



Evolución del apoyo logístico en la Armada mediante tecnologías 4.0

F. Lamas López

Alférez de Navío (Dr. Ing.), Armada española,
Arsenal de Cartagena
Centro de Supervisión y Análisis de Datos de la Armada
Cartagena, España

Resumen—La Armada Española se encuentra inmersa en la digitalización de sus procesos logísticos desde el diseño, construcción y ciclo de vida hasta el mantenimiento de sus unidades. Esto permitirá la automatización y predicción de las tareas de mantenimiento basado en la condición. El desarrollo de herramientas ligadas al mantenimiento predictivo estará centrado no solamente en los datos obtenidos en el CESADAR sino también por otros sistemas como los ligados al control de configuración de equipos embarcados. Este estudio exploratorio muestra como la información de ambos dominios, comportamiento mecánico y control de la configuración, deben ayudar a mejorar las predicciones de malfuncionamiento de un equipo. Para ello, se utilizan datos provenientes de dos motores propulsores de un buque generados desde el 2015 hasta el 2018. A partir de datos de comportamiento mecánico y análisis de los mismos pueden delimitarse modos de funcionamiento diferentes. Con estos registros y con ayuda de técnicas asociadas al aprendizaje automático, se pretende clasificar los diferentes modos de funcionamiento que afecten al normal mantenimiento de un propulsor antes de que ocurran. La predicción de distintos modos de funcionamiento de motores propulsores realizada en CESADAR-Central, puede ser de interés para las dotaciones de los buques en el caso de poder realizar las predicciones a bordo. Esto podría ayudar a prevenir modos de funcionamiento no deseados sobre los propulsores del buque durante sus operaciones. Se puede concluir que el uso de técnicas ligadas al aprendizaje automático es un método eficaz para la clasificación de patrones de un modo de comportamiento concreto. El uso de estas herramientas a bordo puede ayudar a prevenir modos de uso no deseados en tiempo real y debe ser una ayuda efectiva a la decisión de las dotaciones en operación.

Palabras Clave—mantenimiento predictivo, aprendizaje automático, ayuda a la decisión, redes neuronales, clasificación de patrones

I. INTRODUCCIÓN

La Armada española se encuentra inmersa en la digitalización de sus procesos logísticos. Eso incluye todo el ciclo de vida de las unidades, desde su diseño hasta su uso pasando por la producción de las mismas. Esto se encuadra en el concepto de Apoyo Logístico 4.0 (AL 4.0). Los sistemas deben de ser capaces de prever su malfuncionamiento y comenzar automáticamente a gestionar su recambio o mantenimiento. Con el principal objetivo de aumentar la seguridad a bordo y la calidad de las operaciones. La actual predicción de eventos se alimenta de datos aportados por el Sistema Integrado de Control de Plataforma (SICP). Estos son datos relativos a sensores instalados en los sistemas de plataforma del buque, registrados diariamente en los servidores del Centro de Supervisión y Análisis de Datos de la Armada (CESADAR) situado en Cartagena. El SICP es el

encargado a bordo de los buques de la supervisión y el control de los sistemas de maquinaria y componentes del buque. Los datos registrados por los sensores enlazados al SICP son transmitidos diariamente al CESADAR, recibiendo este diariamente datos de sistemas monitorizados de 29 buques de la Armada.

Desde los años 90 ha habido un incremento de las técnicas de Minería de Datos como medio para obtener nuevo conocimiento. Los retos asociados a la gestión de grandes volúmenes de datos empiezan a dividirse en subprocesos para hacer abordable la tarea de obtener conocimiento de ellos. Diferentes métodos de clasificación y de regresión pueden utilizarse principalmente para predecir estados futuros o para clasificar estados similares de comportamiento. Estos métodos son aplicados en la literatura sobre sistemas monitorizados para inferir modos de funcionamientos en los equipos y optimizar el mantenimiento. Estas técnicas conciernen la búsqueda de modos de fallo o identificación de nuevos parámetros a partir de datos registrados. Sin embargo, pese a la literatura existente sobre análisis de fallos en motores navales, aún no ha sido aún presentado un estudio básico sobre los parámetros mecánicos necesarios para predecir mediante técnicas asociadas a la IA (como las redes neuronales) la descompensación de funcionamiento entre los cilindros de un motor embarcado. Con este objetivo, se propone diseñar una solución con la que a partir de los datos registrados por el SICP, se pueda notificar a la dotación del comportamiento esperado de un motor en los próximos instantes. En este estudio se va a reducir el problema, haciendo hincapié en la escalabilidad de este método a otros aspectos del comportamiento del propulsor. Por lo tanto es necesario definir parámetros mecánicos como inputs y por otro lado evaluar la eficacia según el número de parámetros utilizados.

II. DEFINICIÓN DEL PROBLEMA

En los últimos meses se ha observado que tras un período de operación de un motor propulsor, si las temperaturas de sus cilindros estaban descompensadas respecto a la media de todos ellos, esto ha llevado a cabo en varias ocasiones a defectos en la combustión, falta de potencia e incluso podría haber sido originado por fallos en el inyector de un cilindro (atomizadoras). Todo dependía de en qué medida estaban descompensadas sus temperaturas respecto de la media. Debido a esto, en CESADAR se supervisa diariamente por un analista cada uno de los propulsores que han estado en operación durante las 24 horas precedentes al análisis visual de los datos. Si realmente es un malfuncionamiento que pueda dar un fallo inmediato de un componente, este debe ser detectado a bordo.

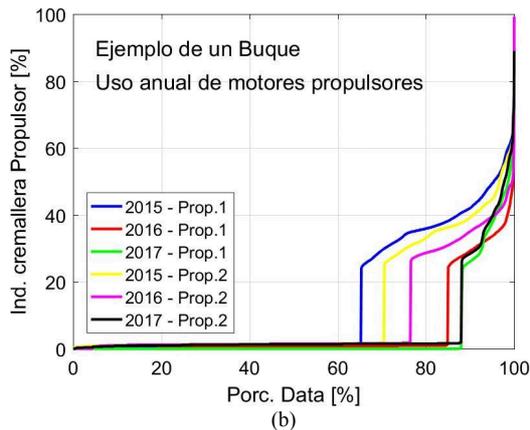
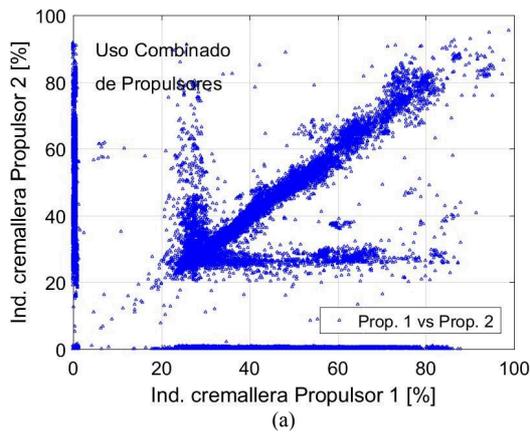


Fig. 1. (a) Uso combinado y (b) Uso anual en buque ejemplo de los propulsores 1 y 2 en el periodo 2015-2017

En este estudio se van a analizar datos de dos propulsores de un buque ejemplo entre el 2015 y el 2018. Los datos extraídos directamente del SICP, sin conversión alguna por el analista son: el Índice de Cremallera (IC), las revoluciones por minuto del propulsor (RPM), la temperatura media de las dos líneas de cilindros (\bar{T}), y la temperatura de gases de escape por cilindro T_i . Estos datos son registrados con una frecuencia de muestreo $f_s=6s$. En el conjunto de los cuatro años mencionados se han obtenido en torno a 8M de registros. En la Fig. 1a se expone el uso combinado de los dos propulsores. Se pueden distinguir principalmente tres modos de uso combinado cuando no están apagados ambos (0,0). El primer modo combinado conlleva utilizar solamente uno de los dos, pero siempre a partir del 30% del IC . Este índice representa la relación de potencia demandada al propulsor en porcentaje (%). En el segundo modo se aprecia que se utiliza uno de los propulsores con una relación de potencia (o IC) fija del 30% mientras que el otro puede funcionar con un IC del 30% al 100%. El último modo es el relativo a un uso de los dos propulsores a la misma relación de potencia, siempre mayor del 30%. Respecto al total de datos registrados, en la Fig. 1b se aprecia que hasta un 40% de los mismos representan tiempo de operación de los propulsores. Se puede describir que la mayor parte de operaciones de los propulsores se realizan con IC de entre 30% y 60%. En ellos se pueden apreciar un similar uso para un mismo año, y sus diferencias anuales de uso en este barco ejemplo en cuestión. Se aprecia igualmente en la Fig. 1b que la mayor parte del tiempo de operación ($TO>80\%$) se realiza entre el 30% y el 42% de IC . Sin embargo, la respuesta del propulsor ante un comando de IC concreto no se desarrolla siempre de la misma manera y depende múltiples factores externos como el escaramujo, lastres, etc (Fig. 2).

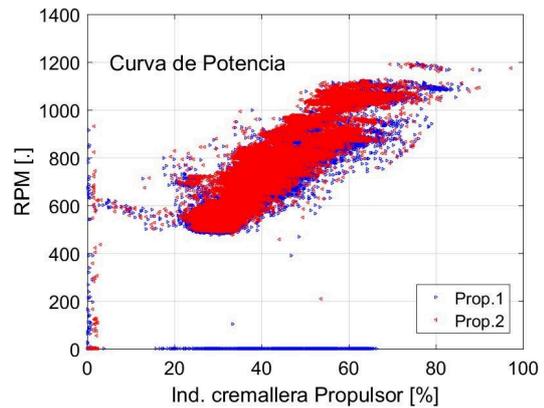


Fig. 2. IC vs RPM en buque ejemplo

Las RPM del motor van de 500 a 1200 RPM en el rango de tiempo representado en la Fig. 2. De entre las variables registradas por SICP de cada propulsor, hay una a la que se le presta especial atención diariamente, como indicador del correcto funcionamiento del mismo, esta es la temperatura de gases de escape de cada uno de los cilindros (T_i). El propulsor del buque ejemplo está compuesto por dos líneas (A y B) de 8 cilindros cada una. A partir de lo expuesto en la Fig. 3 se aprecia que el comportamiento de los cilindros adyacentes en cada una de las líneas evoluciona de forma análoga en el rango de temperaturas medias $\bar{T} > 250^\circ C$, $\bar{T}_{A,B}=(250, 250)$. Se deben tener en cuenta ambas líneas en los cálculos.

A mayor abundamiento, las temperaturas medias de gases de escape (\bar{T}) evolucionan de una forma cuasi-lineal y más homogénea a partir desde $IC=40\%$ (Fig. 4a). Se pueden distinguir dos regímenes de evolución de temperaturas medias en ambos propulsores, de $550^\circ C > \bar{T} > 300^\circ C$ para IC comprendidos entre 25 y 40 % y de $600^\circ C > \bar{T} > 550^\circ C$ para IC comprendidos entre 40 y 100 %. Para realizar una clasificación de modos, se va a utilizar un tercer parámetro, calculado a partir de las variables registradas, que pueda integrar el efecto de las anteriores, como en otros casos de clasificación de eventos. El parámetro, denominado desviación de temperaturas acumulada, que representa las diferencias absolutas de cada cilindro respecto a la media, se calcula según (1) y (2):

$$\Delta T_i = \text{ABS} \left(T_i - \frac{\sum_{i=1}^{16} T_i}{n} \right) = \text{ABS} (T_i - \bar{T}) \quad (1)$$

$$\left(\sum \Delta T_i \right) = \left(\sum_{i=1}^{16} \Delta T_i \right) \quad (2)$$

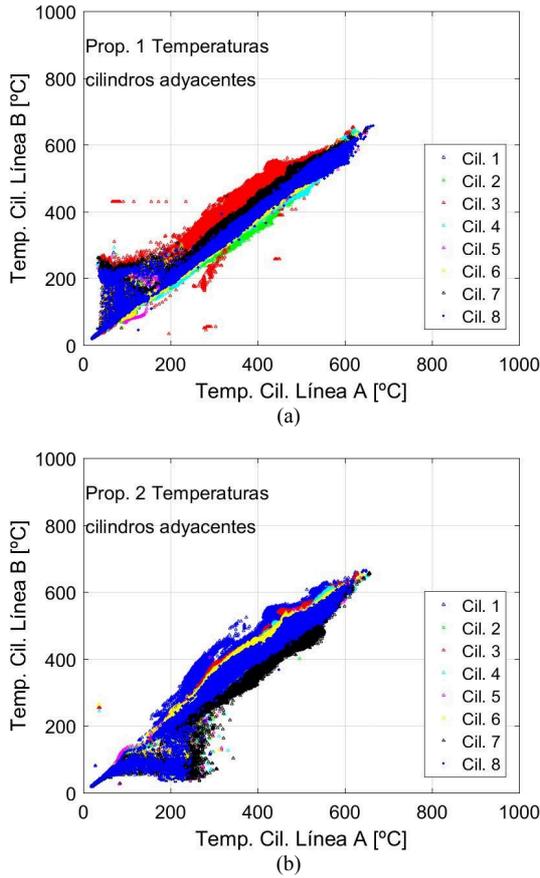


Fig. 3. Temp. de gases de escape en cilindros adyacentes (a) propulsor 1 y (b) propulsor 2

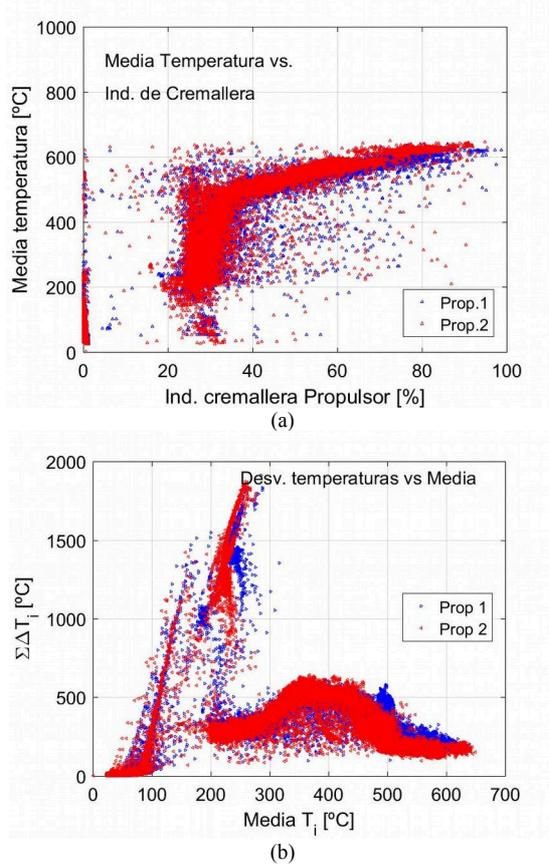


Fig. 4. (a) Media de temperaturas de gases de escape por cilindros vs. IC y (b) Desviación de temperaturas vs media de temperaturas en propulsores 1 y 2

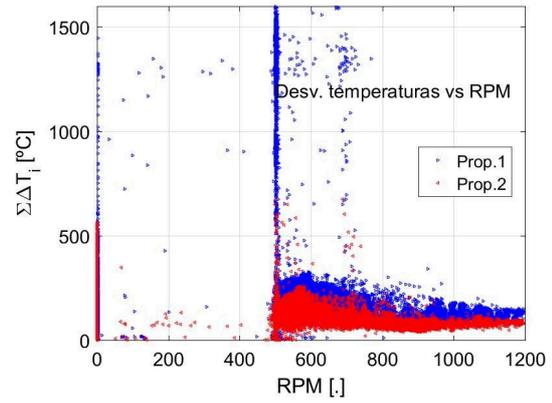


Fig. 5. Desviación de temperaturas vs RPM para los propulsores 1 y 2

Al representar la desviación de temperaturas acumulada respecto a la media (**Fig. 4b**), se observa un pico para temperaturas medias $\bar{T} > 250^{\circ}\text{C}$ que no se repite a lo largo del resto de temperaturas medias registradas en ambos propulsores. En mayores IC se comporta de forma más estable el motor. Hay un incremento no tan notable como en el rango de $250\text{-}300^{\circ}\text{C}$, cuando los cilindros del motor se encuentran en torno a 400°C de media. Este último caso, aún en la región inestable del motor, con $IC < 40\%$ (**Fig. 4a**). Gran parte de desviaciones de temperaturas se produce cuando el eje del propulsor está rotando a $RPM=500$, lo que suele estar aparejado a $IC \approx 30\%$ (**Fig. 5**).

III. RED NEURONAL DE CLASIFICACIÓN

La ciencia de datos es una rama de la inteligencia artificial (IA) en la cual se busca que un sistema sea capaz de aprender de datos que pueden ser usados para hacer predicciones y reconocer patrones de comportamiento. El aprendizaje de este sistema artificial puede ser supervisado según indicadores externos. Una red está formada por un conjunto de neuronas de entrada (donde se introducen los valores de los parámetros de entrada para cada medida), capas sucesivas de neuronas ocultas y una última capa de neuronas de salida. Cada conexión entre neuronas de capas adyacentes está ponderada por un peso y son activadas mediante un peso externo denominado umbral de activación. La función que aplica una neurona sobre los datos de entrada y los pesos se denomina función de transferencia y es no lineal., además toma su valor máximo cuando $x=0$. Los pesos que intervienen sobre cada conexión (ω_{ij} desde la neurona i en la capa anterior hasta la neurona j de la siguiente capa) son automáticamente ajustados iterativamente. El método utilizado, es una función de entrenamiento que actualiza los valores de peso acorde al gradiente escalado conjugado (*scaled conjugate gradient method*). Para las redes de clasificación habrá tantas neuronas de salida como posibles patrones de comportamiento se consideren. Como ejemplo para mostrar cómo se calibran los pesos asociados a cada par de neuronas, se tendrá en cuenta una red de 4 capas (una de entrada, dos ocultas y una de salida) para ver las expresiones en su forma desarrollada. En este método los pesos, ligando cada dos neuronas en capas adyacentes, se ajustan siguiendo la ecuación (3).

$$\frac{\partial y_i}{\partial \omega_{jk}^{(1)}} = x_j a_k^{(2)} (1 - a_k^{(2)}) \cdot \left[\sum_{p=1}^{n_3} \omega_{kp}^{(2)} a_p^{(2)} (1 - a_p^{(3)}) \omega_{pi}^{(3)} \right] \cdot y_i (1 - y_i) \quad (3)$$

El sumatorio de los productos indicados indica que hay que contemplar todos los caminos posibles desde la salida y_i hasta la neurona de entrada x_j . en este caso las entradas a la red se representan como x , y las salidas, o resultados, como y . Cada neurona tiene asociado además de un peso (que une dos neuronas de capas sucesivas), un umbral de activación. Si se realiza el diferencial respecto el umbral asociado a cada neurona de las capas ocultas (u_i), el resultado se muestra en la ecuación (4).

$$\frac{\partial y_i}{\partial u_i^{(2)}} = a_k^{(3)} (1 - a_k^{(3)}) \omega_k^{(3)} y_i (1 - y_i) \quad (4)$$

En cambio, si en vez de ser sobre el umbral, la diferencian de la expresión de salida y_i sobre el peso que une dos neuronas situadas entre la tercera y cuarta capa sería la mostrada en la ecuación (5).

$$\frac{\partial y_i}{\partial \omega_{jk}^{(2)}} = a_j^{(2)} a_k^{(3)} (1 - a_k^{(3)}) \omega_k^{(3)} y_i (1 - y_i) \quad (5)$$

El objetivo de las redes neuronales es calcular los pesos que ligan dos neuronas y los umbrales de activación, para converger hacia los resultados que se busquen en el menor número de iteraciones (épocas, *epochs*). La calidad de los pesos logrados se justifica mediante el error medio cuadrático de los resultados respecto a la salida deseada (*Mean Square Error, MSE*). El *MSE* entre el resultado obtenido y el resultado deseado se calcula mediante la expresión (4) siguiendo la regla de la cadena.

$$\frac{\partial e}{\partial \varepsilon} = \sum_{i=1}^{n(4)} \frac{\partial e}{\partial y_i} \cdot \frac{\partial y_i}{\partial \varepsilon} \quad (6)$$

Siendo e el error entre las soluciones esperadas y obtenidas. Simplificando y aplicando la regla de la cadena:

$$\frac{\partial e}{\partial y_i} = -(s_i - y_i) \quad \text{ya que} \quad e = \sum_{i=1}^{n(4)} \frac{1}{2} (s_i - y_i)^2 \quad (7)$$

Las iteraciones se detienen cuando se consigue un error mínimo tras seis iteraciones seguidas sin mejorar. El conjunto de datos con el que se persigue entrenar una red neuronal se divide en tres: entrenamiento, validación y test.

IV. MODOS DE FUNCIONAMIENTO Y EXPERIMENTACIÓN

Primeramente se han descartado todos los registros que corresponden a $IC < 10\%$ en los que el motor no está operando. Los registros restantes se han discretizado en 4 modos de funcionamiento, atendiendo a una distribución lo más regular (compensada) posible entre modos. Los registros utilizados en este punto corresponden a una frecuencia de muestreo $f_s = 1 \text{min}$, mayor respecto a la de registros brutos y reduciendo la redundancia de datos **Tabla 1**.

La distribución porcentual de valores de desviación de temperaturas respecto a la media se refleja en la **Fig. 6** los límites de los modos considerados en la **Tabla 1**. A partir de $\sum \Delta T_i = 600 \text{ }^\circ\text{C}$ ($\approx 2\%$ de los registros) hay un incremento notable de la tendencia de desviación de temperaturas, y presentan una mayor descompensación respecto a la media. El porcentaje de registros de este modo es estable para

todos los buques y años (en torno al 2%). Los otros 3 grupos de datos (MODO1, MODO2, y MODO3) presentan en torno al 33% de registros por cada uno, depende que propulsores (barco y año) tener en cuenta, pero la variabilidad es menor al $\pm 10\%$ respecto del tercio total de registros con los límites definidos. Esta repartición de registros se muestran en la **Fig. 7**.

Modo	Rango de $\sum \Delta T_i$ ($^\circ\text{C}$)
Modo1	$\sum \Delta T_i < 200 \text{ }^\circ\text{C}$
Modo2	$200 \text{ }^\circ\text{C} < \sum \Delta T_i < 300 \text{ }^\circ\text{C}$
Modo3	$300 \text{ }^\circ\text{C} < \sum \Delta T_i < 600 \text{ }^\circ\text{C}$
Modo4	$600 \text{ }^\circ\text{C} < \sum \Delta T_i$

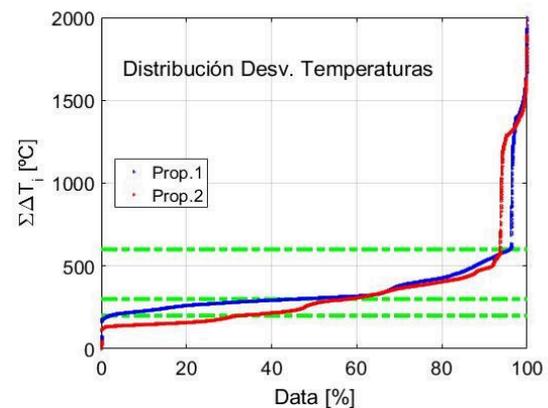


Fig. 6. Distribución de datos de desviación de temperaturas en buque ejemplo durante 1 año

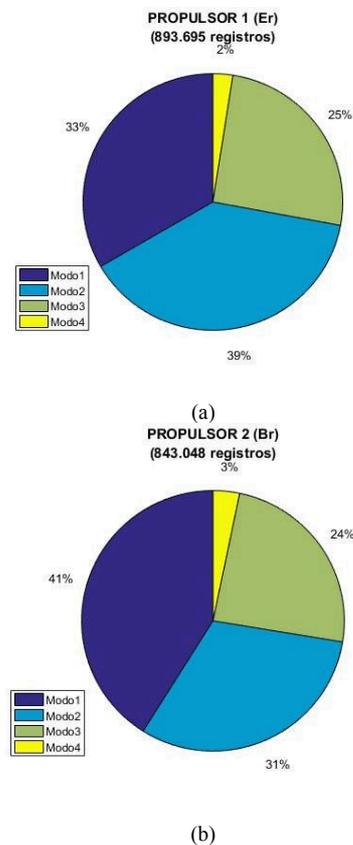


Fig. 7. Modos de funcionamiento registrados, durante funcionamiento, en tres buques equivalentes entre 2015-2018 en (a) propulsor 1-Estribor y (b) propulsor 2-Babor



El objetivo es crear una red capaz de clasificar los 4 modos de funcionamiento expuestos (Outputs), desde el más compensado (MODO1) hasta el más descompensado (MODO4), a partir de unos parámetros de entrada (Inputs). Se establecen 3 tipos de experimentos que se diferencian por el número de Inputs a tener en cuenta en cada uno de ellos, según lo descrito en la **Tabla 2**.

Conjuntos	Inputs (N)	Outputs	Número de registros
Primer experimento	\bar{T} , IC, RPM, $\Delta T\bar{i}$ (Línea A) (11)	4 Modos	163.597 (1 año) Buque ejemplo
Segundo experimento	\bar{T} , IC, RPM (3)		
Tercer experimento	\bar{T} , IC, RPM • (t-30min, t-60min) (9)		

En el primer experimento se tienen en cuenta 11 parámetros (diferencias de temperaturas sólo de cilindros de la línea A), en el segundo 3 parámetros y en el tercer experimento son 9 parámetros correspondientes a los 3 del segundo experimento más dos conjuntos más de los mismos, correspondientes a registros temporales 30 y 60 minutos precedentes a los del momento t en el que se quiere hacer la predicción.

La red neuronal diseñada tiene una capa oculta de 24 neuronas y una capa oculta de 24 neuronas para cada modo de funcionamiento considerado. Se utilizan el 65% de registros en fase de entrenamiento, el 20% en fase de validación y el 15% restante en fase de test.

V. RESULTADOS Y DISCUSIÓN

En el primer experimento, la tasa de verdaderos positivos para los 4 modos de funcionamiento es de en torno a 93,5% (**Tabla 3**), teniendo la red mayor facilidad de clasificar a los registros pertenecientes al MODO4 (98% de verdaderos positivos) que se supone como el más contraproducente para el correcto funcionamiento y desgaste del motor propulsor. En el segundo experimento se reducen drásticamente el número de parámetros de Input (hasta 3), ellos correlacionados positivamente entre sí (tras análisis PCA). En este experimento se observa una reducción de la tasa de verdaderos positivos hasta el 76% (**Tabla 3**) en cada una de las fases de entrenamiento, validación y test. Al contrario que en el primer experimento, aquí se aprecia una mayor tasa de falsos positivos entre los Modos opuestos MODO1 y MODO4, lo que resulta en un riesgo para poder predecir correctamente posibles estados no deseados del propulsor. Esta tasa de falsos positivos aumenta hasta el 61%. En lo que respecta al tercer experimento, aun sirviéndose de los mismos Inputs que el primero, este utiliza valores de los Inputs de registros realizados 30 y 60 minutos antes del momento en el que se pretende predecir el modo de funcionamiento del motor. El número total de parámetros de entrada es intermedio a los dos experimentos previos pero los resultados se aproximan bastante a los del primer experimento, obteniendo una tasa global de verdaderos positivos mayor al 92% (**Tabla 3**). El punto negativo de utilizar esta configuración de parámetros de entrada es la alta tasa de falsos positivos que presentan entre los modos de funcionamiento 1 y 4, mientras que entre los modos 2 y 3 se alcanzan tasas de verdaderos positivos muy altas.

Conjuntos	Entrenamiento	Validación	Test
Primer experimento	93.3%	93.4%	93.6%
Segundo experimento	76.0%	76.2%	76.5%
Tercer experimento	92.4%	92.6%	92.5%

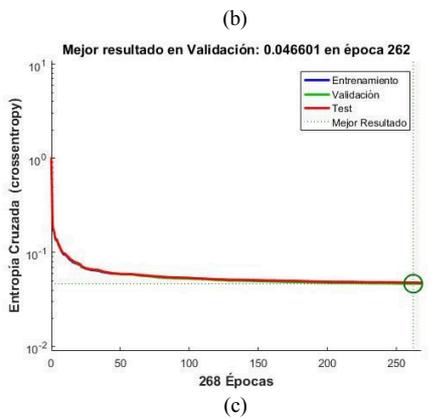
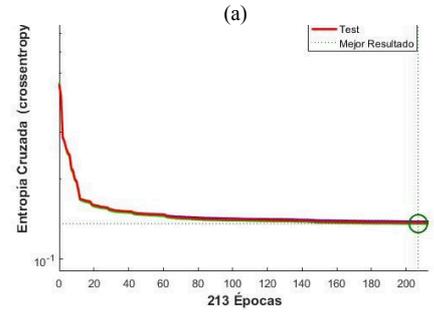
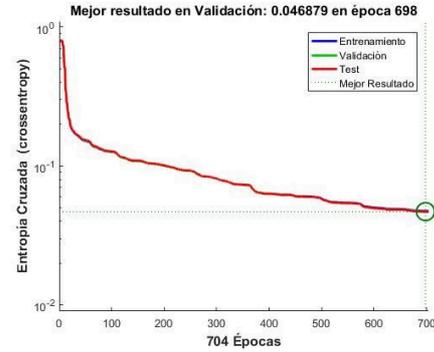


Fig. 8. Convergencia en validación para (a) primer, (b) segundo y (c) tercer experimento

Al analizar las curvas de aprendizaje obtenidas en los tres experimentos de forma conjunta, se puede apreciar las diferencias en la convergencia hacia la solución de error óptimo, siendo los errores finales obtenidos muy similares para los experimentos 1 y 3 (**Fig. 8**). Se converge más tarde cuando mayor número de parámetros Input se consideran (experimento 1). Esto se traduciría en el futuro en un mayor tiempo de computación para cada problema planteado.

VI. CONCLUSIONES Y PERSPECTIVAS

El análisis realizado muestra que los motores propulsores analizados son operados normalmente a una relación de potencia inferior a su capacidad máxima ($IC=30\%-42\%$ durante un tiempo de operación $TO>80\%$), lo que parece poder impactar sobre el comportamiento normal de sus componentes. Igualmente, se ha descrito un

modo de funcionamiento característico ($\approx 2\%$ de los registros totales en operación) a partir de una desviación acumulada de temperaturas sobre la media de $\sum \Delta T_i = 600^\circ\text{C}$, en la que aumenta de forma más notable este parámetro, indicador de descompensación en el comportamiento de los cilindros del propulsor. Mayores valores del parámetro $\sum \Delta T_i$ pueden desembocar en un funcionamiento no deseado del propulsor. En cuanto a los datos, los motores propulsores análogos, resultan en comportamientos y distribuciones análogas de sus modos de funcionamiento. Esto afianza la coherencia de los datos equivalentes para equipos análogos. Finalmente, se puede concluir que el uso de técnicas asociadas al aprendizaje automático para clasificación de eventos supone una herramienta útil de ayuda a la decisión para las dotaciones. Para un mejor conocimiento de los sistemas a mantener por la Armada española, es de capital importancia ligar datos mecánicos como los presentados en este estudio exploratorio a datos de configuración logística. Esto supondrá obtener capacidades para predecir patrones de comportamiento en elementos configurados o actores que participen en el apoyo logístico.

AGRADECIMIENTOS

Este estudio exploratorio se ha realizado en el marco del proyecto de *Apoyo Logístico 4.0* liderado por la Dirección de Sostentamiento (DISOS) de la Jefatura de Apoyo Logístico (JAL) de la Armada española. El autor quiere agradecer al CN D. Juan Díaz del Río Durán, CN D. Diego Carriazo Hernández y al resto de personal de CESADAR-Central, CF D. Fernando Escondrillas Gómez, SGT1 D. Francisco Preciado Conesa y OTA D. José Carlos García Pérez por su apoyo a la consecución de los resultados expresados en este estudio.

REFERENCIAS

- [1] J.D. González-Aller Lacalla and F. Lamas López, "Evolución del CESADAR 'Prediciendo el futuro, eficiencia en el sostenimiento, eficacia de la flota'" Rev. Gen. Mar. no. Agosto-Septiembre, p. 14, 2018.
- [2] F. Escondrillas and F. Lamas López, "Informe Estado General CESADAR 2018 (Informe Interno Confidencial ARMADA)," Cartagena, 2018.
- [3] U. Fayyad, G. P. Shapiro, and P. Smyth, "From Data Mining to Knowledge Discovery in Databases," AI Mag. Am. Assoc. Artif. Intell., no. Fall, p. 18, 1996.
- [4] R. Brachman and T. Anand, "The Process of Knowledge Discovery in Databases: A Human-Centered Approach," Adv. Knowl. Discov. Data Min., pp. 37–58, 1996.
- [5] C. Wang, "Embedded Sensing for Online Bearing Condition Monitoring and Diagnosis," University of Massachusetts, Amherst, MA, 2001.
- [6] P. W. Tse and D. P. Atherton, "Prediction of Machine Deterioration Using Vibration Based Fault Trends and Recurrent Neural Networks," J. Vib. Acoust., vol. 121, no. July, pp. 355–362, 1999.
- [7] H. Taplak, I. Uzmay, and S. Yildirin, "Design of artificial neural networks for rotor dynamics analysis of rotating machine systems," J. Sci. Ind. Res., vol. 64, no. June, pp. 411–419, 2005.
- [8] Y. Shao and K. Nezu, "Prognosis of remaining bearing life using neural networks," J. Syst. Control Eng., vol. 214, no. 3, pp. 217–230, 2000.
- [9] Y. Y. Liu, Y. F. Ju, C. D. Duan, and X. F. Zhao, "Structure damage diagnosis using neural network and feature fusion," Eng. Appl. Artif. Intell., vol. 24, pp. 87–92, 2011.
- [10] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, and D. J. Inman, "Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks," J. Sound Vib., p. 17, 2016.
- [11] M. S. Hossain, O. Z. Chao, Z. Ismail, S. Noroozi, and K. S. Yee, "Artificial Neural Networks for Vibration Based Inverse Parametric Identifications: A Review," Appl. Soft Comput., 2017.
- [12] F. Lamas-Lopez, "Field and laboratory investigation on the dynamic behavior of conventional railway track-bed materials in the context of traffic upgrade," Ecole Nationale des Ponts et Chaussées, 2016.
- [13] F. Lamas López, J. M. Riola Rodríguez, and J. D. González-Aller Lacalle, "La aplicación de Inteligencia Artificial (IA) en industria 4.0: mantenimiento predictivo de equipos embarcados," in 56o congreso del colegio de Ingenieros Navales y Oceánicos., 2017, p. 11.
- [14] C. Sharma, "Big data analytics using neural networks," San José State University, 2014.
- [15] M. Sánchez-Montañés, L. Lago, and A. González, "Métodos avanzados en aprendizaje artificial: Teoría y aplicaciones a problemas de predicción," Madrid, 2014.
- [16] Y. Saad, Iterative methods for sparse linear systems, vol. 3, no. 4. Philadelphia: Society for Industrial and Applied Mathematics, 2000.