECTION DIESEL ENGINE, in: *Combustion Model in Reciprocating Engines*, Symposium, GM Research Laboratory, Warren, Michigan, November 6-7, 1978., 1980.
- [45] M.J. Crocker, J.F. Hamilton, Modeling of diesel engine noise using coherence, *SAE Transactions*, (1979) 1263-1273.
- [46] N. Watson, M. Kamel, Thermodynamic efficiency evaluation of an indirect injection diesel engine, *SAE Transactions*, (1979) 158-171.
- [47] M. Ford, A simplified turbocharged diesel engine model, *Proceedings of the Institution of Mechanical Engineers, Part D: Transport Engineering*, 201 (1987) 229-234.
- [48] J. Smith, A. Stronach, T. Tsao, K. Goodman, Prediction of dynamic response of marine systems incorporating induction-motor propulsion drives, in: *IEE Proceedings B (Electric Power Applications)*, Vol. 127, IET, 1980, pp. 308-316.
- [49] C. Goering, H. Cho, Engine model for mapping BSFC contours, *Mathematical and Computer Modelling*, 11 (1988) 514-518.

- [50] K. Nishida, H. Hiroyasu, Simplified three-dimensional modeling of mixture formation and combustion in a DI diesel engine, *SAE Transactions*, (1989) 276-293.
- [51] P. Pinchon, Three dimensional modelling of combustion in a prechamber Diesel engine, *SAE Transactions*, (1989) 1202-1223.
- [52] M. Kao, J.J. Moskwa, Turbocharged diesel engine modeling for nonlinear engine control and state estimation, (1995).
- [53] J. Benajes, E. Reyes, J. Lujan, Modelling study of the scavenging process in a turbocharged diesel engine with modified valve operation, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 210 (1996) 383-393.
- [54] A. Uludogan, D.E. Foster, R.D. Reitz, Modeling the effect of engine speed on the combustion process and emissions in a DI Diesel engine, in, *SAE Technical Paper*, 1996.
- [55] M. Patterson, S.-C. Kong, G. Hampson, R.D. Reitz, Modeling the effects of fuel injection characteristics on diesel engine soot and NO_x emissions, *SAE Transactions*, (1994) 836-852.
- [56] M.A. Patterson, R.D. Reitz, Modeling the effects of fuel spray characteristics on diesel engine combustion and emission, *SAE Transactions*, (1998) 27-43.
- [57] G. Sujesh, S. Ramesh, Modeling and control of diesel engines: A systematic review, *Alexandria engineering journal*, 57 (2018) 4033-4048.
- [58] H. Abdi, L.J. Williams, Principal component analysis, *Wiley interdisciplinary reviews: computational statistics*, 2 (2010) 433-459.
- [59] X. Wang, U. Kruger, G.W. Irwin, G. McCullough, N. McDowell, Nonlinear PCA with the local approach for diesel engine fault detection and diagnosis, *IEEE Transactions on Control Systems Technology*, 16 (2007) 122-129.
- [60] D. Antory, Application of a data-driven monitoring technique to diagnose air leaks in an automotive diesel engine: A case study, *Mechanical Systems and Signal Processing*, 21 (2007) 795-808.
- [61] K. Zhong, J. Li, J. Wang, M. Han, Fault detection for marine diesel engine using semi-supervised principal component analysis, in: 2019 9th International Conference on Information Science and Technology (ICIST), IEEE, 2019, pp. 146-151.
- [62] M. Lim, G.A. Ayoko, L. Morawska, Z. Ristovski, E. Jayaratne, The effects of fuel characteristics and engine operating conditions on the elemental composition of emissions from heavy duty diesel buses, *Fuel*, 86 (2007) 1831-1839.
- [63] S. Suthaharan, Support vector machine, in: *Machine learning models and algorithms for big data classification*, Springer, 2016, pp. 207-235.
- [64] C. Cai, X. Weng, C. Zhang, A novel approach for marine diesel engine fault diagnosis, *Cluster Computing*, 20 (2017) 1691-1702.
- [65] I. Lazakis, C. Gkerekos, G. Theotokatos, Investigating an SVM-driven, one-class approach to estimating ship systems condition, *Ships and Offshore Structures*, 14 (2019) 432-441.
- [66] B. Liu, J. Hu, F. Yan, R.F. Turkson, F. Lin, A novel optimal support vector machine ensemble model for NO_x emissions prediction of a diesel engine, *Measurement*, 92 (2016) 183-192.
- [67] M. Ghanbari, G. Najafi, B. Ghobadian, R. Mamat, M. Noor, A. Moosavian, Support vector machine to predict diesel engine performance and emission parameters fueled with nano-particles additive to diesel fuel, in: *IOP Conference Series: Materials Science and Engineering*, Vol. 100, IOP Publishing, 2015, pp. 012069.
- [68] L. Hou, J. Zhang, B. Du, A Fault Diagnosis Model of Marine Diesel Engine Fuel Oil Supply System Using PCA and Optimized SVM, in: *Journal of Physics: Conference Series*, Vol. 1576, IOP Publishing, 2020, pp. 012045.
- [69] J. Flett, G.M. Bone, Fault detection and diagnosis of diesel engine valve trains, *Mechanical Systems and Signal Processing*, 72 (2016) 316-327.
- [70] A. Atmanli, E. Ileri, N. Yilmaz, Optimization of diesel–butanol–vegetable oil blend ratios based on engine operating parameters, *Energy*, 96 (2016) 569-580.
- [71] A. Atmanlı, B. Yüksel, E. Ileri, A.D. Karaoglan, Response surface methodology based optimization of diesel–n-butanol–cotton oil ternary blend ratios to improve engine

- performance and exhaust emission characteristics, *Energy conversion and management*, 90 (2015) 383-394.
- [72] A. Moosavian, H. Ahmadi, A. Tabatabaefar, M. Khazaei, Comparison of two classifiers; K-nearest neighbor and artificial neural network, for fault diagnosis on a main engine journal-bearing, *Shock and Vibration*, 20 (2013) 263-272.
- [73] R. Hecht-Nielsen, *Neurocomputing* Addison-Wesley, Reading, MA, (1990).
- [74] X. Yao, Y. Liu, *Machine learning*, in: *Search Methodologies*, Springer, 2014, pp. 477-517.
- [75] F. Payri, P. Olmeda, J. Martín, A. García, A complete OD thermodynamic predictive model for direct injection diesel engines, *Applied Energy*, 88 (2011) 4632-4641.
- [76] J. Benajes, P. Olmeda, J. Martín, R. Carreño, A new methodology for uncertainties characterization in combustion diagnosis and thermodynamic modelling, *Applied Thermal Engineering*, 71 (2014) 389-399.
- [77] G. Gonca, E. Dobrucali, Theoretical and experimental study on the performance of a diesel engine fueled with diesel–biodiesel blends, *Renewable energy*, 93 (2016) 658-666.
- [78] E. Jiaqiang, G. Liu, Z. Zhang, D. Han, J. Chen, K. Wei, J. Gong, Z. Yin, Effect analysis on cold starting performance enhancement of a diesel engine fueled with biodiesel fuel based on an improved thermodynamic model, *Applied Energy*, 243 (2019) 321-335.
- [79] M. Altosole, U. Campora, M. Figari, M. Laviola, M. Martelli, A diesel engine modelling approach for ship propulsion real-time simulators, *Journal of Marine Science and Engineering*, 7 (2019) 138.
- [80] Y. Deng, H. Liu, X. Zhao, E. Jiaqiang, J. Chen, Effects of cold start control strategy on cold start performance of the diesel engine based on a comprehensive preheat diesel engine model, *Applied Energy*, 210 (2018) 279-287.
- [81] D. Khan, M.Z. Gül, Zero-dimensional modelling of a four-cylinder turbocharged diesel engine with variable compression ratio and its effects on emissions, *SN Applied Sciences*, 1 (2019) 1162.
- [82] P. Hield, The effect of back pressure on the operation of a diesel engine, in, *DEFENSE SCIENCE AND TECHNOLOGY ORGANIZATION VICTORIA (AUSTRALIA) MARITIME ...*, 2011.
- [83] L. Mocerino, C.G. Soares, E. Rizzuto, F. Balsamo, F. Quaranta, Validation of an Emission Model for a Marine Diesel Engine with Data from Sea Operations, *Journal of marine science and application*, 20 (2021) 534-545.
- [84] S. Lion, R. Tacani, I. Vlaskos, P. Scrocco, X. Vouvakos, L. Kaiktsis, Thermodynamic analysis of waste heat recovery using Organic Rankine Cycle (ORC) for a two-stroke low speed marine Diesel engine in IMO Tier II and Tier III operation, *Energy*, 183 (2019) 48-60.
- [85] M. Tadros, M. Ventura, C.G. Soares, Surrogate models of the performance and exhaust emissions of marine diesel engines for ship conceptual design, *transport*, 2 (2018) 1.
- [86] A. Alqahtani, F. Shokrollah Hassanbarough, M.L. Wyszynski, Thermodynamic simulation comparison of AVL BOOST and Ricardo WAVE for HCCI and SI engines optimization, *Combustion Engines*, 54 (2015).
- [87] G. Bellér, I. Árpád, J. Kiss, D. Kocsis, AVL Boost: a powerful tool for research and education, in: *Journal of Physics: Conference Series*, Vol. 1935, IOP Publishing, 2021, pp. 012015.
- [88] A.L. GmH, *Boost Theory (v2014. 1)*, AVL List GmbH: Graz, Austria, (2014).
- [89] N.X. Khoa, O. Lim, The effects of combustion duration on residual gas, effective release energy, engine power and engine emissions characteristics of the motorcycle engine, *Applied Energy*, 248 (2019) 54-63.
- [90] D.C. Nguyen, Q.V. Tran, Combustion characteristics of SI engine fueled with 2, 5-dimethylfuran and gasoline blends using AVL-boost simulation, *Journal of Mechanical Engineering Research and Developments*, (2019) 34-37.
- [91] J. Chen, Z. Wang, F. Tian, A new hydraulic variable valve timing and lift system for spark ignition engine, *Chemical Engineering Transactions*, 51 (2016) 1249-1254.
- [92] M. Melaika, A. Rimkus, T. Vipartas, Air restrictor and turbocharger influence for the formula student engine performance, *Procedia engineering*, 187 (2017) 402-407.

- [93] L. Raslavičius, M. Felneris, S. Pukalskas, A. Rimkus, M. Melaika, Evaluation of P. moriformis oil and its blends with diesel fuel as promising contributors to transportation energy, *Energy*, 189 (2019) 116196.
- [94] Z. Petranović, M. Sjerić, I. Taritaš, M. Vujanović, D. Kozarac, Study of advanced engine operating strategies on a turbocharged diesel engine by using coupled numerical approaches, *Energy conversion and management*, 171 (2018) 1-11.
- [95] A. Teo, M. Chiong, M. Yang, A. Romagnoli, R. Martinez-Botas, S. Rajoo, Performance evaluation of low-pressure turbine, turbo-compounding and air-Brayton cycle as engine waste heat recovery method, *Energy*, 166 (2019) 895-907.
- [96] D.D. Ion, N. Anisor, Single cylinder diesel engine performances estimation using AVL boost software, in: *Proceedings of the 12th WSEAS international conference on Neural networks, fuzzy systems, evolutionary computing & automation*, World Scientific and Engineering Academy and Society (WSEAS), 2011, pp. 173-176.
- [97] V.V. Pham, V.V. Le, A modelling technique of the intake and exhaust systems of a medium speed marine diesel engine, in: *AIP Conference Proceedings*, Vol. 2207, AIP Publishing LLC, 2020, pp. 030003.
- [98] J.A.P. Rubio, F. Vera-García, J.H. Grau, J.M. Cámara, D.A. Hernandez, Marine diesel engine failure simulator based on thermodynamic model, *Applied Thermal Engineering*, 144 (2018) 982-995.
- [99] F. Vera-García, J.A. Pagán Rubio, J. Hernández Grau, D. Albaladejo Hernández, Improvements of a failure database for marine diesel engines using the RCM and simulations, *Energies*, 13 (2020) 104.
- [100] L. Lešnik, B. Vajda, Z. Žunič, L. Škerget, B. Kegl, The influence of biodiesel fuel on injection characteristics, diesel engine performance, and emission formation, *Applied Energy*, 111 (2013) 558-570.
- [101] A. Rimkus, J. Žaglinskis, S. Stravinskas, P. Rapalis, J. Matijošius, Á. Bereczky, Research on the combustion, energy and emission parameters of various concentration blends of hydrotreated vegetable oil biofuel and diesel fuel in a compression-ignition engine, *Energies*, 12 (2019) 2978.
- [102] R. Juknelevičius, A. Rimkus, S. Pukalskas, J. Matijošius, Research of performance and emission indicators of the compression-ignition engine powered by hydrogen-Diesel mixtures, *International Journal of Hydrogen Energy*, 44 (2019) 10129-10138.
- [103] Y. Karagöz, Analysis of the impact of gasoline, biogas and biogas+ hydrogen fuels on emissions and vehicle performance in the WLTC and NEDC, *International Journal of Hydrogen Energy*, 44 (2019) 31621-31632.
- [104] A.L. Niculae, L. Miron, R. Chiriac, On the possibility to simulate the operation of a SI engine using alternative gaseous fuels, *Energy Reports*, 6 (2020) 167-176.
- [105] A. Praptijanto, A. Muharam, A. Nur, Y. Putrasari, Effect of ethanol percentage for diesel engine performance using virtual engine simulation tool, *Energy Procedia*, 68 (2015) 345-354.
- [106] C. Bruce, M. Deacon, N. Vaughan, S. Charlton, Prediction of emissions from a turbocharged passenger car diesel engine using a neural network, in: *Institution of Mechanical Engineers Conference Publications*, Vol. 6, MEDICAL ENGINEERING PUBLICATIONS LTD, 1994, pp. 83-83.
- [107] S. Leonhardt, C. Ludwig, R. Schwarz, Real-time supervision for diesel engine injection, *Control engineering practice*, 3 (1995) 1003-1010.
- [108] G. Thompson, C. Atkinson, N. Clark, T. Long, E. Hanzevack, Neural network modelling of the emissions and performance of a heavy-duty diesel engine, *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 214 (2000) 111-126.
- [109] M.L. Traver, R.J. Atkinson, C.M. Atkinson, Neural network-based diesel engine emissions prediction using in-cylinder combustion pressure, *SAE Transactions*, (1999) 1166-1180.
- [110] M. Hafner, M. Schüler, O. Nelles, R. Isermann, Fast neural networks for diesel engine control design, *Control engineering practice*, 8 (2000) 1211-1221.

- [111] C. Atkinson, T. Long, Neural Network-based Intelligent Engine Control for Reducing NO_x and M Emissions from CIDI Engines, in: Proceedings of the US DOE Diesel Engine Emissions Reduction Workshop, San Diego, CA, 1997.
- [112] P. Srihari, K. Govindarajulu, K. Ramachandra, A method to improve reliability of gearbox fault detection with artificial neural networks, *International Journal of Automotive and Mechanical Engineering*, 2 (2010) 221-230.
- [113] A.F. Mofleh, A.N. Shmroukh, N.M. GHAZALY, Fault detection and classification of spark ignition engine based on acoustic signals and artificial neural network, *International Journal of Mechanical and Production Engineering Research and Development*, 10 (2020) 5571-5578.
- [114] B. Liu, C. Zhao, F. Zhang, T. Cui, J. Su, Misfire detection of a turbocharged diesel engine by using artificial neural networks, *Applied Thermal Engineering*, 55 (2013) 26-32.
- [115] J.M. Alonso, F. Alvarruiz, J.M. Desantes, L. Hernández, V. Hernández, G. Molto, Combining neural networks and genetic algorithms to predict and reduce diesel engine emissions, *IEEE transactions on evolutionary computation*, 11 (2007) 46-55.
- [116] A. Parlak, Y. Islamoglu, H. Yasar, A. Egrisogut, Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a diesel engine, *Applied Thermal Engineering*, 26 (2006) 824-828.
- [117] M. Aydın, S. Uslu, M.B. Çelik, Performance and emission prediction of a compression ignition engine fueled with biodiesel-diesel blends: A combined application of ANN and RSM based optimization, *Fuel*, 269 (2020) 117472.
- [118] S.B. Maind, P. Wankar, Research paper on basic of artificial neural network, *International Journal on Recent and Innovation Trends in Computing and Communication*, 2 (2014) 96-100.
- [119] P. Madane, R. Panua, Investigation of Performance of jatropha oil on diesel engine using Artificial Neural Network Model, *International Journal of Computational Intelligence & IoT*, 2 (2019).
- [120] B. Ghobadian, H. Rahimi, A. Nikbakht, G. Najafi, T. Yusaf, Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network, *Renewable energy*, 34 (2009) 976-982.
- [121] B. Işcan, ANN modeling for justification of thermodynamic analysis of experimental applications on combustion parameters of a diesel engine using diesel and safflower biodiesel fuels, *Fuel*, 279 (2020) 118391.
- [122] I. Zeldovich, G.I. Barenblatt, V. Librovich, G. Makhviladze, *Mathematical theory of combustion and explosions*, (1985).
- [123] Ü. Ağbulut, M. Ayyıldız, S. Sarıdemir, Prediction of performance, combustion and emission characteristics for a dual fuel diesel engine at varying injection pressures, *Energy*, (2020) 117257.
- [124] M. Shailaja, A.S.R. Raju, Neural Network—Based Diesel Engine Emissions Prediction for Variable Injection Timing, Injection Pressure, Compression Ratio and Load Conditions, in: *Emerging Trends in Electrical, Communications and Information Technologies*, Springer, 2017, pp. 109-122.
- [125] H. Taghavifar, H. Taghavifar, A. Mardani, A. Mohebbi, S. Khalilarya, S. Jafarmadar, Appraisal of artificial neural networks to the emission analysis and prediction of CO₂, soot, and NO_x of n-heptane fueled engine, *Journal of cleaner production*, 112 (2016) 1729-1739.
- [126] A. Rida, H.M. Nahim, R. Younes, H. Shraim, M. Ouladsine, Modeling and simulation of the thermodynamic cycle of the Diesel Engine using Neural Networks, *IFAC-PapersOnLine*, 49 (2016) 221-226.
- [127] C.V.N. Abbe, R. Nzenzwa, R. Danwe, Z.M. Ayissi, M. Obonou, A study on the OD phenomenological model for diesel engine simulation: Application to combustion of Neem methyl ester biodiesel, *Energy conversion and management*, 89 (2015) 568-576.
- [128] A. Albrecht, O. Grondin, F. Le Berr, G. Le Sollic, Towards a stronger simulation support for engine control design: a methodological point of view, *Oil & Gas Science and Technology- Revue de l'IFP*, 62 (2007) 437-456.

- [129] F. Baldi, G. Theotokatos, K. Andersson, Development of a combined mean value–zero dimensional model and application for a large marine four-stroke Diesel engine simulation, *Applied Energy*, 154 (2015) 402-415.
- [130] I. Lazakis, Y. Raptodimos, T. Varelas, Predicting ship machinery system condition through analytical reliability tools and artificial neural networks, *Ocean Engineering*, 152 (2018) 404-415.
- [131] M.N. CW, M.Y. MH, I. CK, N. MM, Prediction of marine diesel engine performance by using artificial neural network model, (2016).
- [132] S. Roy, R. Banerjee, A.K. Das, P.K. Bose, Development of an ANN based system identification tool to estimate the performance-emission characteristics of a CRDI assisted CNG dual fuel diesel engine, *Journal of Natural Gas Science and Engineering*, 21 (2014) 147-158.
- [133] C.W.M. Noor, R. Mamat, A.N. Ahmed, Comparative study of artificial neural network and mathematical model on marine diesel engine performance prediction, *International Journal of Innovative Computing, Information and Control* Volume 14, Issue 3, June 2018, Pages 959-969, (2018).
- [134] S. Javed, Y.S. Murthy, R.U. Baig, D.P. Rao, Development of ANN model for prediction of performance and emission characteristics of hydrogen dual fueled diesel engine with Jatropa Methyl Ester biodiesel blends, *Journal of Natural Gas Science and Engineering*, 26 (2015) 549-557.
- [135] Y. Cay, A. Çiçek, F. Kara, S. Sağıroğlu, Prediction of engine performance for an alternative fuel using artificial neural network, *Applied Thermal Engineering*, 37 (2012) 217-225.
- [136] S. Roy, R. Banerjee, P.K. Bose, Performance and exhaust emissions prediction of a CRDI assisted single cylinder diesel engine coupled with EGR using artificial neural network, *Applied Energy*, 119 (2014) 330-340.
- [137] L.P. Perera, B. Mo, Data analysis on marine engine operating regions in relation to ship navigation, *Ocean Engineering*, 128 (2016) 163-172.
- [138] C.-y. Guo, X.-h. Zhong, D.-g. Zhao, C. Wang, J.-f. Lin, K.-w. Song, Propulsion performance of large-scale ship model in real sea environment, *Ocean Engineering*, 210 (2020) 107440.
- [139] J. Porteiro, J. Collazo, D. Patiño, J.L. Míguez, Diesel engine condition monitoring using a multi-net neural network system with nonintrusive sensors, *Applied Thermal Engineering*, 31 (2011) 4097-4105.
- [140] M. Jafari, P. Verma, T.A. Bodisco, A. Zare, N.C. Surawski, P. Borghesani, S. Stevanovic, Y. Guo, J. Alroe, C. Osuagwu, Multivariate analysis of performance and emission parameters in a diesel engine using biodiesel and oxygenated additive, *Energy conversion and management*, 201 (2019) 112183.
- [141] Y. Khelil, G. Graton, M. Djeziri, M. Ouladsine, R. Outbib, Fault detection and isolation in marine diesel engines: A generic methodology, *IFAC Proceedings Volumes*, 45 (2012) 964-969.
- [142] R. Wang, H. Chen, C. Guan, W. Gong, Z. Zhang, Research on the fault monitoring method of marine diesel engines based on the manifold learning and isolation forest, *Applied Ocean Research*, 112 (2021) 102681.
- [143] G. Tsaganos, N. Nikitakos, D. Dalaklis, A. Ölcer, D. Papachristos, Machine learning algorithms in shipping: improving engine fault detection and diagnosis via ensemble methods, *WMU Journal of Maritime Affairs*, 19 (2020) 51-72.
- [144] A. BOOST, Users guide, AVL List GmbH, Austria, (2010).
- [145] AVL, 1 Cylinder Gasoline Engine Example, v2014.1 (2015).
- [146] AVL, 6 cylinder Diesel Engine, v2014.1 (2015).
- [147] AVL, 4 Cylinder TCI DI Diesel Engine IRA, v2014.1 (2015).
- [148] K. Pattas, G. Häfner, Stickoxidbildung bei der ottomotorischen Verbrennung, *MOTORTECHN. Z.*, 34 (1973).
- [149] Y.B. Zeldvich, The oxidation of nitrogen in combustion and explosions, *J. Acta Physicochimica*, 21 (1946) 577.

- [150] A. Onorati, G. Ferrari, G. D'Errico, 1D unsteady flows with chemical reactions in the exhaust duct-system of SI engines: predictions and experiments, *SAE Transactions*, (2001) 738-752.
- [151] J.B. Heywood, *Combustion engine fundamentals*, 1ª Edição. Estados Unidos, (1988).
- [152] K.J. Patton, R.G. Nitschke, J.B. Heywood, Development and evaluation of a friction model for spark-ignition engines, *SAE Transactions*, (1989) 1441-1461.
- [153] D. Hountalas, G. Mavropoulos, G. Kourbetis, Experimental investigation to develop a methodology for estimating the compression condition of DI Diesel engines, *Energy conversion and management*, 47 (2006) 1-18.
- [154] I.I. Vibe, F. Meißner, *Brennverlauf und kreisprozess von verbrennungsmotoren*, Verlag Technik, 1970.
- [155] Y. Ding, *Characterising combustion in diesel engines*, TU Delft, 668 (2011).
- [156] Y. Wang, A novel two-zone thermodynamic model for spark-ignition engines based on an idealized thermodynamic process, *Energies*, 13 (2020) 3801.
- [157] S. Kumar, M.K. Chauhan, Numerical modeling of compression ignition engine: a review, *Renewable and sustainable energy reviews*, 19 (2013) 517-530.
- [158] I. Khan, G. Greeves, D. Probert, Prediction of soot and nitric oxide concentrations in diesel engine exhaust, *Air Pollution Control in Transport Engines C*, 142 (1971) 205-217.
- [159] D. Kouremenos, C. Rakopoulos, D. Hountalas, Computer simulation with experimental validation of the exhaust nitric oxide and soot emissions in divided chamber diesel engines, in: *Proceedings of the ASMEWA meeting*, Vol. 10, 1989, pp. 15-28.
- [160] C. Rakopoulos, Influence of ambient temperature and humidity on the performance and emissions of nitric oxide and smoke of high speed diesel engines in the Athens/Greece region, *Energy conversion and management*, 31 (1991) 447-458.
- [161] N.D. Whitehouse, B.K. Sareen, Prediction of heat release in a quiescent chamber diesel engine allowing for fuel/air mixing, in, *SAE Technical Paper*, 1974.
- [162] G. Woschni, A universally applicable equation for the instantaneous heat transfer coefficient in the internal combustion engine, in, *SAE Technical paper*, 1967.
- [163] S. Butterworth, On the theory of filter amplifiers, *Wireless Engineer*, 7 (1930) 536-541.
- [164] P. Benardos, G.-C. Vosniakos, Optimizing feedforward artificial neural network architecture, *Engineering Applications of Artificial Intelligence*, 20 (2007) 365-382.
- [165] D. Svozil, V. Kvasnicka, J. Pospichal, Introduction to multi-layer feed-forward neural networks, *Chemometrics and intelligent laboratory systems*, 39 (1997) 43-62.
- [166] G. Bebis, M. Georgiopoulos, Feed-forward neural networks, *IEEE Potentials*, 13 (1994) 27-31.
- [167] N. Qian, On the momentum term in gradient descent learning algorithms, *Neural networks*, 12 (1999) 145-151.
- [168] J. Duchi, E. Hazan, Y. Singer, Adaptive subgradient methods for online learning and stochastic optimization, *Journal of machine learning research*, 12 (2011).
- [169] G. Hinton, N. Srivastava, K. Swersky, *Neural networks for machine learning*, Coursera, video lectures, 264 (2012) 1.
- [170] D.P. Kingma, J. Ba, Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, (2014).
- [171] S. Ruder, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747*, (2016).
- [172] H. Yu, B.M. Wilamowski, Levenberg–marquardt training, in: *Intelligent systems*, CRC Press, 2018, pp. 12-11-12-16.
- [173] K. Levenberg, A method for the solution of certain non-linear problems in least squares, *Quarterly of applied mathematics*, 2 (1944) 164-168.
- [174] D.W. Marquardt, An algorithm for least-squares estimation of nonlinear parameters, *Journal of the society for Industrial and Applied Mathematics*, 11 (1963) 431-441.

- [175] J. Rezaei, M. Shahbakhti, B. Bahri, A.A. Aziz, Performance prediction of HCCI engines with oxygenated fuels using artificial neural networks, *Applied Energy*, 138 (2015) 460-473.
- [176] O. Obodeh, C. Ajuwa, Evaluation of artificial neural network performance in predicting diesel engine NOx emissions, *European Journal of Scientific Research*, 33 (2009) 642-653.
- [177] T.F. Yusaf, D. Buttsworth, K.H. Saleh, B. Yousif, CNG-diesel engine performance and exhaust emission analysis with the aid of artificial neural network, *Applied Energy*, 87 (2010) 1661-1669.
- [178] F. Yang, H. Cho, H. Zhang, J. Zhang, Y. Wu, Artificial neural network (ANN) based prediction and optimization of an organic Rankine cycle (ORC) for diesel engine waste heat recovery, *Energy conversion and management*, 164 (2018) 15-26.
- [179] P. Tunestål, TDC offset estimation from motored cylinder pressure data based on heat release shaping, *Oil & Gas Science and Technology—Revue d'IFP Energies nouvelles*, 66 (2011) 705-716.
- [180] P. Tunestål, Model based TDC offset estimation from motored cylinder pressure data, *IFAC Proceedings Volumes*, 42 (2009) 241-247.
- [181] U. Žvar Baškovič, R. Vihar, I. Mele, T. Katrašnik, A new method for simultaneous determination of the TDC offset and the pressure offset in fired cylinders of an internal combustion engine, *Energies*, 10 (2017) 143.
- [182] K. Ramalingam, A. Kandasamy, D. Balasubramanian, M. Palani, T. Subramanian, E.G. Varuvel, K. Viswanathan, Forecasting of an ANN model for predicting behaviour of diesel engine energised by a combination of two low viscous biofuels, *Environmental Science and Pollution Research*, (2019) 1-21.
- [183] M. Canakci, A.N. Ozsezen, E. Arcaklioglu, A. Erdil, Prediction of performance and exhaust emissions of a diesel engine fueled with biodiesel produced from waste frying palm oil, *Expert systems with Applications*, 36 (2009) 9268-9280.
- [184] S. Uslu, Optimization of diesel engine operating parameters fueled with palm oil-diesel blend: Comparative evaluation between response surface methodology (RSM) and artificial neural network (ANN), *Fuel*, 276 (2020) 117990.
- [185] P.J. Shayler, D.K. Leong, M. Murphy, Friction teardown data from motored engine tests on light duty automotive diesel engines at low temperatures and speeds, in: *ASME 2003 Internal Combustion Engine and Rail Transportation Divisions Fall Technical Conference, American Society of Mechanical Engineers Digital Collection*, 2003, pp. 363-380.
- [186] S.K. Chen, P.F. Flynn, Development of a single cylinder compression ignition research engine, in, *SAE Technical Paper*, 1965.
- [187] H. Oğuz, I. Saritas, H.E. Baydan, Prediction of diesel engine performance using biofuels with artificial neural network, *Expert systems with Applications*, 37 (2010) 6579-6586.
- [188] International Organization for Standardization ISO, ISO 14726:2008 Ships and marine technology — Identification colours for the content of piping systems, in, 2008.
- [189] G. Theotokatos, V. Tzelepis, A computational study on the performance and emission parameters mapping of a ship propulsion system, *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, 229 (2015) 58-76.
- [190] MAN Energy solutions, Basic principles of ship propulsion, *MAN Energy Solutions: Copenhagen, Denmark*, (2018).
- [191] MARPOL, Annex VI- Regulations for the Prevention of Air Pollution from Ships, in: *Appendix II - Test cycles and weighting factors (Regulation 13)*, 2005.
- [192] International Organization for Standardization ISO, ISO 8178-1:2020 - Reciprocating internal combustion engines - Exhaust emission measurement in: Part 1: Test-bed measurement systems of gaseous and particulate emissions, 2020.
- [193] B. Mahesh, Machine Learning Algorithms-A Review, *International Journal of Science and Research (IJSR)*. [Internet], 9 (2020) 381-386.

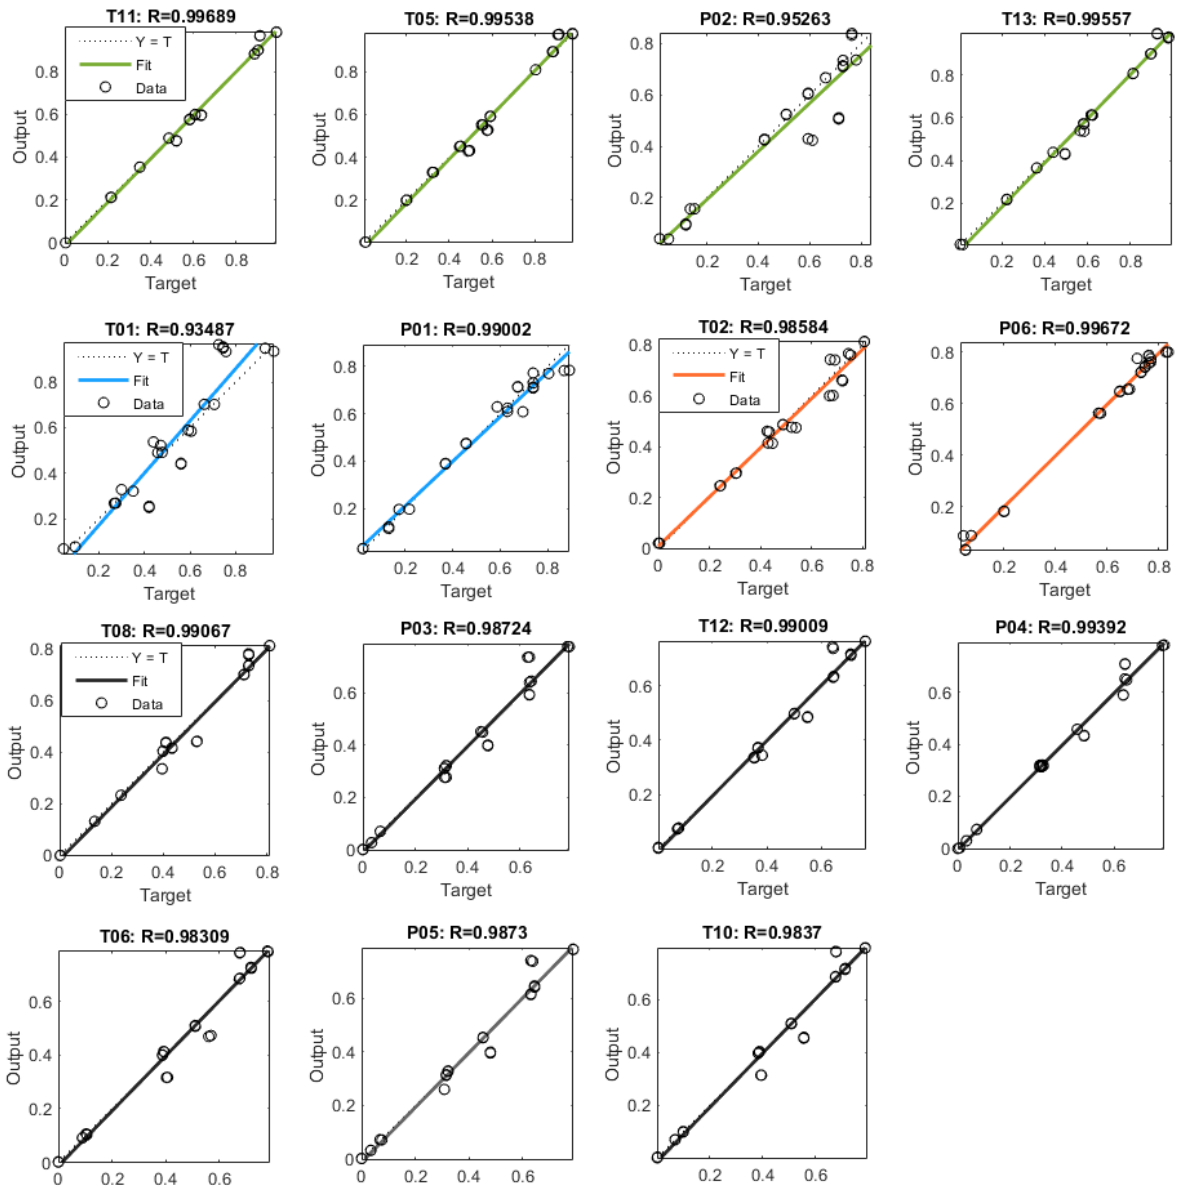
- [194] X. Niu, C. Yang, H. Wang, Y. Wang, Investigation of ANN and SVM based on limited samples for performance and emissions prediction of a CRDI-assisted marine diesel engine, *Applied Thermal Engineering*, 111 (2017) 1353-1364.
- [195] Matlab, Divide Data for Optimal Neural Network Training, in: Mathworks (ed.), 2022.
- [196] J. Liu, Q. Huang, C. Ulishney, C.E. Dumitrescu, Machine learning assisted prediction of exhaust gas temperature of a heavy-duty natural gas spark ignition engine, *Applied Energy*, 300 (2021) 117413.
- [197] K.I. Wong, P.K. Wong, C.S. Cheung, C.M. Vong, Modelling of diesel engine performance using advanced machine learning methods under scarce and exponential data set, *Applied Soft Computing*, 13 (2013) 4428-4441.
- [198] Y. Cay, Prediction of a gasoline engine performance with artificial neural network, *Fuel*, 111 (2013) 324-331.
- [199] V. Çelik, E. Arcaklioğlu, Performance maps of a diesel engine, *Applied Energy*, 81 (2005) 247-259.
- [200] Q. Yao, Y. Liu, C. Guo, C. Ao, T. Guan, Z. Xu, Research on fault warning of marine diesel engine cooling system based on Deep Belief Network, in: *Journal of Physics: Conference Series*, Vol. 1750, IOP Publishing, 2021, pp. 012066.
- [201] E. Tosun, K. Aydin, M. Bilgili, Comparison of linear regression and artificial neural network model of a diesel engine fueled with biodiesel-alcohol mixtures, *Alexandria engineering journal*, 55 (2016) 3081-3089.
- [202] E. Arcaklioğlu, İ. Çelikten, A diesel engine's performance and exhaust emissions, *Applied Energy*, 80 (2005) 11-22.
- [203] A.K. Agarwal, D.K. Srivastava, A. Dhar, R.K. Maurya, P.C. Shukla, A.P. Singh, Effect of fuel injection timing and pressure on combustion, emissions and performance characteristics of a single cylinder diesel engine, *Fuel*, 111 (2013) 374-383.
- [204] H.G. How, H.H. Masjuki, M. Kalam, Y.H. Teoh, Influence of injection timing and split injection strategies on performance, emissions, and combustion characteristics of diesel engine fueled with biodiesel blended fuels, *Fuel*, 213 (2018) 106-114.
- [205] M. K.Kahir, Pump-Line-Nozzle Injection System, *Diesel Technology Guide, Diesel Fuel Injection* (2020).
- [206] J. Castresana, G. Gabiña, L. Martin, Z. Uriondo, Diesel engine performance prediction using Artificial Neural Networks with low correlation inputs, in: *15th International Conference on Heat Transfer, Fluid Mechanics and Thermodynamics*, 2021.
- [207] F.A. Ruiz, C.V. Isaza, A.F. Agudelo, J.R. Agudelo, A new criterion to validate and improve the classification process of LAMDA algorithm applied to diesel engines, *Engineering Applications of Artificial Intelligence*, 60 (2017) 117-127.
- [208] A. Jamrozik, W. Tutak, R. Gnatowska, Ł. Nowak, Comparative analysis of the combustion stability of diesel-methanol and diesel-ethanol in a dual fuel engine, *Energies*, 12 (2019) 971.
- [209] I.W. Burr, Cumulative frequency functions, *The Annals of mathematical statistics*, 13 (1942) 215-232.
- [210] J. Castresana, G. Gabiña, L. Martin, A. Basterretxea, Z. Uriondo, Marine diesel engine ANN modelling with multiple output for complete engine performance map, *Fuel*, 319 (2022) 123873.
- [211] D. Hunter, H. Yu, M.S. Pukish III, J. Kolbusz, B.M. Wilamowski, Selection of proper neural network sizes and architectures—A comparative study, *IEEE Transactions on Industrial Informatics*, 8 (2012) 228-240.
- [212] K.G. Sheela, S.N. Deepa, Review on methods to fix number of hidden neurons in neural networks, *Mathematical problems in engineering*, 2013 (2013).
- [213] T. O'Malley, E. Bursztein, J. Long, F. Chollet, H. Jin, L. Invernizzi, Others, *KerasTuner*, in, 2019.

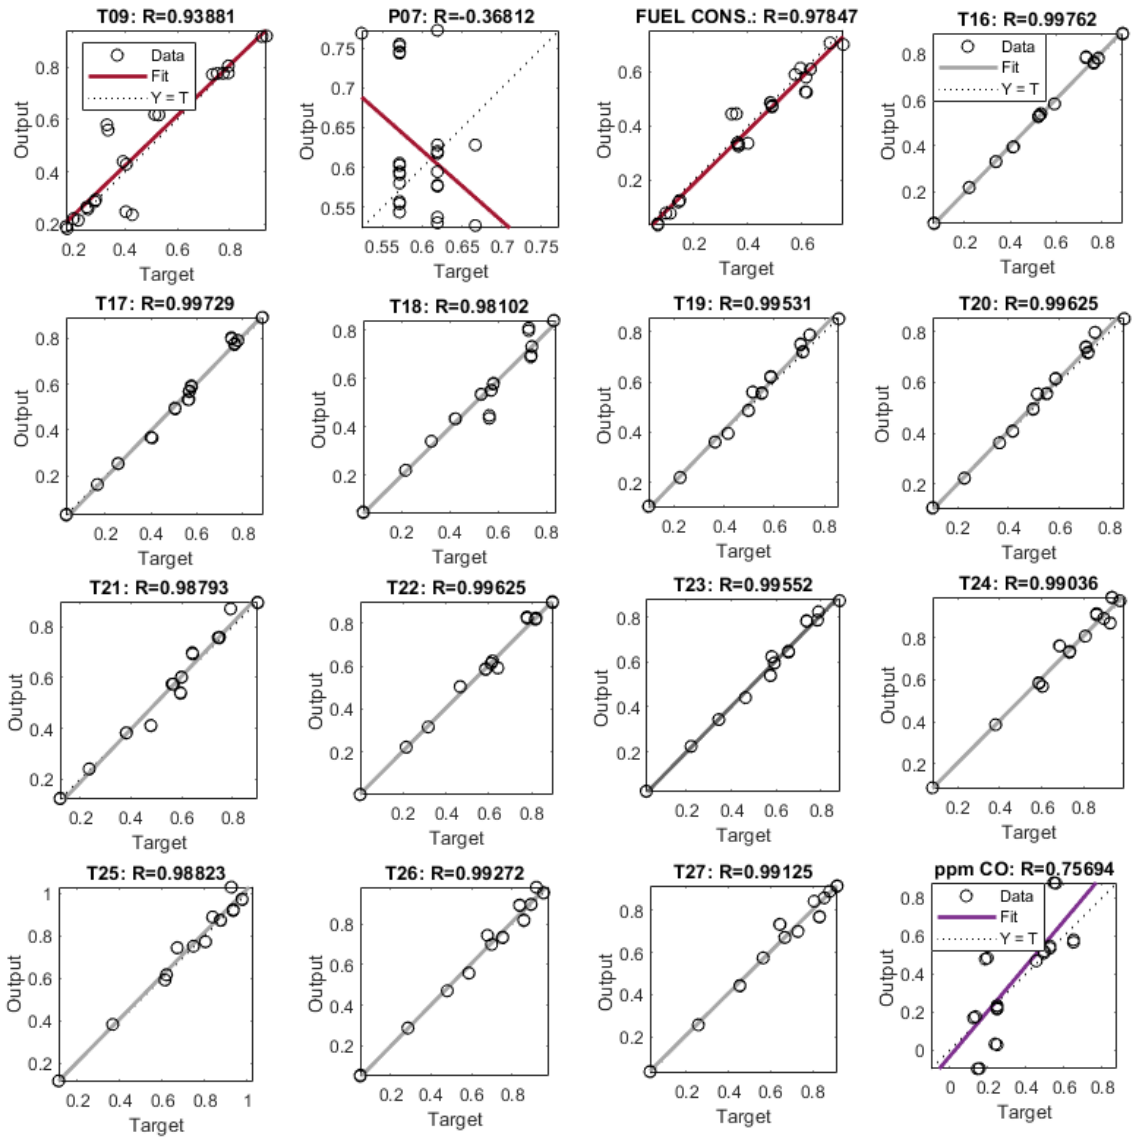
- [214] M. Erauskin-Extramiana, H. Arrizabalaga, A.J. Hobday, A. Cabré, L. Ibaibarriaga, I. Arregui, H. Murua, G. Chust, Large-scale distribution of tuna species in a warming ocean, *Global change biology*, 25 (2019) 2043-2060.
- [215] M. Issa, H. Ibrahim, H. Hosni, A. Ilinca, M. Rezkallah, Effects of low charge and environmental conditions on diesel generators operation, *Eng*, 1 (2020) 137-152.
- [216] D. Boullosa-Falces, J.L.L. Barrena, A. Lopez-Arraiza, J. Menendez, M.A.G. Solaetxe, Monitoring of fuel oil process of marine diesel engine, *Applied Thermal Engineering*, 127 (2017) 517-526.
- [217] S. Stoumpos, G. Theotokatos, A novel methodology for marine dual fuel engines sensors diagnostics and health management, *International Journal of Engine Research*, (2021) 1468087421998635.
- [218] H.M. Nahim, R. Younes, H. Shraim, M. Ouladsine, Modeling with fault integration of the cooling and the lubricating systems in marine diesel engine: Experimental validation, *IFAC-PapersOnLine*, 49 (2016) 570-575.
- [219] M. Gholinia, M. Pourfallah, H. Chamani, Numerical investigation of heat transfers in the water jacket of heavy duty diesel engine by considering boiling phenomenon, *Case studies in thermal engineering*, 12 (2018) 497-509.
- [220] J. Zhou, L. Xu, The fault diagnosis of marine engine cooling system based on artificial neural network (ANN), in: 2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE), Vol. 2, IEEE, 2010, pp. 186-189.
- [221] Eurostat, International trade in goods by mode of transport, in, 2020.
- [222] A. Guterres, El mundo se quema. Necesitamos una revolución de renovables. , United Nations Publications, (2022).
- [223] D. Lowell, H. Wang, N. Lutsey, Assessment of the fuel cycle impact of liquefied natural gas as used in international shipping, *The International Council on Clean Transportation*, (2013).
- [224] Make room for LPG as a marine fuel, in: *Emission Possible*, International Shipping News, 2020.
- [225] B. Zincir, C. Deniz, Methanol as a fuel for marine diesel engines, in: *Alcohol as an Alternative Fuel for Internal Combustion Engines*, Springer, 2021, pp. 45-85.
- [226] C.D. Rakopoulos, D.C. Rakopoulos, G.M. Kosmadakis, R.G. Papagiannakis, Experimental comparative assessment of butanol or ethanol diesel-fuel extenders impact on combustion features, cyclic irregularity, and regulated emissions balance in heavy-duty diesel engine, *Energy*, 174 (2019) 1145-1157.
- [227] D. Rakopoulos, C. Rakopoulos, E. Kakaras, E. Giakoumis, Effects of ethanol–diesel fuel blends on the performance and exhaust emissions of heavy duty DI diesel engine, *Energy conversion and management*, 49 (2008) 3155-3162.
- [228] J. Huang, Y. Wang, S. Li, A.P. Roskilly, H. Yu, H. Li, Experimental investigation on the performance and emissions of a diesel engine fuelled with ethanol–diesel blends, *Applied Thermal Engineering*, 29 (2009) 2484-2490.
- [229] AZTI-BRTA, ORTZE-CV. (On the Research of Technologies towards Zero-Emission Coastal Vessels, in, Ingeteam. Lasa Naval. Indar. SKV. Ormazabal. Foro marítimo vasco. AZTI BRTA. UPV/EHU. Mondragón Unibertsitatea. Blas de Lezo. Tknika. Grupo Spri. Departamento de Desarrollo Económico e Infraestructuras del Gobierno Vasco., 2017.
- [230] Statista, Annual fuel consumption by ships worldwide from 2019 to 2020, by fuel type, in: *Transportation & Logistics. Water Transport*, 2022.
- [231] YANMAR, Marine operations division. YANMAR 6HYM-WET. Engine specifications, dimensions and performance curves, in, 2022.
- [232] M.N. Nabi, M. Rasul, One-dimensional thermodynamic model development for engine performance, combustion and emissions analysis using diesel and two paraffin fuels, *Energy Procedia*, 156 (2019) 259-265.


- [233] F. Selmane, M. Djermouni, A. Ouadha, Thermodynamic modeling of a turbocharged diesel–hydrogen dual-fuel marine engine, *Journal of The Institution of Engineers (India): Series C*, 102 (2021) 221-234.
- [234] J. Castresana, G. Gabiña, A. Basterretxea, Z. Uriondo, Marine diesel engine multiple performance parameter characterization in variable conditions with thermodynamic modelling, in: 16th International Conference on Heat Transfer, Fluid Mechanics and Thermodynamics, 2022.
- [235] Keras, Keras API Reference: Optimizers, in: Available Optimizers, 2022.
- [236] Mathworks, Multilayer Neural Network Training Function, in: Matlab, 2022.
- [237] Ö. Can, T. Baklacioglu, E. Öztürk, O. Turan, Artificial neural networks modeling of combustion parameters for a diesel engine fueled with biodiesel fuel, *Energy*, 247 (2022) 123473.
- [238] F. Maroteaux, C. Saad, Combined mean value engine model and crank angle resolved in-cylinder modeling with NOx emissions model for real-time Diesel engine simulations at high engine speed, *Energy*, 88 (2015) 515-527.
- [239] A. Malozemov, V. Bondar, V. Egorov, G. Malozemov, Digital twins technology for internal combustion engines development, in: 2018 Global Smart Industry Conference (GloSIC), IEEE, 2018, pp. 1-6.
- [240] Y. Tang, J. Zhang, H. Gan, B. Jia, Y. Xia, Development of a real-time two-stroke marine diesel engine model with in-cylinder pressure prediction capability, *Applied Energy*, 194 (2017) 55-70.
- [241] D. Watzenig, G. Steiner, M. Sommer, Robust estimation of blow-by and compression ratio for large diesel engines based on cylinder pressure traces, in: 2008 IEEE Instrumentation and Measurement Technology Conference, IEEE, 2008, pp. 974-978.
- [242] U. Qadiri, M.M. Wani, Computational Investigation on Single Cylinder Spark Ignition Engine Using Gasoline-propane in Dual Fuel Mode, *Journal homepage: <http://iieta.org/journals/ijht>*, 37 (2019) 457-465.
- [243] A.K. Jain, J. Mao, K.M. Mohiuddin, Artificial neural networks: A tutorial, *Computer*, 29 (1996) 31-44.
- [244] S. Xie, X. Hu, S. Qi, K. Lang, An artificial neural network-enhanced energy management strategy for plug-in hybrid electric vehicles, *Energy*, 163 (2018) 837-848.
- [245] Z.D. Asher, A.A. Galang, W. Briggs, B. Johnston, T.H. Bradley, S. Jathar, Economic and efficient hybrid vehicle fuel economy and emissions modeling using an artificial neural network, in, SAE Technical Paper, 2018.
- [246] T. Bazhynova, O. Kravchenko, D. Barta, O. Haievyyi, V. Pavelcik, Neural Network Model of Assessing the Technical Condition of the Power Unit of a Hybrid Vehicle, in: 2020 XII International Science-Technical Conference AUTOMOTIVE SAFETY, IEEE, 2020, pp. 1-7.
- [247] S. Kim, J. Kim, Optimal Energy Control of Battery Hybrid System for Marine Vessels by Applying Neural Network Based on Equivalent Consumption Minimization Strategy, *Journal of Marine Science and Engineering*, 9 (2021) 1228.
- [248] M. Wei, B. Qiu, Y. Jiang, X. He, Multi-sensor monitoring based on-line diesel engine anomaly detection with baseline deviation, in: 2016 Prognostics and System Health Management Conference (PHM-Chengdu), IEEE, 2016, pp. 1-5.
- [249] E.G. Giakoumis, Lubricating oil effects on the transient performance of a turbocharged diesel engine, *Energy*, 35 (2010) 864-873.
- [250] C.I. Ospina Tarazona, Sistema electrónico para el diagnóstico de filtros de aceite en vehículos pesados, (2004).
- [251] X. Tauzia, A. Maiboom, H. Karaky, P. Chesse, Experimental analysis of the influence of coolant and oil temperature on combustion and emissions in an automotive diesel engine, *International Journal of Engine Research*, 20 (2019) 247-260.

- [252] Y. Hu, B. Gangadhara Prusty, Y. Liu, Deviation Analysis and Failure Diagnosis of Diesel Engine, in: International Conference on Intelligent Information Processing, Springer, 2006, pp. 347-356.
- [253] Y.Q. Wang, G. Ren, Z.Q. Zhou, Research for fuel common rail system about Marine Diesel Engine, in: Advanced Materials Research, Vol. 960, Trans Tech Publ, 2014, pp. 1455-1459.
- [254] G. Aiello, A. Giallanza, S. Vacante, S. Fasoli, G. Mascarella, Propulsion monitoring system for digitized ship management: Preliminary results from a case study, *Procedia Manufacturing*, 42 (2020) 16-23.


ANEXOS I: Regresiones para parámetros del motor YANMAR 6HYM-WET (Capítulo 2)







ANEXOS II: Contribuciones científicas



Comparative performance and emissions assessments of a single-cylinder diesel engine using artificial neural network and thermodynamic simulation

Joseba Castresana^{a,*}, Gorka Gabiña^a, Leopoldo Martin^b, Zigor Uriondo^b

^a AZTI, Marine Research, Basque Research and Technology Alliance (BRTA), Txatxarramendi Ugartea 0-48395, Sukarrieta, Spain

^b Department of Thermal Engineering, University of the Basque Country UPV/EHU, Alameda Urquijo s/n, 48013 Bilbao, Spain

ARTICLE INFO

Keywords:

Thermodynamic modelling
ANN
Diesel engine modelling
Performance prediction
Emission prediction
Variable condition modelling

ABSTRACT

Diesel engine parameter prediction became a topic of interest in recent years, along with the development of condition-based maintenance, and is now considered a key instrument for engine diagnosis research. This contribution compares two different approaches for diesel engine performance prediction: thermodynamic modelling and artificial neural networks (ANNs). The thermodynamic modelling was developed using AVL Boost™ software simulating a single-cylinder diesel engine with different engine loads and operating conditions. The ANN modelling was conducted by comparing two efficient training algorithms to achieve the best prediction performance, with the ANN structure parameters determined by network error analysis. Both models' prediction accuracy was verified by a single-cylinder engine test bench operating under real conditions. The adaptability and robustness of the two approaches was studied for the whole engine load spectrum, comparing predicted values to experimental measurements. Both prediction tools, ANN and thermodynamic modelling, proved to be reliable for engine performance and emissions prediction. In both models brake-specific fuel consumption (BSFC), exhaust gas temperature (T_{exh}), carbon monoxide (CO) and nitrogen oxides (NO_x) were predicted using brake mean effective pressure (BMEP) and engine speed as inputs. ANN show higher accuracy for BSFC prediction in all engine loads, and T_{exh} prediction accuracy is better for ANN when dealing with medium to high loads, while the thermodynamic model shows better results when dealing with medium to low loads. CO is better predicted by the thermodynamic model except for the highest engine loads, and NO_x predictions present high accuracy in both models, except for the lowest loads. Calculation time is lower for ANN, but the thermodynamic model provides additional performance results (i.e. combustion pressure tracing and associated values).

1. Introduction

Condition-based maintenance (CBM) has become very popular in recent decades along with the introduction of machine learning (ML) in different research fields. Maintenance operations have changed over the years from the corrective and planned maintenance used in the past to the current condition and risk-based maintenance [1]. Wang et al. assume that the mean cost of a failure replacement is 10 times higher than for a preventive replacement [2], whereby preventive maintenance is interesting from a safety and economic standpoint. According to Antonic et al. [3], measurement of a large number of engine operation parameters makes it possible to detect an incipient fault before severe consequences arise, such as engine component failures or shut-down safety

action. In this regard, engine performance prediction is essential to identify early failures before they happen; two different approaches used for performance prediction were accordingly analysed and compared in this contribution: (1) thermodynamic modelling and (2) artificial neural networks.

Various studies on thermodynamic modelling have focused on theoretical approaches, in some cases accompanied by sub-models to enhance prediction capability. Payri et al. [4] developed a 0-dimensional thermodynamic model to predict performance parameters (i.e. IMEP, P_{max}), including sub-models to reproduce blow-by leakage, chamber deformation, heat transfer and fuel injection. This study was later used by Benajes et al. [5], who conducted a sensitivity study to ascertain the effect of different uncertainties (i.e. compression ratio, TDC position) on in-cylinder pressure and ROHR error. Gonca and

* Corresponding author.

E-mail addresses: jcastresana@azti.es (J. Castresana), ggabina@azti.es (G. Gabiña), leopoldo.martin@ehu.eus (L. Martin), zigor.uriondo@ehu.eus (Z. Uriondo).

Nomenclature

ANN	Artificial neural network	LPG	liquefied petroleum gas
BSFC	brake specific fuel consumption	HC	hydrocarbons
T_{exh}	exhaust gas temperature	O₂	oxygen
CO	carbon monoxide	CO₂	carbon dioxide
NO_x	nitrogen oxides	CNG	compressed natural gas
BMEP	brake mean effective pressure	BTE	brake thermal efficiency
CBM	condition based maintenance	VE	volumetric efficiency
IMEP	indicated mean effective pressure	EGT	exhaust gas temperature
P_{max}	maximum pressure value	FMEP	friction mean effective pressure
ROHR	rate of heat release	LM	Levenberg – Marquardt
TDC	top dead centre	MSE	mean squared error
		MAPE	mean absolute percentage error

Dobrucali [6] analysed the effects of engine load and biodiesel percentage both theoretically and experimentally, validating theoretical results with experimental measurements. A recent study by Jiaqiang et al. [7] involved entropy and exergy analysis along with thermodynamic modelling to investigate diesel engine performance during cold start, comparing simulated results to real experimental values.

These models can also be developed using different software for thermodynamic calculations [8–10]. Computation time varies according to each model's specifications. As described by Albrecht et al. [11], a major advantage of 0D and 1D models is that they require less calculation time than higher dimension approaches. Alqahtani et al. [12] simulated a spark ignition and homogeneous compression ignition charge single-cylinder engine using two kinds of thermodynamic modelling software: AVL Boost™ and Ricardo WAVE™. They concluded that AVL Boost™ provided more complex simulation resources in terms of engine design and cycle simulations. Ion and Anisor [13] also used AVL Boost™ to estimate performance parameters in a single-cylinder diesel engine. In the field of condition-based monitoring and fault detection, some authors have studied the effects of different faults on engine parameters using this software. Rubio et al. [14] developed a diesel engine failure simulator based on AVL Boost™. They studied the effects of different faults (i.e. excessive pressure drop in air filter, valve clearance, intake/exhaust manifold leakage) on operating parameters (i.e. boost pressure, cylinder outlet gas temperature, air mass flow). Yang et al. [15] simulated some engine faults using AVL Boost™ using 15 different thermal parameters to conduct fault diagnosis in a 6-cylinder diesel engine. More recently, Pham et al. [16] used this software for marine medium-speed intake and exhaust system modelling.

Many research efforts have employed AVL Boost™ for performance and emission prediction while alternative fuels are used, as this software allows users to determine the fuel used in the engine. Aldhaidhawi et al. [17] proposed adding ethanol to diesel fuel to reduce greenhouse gas emissions. Engine performance was analysed for different ethanol blends, studying gas emissions and power for different engine speeds. Rimkus et al. [18] studied the effect of additional supplies of liquefied petroleum gas (LPG) blends on diesel engines' energetic and environmental indicators. It was seen that LPG addition reduced engines' thermal efficiency and augmented incomplete combustion products (i.e. CO, HC and smoke) while decreasing NO_x and CO₂ emissions. Nguyen [19] studied the effects of adding 2,5-dimethylfuran to gasoline on spark ignition engine performance, concluding that it was possible to reach the same power and torque as with pure gasoline if the amount of fuel per cycle was adjusted. A review of the literature indicates that AVL Boost™ has proved to be an effective tool used for thermodynamic modelling. It was thus selected for the single-cylinder diesel engine modelling carried out in this study.

Machine learning is also becoming a popular tool for operation prediction and diesel engine diagnosis. The term 'machine learning' encompasses a wide range of statistical tools that can be used for

condition-based diesel engine maintenance. Cai et al. [20] developed an approach for diesel engine diagnosis based on support vector machine (SVM) classification for the operative state of engine subsystems. Flett and Bone [21] compared five different classification techniques for fault detection in diesel engine valve trains, concluding that Naïve Bayes gave the best overall performance in terms of detection and classification accuracies. Moosavian et al. [22] compared K-nearest neighbour and artificial neural networks (ANNs) for fault detection on a main engine journal bearing, concluding that ANNs with 5 neurons in hidden layer gave the best results. Alternative statistical methods such as response surface methodology have also been included recently in different studies to reach optimum alternative fuel blends [23,24].

In this study, ANN was selected for diesel engine performance and emissions prediction. The robustness and flexibility offered by ANNs have made this tool very useful in performance prediction; many authors have thus chosen ANN as a prediction method for fault detection. Basurko et al. [25] predicted 15 different parameters with ANN and then compared predicted to measured values in a marine operational environment to evaluate whether any fault was indicated. Noor et al. [26] predicted power, BSFC, BTE, VE, EGT and NO_x and compared them with the results from mathematical models. Parlak et al. [27] predicted SFOC and T_{exh} for different injection timings in a diesel engine. Yusaf et al. [28] predicted brake power, torque, BSFC and exhaust emissions for a CNG/diesel dual-fuel engine where engine parameters were compared, concluding that there was lower power as well as lower emissions (NO_x, CO and CO₂) in dual-fuel cases.

As occurred with thermodynamic modelling, neural networks have also been used for performance prediction while using alternative fuels [29–32]. Many authors have likewise been including emission parameters in their neural networks, as that concept is becoming essential as time goes by. Agbulut et al. [33] predicted BSFC, P_{max} and HC, CO and NO_x emissions using engine load, fuel type and injection pressure as inputs. Among other conclusions, they stated that when increasing biofuel blends, CO and NO_x tended to decrease. Shailaja and Raju [34] predicted CO₂ soot and NO_x using crank angle, equivalence ratio, temperature, pressure, liquid mass evaporated and O₂ as inputs. Taghavifar et al. [35] studied soot, NO_x and CO₂ concentrations for different engine speeds. These emission parameters were predicted using the following inputs: Crank angle, equivalence ratio, inlet manifold temperature and pressure, O₂ concentration and liquid mass evaporated. This was carried out in an n-heptane fuelled engine.

Thermodynamic and neural network modelling have been widely used separately for different performance prediction studies, though few papers have compared these two prediction tools' accuracy in a real engine case while operating with different engine loads and conditions. Rida et al. [36] compared the performance of a multi-layer neural network and thermodynamic model for prediction of pressure and temperature in the cylinder in normal and faulty conditions. The comparison was made at a unique operation point of 1500 rpm; it was seen

that ANN was an accurate tool for predicting engine performance in normal and faulty conditions.

In this study, a comparison was made to contrast the reliability of ANN and thermodynamic modelling under different engine operation conditions. First, the thermodynamic model was fitted to a real test-bench engine, adjusting the combustion pressure curve to different engine loads with a unique model. ANN was then designed and trained to predict engine performance parameters. Finally, the accuracy of both models was verified in a single-cylinder engine running in real conditions. Although both modelling methods have been widely studied for parameter prediction, their level of utility and robustness was not previously compared when applied to the whole load range of an engine. Besides studying the accuracy of the models themselves, this study also analyses and compares the ability of these two modelling approaches to adapt to the whole load spectrum of a real engine, with the aim of discussing their application to real modelling cases.

2. Materials and methods

2.1. Testing bench and equipment

The engine used for the experimental phase is a single-cylinder Minsel 430; its characteristics are listed in Table 1. Different operating points are set using a hydraulic brake. The test bench diagram is shown in Fig. 1. The acquisition system used to measure and acquire engine parameters is DEWETRON 2600. This data acquisition tool can acquire data at high speed, which allows cylinder combustion pressure data to be measured according to crank angle position. After the data was recorded, it was processed using AVL Concerto data treatment software, and then filtered and prepared for introduction in the models using Python3. Table 2 shows the equipment used to measure test bench parameters (see Fig. 1) during the tests.

The engine was tested in 7 different operating conditions, increasing engine load from 0% to 100%. After setting each operating point, the engine was kept running for 30 min to ensure steadiness at that operating point. Meanwhile, engine fuel mass consumption was calculated by measuring the fuel tank weight difference using an accurate load cell; BSFC was therefore achieved. After 30 min, cylinder performance parameters (i.e. combustion pressure) were obtained with high acquisition frequency and engine parameters (i.e. exhaust gas temperature, emissions) with low acquisition frequency. These parameters were measured for 1.5 min, repeating the process twice to identify and eliminate any deviated data owing to measurement failure. Two 1.5 min files were therefore recorded for each engine load condition. Even when steady state is reached the engine parameters are not constant and vary somewhat; 10 different data samples were therefore recorded from each file, allowing $7 \times 2 \times 10 = 140$ sample datasets to be created to test the thermodynamic and ANN modelling predictions. The procedure followed to create datasets during engine tests is shown in Fig. 2. Each sample introduced in a dataset has two inputs and four outputs. Both models will have BMEP and engine speed as inputs, and BSFC, T_{exh} , CO and NO_x concentration predictions as outputs, predicted by both models and compared to real measured values.

Table 1
Minsel430 Characteristics.

Parameter	Value	Unit
Number of cylinders	1	[-]
Type of cycle	4-stroke high-speed	[-]
Compression ratio	19.3:1	[-]
Bore	85	mm
Stroke	75	mm
Nominal speed	3000	rpm
Nominal Power	5	kW
Air charge	Naturally aspirated	[-]

2.2. Thermodynamic modelling

The thermodynamic modelling software used to simulate engine performance was AVL Boost™. This is a one-dimensional engine cycle and gas exchange simulation software, with which users can connect different elements using pipes for simulations ranging from small motorcycle engines to large diesel marine engines [37]. Model fitting was conducted by approaching modelled combustion pressure curves to real curves. Analogue curve approximation validations can be found in different studies [12,14]. In this study, many different load conditions need to be simulated with a single model, fitting combustion pressure curves for all engine loads from 0% to 100%. The Minsel430 engine diagram developed in AVL Boost™ is shown in Fig. 3:

AVL Boost™ consists of a graphic programming environment in which engine elements are manually selected by the user. Once all engine elements are introduced to the model and connections between them are made using pipes, the model is ready to be adjusted to real engine operation. Engine data was introduced according to different AVL manuals and studies, following a specific order to introduce engine characteristics in the model [38,39].

2.2.1. Engine element

As seen in Fig. 3, the AVL scheme includes a component named engine, which is not apparently connected to any other element. In this component, the general features of the engine's operation were defined. Engine speed is one of the inputs introduced in both the thermodynamic and artificial intelligence models in this study, so this was introduced as a variable engine element parameter. Regarding engine friction, the FMEP calculation was conducted using the Patton et al. model [40], as seen in other diesel engine performance studies [41]. BMEP is the second input introduced in both models; it was regulated using an integral controller and controlling fuel mass supplied by cycle to the engine. The equation used for the integral controller is included in the supplementary material.

2.2.2. Cylinder

For cylinder modelling, geometrical cylinder characteristics were introduced as indicated in Table 2, including blow-by gap. Increased blow-by gap generates notable peak pressure reduction and also causes changes in peak pressure angle, as concluded by Hountalas et al. [42]. To accurately measure the blow-by, different blow-by values were tested to adjust both motored and combustion pressure curves to real ones. With respect to the combustion phase, multiple Vibe was used to model combustion. In this case study, real combustion pressure traces were available, so multiple iterations were conducted to approximate modelled curves to real pressure traces by modifying shaping parameters and fuel fraction burned in each Vibe function. The result is a second order Vibe function, which is a weighted sum of the two Vibe functions, basing the weighting on fuel fraction burned in each of them. The suitability of different-order Vibe functions to fit the combustion pressure curve was studied in [43]. Simpler approaches such as single Vibe functions were also applicable in the software, but modelled curves were not as close as with the multiple Vibe combustion model. Heat transfer was calculated based on the Woschni heat transfer model [44], where in-cylinder geometrical specifications were introduced as well as piston, cylinder head and liner wall temperatures. Finally, valve port specifications were introduced, along with valve lift curves and flow coefficient curves to characterize valve motion.

Emissions are modelled using specific models for each exhaust gas component. NO_x is modelled using equations based on Pattas and Hafner [45] and Zeldovich extended mechanisms. Carbon monoxide is modelled using reactions mentioned by Onorati et al. [46]. They calculated the carbon monoxide creation/destruction rate based on the classic kinetic sub-model described by Heywood [47]. Both emission gas creation/destruction equations contain empirical constants that have been tuned to accurately mimic those gases' concentration evolution

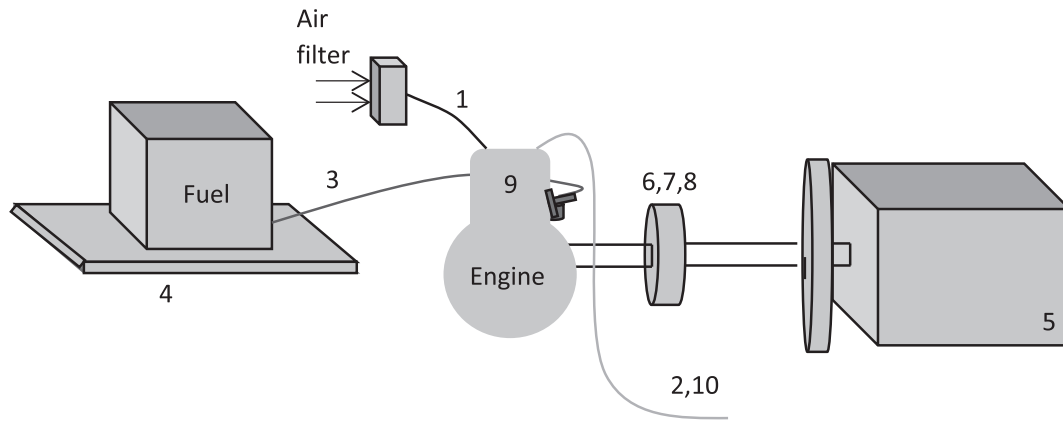


Fig. 1. Test bench diagram.

Table 2
Measuring instruments and uncertainties.

ID	Parameter	Unit	Instrument	Uncertainty
1	Air intake temperature	[°C]	K type thermocouple	± 4%
2	Exhaust gas temperature	[°C]	K type thermocouple	± 4%
3	Fuel temperature	[°C]	K type thermocouple	± 4%
4	Fuel tank weight	[kg]	HBM class 3 load cell	± 0.03%
5	Brake oil temperature	[°C]	K type thermocouple	± 4%
6	Engine Speed	Rpm	Kistler encoder type 2614B	± 0.05%
7	Piston position	°	Kistler encoder type 2614B	± 0.02°
8	Torque	Nm	Kistler 4502A50RA	< 0.07%
9	Pcomb	Bar	Piezoelectric sensor KISTLER 6013 CA	sensitivity: 21 pC/bar max. pressure 250 bar
10	Exhaust gas emissions	Ppm	TESTO 350XL MARITIME analyser	According to MARPOL Annex VI and NO _x technical code

through different engine loads. The equations used for both cylinder thermodynamic state calculation and emission parameter calculations are included in [supplementary material](#).

2.2.3. Air filter

The diesel engine used in this study is naturally aspirated, though the air filter needs to be modelled for proper air intake consideration in AVL Boost™. For this reason target pressure drop was determined, and inlet mass flow and air temperatures were introduced to ascertain the pressure drop curve. This pressure drop was later validated with the measured actual value, with good agreement.

2.2.4. Plenum, pipes and system boundaries

A plenum was introduced to the model to reproduce exhaust

manifold installed in a real engine, in which exhaust gas emissions are measured. The plenum volume and initial exhaust gas pressure and temperature were introduced to model this element. System boundary 1 represents air conditions when introduced to the engine, so ambient conditions were introduced in this element. For system boundary 2, depression with respect to ambient pressure was considered, since exhaust gases are removed from the test bed using an extractor. As mentioned by Hield [48], increased back pressure causes higher exhaust gas temperatures, so the initial system boundary pressure was tuned to fit exhaust gas temperatures to the real engine. Pipe modelling does require initial gas properties, as well as geometrical characteristics for each pipe. The pipe friction was set to default values and pipe wall temperature were introduced for each pipe according to the gas conditions of each pipe.

2.2.5. Reference combustion pressure curve filtering

Real combustion pressure curves were filtered to avoid noise and ensure exact reference curves to fit the model. For that purpose a Butterworth filter [49] was implemented in Python3 to pass different operating point curves through the filter. The filter order is 3, and the cut-off frequency is set at 0.05 Hz. The top dead-centre offset was also considered to make model curves and real curves match in the crank angle domain. With this filtering, measurement pressure pulses that occur in the sensor duct are eliminated. Fig. 4 shows a pressure curve filtered for one operating point:

2.3. Artificial neural network modelling

In this case study, a feed forward neural network structure was selected because of its generalization ability [50]. Such prediction tools are structures comprised of densely interconnected simple adaptive processing elements (called artificial neurons or nodes) which are capable of performing massively parallel computations for data processing and knowledge representation [51]. It operates as a human neural system, as it can learn from different situations to solve them in the near future. For instance, neural networks are very robust and able to




Fig. 2. Engine test procedure.




Fig. 3. . Minsel430 AVL Boost™ diagram.




Fig. 4. . Combustion pressure filtering.

solve complex nonlinear mathematical problems. The network structure is shown in Fig. 5:

Neural network modelling was conducted, comparing two different training algorithms: ADAM and Levenberg-Marquardt, respectively developed in Python and Matlab Neural Network Toolbox. The ADAM algorithm [52] is an extension of RMSprop [53], using momentum for




Fig. 5. Neural network diagram.

parameter updates. As mentioned in [52], the difference between RMSprop with momentum and ADAM is that ADAM updates are directly estimated using a running average of the first and second moment of the gradient. Ruder [54] stated that ADAM might be the best choice in terms of gradient descent optimization algorithms. Such algorithms perform first-order gradients, though there are other optimization algorithms that use higher order algorithms, such as the Levenberg-Marquardt algorithm. As seen in Table 4, Levenberg-Marquardt (LM) is widely used for diesel engine diagnosis applications. The reason for using this training algorithm is that it performs faster and achieves higher accuracy levels than other training algorithms, as demonstrated in different papers. Rezaei et al. [55] compared 12 different training algorithms, concluding that LM was the most suitable for the feed forward ANN. They affirmed that LM is faster and has better convergence than the commonly used back-propagation algorithm. As seen in [34], comparatively, time consumed by training is notably higher with gradient descent (498 s) than when using LM (0.663 s). Javed et al. [56] compared 7 different training algorithms, each with 5 combinations of activation functions, concluding that LM with logarithmic sigmoid and hyperbolic tangent sigmoid activation functions were the best option for predicting performance and emission characteristics of a dual-fuelled diesel engine.

In this study, network training error was analysed to define neuron

number in hidden layer and select the most accurate training algorithm. Analogue methodologies were used in other studies to ascertain neuron number in hidden layer by Noor et al. [57] or training learning rate by Yang et al. [58]. The minimum number of neurons found in literature is 7–8 for hidden layer [30], although it could be less if few inputs/outputs are considered. In this particular study, 7 will be minimum number of neurons considered for hidden layer. Error representations used for the study are R^2 and mean squared error (MSE), which are shown in Table 3.

In this case study, Levenberg-Marquardt shows higher R^2 and lower MSE values, so this algorithm was chosen for parameter prediction. From Table 3, it can be concluded that Levenberg-Marquardt shows higher training accuracy than the ADAM algorithm for any neuron number selected for hidden layer. Furthermore, LM needed 6.8 s for training, whereas the ADAM algorithm needed 11.3 s, indicating faster performance for the LM algorithm. The CPU used for the calculations is an Intel Core i5-8250U, with speeds up to 3.40 GHz, 4 cores, 8 threads processor and 8 GB RAM. For LM training, minimum MSE values match higher R^2 values when neuron number is 17, so this was selected as the number of neurons for the hidden layer. Table 4 shows different ANN structures, learning algorithms and activation functions used for diesel engine applications. It can be seen that Levenberg-Marquardt is widely used for this type of neural network, and hidden layer neuron number does not notably differ from other studies with similar input/output numbers [31,59]. Transfer functions used in this neural network are hyperbolic tangent sigmoid and pure linear for hidden and output layers, respectively.

Hence, 120 samples were used for network training, using Levenberg-Marquardt in Matlab, while 20 samples were reserved to test and compare network prediction with thermodynamic model predictions. The performance goal was set at 10^{-5} to ensure accurate prediction; if the performance goal is not met then the limit of 400 epochs was set as the maximum number of iterations.

3. Results

3.1. Model fitting

3.1.1. Thermodynamic modelling

The thermodynamic model was adjusted to the real engine by comparing modelled combustion pressure traces to real curves. In this case, for each of the 7 break positions the average combustion pressure curves were calculated, attempting to adjust modelled curves to these 7 different real average pressure curves.

First, motored pressure was studied and the TDC offset calculated, reaching good adjustments for all engine loads, as can be seen in Fig. 6. Before combustion starts, modelled curves perfectly match real curves in

Table 3
Training algorithms error for different neuron numbers in hidden layer.

Neuron no.	ADAM		Levenberg-Marquardt	
	R ²	MSE	R ²	MSE
7	0.9515	0.0048	0.99864	0.000291
8	0.9539	0.0045	0.9988	0.000256
9	0.9466	0.0053	0.9989	0.00024
10	0.9462	0.0053	0.9988	0.000253
11	0.952	0.0047	0.9991	0.000196
12	0.9477	0.0052	0.999	0.00022
13	0.9463	0.0053	0.9992	0.000178
14	0.9462	0.0053	0.9991	0.000185
15	0.9458	0.0054	0.9991	0.0002
16	0.9459	0.0054	0.9992	0.000162
17	0.9467	0.0053	0.9993	0.000158
18	0.9616	0.0037	0.9991	0.000192
19	0.959	0.004	0.9992	0.000163
20	0.9575	0.0041	0.9992	0.00017
21	0.9605	0.0038	0.9992	0.000164
22	0.9531	0.0046	0.9992	0.000162

Table 4

ANN structures, Training algorithms and Activation Functions used for diesel engine applications.

Author	ANN structure	Training algorithm	Activation functions
[25]	6 – 49 – 15	Back propagation	Sigmoid
[60]	1 – 8 – 1	Bayesian regularization back propagation	Hidden layer: hyperbolic tangent Output layer: Linear
[30]	5 – (5–7) * – 1 *Depending on the variable predicted	Levenberg-Marquardt & scaled conjugate gradient	Logistic sigmoid function
[57]	4 – 22 – 4	Levenberg-Marquardt	Tangent-sigmoid
[59]	2 – (8–15) – 3	Levenberg-Marquardt	Using different functions to identify different patterns in data: $f(x) = \exp(-x^2)f(x) = 1 - \exp(-x^2)$
[26]	3 – 22 – 6	Levenberg-Marquardt	Logistic sigmoid
[27]	3 – 7 – 2	Levenberg-Marquardt	Linear
[28]	2 – 22 – 9 (Double hidden layers approach)	Levenberg-Marquardt	Logistic sigmoid
[61]	4 – 10 – 10 – 5	Levenberg-Marquardt	TanhAxon
[34]	4 – 17 – 3	Levenberg-Marquardt	Log sigmoid
[62]	3 – 8 – 8 – 5	Levenberg-Marquardt	Hidden layer: tan-sigmoid Output: linear Log-sigmoid
[35]	6 – 18 – 3	Levenberg-Marquardt	Logsig (not specifically mentioned)
[63]	6 – 18 – 3x1	Levenberg-Marquardt	Hidden layer: Tansig Output layer: Logsig
[31]	2 – 25 – 4	Levenberg-Marquardt	Hidden layer: Logsig Output layer: Linear

all engine loads, as engine load does not directly affect motored pressure curves, it being a naturally aspirated engine. These adjustments were done by tuning cylinder parameters as blow-by gap.

After the motored pressure adjustments, combustion parameters were fitted to adjust the high-pressure phase for different operating loads. Fig. 6 shows combustion pressure curves for 3 different engine loads. After the start of combustion, modelled pressure curve accuracy changes with load, as lower load curves seem to be better adjusted than higher load curves. It is possible to appreciate a slight overestimation of peak pressure at high load and an underestimation at low load, although the difference is small and there is very good agreement in the curve fitting. This will be discussed later in Section 4.

3.1.2. Neural network modelling

Neural network adjustment was evaluated by studying training regression for different outputs. After designing a neural network structure meant to be as accurate as possible for this particular application, the training regression was analysed, observing whether outputs match target values. Testing was conducted, comparing performance and emission predictions with the thermodynamic model and real engine test values. Fig. 7 shows the training regression values for the four outputs studied in this work: BSFC, T_{exh} , CO and NO_x . Four outputs present high training regression coefficients after running 400 epochs; these high regression values' effect on predictions will be analysed later.

3.2. Model predictions

The thermodynamic and artificial intelligence models were independently fitted to reproduce Minsel430 diesel engine performance. BMEP and engine speed are inputs for both models, and SFOC, T_{exh} , NO_x




Fig. 6. . Combustion pressure curve fitting.

and CO were predicted for 20 different samples by both models. Calculation time was measured in both thermodynamic and neural network models so their utility in real performance prediction applications could be discussed later. The thermodynamic model requires 1234.29 s to make calculations, while the ANN model requires 0.52 s.

Fig. 8 shows performance and emission parameter predictions for 20 selected testing samples, as well as their respective measured target values. Both model predictions and target values are shown with respect to engine power, measured in real-condition engine tests.

As seen in Fig. 8a, AVL predicts higher BSFC values with respect to real values for the whole load range of the engine. Error remains constant according to the load, so it seems that the thermodynamic model has created a close relationship between BSFC and load, though with an incorrect intercept term. On the other hand, ANN accurately predicts BSFC for almost all engine loads. The overall MAPE values for BSFC prediction are 0.46% and 5.91% for ANN and AVL, respectively. Fig. 9a shows the MAPE evolution with respect to load, showing that the MAPE values for BSFC prediction are higher in AVL for the entire engine load range.

In the case of T_{exh} prediction, model prediction accuracy changes depending on engine load. There is a load range in which AVL performs better than ANN, corresponding to medium–low engine loads. Outside this range, in the case of the lowest loads, ANN makes closer predictions and more notably in medium to higher loads (Fig. 9b). In the case of the highest loads (power values around 4.5 kW), the AVL results diverge from real values (Fig. 8b). The overall MAPE values for T_{exh} prediction given by the two models are 0.50% and 1.86% for ANN and AVL, respectively, and are the lowest MAPE values compared to other parameter predictions.

The CO emission predicted by AVL is closer to real values for lower engine loads (Fig. 8c). When increasing engine load, the ANN prediction error decreases while AVL error increases, until reaching the highest engine load values in which AVL gives higher MAPE values than ANN. This indicates that the thermodynamic model does not properly represent the sharp increase in CO concentrations at high engine loads. The overall MAPE values for ANN and AVL predictions are 13.75% and 14.99%, respectively (Fig. 9c).

NO_x emissions are more accurately predicted by the neural network model for the engine's entire load spectrum (Fig. 8d). The overall MAPE values are 2.18% and 3.28% for the ANN and AVL predictions

respectively. Likewise, higher engine load values do not affect thermodynamic prediction accuracy level, as occurs with CO emission predictions. Thermodynamic model predictions give higher MAPE values for all the samples, and error difference between both prediction methods is almost constant throughout the engine load range (Fig. 9d).

4. Discussion

In this contribution two different modelling approaches were fitted to reproduce diesel engine performance and emissions, analysing the adaptability of each model when facing different conditions. According to the MAPE values shown in Section 3.2, both models proved to be capable of simulating a single-cylinder diesel engine functioning in different load conditions. However, each model showed better results for some parameters and load conditions. Some authors focused their models on only a few different engine conditions [19,36]. Others [33] have covered a wider engine load range, though designing a specific ANN for each of the outputs selected for the model, which suggests higher accuracy but lower robustness. In this study the adaptability of each modelling technique was tested, covering the whole engine load spectrum with a single model for each approach. The results of the models and implementation requirements were compared to evaluate the feasibility of employing them for CBM in actual operational environments.

According to BSFC, ANN is seen to provide accurate results for all engine loads, partly due to the highest training regression reached for this parameter (Fig. 7). However, the AVL model predictions show higher deviation from real values, compared to the ANN model predictions, maintaining constant deviation through different engine loads. This leads to the conclusion that that AVL has created a proper relationship between BSFC and engine load, but the intercept term is wrongly calculated. Although the AVL results are quite deviated, both models show relatively low MAPE values (ANN 0.45% and AVL 5.91%). Roy et al. [61] included BSFC among the parameters predicted by their ANN, based on a previous correlation study which showed a strong correlation between load and BSFC. This may consequently be one of the reasons for BSFC predicted by ANN being the parameter with the lowest overall MAPE value of all parameters in this study. Noor et al. [26] reached 4.45% and 28.35% MAPE values for ANN and mathematical model predictions respectively for BSFC. Javed et al. [56] reached




Fig. 7. . Training regression values for BSFC, Texh, CO and NOx.

4.86% overall MAPE values for different performance and emission predictions, among which BSFC was included, using ANN trained by the Levenberg-Marquardt algorithm, as in this study. The cited results show that even if AVL shows higher error than ANN for BSFC prediction, the thermodynamic model's error is in the range of other research work.

As expected, T_{exh} shows dependency with respect to engine load. In the case of medium–low power values AVL presents better results, while for medium–high power values ANN is more accurate. This may be caused by maladjustment of the thermodynamic model for higher engine loads. As seen in Fig. 6, combustion pressure curves were closer to real curves when facing lower loads than in the higher load curve fitting; it may thus be the reason for obtaining worse results in the thermodynamic model when introducing higher power values. Parlak et al. [27] and Cay et al. [30] reached 2.36% and 3.14% MAPE values respectively for T_{exh} prediction with ANN, which leads to belief that the T_{exh} prediction in this study is reliable in both models, with 0.50% and 1.86% overall MAPE values for ANN and AVL, respectively. Despite this, there are also closer approximations for T_{exh} using ANN in the literature, as can be seen in [57], with a 0.58% MAPE value for T_{exh} prediction.

According to Ramalingam et al. [64] when brake power exceeds 70%, CO emissions undergo a sharp increase for various possible reasons (i.e. increase in fuel fraction, in-cylinder temperature, knocking capability or lack of O_2 leading to incomplete combustion for highest loads).

This may be one of the reasons why the AVL model is more accurate than ANN when predicting CO emissions, except for the highest engine loads. If only the overall MAPE values of 20 samples are studied, ANN and AVL present MAPE values of 13.75% and 14.99%, respectively, which are relatively high comparing to the 1.3% obtained in [55] using a feed forward neural network. These MAPE values would suggest more accuracy in ANN predictions. Nevertheless, if MAPE evolution is studied through different engine loads, the conclusion drawn is that only when considering very high CO load predictions does the AVL error becomes higher than the ANN error (Fig. 9c), concluding that there is better performance for the thermodynamic model when not considering highest engine loads.

The NO_x predictions are reliable in both models, regardless of engine load. As seen in [65], the MAPE value for NO_x prediction is 1.99%, the same as the MAPE reached in [61] and lower than the 2.18% and 3.28% achieved in this study for ANN and AVL, respectively. Despite this, the error values are low enough to prove that both models are able to adjust to different load conditions and ensure accurate NO_x predictions. A recent study by Uslu [66] included NO_x among predicted parameters when comparing response surface methodology to ANN prediction capability. Even though the NO_x predictions were less accurate (9.705% and 6.438% for ANN and RSM, respectively) than in the present study, the CO predictions showed higher accuracy (9.365% and 7.894% for

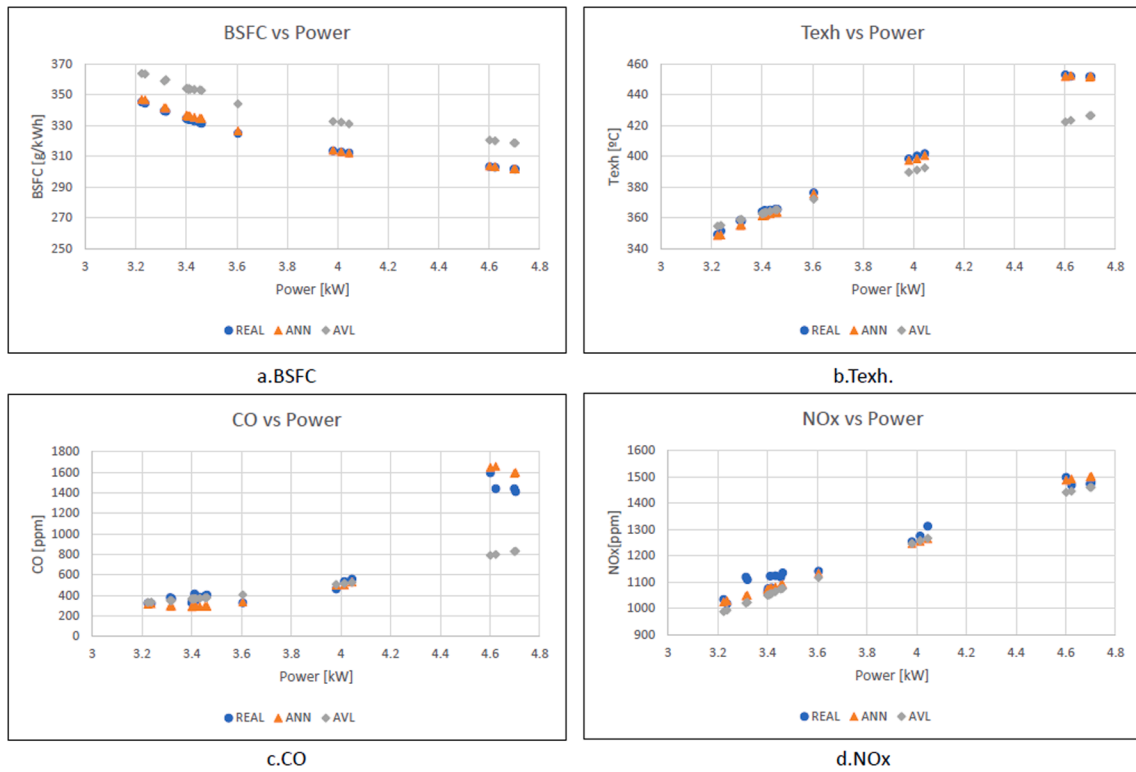


Fig. 8. . Thermodynamic, ANN model and engine test results for BSFC, Texh, CO and NOx.

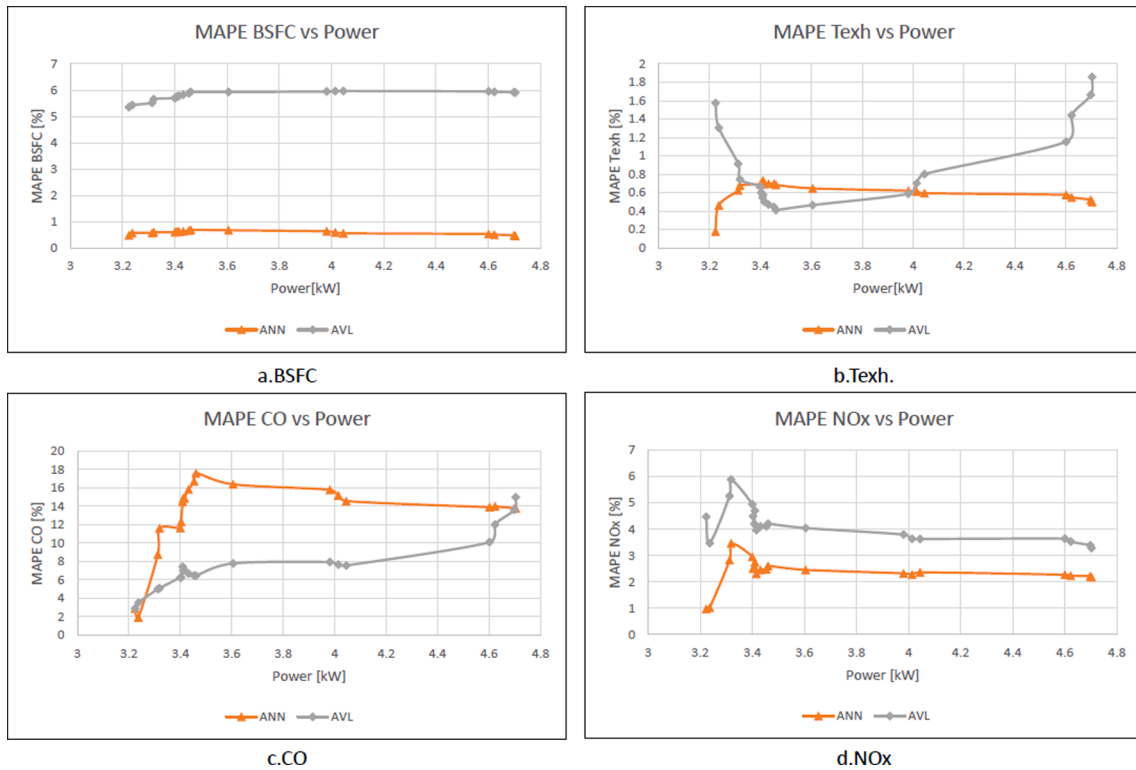


Fig. 9. . MAPE values for thermodynamic and ANN models for BSFC, Texh, CO and NOx predictions.

ANN and RSM, respectively). These results, along with other results from similar studies [67], suggest that accuracy level does not only depend on the model but also on the parameter studied.

As seen in Fig. 8b and 8c, in the case of the parameters T_{exh} and CO,

when the highest engine loads are reached, the thermodynamic predictions' difference from real values increases. This could be caused by the existing maladjustment of the model for highest load operations as seen in Fig. 6. Alternative papers may analyse the viability of

introducing variable FMEP variable with respect to engine load, adjusting engine friction losses for high load condition curves. Different engine friction modelling techniques could be studied, such as the Shayler et al. model [68] available in AVL, the classic Chen-Flynn model [69] or table-based experimental measured FMEP values.

Finally, when calculation time is observed it can be seen that ANN performs much faster than AVL, needing only 0.52 s for 20 sample output calculations, while AVL requires 1234.29 s. As claimed in [70], a well-trained ANN performs much faster than conventional simulation programs or mathematical models. Rida et al. [36] likewise concluded that ANN performed 80 times faster than the physical model developed in the study. This suggests that if instant output calculations are required, then ANN may be more recommendable. On the other hand, besides calculating BSFC, T_{exh} , CO and NO_x , AVL provides many additional outputs (i.e. combustion pressure curves, in-cylinder temperature curves) that may be useful for condition-based engine maintenance. The adaptability of the thermodynamic model to different engine loads nevertheless presents a challenge, as it has to be accurate from 0% to 100% loads.

The thermodynamic model requires many engine design variables for implementation (valve lift, discharge coefficient, pipe length and diameter, etc). All these parameters are not always available for an engine in field conditions; hence, the implementation of thermodynamic modelling in operational engines in the field represents a challenge in itself (i.e., engines in power plants and/or ships). And that's not all. Once implemented, the thermodynamic model has to be fitted to the actual engine performance parameters measured in real operating conditions. On the contrary, ANN only requires operational parameters and much less computation time, thereby increasing the feasibility of its application in field conditions and real-time operation with the engine running. All things considered, each model presents its specific advantages, and both proved to be reliable in terms of the performance and emission prediction presented in this case study.

5. Conclusions

In this study two prediction tools were compared when facing different engine loads and operating points. Both tools, such as, the thermodynamic and artificial intelligence models, were fitted to predict BSFC, T_{exh} , CO and NO_x based on engine speed and BMEP.

On the one hand, the thermodynamic model was developed using AVL Boost™ software, designing a suitable engine scheme and fitting combustion pressure curves according to different loads to real pressure traces using a single model. On the other hand, the neural network model was developed by studying network error for tuning and comparing two efficient training algorithms to obtain more accurate network prediction.

Both models proved to be good adaptable tools to make performance and emission parameter predictions; but depending on each parameter and operating field, there were differences in model accuracies. From the present study, we could draw the following conclusions:

- Both models are capable of accurately predicting engine performance parameters (MAPE below 6 in BSFC and below 2% in T_{exh});
- ANN shows better results than the thermodynamic model for BSFC prediction, regardless of engine load;
- The thermodynamic model's prediction of T_{exh} is more accurate than the ANN prediction for medium–low loads, while ANN performs better with higher loads;
- CO emissions are better predicted by the thermodynamic model in the whole range of engine loads, except for the highest loads;
- NO_x predictions present high accuracy in both models, except in the range of low engine loads;
- The time consumed for calculations is much higher in the thermodynamic model than in the ANN model.

Neural Networks have proved to be an effective tool for diesel engine performance prediction and fault detection, which is why many research studies include neural networks. The advantage of this tool is that it very flexible and robust, adapting to different engine operation points with little error. The thermodynamic model has proved to be slower and has not adapted well to the highest engine loads. This may be corrected by introducing adaptive parameters with respect to engine load, as it may be a variable FMEP with respect to different loads or trying alternative friction models to adjust the engine. Even so, the thermodynamic model supplies many additional results, such as combustion pressure curves, rate of heat release curves or in-cylinder temperature, which may be useful for engine diagnosis. The thermodynamic models require engine construction and structure information that may not always be available in actual field conditions, while ANN employs engine performance parameters that are measured in engine operation.

Although the thermodynamic model requires more time than artificial neural networks for calculations, it would need much less time than real engine tests. As has been demonstrated in this contribution, the thermodynamic model is able to adapt to different engine conditions, whereby after fitting the model to a real engine it could be used to reproduce real engine tests. Excessive time-consuming engine tests would thus be avoided.

Neural networks have shown to be fast and accurate for performance and emissions parameter predictions. New networks could be trained using thermodynamic model outputs and then tested in real engine tests, analysing whether they are accurate enough.

Further work may implement a combination between both models. Fault generation with the thermodynamic model could be used in combination with ANN to define fault condition without the need to generate a fault in the real engine. Based in the results of this study, future papers will cover implementation of the same methodology in a turbocharged and air-cooled multi-cylinder engine with higher output. The papers are expected to also cover actual fault generation in an engine in test bench for the validation of ANN and thermodynamic models in fault detection.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgements

The work behind this contribution was funded by the Basque Government. J. Castresana has benefited from a grant from the Department of Economic Development and Infrastructures. The authors also want to thank the Department of Thermal Engineering and Nautical and Naval Machines of the University of the Basque Country. This paper is contribution no. 1007 of AZTI, Marine Research, Basque Research and Technology Alliance (BRTA).

Appendix A. Supplementary material


Supplementary data to this article can be found online at <https://doi.org/10.1016/j.applthermaleng.2020.116343>.

References

- [1] N. Arunraj, J. Maiti, Risk-based maintenance—techniques and applications, *J. Hazard. Mater.* 142 (2007) 653–661.
- [2] W. Wang, B. Hussin, T. Jefferis, A case study of condition based maintenance modelling based upon the oil analysis data of marine diesel engines using stochastic filtering, *Int. J. Prod. Econ.* 136 (2012) 84–92.
- [3] R. Antonić, Z. Vukić, O. Kuljača, Marine diesel engine faults diagnosis based on observed symptoms and expert knowledge, *IFAC Proc. Volumes* 36 (2003) 133–138.

- [4] F. Payri, P. Olmeda, J. Martín, A. García, A complete 0D thermodynamic predictive model for direct injection diesel engines, *Appl. Energy* 88 (2011) 4632–4641.
- [5] J. Benajes, P. Olmeda, J. Martín, R. Carreño, A new methodology for uncertainties characterization in combustion diagnosis and thermodynamic modelling, *Appl. Therm. Eng.* 71 (2014) 389–399.
- [6] G. Gonca, E. Dobrucali, Theoretical and experimental study on the performance of a diesel engine fueled with diesel–biodiesel blends, *Renew. Energy* 93 (2016) 658–666.
- [7] E. Jiaqiang, G. Liu, Z. Zhang, D. Han, J. Chen, K. Wei, J. Gong, Z. Yin, Effect analysis on cold starting performance enhancement of a diesel engine fueled with biodiesel fuel based on an improved thermodynamic model, *Appl. Energy* 243 (2019) 321–335.
- [8] M. Altosole, U. Campora, M. Figari, M. Laviola, M. Martelli, A diesel engine modelling approach for ship propulsion real-time simulators, *J. Mar. Sci. Eng.* 7 (2019) 138.
- [9] D. Khan, M.Z. Gül, Zero-dimensional modelling of a four-cylinder turbocharged diesel engine with variable compression ratio and its effects on emissions, *SN Appl. Sci.* 1 (2019) 1162.
- [10] G. Theotokatos, S. Stoumpos, V. Bolbot, E. Boulougouris, Simulation-based investigation of a marine dual-fuel engine, *J. Mar. Eng. Technol.* 19 (2020) 5–16.
- [11] A. Albrecht, O. Grondin, F. Le Berr, G. Le Sollic, Towards a stronger simulation support for engine control design: a methodological point of view, *Oil Gas Sci. Technol.-Revue de l'IFP* 62 (2007) 437–456.
- [12] A. Alqahtani, F. Shokrollahhassanbarough, M.L. Wyszynski, Thermodynamic simulation comparison of AVL BOOST and Ricardo WAVE for HCCI and SI engines optimization, *Combust. Eng.* 54 (2015).
- [13] D.D. Ion, N. Anisor, Single cylinder diesel engine performance estimation using AVL boost software, in: *Proceedings of the 12th WSEAS international conference on Neural networks, fuzzy systems, evolutionary computing & automation, World Scientific and Engineering Academy and Society (WSEAS)*, 2011, pp. 173–176.
- [14] J.A.P. Rubio, F. Vera-García, J.H. Grau, J.M. Cámara, D.A. Hernandez, Marine diesel engine failure simulator based on thermodynamic model, *Appl. Therm. Eng.* 144 (2018) 982–995.
- [15] J.-G. Yang, X.-M. Zhang, H.-F. Wang, Fault simulation for the marine intelligent diesel engine [J], *Ship Ocean Eng.* 3 (2008).
- [16] V.V. Pham, V.V. Le, A modelling technique of the intake and exhaust systems of a medium speed marine diesel engine, in: *AIP Conference Proceedings*, Vol. 2207, AIP Publishing LLC, 2020, pp. 030003.
- [17] M. Aldhaidhawi, R. Chiriac, V. Bădescu, G. Descombes, P. Podevin, Investigation on the mixture formation, combustion characteristics and performance of a Diesel engine fueled with Diesel, Biodiesel B20 and hydrogen addition, *Int. J. Hydrogen Energy* 42 (2017) 16793–16807.
- [18] A. Rimkus, M. Berioza, M. Melaika, R. Juknelevičius, Z. Bogdanovičius, Improvement of the compression-ignition engine indicators using dual fuel diesel and liquefied petroleum gas, *Procedia Eng.* 134 (2016) 30–39.
- [19] D.C. Nguyen, Q.V. Tran, Combustion characteristics of SI engine fueled with 2, 5-dimethylfuran and gasoline blends using AVL-boost simulation, *J. Mech. Eng. Res. Dev.* (2019) 34–37.
- [20] C. Cai, X. Weng, C. Zhang, A novel approach for marine diesel engine fault diagnosis, *Cluster Comput.* 20 (2017) 1691–1702.
- [21] J. Flett, G.M. Bone, Fault detection and diagnosis of diesel engine valve trains, *Mech. Syst. Sig. Process.* 72 (2016) 316–327.
- [22] A. Moosavian, H. Ahmadi, A. Tabatabaefar, M. Khazaei, Comparison of two classifiers K-nearest neighbor and artificial neural network, for fault diagnosis on a main engine journal-bearing, *Shock Vibration* 20 (2013) 263–272.
- [23] A. Atmanli, B. Yüksel, E. Ileri, A.D. Karaoglan, Response surface methodology based optimization of diesel–n-butanol–cotton oil ternary blend ratios to improve engine performance and exhaust emission characteristics, *Energy Convers. Manage.* 90 (2015) 383–394.
- [24] A. Atmanli, E. Ileri, N. Yilmaz, Optimization of diesel–butanol–vegetable oil blend ratios based on engine operating parameters, *Energy* 96 (2016) 569–580.
- [25] O.C. Basurko, Z. Uriondo, Condition-based maintenance for medium speed diesel engines used in vessels in operation, *Appl. Therm. Eng.* 80 (2015) 404–412.
- [26] C.W.M. Noor, R. Mamat, A.N. Ahmed, Comparative study of artificial neural network and mathematical model on marine diesel engine performance prediction, *Int. J. Innovat. Comput. Inform. Control* 14 (3) (2018) 959–969.
- [27] A. Parlak, Y. Islamoglu, H. Yasar, A. Egrisogut, Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a diesel engine, *Appl. Therm. Eng.* 26 (2006) 824–828.
- [28] T.F. Yusaf, D. Buttsworth, K.H. Saleh, B. Yousif, CNG-diesel engine performance and exhaust emission analysis with the aid of artificial neural network, *Appl. Energy* 87 (2010) 1661–1669.
- [29] P. Madane, R. Panua, Investigation of Performance of jatropha oil on diesel engine using Artificial Neural Network Model, *Int. J. Computat. Intell.* IoT 2 (2019).
- [30] Y. Cay, A. Çiçek, F. Kara, S. Sağıroğlu, Prediction of engine performance for an alternative fuel using artificial neural network, *Appl. Therm. Eng.* 37 (2012) 217–225.
- [31] B. Ghobadian, H. Rahimi, A. Nikbakht, G. Najafi, T. Yusaf, Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network, *Renew. Energy* 34 (2009) 976–982.
- [32] B. Işcan, ANN modeling for justification of thermodynamic analysis of experimental applications on combustion parameters of a diesel engine using diesel and safflower biodiesel fuels, *Fuel* 279 (2020), 118391.
- [33] Ü. Ağbulut, M. Ayyıldız, S. Saridemir, Prediction of performance, combustion and emission characteristics for a dual fuel diesel engine at varying injection pressures, *Energy* 117257 (2020).
- [34] M. Shailaja, A.S.R. Raju, Neural Network—Based Diesel Engine Emissions Prediction for Variable Injection Timing, Injection Pressure, Compression Ratio and Load Conditions, in: *Emerging Trends in Electrical, Communications and Information Technologies*, Springer, 2017, pp. 109–122.
- [35] H. Taghavifar, H. Taghavifar, A. Mardani, A. Mohebbi, S. Khalilarya, S. Jafarmadar, Appraisal of artificial neural networks to the emission analysis and prediction of CO₂, soot, and NO_x of n-heptane fueled engine, *J. Cleaner Prod.* 112 (2016) 1729–1739.
- [36] A. Rida, H.M. Nahim, R. Younes, H. Shraim, M. Ouladsine, Modeling and simulation of the thermodynamic cycle of the diesel engine using neural networks, *IFAC-PapersOnLine* 49 (2016) 221–226.
- [37] A.L. GmH, Boost Theory (v2014. 1), AVL List GmbH: Graz, Austria, (2014).
- [38] A. BOOST, Users guide, AVL List GmbH, Austria, (2010).
- [39] AVL, 4 Cylinder TCI DI Diesel Engine IRA, v2014.1 (2015).
- [40] K.J. Patton, R.G. Nitschke, J.B. Heywood, Development and evaluation of a friction model for spark-ignition engines, *SAE Trans.* (1989) 1441–1461.
- [41] A. Praptijanto, A. Muharam, A. Nur, Y. Putrasari, Effect of ethanol percentage for diesel engine performance using virtual engine simulation tool, *Energy Procedia* 68 (2015) 345–354.
- [42] D. Hountalas, G. Mavropoulos, G. Kourbetis, Experimental investigation to develop a methodology for estimating the compression condition of DI Diesel engines, *Energy Convers. Manage.* 47 (2006) 1–18.
- [43] Y. Ding, Characterising combustion in diesel engines, *TU Delft* 668 (2011).
- [44] G. Woschni, A universally applicable equation for the instantaneous heat transfer coefficient in the internal combustion engine, in: *SAE Technical paper*, 1967.
- [45] K. Pattas, G. Häfner, Stickoxidbildung bei der ottomotorischen Verbrennung, *MOTORTECHN. Z.* 34 (1973).
- [46] A. Onorati, G. Ferrari, G. D'Errico, 1D unsteady flows with chemical reactions in the exhaust duct-system of SI engines: predictions and experiments, *SAE Trans.* (2001) 738–752.
- [47] J.B. Heywood, *Combustion engine fundamentals*, 1^a Edição., Estados Unidos, 1988.
- [48] P. Hield, The effect of back pressure on the operation of a diesel engine, in: *DEFENSE SCIENCE AND TECHNOLOGY ORGANIZATION VICTORIA (AUSTRALIA) MARITIME ...*, 2011.
- [49] S. Butterworth, On the theory of filter amplifiers, *Wireless Engineer* 7 (1930) 536–541.
- [50] P. Benardos, G.-C. Vosniakos, Optimizing feedforward artificial neural network architecture, *Eng. Appl. Artif. Intell.* 20 (2007) 365–382.
- [51] R. Hecht-Nielsen, *Neurocomputing* Addison-Wesley, Reading, MA, (1990).
- [52] D.P. Kingma, J. Ba, Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, (2014).
- [53] G. Hinton, N. Srivastava, K. Swersky, Neural networks for machine learning, Coursera, video lectures, 264 (2012) 1.
- [54] S. Ruder, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747*, (2016).
- [55] J. Rezaei, M. Shahbakhti, B. Bahri, A.A. Aziz, Performance prediction of HCCI engines with oxygenated fuels using artificial neural networks, *Appl. Energy* 138 (2015) 460–473.
- [56] S. Javed, Y.S. Murthy, R.U. Baig, D.P. Rao, Development of ANN model for prediction of performance and emission characteristics of hydrogen dual fueled diesel engine with Jatropha Methyl Ester biodiesel blends, *J. Nat. Gas Sci. Eng.* 26 (2015) 549–557.
- [57] M.N. CW, M.Y. MH, I. CK, N. MM, Prediction of marine diesel engine performance by using artificial neural network model, (2016).
- [58] F. Yang, H. Cho, H. Zhang, J. Zhang, Y. Wu, Artificial neural network (ANN) based prediction and optimization of an organic Rankine cycle (ORC) for diesel engine waste heat recovery, *Energy Convers. Manage.* 164 (2018) 15–26.
- [59] O. Obodeh, C. Ajuwa, Evaluation of artificial neural network performance in predicting diesel engine NO_x emissions, *Eur. J. Scientific Res.* 33 (2009) 642–653.
- [60] I. Lazakis, Y. Raptodimos, T. Varelas, Predicting ship machinery system condition through analytical reliability tools and artificial neural networks, *Ocean Eng.* 152 (2018) 404–415.
- [61] S. Roy, R. Banerjee, P.K. Bose, Performance and exhaust emissions prediction of a CRDI assisted single cylinder diesel engine coupled with EGR using artificial neural network, *Appl. Energy* 119 (2014) 330–340.
- [62] S. Roy, R. Banerjee, A.K. Das, P.K. Bose, Development of an ANN based system identification tool to estimate the performance-emission characteristics of a CRDI assisted CNG dual fuel diesel engine, *J. Nat. Gas Sci. Eng.* 21 (2014) 147–158.
- [63] B. Liu, C. Zhao, F. Zhang, T. Cui, J. Su, Misfire detection of a turbocharged diesel engine by using artificial neural networks, *Appl. Therm. Eng.* 55 (2013) 26–32.
- [64] K. Ramalingam, A. Kandasamy, D. Balasubramanian, M. Palani, T. Subramanian, E. G. Varuvel, K. Viswanathan, Forecasting of an ANN model for predicting behaviour of diesel engine energised by a combination of two low viscous biofuels, *Environ. Sci. Pollut. Res.* (2019) 1–21.

- [65] M. Canakci, A.N. Ozsezen, E. Arcaklioglu, A. Erdil, Prediction of performance and exhaust emissions of a diesel engine fueled with biodiesel produced from waste frying palm oil, *Expert Syst. Appl.* 36 (2009) 9268–9280.
- [66] S. Uslu, Optimization of diesel engine operating parameters fueled with palm oil-diesel blend: Comparative evaluation between response surface methodology (RSM) and artificial neural network (ANN), *Fuel* 276 (2020), 117990.
- [67] M. Aydın, S. Uslu, M.B. Çelik, Performance and emission prediction of a compression ignition engine fueled with biodiesel-diesel blends: a combined application of ANN and RSM based optimization, *Fuel* 269 (2020), 117472.
- [68] P.J. Shayler, D.K. Leong, M. Murphy, Friction teardown data from motored engine tests on light duty automotive diesel engines at low temperatures and speeds, in: *ASME 2003 Internal Combustion Engine and Rail Transportation Divisions Fall Technical Conference*, American Society of Mechanical Engineers Digital Collection, 2003, pp. 363-380.
- [69] S.K. Chen, P.F. Flynn, Development of a single cylinder compression ignition research engine, in, *SAE Technical Paper*, 1965.
- [70] H. Oğuz, I. Sarıtas, H.E. Baydan, Prediction of diesel engine performance using biofuels with artificial neural network, *Expert Syst. Appl.* 37 (2010) 6579–6586.



Full Length Article

Marine diesel engine ANN modelling with multiple output for complete engine performance map

Joseba Castresana^{a,*}, Gorka Gabiña^a, Leopoldo Martin^b, Aingeru Basterretxea^c, Zigor Uriondo^b

^a AZTI, Marine Research, Basque Research and Technology Alliance (BRTA), Txatxarramendi ugarte, 0-48395 Sukarrieta, Spain

^b Department of Thermal Engineering, University of the Basque Country UPV/EHU, Alameda Urquijo s/n, 48013 Bilbao, Spain

^c Nautical and Naval Machines, University of the Basque Country UPV/EHU, María Díaz de Haro 68, 48920 Portugalete, Spain



ARTICLE INFO

Keywords:

ANN
Diesel engine modelling
Performance prediction
Emission prediction
Performance map modelling
Multiple output prediction

ABSTRACT

Marine incidents given in recent years have been in part caused by propulsion issues. In this context, incipient propulsion faults may be identified by deviations between real values and healthy engine values provided by an accurate model. Engine modelling techniques have thus become a topic of interest in the last decade. On this basis, Machine learning approaches such as Artificial Neural Networks (ANN) have proved to be accurate and fast in terms of calculation times. However, up to now most research work has focused on predicting a few parameters for specific operation points. In order to analyse the generalization capability of ANN when predicting multiple outputs in real engine conditions, 35 different performance and emission parameters were simultaneously predicted in this study with an ANN. To do so, different engine operation points were tested in a six-cylinder marine diesel engine, characterizing the whole engine performance map. Additionally, some points from random regions throughout the entire engine performance map were tested to later analyse ANN performance on them. After defining network optimum structure and training and validating the Artificial Neural Network with 1000 data samples, the ANN was tested with data extracted from unseen random regions of the performance map. Mean Absolute Percentage Errors obtained for testing samples from random points of the engine performance map remained below 8.5% for all parameters with the exception of CO and NO₂ emissions predictions. For low temperature and high temperature cooling systems, oil system and exhaust gas system, MAPE values obtained were below 4.3%. Calculation time for 24 testing samples containing 35 parameters was 0.109 s, which along with the high accuracy level obtained demonstrated that ANN can predict multiple outputs throughout the whole engine performance map.

1. Introduction

Marine transport plays a pivotal role in global trade. It accounted for 46% of the value of goods exported from the European Union and 56.2% imported to the same region in 2019, making it the most widely used mean of goods transport [1]. In the same year, 1355 incidents were registered in the EU fleet, among which 295 were caused by propulsion loss [2]. In this context, a suitable maintenance strategy may lead to reduce the amount of future reported incidents. Maintenance approaches have been in constant development, from corrective or planned maintenance used in the past to the present condition-based maintenance strategies [3]. On this basis, incipient faults may be identified by detecting deviations between measured values and values

corresponding to a healthy engine that might be provided by an accurate engine model. Engine modelling techniques have thus become a topic of interest in the last years [4].

Among the several methods that currently exist for simulating internal combustion engines, thermodynamic modelling is one of the most widely utilized approaches, which in the last decade has been mostly carried out with different modelling software. Rubio et al. [5] analysed the effect of different engine faults (e.g. injection timing failure, turbine failure, exhaust manifold leakage) in 10 different performance parameters of interest (e.g. boost pressure, air mass flow, IMEP) throughout different engine load conditions by using AVL Boost software. More recently, Vera-García et al. [6] combined AVL Boost and reliability-centred maintenance to develop, evaluate and optimize a failure database in a four stroke medium speed marine diesel engine considering 15

* Corresponding author.

E-mail addresses: jcastresana@azti.es (J. Castresana), ggabina@azti.es (G. Gabiña), leopoldo.martin@ehu.eus (L. Martin), aingeru.basterretxea@ehu.eus (A. Basterretxea), zigor.uriondo@ehu.eus (Z. Uriondo).

<https://doi.org/10.1016/j.fuel.2022.123873>

Received 11 October 2021; Received in revised form 8 March 2022; Accepted 11 March 2022

0016-2361/© 2022 Elsevier Ltd. All rights reserved.

Nomenclature		ρ_0	Air density
<i>Acronyms</i>		<i>Temperatures</i>	
ANN	Artificial neural network	T_0	Ambient temperature
AVL	Anstalt für Verbrennungskraft maschinen List	T_{01}	LT water (Water cooler outlet)
BSFC	Brake specific fuel consumption	T_{02}	Oil (Engine outlet)
BTE	Brake thermal efficiency	T_{03}	HT Water (Engine inlet)
CBM	Condition based maintenance	T_{04}	LT Water (Water cooler inlet)
CO	Carbon monoxide	T_{05}	LT water (Water cooler inlet)
CO ₂	Carbon dioxide	T_{06}	Air (TC#2 outlet)
CRDI	Common rail direct injection	T_{07}	Oil (Engine inlet)
H ₀	Ambient relative humidity	T_{08}	Air (Engine inlet)
HC	Hydrocarbons	T_{09}	Fuel (engine inlet)
HCCI	Homogeneous charge compression ignition	T_{10}	Air (Air cooler inlet)
HT	High temperature	T_{11}	LT water (Water cooler outlet)
IMEP	Indicated mean effective pressure	T_{12}	Air (TC#1 outlet)
IMO	International Maritime Organization	T_{13}	LT water (Air cooler inlet)
ISO	International Organization for Standardization	T_{16}	Exhaust gas cylinder#1
k^h	Function multiplier for heavy conditions	T_{17}	Exhaust gas cylinder#2
k^l	Function multiplier for light conditions	T_{18}	Exhaust gas cylinder#3
LT	Low temperature	T_{19}	Exhaust gas cylinder#4
MAPE	Mean Absolute Percentage Error	T_{20}	Exhaust gas cylinder#5
MSE	Mean Squared Error	T_{21}	Exhaust gas cylinder#6
NO	Nitrogen oxide	T_{22}	Exhaust gas (TC#1 inlet)
NO ₂	Nitrogen dioxide	T_{23}	Exhaust gas (TC#2 inlet)
NO _x	Nitrogen oxides	T_{24}	Exhaust gas (TC#1 outlet)
PCA	Principal Component Analysis	T_{25}	Exhaust gas (TC#2 outlet)
P _e	Effective Power	T_{26}	Exhaust gas (Exhaust duct)
PM	Particulate mater	T_{27}	Exhaust gas (Exhaust duct)
R	Regression coefficient	<i>Pressures</i>	
ROHR	Rate of heat release	P ₀₁	HT water (Engine inlet)
SFOC	Specific fuel oil consumption	P ₀₂	LT water (Water cooler inlet)
SO ₂	Sulphur dioxide	P ₀₃	Air (Engine inlet)
SVM	Support vector machine	P ₀₄	Air (TC#1 outlet)
t	Target value	P ₀₅	Air (TC#2 outlet)
TC	Turbocharger	P ₀₆	Oil (Engine inlet)
TDC	Top dead centre	P ₀₇	Fuel (engine inlet)
T _{exh}	Exhaust gas temperature		
Y	Output value		

different engine failures. Likewise, some marine engine research studies have used this program for different applications such as fault detection system development [7] or engine subsystem performance modelling (e.g. intake and exhaust manifolds) [8]. Alternative types of software have also been utilized in marine propulsion system modelling and control strategies [9,10]. Most of the above-mentioned research work applied 0D or 1D models, which according to Albretch et al. [11] may offer lower calculation times than higher dimensional approaches. However, this kind of models might present in some cases the drawback of relatively high calculation times even in 0D cases as stated by Baldi et al. [12], who combined a 0D thermodynamic model with mean value modelling approach to reduce calculation time.

Given the increasing interest in reaching high accuracy levels whilst also decreasing computational effort, machine learning methodologies have become of particular interest in engine modelling applications. As depicted by Mahesh [13], the term 'machine learning' covers various different algorithms and statistical models many of which have been used in engine modelling. Alonso et al. [14] combined ANN and Genetic Algorithms firstly predicting engine emissions and specific fuel consumption with ANN and later conducting optimization of these parameters with Genetic Algorithms. Among the results, they reached reductions up to 36% for HC and 3% to 6% reduction for BSFC. Lazakis et al. [15] employed a Support Vector Machine model training it with

healthy engine data and later utilizing this model to identify incipient faulty conditions based on real value deviations in a marine diesel engine. More recently, Wang et al. [16] combined PCA and back propagation Neural Network first to reduce the dimension of measured parameters from 16 to 3 using PCA and then classifying among 5 different engine faults (e.g. injector blockage, compressor blockage) by using ANN.

According to Yao et al. [17], Artificial Neural Networks have become so popular because of their many practical advantages such as adaptability, robustness, fault tolerance etc. Aside from fault detection and classification [18–20], ANNs have been widely used for engine performance parameter prediction. Parlak et al. [21] predicted exhaust gas temperature (T_{exh}) and specific fuel oil consumption (SFOC) for different injection timings in a single-cylinder diesel engine, proving that a well-trained ANN was fast and accurate enough to evaluate diesel engine parameters. Aydin et al. [22] predicted 7 different performance and emission parameters (e.g. BSFC, T_{exh} , NO_x) in a single cylinder diesel engine. Once ANN was trained, it was used to find optimum values of different engine variables such as maximum BTE or minimum BSFC. Recently, Castresana et al. [23] predicted BSFC, T_{exh} , NO_x and CO emissions for different engine speed and engine load conditions, proving that ANN was in the same accuracy range of thermodynamic modelling whilst it performed much faster in terms of output calculation time. As

stated by Maind et al. [24], an ANN can capture many kinds of relationships, quickly and easily modelling phenomena which otherwise may have been very difficult to explain. For this reason, ANNs have been widely used to calculate engine performance while using alternative fuels [25–27], without needing to know about the relation between the alternative fuel blends and the engine performance. This has also led many other authors to use ANNs for engine emission prediction [28–30], without the need for numerous chemical reactions to be solved. In the marine field, many authors have relied on ANNs to simulate marine diesel engines. Basurko et al. [31] predicted 15 different parameters in an 8-cylinder medium-speed marine diesel engine to later identify incipient faults (e.g. clogged turbine, bad fuel injection) based on deviations between modelled and real values. Noor et al. [32] compared the accuracy level of ANN and mathematical modelling when predicting brake power, BSFC, BTE, volumetric efficiency, T_{exh} and NO_x in a 6-cylinder marine diesel engine. They concluded that ANN was not only a reliable tool in terms of accuracy but that it also showed better overall performance than the mathematical modelling approach.

Although the existing literature shows a clear trend towards the usage of ANNs for engine modelling, most of the existing studies have not dealt with multiple output models, considering reduced output quantities in most contributions. Lazakis et al. [33] conducted a fault detection system based solely on T_{exh} prediction. Shailaja et al. [26] predicted CO, NO_x and HC, only including 3 different outputs for their model. Higher output dimension models could be found in [31,34] with 5 outputs, [29] with 6 and [35] with 8 outputs. Nevertheless, none of the presented studies included more than 10 outputs with some exceptions [28]. Some authors even designed separate ANNs for each output when higher output dimensions were presented [36]. Therefore, the present contribution explores, for the first time, the capability of neural networks to calculate 35 different outputs in a 6-cylinder marine diesel engine by using 8 inputs. This makes the study useful for engine condition maintenance because deviation from output values of engine model gives information about the engine condition, compared to previous studies that provided just a partial information of engine condition with limited outputs. Moreover, by introducing 8 measurable inputs, the model offers a complete image of the engine, predicting performance and emission parameters throughout the whole engine within low error levels.

Apart from that, most of the above-mentioned research predicted performance parameters in specific engine load and engine speed conditions. Some authors kept constant engine speeds while varying engine load and alternative fuel blends [22,33]. Some other research also focused on changing specific engine parameters such as fuel injection pressure [34] or compression ratio [29] as well as engine load. Alternatively, Noor et al. [35] varied engine load from 0% to 30% while also changing engine speed for their experiments. However, real vessel operations may be affected by external factors such as weather/sea conditions, so engine load relation with engine speed could vary. As stated by Perera et al. [36], the relation curve between engine load and engine speed in a Fixed Pitch Propeller may change from light running towards a heavier running curve depending on factors such as fouled vessel hull or rough weather. Moreover, Guo et al. [37] concluded that sea state and the direction of the waves (e.g. oblique direction) could affect the propeller thrust and torque for given rotation speeds.

However, research to date has not yet studied the generalization capability of ANN when considering the whole performance spectrum of the engine, simulating real changing operation conditions. Therefore, in this study, the whole performance map of a marine diesel engine was considered for the experimental trials. First, several engine trials were carried out by varying engine load and engine speed to cover the whole engine performance map. Consequently, an Artificial Neural Network structure was proposed with 8 inputs and 35 outputs, calculating the optimum number of neurons in a hidden layer by evaluating validation error parameters. Once the optimum ANN was trained and validated, it was tested both using some samples from the training/validation dataset

and also using unseen data from random samples throughout the engine performance map. Finally, results were discussed by analysing whether ANN are capable of multiple performance and emission output calculations in the whole performance map of the marine diesel engine.

2. Materials and methods

2.1. Experimental setup

Experimental trials were carried out in a 6-cylinder YANMAR-HYM-WET marine diesel engine test bench. This engine has twin-turbochargers and is cooled with a double circuit of sea water and fresh water; its characteristics are shown in Table 1. Engine load was regulated by using a hydraulic brake which allowed the load to be manually set from 0% to 100% of the engine capacity. Performance parameters of the engine were recorded using National Instruments Compact FieldPoint acquisition system, with except to engine speed, torque and piston position that were acquired by using DEWETRON 2600 which allows to measure some parameters with high acquisition frequency. Simultaneously, emission parameters acquired with TESTO 350XL Maritime Analyser were exported from easyEmission software. All acquired data was then coupled and pre-processed in Python 3 to later enter it in the Artificial Neural Network model.

Fig. 1 shows the engine scheme used for experimental tests. Temperature was measured at the inlet and outlet of each element of the scheme as well as in the exhaust gas outlet in each cylinder of the engine; pressure was also registered in some specific points of interest. All in all, 43 different performance and emission parameters were acquired throughout the whole engine, which are listed as follows: 25 temperature data, 7 pressure data, ambient conditions, engine torque, engine speed, fuel consumption and 5 emission parameters. Of these parameters, 8 were used as inputs and 35 were used as outputs for the neural network model. For Fig. 1, different colours were used depending on the working fluid (e.g. exhaust gases, Low temp. water), according to the main colours set for different fluids in ISO 14726 [38]. Data acquisition systems and their respective uncertainties are listed in Table 2.

2.2. Engine test procedure

2.2.1. Engine performance map

As seen in the literature review, many studies have used ANNs for diesel engine modelling. Nevertheless, most of this research has focused on specific engine load and engine speed conditions. To analyse the regression capability of ANN in real changing propulsion situations, the whole performance map of a marine diesel engine was considered in this study. To do so, different “power vs engine speed” relations were proposed and tested to later train, validate and test the Artificial Neural Network. Theotokatos et al. [39] studied the relation between engine brake power and rotational speed for different operating conditions in a ship propulsion system. They concluded that this relation should be considered cubic since the exponents of their fitted functions ranged from 3.048 to 3.013. Therefore, the present experimental trials were first conducted by considering the simplest cubic relation of the engine

Table 1
YANMAR-6HYM-WET engine characteristics.

Parameter	Value	Unit
Manufacturer	YANMAR	[-]
Type of cycle	4 S medium speed	[-]
N cylinders	6	[-]
Nominal speed	2100	Rpm
Nominal power	400	kW
Compression ratio	15.18	[-]
Bore	132.9	mm
Stroke	165	mm
Air charge	Turbocharged	[-]

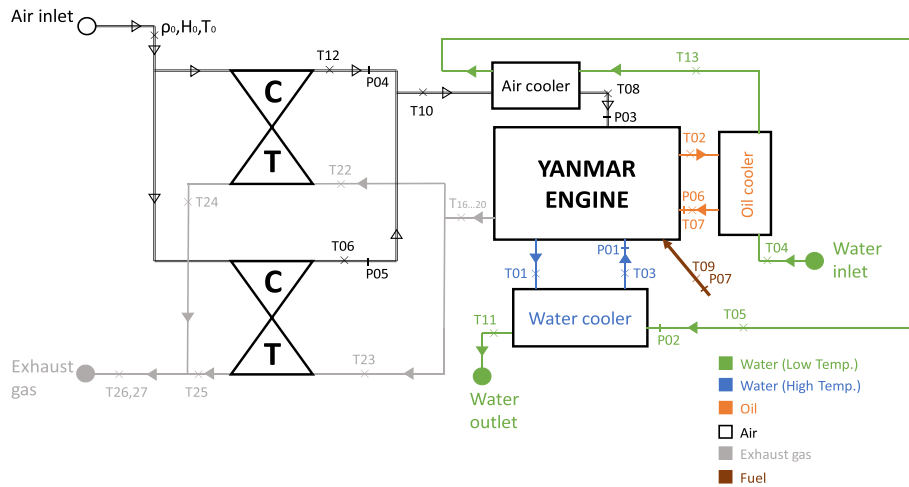


Fig. 1. YANMAR-6HYM-WET engine scheme.

Table 2
Data acquisition instruments and uncertainties.

ID	Unit	Instrument	Uncertainty	Acq. rate
T ₀₁ , T ₀₅ , T ₀₉ , T ₁₀ , T ₁₃	[°C]	Pt100 temperature sensor	±0.3 °C	1 sample/s
T ₀₂ , T ₀₃ , T ₀₄ , T ₀₆ , T ₀₇ , T ₀₈ , T ₁₁ , T ₁₂ , [T ₁₆ ,...,T ₂₇]	[°C]	K Type Thermocouple	±4%	1 sample/s
ρ ₀ ,H ₀ ,T ₀	[kg/m ³], [%], [°C]	HD2001.1 meteorological station	T0: ±0.3% H0: ±1.5% ρ0: ±0.5 mbar	1 sample/s
P ₀₁ , P ₀₂	[bar]	Pressure transmitter SEN 9601 B055	±0.5%	1 sample/s
P ₀₆ , P ₀₇	[bar]	Pressure transmitter SEN 9601 B075	±0.5%	1 sample/s
P ₀₃ , P ₀₄ , P ₀₅	[bar]	Pressure transmitter KTP-D-F1	±0.25%	1 sample/s
Engine speed	[rpm]	Kistler encoder Type 2614B	±0.05%	1 MHz
Piston Position	[°]	Kistler encoder Type 2614B	±0.02°	1 MHz
Torque	[Nm]	Kistler 4502A50RA	<0.07%	1 MHz
Fuel consumption	[Kg/h]	Instrument: KRAL OME13flow metre	±0.1%	1 sample/s
Exhaust gas emissions	[ppm], [%]	TESTO 350XL MARITIME analyser	NO: ± 5% NO2: ± 5 ppm CO: ± 10 ppm CO2: ± 0.3% vol	1 sample/s

and then varying this cubic relation to represent heavy and light propulsion conditions. These tests were carried out according to Test Type E3 in ISO8178 and IMO NO_x Technical Code [40,41]. Finally, constant speed performance of the engine was also considered and tested. Equation (1) shows the initial cubic relation considered for the first engine trials.

$$P_e = k \cdot N^3 \quad (1)$$

where P_e is the effective power of the engine measured in kW, k is the function multiplier and N is the engine speed measured in rpm.

Considering the nominal power and nominal speed of the engine depicted in Table 1, the following calculation can be made.

$$k = \frac{400kW}{2100rpm} = 4.3192 \cdot 10^{-8} \quad (2)$$

To represent heavy and light performance conditions caused by external factors (rough weather, fouled hull), the function multiplier k was modified to reach heavy and light condition functions. For that, the same displacement was provoked for the two curves as represented in equations (3) and (4).

$$k^h = k + 8 \cdot 10^{-9} = 5.1192 \cdot 10^{-8} \quad (3)$$

$$k^l = k - 8 \cdot 10^{-9} = 3.5192 \cdot 10^{-8} \quad (4)$$

k^h and k^l represent function multipliers for engine heavy and light performance functions respectively. Hence, 3 different relations between engine effective power and engine speed were reached. Additionally, engine constant speed condition was also considered (test cycle E2 according IMO NO_x Technical Code for controlled pitch propeller operation [40]). Fig. 2 shows the functions considered for experimental tests.

2.2.2. Data acquisition process

The engine was tested in each performance curve in the following load conditions: 25, 40, 50, 60, 75 and 100% of each curve (except 100% load of heavy conditions since it exceeded engine maximum power). After setting each load/engine speed condition, the engine was kept running for 20 min before data acquisition to ensure steady state of each point. Consequently, performance and emission data were acquired for 5 min; data acquisition frequency was 1 sample/second for both performance and emission parameters. This way, all conditions represented by circles in Fig. 2 were measured from the 3 cubic functions and constant RPM function. From each measured point, 50 samples were acquired for the database to later train/validate the ANN. Since performance data and emissions data were acquired with different software, data was coupled prior to its inclusion to the database. At the end of the experimental trials, a database containing 1000 samples from 43 performance and emission parameters was acquired.

In order to analyse the regression capability of the ANN for unseen data, 6 additional points were randomly selected from the engine performance map (depicted as triangles in Fig. 2). The experimental procedure of these 6 testing points was the same as the others (20 min to steady state, 5 min extraction), but these were not introduced in the training/validation phase of the ANN to later discuss the ANN prediction accuracy on them. Fig. 3a shows a general schema of the testing




Fig. 2. Engine performance curves and testing random points.

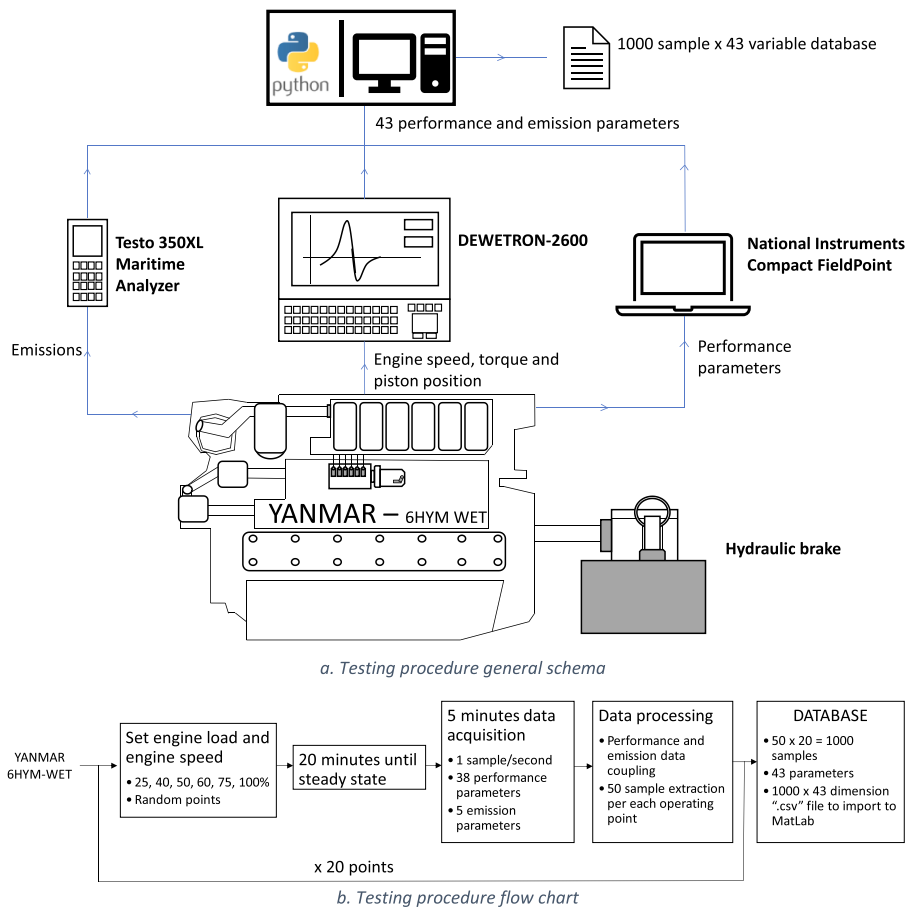


Fig. 3. Experimental test procedure.

procedure, while Fig. 3b shows the flow chart of the experimental procedure .

2.3. Artificial Neural Network model

In this study, Feed Forward Artificial Neural Networks were used to

predict engine performance and emission parameters. These are supervised learning networks, which receive both inputs and their respective outputs and then network parameters are changed to reach minimum error between predictions and real values [13]. The optimization algorithm used to train the network is Levenberg Marquardt. Rezaei et al. [42] concluded that Levenberg Marquardt was the most suitable

training algorithm after comparing it to other 12 algorithms when modelling a HCCI engine with alternative fuels. Furthermore, as demonstrated by Shailaja et al. [29] this algorithm is much faster than other gradient based algorithms, which is very interesting for real time applications. Many studies have thus employed Levenberg Marquardt algorithm in diesel engine ANN modelling [23]. The software employed to create and design the ANN is MatLab Neural Network Toolbox. Fig. 4 shows network structure; parameter ids are the same as in Fig. 1.

The network has 8 inputs and 35 outputs, and the optimum neuron number in hidden layer was selected by evaluating validation MSE and R values for different numbers ranging from 15 to 35 neurons. Mathematical expressions for such error parameters are shown in equations (5) and (6). Analogue methodologies were followed by Yang et al. [43] and Noor et al. [35] to determine training learning rate and neuron number in the hidden layer respectively. In this study, each neuron configuration was assessed 3 times and average MSE and R values were calculated to provide a fair comparison between different neuron numbers.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \tag{5}$$

$$R = \frac{(y - \bar{y})(t - \bar{t})^T}{\sqrt{(y - \bar{y})(y - \bar{y})^T} \sqrt{(t - \bar{t})(t - \bar{t})^T}} \tag{6}$$

y are the outputs calculated by the network and t are their respective target values. According to Yang et al. [43], a low MSE value may induce high accuracy prediction while high R values were expected for ANN. Therefore, neuron numbers within highest validation R and lowest MSE values were found in the present contribution. As Fig. 5 shows, 31 neurons in hidden layer presented lowest MSE values and highest R values, so this was chosen as the optimum neuron number for the hidden layer. The average training time for the 3 attempts with 31 neurons was

400.43 s. The CPU used for the calculations was an Intel Core i5-8250U, with speeds up to 3.40 GHz, 4 cores 8 threads processor and 8 GB RAM. Transfer functions used for hidden and output layer were hyperbolic tangent sigmoid and pure linear respectively. From the 1000 data samples, 70% were used for training and 30% for validation. Afterwards, testing was carried out by using the 6 points randomly located throughout the whole engine performance map. From each random point, 2 samples were extracted to avoid errors caused by measurement issues. Therefore, 12 samples were reserved from such random points for network testing. Additionally, from each cubic function 2 points from 25% and 75% loads were also included in testing database, in order to later compare performance prediction between these points and random points from the engine performance map. Therefore, a 24-sample database was built for network testing: 12 samples extracted from random engine operation points and another 12 extracted from engine cubic performance functions.

3. Results

3.1. Testing data prediction

After training and validating the ANN and searching for the optimum network structure, the model was tested with the above-mentioned 24 testing samples extracted from different regions of the engine performance map. Therefore, 35 performance and emission parameters were simultaneously predicted for those 24 testing samples. To analyse prediction accuracy at first sight, first regression lines were drawn between predicted outputs and their respective target values for testing data in each parameter. Fig. 6 shows the regression lines obtained for 16 representative parameters; the regression lines for all the 35 parameters are included in supplementary material. Colour code is the same as the one followed in Fig. 1; regression values were obtained with equation (6), in this case using outputs and target values for testing the data base.

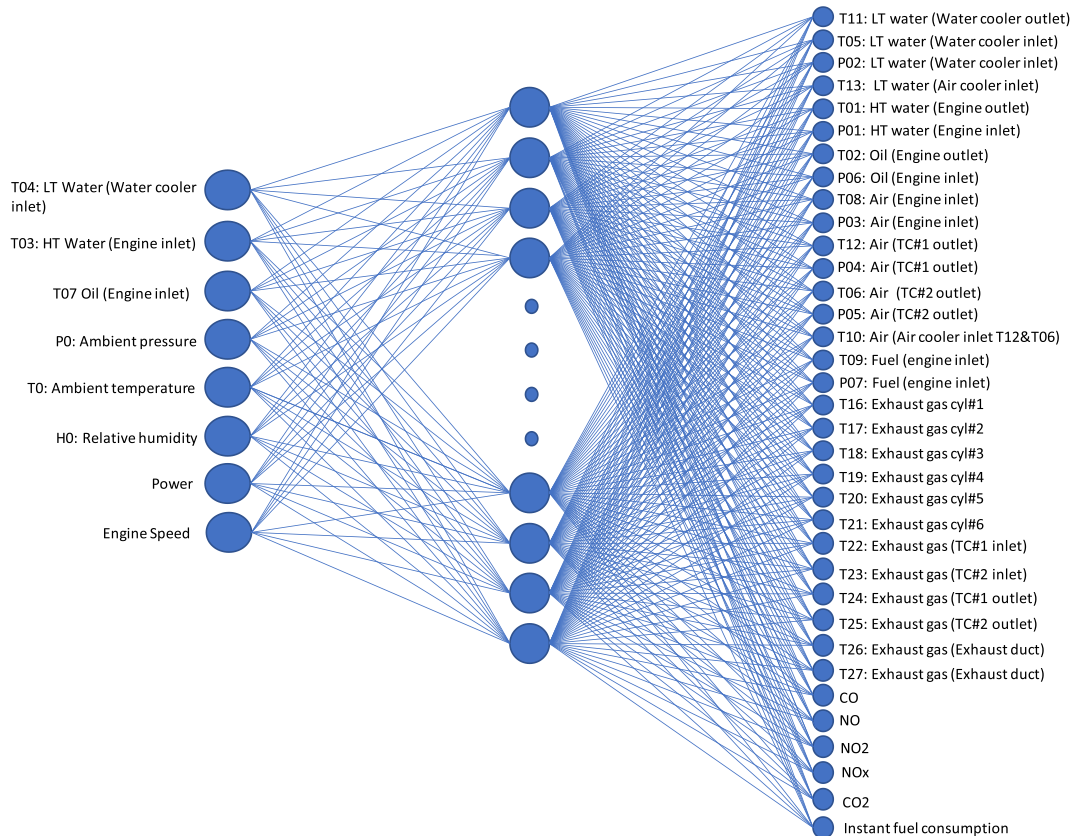


Fig. 4. Artificial Neural Network scheme.




Fig. 5. Validation MSE and R values for different neuron numbers in hidden layer.

Temperature predictions of low temperature water at water cooler outlet (T_{11}) and high temperature water at engine outlet (T_{01}) showed good agreement with their target values. Similar regression values near 1 were reached for air temperature at turbocharger #1 outlet (T_{12}) and temperature (T_{08}) and pressure (P_{03}) predictions in engine inlet. Regarding the fuel and oil circuits, fuel consumption prediction, oil temperature at engine outlet (T_{02}) and oil pressure at engine inlet (P_{06}) also showed relatively high regressions between predicted and output values. In this study, exhaust gas temperatures were measured not only in the exhaust manifold but also throughout the whole engine exhaust system, from engine cylinder outputs to the turbocharger output. On this basis, ANN predictions showed highest regression values of all engine parameters in exhaust system temperature predictions. As an example, Fig. 6 shows exhaust gas temperature predictions at cylinder 1 (T_{16}), turbocharger 1 inlet (T_{22}) and turbocharger 1 outlet (T_{24}). On the other hand, exhaust gas emission predictions varied depending on the predicted emission parameter. NO , NO_x and CO_2 predictions showed relatively high regression values, while NO_2 and CO predictions were not that close to their target values.

In order to understand the accuracy level of the mentioned testing data predictions, 4 different parameter outputs are shown in Fig. 7: Instant fuel consumption, air pressure at engine inlet (P_{03}), Exhaust gas temperature in cylinder #1 (T_{16}) and NO_x emissions. The first 12 samples represented by circles correspond to testing data extracted from engine performance cubic functions, and the following 12 samples depicted as triangles correspond to random points through the engine performance map. Validation MSE and R values reached in Fig. 5 may lead to high accuracy levels for testing data. As expected, in samples of 25% and 75% loads extracted from cubic functions prediction outputs are close to their target values, which is logical since these operation points are close to those used for engine training and validation. Nevertheless, the samples extracted from random conditions also show relatively high accuracy levels.

The parameters that have the highest regression values (Fig. 6) do not necessarily have to be the most accurately predicted ones for all the testing samples. As an example, NO_x which showed lower R values than other parameters such as (P_{03}) or fuel consumption, presented good agreement between predicted and real values with the exception of some isolated sample predictions (see samples 21 and 22 in Fig. 7d). However, regression values in Fig. 6 may lead to conclude which parameters display a better overall prediction accuracy. For example, regression values of exhaust gas temperatures were very close to 1; this may induce relatively high accuracy levels for parameters such as exhaust gas

temperature in cylinder #1 (T_{16}) which was later seen as the most accurately predicted parameter in Fig. 7. Aiming to further analyse the regression capability of the ANN for the random sample predictions of each of the 35 parameters, an error analysis was conducted for the testing data predictions.

3.2. Error analysis

Many studies that include ANNs have separated their train/validation/test data automatically. This way, a portion of the database is randomly reserved for testing. In this study, some testing samples were extracted from the cubic functions which were used to train and validate the network, but additionally some other samples were extracted from random points in the engine performance map. The error analysis was thus carried out by comparing testing predictions on samples extracted from cubic functions and on samples extracted from random operation points. The aim of this study was to ascertain the regression capability of the ANN when predicting performance and emission parameters for unseen regions in the engine performance map. The error expression used for the analysis is Mean Absolute Percentage Error, which has been widely used in the existing engine ANN modelling literature [32,44,45]. This expression is calculated following equation (7) and represents the mean of the relative percentage error for a n number of predictions. In this study, two MAPE values were calculated for each parameter prediction, one for the 12 testing data samples extracted from engine performance cubic functions and the other one for the 12 testing data samples extracted from random points of the engine performance map.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{t_i - y_i}{t_i} \right| \quad (7)$$

where n is the number of predictions, which is 12 for both MAPE values calculated for each parameter, t_i is the target value of the sample i and y_i is the predicted output for that sample. Fig. 8 shows the results obtained from the error analysis for testing data.

For all parameters the error values reached for testing data extracted from random operation conditions are higher than those obtained for data extracted from cubic functions. MAPE values obtained for random operation conditions will therefore be analysed in greater depth. Regarding water systems, both low temperature and high temperature water parameters showed low error values. In the case of low temperature water, the highest error value reached was 4.22% for low temperature pressure at water cooler inlet (P_{02}). This was the MAPE value obtained for random condition testing samples. The rest of the

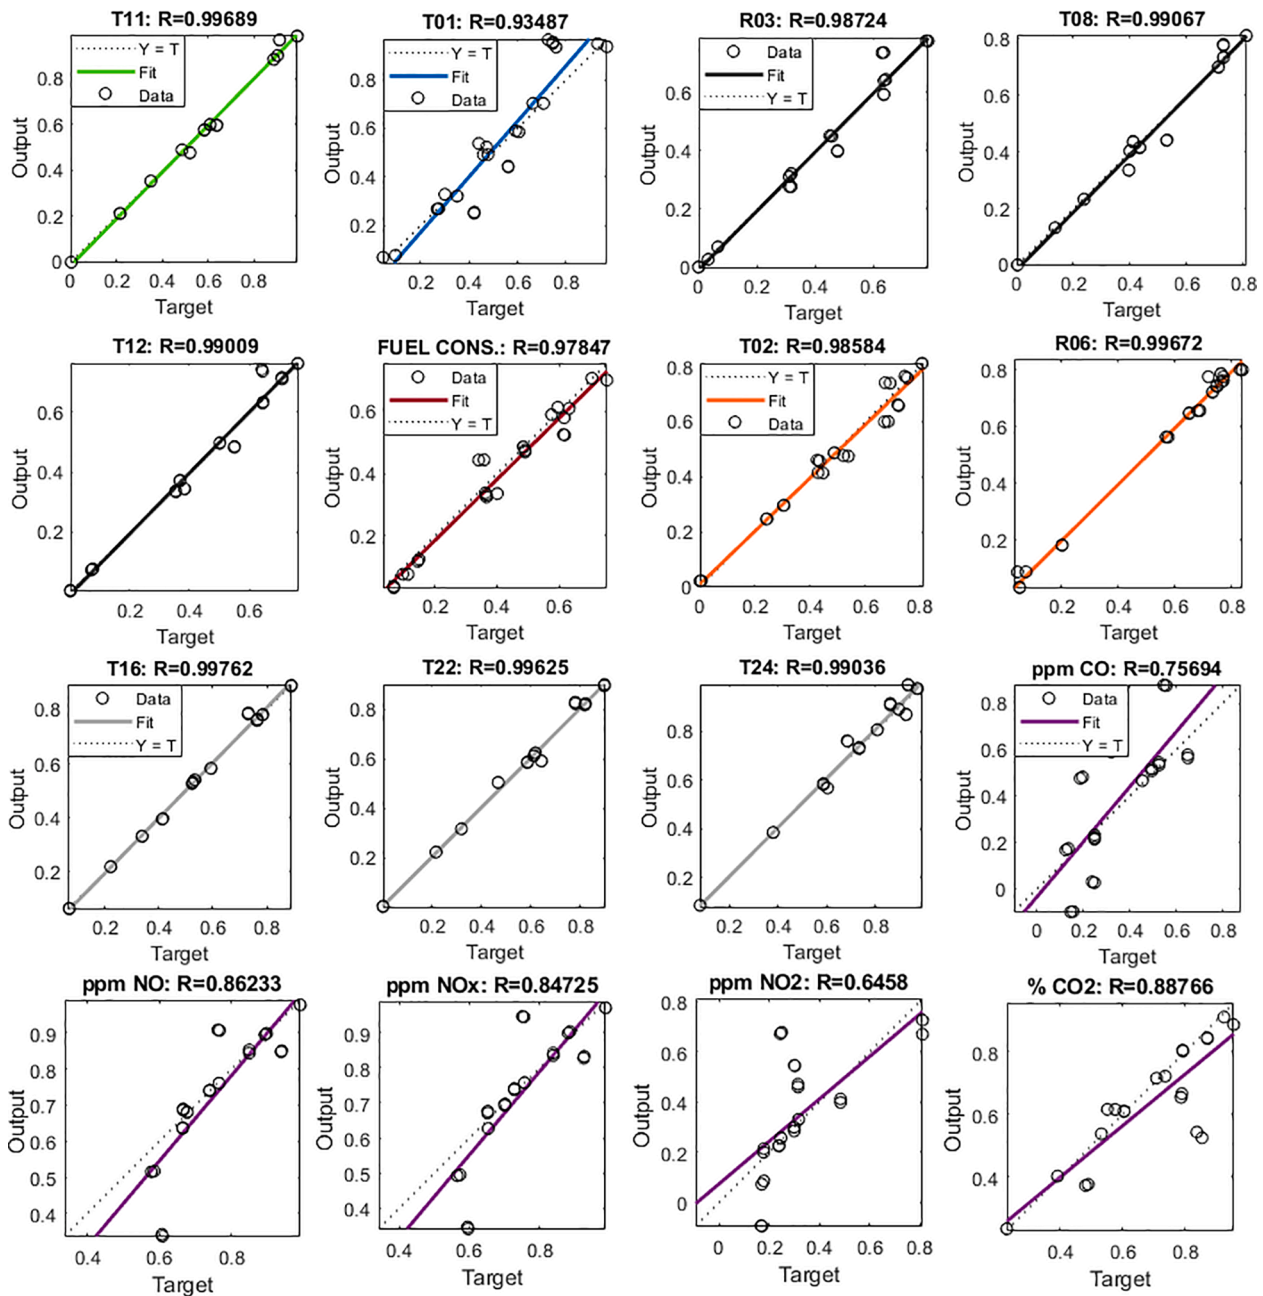



Fig. 6. Regression values for testing data prediction in 16 representative parameters.

parameters T₁₁, T₀₅ and T₁₃ remained with errors below 1.89% (seen in T₀₅) which induces a very accurate performance for these parameters, even for random region samples. Closer predictions are reached for high temperature water system which showed 0.28% and 1.29% values for random samples in T₀₁ and P₀₁ respectively being two of the most accurately predicted parameters of the whole engine. Oil temperature at engine outlet T₀₂ and P₀₆ showed a high accuracy level with 1.35% and 0.5% MAPE values respectively. Up to this point, parameter predictions showed high accuracy levels, which may mean a strong correlation between them and engine performance, even when random regions from engine performance map are evaluated. Their applications to condition based systems or further applications will be later analysed in the discussion section.


In the case of the engine air system, MAPE values obtained for random samples are much higher than in other engine parts such as cooling water or oil systems. Interestingly, pressure measurements

present three of the highest MAPE values in the air circuit, with 7.82%, 4.91% and 7.66% values for P₀₃, P₀₄ and P₀₅ respectively. This issue will be later examined in the discussion section. As for the engine fuel system, fuel pressure at engine inlet (P₀₇) and instant fuel consumption showed rather high MAPE values with 8.38% and 7.97% respectively. Remarkably, the fuel consumption error reached for testing data extracted from the engine cubic functions is also one of the highest in the whole engine (6.53%) obtained for cubic function samples, which will be later object of discussion.


MAPE values are especially low for exhaust gas temperatures, staying under 2.35% for every part of the exhaust gas system of the engine, showing a strong correlation with engine performance even in random region samples. Finally, exhaust gas emissions show different MAPE values depending on the parameter predicted. CO and NO₂ show undesirable predictions with 25.3% and 48.84% MAPE values respectively. On the other hand, 6.5%, 7.32% and 5.71% were reached for NO, NO_x




a. Fuel consumption



b. P03



c. T16



d. NOx

Fig. 7. Fuel consumption, P03, T16 and NOx emission predictions for testing data.




Fig. 8. MAPE values for different parameter predictions.

and CO₂ respectively, which are in the range of the other parameters predicted in the engine. Calculation time for the 24 testing samples containing 35 outputs was 0.109 s, which is relatively low considering the amount of variables simultaneously predicted.

4. Discussion

In this study, the generalization capability of ANNs was studied by predicting multiple outputs for unseen regions in the performance map of a marine diesel engine. To date, some authors have discussed the topic of an overfitted ANN model, resulting in poor prediction capability when data is different from training-validation data. As stated by Wong et al. [46] an ANN may present the drawback of tending to overfitting or show difficulties in establishing the optimum network structure. On the other hand, Niu et al. [47] compared the performance of ANN and SVM when predicting 5 different performance and emission parameters (e.g. BSFC, NO_x) and concluded that when being trained with small amounts of samples an ANN could face overfitting, resulting in unstable prediction accuracy. However, in this study the robustness of the ANN was studied by first training and validating the model with a 1000 sample database and then operating on data extracted from unseen regions of the engine performance map. Even if training time was high, once the network was trained the 24 testing samples were predicted within short calculation times. This is one of the main reasons for choosing these data driven methodologies, which in contrast to other physical modelling approaches offer high accuracy levels in much less time [48], and are an interesting option for real time modelling applications. Furthermore, with the measurement of few parameters such as engine torque, engine speed and ambient conditions the complete performance of the engine can be calculated, obtaining predictions of multiple parameters throughout the entire engine.

As seen in Fig. 8, results obtained from testing data extracted from engine cubic functions presented remarkably low errors, which is logical since these data were close to data used for network training and validation. However, the aim was not only to test the network with that testing data but also to include data from random operation regions of the engine performance map. On this basis, from the error analysis it can be concluded that for most of the predicted parameters, ANN gave relatively high accuracy levels. Some predicted parameters have been

more seen than others in existing literature. For instance, T_{exh} has been widely used as an output in many studies. The highest error reached in this study for the exhaust gas system was 2.35% for exhaust gas temperature in cylinder #6 (T₂₁), which is in the range of other studies, which contained much fewer outputs. Parlak et al. [21] predicted specific fuel consumption and exhaust gas temperature in a single cylinder diesel engine by using ANN, reaching 2.36% MAPE value for T_{exh} prediction. Likewise, Cay et al. [49] reached 3.14% MAPE value for T_{exh} prediction, however, one specific ANN was developed for each of the four outputs predicted. Exhaust gas temperatures thus proved to be a reliable source of deviation indicators, showing high accuracy even in random regions of the engine performance map. Besides, oil temperature and pressure were also predicted within relatively low errors, with 1.5% and 0.5% for T₀₂ and P₀₆ respectively. Porteiro et al. [50] developed a load prediction and engine state identification ANN model and discarded coolant and oil temperatures from input vector after several attempts, claiming they proved to be unnecessary. However, as seen by Khelil et al. [51] oil temperature and pressure may be good indicators for many different failures such as oil leaking or oil pump wearing. Therefore, accuracy ranges reached in the present study may be reliable enough for such applications in failure identification.

In contrast to parameters such as T_{exh} or BSFC, few cooling water variables have been included in ANN modelling studies. In some investigations they have been included in the input layer of the ANN [52,53]. Nevertheless, according to a recent study carried out by Yao et al. [54], parameters such as cooling water temperature or pressure have high correlation with cooling system faults in a marine diesel engine. This, along with the high accuracy levels reached in this study for both low and high temperature water systems, suggests that they may be effective for fault detection applications in engine cooling systems. As regards temperature and pressure parameters from engine intake air systems, what stands out from Fig. 8 is that three of the highest error levels correspond to pressure measurements in both compressors outlets (P₀₄, P₀₅) and in engine inlet (P₀₃). Closer inspection of these three parameters suggests that this relatively high error level may be caused by the small range in which these pressures changed during the engine tests. For instance, air pressure at engine inlet P₀₃ varied from 0.09 up to 1.63 bar (gauge pressure), which means that an error of 0.1 bar would induce an error of 5.81%. Therefore, apart from observing mean

absolute percentage errors, in these parameters absolute errors should be also analysed to see whether they may be caused by an incipient engine fault.

On the other hand, prediction accuracy for emission parameters varied according to each parameter. MAPE value for NO_x prediction was 7.32% which was in the range of other research works carried out in the engine modelling field. Tosun et al. [55] reached 9.63% error for NO_x prediction when comparing linear regression to ANN in a diesel engine fuelled with different biodiesel-alcohol mixtures. Noor et al. [32] reached 9.32% MAPE for NO_x prediction after comparing ANN and mathematical models to predict a marine diesel engine performance. NO and CO₂ were also in the same range of error level with 6.51% and 5.71% MAPE values respectively. For CO₂, relative error values reached in the existing literature are generally lower than in this study. For example, Roy et al. [34] reached 2.54% MAPE for CO₂ when predicting 5 different parameters (e.g. BSFC, PM) in a CRDI assisted single cylinder diesel engine. Arcaklioglu et al. [56] reached 3.05% MAPE when predicting CO₂ among 8 different performance and emission parameters (e.g. BMEP, Torque, SO₂). However, for each output one specific ANN was designed. In the present study, the MAPE values reached for CO₂ were slightly higher than in the above-mentioned contributions. Nevertheless, the number of outputs simultaneously predicted with a unique ANN is much bigger as well, proving the robustness of the model. Concerning NO₂ and CO, the error values reached in the present study did not provide a reliable source for predicting these two emission parameters. One of the reasons for reaching such large MAPE values for NO₂ may be that the concentration of NO₂ is relatively small in comparison to other predicted pollutant gases. To understand the magnitude of this parameter, NO₂ emissions ranged from 6.8 to 46.3 ppm in this present study, while NO ranged from 497 to 1143 ppm. Therefore, this parameter could be discarded for future diagnosis applications since it is part of the NO_x emissions and its relatively big errors may cause maladjustments in the diagnosis system. For CO, Iscan et al. [27] recently concluded that CO emissions were low when compared to other emission parameters, even when alternative fuels were introduced into the engine. This may be one of the reasons for CO presenting higher error rates than other emission parameters in some contributions [28,45] as well as in the present study. Furthermore, the experimental uncertainties shown in Table 2 for emission parameters such as CO (± 10 ppm), may also have induced higher prediction errors for these variables. Hence, this should also be considered when setting threshold values for future failure indicators. Aiming to enhance prediction capability of the ANN on emission parameters, additional inputs may be considered for the model. In this context, fuel injection timing and injection strategies are two factors that hold big correlation with engine emissions. Agarwal et al. [57] concluded that advanced injection timing decreased CO₂ and HC emissions while NO_x increased. How et al. [58] proved that multiple split injections could decrease NO_x and smoke emissions along with an adjusted injection timing when working with different biodiesel blends. Therefore, future emission prediction studies may analyse the effect of including injection timing as well as injection strategies in the input layer of their ANN. Finally, if fuel system predictions are observed, both fuel temperature (T₀₉) and pressure (P₀₇) predictions showed high error values. For engine trials, both engine power and engine speed were varied to test different cubic function points, however, fuel temperature and pressure did not significantly change while varying engine performance condition. This could imply a small correlation between these parameters and engine performance, which could have led to worse prediction performance. The relatively high error (7.97%) for fuel consumption seen in random sample prediction was not due to a small correlation with respect to engine performance. A closer look at Fig. 8 shows that error is also high for samples extracted from cubic functions, with 6.53% MAPE value. This leads to the conclusion that it was not a problem of ANN generalization capability on this parameter, but a problem of variability during measurement. All in all, the error range permits a close result of engine fuel consumption.

When observing threshold values set for faulty conditions in other studies, the conclusion is that most of the parameters predicted in the present study may be valuable for future fault detection systems. Basurko et al. [31] established threshold values between 5 and 8% for different faulty situations (e.g. dirty turbine, bad fuel injection). Rubio et al. [5] developed a marine diesel failure simulator by utilizing a commercial software for thermodynamic modelling of the engine. Among the faults induced in the model, misfiring was provoked by reducing fuel flow rate in 25% and 50%, which is much more than the error obtained for fuel flow rate in this study. Therefore, most of the parameters predicted in this study are under the range of the variations that may induce incipient faults. Furthermore, the accuracy level obtained for testing data extracted from random points of the engine performance map are remarkably high for most of the predicted parameters, proving the generalization capability of the ANN even if multiple output quantities are predicted all at once.

5. Conclusions

In the present study, the aim was to investigate the robustness of artificial neural networks when predicting multiple performance and emission parameters considering the whole performance map of a marine diesel engine. Hence, 35 performance and emission parameters were simultaneously predicted for different engine operating conditions throughout the whole performance spectrum of the engine. Firstly, optimum ANN structure was established, and the ANN was trained and validated with data extracted from engine trials. To do so, different engine performance cubic functions were tested by simulating real changing operation conditions in a six-cylinder marine diesel engine following the propeller curve. Additionally, some operation points located in random zones throughout the whole engine performance map were tested, to later analyse the regression capability of the ANN when predicting outputs on these points from unseen performance regions.

Prediction accuracy was proved to be relatively high for most of the predicted performance and emission parameters, even for unseen regions of the engine performance map, creating a model capable of predicting multiple outputs with a relatively low calculation time. From the present study, the following conclusions can be drawn:

- ANNs were able to predict 35 parameters in samples extracted from random points of the engine performance map within MAPE values below 8.5% with the exception of 2 parameters.
- Low temperature and high temperature water systems, oil system and exhaust gas systems showed the highest accuracy levels, being modelled with MAPE values below 4.3%. These low error levels highlight the great potential of Artificial Neural Networks for condition-based maintenance processes even when considering large amounts of parameters.
- Calculation time for the 24 testing samples containing 35 parameters was 0.109 s, which along with the high accuracy levels provides a reliable and fast tool for real time modelling applications. Moreover, a complete image of the engine condition is reached instantly so in case of deviations in certain predicted outputs it may be a good indicator for incipient failures.
- If trained with large enough data bases, ANN generalization capability is comparatively high even when performing in unseen regions of the engine performance map. Therefore, the reliability of the developed ANN methodology has been proved even when being tested in real changing performance conditions.

Artificial Neural Networks are thus a reliable modelling technique, offering low relative errors even in multiple output calculations. Future studies may implement this modelling technique for deviation identification and fault detection system developments. A further study could assess the applicability of this kind of system in real vessel operation conditions. As seen in this study, the generalization capability of the

ANN proved to be superior, even if different engine performance cubic functions were considered. ANN can be a good tool in marine engine performance modelling for condition monitoring purposes to increase operational safety in ships.

CRediT authorship contribution statement

Joseba Castresana: Conceptualization, Methodology, Software, Formal analysis, Writing – original draft. **Gorka Gabiña:** Software, Investigation, Resources, Writing – review & editing. **Leopoldo Martin:** Conceptualization, Validation, Resources. **Aingeru Basterretxea:** Methodology, Investigation, Data curation, Writing – review & editing. **Zigor Uriondo:** Conceptualization, Software, Formal analysis, Writing – review & editing.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgments

The work behind this study was funded by the Basque Government. J. Castresana received a grant from the Department of Economic Development and Infrastructures. The authors also want to thank the Department of Thermal Engineering and Nautical and Naval Machines of the University of the Basque Country. This paper is contribution no. 1093 of AZTI, Marine Research, Basque Research and Technology Alliance (BRTA).

Appendix A. Supplementary data

Supplementary data to this article can be found online at <https://doi.org/10.1016/j.fuel.2022.123873>.

References

- [1] Eurostat, International trade in goods by mode of transport, in; 2020.
- [2] Emsa EMSA. Learning from accidents through EMCIP (European Marine Casualty Information Platform). EMSA; 2018.
- [3] Arunraj N, Maiti J. Risk-based maintenance—techniques and applications. *J Hazard Mater* 2007;142:653–61.
- [4] Sujesh G, Ramesh S. Modeling and control of diesel engines: a systematic review. *Alexandria Eng J* 2018;57(4):4033–48.
- [5] Rubio JAP, Vera-García F, Grau JH, Cámara JM, Hernández DA. Marine diesel engine failure simulator based on thermodynamic model. *Appl Therm Eng* 2018;144:982–95.
- [6] Vera-García F, Pagán Rubio JA, Hernández Grau J, Albaladejo Hernández D. Improvements of a failure database for marine diesel engines using the RCM and simulations. *Energies* 2020;13:104.
- [7] Yang J-G, Zhang X-M, Wang H-F. Fault simulation for the marine intelligent diesel engine. *Ship Ocean Eng* 2008;3.
- [8] Pham VV, Le VV. A modelling technique of the intake and exhaust systems of a medium speed marine diesel engine, in: AIP Conference Proceedings, Vol. 2207, AIP Publishing LLC, 2020, pp. 030003.
- [9] Altosole M, Campora U, Figari M, Laviola M, Martelli M. A diesel engine modelling approach for ship propulsion real-time simulators. *J Marine Sci Eng* 2019;7:138.
- [10] Theotokatos G, Stoumpos S, Bolbot V, Boulougouris E. Simulation-based investigation of a marine dual-fuel engine. *J Marine Eng Technol* 2020;19:5–16.
- [11] Albrecht A, Grondin O, Le Berr F, Le Sollic G. Towards a stronger simulation support for engine control design: a methodological point of view. *Oil Gas Sci Technol-Revue de l'IFP* 2007;62(4):437–56.
- [12] Baldi F, Theotokatos G, Andersson K. Development of a combined mean value-zero dimensional model and application for a large marine four-stroke Diesel engine simulation. *Appl Energy* 2015;154:402–15.
- [13] Mahesh B. Machine learning algorithms-a review. *Int J Sci Res (IJSR)* 2020;9:381–6.
- [14] Alonso JM, Alvarruiz F, Desantes JM, Hernandez L, Hernandez V, Molt G. Combining neural networks and genetic algorithms to predict and reduce diesel engine emissions. *IEEE Trans Evol Comput* 2007;11(1):46–55.
- [15] Lazakis I, Gkerekos C, Theotokatos G. Investigating an SVM-driven, one-class approach to estimating ship systems condition. *Ships Offshore Struct* 2019;14(5):432–41.
- [16] Wang S, Wang J, Ding X. An intelligent fault diagnosis scheme based on PCA-BP neural network for the marine diesel engine. In: IOP Conference Series: Materials Science and Engineering, Vol. 782. IOP Publishing; 2020. p. 032079.
- [17] Yao X, Liu Y. Machine learning. In: Burke EK, Kendall G, editors. Search methodologies. Boston, MA: Springer US; 2014. p. 477–517.
- [18] Srihari PV, Govindarajulu K, Ramachandra K. A method to improve reliability of gearbox fault detection with artificial neural networks. *Int J Autom Mech Eng* 2010;2:221–30.
- [19] Mofleh AF, Shmroukh AN, Ghazaly NM. Fault detection and classification of spark ignition engine based on acoustic signals and artificial neural network. *Int J Mech Product Eng Res Develop* 2020;10:5571–8.
- [20] Liu B, Zhao C, Zhang F, Cui T, Su J. Misfire detection of a turbocharged diesel engine by using artificial neural networks. *Appl Therm Eng* 2013;55(1-2):26–32.
- [21] Parlak A, Islamoglu Y, Yasar H, Egrisoğut A. Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a diesel engine. *Appl Therm Eng* 2006;26(8-9):824–8.
- [22] Aydın M, Uslu S, Çelik MB. Performance and emission prediction of a compression ignition engine fueled with biodiesel-diesel blends: a combined application of ANN and RSM based optimization. *Fuel* 2020;269.
- [23] Castresana J, Gabiña G, Martin L, Uriondo Z. Comparative performance and emissions assessments of a single-cylinder diesel engine using artificial neural network and thermodynamic simulation. *Appl Therm Eng* 2021;185:116343.
- [24] Maind SB, Wankar P. Research paper on basic of artificial neural network. *Int J Recent Innov Trends Comp Commun* 2014;2:96–100.
- [25] Madane P, Panua R. Investigation of performance of jatropha oil on diesel engine using artificial neural network model. *Int J Comput Intelligence & IoT* 2019;2.
- [26] Ghoobadian B, Rahimi H, Nikbakht A, Najafi G, Yusaf T. Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network. *Renewable Energy* 2009;34:976–82.
- [27] Işcan B. ANN modeling for justification of thermodynamic analysis of experimental applications on combustion parameters of a diesel engine using diesel and safflower biodiesel fuels. *Fuel* 2020;279:118391.
- [28] Ağbulut Ü, Ayyıldız M, Sarıdemir S. Prediction of performance, combustion and emission characteristics for a dual fuel diesel engine at varying injection pressures. *Energy* 2020. 117257.
- [29] Shailaja M, Raju ASR. Neural Network—Based Diesel Engine Emissions Prediction for Variable Injection Timing, Injection Pressure, Compression Ratio and Load Conditions, in: Emerging Trends in Electrical, Communications and Information Technologies, Springer, 2017, pp. 109–122.
- [30] Taghavifar H, Taghavifar H, Mardani A, Mohebbi A, Khalilarya S, Jafarmadar S. Appraisal of artificial neural networks to the emission analysis and prediction of CO₂, soot, and NO_x of n-heptane fueled engine. *J Cleaner Prod* 2016;112:1729–39.
- [31] Basurko OC, Uriondo Z. Condition-based maintenance for medium speed diesel engines used in vessels in operation. *Appl Therm Eng* 2015;80:404–12.
- [32] Noor CWM, Mamat R, Ahmed AN. Comparative study of artificial neural network and mathematical model on marine diesel engine performance prediction. *Int J Innov Comp Inf Control* 2018;14(3):959–69.
- [33] Javed S, Murthy YS, Baig RU, Rao DP. Development of ANN model for prediction of performance and emission characteristics of hydrogen dual fueled diesel engine with Jatropha Methyl Ester biodiesel blends. *J Nat Gas Sci Eng* 2015;26:549–57.
- [34] Roy S, Banerjee R, Bose PK. Performance and exhaust emissions prediction of a CRDI assisted single cylinder diesel engine coupled with EGR using artificial neural network. *Appl Energy* 2014;119:330–40.
- [35] M.N. CW, M.Y. MH, I. CK, N. MM. Prediction of marine diesel engine performance by using artificial neural network model; 2016.
- [36] Perera LP, Mo B. Data analysis on marine engine operating regions in relation to ship navigation. *Ocean Eng* 2016;128:163–72.
- [37] Guo C-Y, Zhong X-H, Zhao D-G, Wang C, Lin J-F, Song K-W. Propulsion performance of large-scale ship model in real sea environment. *Ocean Eng* 2020;210:107440.
- [38] I.O.f.S. ISO, ISO 14726:2008 Ships and marine technology — Identification colours for the content of piping systems, in, 2008.
- [39] Theotokatos G, Tzelepis V. A computational study on the performance and emission parameters mapping of a ship propulsion system. *Proc Instit Mech Eng, Part M: J Eng Maritime Environ* 2015;229:58–76.
- [40] MARPOL, Annex VI – Regulations for the Prevention of Air Pollution from Ships, in: Appendix II – Test cycles and weighting factors (Regulation 13), 2005.
- [41] I.O.f.S. ISO, ISO 8178-1:2020 - Reciprocating internal combustion engines - Exhaust emission measurement in: Part 1: Test-bed measurement systems of gaseous and particulate emissions, 2020.
- [42] Rezaei J, Shahbakhti M, Bahri B, Aziz AA. Performance prediction of HCCI engines with oxygenated fuels using artificial neural networks. *Appl Energy* 2015;138:460–73.
- [43] Yang F, Cho H, Zhang H, Zhang J, Wu Y. Artificial neural network (ANN) based prediction and optimization of an organic Rankine cycle (ORC) for diesel engine waste heat recovery. *Energy Convers Manage* 2018;164:15–26.
- [44] Roy S, Banerjee R, Das AK, Bose PK. Development of an ANN based system identification tool to estimate the performance-emission characteristics of a CRDI assisted CNG dual fuel diesel engine. *J Nat Gas Sci Eng* 2014;21:147–58.
- [45] Canakci M, Ozsezen AN, Arcaklioglu E, Erdil A. Prediction of performance and exhaust emissions of a diesel engine fueled with biodiesel produced from waste frying palm oil. *Expert Syst Appl* 2009;36:9268–80.
- [46] Wong KI, Wong PK, Cheung CS, Vong CM. Modelling of diesel engine performance using advanced machine learning methods under scarce and exponential data set. *Appl Soft Comput* 2013;13:4428–41.

- [47] Niu X, Yang C, Wang H, Wang Y. Investigation of ANN and SVM based on limited samples for performance and emissions prediction of a CRDI-assisted marine diesel engine. *Appl Therm Eng* 2017;111:1353–64.
- [48] Rida A, Nahim HM, Younes R, Shraim H, Ouladsine M. Modeling and simulation of the thermodynamic cycle of the Diesel Engine using Neural Networks. *IFAC-PapersOnLine* 2016;49:221–6.
- [49] Cay Y, Çiçek A, Kara F, Sağiroğlu S. Prediction of engine performance for an alternative fuel using artificial neural network. *Appl Therm Eng* 2012;37:217–25.
- [50] Porteiro J, Collazo J, Patiño D, Míguez JL. Diesel engine condition monitoring using a multi-net neural network system with nonintrusive sensors. *Appl Therm Eng* 2011;31:4097–105.
- [51] Khelil Y, Graton G, Djeziri M, Ouladsine M, Outbib R. Fault detection and isolation in marine diesel engines: a generic methodology. *IFAC Proc Volumes* 2012;45(20): 964–9.
- [52] Cay Y. Prediction of a gasoline engine performance with artificial neural network. *Fuel* 2013;111:324–31.
- [53] Çelik V, Arcaklıoğlu E. Performance maps of a diesel engine. *Appl Energy* 2005;81: 247–59.
- [54] Yao Q, Liu Y, Guo C, Ao C, Guan T, Xu Z. Research on fault warning of marine diesel engine cooling system based on Deep Belief Network, in: *Journal of Physics: Conference Series*, Vol. 1750, IOP Publishing, 2021, pp. 012066.
- [55] Tosun E, Aydın K, Bilgili M. Comparison of linear regression and artificial neural network model of a diesel engine fueled with biodiesel-alcohol mixtures. *Alexandria Eng J* 2016;55:3081–9.
- [56] Arcaklıoğlu E, Çelikten İ. A diesel engine's performance and exhaust emissions. *Appl Energy* 2005;80:11–22.
- [57] Agarwal AK, Srivastava DK, Dhar A, Maurya RK, Shukla PC, Singh AP. Effect of fuel injection timing and pressure on combustion, emissions and performance characteristics of a single cylinder diesel engine. *Fuel* 2013;111:374–83.
- [58] How HG, Masjuki HH, Kalam M, Teoh YH. Influence of injection timing and split injection strategies on performance, emissions, and combustion characteristics of diesel engine fueled with biodiesel blended fuels. *Fuel* 2018;213:106–14.

1 Healthy Marine Diesel Engine
2 Threshold Characterization with
3 Probability Density Functions and
4 ANN

5
6 Joseba Castresana^{a*}, Gorka Gabiña^a, Iñaki Quincoces^a, Zigor Uriondo^b

7 ^a AZTI, Marine Research, Basque Research and Technology Alliance (BRTA) - Txatxarramendi ugartea 0-48395,
8 Sukarrieta

9 ^bDeapartment of Thermal Engineering, University of the Basque Country UPV/EHU, Alameda Urquijo s/n 48013
10 Bilbao, Spain

11
12
13
14
15
16
17
18
19
20
21
22 ***Corresponding author:** Joseba Castresana Larrauri

23 Phone: +34 667183668

24 Email: jcastresana@azti.es

25
26 Email addresses: ggabina@azti.es; iquincoes@azti.es; zigor.uriondo@ehu.eus

27

28 ABSTRACT

29

30 Condition-based maintenance of marine propulsion systems has increasingly become a focus of
31 interest in safety-related and financial terms. Many research papers have studied different
32 marine diesel engine modelling and fault identification techniques. However, the thresholds
33 between a healthy engine and a faulty one have not been deeply analysed. This contribution
34 thus aimed to determine healthy engine threshold values for multiple parameters of a marine
35 diesel engine. For that, an operative commercial fishing vessel was considered, measuring
36 multiple engine performance variables through 2020 and the first half of 2021, totalling 5181
37 operating hours of the main engine without any fault occurrence. Preliminary correlation and
38 relative deviation studies suggested analysing some constant trend parameters with alternative
39 modelling techniques. Hence, Probability density functions (PDF) were used, establishing
40 confidence intervals for such parameters with data from the whole year of 2020. The highest
41 correlation and deviation parameters were alternatively modelled using artificial neural
42 networks (ANN). Four different ANNs were thus trained, validated and tested with data from
43 2020, calculating mean absolute percentage errors for all predicted parameters. Finally, data
44 from 2021 was used to validate both PDF modelled and ANN modelled parameter thresholds
45 set in 2020. For the 2021 data, confidence intervals set with PDF showed a maximum failure rate
46 of 1.21%. Alternatively, ANN modelled parameters showed maximum percentage errors of 1.1%,
47 1.22% and 1.95% for engine performance, cooling and cylinder subsystems respectively. Finally,
48 all obtained thresholds were summarized, providing a good source to establish faulty engine
49 threshold values in future fault detection studies.

50

51 Keywords

- 52 • Artificial neural networks
- 53 • Probability density functions
- 54 • Diesel engine modelling
- 55 • Ship propulsion characterization
- 56 • Threshold characterization
- 57 • Onboard model validation

58

59

60 Highlights

- 61 • Threshold values for multiple engine subsystem parameters were characterized.
- 62 • 5181 hours of healthy engine operation were analysed.
- 63 • Healthy engine threshold values were defined and validated with data from 2020 and
64 2021.
- 65 • Probability Density Function modelled thresholds showed 1.21% maximum failure rate
- 66 • Performance, cooling and cylinder subsystem ANN prediction errors were under 1.1%,
67 1.22% and 1.95% respectively.

68

<i>Acronyms</i>		<i>Parameters</i>	
ANN	Artificial neural network	FOP	Fuel oil pressure
BSFC	Brake specific fuel consumption	T_{FO}^{in}	Fuel oil temperature in engine inlet
BTE	Brake thermal efficiency	T_{FO}^{out}	Fuel oil temperature in engine outlet
CBM	Condition-based maintenance	P_{LO}	Lubricating oil pressure
CO	Carbon monoxide	P_{LO}^{filter}	Lubricating oil pressure at filter inlet
CO₂	Carbon dioxide	dP_{LO}^{filter}	Lubricating oil filter differential pressure
CRDI	Common rail direct injection	T_{LO}	Lubricating oil temperature
EGR	Exhaust gas recirculation	P_{LO}^{TCin}	Lubricating oil pressure at turbocharger inlet
EU	European Union	T_{LO}^{TCout}	Lubricating oil temperature at turbocharger outlet
HC	Hydrocarbons	P_{HTCW}	High-temperature cooling water pressure
IMEP	Indicated mean effective pressure	P_{LTCW}^{CACin}	Low-temperature cooling water temperature in air cooler inlet
MAPE	Mean absolute percentage error	T_{JCW}^{in}	Jacket cooling water inlet temperature
MSE	Mean squared error	T_{JCW}^{out}	Jacket cooling water outlet temperature
NO_x	Nitrogen oxides	T_{HTCW}^{CACout}	High-temperature cooling water temperature in air cooler outlet
PCA	Principal component analysis	T_{LTCW}^{CACin}	Low-temperature cooling water in air cooler inlet
PDF	Probability density function	T_{LTCW}^{LOCout}	Low-temperature cooling water in lubricating oil cooler outlet
R	Regression coefficient	$T_{exh}^{C01-C09}$	1-9 cylinder exhaust gas temperature
RSD	Relative standard deviation	T_{EXH}^{Avg}	Average exhaust gas temperature
RSS	Residual sum of squares	T_{EXH}^{TCin}	Exhaust gas temperature at turbocharger inlet
T_{exh}	Exhaust gas temperature	T_{EXH}^{TCout}	Exhaust gas temperature at turbocharger outlet
		RPM^{TC}	Turbocharger angular speed
		T_{AIR}^{CYLin}	Cylinder inlet air temperature
		T_{COJ}^{00-10}	0-10 bearing temperature
		T_{CR}^{01-09}	1-9 crankshaft temperature
		T_{CYL}^{01-09}	1-9 cylinder temperature
		FORACK	Fuel oil pump rack
		dTFO	Fuel oil differential temperature

1- INTRODUCTION

71

72

73 Marine transport was the most used mean of goods transport in the European Union in 2020,
74 followed by air and road carriage [1]. Since 2002 sea transport has maintained the same levels
75 of exportation and higher levels of importation in the EU and is still the most important mean of
76 goods transport in the region. According to a recent survey (2015-2017) carried out by Swedish
77 Club insurance company, 28% of the machinery claims of their fleet were due to main engine
78 issues. The average cost of main engine issues meanwhile had increased by 21% since their
79 previous survey (2010-2014) [2]. In this context, maintenance strategies such as condition-based
80 maintenance or risk-based maintenance could help reduce the costs of such engine-related
81 issues. As stated by Basurko and Uriondo [3], introducing the use of suitable CBM to a ship could
82 extend the time between engine overhauls from two to three years in some cases, also leading
83 to potential fuel savings of 2%. CBM has therefore proved to be essential in terms of both ship
84 safety and financial aspects.

85 One of the most well-known methods for assessing CBM is to develop an accurate engine model
86 to subsequently compare real and modelled engine parameter values and perceive incipient
87 faults based on model deviations. In the last decade there have been many different approaches
88 for engine modelling and optimization [4]. On this basis, the use of thermodynamic and
89 conservation equations is a well-established methodology in diesel engine modelling studies [5-
90 7]. Most recent studies hence show a clear trend towards using different software to accomplish
91 these simulation calculations [8-10]. However, as stated by Altosole et al. [11], these kind of
92 thermodynamic models which represent in-cylinder phenomena may require relatively high
93 calculation times, presenting an important drawback for real time applications. Furthermore,
94 they require a lot of data and parameters that are not always available in real operation
95 conditions on board a ship.

96 With the aim of responding to the need for high accuracy levels within short calculation times,
97 alternative data-driven methodologies have gained interest in the last two decades. In the field
98 of marine engines, many different machine learning algorithms have been developed with
99 different modelling purposes. Lazakis et al. [12] used Support Vector Machine to identify
100 incipient failures in a marine diesel engine. They trained the model with healthy engine data to
101 later identify incipient engine failures based on deviations between modelled and real
102 parameter values. Kowalski et al. [13] employed different Extreme Learning Machines to make
103 classifications of 15 different faulty engine conditions (e.g. air inlet valve leakage, decreased fuel
104 injector opening pressure) by measuring engine emissions and exhaust gas temperatures.
105 Alternatively, Zhang et al. [14] used PCA to reduce the dimensionality of eight factors that
106 affected engine faults (e.g. reduced fuel supply, needle valve leakage) to three principal
107 components. These principal components were consequently used as inputs in a Radial Basis
108 Function ANN to classify among the different faulty situations, reducing training time and
109 increasing training accuracy.

110 As stated by Sujesh and Ramesh [15], artificial neural networks can determine engine
111 performance and emission parameters by performing only a limited number of tests, providing
112 a time and cost saving alternative to detailed experimental studies. Furthermore, in the late
113 1990s they were already defined to fit complex nonlinear models without having to define them
114 in advance [16], which generated increased interest in many fields of study in the following
115 decades, including diesel engine modelling research works. Some authors have used this tool

116 with regression purposes, predicting engine performance parameters and later discussing
117 prediction accuracy levels. Castresana et al. [17] predicted exhaust gas temperature, brake
118 specific fuel consumption, NO_x and CO emissions using both ANN and thermodynamic modelling
119 techniques. They concluded that ANN was much faster than the thermodynamic modelling while
120 maintaining the same accuracy level in the output predictions. Likewise, Roy et al. [18] predicted
121 BSFC, BTE, CO₂, NO_x and soot in a CRDI engine with variable EGR levels. Among the results, MAPE
122 values under 4.57% were obtained for the predictions, concluding that ANN was an effective
123 forecasting tool which can be employed to emulate engine performance. Concerning higher
124 output dimensions, Basurko and Uriondo [3] predicted 15 different engine parameters (e.g.
125 Boost Pressure, T_{exh}, fuel consumption) by using ANN in an 8-cylinder medium-speed marine
126 diesel engine. They later used the developed model to identify multiple incipient faults such as
127 dirty air filter or bad fuel injection in the engine by observing deviations between the ANN model
128 and measured values. Most recently, Castresana et al. [19] developed an ANN model which
129 predicted 35 different performance and emission parameters all at once in the whole
130 performance map of the engine. As they concluded, the model was able to predict the 35
131 parameters simultaneously in less than a second, showing a complete image of the engine
132 condition. The predictions were carried out in the whole performance map of the engine,
133 proving great generalization capability of ANN for variable conditions.

134 Apart from regression and parameter prediction applications, ANN have been also employed to
135 directly classify among different engine faulty conditions. Liu et al. [20] classified misfire
136 operation in a 6-cylinder diesel engine by including 7 different performance parameters as ANN
137 inputs (e.g. engine speed, exhaust temperature, fuel consumption). They concluded that
138 including in-cylinder speed variations enhanced misfire detection capability of the ANN. Srihari
139 et al. [21] identified worn-out gear cases and cracked tooth cases by employing a multilayer feed
140 forward ANN. Mofleh et al. [22] also developed a fault detection system in a four-cylinder spark
141 ignition engine by using acoustic signals. They classified among healthy engine, 1-cylinder misfire
142 and 2-cylinder misfire conditions. Alternatively, some authors have used ANN with engine
143 optimization purposes. Alonso et al. [23] predicted engine fuel consumption and emission
144 parameters with ANN and reached up to 36% reduction for HC emissions and 3 to 6% reductions
145 for fuel consumption. Yang et al. [24] optimized an Organic Rankine Cycle to maximize expander
146 power and optimize waste heat recovery. The methodology proposed included an optimization
147 of ANN hyperparameters such as learning rate or training functions to provide highest accuracy
148 levels.

149 Up to the present, many research papers have employed both thermodynamic and machine
150 learning modelling approaches to conduct CBM in marine diesel engines. Nevertheless, few
151 studies have justified the selection of the input/output parameters for their models. Porteiro et
152 al. [25] employed trial and error and discarded lubricating oil temperature and coolant
153 temperature from the input vector of their neural network model after making several attempts.
154 Roy et al. [18] calculated Pearson correlation coefficient to ascertain the relations between pairs
155 of parameters. More recently, Jafari et al. [26] combined correlation matrix, PCA and hierarchical
156 clustering to ascertain the correlations between parameters from different groups of a six-
157 cylinder marine diesel engine. In fact, some parameters may be designed to be constant (e.g. oil
158 temperature of the engine being regulated by a thermostatic valve) so ANN may not be the best
159 modelling technique for such parameters. In this study, 61 parameters were measured during
160 2020 and 2021 in a commercial fishing vessel. Before modelling the engine parameters with
161 ANN, the correlation and relative deviations of the parameters were analysed, proposing an

162 alternative method which includes probability density functions for those parameters with
163 lowest correlation and deviations.

164 Furthermore, although modelling methodologies are extensively explained and studied in the
165 existing literature, there has been little quantitative analysis of the threshold values set for
166 different faulty engine situations. Khelil et al. [27] defined faulty situation thresholds by taking
167 maximum positive and negative residual values of the ANN predictions during the training
168 phase. However, the model may present high residual values not because of a faulty situation
169 of the engine but because of a bad performance of the model in certain conditions. On the other
170 hand, some authors have more recently set threshold values in reduced dimension models,
171 which makes it difficult to understand what parameter was deviated and which was the
172 deviation range of such parameter when facing a faulty situation [28]. In some contributions,
173 threshold values may be found for some specific parameters, however, their source remains
174 unclear, not knowing whether they are provided by engine manufacturers or other sources of
175 information [29]. It is necessary to point out that practically all the studies mentioned in this
176 introduction have been carried out in test bench under laboratory conditions, not facing the
177 difficulties of real operating condition stresses. The main objective of the present study is
178 therefore to provide a set of threshold values for multiple parameters of a main engine of a
179 commercial fishing vessel in real operating conditions, calculated with data from a whole
180 operating year and validated with data from the next operating year of the vessel, totalling 5181
181 operating hours without any fault occurrence.

182 For that purpose, 61 different engine variables were measured in 2020 and 2021 in a real
183 operating vessel. Correlation and variability studies were then conducted with data from 2020,
184 and two different modelling strategies were proposed depending on the correlation and
185 variability of each variable. High correlation and variable values were modelled using ANN and
186 the modelled errors were then studied to set threshold values for healthy engine operation. On
187 the other hand, low correlation and constant values were studied with probability density
188 functions (PDF), finding optimum PDF for each parameter among 94 different distributions and
189 then calculating confidence intervals for each variable to ascertain their threshold values.
190 Finally, all the defined healthy engine threshold values were validated with engine data acquired
191 in 2021, taking multiple samples throughout the first half of this year to test proposed
192 thresholds.

193

194

195

196

197

198

199

200

201

202 **2- MATERIALS AND METHODS**

203 **2.1 Data acquisition in operative vessel**

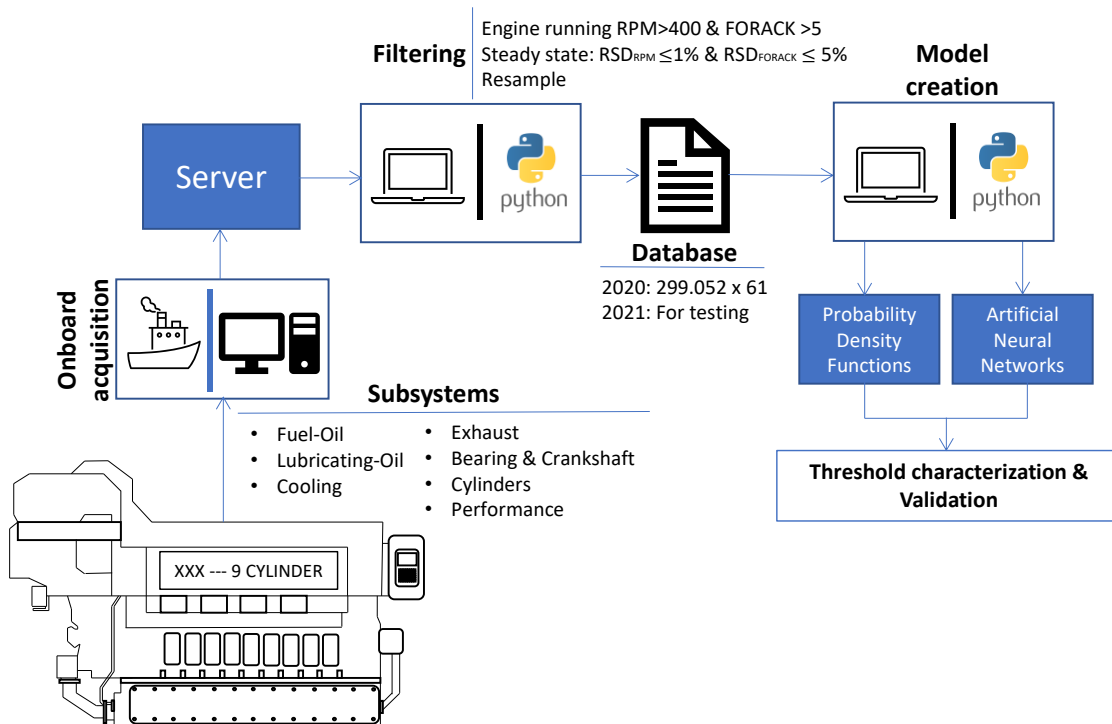
204 In the present study, the operation of the main engine of a commercial fishing vessel was
 205 measured during 2020 and the first half of 2021. The name and specific characteristics of the
 206 vessel’s engine will remain confidential to conceal the ship’s owner. Without loss of generality,
 207 indicative values will therefore be given for engine characteristics. The engine used in this vessel
 208 is a medium speed nine-cylinder diesel engine. This engine has a single turbocharger and is
 209 cooled with sea water. Its characteristics are shown in table 1.

210 *Table 1 Vessel main engine characteristics*

Parameter	Value	Unit
Type of cycle	4 stroke medium speed	[-]
N cylinders	9	[-]
Nominal speed	750	Rpm
Nominal power	4500	kW
Bore	320	mm
Stroke	460	mm
Air charge	Turbocharged	[-]

211

212 For engine parameter acquisition, 61 parameters were measured with a 10 second period
 213 between samples in 2020 and 2021. Data from 2020 was pre-processed and filtered to set the
 214 threshold values using different modelling techniques; data from 2021 was then used to validate
 215 the calculated thresholds. The scheme of the acquisition system is shown in Figure 1. Measured
 216 parameters and their sensors are likewise listed in Table 2. As measured parameter dimension
 217 is relatively high, variables have been grouped in different engine subsystems.



218

219

Figure 1 Data acquisition scheme

Table 2 Data acquisition instruments and uncertainties

Subsystem	ID	Unit	Instrument	Uncertainty
Fuel - Oil	FOP	[bar]	Pressure transmitter SEN 9601 B075	±0.5%
	T_{FO}^{in}	[°C]	Pt100 temperature sensor	± 0.3 °C
	T_{FO}^{out}	[°C]		
Lubricating - Oil	P_{LO}	[bar]	Pressure transmitter SEN 9601 B075	±0.5%
	P_{LO}^{filter}	[bar]		
	dP_{LO}^{filter}	[bar]		
	T_{LO}	[°C]	Pt100 temperature sensor	± 0.3 °C
	P_{LO}^{TCin}	[°C]		
	T_{LO}^{TCout}	[°C]		
Cooling	P_{HTCW}	[bar]	Pressure transmitter SEN 9601	±0.5%
	T_{JCW}^{in}	[°C]	K Type Thermocouple	± 4%
	T_{JCW}^{out}	[°C]		
	T_{HTCW}^{CACout}	[°C]		
	T_{LTCW}^{CACin}	[°C]		
	T_{LTCW}^{LOCout}	[°C]		
Air & Exhaust system	$T_{exh}^{C01-C09}$	[°C]	K Type Thermocouple	± 4%
	T_{EXH}^{Avg}	[°C]		
	T_{EXH}^{TCin}	[°C]		
	T_{EXH}^{TCout}	[°C]		
	T_{AIR}^{CYLin}	[°C]		
Bearing & Crankshaft	T_{COJ}^{00-10}	[°C]	K Type Thermocouple	± 4%
	T_{CR}^{01-09}	[°C]		
Cylinder	T_{CYL}^{01-09}	[°C]	K Type Thermocouple	± 4%
Engine Performance	Engine Speed	[Rpm]	Kistler encoder Type 2614B	±0.05%
	Relative Load	[%]	Kistler 4502A50RA 4-20 mA	<0.07%
	FORACK	[-]	Potentiometer	± 3%
	RPM ^{TC}	[Rpm]	Kistler encoder Type 2614B	±0.05%

221

222 Due to real engine operation, the acquisition system failed sporadically, whereby there are some
 223 empty samples in the original database. Furthermore, engine transients did sometimes show
 224 outliers, which may lead to increased modelling errors. Three different criteria were therefore
 225 used to filter and resample the data and reach the final version of the database which was later
 226 introduced to the models: i) engine running operation ii) engine steady state operation iii)
 227 database final resample.

228 Concerning engine running operation, two key parameters were selected to carry out the first
 229 filtering step of the database: engine speed and FORACK (Fuel Oil Rack). For the first parameter
 230 the minimum value was set at 400 rpm, since in this kind of medium-speed diesel engines lower
 231 engine speeds are rarely seen during engine running operations. The second parameter
 232 indirectly represents the quantity of fuel injected by the fuel pump in each engine stroke, being
 233 a direct indicator of engine fuel consumption due to the high correlation between both

234 parameters. This parameter's minimum value was set at 5 [-]. The second criteria for the filtering
 235 process aimed to ensure the steady state of engine operation. For that purpose, the relative
 236 standard deviation for the previous three minutes of each sample was calculated and limit
 237 values were set for RSD in the engine speed and FORACK parameters. Equation 1 shows the
 238 expression used for RSD calculation with standard deviations and moving averages calculated
 239 for the previous 3 minutes of each sample. Note that this expression is multiplied by 100 to
 240 represent percentage values.

241

$$RSD_{3min} = \frac{Sd_{3min}}{\bar{x}_{3min}} * 100 = \frac{\sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x}_{3min})^2}{n-1}}}{\bar{x}_{3min}} * 100 \quad (1)$$

242

243 Where Sd is the standard deviation of the last three minutes containing each sample, \bar{x}_{3min} is
 244 the moving average calculated for those 3 minutes, x_i represents i^{th} sample observation and n
 245 is the number of samples of the 3 minutes considered prior to each sample. Therefore, RSD_{RPM}
 246 $\leq 1\%$ and $RSD_{FORACK} \leq 5\%$ were set as limit values to ensure that each sample was in steady state
 247 of the engine. Finally, one minute resample was conducted to reach the final homogeneous
 248 database used for posterior correlation and deviation studies and modelling approaches. This
 249 data contained 299,052 samples of 61 variables in year 2020.


250 2.2 Correlation and variability study

251 The great amount of engine parameters measured and modelled in the present study led to the
 252 conducting of a prior correlation and variability study to understand the interactions of engine
 253 variables. Up to the present, few studies have focused on input/output selection criteria for their
 254 models. Two different parameters were therefore selected to decide the modelling strategy for
 255 each parameter: relative deviation and correlation coefficient. First, the relative standard
 256 deviation of each parameter through the whole year of 2020 was calculated by applying
 257 equation 1. The correlation matrix was consequently calculated by computing the Pearson
 258 correlation coefficient between all possible pairs of parameters for 2020. Finally, the mean
 259 correlation coefficient of each parameter with respect to the rest of the variables was calculated
 260 according to equation 2 to understand the correlation level of each parameter.

261

$$\bar{r} = \frac{1}{m} \sum_{j=1}^{m-1} \left| \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \right| \quad (2)$$

262 Where x and y are the parameters for which the correlation coefficient is calculated. \bar{x} and \bar{y} are
 263 the mean values for those parameters for the whole year of 2020. n represents the number of
 264 samples of the whole year of 2020, which is 299,052. Finally, m is the number of parameters of
 265 the database, in this case 61. Note that the mean was calculated for absolute correlation
 266 coefficients because Pearson correlation coefficient ranges from -1 to 1 depending on the type
 267 of relation between parameters. If absolute values were not considered, negative and positive
 268 values would cancel each other causing errors. Finally, RSD values were displayed versus
 269 correlation coefficient to decide which parameters had constant trends and should not be
 270 included in ANN models. Figure 2 shows the relation between relative deviation and mean
 271 correlation coefficient of each parameter.



272

273

Figure 2 RSD vs Correlation Coefficient – graph

274

275

276

277

278

279

280

281

282

283

284

285

286

287

288

289

290

291

292

293

294

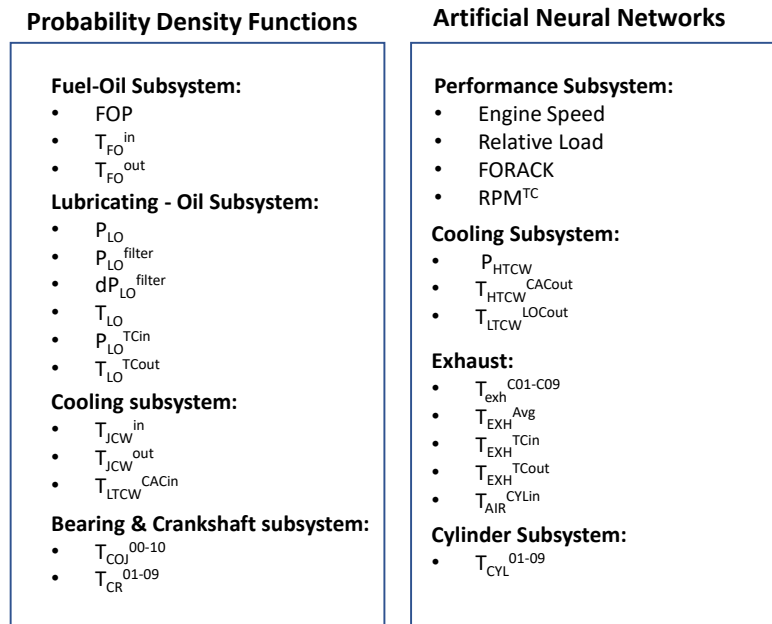
295

296

297

The line drawn in Figure 2 served as a reference to separate lowest correlation and relative deviation numbers to be analysed with Probability Density Functions instead of being included in ANN. The model selection criterion was not absolutely based on the mentioned line, specifically in those points that fell near the line. However, this scatter plot served as a useful tool to understand such a big database before starting the modelling process. For example, 3 large point clouds can be distinguished in Figure 2. The first one between 0.5 and 0.6 correlation coefficients which corresponds to the 9 crankshaft crankpin bearing temperature measurements. These parameters, even though presenting relatively high correlation levels, did not vary during 2020, which led to exclude them from ANN modelling. Similarly, the second point cloud below the line which falls to around 0.7 correlation coefficient corresponds to the 11 main bearing temperature measurements, which presented low RSD values, leading to study them with probability density functions. Finally, the third point cloud which is on top of the separating line corresponded to exhaust gas temperatures, which had large correlation numbers as well as much variability. These parameters were therefore modelled with artificial neural networks. Parameters which were near the line such as fuel-oil temperature in engine outlet (T_{FO}^{out}) were then studied more in depth to decide whether to include them in ANN models or analyse them with PDF. Specifically, after conducting preliminary ANN tests with T_{FO}^{out} , the prediction error was relatively high, which discarded this parameter from ANN modelling. Finally, some parameters such as FORACK or relative load showed very high correlation and variability numbers. This is logical since they are parameters that define the condition of the engine which are very good candidates to be inputs in ANN models. Based on this study the distribution of ANN and PDF modelled parameters was decided, which is shown in Figure 3. Note that part of the cooling subsystem parameters is modelled with PDF and some others with ANN. This is logical, because even when belonging to the same subsystem some parameters are designed to

298 undergo small variations while others are not, i.e. some parameters are controlled by means of
 299 thermostatic valves to be kept constant and others are dependent on operating conditions.



300

301

Figure 3 Parameter modelling technique decision

302 2.3 Probability density function models

303 Engine parameters with the lowest correlation and variability coefficients were not included in
 304 the ANN modelling process. Indeed, these parameters showed constant trends throughout the
 305 whole year, which would lead the ANN models to overfitting and decreased prediction accuracy.
 306 Probability density functions were therefore selected to ascertain the threshold values for such
 307 parameters. Some authors have already used this statistical approach to evaluate diesel engine
 308 parameters. Ruiz et al. [30] developed a new classification tool named LAMDA-FAR to categorize
 309 different engine operation conditions. This algorithm used PDF to conduct a similarity analysis
 310 which was used for different class grouping criteria. More recently, Jamrozik et al. [31] compared
 311 the combustion stability of diesel-methanol and diesel-ethanol fuel mixtures in a single-cylinder
 312 dual fuel engine by analysing the PDF of the engine IMEP.


313 In this study, one independent PDF was calculated for each parameter to ensure a fair
 314 calculation of threshold values. For that purpose, 94 different probability density functions were
 315 compared and fitted to the 2020 observations for each parameter. The fitting was carried out
 316 by computing the residual sum of squares (RSS) for each of the 94 PDFs considered. For every
 317 parameter, the PDF which provided minimum RSS was selected. Equation 3 shows the
 318 expression used to compute RSS.

319

$$RSS = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (3)$$

320 Where y_i is the actual density value of the i^{th} observation, $f(x_i)$ is the value predicted by the
 321 probability density function and n is the number of observations, which was 299,052 as the
 322 whole year of 2020 was considered. Figure 4a shows an example of the fitting process for the


323 lubricating oil pressure in the turbocharger inlet, while Figure 4b shows the PDF which provided
324 the minimum RSS value, which in that case is a Burr type 12 [32] distribution.



325

326

Figure 4a: Different PDF testing



327

328

329

330

331

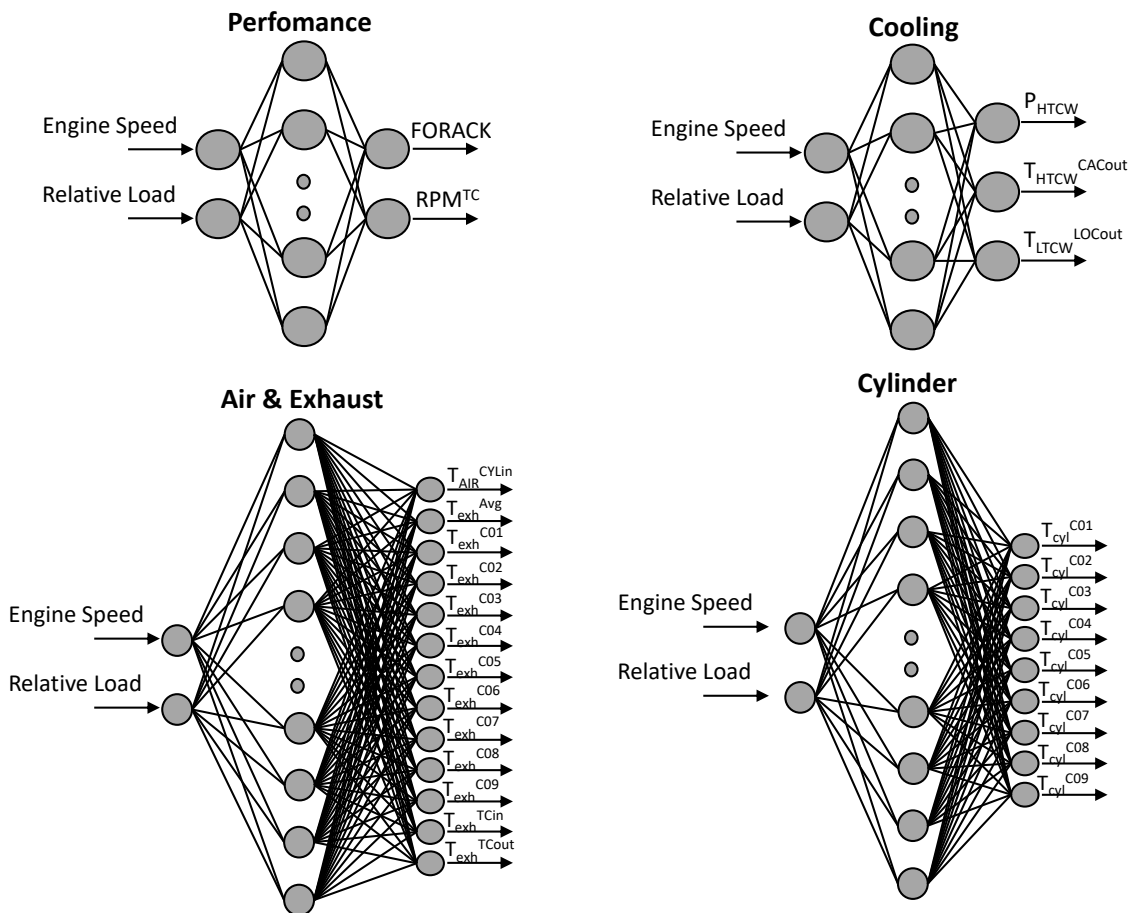
Figure 4b: Optimum PDF representation

Figure 4 Probability Density Function Fitting

332 **2.4 Artificial neural network models**

333 In this study, artificial neural networks were selected as the modelling technique to predict
 334 healthy engine values for the parameters that presented the highest correlation and relative
 335 deviation values. On these terms, one separate ANN model was proposed for each of the four
 336 different subsystems which contained such highly correlated parameters: performance, cooling,
 337 air & exhaust and cylinder subsystems. Regarding input layers, the four ANN models had the two
 338 same input parameters: engine load and engine speed. The first parameter showed one of the
 339 highest correlation and RSD values of the whole engine. This result may be explained by the fact
 340 that when different vessel speeds are needed, different propeller speeds are also needed to
 341 move the vessel. The main engine drives the propeller via a gearbox with one fixed reduction
 342 ratio, hence, propeller speed change means that main engine speed will also change. When
 343 propeller speed changes, the relative load of the engine is also directly modified, being a key
 344 representation of the engine state. This, along with engine speed, almost completely determines
 345 the engine's running situation. What stands out from Figure 2 is the relatively low correlation
 346 coefficient and RSD given by engine speed. Hence, it may be given by the filtering process
 347 previously carried out, in which engine speed was limited to values over 400 rpm. Much of the
 348 previous research has thus selected both engine load [19, 33] and engine speed [34, 35] in their
 349 ANN models when simulating diesel engine performance. Figure 5 shows the ANN structures
 350 proposed for this study.

351



352

353

Figure 5 ANN structures for different engine subsystems

354 Regarding the definition of neuron number in hidden layers of different ANNs, the trial and error
355 approach has traditionally been used to determine such hyperparameters. Yang et al. [24]
356 observed MSE and R values of their ANN model to ascertain the optimum learning rate.
357 Alternatively, Castresana et al. [19] observed validation MSE and R values for their model to
358 ascertain optimum neuron number of their developed ANN model. However, for trial-and-error
359 tests the network needs to be trained once with each of the different network configurations,
360 which would be remarkably time-consuming if done with the present 299,052 x 61 database. As
361 an alternative, some authors have developed mathematical equations to ascertain optimum
362 neuron number in hidden layer based on other network parameters [36, 37]. For this
363 contribution, a novel open source hyperparameter fitting software developed by O'Malley et al.
364 [38] called KerasTuner was used. This software runs multiple iterations with different network
365 hyperparameters aiming to minimize an objective function. In this case study, validation mean
366 squared error was used as the objective function to minimize by testing different neuron
367 numbers in hidden layer.

368 As a result, 8, 10, 18 and 7 neurons were defined as optimum numbers in hidden layer for
369 performance, cooling, air & exhaust and cylinder subsystems. The optimization algorithm used
370 for ANN training was Adam [39], which Ruder [40] asserted was the best choice in terms of
371 gradient descent algorithms. Transfer functions for the four ANN models were sigmoid and pure
372 linear functions for hidden and output layers respectively. For network training, an early stop
373 criterion was introduced to avoid excessive training epochs that could imply network overfitting.
374 To that end, if validation R^2 did not improve a minimum of 10^{-4} for 10 epochs, the training
375 process is stopped, assuming that the network is ready for testing. Data partition was 85%-15%
376 for training and validation. Testing was carried out in two phases: first, 1000 samples from 2020
377 that were not introduced to the network training were tested in the ANN to set threshold values
378 by observing model errors. In the second phase the network was then tested with data from
379 2021 to validate the calculated thresholds.

380

381 3- RESULTS

382 3.1 Probability density functions

383 Once the most suitable PDF was defined for each parameter, confidence intervals were
384 calculated to set threshold values in each variable. For that purpose, 98% confidence interval
385 was selected, to avoid possible isolate outliers to be considered in the threshold calculation.
386 Table 3 shows all the calculated PDFs for different engine subsystem parameters, along with the
387 confidence intervals calculated for them and the percentage deviation with respect to the mean
388 value derived from the confidence interval.

389

390

391

392

393

Table 3 PDFs, Confidence intervals and threshold deviations set for different engine parameters

Subsystem	ID	Unit	Probability Density Function	Confidence interval 98%	Max. deviation [%] 98%
Fuel - Oil	FOP	[bar]	Skew-Normal	[6.85,8.11]	[7.48,9.54]
	T_{FO}^{in}	[°C]	Generalized-Gamma	[32.32,40.37]	[13.16,8.45]
	T_{FO}^{out}	[°C]	Left-skewed Gumbel	[41.37,51.6]	[13.97,7.31]
Lubricating - Oil	P_{LO}	[bar]	Laplace asymmetric	[5.25,6]	[7.97,5.11]
	P_{LO}^{filter}	[bar]	Laplace	[5.79,6.65]	[6.92,6.92]
	dP_{LO}^{filter}	[bar]	Burr	[0.44,0.56]	[10.59,14.47]
	T_{LO}	[°C]	Laplace asymmetric	[61.16,63.22]	[1.48,1.85]
	P_{LO}^{TCin}	[bar]	Burr12	[4.79,5.67]	[9.05,7.65]
	T_{LO}^{TCout}	[°C]	Log-Laplace	[74.33,92.68]	[10.51,11.57]
Cooling	T_{JCW}^{in}	[°C]	Laplace	[75.5,78.53]	[1.95,1.95]
	T_{JCW}^{out}	[°C]	Laplace Asymmetric	[80.9,84.81]	[1.76,2.99]
	T_{LTCW}^{CACin}	[°C]	Laplace Asymmetric	[32.95,34.4]	[1.01,3.36]
Bearing & Crankshaft	T_{COJ}^{00}	[°C]	Laplace asymmetric	[71.87,75.38]	[2.68,2.07]
	T_{COJ}^{01}	[°C]	Weibull Maximum	[78.22,85.3]	[4.78,3.85]
	T_{COJ}^{02}	[°C]	Inverted Gamma	[79.32,87.68]	[4.94,5.08]
	T_{COJ}^{03}	[°C]	Laplace asymmetric	[81.48,92.41]	[5.68,6.97]
	T_{COJ}^{04}	[°C]	Von Mises	[81.66,90.02]	[4.87,4.87]
	T_{COJ}^{05}	[°C]	Gauss hypergeometric	[81.66,89.08]	[4.73,3.92]
	T_{COJ}^{06}	[°C]	Von Mises	[80.6,88.84]	[4.86,4.86]
	T_{COJ}^{07}	[°C]	Generalized extreme value	[81.04,88.97]	[5.07,4.21]
	T_{COJ}^{08}	[°C]	value	[81.78,89.43]	[5,3.89]
	T_{COJ}^{09}	[°C]	Von Mises	[81.75,89.95]	[4.77,4.77]
	T_{COJ}^{10}	[°C]	Skew-Normal	[77.04,83.22]	[4.8,2.84]
	T_{CR}^{01}	[°C]	Laplace asymmetric	[71.92,78.23]	[4.9,3.46]
	T_{CR}^{02}	[°C]	Skew-Normal	[70.55,78.21]	[6.94,3.16]
	T_{CR}^{03}	[°C]		[72.55,78.58]	[3.56,4.45]
	T_{CR}^{04}	[°C]	Laplace asymmetric	[72.08,78.41]	[5.51,2.79]
	T_{CR}^{05}	[°C]		[71.86,78.51]	[5.04,3.76]
	T_{CR}^{06}	[°C]	Generalized logistic	[70.21,77.2]	[7.16,2.08]
	T_{CR}^{07}	[°C]	Laplace asymmetric	[73.2,79.13]	[3.02,4.84]
	T_{CR}^{08}	[°C]	Mielke	[70.81,77.2]	[6.49,1.95]
T_{CR}^{09}	[°C]	Mielke	[71.64,78.14]	[6.56,1.91]	

395

396 With the aim of providing an extrapolative source of information, apart from calculating
397 confidence intervals for all PDF modelled parameters the relative maximum deviation of such
398 intervals with respect to the mean value of each parameter was calculated. As seen in Table 3,
399 the deviation ranges depended not only on each parameter but also on each subsystem, being
400 higher for some specific subsystems. For instance, the fuel-oil subsystem and the lubricating-oil
401 subsystems presented the highest variation ranges of all the analysed parameters. Regarding
402 fuel-oil variables, while fuel oil pressure (FOP) showed relatively low variations, both fuel oil
403 temperatures at engine inlet (T_{FO}^{in}) and engine outlet (T_{FO}^{out}) presented maximum variation rates
404 of 13.16 and 13.97%, respectively. For the lubricating-oil system, differential pressure in oil filter
405 (dP_{LO}^{filter}), oil pressure at turbocharger inlet (P_{LO}^{TCin}) and oil temperature at turbocharger outlet
406 (T_{LO}^{TCout}) presented the highest maximum deviation rates with 14.47%, 9.05% and 11.57%,
407 respectively, while the rest of the parameter deviations remained below 8%, being especially

408 low for the oil temperature, with a 1.85% maximum deviation rate. Cooling subsystem
409 parameters presented the lowest deviation levels, attaining maximum deviations of 0.81%,
410 2.99% and 3.36% for jacket cooling water temperature at jacket inlet ($T_{J_{CW}^{in}}$) and outlet ($T_{J_{CW}^{out}}$)
411 and low temperature cooling water temperature at air cooler inlet (T_{LTCW}^{CACin}), respectively.
412 Finally, observing the bearing & crankshaft subsystem, all bearing temperature deviations
413 remained below 6.97%, which was seen in the third bearing temperature parameter (T_{COJ}^{03}).
414 Furthermore, if confidence intervals are examined in this subsystem, intervals of bearing
415 temperatures from engine extremes (e.g. T_{COJ}^{00} , T_{COJ}^{01} , T_{COJ}^{10}) appear to present lower
416 temperatures than others measured in the centre of the engine, which is logical since engine
417 extremes may be more exposed to heat losses. If all bearing temperatures were considered as
418 only one, this fact would induce larger confidence intervals for all bearing temperatures, being
419 source of misclassification in some faulty bearing situations. The obtained confidence intervals
420 and percentage deviation ranges were later validated with real operative vessel data measured
421 in 2021.

422

423 3.2 Artificial neural network results

424 In this contribution ANN models were trained and validated with data from 2020 and 1000
425 random samples of that year not seen in training/validation phase were tested in the networks
426 to ascertain threshold deviation values for model predictions. For that purpose, the mean
427 absolute percentage error was calculated for each parameter following equation 4. This error
428 parameter represents the mean of the relative percentage errors computed for n predictions
429 and has been widely used for marine diesel engine modelling evaluation [33, 41].


430

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{t_i - y_i}{t_i} \right| * 100 \quad (4)$$

431

432

433 Where y_i is the i^{th} prediction for one specific parameter, t_i is its actual value, and n is the number
434 of predictions for which MAPE is calculated, which in this case is 1000. The error values reached
435 for the 1000 testing samples are depicted in Figure 6.



436


437

Figure 6 MAPE values for different ANN predictions

438 Overall, the accuracy levels obtained for all parameters were remarkably high. This may be partly
 439 due to the large dataset containing 299,052 samples that was introduced to the engine for
 440 training/validation. Such parameters have much higher variation ranges than the ones studied
 441 with probability density functions; the confidence intervals for these parameters would not
 442 therefore serve to identify healthy engine threshold values. ANNs were thus used to accurately
 443 calculate healthy engine parameter values throughout the whole performance map. The 1000
 444 data samples reserved for testing were randomly selected so they do not represent only specific
 445 operative points, though they do represent different engine conditions. Regarding performance
 446 subsystem, 0.78% and 0.90% MAPE values were obtained, being two of the most accurately
 447 predicted parameters. Cooling subsystem and cylinder subsystem prediction errors likewise
 448 remained below 1.22% and 1.17% MAPE values, which highlight the accuracy level of the
 449 developed ANNs. Finally, air & exhaust subsystem showed some of the highest errors, with
 450 MAPE values of 2.99% and 4.36% for temperatures of turbocharger inlet (T_{EXH}^{TCin}) and outlet
 451 (T_{EXH}^{TCout}), respectively. The possible reasons for these parameters presenting higher errors than
 452 the rest of variables, along with its implication in possible threshold characterization, will be
 453 further analysed in the discussion section. To understand the magnitude of the errors shown in
 454 Figure 6, two parameter predictions are shown in Figure 7: FORACK and T_{EXH}^{TCout} , which are the
 455 lowest error and the highest error containing predicted parameters. The first 50 samples of the
 456 1000 sample testing database were represented to provide a better understanding of the
 457 prediction accuracies. Overall, FORACK predictions are very close to their actual values, which
 458 are a direct indicator of engine fuel consumption. On the other hand, even if the accuracy level
 459 is lower for T_{EXH}^{TCout} , the model predictions keep close to actual values in all the testing data
 460 samples, proving the great prediction potential of the designed ANN.

461

462



463

464

Figure 7 T_{EXH}^{TCout} and FORACK predictions

465


466 3.3 Threshold validation

467 In sections 3.1 and 3.2, threshold values were determined for all measured engine parameters.
 468 On the one hand, confidence intervals were calculated for those parameters showing lowest
 469 correlation and relative deviation coefficients. From these intervals, maximum percentage
 470 deviation from baseline was calculated for each parameter, using data from the whole year of
 471 2020. On the other hand, other parameters with higher correlation and variability in 2020 were
 472 modelled by using artificial neural networks. After training and validating the four models
 473 designed for the four different engine subsystems, the models were tested with 1000 random
 474 testing samples from 2020, analysing prediction error and setting percentage deviation
 475 thresholds between model and real engine. Finally, to see whether established thresholds were
 476 suitable, engine data from 2021 was used to validate the determined values.

477 From 2021, data from different days was extracted to validate both modelling techniques. At
 478 this time, only data from the first half of the year 2021 was available since it is relatively recent,
 479 and the rest of the year has not yet been received. Data from different days through the first
 480 half of 2021 was therefore selected. Specifically, data measured between 12 p.m. and 5 p.m. on
 481 the 20th day of each month was used for the model validation. This data was also subject to all
 482 the filtering and resampling processes conducted in 2020. Having one sample per minute and 5
 483 hours from 6 different days, a total of 60 samples x 5 hours x 6 days = 1800 samples would
 484 therefore be used for validation. However, as mentioned, non-steady data and samples
 485 corresponding to non-running engine conditions were filtered, attaining a final validation
 486 database of 1647 samples.

487 First, the thresholds calculated with confidence intervals were tested. Considering validation
 488 dataset from 2021, the times in which each parameter value fell out of the 2020 ranges (shown
 489 in Table 3) were counted. The result is a number for each engine variable representing the times
 490 in which the threshold values set with 2020 data failed. Surprisingly, fuel oil temperature
 491 measurements in engine inlet (T_{FO}^{in}) and outlet (T_{FO}^{out}) fell out of the threshold ranges almost
 492 50% of the times in 2021. After further analysing the evolution of these two parameters in 2020
 493 and 2021, it was seen that overall, in 2021 both temperature values were in higher value ranges


494 than in the past 2020. This may actually be due to a change of the geographic zone in which the
 495 vessel was operating between the two years. Therefore, to prevent the developed PDF modelled
 496 intervals from external factors (e.g. fishing zone), the difference between both inlet and outlet
 497 temperatures was modelled with an additional PDF. The result was a gamma distribution, and
 498 the confidence interval for the temperature difference (dTFO) was [9.14,16.59] [°C]. Figure 8a
 499 shows the counts in which each parameter value of 2021 data fell out of the thresholds
 500 determined in 2020, while Figure 8b shows an example of lubricating-oil pressure
 501 measurements from 2021 versus the threshold values set in 2020.



502

Figure 8a Threshold value fails in 2021

503



504

Figure 8b P_{LO}^{TCin} values from 2021 vs threshold range set in 2020


505

506

Figure 8 PDF modelled parameter threshold ranges validation

507 As seen in Figure 8a, all the parameters tested in 2021 generally fell inside the threshold ranges
 508 set in 2020 (Table3). Indeed, the highest number of threshold failures was 20 for jacket cooling
 509 water temperature in engine inlet (T_{JcW}^{in}). If compared to the 1647 samples that were used for
 510 validation, this would lead to a threshold failure of 1.21%, which is acceptable, since some
 511 outliers may appear in real vessel operating conditions. When observing Figure 8b, all the data
 512 used for validation in 2021 fell into the threshold range with the exception of some isolated
 513 points that were not extended in a considerable period of time. What stands out from Figure 8
 514 is the low error level given by the proposed threshold values. If some of these constant trending
 515 parameters fell out of the mentioned ranges for a time, we could state that the engine was not
 516 working in 100% healthy engine conditions.

517 Concerning the parameters modelled by ANN, the same database was used for the model
 518 validation. The ANNs which were trained, validated and tested with data from 2020 were first
 519 saved and then loaded again to be tested with the 2021 data. Figure 9 shows the MAPE values
 520 attained for the testing data of the first half of 2021.



521

522

Figure 9 ANN predictions for 2021 data

523 As seen in Figure 9, the prediction errors presented for the 2021 testing data were in the same
 524 range of the 2020 testing errors. Furthermore, testing data from 2020 contained random
 525 samples not seen in the training phase; however, those samples were in between other samples
 526 which were used for training, representing engine conditions which were close to those used for
 527 training and validation. The 2021 dataset nevertheless contained engine conditions that in some
 528 cases were obtained months after those used for model training and validation, so the low errors
 529 obtained indicate high robustness and regression capability for the designed ANNs. Performance
 530 subsystem prediction errors remained at the same levels as in 2020. For cooling subsystem
 531 parameter predictions, MAPE values were even lower than for the 2020 data predictions,
 532 remaining below 1% in the three cooling parameters. Regarding air & exhaust subsystem, air
 533 temperature in cylinder inlet presented higher MAPE values with 3.70%, compared to the 1.56%
 534 obtained in 2020. This may partly be caused by a changed ambient temperature of the vessel's
 535 location in 2021. For the exhaust gas temperatures of cylinder outlets, the obtained errors also
 536 increased slightly with respect to the 2020 errors. The highest prediction error was again seen

537 in exhaust gas temperature prediction in turbocharger outlet, which was 7.34%. This may
538 actually be due to the high amount of engine variables that have an impact on this parameter
539 (e.g. engine load and speed, turbocharger angular speed, intake air temperature etc.). Finally,
540 cylinder subsystem predictions showed similar error levels as in the 2020 testing, remaining
541 under 2% in all cylinder temperature predictions. In the following discussion section, all the
542 obtained threshold deviations will be further analysed and summarized to serve as a reference
543 point for future fault detection investigations.

544 4-DISCUSSION

545

546 In this study, the operation of the main engine of a commercial fishing vessel was studied
547 throughout 2020 and the first half of 2021. During the studied period, the engine operated
548 without any fault occurrence. Many research studies have up to now included different
549 threshold values for faulty engine situations; however, those thresholds are not sometimes
550 sufficiently justified or are limited to laboratory conditions. In this study more than 5181 engine
551 running hours were used, providing an invaluable insight into engine performance prediction
552 models. After conducting a correlation and deviation study, constant trending parameters were
553 modelled with probability density functions, while parameters with higher correlation and
554 relative deviation coefficients were modelled with ANN. The validation results show the great
555 potential of both modelling techniques to accurately define healthy engine threshold values for
556 all the studied parameters.

557 For PDF modelled parameters, the most suitable PDF function was determined for each
558 parameter and 98% confidence intervals were calculated. After that the mean value of each
559 parameter was also calculated with the PDF and the percentage deviations of the confidence
560 interval limits with respect to the mean parameter value were computed. As seen in Figure 8a,
561 the thresholds established in 2020 proved to be suitable since the number of points that fell out
562 of the thresholds in 2021 was remarkably low. However, engine inlet (T_{FO}^{in}) and outlet (T_{FO}^{out})
563 temperatures at first fell almost 50% of the times out of the established thresholds, which may
564 be due to a change in the geographic fishing zone. Recently, Issa et al. [42] analysed the effect
565 of ambient parameters in engine efficiency, concluding that ambient temperature had a direct
566 relationship with engine parameters such as engine efficiency or fuel consumption.
567 Consequently, in this study the difference between engine inlet and outlet temperatures ($dTFO$)
568 was computed and modelled with a new PDF. As seen in Figure 8a, the new parameter ($dTFO$)
569 fell only 4 times out of its threshold values in 2021, even when the geographic fishing zone was
570 different.

571 Regarding PDF analysis, some authors have used analogue methodologies to conduct condition-
572 based maintenance operations. For instance, Boulloua-Falces et al. [43] calculated the so-called
573 decision intervals for different parameters such as air intake temperature or SFOC in a two-
574 stroke marine diesel engine, concluding that manufacturer threshold limits were too high to
575 identify early operational engine failure. Alternatively, Stoumpos and Theotokatos [44]
576 established 5% and 10% deviations for engine speed and boost pressure failures respectively.
577 However, in some specific parameters the maximum threshold deviations without failures may
578 be larger. For instance, in this study, for differential pressure in fuel oil filter dP_{LO}^{filter} and
579 lubricating-oil temperature at turbocharger outlet (T_{LO}^{TCout}), maximum relative deviations of
580 14.47% and 11.57% were obtained, respectively. Furthermore, the fact that a certain sample
581 exceeded the calculated thresholds may not represent an incipient fault. The specific subsystem

582 characteristics must also be considered. The engine has a large volume of lubricating oil, which
583 means that it acts as a thermal buffer with high thermal inertia. This means that lubricating oil
584 temperature will not change as fast as engine-relative load and speed, creating values out of
585 threshold but just momentary values, going inside the threshold once engine oil temperature is
586 completely stabilized. Temperature will also impact the system pressure, as lubricating oil
587 viscosity is temperature dependant and pressure in the system will depend on oil viscosity.
588 Before an upcoming fault, the measured engine variables should be out of the calculated
589 thresholds for a while, ensuring that the engine is completely stabilized, and not just falling out
590 of threshold ranges in concrete situations. As stated by Nahim et al. [45], a higher oil
591 temperature may represent oil leaking or oil cooler fouling, while a lower oil pressure value may
592 indicate oil pump wear, high oil temperature, engine bearing wear or oil filter fouling. This, along
593 with the rest of the parameters modelled in the lubricating-oil subsystem in this study, may be
594 good indicators of the aforementioned fault in the engine oil circuit.

595 As for the rest of the parameters in this study, the highest numbers of threshold-exceeding
596 samples seen in Figure 8a were given in cooling parameters. This may accordingly be caused by
597 the small threshold deviation ranges defined in those parameters and the fact that liquid
598 systems had an important thermal inertia due to the capacity of storing sensible heat in a liquid.
599 This will always imply a response delay in temperature change with engine speed and relative
600 load change that are basically instantaneous. The highest threshold deviation was 3.36% for low-
601 temperature cooling water temperature in air cooler inlet (T_{LTCW}^{CACin}), which is notably lower
602 than the faulty threshold values seen in the cited research works. However, the maximum of
603 validation samples falling out of threshold ranges was 20, which compared to all the samples
604 used for validation (1647) results in a 1.21% error, which is acceptable. In the case of this specific
605 vessel the cooling water temperature in air cooler inlet (T_{LTCW}^{CACin}) was coming directly from a
606 plate heat exchanger cooled with sea water. The vessel operates in tropical waters and sea water
607 temperature values may influence outlet temperature of the cooled water to the air cooler. This
608 may also be the cause of difference in the period of 2021, as it is also an indicator of partial heat
609 exchanger plate cooling due to fouling. Gholinia et al. [46] simulated the cooling water jacket
610 system of a heavy-duty diesel engine, concluding that insufficient cooling between exhaust valve
611 and glow-plug could lead to gas leakage and cause reduced engine power. The threshold ranges
612 set in the present study for cooling water jacket temperatures may thus be useful to identify
613 such faulty conditions. Finally, bearing and crankshaft subsystem parameters fell out of the
614 threshold ranges only a few times, which induced a good determination of such limits.

615 Concerning Artificial Neural Network modelled parameters, prediction error varied slightly in
616 some parameters when predicting validation data from 2021. After observing MAPE values for
617 both 2020 and 2021, it was seen that many of those errors had a direct relationship with the
618 correlation and RSD values shown in Figure 2. Indeed, the performance subsystem parameters
619 FORACK and turbocharger angular speed showed two of the highest correlation and RSD values
620 in the whole engine, which later led to two of the lowest prediction errors for the whole engine
621 in both 2020 and 2021, with MAPE values under 1.10%. Fuel consumption related parameters
622 have traditionally presented relatively low percentage errors when predicted with ANN. Niu et
623 al. [41] obtained a 1.28% MAPE value when predicting BSFC among other parameters in a marine
624 diesel engine by training their model with limited samples. Ağbulut et al. [34] recently obtained
625 a 2.078% mean error percentage for BSFC when modelling a single-cylinder diesel engine using
626 cottonseed methyl-ester.

627

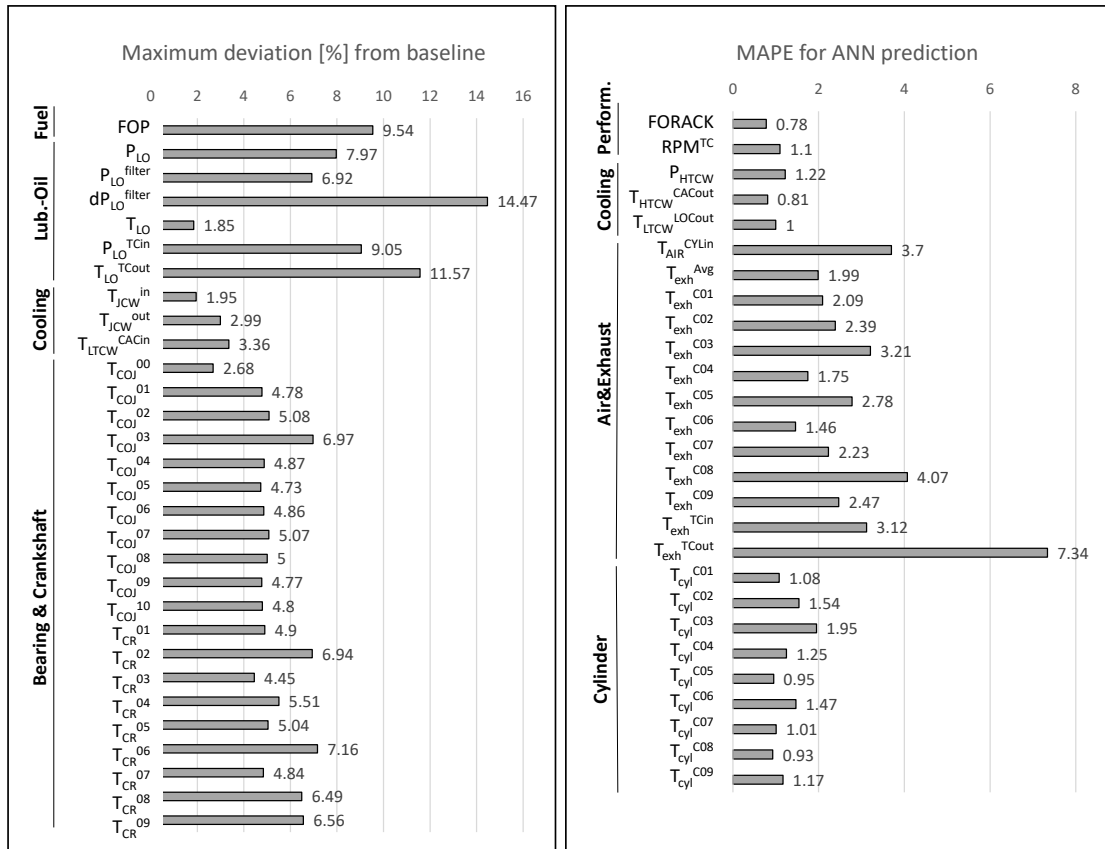
628 For cooling subsystem, a high accuracy level was reached for the three parameters predicted in
629 the 2021 validation data predictions. MAPE values of 0.96%, 0.57% and 0.83% were obtained
630 for high temperature cooling water pressure (P_{HTCW}), high temperature cooling water
631 temperature at air cooler outlet (T_{HTCW}^{CAout}) and low temperature cooling water temperature at
632 lubricating oil cooler outlet (T_{LTCW}^{LOCout}), respectively. As seen by Zhou and Xu [47], these
633 parameters may be useful for diagnosing engine faults such as water pump failure or dirty cooler
634 clogging. Thus, model to real value deviations in such variables may be good indicators of
635 incipient faults in the engine.

636 On the other hand, air & exhaust subsystem predictions generally showed higher error values in
637 the 2021 predictions than in 2020. However, the error levels attained in 2021 remained
638 relatively low. Exhaust gas temperature has been predicted in multiple engine modelling
639 research papers. But few studies have separated all exhaust subsystem elements and predicted
640 them separately and most of them have been under laboratory conditions with practically no
641 change of ambient conditions. For example, Basurko and Uriondo [3] predicted different
642 turbocharger and cylinder exhaust gas temperatures. Similarly, Castresana et al. [19] calculated
643 multiple exhaust system parameters containing cylinder exhaust gas temperatures and
644 turbocharger inlet and outlet temperatures. Among the results, they obtained MAPE values
645 under 2.35% for all the exhaust subsystem parameters. Alternatively, Cay et al. [48] reached
646 3.14% MAPE value for T_{exh} prediction while modelling a methanol engine. In the case of exhaust
647 gas temperatures in cylinders, the maximum MAPE reached in this study was 4.09% for cylinder
648 number 8 (T_{exh}^{CO8}), though the average value of all cylinders was below 2% (T_{exh}^{Avg}). Individual
649 cylinders may hence change performance easier than the overall engine represented by the
650 average value (T_{exh}^{Avg}), which showed remarkably lower MAPE. From Figure 9, it can be seen that
651 by far the highest prediction error was given in exhaust gas temperature calculation in
652 turbocharger outlet (T_{EXH}^{TCout}). This in part may occur because this parameter does not only
653 depend on in-cylinder phenomena as it happens to cylinder exhaust gases, but also on
654 turbocharger performance, expansion occurring in the turbine and ambient conditions.

655 Additionally, for some reason the parameter T_{EXH}^{TCout} appeared on the left side of Figure 2, not
656 being one of the highest correlation and deviation containing parameters. Thus, this stands once
657 again the importance of a previous correlation and deviation analysis to better understand the
658 role of each parameter in the engine. All in all, the prediction error still remains acceptable and
659 this parameter is of great importance for certain faulty conditions. For example, as stated by
660 Hield [49], increased back-pressure may lead to higher exhaust gas temperatures, which in this
661 case study may be identified by an increased deviation between real values and modelled
662 T_{EXH}^{TCout} presenting errors higher than the obtained 7.34% extended in time. Finally, cylinder
663 subsystem temperature predictions proved to be very accurate, which in combination with
664 other engine parameters may be useful for engine CBM.

665 From the results obtained in the present study, a final figure was built to provide a reference
666 point for future fault detection publications. For the parameters measured with PDF, the
667 maximum relative deviation of each parameter was taken from Table 3. This is logical, since it
668 represents the most deviated a parameter has been with respect to its baseline in the whole
669 year of 2020. For parameters modelled with ANN, the maximum MAPE value between the 2020
670 testing (Figure 6) and 2021 validation (Figure 9) predictions was extracted. These values would
671 therefore represent the maximum errors seen in two different years for an ANN trained with a
672 big dimension dataset. So, the present paper aims to serve as a reference point for other CBM
673 studies, specifically in the field of marine diesel engines, considering the lengthy period of

674 operating time without any fault occurrence of the engine used for the study. The deviations
 675 seen in Figure 10 may not be exactly the same in other marine diesel engines; however, they
 676 could serve as an interesting option when setting thresholds for different engine fault
 677 conditions.



678

679

Figure 10 Threshold values for multiple marine diesel engine variables

680

681 5- Conclusions

682

683 In the present study the propulsion system of a commercial fishing vessel was analysed. After
 684 acquiring 61 different engine parameters throughout 2020 and 2021, the threshold values of
 685 this healthy engine were studied using different modelling strategies. On the one hand,
 686 probability density functions were used to model constant trending parameters and set
 687 threshold confidence intervals for each of them. On the other hand, parameters presenting
 688 higher correlation and relative deviation coefficients were modelled with ANN and threshold
 689 deviations between model and real values were set. Finally, all defined thresholds were
 690 validated using data from 2021. This contribution studied for the first time the limits of multiple
 691 engine performance parameters for the entire operating year of a fishing vessel, validating the
 692 established healthy engine threshold values with operative data from the next year totalling
 693 5181 hours of engine operation. From the obtained results, the following conclusions can be
 694 drawn:

695

696

- Probability density functions proved to be of great potential for modelling constant trending parameters. After validation, the maximum number of threshold failures

697 was 1.21%, which stands the high accuracy level of the established thresholds.
698 Faulty values need to be permanent in time to be considered actual performance
699 deviations.
700 - Threshold values vary depending on the engine subsystem and parameter. While
701 cooling subsystem showed maximum deviations of 3.36% from baseline, fuel-oil
702 subsystem showed a maximum deviation of 14.47%. Hence, individualized threshold
703 values should be defined when setting engine faulty conditions.
704 - Artificial neural networks proved to be a fast and accurate modelling methodology.
705 27 different parameters were predicted with MAPE values under 7.34%, even when
706 predicting data obtained months later than the database used for model training.
707 - For certain engine subsystems the obtained MAPE values were remarkably low:
708 performance subsystem was below 1.1%, cooling subsystem below 1.22% and
709 cylinder subsystem below 1.95%. Small deviations over time may thus be good
710 indicators for different engine fault situations.

711 Future works may analyse different commercial vessel propulsion faults, further observing
712 whether the thresholds presented in this contribution are surpassed or not. Ambient conditions
713 in engine room and sea water temperature will also have to be considered in order to define
714 more accurate models. At this stage, this research team is working on a six-cylinder marine diesel
715 engine measuring multiple engine parameters in some engine fault situations. The inclusion of
716 thermodynamic modelling techniques to simulate engine fault conditions and later train ANN
717 models is also being studied. For that purpose, these thresholds will serve to ascertain the
718 ranges in which each engine parameter can vary without indicating an incipient fault.

719

720 Declaration of competing interests

721

722 The authors declare that they have no known competing financial interests or personal
723 relationships that could have appeared to influence the work reported in this paper.

724 Acknowledgements

725

726 The work behind this contribution was funded by the Basque Government. J. Castresana has
727 benefited from a grant from the Department of Economic Development and Infrastructures. The
728 authors also want to thank the Department of Thermal Engineering and Nautical and Naval
729 Machines of the University of the Basque Country as well as the ASADIP project. This paper is
730 contribution no. _ _ _ of AZTI, Marine Research, Basque Research and Technology Alliance
731 (BRTA).

732

733

734

735

736

737 REFERENCES

- 738 [1] Eurostat, International trade in goods by mode of transport, in, 2022.
739 [2] S.C. S.C, Third Main Engine Damage report, in, 2018.
740 [3] O.C. Basurko, Z. Uriondo, Condition-Based Maintenance for medium speed diesel engines
741 used in vessels in operation, *Applied Thermal Engineering*, 80 (2015) 404-412.
742 [4] S. Salam, T. Choudhary, A. Pugazhendhi, T.N. Verma, A. Sharma, A review on recent
743 progress in computational and empirical studies of compression ignition internal combustion
744 engine, *Fuel*, 279 (2020) 118469.
745 [5] J. Benajes, P. Olmeda, J. Martín, R. Carreño, A new methodology for uncertainties
746 characterization in combustion diagnosis and thermodynamic modelling, *Applied Thermal
747 Engineering*, 71 (2014) 389-399.
748 [6] G. Gonca, E. Dobrucali, Theoretical and experimental study on the performance of a diesel
749 engine fueled with diesel–biodiesel blends, *Renewable energy*, 93 (2016) 658-666.
750 [7] E. Jiaqiang, G. Liu, Z. Zhang, D. Han, J. Chen, K. Wei, J. Gong, Z. Yin, Effect analysis on cold
751 starting performance enhancement of a diesel engine fueled with biodiesel fuel based on an
752 improved thermodynamic model, *Applied Energy*, 243 (2019) 321-335.
753 [8] G. Theotokatos, V. Tzelepis, A computational study on the performance and emission
754 parameters mapping of a ship propulsion system, *Proceedings of the Institution of Mechanical
755 Engineers, Part M: Journal of Engineering for the Maritime Environment*, 229 (2015) 58-76.
756 [9] J.A.P. Rubio, F. Vera-García, J.H. Grau, J.M. Cámara, D.A. Hernandez, Marine diesel engine
757 failure simulator based on thermodynamic model, *Applied Thermal Engineering*, 144 (2018)
758 982-995.
759 [10] F. Vera-García, J.A. Pagán Rubio, J. Hernández Grau, D. Albaladejo Hernández,
760 Improvements of a failure database for marine diesel engines using the RCM and simulations,
761 *Energies*, 13 (2020) 104.
762 [11] M. Altosole, U. Campora, M. Figari, M. Laviola, M. Martelli, A diesel engine modelling
763 approach for ship propulsion real-time simulators, *Journal of Marine Science and Engineering*,
764 7 (2019) 138.
765 [12] I. Lazakis, C. Gkerekos, G. Theotokatos, Investigating an SVM-driven, one-class approach
766 to estimating ship systems condition, *Ships and Offshore Structures*, 14 (2019) 432-441.
767 [13] J. Kowalski, B. Krawczyk, M. Woźniak, Fault diagnosis of marine 4-stroke diesel engines
768 using a one-vs-one extreme learning ensemble, *Engineering Applications of Artificial
769 Intelligence*, 57 (2017) 134-141.
770 [14] M. Zhang, Y. Li, J. Cai, F. Chen, X. Miao, Research on fault diagnosis of diesel engine based
771 on PCA-RBF neural network, *Modern Physics Letters B*, 32 (2018) 1840099.
772 [15] G. Sujesh, S. Ramesh, Modeling and control of diesel engines: A systematic review,
773 *Alexandria engineering journal*, 57 (2018) 4033-4048.
774 [16] D.J. Livingstone, D.T. Manallack, I.V. Tetko, Data modelling with neural networks:
775 advantages and limitations, *Journal of computer-aided molecular design*, 11 (1997) 135-142.
776 [17] J. Castresana, G. Gabiña, L. Martin, Z. Uriondo, Comparative performance and emissions
777 assessments of a single-cylinder diesel engine using artificial neural network and
778 thermodynamic simulation, *Applied Thermal Engineering*, (2020) 116343.
779 [18] S. Roy, R. Banerjee, P.K. Bose, Performance and exhaust emissions prediction of a CRDI
780 assisted single cylinder diesel engine coupled with EGR using artificial neural network, *Applied
781 Energy*, 119 (2014) 330-340.
782 [19] J. Castresana, G. Gabiña, L. Martin, A. Basterretxea, Z. Uriondo, Marine diesel engine ANN
783 modelling with multiple output for complete engine performance map, *Fuel*, 319 (2022)
784 123873.
785 [20] B. Liu, C. Zhao, F. Zhang, T. Cui, J. Su, Misfire detection of a turbocharged diesel engine by
786 using artificial neural networks, *Applied Thermal Engineering*, 55 (2013) 26-32.

787 [21] P. Srihari, K. Govindarajulu, K. Ramachandra, A method to improve reliability of gearbox
788 fault detection with artificial neural networks, *International Journal of Automotive and*
789 *Mechanical Engineering*, 2 (2010) 221-230.

790 [22] A.F. Mofleh, A.N. Shmroukh, N.M. GHAZALY, Fault detection and classification of spark
791 ignition engine based on acoustic signals and artificial neural network, *International Journal of*
792 *Mechanical and Production Engineering Research and Development*, 10 (2020) 5571-5578.

793 [23] J.M. Alonso, F. Alvarruiz, J.M. Desantes, L. Hernández, V. Hernández, G. Molto, Combining
794 neural networks and genetic algorithms to predict and reduce diesel engine emissions, *IEEE*
795 *transactions on evolutionary computation*, 11 (2007) 46-55.

796 [24] F. Yang, H. Cho, H. Zhang, J. Zhang, Y. Wu, Artificial neural network (ANN) based prediction
797 and optimization of an organic Rankine cycle (ORC) for diesel engine waste heat recovery,
798 *Energy conversion and management*, 164 (2018) 15-26.

799 [25] J. Porteiro, J. Collazo, D. Patiño, J.L. Míguez, Diesel engine condition monitoring using a
800 multi-net neural network system with nonintrusive sensors, *Applied Thermal Engineering*, 31
801 (2011) 4097-4105.

802 [26] M. Jafari, P. Verma, T.A. Bodisco, A. Zare, N.C. Surawski, P. Borghesani, S. Stevanovic, Y.
803 Guo, J. Alroe, C. Osuagwu, Multivariate analysis of performance and emission parameters in a
804 diesel engine using biodiesel and oxygenated additive, *Energy conversion and management*,
805 201 (2019) 112183.

806 [27] Y. Khelil, G. Graton, M. Djeziri, M. Ouladsine, R. Outbib, Fault detection and isolation in
807 marine diesel engines: A generic methodology, *IFAC Proceedings Volumes*, 45 (2012) 964-969.

808 [28] R. Wang, H. Chen, C. Guan, W. Gong, Z. Zhang, Research on the fault monitoring method
809 of marine diesel engines based on the manifold learning and isolation forest, *Applied Ocean*
810 *Research*, 112 (2021) 102681.

811 [29] G. Tsaganos, N. Nikitakos, D. Dalaklis, A. Ölcer, D. Papachristos, Machine learning
812 algorithms in shipping: improving engine fault detection and diagnosis via ensemble methods,
813 *WMU Journal of Maritime Affairs*, 19 (2020) 51-72.

814 [30] F.A. Ruiz, C.V. Isaza, A.F. Agudelo, J.R. Agudelo, A new criterion to validate and improve
815 the classification process of LAMDA algorithm applied to diesel engines, *Engineering*
816 *Applications of Artificial Intelligence*, 60 (2017) 117-127.

817 [31] A. Jamrozik, W. Tutak, R. Gnatowska, Ł. Nowak, Comparative analysis of the combustion
818 stability of diesel-methanol and diesel-ethanol in a dual fuel engine, *Energies*, 12 (2019) 971.

819 [32] I.W. Burr, Cumulative frequency functions, *The Annals of mathematical statistics*, 13
820 (1942) 215-232.

821 [33] C.W.M. Noor, R. Mamat, A.N. Ahmed, Comparative study of artificial neural network and
822 mathematical model on marine diesel engine performance prediction, *International Journal of*
823 *Innovative Computing, Information and Control* Volume 14, Issue 3, June 2018, Pages 959-969,
824 (2018).

825 [34] Ü. Ağbulut, M. Ayyıldız, S. Sarıdemir, Prediction of performance, combustion and emission
826 characteristics for a dual fuel diesel engine at varying injection pressures, *Energy*, (2020)
827 117257.

828 [35] B. Işcan, ANN modeling for justification of thermodynamic analysis of experimental
829 applications on combustion parameters of a diesel engine using diesel and safflower biodiesel
830 fuels, *Fuel*, 279 (2020) 118391.

831 [36] D. Hunter, H. Yu, M.S. Pukish III, J. Kolbusz, B.M. Wilamowski, Selection of proper neural
832 network sizes and architectures—A comparative study, *IEEE Transactions on Industrial*
833 *Informatics*, 8 (2012) 228-240.

834 [37] K.G. Sheela, S.N. Deepa, Review on methods to fix number of hidden neurons in neural
835 networks, *Mathematical problems in engineering*, 2013 (2013).

836 [38] T. O'Malley, E. Bursztejn, J. Long, F. Chollet, H. Jin, L. Invernizzi, Others, KerasTuner, in,
837 2019.

- 838 [39] D.P. Kingma, J. Ba, Adam: A method for stochastic optimization, arXiv preprint
839 arXiv:1412.6980, (2014).
- 840 [40] S. Ruder, An overview of gradient descent optimization algorithms, arXiv preprint
841 arXiv:1609.04747, (2016).
- 842 [41] X. Niu, C. Yang, H. Wang, Y. Wang, Investigation of ANN and SVM based on limited
843 samples for performance and emissions prediction of a CRDI-assisted marine diesel engine,
844 Applied Thermal Engineering, 111 (2017) 1353-1364.
- 845 [42] M. Issa, H. Ibrahim, H. Hosni, A. Ilinca, M. Rezkallah, Effects of low charge and
846 environmental conditions on diesel generators operation, Eng, 1 (2020) 137-152.
- 847 [43] D. Boullosa-Falces, J.L.L. Barrena, A. Lopez-Arraiza, J. Menendez, M.A.G. Solaetxe,
848 Monitoring of fuel oil process of marine diesel engine, Applied Thermal Engineering, 127
849 (2017) 517-526.
- 850 [44] S. Stoumpos, G. Theotokatos, A novel methodology for marine dual fuel engines sensors
851 diagnostics and health management, International Journal of Engine Research, (2021)
852 1468087421998635.
- 853 [45] H.M. Nahim, R. Younes, H. Shraim, M. Ouladsine, Modeling with fault integration of the
854 cooling and the lubricating systems in marine diesel engine: Experimental validation, IFAC-
855 PapersOnLine, 49 (2016) 570-575.
- 856 [46] M. Gholinia, M. Pourfallah, H. Chamani, Numerical investigation of heat transfers in the
857 water jacket of heavy duty diesel engine by considering boiling phenomenon, Case studies in
858 thermal engineering, 12 (2018) 497-509.
- 859 [47] J. Zhou, L. Xu, The fault diagnosis of marine engine cooling system based on artificial
860 neural network (ANN), in: 2010 The 2nd International Conference on Computer and
861 Automation Engineering (ICCAE), Vol. 2, IEEE, 2010, pp. 186-189.
- 862 [48] Y. Cay, A. Çiçek, F. Kara, S. Sağıroğlu, Prediction of engine performance for an alternative
863 fuel using artificial neural network, Applied Thermal Engineering, 37 (2012) 217-225.
- 864 [49] P. Hield, The effect of back pressure on the operation of a diesel engine, in, DEFENSE
865 SCIENCE AND TECHNOLOGY ORGANIZATION VICTORIA (AUSTRALIA) MARITIME ..., 2011.

866

867