

Aplicación De Inteligencia Artificial Para La Predicción De La Fricción Lubricada En Contactos Mecánicos Microtexturizados

Francisco Franco-Martínez¹, Jorge Juan García Moltó¹, Javier Echávarri Otero¹, Enrique Chacón Tanarro¹, Andrés Díaz-Lantada¹

¹Grupo de investigación en Ingeniería de Máquinas, Departamento de Ingeniería Mecánica, Universidad Politécnica de Madrid, España. Email: francisco.franco@upm.es

Resumen

El microtexturizado de superficies ha mostrado ser de utilidad para mejorar la lubricación, ya que ofrece fuertes reducciones del coeficiente de fricción cuando las condiciones de operación del contacto comprometen el mantenimiento de una película de lubricante suficientemente gruesa. Para estudiar la influencia de los texturizados en la reducción del coeficiente de fricción se hará uso de tres algoritmos de Inteligencia Artificial, analizando y comparando su funcionamiento para seleccionar aquel que mejor realice la predicción de la fricción. Tras esto, se usará el algoritmo con nuevos texturizados con el objetivo de encontrar los óptimos, es decir, aquellos capaces de reducir la fricción para diferentes condiciones de ensayo. La selección del texturizado óptimo se hará empleando el Valor Medio Ponderado del coeficiente de fricción (VMPE) métrica creada en este estudio para tal fin.

Palabras clave: tribología; inteligencia artificial; microtexturizado; lubricación.

Abstract

The use of microtextured surfaces has shown to be very useful to improve the lubrication performance. It provides an important friction reduction when contact's operating conditions compromise an adequate fluid film thickness. To study the influence of texturing in the reduction of friction, three Artificial Intelligence algorithms will be used. They will be analyzed and compared to select the one more suitable to predict the friction coefficient. Afterwards, the algorithm will be applied to a new set of textured surfaces to find the optima among them, that is, those capable of reducing friction under different operating conditions. The selection of the optimal texturing will be based on the weighted mean value of the friction coefficient (VMPE). This metrics was specifically created for this purpose.

Keywords: tribology; artificial intelligence; microtexture; lubrication.

1. Introducción

Desde que Peter Jost acuñara el término tribología, en 1966 [1], esta disciplina ha vivido una fuerte expansión. La generación de conocimiento y su correspondiente aplicación práctica han sido esenciales para disminuir los costes tribológicos asociados a las máquinas y han contribuido a reducir las emisiones contaminantes [2,3]. Sin embargo, pese a los avances conseguidos, todavía se emplea en torno a un 20% de la energía mundial en vencer la fricción [4]. La mejora de la eficiencia energética, particularmente a través de

la reducción de la fricción en las máquinas, puede contribuir de forma muy significativa a disminuir el consumo energético.

El microtexturizado de superficies de manera controlada es una interesante opción para reducir la fricción, ya que puede mejorar las condiciones de lubricación, sobre todo cuando el funcionamiento del sistema compromete el mantenimiento de una película de lubricante suficientemente gruesa [5,6]. Por lo tanto, el principal efecto tiene lugar en la transición hacia un régimen de lubricación parcial o mixta, como es el caso

de los elementos de máquinas que funcionan con elevada carga y/o baja velocidad, tales como rodamientos, engranajes, etc.

Existen numerosas referencias que cuantifican experimentalmente el efecto de los microtexturizados basados en hoyuelos sobre la fricción lubricada, mediante el análisis de diferentes tipos de patrones, geometrías, densidades del texturizado y métodos de fabricación [5,7-9]. En general, las dimensiones de estos texturizados artificiales están sensiblemente por encima de la rugosidad superficial [6]. También se han reportado beneficios de las texturas a largo plazo, ya que ayudan a estabilizar el valor del coeficiente de fricción en el tiempo [10,11].

En cuanto a los mecanismos que permiten reducir la fricción, la literatura describe la capacidad del texturizado para formar microdepósitos de lubricante [12], que permiten separar las superficies mediante la formación de cuñas hidrodinámicas locales [6,13], a la vez que contribuye a atrapar partículas libres existentes en el contacto [14]. Si bien son muchas las fuentes de estudio existentes, los intentos de modelar el funcionamiento de las superficies texturizadas son relativamente escasos, con excepción de los presentados en las referencias [15,16] y algunas otras. Ello es debido a la complejidad de las interacciones existentes entre las superficies texturizadas, que lógicamente dificulta el modelado de su comportamiento.

En consecuencia, la mayor parte de los análisis publicados son meramente experimentales y emplean equipos tribológicos y condiciones de ensayo muy diferentes en cada caso. Este aspecto, unido al elevado número de parámetros de influencia, dificulta enormemente la comparación de los diferentes trabajos y la extracción de conclusiones generales sobre los diseños de texturizado que presentan un mejor comportamiento a fricción en cada caso.

Para abordar esta problemática, la aplicación de algoritmos de Inteligencia Artificial (IA) puede resultar de gran interés, ya que facilitan el manejo de toda la información experimental disponible. Estos algoritmos pueden aplicarse para predecir la fricción entre superficies texturizadas y optimizar su comportamiento, sin necesidad de modelar los complejos fenómenos físicos que tienen lugar en el contacto. De hecho, la IA se ha utilizado previamente con éxito en muchas aplicaciones tribológicas, como por ejemplo se recoge en las referencias [17,18].

Marian *et al.* han estudiado la evolución de la investigación de IA aplicada a tribología, mostrando un crecimiento exponencial desde 1985 hasta el año 2020. Además estos autores muestran que el 9% de un total de 77 publicaciones es en el área de ingeniería de

superficies [17]. Echávarri Otero *et al.* han investigado el uso de redes neuronales para predecir el coeficiente de fricción en contactos puntuales texturizados bajo diferentes regímenes de lubricación. Para ello, emplean el conjunto de herramientas de Matlab *Deep Learning Toolbox* [5]. Por otro lado, Boidi *et al.* han estudiado el uso de algoritmos Radial Basis Function (RBF) para predecir el coeficiente de fricción mediante el uso de cuatro variables características sobre superficies texturizadas con surcos y hoyuelos obteniendo en este caso un la métrica de correlación R^2 con un resultado mayor de 0.935 [19]. Por tanto, observando las publicaciones existentes en la literatura actual queda patente que el uso de los algoritmos de IA en tribología tiene una gran importancia, ya que la complejidad de las variables que afectan en un contacto mecánico lubricado es muy elevada.

En este estudio se analiza el uso de tres tipos de Machine Learning para la predicción del coeficiente de fricción (CoF) en contactos lubricados que disponen de diferentes patrones de microtexturizado con el fin de reducir la fricción. Con ello, se trata de seleccionar aquel algoritmo de machine learning, cuya aplicación sea óptima para la predicción de la fricción y a partir de él poder seleccionar aquel texturizado que reduzca en mayor medida el coeficiente de fricción bajo un rango de condiciones de trabajo determinado, consiguiendo así minimizar las pérdidas energéticas.

2. Metodología

El procedimiento seguido en este estudio comienza con la obtención de los datos de partida, continúa con su preprocesamiento para introducirlos en los algoritmos de inteligencia artificial y finalmente el entrenamiento de los mismos y su evaluación, siendo elaborados los dos últimos puntos de este proceso con el uso de los software de programación *Anaconda3* y *Jupiter Notebook*, empleando el lenguaje *Python*.

2.1. Obtención de datos de partida

Para este estudio se emplea como conjunto de datos una serie de ensayos de fricción realizados en la máquina Mini-Traction Machine (conocida como MTM).



Figura 1. Máquina MTM donde se muestra el baño de lubricante y el contacto bola-disco [20].

En esta máquina se han ensayado una serie de probetas de cobre microtexturizadas con diferentes patrones geométricos, en contacto con una bola de acero de 3/4” de diámetro (19 mm), dando lugar a un contacto puntual lubricado con un aceite base PAO-6. Las condiciones de ensayo se enumeran a continuación:

- Relación deslizamiento-rodadura (%), se trata del cociente entre la diferencia de velocidades bola-disco y la velocidad media de ambos: 5, 10, 20 50, 75 y 100%.
- Velocidad media (mm/s): rango de valores desde 100 hasta 3500 mm/s.
- Carga normal en el contacto (N): 5 y 20 N.
- Temperatura del baño de lubricante (°C): 40 y 80 °C.

Para caracterizar geoméricamente los patrones microtexturizados de las 21 probetas utilizadas se han empleado las siguientes variables:

- Forma: el conjunto incluye probetas con patrones de microtexturizado circular, elíptico, radial y sin texturizar. Esta variable es categórica y permite diferenciar entre cada tipo de microtexturizado.
- Dimensión 1 (µm): radio para texturas circulares o diámetro menor en dirección de movimiento para probetas elípticas o ancho del surco para la textura radial (ver Fig. 2).
- Dimensión 2 (µm): radio para texturas circulares o diámetro mayor perpendicular a la dirección de movimiento o largo del surco para textura radial (ver Fig. 2).
- Densidad (%): área de la superficie que ha sido texturizada respecto al total.
- Profundidad (µm): profundidad del microtexturizado.
- Rugosidad (µm): rugosidad promedio de la superficie de la probeta antes del texturizado. Se han utilizado probetas con 0.007 y 0.1 µm de rugosidad Ra.




Figura 2. Representación esquemática de las dimensiones geométricas 1 y 2 que definen una textura elíptica, según la dirección del movimiento indicada por la flecha.

A continuación se muestra una tabla con el rango de valores de las variables descritas que definen cada probeta.

Tabla 1. Rango de las variables utilizadas en el conjunto de datos para el estudio.

Conjunto de datos	
Variable	Rango
Dimensión 1	0-350 µm
Dimensión 2	0-1100 µm
Densidad	0-25 %
Profundidad	0-185 µm

Respecto a los ensayos con estas probetas microtexturizadas, se obtienen un total de 9 pares de valor coeficiente de fricción-velocidad media, por cada valor de carga, temperatura y relación de deslizamiento-rodadura. Las curvas para cada probeta como las mostradas en la Figura 3, se corresponden con un comportamiento típico de las curvas de Stribeck [5].

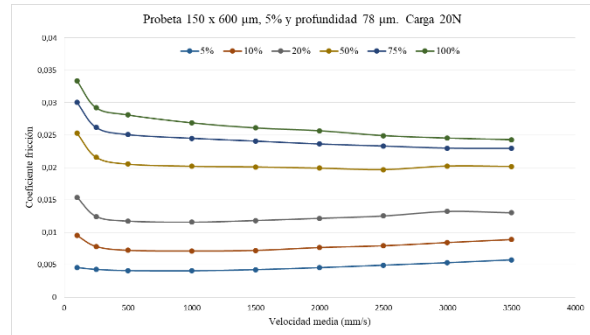


Figura 3. Representación de ensayos de la probeta con características: dimensión 1 = 150 µm; dimensión 2 = 600 µm; Densidad = 5 %; Profundidad = 78 µm; Ra = 0.007 µm; Los ensayos mostrados han sido realizados con carga 20 N, Temperatura = 40 °C y diferentes SRR desde 5 a 100 %.

2.2. Preprocesamiento de datos

A la hora de entrenar un algoritmo de IA resulta de vital importancia utilizar un conjunto de datos previamente procesado, de forma que el entrenamiento mejore tanto en su predicción como en el tiempo de cómputo.

Para tener un conjunto de datos mayor, el primer objetivo ha sido realizar un proceso de *data augmentation*. Para ello, se ha empleado la función *UnivariateSpline* disponible en la librería *Scipy* de *Python*. Este método se trata de una curva derivable definida en porciones mediante el uso de polinomios [21,22]. Ajustando sus parámetros para cada probeta y cada ensayo realizado, se obtienen valores del coeficiente de fricción. A partir de esta curva se obtiene un total de 160 pares de valor coeficiente de fricción y velocidad media.

La segunda etapa en el preprocesamiento de los datos es el escalado de cada variable en el rango de valores desde -1 hasta 1 ya que los algoritmos de Machine Learning presentan un funcionamiento optimizado cuando los valores tienen un rango de valores

homogéneos. Para ello, se emplea la función *MinMaxScaler* disponible en la librería *SciKitLearn* [21-23].

A continuación, a partir del conjunto de datos completo formado por 40320 datos, se realiza la división del mismo en dos conjuntos. Para ello, se ha empleado una función pseudoaleatoria definiendo un valor denominado “semilla” que permite trabajar con el mismo conjunto de datos para todos los algoritmos:

- Conjunto de entrenamiento: este conjunto se compone del 90% del conjunto total. Estos datos han sido utilizados para el entrenamiento de los diferentes tipos de IA estudiados. Es decir, a partir de él los algoritmos establecerán las relaciones entre las variables de entrada que permitan determinar la variable objetivo.
- Conjunto de validación: se trata del restante 10% del total de los datos. A partir de ellos se puede evaluar la predicción de la red a través de diferentes métricas de evaluación. Tras esto, el programador modificará los hiperparámetros del algoritmo para optimizar su funcionamiento.

Cabe reseñar que el conjunto total de datos ha sido dividido con esta distribución ya que, al ser un conjunto amplio, el 10% del mismo representa un total de 4032 datos sobre los que se realiza la validación, siendo este un número suficiente para recoger la casuística del problema a resolver.

Por último, se muestra a continuación un esquema donde se ilustran las variables utilizadas como datos de entrada de la IA y la variable de salida, en este caso de estudio el coeficiente de fricción:

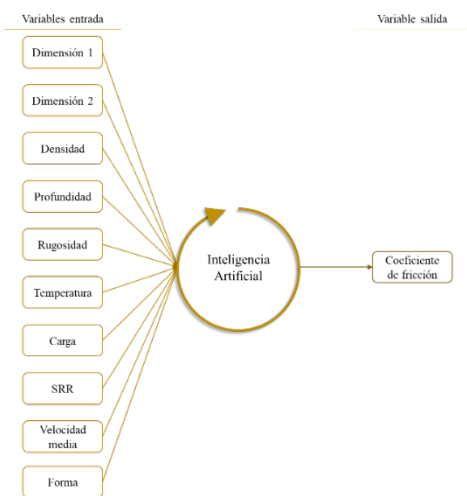


Figura 4. Esquema de proceso de Inteligencia Artificial. A la izquierda las variables de entrada, en el centro algoritmo de Inteligencia artificial y a la derecha variable de salida o predicción.

2.3. Algoritmos de Inteligencia Artificial, entrenamiento y métricas de evaluación.

Para este estudio se han seleccionado tres algoritmos de Inteligencia Artificial que emplean diferentes métodos para realizar las predicciones. El caso de estudio se trata de un enfoque de aprendizaje supervisado, ya que se conocen los valores de la variable de salida que se desea predecir. Esta variable es el coeficiente de fricción, cuyo valor se obtendrá a partir del resto de variables comentadas en el apartado 2.1.

De forma general, los algoritmos se han entrenado siguiendo un método iterativo, con el fin de optimizar su funcionamiento a partir de la evaluación de su rendimiento según las métricas matemáticas empleadas sobre el conjunto de entrenamiento y validación, como se muestra en la Figura 5. Este método comienza con la etapa de entrenamiento, definiendo unos valores de los hiperparámetros del algoritmo de IA; Una vez el algoritmo ha terminado esta etapa, se procede a la evaluación del mismo a través de la métrica de calidad error cuadrático medio, conocido por sus siglas en inglés como MSE. Esta métrica es ampliamente empleada en problemas de regresión, se trata del promedio de la diferencia al cuadrado entre el valor predicho por la red y el valor real; Por último, se lleva a cabo la etapa de modificación, donde se realizan los cambios necesarios de los hiperparámetros tras evaluar el modelo para mejorar su funcionamiento y obtener una predicción lo más fidedigna posible. Se itera sobre este proceso hasta encontrar la solución óptima tras realizar la evaluación sobre el conjunto de validación.



Figura 5. Proceso iterativo de entrenamiento de los algoritmos de Inteligencia Artificial.

Los algoritmos seleccionados en este estudio son:

- *K-Nearest Neighbors Regression (KNN)*: Es un método de regresión, que trata de determinar el valor de la variable dependiente (en este caso, CoF) dadas las variables independientes (datos de entrada) a partir de una media ponderada del valor de la variable independiente de las k observaciones más similares (vecinos más próximos) a aquella que queremos predecir [21, 22].

- *Decision Tree Regression*: Los árboles de decisión es un método de aprendizaje supervisado no paramétrico, que predice el valor de una variable objetivo mediante la creación de reglas de tipo “if-then-else”, que infieren a partir de los datos de entrenamiento [21,22].
- *Redes neuronales secuenciales*: se trata de un modelo compuesto por neuronas artificiales conectadas entre sí y agrupadas en forma de capas. Una neurona artificial imita a las neuronas biológicas y consta de: un número no limitado de valores de entrada, cada una de ellas con un valor de inhibición o excitación, comúnmente conocido como *peso*. A través de los valores de entrada, la neurona genera un valor de salida. En el interior de la neurona artificial existe el núcleo, donde se realiza la suma de las señales de entrada y se aplica una función de salida o transferencia que evita la linealidad del cómputo. Finalmente, para que la red neuronal pueda realizar el proceso de aprendizaje el algoritmo seleccionado es *Back Propagation*. El principio general de este algoritmo es comparar las salidas obtenidas con las salidas esperadas (coeficiente de fricción ensayado) y reajustar los pesos para que la red produzca un resultado más acertado [24]. Además, destacar que de forma general una red neuronal se divide en tres tipos de capas: capa de entrada, recibe las variables a partir de las que la red emitirá la predicción; capas ocultas, tratan de aprender las relaciones entre las variables de entrada para predecir la variable de salida; y la capa de salida que consta de las neuronas encargadas de emitir la predicción.

Por último, mencionar que los algoritmos *KNN* y *Decision Tree Regression* han sido utilizados por medio de la librería *SciKitLearn*, mientras que para las redes neuronales secuenciales se ha empleado la librería *Keras*.

2.4. Predicción del microtexturizado óptimo.

Seleccionado el algoritmo más eficaz a la hora de predecir el CoF, se procede a realizar la predicción de este coeficiente con nuevos patrones de microtexturizado diferentes a los que forman el conjunto de entrenamiento y validación.

Seleccionar el microtexturizado que alcance una menor fricción para las dos cargas estudiadas y seis ratios de deslizamiento-rodadura (SRR) puede ser una tarea de elevada complejidad. Por ello, se decide aplicar como método de comparación y selección el cálculo de un valor medio ponderado del coeficiente de fricción por ensayo (se refiere a ensayo a una curva de Stribeck a

carga, temperatura y SRR fijos), denominado como VMPE. Se opta por este valor medio ponderado para dar más peso a las velocidades medias más bajas, ya que las microtexturas deben actuar para dichas velocidades bajas, en las que las condiciones de ensayo son más severas y se alcanza lubricación mixta. En la Figura 6 se muestra un ejemplo del efecto de las microtexturas, donde se aprecia la reducción en la fricción para las diferentes velocidades. El área marcada en naranja es donde mayor importancia tiene el efecto del microtexturizado.

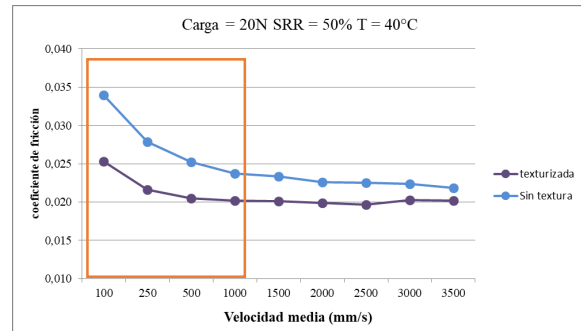


Figura 6. Comparación entre curvas de Stribeck de dos probetas ensayadas bajo las mismas condiciones de carga, SRR y Temperatura. En azul, probeta sin textura, en morado probeta microtexturizada.

El valor VMPE se calcula para cada ensayo, teniendo en cuenta los nueve valores de coeficiente de fricción f_i predichos para las velocidades medias: 100, 250, 500, 1000 y 1500, 2000, 2500, 3000, 3500 mm/s de forma ponderada, siguiendo la siguiente fórmula:

$$VMPE = c_1 \sum_1^4 f_i + c_2 \sum_5^9 f_i \quad (1)$$

Se han seleccionado los valores c_1 y c_2 como 0,15 y 0,08 respectivamente. Así los cuatro valores de menor velocidad de 100-1000 mm/s tienen casi el doble de peso sobre la media ponderada que el resto de valores de mayor velocidad.

Considerando que cada probeta es ensayada a dos cargas y seis grados de SRR distintos para cada carga, se obtiene un total de 12 ensayos y sobre cada uno de ellos se calcula la métrica VMPE. Como control, se considera una probeta sin texturizar y se calcula de nuevo la métrica VMPE para cada uno de los ensayos, que se denominará VMPEc.

Por último, se compara el VMPE de cada ensayo de cada probeta con el valor del ensayo de control (VMPEc para la probeta sin texturizar). Con el resultado se sigue un procedimiento de recuento, que permitirá seleccionar las probetas óptimas, siguiendo la fórmula indicada a continuación:

$$x = \begin{cases} 1, & \text{si } (VMPEc - VMPE > 0) \\ 0, & \text{si } (VMPEc - VMPE < 0) \end{cases} \quad (2)$$

Es decir, x toma valor 1 cuando el texturizado reduce el coeficiente de fricción medio ponderado VMPE con respecto al ensayo de control.

Por último, se realiza la suma de valores x de cada probeta obteniendo así un criterio que permite decidir qué tipo o tipos de microtexturizado mejoran la fricción de forma promedio para las combinaciones de carga y SRR.

3. Resultados

A continuación, se analizan los tres algoritmos utilizados y se comparan entre ellos con el fin de seleccionar aquel más adecuado para predecir el microtexturizado óptimo según las condiciones de trabajo.

3.1. K-Nearest Neighbors Regression

Este algoritmo es el más sencillo de los empleados. Los parámetros óptimos y el MSE obtenido han sido representados en la Tabla 2.

Tabla 2. Parámetros óptimos y resultados de error cuadrático medio para el algoritmo *K-Nearest Neighbors Regression*.

<i>Parámetros óptimos</i>	
n_neighbors	2
weights	uniform
algorithm	Auto
metric	Euclidean
<i>Resultados de error</i>	
MSE (entrenamiento)	1.20e-05
MSE (validación)	6.61e-05

Como se puede ver se trata de un error muy bajo, mostrando una predicción precisa del coeficiente de fricción sobre los datos de validación. Por otro lado, al ser los valores de MSE sobre el conjunto de entrenamiento y validación muy similares se determina que no existe *overfitting* o *sobreajuste*. Este problema se presenta frecuentemente y ocurre cuando el algoritmo es capaz de predecir con una precisión muy elevada sobre el conjunto de entrenamiento pero no lo hace igual sobre el conjunto de validación, mostrando sobre este último conjunto un error mayor y muy dispar respecto al error en el conjunto de entrenamiento. En este caso, como se ha comentado, no existe este problema de *sobreajuste*.

3.2. Decision Tree Regression

Este algoritmo es más complejo que el anterior y ha sido utilizado en numerosos casos de éxito. Por ejemplo, en tribología R.T. Kristipadu y D. Lawrence han comparado diferentes algoritmos de IA (*Regression method, Support Vector Machine, Decision Tree* y *Long Short-Term Memory*) para predecir el coeficiente de fricción en un contacto en

seco, bajo diferentes condiciones de carga, siendo *Decision Tree* el que ha demostrado una mejor predicción [25]. Además este tipo de IA se trata de la unidad básica del algoritmo *Random Forest* compuesto por numerosos *Decision Tree* y empleado en la resolución de problemas de elevada complejidad. Para el caso de estudio los parámetros óptimos y el mínimo MSE obtenido se muestran en la Tabla 3.

Tabla 3. Parámetros óptimos y resultados de error cuadrático medio para el algoritmo *K-Nearest Neighbors Regression*.

<i>Parámetros óptimos</i>	
criterion	Squared error
splitter	Best
Max_depth	None
Min_samples_split	2
Min_samples_leaf	1
Min_weight_fraction_leaf	0.0
Max_features	None
Random_state	0
Max_leaf_nodes	None
Min_impurity_decrease	0.0
ccp_alpha	0.0
<i>Resultados de error</i>	
MSE (entrenamiento)	2.79e-08
MSE (validación)	6.48e-05

En este caso, los parámetros con los que se obtienen mejores resultados son los establecidos por defecto para el algoritmo, exceptuando el parámetro *Random_State* que se establece en 0 para obtener un comportamiento determinista durante el ajuste.

Comparando entre los errores de entrenamiento y validación, existen tres órdenes de magnitud de diferencia, siendo este el mejor resultado obtenido, por tanto podría decirse que el algoritmo se encuentra *sobreajustado*. Sin embargo, el error para la validación sigue siendo muy bajo y similar al obtenido con *KNN* por lo que se decide seguir considerando este algoritmo y comparar su predicción con *KNN* sobre nuevas probetas para evaluar cuál es el texturizado óptimo.

3.3. Red Neuronal Secuencial

Este caso se trata de un algoritmo de Deep Learning, subconjunto del Machine Learning que se emplea típicamente para resolver problemas de elevada complejidad. El algoritmo de neurona empleado utiliza la denominada *Dense Layer* de la librería de programación *Keras*, que procesa los datos de entrada de forma lineal. Se ha entrenado con diferentes configuraciones de la red, empleando diferente número de neuronas y capas ocultas. Los parámetros óptimos y el MSE obtenido se recogen en la Tabla 4:

Tabla 4. Parámetros óptimos y resultados de error cuadrático medio para el algoritmo *K-Nearest Neighbors Regression*.

Parámetros óptimos	
Neuronas	64
Capas ocultas	1
Optimizador	RMSprop
Learning rate	0.001
Función de pérdida	MSE
Resultados de error	
MSE (validación)	1.44e-04

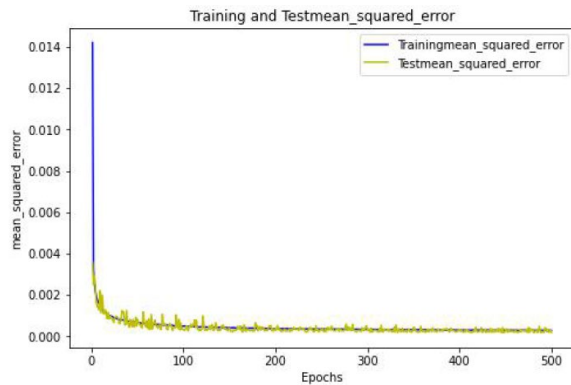


Figura 7. MSE para los conjuntos de entrenamiento y validación en cada época de entrenamiento.

Como se observa en la gráfica el valor de MSE para el conjunto de entrenamiento y validación es muy similar en las últimas épocas, siendo el mínimo en la época 491 con un valor de 1.44e-04, valor que de nuevo vuelve a ser muy bajo.

3.4. Comparación entre algoritmos.

Comparando entre los tres algoritmos analizados, se muestra en la Tabla 5 que aquel con menor valor de MSE sobre el conjunto de validación es *Decision Tree Regressor* siendo este error prácticamente igual al de *KNN* y medio orden de magnitud inferior que la *Red Neuronal*.

Tabla 5. Valores de MSE en el conjunto de validación para cada algoritmo.

<i>K-Nearest Neighbor (KNN)</i>	6.61e-05
<i>Decision Tree Regressor</i>	6.48e-05
<i>Red Neuronal Secuencial</i>	1.44e-04

Una vez analizados estos resultados se decide que los mejores algoritmos son *KNN* y *Decision Tree Regressor*, procediéndose a realizar predicciones con ellos para intentar determinar aquel microtexturizado que permita reducir en mayor medida la fricción. Sin embargo, al realizar la predicción, los resultados muestran que ambos algoritmos producen valores discretos, siendo poco sensibles a cambios sutiles en el conjunto de datos, como el cambio de una sola

variable. Como ejemplo, se presenta a continuación la predicción de estos algoritmos sobre unas probetas circulares que no han sido empleadas para el entrenamiento ni validación, donde el cambio entre los diferentes patrones microtexturizados se produce solamente en función de la densidad siendo las dimensiones 1 y 2 de la probeta 50 µm, profundidad 17 µm y rugosidad Ra 0.007 µm:

Tabla 6. Predicciones del coeficiente de fricción para ensayo con carga 5 N, SRR 20%, 40°C y velocidad media 1000 mm/s.

Densidad (%)	<i>KNN</i>	<i>Decision Tree</i>	<i>Red Neuronal</i>
5	0.00328	0.00515	0.00413
6	0.00328	0.00515	0.00453
7	0.00328	0.00515	0.00492
8	0.00328	0.00515	0.00545

Por tanto, se determina que estos algoritmos no son adecuados a pesar del bajo valor de MSE obtenido en ellos sobre ambos conjuntos, entrenamiento y validación. Finalmente se opta por emplear la *Red Neuronal* como algoritmo óptimo, ya que a pesar de tener un MSE mayor, produce una predicción continua de los resultados y es capaz de detectar pequeños cambios entre microtexturizados, como es en este caso al variar la densidad.

3.5. Predicción de microtexturizado óptimo.

Una vez seleccionada la *Red Neuronal* como el algoritmo adecuado, se procede a realizar la predicción y selección de aquel microtexturizado óptimo utilizando este algoritmo y aplicando el método descrito en el apartado 2.4.

Para ello, se crea un nuevo conjunto de probetas microtexturizadas sobre las que se predecirá el CoF, modificando y combinando las diferentes variables geométricas que definen un microtexturizado recogidas en el apartado 2.1, dentro del rango de valores estudiado para cada una de ellas. El total de microtexturizado estudiados ha sido 6783. De esta forma se obtiene para cada una de las diferentes probetas los ensayos con los mismos parámetros mostrados en el apartado 2.1.

Con ello se realiza el proceso descrito en el apartado 2.4 de este artículo, de acuerdo con los datos de coeficiente de fricción predichos mediante el uso de la *Red Neuronal* se determina que los microtexturizados óptimos son los mostrados en la Tabla 7, donde además de recoger las variables que definen el texturizado, también se ha recogido el valor de recuento de VMPE mostrando que este valor es menor que para la probeta

sin texturizar en seis ensayos para la probeta 1 y 3 y siete ensayos para la probeta 2.

Tabla 7. Microtexturizados óptimos.

Variable	Probeta 1	Probeta 2	Probeta 3
Forma	Circular	Circular	Elíptica
Dimensión 1	50 μm	100 μm	100 μm
Dimensión 2	50 μm	100 μm	200 μm
Densidad	5 %	8 %	5 %
Profundidad	140 μm	110 μm	120 μm
Rugosidad	0.007 μm	0.007 μm	0.007 μm
Recuento VMPE	6	7	6

En la Figura 8 se muestra una serie de seis ensayos para la Probeta 2 de la Tabla 7 comparada con una Probeta similar sin texturizar. Observando este gráfico, se evidencia que los valores predichos para el coeficiente de fricción por la *Red Neuronal* para esta textura reducen en todas las condiciones de SRR para carga 20N con respecto a la probeta sin texturizar. Además el efecto del texturizado es mayor a bajas velocidades, donde teóricamente debe actuar prolongando las condiciones de funcionamiento bajo un régimen en película gruesa para velocidades medias menores.

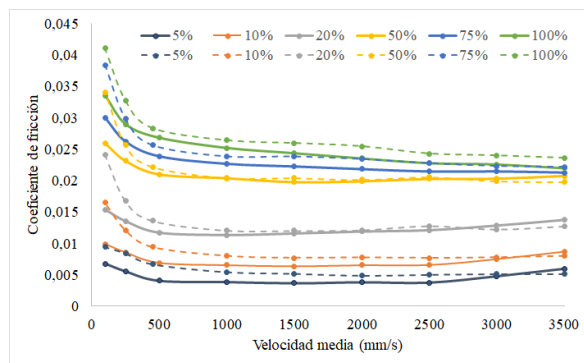


Figura 8. Comparativa entre las curvas de Stribeck para la Probeta 2 (línea continua) y una probeta sin texturizar (línea discontinua) a diferentes SRR, carga 20 N y temperatura 40°C.

En este estudio se ha mostrado la comparación entre tres algoritmos de IA, obteniendo como mejor algoritmo basándose solamente en la métrica de calidad MSE *Decision Tree*. Resultado similar al de Kristipadu *et al.* en su estudio empleando una métrica similar [25]. Esto demuestra que *Decision Tree* es un algoritmo potente, capaz de captar la influencia de las condiciones de ensayo y texturizados sobre el CoF. Sin embargo, en este estudio teniendo en cuenta los resultados mostrados en la Tabla 6 se determina que, aunque este algoritmo es el que mejor consigue

minimizar la métrica de calidad, no es lo suficientemente sensible como para captar ciertos cambios entre geometrías. Por ello, se ha encontrado que la *Red Neuronal* es un algoritmo más adecuado, capaz de captar pequeños cambios entre geometrías, a pesar de tener un MSE ligeramente superior.

En cuanto a las geometrías establecidas como óptimas a través de la métrica VMPE evidencian que la *Red Neuronal* sigue la tendencia de otros estudios empíricos, donde se ha determinado que el parámetro densidad de texturizado debe estar en un rango óptimo entre 5-10% [5, 12].

En cuanto a las dimensiones del texturizado, la predicción realizada por esta *Red Neuronal* muestra que estas deben tener un tamaño de unos pocos cientos de micrómetros, siendo la de mayor tamaño 200 micrómetros que es ligeramente inferior a huella de contacto Hertziana 239 μm . Contrasta con la predicción otros estudios como [5, 12] que muestran, mediante resultados experimentales, que microtexturizados de tamaño similar a la huella de contacto o superior a la misma reducen en mayor medida la fricción. Por tanto, el efecto del tamaño del texturizado debe comprobarse experimentalmente.

Por otro lado, mencionar que Echávarri *et al.* [5] mostraron en su estudio sobre microtexturizados elípticos que geometrías cuyo eje menor fuese menor que el ancho de la huella de contacto (en este caso dimensión 1 para la Probeta 3 mostrada en la Tabla 7) reducen en mayor medida la fricción, tendencia similar a la mostrada en los resultados recogidos en la Tabla 7.

En cuanto a la profundidad, parece lógico que mayores profundidades permitan una mayor reducción de fricción, ya que las microtexturas actuarán como reservas de lubricante. Además, permiten la recolección y decantación de micropartículas desprendidas por el desgaste, evitando que estas se encuentren en el contacto mecánico. Sin embargo, no existe un valor óptimo en general para esta variable. Por ejemplo, Rosekranz *et al.* [26] mostraron en su estudio que para densidad de texturizado entre 10 y 20% la profundidad óptima estaba entre 25 y 50 μm . Mientras que Echávarri *et al.* [5] han determinado para texturizados elíptico que la profundidad óptima está en torno a 78 μm , aumentando la reducción de fricción conforme aumenta la profundidad del texturizado. Por tanto, deben realizarse ensayos para comprobar este efecto, sobre el que la *Red Neuronal* predice profundidades óptimas ligeramente superiores a 100 μm .

4. Conclusiones

En este estudio se ha mostrado el uso de algoritmos de Inteligencia Artificial para la predicción del coeficiente de fricción en contactos lubricados con superficies microtexturizadas, comparándose tres algoritmos ampliamente utilizados en diferentes campos de investigación: *K-Nearest Neighbor*, *Decision Tree Regressor* y *Red Neuronal Secuencial*. Para la evaluación de estos algoritmos se ha empleado la métrica de calidad *Mean Squared Error* donde los tres han presentado unos resultados similares y muy bajos, en el orden 10^{-4} y 10^{-5} . Al analizar las predicciones individuales de cada algoritmo, se concluye que el mejor de ellos es la *Red Neuronal* que gracias a su funcionamiento y alta capacidad de cómputo es sensible a pequeños cambios en las variables que definen el microtexturizado, como se ha demostrado al realizar la variación de la densidad superficial.

Observando la arquitectura de la *Red Neuronal*, compuesta tan solo por una capa oculta de 64 neuronas, queda patente que predecir la fricción en contacto lubricados texturizados bajo las condiciones ensayadas no es un problema de elevada dificultad para este algoritmo. Además, la simplicidad de este algoritmo permite su uso en cualquier ordenador capaz de ejecutar un entorno de desarrollo en lenguaje *Python* como *Jupyter Notebook* o *Spyder*, incluso a través de servicios en línea, produciendo la predicción en cuestión de segundos, ventaja notable de los algoritmos de IA frente a simulaciones numéricas complejas.

Mediante el uso de este algoritmo, se han seleccionado los texturizados óptimos para todos los ensayos a temperatura constante de 40°C, variando carga y SRR. La selección de un texturizado óptimo en este rango de condiciones de trabajo no es una tarea sencilla y para ello, los investigadores han creado una métrica definida como VMPE que tiene en cuenta la acción de los microtexturizados a lo largo de la curva de Stribeck, ponderando en mayor medida aquellos valores para bajas velocidades, donde los texturizados deben actuar evitando la rotura de la película lubricante. A través de esta métrica se han seleccionado los texturizados óptimos para reducir la fricción en un mayor rango de condiciones de trabajo, dando lugar a reducciones de la fricción en 6-7 de los ensayos de un total de 12 como se muestra en la Tabla 7 y Figura 8. Además las geometrías de los texturizados óptimos seleccionados a través de la predicción de la *Red Neuronal* están de acuerdo con algunas investigaciones previamente realizadas para mejorar la fricción.

Las predicciones realizadas por la *Red Neuronal* sobre el coeficiente de fricción muestran una curva de Stribeck con forma similar a los datos experimentales, demostrando que la red capta el efecto del texturizado sobre la curva de Stribeck. Además, todas las curvas de

Stribeck de la probeta texturizada en la Figura 8 presentan una mejora de la fricción con respecto a la probeta sin texturizar. Por último, mencionar que la red es capaz de predecir de forma precisa la influencia del SRR, permitiendo generalizar los resultados para otros valores de SRR dentro del rango estudiado.

Como línea futura, los autores contrastarán los resultados de la predicción de la *Red Neuronal* con experimentación en el laboratorio de tal forma que pueda comprobarse si los texturizados seleccionados como óptimos (Tabla 7) reducen la fricción y si este algoritmo puede utilizarse como ayuda al diseño de superficies texturizadas, permitiendo el ahorro en costes de fabricación y posterior ensayo, así como el consumo de tiempo que conllevan estos procesos.

5. Agradecimientos

Los autores agradecen la colaboración del Repsol Tech lab en la fase experimental previa del trabajo.

6. Referencias

- [1] P. Jost. "Lubrication (tribology), education and research. A report on the present position and industry's needs". Publicado como un informe del gobierno del Reino Unido, el 9 de marzo de 1966.
- [2] G.W. Stachowiak. "How tribology has been helping us to advance and to survive". *Friction* 5(3), pp. 233-247, 2017.
- [3] J. Echávarri, E. de la Guerra, E. Chacón. "Tribology: A historical overview of the relation between theory and application". Capítulo de libro "A bridge between conceptual frameworks: sciences, society and technology studies". Springer, 2015.
- [4] K. Holmberg, A. Erdemir. "The impact of tribology on energy use and CO₂ emission globally and in combustion engine and electric cars". *Tribology International* 135, pp. 389-396, 2019.
- [5] J. Echávarri, E. de la Guerra, I. Bellón, E. Chacón. "Optimising the design of textured surfaces for reducing lubricated friction coefficient". *Lubrication Science* 29(3), pp. 183-199, 2017.
- [6] R. Gohar, H. Rahnejat. "Fundamentals of tribology (Third Edition)". World Scientific Publishing Europe, 2019.
- [7] A. Kovalchenko, O. Ajayi, A. Erdemir, G. Fenske, I. Etsion. "The effect of laser surface texturing on transitions in lubrication regimes during unidirectional sliding contact". *Tribology International* 38, pp. 219-225, 2005.

- [8] C. Gachot, A. Rosenkranz, S.M. Hsu, H.L. Costa. “A critical assessment of surface texturing for friction and wear improvement”. *Wear* 372-373, pp. 21-41, 2017.
- [9] Y. Xu, J. Yu, J. Geng, R. Abuflaha, D. Olson, X. Hu, W.T. Tysoe. “Characterization of the tribological behavior of the textured steel surfaces fabricated by photolithographic etching”. *Tribology Letters* 66:55, 2018.
- [10] D.Z. Segu, P. Hwang. “Friction control by multi-shape textured surface under pin-on disc test”. *Tribology International* 91, pp. 111-117, 2015.
- [11] A.M. Kovalchenko, A. Erdemir, O.O. Ajayi, I. Etsion. “Tribological behavior of oil lubricated laser textured steel surfaces in conformal flat and non-conformal contacts”. *Materials Performance and Characterization* 6(2), pp. 1-23, 2017.
- [12] M. Wakuda, Y. Yamauchi, S. Kanzaki, Y. Yasuda. “Effect of surface texturing on friction reduction between ceramic and steel materials under lubricated sliding contact”. *Wear* 254(3), pp.356-363, 2003.
- [13] A. Predescu, M.D. Pascovici, T. Cicone, C.S. Popescu, C. Grigoriu, D. Dragulinescu. “Friction evaluation of lubricated laser-textured surfaces”. *Lubrication Science* 22(10), pp. 431-442, 2010.
- [14] U. Pettersson, S. Jacobson. “Influence of surface texture on boundary lubricated sliding contacts”. *Tribology International* 36, pp. 857-864, 2003.
- [15] A. Ronen, I. Etsion, Y. Kligerman. “Friction-reducing surface-texturing in reciprocating automotive components”. *Tribology Transactions* 44, pp. 359-366, 2001.
- [16] M. Marian, P. Grützmaier, A. Rosenkranz, S. Tremmel, Frank Mücklich, S. Wartzack. “Designing surface textures for EHL point-contacts - Transient 3D simulations, meta-modeling and experimental validation”. *Tribology International* 137, pp. 152-163, 2019.
- [17] M. Marian, S. Tremmel, S. “Current trends and applications of machine learning in tribology—A review”. *Lubricants* 9(9), 86, 2021.
- [18] J. Echávarri, E. de La Guerra, E. Chacón, P. Lafont, A. Díaz; J.M. Muñoz-Guijosa, J.L. Muñoz Sanz. “Artificial neural network approach to predict the lubricated friction coefficient”. *Lubrication Science* 26, pp. 141–162, 2014.
- [19] G. Boidi, M.R. Da Silva, F.J. Profíto, I.F. Machado: “Using machine learning Radial Basis Function (RBF) method for predicting lubricated friction on textured and porous surfaces. *Surf. Topogr. Metrol. Prop.* 2020, 8, 044002.
- [20] I. Bellón Vainot: “Optimización de la eficiencia en contactos lubricados a través del texturizado superficial”, Trabajo Fin de Grado, Universidad Politécnica de Madrid, Madrid, junio 2015.
- [21] J.J. García Moltó: “Inteligencia Artificial Aplicada al Análisis Tribológico de Texturizados Superficiales con Python”, Trabajo Fin de Grado, Universidad Politécnica de Madrid, septiembre 2021.
- [22] A. Gerón: “Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: Concepts, tools and techniques to build intelligent systems” O’Reilly Media, 2019.
- [23] J. Torres: “Deep Learning- Introducción práctica con Keras” [en línea]. Disponible en: <https://torres.ai/deep-learning-inteligencia-artificial-keras/>
- [24] J. Bobadilla: “Machine Learning y Deep Learning: Usando Python, Scikit y Keras”, Ra-Ma Editorial, 9789587921465, 2021.
- [25] R.T. Kristipadu, D. Lawrence: “Development of machine learning based predictive analytical models for the surface interaction studies of tribological pairs”, *AIP Conference Proceedings*, 2336, 2021.
- [26] A. Rosenkranz, A. Szurdak, C. Garchot, G. Hirt, F. Mücklich. “Friction reduction under mixed and full film EHL induced by hot micro-coined surface patterns”. *Tribological International* 95, 290-297, 2016