

# Aplicación de herramientas de Inteligencia Artificial para la optimización frente al gripado del contenido de aditivos FM, EP y AW en un lubricante

Rafael Wilmer Contreras Urgiles<sup>1</sup>, Enrique Chacón Tanarro<sup>2</sup>, Javier Echávarri Otero<sup>3</sup>

<sup>1</sup>Grupo de investigación en Ingeniería de Máquinas, Universidad Politécnica de Madrid, España. Email: [rw.contreras@alumnos.upm.es](mailto:rw.contreras@alumnos.upm.es)

<sup>2</sup>Grupo de investigación en Ingeniería de Máquinas, Universidad Politécnica de Madrid, España. Email: [e.chacon@upm.es](mailto:e.chacon@upm.es)

<sup>3</sup>Grupo de investigación en Ingeniería de Máquinas, Universidad Politécnica de Madrid, España. Email: [javier.echavari@upm.es](mailto:javier.echavari@upm.es)

## Resumen

Este trabajo presenta una metodología para correlacionar la concentración de aditivos modificadores de fricción (FM), extrema presión (EP) y anti desgaste (AW) en un lubricante con su comportamiento de fricción en un ensayo de scuffing mediante el uso de herramientas de Inteligencia Artificial (IA). Para ello, se ha integrado una gran cantidad de información procedente de estudios experimentales previos sobre scuffing y valores propios experimentales de fricción, obtenidos en una Mini-Máquina de Tracción (MTM), con aceites que contienen diferentes concentraciones de aditivos. Con la información seleccionada se ha contrastado la eficacia y fiabilidad de la predicción con dos herramientas de IA: RNA (Red Neuronal Artificial) y SVM (Máquina de Soporte Vectorial). Los parámetros de creación y entrenamiento de las herramientas se han seleccionado de forma que se obtenga un valor de correlación que supere el 98 % para ambos casos. Posteriormente, en una segunda fase, se aplica la predicción de la concentración óptima de aditivo del lubricante que mejora la resistencia del lubricante al scuffing.

**Palabras clave:** aditivos FM, AW y EP, gripado, Inteligencia Artificial, Lubricación.

## Abstract

This paper presents a methodology to correlate the concentration of friction modifier (FM), extreme pressure (EP) and anti-wear (AW) additives in a lubricant with its friction behavior in a scuffing test by using Artificial Intelligence (AI) tools. For this purpose, we have integrated a large amount of information from previous experimental studies on scuffing and our own experimental friction values obtained in a Mini-Traction Machine (MTM) with oils containing different concentrations of additives. With the selected information, the efficiency and reliability of the prediction has been contrasted with two AI tools: ANN (Artificial Neural Network) and SVM (Support Vector Machine). The creation and training parameters of the tools have been selected in such a way as to obtain a correlation value exceeding 98% for both cases. Subsequently, in a second phase, the prediction of the optimum concentration of lubricant additive that improves the lubricant's resistance to scuffing was applied.

**Keywords:** FM, AW and EP additives, scuffing, Artificial Intelligence, Lubrication.

## 1. Introducción

La presencia de aditivos modificadores de fricción (FM), extrema presión (EP) y anti desgaste (AW) en un lubricante tiene un gran efecto sobre la fricción de los contactos mecánicos en régimen de lubricación mixta y límite. Cuando las condiciones de funcionamiento del contacto se vuelven muy extremas (presión, temperatura y gradiente de cizalladura), se puede llegar a producir el fenómeno de gripado de las superficies por la pérdida de la acción protectora del conjunto de dichos aditivos [1].

Estudios previos han analizado, desde un enfoque puramente experimental, la influencia de distintas configuraciones de contacto, condiciones de funcionamiento y lubricantes (base y aditivos) sobre el gripado [2, 3, 4]. La presencia de un elevado número de variables involucradas en el fenómeno dificulta el desarrollo de modelos analíticos que permitan definir la configuración óptima del lubricante para mejorar su resistencia al gripado sin la realización de nuevos ensayos experimentales. En este campo existe un importante interés científico por lograr configurar la formulación óptima de la base y los aditivos [5, 6] de un lubricante que proteja el contacto frente a este fallo. Esta tarea resulta especialmente complicada como consecuencia de las complejas interacciones químicas que se producen entre los aditivos. Estas reacciones son a su vez dependientes de su concentración en la solución y las condiciones (presión, temperatura o gradiente de cizalladura) que tienen lugar en el contacto lubricado.

Para la resolución de este tipo de problemáticas, algunos autores han recurrido en la actualidad a la aplicación de herramientas de Inteligencia Artificial (IA) en el estudio del comportamiento de los contactos lubricados [7, 8]. En 2019 se ha aplicado la herramienta de IA tipo RNA (Red Neuronal Artificial) para el estudio del comportamiento del coeficiente de fricción (COF) y su relación con la tasa de desgaste [9], tanto en engranajes [10], como en recubrimientos de superficies con diferentes materiales [11, 12]. También se han desarrollado sistemas de RNA para diseñar nuevos lubricantes y reducir el desgaste superficial [13] y COF, tanto para aceites bases como aditivados [14]. En el mismo año se ha entrenado una RNA que ha permitido predecir la viscosidad dinámica de lubricantes bases, a partir de valores experimentales de viscosidad tomados en un reómetro rotacional (MCR 702), obteniendo un error de 0,98% [15]. Con respecto a la optimización de aditivos en lubricantes, en [16], se ha aplicado una metodología de optimización con dos etapas. En la primera se ha empleado una RNA para estudiar el efecto de diferentes concentraciones de aditivos en el COF mientras que en la segunda se han simulado nuevas concentraciones determinadas por un algoritmo genético, del cual ha concluido que una adecuada proporción de FM es responsable de una reducción en el COF. En la misma línea y en 2020, se han continuado desarrollando los procedimientos de

optimización de la fricción y el desgaste con variaciones de la metodología presentada en [16]. Estas modificaciones se han centrado principalmente en la simulación de nuevas concentraciones determinadas por un sistema de toma de decisiones multicriterio, basadas en valores objetivo asignados por expertos. Por ejemplo, se ha determinado que una alta concentración de glicerol en lubricante vegetal es beneficiosa para las propiedades tribológicas del lubricante como la disminución del COF [17]. En la misma línea se han implementado algoritmos de retro propagación para investigar el efecto de un lubricante con aditivo tipo polytetrafluorethylene sobre el comportamiento de fricción en un cojinete a presión constante. En este trabajo se ha estimado que un aumento del 10 al 15% de este aditivo indicaba una tendencia más baja del COF [18].

En 2021 se ha propuesto una metodología, apoyada en algoritmos de aprendizaje automático ML (Machine Learning), capaz de diferenciar los regímenes de desgaste mediante señales de emisión acústica, consiguiendo una precisión de identificación del 97 % [19]. Ya en 2022, se ha desarrollado un modelo que permite clasificar los mecanismos de desgaste a partir de imágenes SEM y RNA, obteniendo una precisión de alrededor del 98% para los datos de entrenamiento, en torno al 72% para los datos de validación y alrededor del 73% para los datos de prueba [20]. En el mismo año se ha establecido un método de aprendizaje automático para diseñar recubrimientos de carbono amorfo, con el empleo de regresiones de proceso gaussiano, regresiones polinomiales, máquinas de soporte vectorial (SVM) y RNA, obteniendo precisiones de hasta 78% para la optimización de superficies [21]. En [22] se han resumido las investigaciones que destacan las aplicaciones de ML e AI en el ámbito de los materiales compuestos, la tecnología de fabricación, ingeniería de superficies, formulación de lubricantes y diversas áreas de la tribología.

Tal y como se ha introducido anteriormente, las herramientas de IA han sido aplicadas exitosamente en el estudio de COF [8] y la tasa de desgaste [10] en los contactos tribológicos, así como en el desarrollo de lubricantes [12] y la optimización de sus aditivos [17]. Continuando con estas investigaciones, este trabajo presenta una metodología que permite correlacionar mediante las herramientas de IA la concentración de aditivos FM, EP y AW de un lubricante con el comportamiento de su fricción en un ensayo de gripado. Una vez desarrollada y validada la herramienta, se ha aplicado en una segunda fase, la predicción de la concentración óptima de aditivos de un lubricante que mejora su resistencia frente al fenómeno de gripado. Esta aplicación constituye una aproximación al estudio de

la influencia de la tipología de aditivos y su concentración en el comportamiento del fenómeno del gripado. La comparación de diferentes aditivos del mismo tipo, aunque fuera del alcance de este estudio, constituye un reto futuro para el planteamiento mejorado del estudio.

## 2. Metodología

Cuando las condiciones de funcionamiento de un contacto lubricado se vuelven muy extremas, se puede llegar a producir el fenómeno de gripado de las superficies. Este fenómeno se produce por la pérdida de espesor de película lubricante y de la acción protectora del conjunto de aditivos. El gripado se caracteriza por un incremento brusco de la fricción previo al fallo completo [2, 3]. Las variables más influyentes [2, 3] sobre el gripado son la presión de Hertz ( $p_0$ ) (GPa), la velocidad media ( $U_m$ ) (mm/s), la velocidad de deslizamiento ( $U_s$ ) (mm/s) y la rugosidad combinada de las superficies ( $Ra$ ) (nm). Para identificar el gripado se considera representativa la velocidad  $U_s$  correspondiente a un valor de COF superior a 0.2 para cada ensayo gripado [2, 3]. El conjunto de los valores de estas variables representa la matriz de entrada de datos en este procedimiento. Otros parámetros del ensayo, como son la temperatura de baño ( $T_b$ ) (°C) y el material de probetas, son iguales en todos los casos.

Con respecto al lubricante, los parámetros principales son la viscosidad a la temperatura de baño ( $KV$ ) (cSt) y la cantidad de aditivos (wt%) FM, EP y AW. Entre estos parámetros, la viscosidad es la única que es empleada como dato de entrada. Los parámetros restantes, cantidad de aditivos de FM, EP y AW, forman parte de la matriz objetivo para el entrenamiento en las herramientas de IA. En este estudio se desprecia la influencia de otras propiedades del lubricante.

Definidas las matrices de entrada y objetivo se procesan en dos herramientas de IA como son las RNA y SVM en una primera fase. Se aplican estas dos herramientas con el fin de poder contrastar los resultados obtenidos de ambas.


Para establecer los parámetros de creación y entrenamiento de la RNA se siguen las indicaciones planteadas en otros trabajos [9, 12, 23] sobre el número de capas ocultas, número de neuronas, funciones de transferencia, algoritmo de entrenamiento, que permiten obtener una predicción más precisa. Para esta investigación se ha buscado una precisión mayor al 98 %, al igual que en otros trabajos similares [19]. Con la herramienta SVM se ha procedido de la misma manera, es decir, se han seleccionado los parámetros Kernel, función de entrenamiento, orden del polinomio de entrenamiento, BoxConstrain, y KFold para obtener una precisión similar.

Una vez ajustadas, validadas y comparadas ambas herramientas IA, en una segunda fase de este trabajo se ha buscado optimizar la concentración de aditivos del lubricante que mejora su resistencia en un ensayo de gripado. En los ensayos de gripado más comunes se aplican unas condiciones constantes de funcionamiento en un tribómetro, aplicando un incremento escalonado de la velocidad de deslizamiento hasta llegar al fallo. En este trabajo se ha aplicado la mejor herramienta detectada en la primera fase para establecer una metodología que permite identificar las concentraciones óptimas de FM, EP y AW que mejoran la resistencia de un lubricante en este tipo de ensayos.

### 2.1. Recopilación de datos de ensayos de gripado

En este estudio se ha realizado una recopilación de las condiciones de los experimentos y lubricantes ensayados en pruebas de gripado de otros estudios previos. Hacen un total de 48 [2], 51 [3], 12 [4] ensayos. A estas se ha adicionado 32 ensayos ejecutados por este equipo investigador, haciendo un número total de 143 pruebas.

Los ensayos propios de scuffing se han llevado a cabo en el tribómetro MTM de PCS Instruments, con dos tipos de especímenes superiores tipo bola y barril sobre disco. Todos ellos están fabricados en acero AISI 52100. La Figura 1 muestra los contactos lubricados bola-disco y barril-disco en la MTM. La bola tiene un radio de 9.525 mm y el barril tiene radios de 9.525 y 1 mm en dirección del movimiento y dirección transversal, respectivamente. La rugosidad  $Ra$  de bola es menor de 25 nm, la del barril menor de 15 nm y la del disco menor de 10 nm [2, 24], con módulo de elasticidad de 210 GPa y un coeficiente de Poisson de 0.3.




**Figura 1.** Especímenes superiores de contacto para ensayo tribológico, a) bola-disco, b) barril-disco. Fuente: Elaboración propia.

Para la obtención del COF con el barril, se ha desarrollado un procedimiento experimental en dos etapas. La primera de ellas, denominada run-in, se lleva a cabo con unas condiciones constantes de  $T_b = 120$  °C,  $p_0 = 1.98$  GPa,  $U_m = 3$  mm/s,  $U_s = 10$  mm/s

durante 600 s. La segunda etapa es propiamente la del ensayo de scuffing, con  $T_b = 120^\circ\text{C}$ ,  $p_0 = 2.7 \text{ GPa}$ ,  $U_m = 10 \text{ mm/s}$ , con aumentos escalonados de  $U_s$  de 50 mm/s. Cada escalón a  $U_s$  constante tiene una duración de 30 s entre escalón y escalón.

Para la obtención del COF con la bola, las condiciones aplicadas en los ensayos son de  $p_0 = 0.83 \text{ GPa}$  en el run-in y  $p_0 = 1.04 \text{ GPa}$  en el ensayo, manteniéndose igual el resto de parámetros respecto al ensayo con el barril.

La Figura 2 presenta el comportamiento del COF con un lubricante al aplicar la metodología propuesta con un contacto barril-disco. A partir del segundo 600 se observa representado en la Figura el incremento escalonado de  $U_s$ , asociado a su efecto sobre el COF. También se puede ver como en el entorno de los valores de COF de 0.2 la fricción aumenta fuertemente, síntoma de la aparición del gripado.



**Figura 2.** Resultado de fricción en ensayo con espécimen superior tipo barril-disco en un lubricante. Fuente: Elaboración propia.

En el run-in de la Figura 2 el COF disminuye hasta estabilizarse. Esta estabilización se atribuye al pulido de las superficies en contacto. Tras el run-in se observa como el COF se mantiene estable en los primeros escalones. Posteriormente, ya con altos valores de  $U_s$ , se identifica el incremento brusco del COF con  $U_s$  hasta alcanzar el gripado.

## 2.2. Lubricantes de estudio

Los lubricantes recopilados de la bibliografía son bases y aceites aditivados. Las bases corresponden a SN150, Nexbase 3043, PAO 4, cuyas características principales se detallan en [2, 3]. Los lubricantes con aditivo pertenecen, por una parte, a las bases anteriores adicionadas con diferentes contenidos de FM o EP, siendo Nexbase3043 + FM, SN150 + EP [2, 3]. Por otra parte, se incluyen lubricantes industriales terminados como lubricante mineral para motor SAE 40; lubricante mineral para engranajes ISO VG 150 y lubricante sintético para engranaje, Grupo V, EAL ISO VG 150 [4].

Con respecto a las características de los lubricantes aplicados en la experimentación propia, sus principales valores y rangos característicos se resumen en la Tabla 1.

**Tabla 1.** Lubricantes ensayados.

Denominación	KV*				
	120°C (cSt)	Base (wt%)	FM (wt%)	EP (wt%)	AW (wt%)
Nexbase 3043	3.09	100	0	0	0
PAO 4	2.9	100	0	0	0
Lubricantes aditivados	6-23	93-98	0-1.6	0-2	0-3.9

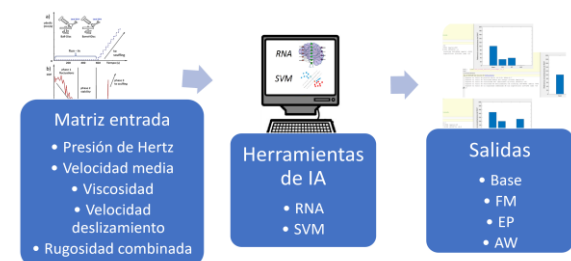
\*Calculada según ASTM D341

Fuente: Elaboración propia.

## 2.3. Metodología con las herramientas de inteligencia artificial

Cuando el objetivo de las herramientas de IA consiste en aprender la correspondencia entre una matriz de entrada (datos de entrenamiento) y un vector o matriz de salida (datos objetivos) se trata de un aprendizaje supervisado [7]. En este trabajo se desarrolla un aprendizaje supervisado empleando dos herramientas de IA como son RNA y SVM.

Con ambas herramientas se aplica la metodología esquematizada en la Figura 3. El procedimiento comienza generando la matriz de entrada (cinco variables ya definidas en la sección 2), que posteriormente se procesa con las herramientas de aprendizaje supervisado mencionadas. Tras este procesamiento, se analiza la configuración y el grado de precisión de los resultados con los datos de la matriz objetivo. Desarrollada la configuración de las herramientas que proporcionen la precisión de 98 %, se continúa con la etapa de aplicación. En esta final se introducen otros valores de entrada, distintos a los empleados para el aprendizaje, y sus valores correspondientes de la matriz de salida. Por último, se comparan los valores predichos por la herramienta y los experimentales, obteniendo los porcentajes de error en la predicción.



**Figura 3.** Metodología de IA para determinación de aditivos. Fuente: Elaboración propia.

### 2.3.1. Herramienta RNA

Una herramienta destacada de IA es el uso de redes neuronales artificiales (RNA) [7]. Estas redes se fundamentan en la red de neuronas del cerebro humano, con capacidad para "aprender" de forma similar. Una RNA está formada por una red de neuronas modelo, que pueden utilizar algoritmos para hacerlas funcionar como las neuronas biológicas.

En este contexto, cada neurona modelo tiene un umbral. Las neuronas modelo pueden recibir varias entradas diferentes, que se suman y envían una salida igual a 1, si la suma es mayor que el umbral. En caso contrario, la salida es 0. Las RNA son capaces de aprender modificando los umbrales de cada neurona modelo cuando se introduce un nuevo ejemplo. Esto sucede hasta que los umbrales llegan a un punto en el que su variación es mínima. En el campo de la tribología, las RNA han sido aplicadas para predecir el COF [8], optimizar compuestos [6], estudiar rugosidades de superficie [21].

De acuerdo con la metodología planteada en la Figura 3, una vez determinadas las entradas y salidas, se procede a la creación y entrenamiento de la RNA. Para su creación se ha tenido en cuenta las configuraciones más comunes propuestas en la literatura: feed-forward backpropagation network (Newff), cascade-forward backpropagation network (Newcf) y Elman backpropagation network (Newelm) [22]. Respecto al número de capas de la RNA, se ha probado empezando con dos capas para ir aumentando hasta cuatro posteriormente según la complejidad del modelo y la precisión del resultado objetivo. Hay que tener en cuenta que, al aumentar el número de capas, también lo hace la demanda computacional. Dentro de cada capa, están las neuronas. Idéntico al caso de las capas, mientras más neuronas se aplique por capa, aumentará la demanda computacional. Con respecto a las funciones de transferencia que se encuentran entre capas, las más comunes son de tipo Logsig, Tansig, Ellipsig, y Purelin [22, 23]. De estas, se ha optado por aplicar las de Tansig y Ellipsig debido a su rapidez de cálculo ya que no requieren de funciones exponenciales o trigonométricas. En su contra, requieren de más neuronas y épocas para lograr una alta precisión.

Una vez creadas las RNA, se han seleccionado de la matriz de entrada el 70% de datos para entrenamiento, el 15% para validación y el 15% para prueba. Estos porcentajes son comúnmente utilizados en estudios semejantes [22] y han presentado buenos resultados. Se ha entrenado la RNA con la función de tipo 'trainsg' [7], que actualiza por cada época de entrenamiento los valores de peso y sesgo, según el método del gradiente conjugado escalado.

### 2.3.2. Herramienta SVM

Además de las RNA, las herramientas de tipo SVM también han sido aplicadas para estudiar fenómenos tribológicos [22].

Esta herramienta representa un conjunto conocido de datos en un vector de un espacio vectorial. Cuando se adicionan más conjuntos y con el fin de identificarlos, se introducen hiperplanos entre los conjuntos de datos. En la mayoría de los casos, se identifica el subconjunto de datos que se encuentra en los límites de los planos. Identificados estos límites, cuando se ingresan nuevos datos, estos se pueden clasificar. Para tener en cuenta los límites no lineales, las funciones Kernel son una parte esencial de la SVM. Utilizando el efecto del Kernel, el espacio vectorial se transforma en un espacio de dimensiones superiores, de modo que los conjuntos de vectores y subconjuntos de datos en esta dimensión son separables.

En este trabajo los conjuntos de datos conocidos son las variables ya definidas en la Figura 3. Con respecto a los parámetros de configuración de la SVM, el valor de escala de Kernel es un valor escalar positivo [25], que en el software de programación (Matlab), se coloca por defecto el valor de uno. Esta investigación ha empezado por el valor de defecto y luego se ha disminuido hasta 0.2. Además del valor de escala de Kernel, está el tipo de función de Kernel. Esta puede ser de tipo lineal, polinomial o gaussiana. La aplicación del tipo de función dependerá de la forma del campo vectorial donde se ubican los valores de clasificación. Si se selecciona la función polinomial, también se debe indicar el orden del polinomio, que en este caso es de orden dos. Con respecto al parámetro de BoxConstrain, este contribuye en la regularización de los datos y evita el sobreajuste de la SVM. Este valor por defecto es uno. Sin embargo, cuando este valor se disminuye, el tiempo de entrenamiento y gasto computacional aumenta. Para esta investigación se ha aplicado el valor por defecto. Con respecto al entrenamiento y validación cruzada de resultados, el valor de KFold ha sido programado. Este valor corresponde al número de divisiones del conjunto de datos de entrada, con los que se han validado los resultados. Por defecto en software de programación es uno, sin embargo, en esta trabajo se han programado desde uno a cinco.


## 3. Resultados

### 3.1. RNA

Como resultado de las diferentes configuraciones indicadas en la sección 2.3.1 de este trabajo, para alcanzar la precisión de 98% con el menor tiempo de

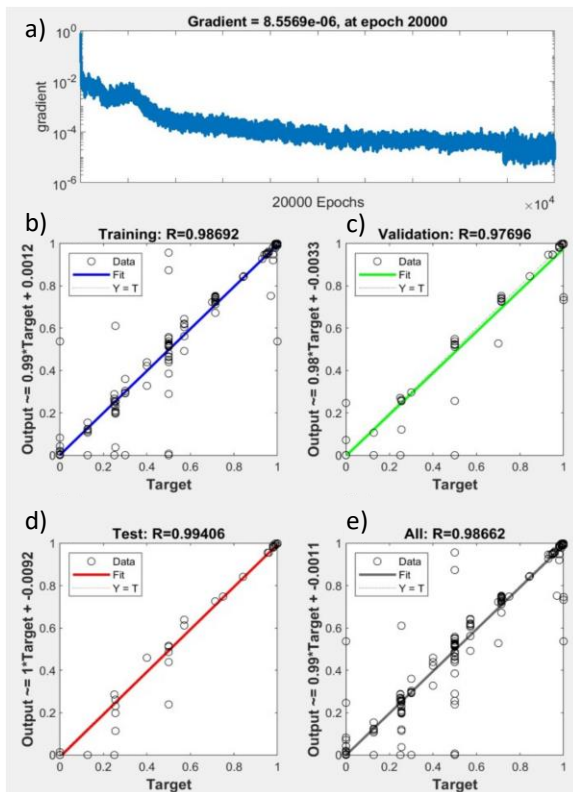
cálculo computacional, se ha determinado que la configuración óptima se consigue con Newff. Esta red cuenta con 4 capas ocultas y 1 para la salida, con 20, 40, 80 y 160 neuronas por cada capa.

La función de transferencia entre las tres primeras capas ocultas ha sido Elliottsig y las siguientes Tansig. El entrenamiento se ha realizado con 'trainscg'. Esta configuración, representada esquemáticamente en la Figura 4, resulta la mejor. Se han obtenido precisiones para, Base=99.78%, FM=99.98%, EP=99.92% y AW=99.93%. Estos resultados son positivos con una alta correlación, superior a los 98% planteados.



**Figura 4.** Configuración de RNA tipo Newff. Fuente: Elaboración propia.

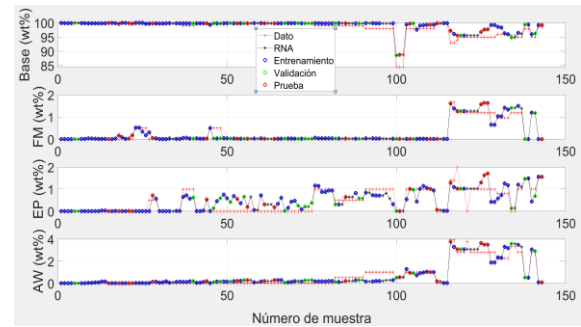
En la Figura 5a se observa la disminución exponencial del error con el número de épocas de entrenamiento. Esta disminución concuerda con la alta precisión de clasificación de la RNA. Las regresiones de selección de datos para entrenamiento (Figura 5b), validación (Figura 5c) y prueba (Figura 5d), garantizan el rendimiento y fiabilidad de la predicción con un coeficiente de determinación R entorno al 0.98 para todos los casos (Figura 5e).



**Figura 5.** Gradiente de error para RNA tipo feed-forward backpropagation network (Newff). Fuente: Elaboración propia.

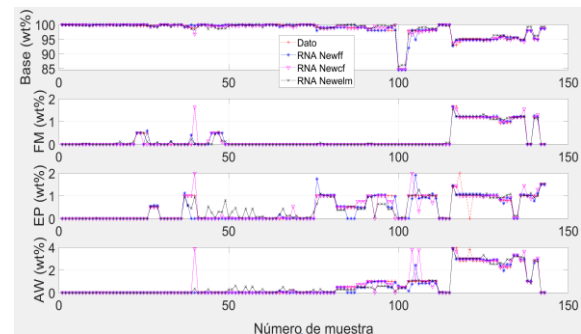
Las predicciones de los aditivos de la RNA Newff se muestran en la Figura 6. Los puntos con círculos en verde y rojo identifican los resultados para los datos de validación y prueba. Estos datos no fueron parte del entrenamiento de la RNA, sin embargo, sus resultados de predicción son comparables a los de entrenamiento.

Las mejores predicciones obtenidas son para los aditivos FM. Este aditivo estudiado en [13] también presenta una alta correlación. Respecto a los aditivos AW y EP, existen puntos que distan del modelo, como las muestras 49, 76 y 127. Este comportamiento se justifica con la existencia de puntos alejados de la línea de correlación en la regresión de validación de la Figura 5c. Pese a estas discrepancias, los valores de R son parecidos a los de otros estudios similares [6, 22].



**Figura 6.** Resultados de RNA tipo feed-forward backpropagation network (Newff). Fuente: Elaboración propia.

La configuración de los parámetros de la RNA con Newff igualmente se aplicó con Newcfc y Newelm. Su aplicación también presenta una gran similitud en los resultados, especialmente para la FM, tal y como se observa en la Figura 7, comparables con la Figura 6.



**Figura 7.** Comparativa general de resultados para Newff, Newcfc y Newelm. Fuente: Elaboración propia.

### 3.2. SVM

Como ya se ha mencionado en la sección 2.3, con el fin de contrastar la fiabilidad de los resultados obtenidos por las RNA se aplica la herramienta de SVM. Las características de creación y entrenamiento para SVM son, Kernel = 0.2, Function = Polynomial, Order = 2, BoxConstrain = 1 y KFold = 5. Estas características fueron seleccionadas tras diferentes combinaciones, manteniendo el objetivo de obtener la precisión de 98% en los resultados. Se obtuvieron unas precisiones para, Base=99.93 %, FM=99.99 %, EP=99.92 % y AW=99.93 %. Los resultados de la Figura 8 demuestran que la precisión en la predicción es mayor al 98 %, que es comparable con [5, 18]. Visto en la comparativa de las precisiones en la Figura 9, se define la fiabilidad y validez de las herramientas ya que superan el 98 % de precisión.

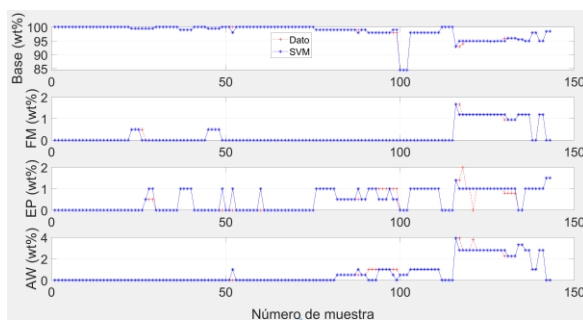


Figura 8. Resultados de SVM. Fuente: Elaboración propia.

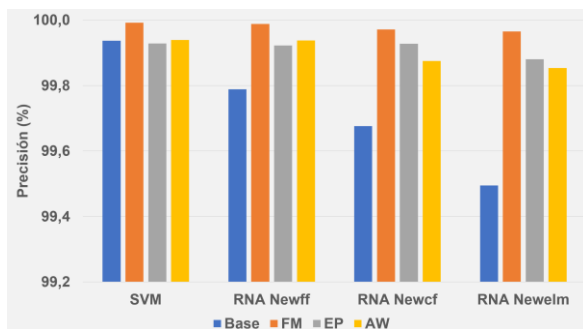


Figura 9. Comparativa de precisión en clasificadores. Fuente: Elaboración propia.

Los resultados de todas las herramientas de clasificación son muy similares (ver Figura 9), mostrando SVM una precisión ligeramente mayor.

Una vez validada la fiabilidad de los resultados de la mejor herramienta (SVM), esta, se ha utilizado para el desarrollo de optimización.

### 3.3. Optimización de concentraciones de aditivos

Para esta fase de la investigación el objetivo ha sido comprobar que la herramienta permite predecir las concentraciones de aditivo en un lubricante base capaces

de aumentar la velocidad de deslizamiento a la que se alcanza el gripado.

En la Figura 10 se muestra un ejemplo de predicción de los aditivos para las condiciones de  $p_0=2.7$  GPa,  $U_m=10$  mm/s,  $Ra=15.81$  nm, viscosidad de 6 cSt y  $U_s$  en un rango de 200 a 600 mm/s. Las muestras 116, 124 y 136 ensayadas en estas condiciones se han utilizado para la comprobación experimental. En esta Figura los valores puntuales corresponden a los resultados experimentales y las curvas representan las predicciones en función de  $U_s$ .

En la Tabla 2 se presentan los resultados para estas muestras, obteniendo un error máximo absoluto de 13 % para el EP en la muestra 136. El error promedio global es de 6 %. De acuerdo con los resultados, el aditivo EP ha presentado el menor error promedio con 5.01 %.

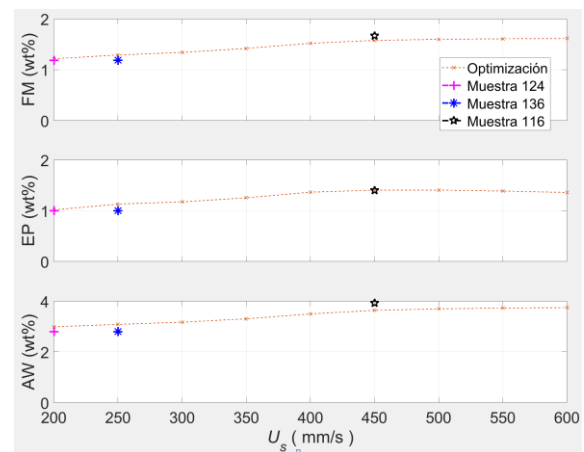


Figura 10. Resultado de predicción y comparación con muestras 116, 124 y 136. Fuente: Elaboración propia.

Tabla 2. Comparación de valores de error entre resultados de predicción y experimentales.

Aditivo	Resultado	Número de muestra		
		116	124	136
FM	Experimental (wt%)	1.66	1.19	1.19
	Predicción (wt%)	1.57	1.22	1.28
	*Error (%)	5.42	-2.18	-7.56
EP	Experimental (wt%)	1.40	1	1
	Predicción (wt%)	1.41	1.02	1.13
	*Error (%)	-0.43	-1.6	-13
AW	Experimental (wt%)	3.92	2.8	2.8
	Predicción (wt%)	3.63	2.99	3.08
	*Error (%)	7.4	-6.71	-10

\*Errores calculados como valor experimental menos valor de predicción dividido entre el valor experimental.

Fuente: Elaboración propia.

La aplicación del método ha permitido estudiar la optimización de los aditivos en una selección de muestras. Sin embargo, para generalizar la optimización se propone como trabajo futuro incluir ensayos adicionales que tengan en cuenta la composición química de cada tipo de aditivo y otras propiedades que permitan caracterizar mejor el lubricante.

#### 4. Conclusiones

Esta investigación corrobora que las metodologías de IA y herramientas de tipo RNA y SVM permiten estudiar el efecto de los aditivos FM, EP y AW en un lubricante frente a una prueba de gripado.

Conforme con otros estudios, la división de la matriz de datos de entrada en 70% para entrenamiento, 15% para validación y 15% para prueba, ha resultado correcta. Se han llegado a determinar las configuraciones para RNA y SVM que han permitido obtener una precisión del 99% para el entrenamiento y los resultados.

La optimización ha mostrado una tendencia coherente de las concentraciones de todos los tipos de aditivo, lo cual se ha comprobado con los ensayos de las muestras 116, 124 y 136, del cual se ha obtenido un error promedio de 6%.

En resumen, este trabajo presenta una metodología para identificar la cantidad y tipo de aditivo que mejora la resistencia al gripado. Sin embargo, para mejorar su capacidad predictiva, se plantea complementar los datos de entrenamiento con nuevos ensayos que incorporen otras variables influyentes en el gripado.

#### 5. Agradecimientos

Los autores agradecen la valiosa colaboración de "Repsol Tech Lab. Móstoles (España)"

#### 6. Referencias

- [1] L. Wojciechowski, S. Eymard, Z. Ignaszak y T. G. Mathia, «Fundamentals of ductile cast iron scuffing at the boundary,» *Tribology International*, vol. 90, pp. 445-454, 2015.
- [2] M. Ingram, C. Hamer y H. Spikes, «A new scuffing test using contra-rotation,» *WEAR*, pp. 229-240, 2015.
- [3] B. Peng, H. Spikes y A. Kadiric, «The Development and Application of a Scuffing Test Based on Contra-rotation,» *Tribology Letters*, vol. 67, n° 37, pp. 1-25, 2019.
- [4] R. Bayat y A. Lehtovaara, «Scuffing evaluation of fully formulated environmentally acceptable lubricant using barrel-on-disc technique,» *Tribology International*, vol. 160, pp. 1-10, 2021.
- [5] T. Yu, P. Yin, W. Zhang, Y. Song y X. Zhang, «A compounding-model comprising back propagation neural network and genetic algorithm for performance prediction of bio-based lubricant blending with functional additives,» *Industrial Lubrication and Tribology*, pp. 1-7, 2020.
- [6] Z. Chen y L. Feng, «Based on the PB Neural Network of Optimization Design in Lubricant Additives,» *Advanced Materials Research*, Vols. %1 de %2311-313, pp. 2018-222, 2011.
- [7] A. Rosenkranz, M. Marian, F. J. Profito, N. Aragon y R. Shah, «The Use of Artificial Intelligence in Tribology - A Perspective,» *Lubricants*, vol. 9, n° 2, pp. 1-11, 2021.
- [8] J. Echávarri Otero, E. de la Guerra Ochoa, E. Chacón Tanarro, P. Lafont Morgado, A. Díaz Lantada, J. Muñoz-Guijosa y J. L. Muñoz Sanz, «Artificial neural network approach to predict the lubricated friction coefficient,» *Lubrication Science*, vol. 26, pp. 141-162, 2014.
- [9] I. Argatov, «Artificial Neural Networks (ANNs) as a Novel Modeling Technique in tribology,» *Frontiers in Mechanical Engineering*, vol. 5, n° 30, pp. 1-9, 2019.
- [10] H. Chang, P. Borghesani, W. A. Smith y P. Zhongxiao, «Application of surface replication combined with image analysis to investigate wear on gear teeth - A case study,» *Wear*, vol. 430, n° 431, pp. 355-368, 2019.
- [11] S. Sardar, S. Dey y D. Das, «Modelling of tribological responses of composites using integrated ANN-GA technique,» *Journal of Composite Materials*, vol. 55, n° 7, pp. 873-896, 2021.
- [12] U. M. Reddy Paturi, S. Cheruku y N. S. Reddy, «The Role of Artificial Networks in Prediction of Mechanical and Tribological Properties of Composites - A Comprehensive Review,» *Archives of Computational Methods in Engineering*, pp. 1-41, 2022.
- [13] S. Bhaumik, S. Pathak, S. Dey y S. Datta, «Artificial intelligence based design of multiple friction modifiers dispersed castor oil and evaluating its tribological properties,» *Tribology International*, vol. 140, pp. 1-11, 2019.
- [14] N. Rivera, D. Blanco, J. Viesca, A. Fernández-González, R. González y A. Hernández Battez, «Tribological performance of three fatty acid anion-based ionic liquids (FAILs) used as lubricant additive,» *Journal of Molecular Liquids*, vol. 296, pp. 1-12, 2019.



- [15] G. C. Loh, H.-C. Lee, X. Y. Tee, P. S. Chow y J. W. Zheng, «Viscosity Prediction of Lubricants by a General Feed-Forward Neural Network,» *Journal of chemical information and modeling*, vol. 60, pp. 1224-1234, 2020.
- [16] S. Bhaumik, B. R. Mathew y S. Datta, «Computational intelligence-based design of lubricant with vegetable oil blend and various nano friction modifiers,» *Fuel*, vol. 241, pp. 733-743, 2019.
- [17] S. Bhaumik y M. Kamaraj, «Artificial neural network and multi-criterion decision making approach of designing a blends of biodegradable lubricants and investigating its tribological properties,» *Institution of Mechanical Engineers Journal of Engineering Tribology*, pp. 1-15, 2020.
- [18] E. Durak, O. Salman y C. Kurbanoglu, «Analysis of effects of oil additive into friction coefficient variations on journal bearing using artificial neural network,» *Industrial Lubrication and Tribology*, vol. 60, n° 6, pp. 309-316, 2008.
- [19] V. Pandiyan, J. Prost, G. Vorlauffer, M. Varga y K. Wasmer, «Identification of abnormal tribological regimes using a microphone and semi-supervised machine-learning algorithm,» *Friction*, vol. 10, n° 4, pp. 583-596, 2022.
- [20] P. M. Sieberg, D. Kurtulan y S. Hanke, «Wear Mechanism Classification Using Artificial Intelligence,» *Materials*, vol. 15, n° 2358, pp. 1-16, 2022.
- [21] C. Sauer, B. Rothhammer, N. Pottin, M. Bartz, B. Schleich y S. Wartzack, «Design of Amorphous Carbon Coatings Using Gaussian Processes and Advanced Data Visualization,» *Lubricants*, vol. 10, n° 22, pp. 1-15, 2022.
- [22] M. Marian y S. Tremmel, «Current Trends and Applications of Machine Learning in Tribology - A Review,» *Lubricants*, vol. 9, n° 86, pp. 1-32, 2021.
- [23] L. Cavaleri, P. G. Asteris, P. P. Psyllaki, M. G. Douvika, A. D. Skentou y N. M. Vaxevanidis, «Prediction of Surface Treatment Effects on the Tribological Performance of Tool Steels Using Artificial Neural Networks,» *Applied Sciences*, vol. 9, n° 2788, pp. 1-20, 2019.
- [24] J. Echávarri Otero, P. Lafont Morgado, E. Chacón Tanarro, E. de la Guerra Ochoa, A. Díaz Lantada, J. Muñoz-Guijosa y J. Muñoz Sanz, «Analytical model for predicting the friction coefficient in point contacts with thermal elastohydrodynamic lubrication,» *Proc. IMechE Part J: Engineering Tribology*, vol. 225, pp. 181-191, 2011.
- [25] T. Hastie, R. Tibshirani y J. Friedman, *The Elements of Statistical Learning, Data Mining, Inference, and Prediction.*, New York: Springer, 2009.