



# Predicción del coeficiente de fricción lubricado empleando redes neuronales en contactos mecánicos microtexturizados

Francisco Franco-Martínez<sup>1</sup>, Irene García Ayuso<sup>1</sup>, Javier Echávarri Otero<sup>1</sup>, Enrique Chacón Tanarro<sup>1</sup>, Adrián López Arrabal<sup>1</sup>

<sup>1</sup> Grupo de Investigación en Ingeniería de Máquinas, Departamento de Ingeniería Mecánica, Universidad Politécnica de Madrid, España; email: francisco.franco@upm.es

---

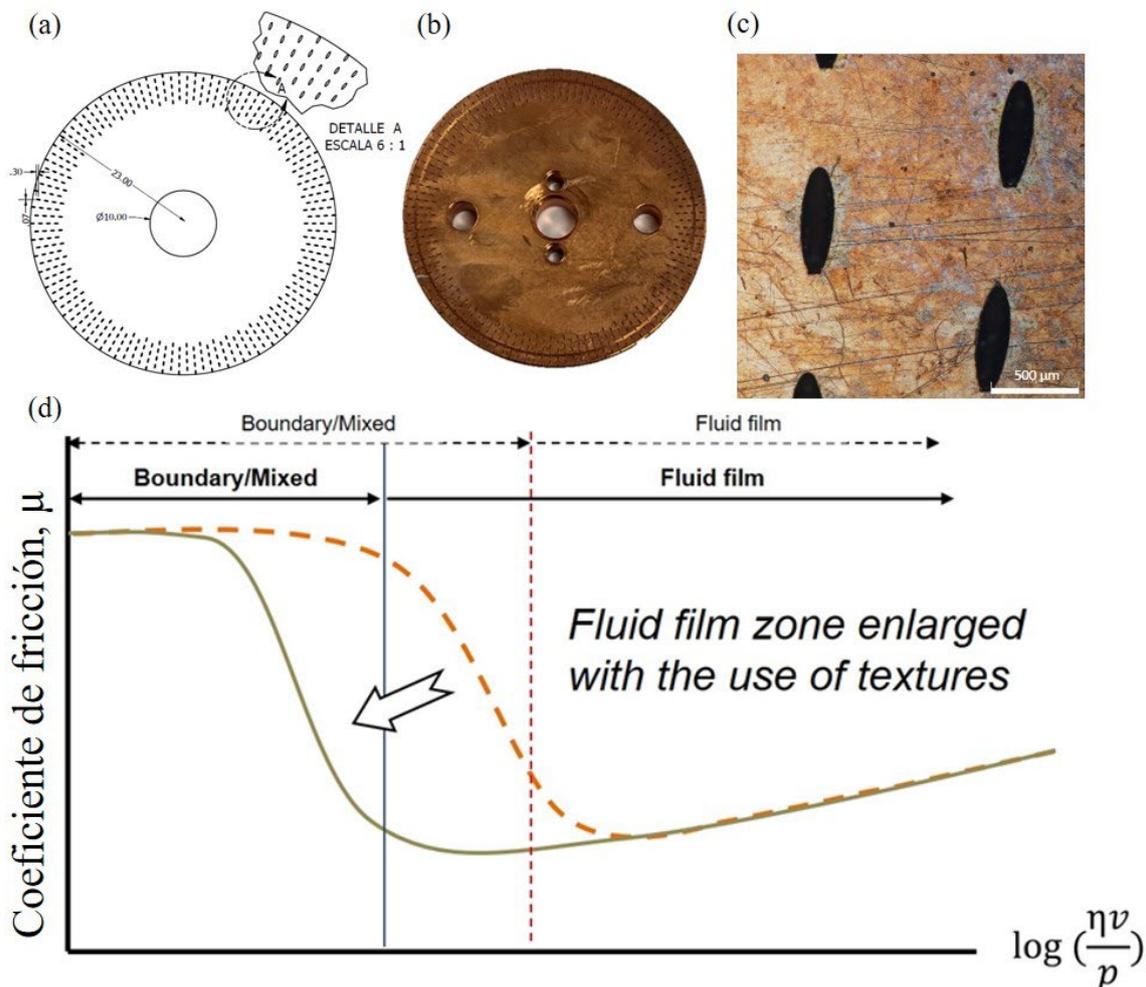
*Desde que se acuñó el término tribología en la década de los sesenta se han logrado numerosos avances que reducen la fricción en máquinas. Aun con estos avances el estudio de la fricción en máquinas es un área activa de investigación, ya que todavía se emplea el 20% de la energía mundial en vencer esta resistencia pasiva. El microtexturizado de superficies ha resultado ser una técnica efectiva para reducir la fricción en contactos mecánicos con condiciones de trabajo que pueden dificultar la formación de una lubricación en película gruesa. En la literatura hay escasos estudios que modelen los fenómenos físicos de este tipo de contactos lubricados con superficies microtexturizadas debido a la dificultad que conlleva la influencia de numerosas variables, como las condiciones de trabajo, la geometría que define el patrón de texturas y su interrelación. Estudios recientes muestran la aplicabilidad de los algoritmos de Inteligencia Artificial (IA) para la predicción de la fricción. Por ello, el objetivo de este estudio es emplear redes neuronales para determinar el coeficiente de fricción en contactos lubricados microtexturizados. A diferencia de estudios previos en los que se utilizan algoritmos de IA entrenados con datos que no tienen en consideración la incertidumbre de la microfabricación, el algoritmo propuesto se desarrolla empleando datos que se han obtenido midiendo los patrones de texturizado fabricados tanto por fotolitografía y ataque químico como mediante ablación láser. De esta forma, se establece como segundo objetivo comprobar que la influencia de la precisión de la fabricación es relevante en la correcta predicción del coeficiente de fricción.*

---

## 1. Introducción

Desde que P. Jost acuñara el término tribología en la década de 1960 [1], se han realizado numerosos avances científicos para reducir la fricción en máquinas. Aun así se sigue empleando alrededor del 20% de la energía mundial en vencer esta resistencia pasiva [2].

Los texturizados superficiales, en la escala micrométrica, han demostrado ser una técnica eficaz para reducir la fricción. Los patrones de cavidades sobre la superficie (Figura 1) permiten disminuir la fricción especialmente en contactos que trabajan en condiciones de lubricación mixta o incluso límite, que suelen ocurrir en elementos de máquinas con contactos puntuales o lineales como rodamientos, engranajes o levas. El efecto del texturizado permite reducir la fricción, haciendo que la lubricación mixta y límite aparezca bajo condiciones de trabajo aún más severas que si no se emplearan microtexturas, como se muestra en la Figura 1. La capacidad del texturizado superficial para mejorar la lubricación en condiciones de trabajo severas como bajas velocidades de deslizamiento o altas presiones, se debe a que las texturas actúan como reservas de lubricante donde se forman cuñas hidrodinámicas locales que permiten mantener una lubricación adecuada en el contacto [3-5]. Además, algunos autores científicos han reportado que estas texturas también actúan como depósitos de partículas que se producen en el contacto debido al desgaste [6].



**Figura 1:** (a) Diseño de una probeta microtexturizada con cavidades de forma elíptica. (b, c) imágenes de la probeta microtexturizada fabricada. (d) Efecto del texturizado en un contacto lubricado. En la gráfica se representa el coeficiente de fricción ( $\mu$ ) frente al logaritmo de la viscosidad, velocidad y presión ( $\eta$ ,  $v$  y  $p$ , respectivamente). La curva naranja punteada representa un contacto sin texturas, mientras que la curva verde sólida representa el mismo contacto texturizado. Fuente: [7]

En la literatura científica, existen numerosos estudios que investigan el efecto sobre la fricción de los microtexturizados, generalmente realizados con formas geométricas sencillas como círculos, triángulos o elipses, con el fin de optimizar el tamaño, profundidad, la densidad superficial de texturizado, la forma geométrica la orientación [4], [8-12]. En base a estas referencias puede decirse que, si bien en la mayoría de los estudios realizados las formas elíptica y circular para el texturizado son aquellas que reducen en mayor medida la fricción, dependiendo de las condiciones de trabajo es necesario adaptar el tamaño, profundidad y densidad de texturizado superficial [4], [10], [13]. Debido a ello, es necesario un modelo capaz de correlacionar el texturizado óptimo para

unas condiciones de trabajo dadas. Sin embargo, dadas las numerosas variables que influyen en este proceso tribológico como las condiciones de trabajo, la geometría del patrón de texturizado y su interrelación, existen escasos estudios que modelen este proceso. Como las referencias [14], [15] que tratan de modelar físicamente el uso de texturas en contactos conformes o la referencia [16] donde Marian *et al.* utilizan un meta-modelo de prognosis óptima combinado con herramientas de Inteligencia Artificial para determinar la influencia de las microtexturas bajo ciertas condiciones de lubricación en contacto puntual. Este modelo ha sido desarrollado basándose en simulaciones elastohidrodinámicas y considerando una única textura en el contacto, simplificando así el modelo, ya que no considera el efecto de las texturas vecinas al contacto sobre la lubricación.

Dada la capacidad de los contactos microtexturizados para reducir la fricción y la dificultad de modelar el proceso físico, la Inteligencia Artificial podría ser una herramienta de gran utilidad para resolver esta problemática. En tribología, los algoritmos de IA están siendo empleados cada vez más, siguiendo su uso una tendencia exponencial desde 2010 [17]. Además, en la referencia [18] Rosekranz propone como una línea de investigación en la que la IA podría desempeñar un rol importante la ingeniería de superficies, donde se engloba el estudio del efecto de los microtexturizados sobre la fricción. Asimismo, el grupo de investigación en ingeniería de máquinas de la Universidad Politécnica de Madrid ha desarrollado previamente estudios tratando de predecir el coeficiente de fricción en un contacto puntual lubricado tanto con probetas microtexturizadas como sin texturizar [7], [19], [20].

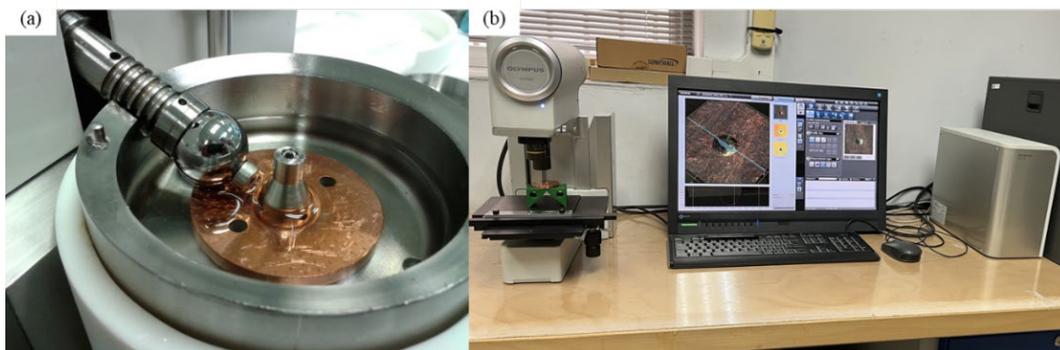
Ye *et al.* analizan la influencia del perfil de la textura, es decir, si la cavidad generada tiene un perfil cilíndrico, semiesférico o de tronco de cono, entre otros. Dependiendo de este perfil, los autores analizan el efecto del texturizado sobre la fricción, mostrando en sus resultados que perfiles cilíndricos alcanzan una reducción mayor de esta variable [21]. El perfil de la cavidad de una textura puede venir determinado por el proceso de fabricación como ocurre en el caso de emplear ablación láser. El láser se enfoca sobre la superficie con un cierto ángulo, que hace que la textura acabe teniendo una forma de tronco de cono. Por otro lado, un proceso como la fotolitografía y ataque químico, al atacar con un fluido puede generar cavidades con un perfil cilíndrico, siempre que las variables de la reacción química estén ajustadas correctamente [7].

En este artículo se emplean redes neuronales artificiales (RNA) para la predicción del coeficiente de fricción en contactos puntuales lubricados y a diferencia de estudios previos realizados como el de la referencia [19], estudio que servirá de base para éste, el algoritmo propuesto se desarrolla empleando datos que se han obtenido midiendo los patrones de texturizado fabricados tanto por fotolitografía y ataque químico como mediante ablación láser. Así, se trata de evaluar la influencia de la precisión del método de fabricación del texturizado en la fricción que se produce en el contacto.

## 2. Materiales y métodos

Para este estudio, como datos de partida se han empleado un conjunto de ensayos de fricción realizados en la máquina Mini-Traction Machine (MTM) de PCS instruments. En los ensayos se han empleado discos de cobre microtexturizados con diferentes patrones geométricos, en contacto con una bola de acero de 19 mm de diámetro, generando así el contacto puntual que se ha lubricado con un aceite base PAO-6, como se puede ver en Figura 2 (a). Estos ensayos han sido realizados en estudios previos llevados a cabo por este grupo de investigación [7], [10], [19], [22-24]. En este trabajo se han realizado algunas pruebas de repetibilidad de los ensayos en la MTM que están en línea con los buenos resultados reportados por el grupo de investigación en el estudio previo [25].

El conjunto de datos está formado por un total de 35 probetas (23 fabricadas mediante fotolitografía y ataque químico, 10 fabricadas mediante ablación láser y 2 sin textura) ensayadas cada una de ellas bajo 12 condiciones de trabajo considerando combinaciones de SRR y carga, indicadas en Tabla 1. En cuanto a la tipología de las texturas, se han empleado probetas texturizadas con forma elíptica, circular, radial y sin textura teniendo en cuenta las características y rangos que se definen en la referencia [19] y que se incluyen a continuación en la Tabla 1 junto al rango de condiciones de trabajo ensayadas.



**Figura 2.** (a) Equipo experimental Minitraction-Machine antes de realizar el ensayo; (b) medición del tamaño textura de una de las probetas del conjunto de datos con el microscopio DSX-500.

**Tabla 1.** Variables geométricas que definen el texturizado y variables del ensayo de fricción en la MTM.

Variable	Rango	Definición
<b>Geométricas</b>		
Forma		Textura elíptica, circular, radial o sin textura
Dimensión 1	0-350 $\mu\text{m}$	Diámetro menor en el caso de elipses en la dirección de movimiento, radio en el caso de círculos o ancho del surco en caso de textura radial
Dimensión 2	0-1100 $\mu\text{m}$	Diámetro mayor en el caso de elipses en la dirección del movimiento, radio en el caso de círculos o largo del surco en caso de textura radial
Densidad texturizado	0-25 %	Área de la superficie que ha sido texturizada respecto al total
Profundidad	0-185 $\mu\text{m}$	Altura de la cavidad texturizada
Rugosidad antes del texturizado	0.007 y 0.1 $\mu\text{m}$	Rugosidad promedio de la superficie de la probeta sin texturizar
<b>De ensayo</b>		
Relación deslizamiento-rodadura	5-100 %	Cociente entre la diferencia de las velocidades bola-disco y la velocidad media de ambos
Velocidad media	100-3500 mm/s	Velocidad media de la bola y el disco
Carga normal	5 y 20 N	Carga normal aplicada para generar el contacto
Temperatura del baño de lubricante	40 y 80 $^{\circ}\text{C}$	Temperatura estable del baño de lubricante durante el ensayo

Como se ha indicado, las probetas de cobre microtexturizadas que han sido ensayadas en los trabajos previamente mencionados, fueron fabricadas mediante fotolitografía y ataque químico, así como mediante ablación láser. Estos procesos de fabricación, aunque cuentan con una precisión razonable, pueden generar ciertas desviaciones en el tamaño o profundidad de las texturas. Por esta razón, las probetas han sido caracterizadas con un microscopio opto-digital DSX 500 de Olympus mostrado en la Figura 2 (b). Dadas las desviaciones de tamaño entre texturas individuales de una misma probeta, se realizan 5 medidas para obtener el valor medio y tras esto se calcula la diferencia relativa promedio entre el valor teórico esperado y el real con la fórmula (1). Además, considerando el tamaño real de las texturas, la densidad de texturizado, puede variar y por tanto se calcula de nuevo empleando la fórmula (2).

$$Diferencia\ relativa\ promedio = \frac{1}{n} \sum \frac{(tamaño\ real - tamaño\ teórico)}{(tamaño\ teórico)} \quad (1)$$

$$densidad\ text.\ real\ (\%) = densidad\ text.\ teórica\ (\%) \cdot \frac{área\ real\ texturizada}{área\ teórica\ texturizada} \quad (2)$$

Con los datos de los texturizados obtenidos mediante mediciones, se modifica el conjunto de datos compuesto por las 35 probetas mencionadas previamente. De esta manera se crea el conjunto con las variables de tamaño y densidad obtenidas a partir de las medidas tomadas con el microscopio DSX-500. Previo al desarrollo de las redes neuronales, el conjunto de datos es preprocesado realizando un escalado de los datos al rango 0 y 1 para cada variable mediante la función “MinMaxScaler” de la librería de funciones Keras. Una vez los datos han sido escalados, se seleccionan las probetas que han sido fabricadas mediante fotolitografía y ataque químico del conjunto total (40320 datos) para generar los conjuntos de entrenamiento, empleándose para este conjunto el 90% de los datos y de validación con el 10% restante de los datos totales, siendo los datos distribuidos de manera aleatoria en cada conjunto. Cabe destacar que los 40320 datos fueron obtenidos mediante un proceso de data augmentation en el trabajo previo [19]. Por otro lado, las probetas fabricadas mediante láser se emplean como conjunto de test, al igual que en los estudios previos realizados [7], [19] con los que se comparan los resultados obtenidos para determinar la influencia de la precisión de la fabricación en la predicción del coeficiente de fricción.

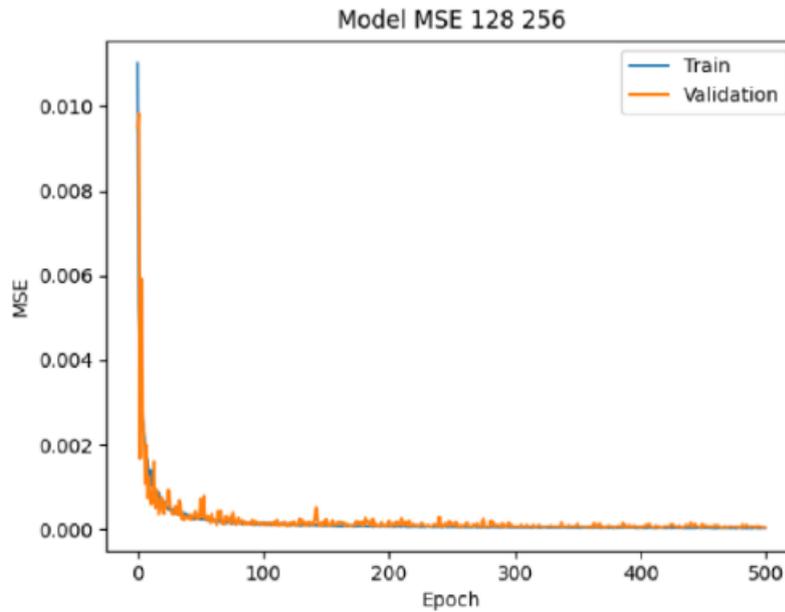
Definidos los conjuntos de entrenamiento, validación y test, se desarrollan los algoritmos de RNA para predecir una variable de salida, el coeficiente de fricción, a partir de 10 variables de entrada: forma del texturizado, dimensión 1, dimensión 2, profundidad, densidad de texturizado, rugosidad promedio antes de texturizado, carga normal aplicada, velocidad media, relación deslizamiento-rodadura y temperatura del baño de lubricante.

Para obtener la red neuronal óptima se han desarrollado diferentes configuraciones variando algunos de sus hiperparámetros principales: el número de capas ocultas de 1 hasta 3, el número de neuronas por capa desde 32 hasta 512 en múltiplos de dos, y la tasa de aprendizaje (tr) entre 1,00E-02 y 1,00E-04. En todos los modelos se ha utilizado como función de activación de las capas ocultas “ReLU” y el error cuadrático promedio (MSE, de sus siglas en inglés) como función de pérdida a minimizar. El proceso de entrenamiento es “feedforward-backpropagation” y se emplean un total de 500 iteraciones, de las que se selecciona como configuración óptima la iteración en la que se obtiene un menor MSE en el conjunto de validación.

$$MSE = \frac{1}{n} \sum (Y_i - \hat{Y}_i)^2 \quad (3)$$

Siendo  $n$  el número de muestras,  $Y_i$  el valor real e  $\hat{Y}_i$  el valor de predicción

A continuación, se evalúan los modelos obtenidos considerando el MSE para los conjuntos de validación y entrenamiento y se seleccionan aquellos que hayan alcanzado un valor menor en validación, teniendo en cuenta además que la diferencia del MSE (3) entre los conjuntos de entrenamiento y validación sea lo menor posible, asegurando así que no existen problemas de sobreajuste o subajuste. Adicionalmente, como comprobación visual se emplean gráficas como la Figura 3 donde se muestra el entrenamiento de una red neuronal, observándose que no existe subajuste u sobreajuste ya que tanto la curva de validación como entrenamiento están prácticamente superpuestas.



**Figura 3.** Entrenamiento de una red neuronal de dos capas ocultas con 128 y 256 neuronas respectivamente

Finalmente, una vez se han seleccionado los mejores modelos, se procede a emplear el conjunto de muestras fabricadas mediante láser para determinar el mejor de ellos. Estos datos componen el conjunto de test, en el que se evalúa la capacidad predictiva de los algoritmos seleccionados con muestras que no han sido empleadas en el proceso de entrenamiento y selección de modelos. Además, se emplea una nueva métrica, el error absoluto relativo promedio (denominado en adelante con sus siglas en inglés, MAE%). Se utiliza esta medida de error relativo para comparar entre los mejores modelos, ya que todas las probetas han sido ensayadas a diferentes cargas y SRR, variando el rango del coeficiente de fricción en cada una de las condiciones de ensayo. Cabe destacar que, para calcular el MAE% (4) con el conjunto de test, solamente se han usado los ensayos realizados con carga a 20 N porque al realizar ensayos a 5 N la MTM se encuentra cerca del límite de sus condiciones de trabajo, lo que afecta a su sensibilidad dando como resultado valores menos precisos.

$$MAE\% = \frac{1}{n} \sum \frac{(Y_i - \hat{Y}_i)^2}{Y_i} \cdot 100\% \quad (4)$$

Siendo  $n$  el número de muestras,  $Y_i$  el valor real e  $\hat{Y}_i$  el valor de predicción

### 3. Resultados y discusión

En esta sección se detallan los resultados obtenidos en este estudio, comenzando por las mediciones realizadas para analizar el tamaño real de las texturas respecto al tamaño de diseño; continuando con la elección de las mejores RNA en base al MSE y finalmente la predicción de los diferentes algoritmos sobre el conjunto de test basándose en la métrica MAE%.

En la Tabla 2 se muestra un ejemplo comparando algunas de las probetas microtexturizadas. Puede verse que para las cuatro probetas mostradas las dimensiones 1 y 2 (D1 y D2) que representan los diámetros para las texturas elípticas y el radio para las texturas circulares tienen una cierta desviación respecto al tamaño de diseño. Incluso el tamaño medido varía entre probetas que tienen el mismo tamaño de diseño. Cabe mencionar, que de las 23 probetas fabricadas mediante fotolitografía, hubo 7 en las que no se pudieron realizar las medidas con el microscopio debido a que no se encontraron estas probetas que fueron fabricadas más de 5 años antes en trabajos

previos, por lo que su tamaño se calculó considerando la desviación promedio de todas las probetas fabricadas mediante la misma técnica y con la misma forma. Asimismo, todas las probetas fabricadas mediante ablación láser pudieron ser medidas. En consecuencia a los valores medidos para D1 y D2, se modificó la densidad de texturizado como se muestra en la tabla.

También puede observarse en la Tabla 2 que la profundidad presenta cierta desviación. Sin embargo, solamente pudo medirse en 10 de las 33 probetas debido al pequeño tamaño de las cavidades y la resolución del equipo de medida. Por tanto, solamente fue modificada la profundidad para estas probetas y para aquellas que no pudo medirse esta variable se mantuvo el valor de diseño.

**Tabla 2.** Ejemplo de probetas microtexturizadas fabricadas por fotolitografía y ataque químico donde se compara la medida realizada con el microscopio respecto al tamaño de diseño.

Nombre	D1 (μm)	D2 (μm)	D1 diseño (μm)	D2 diseño (μm)	Profundidad (μm)	Profundidad diseño (μm)	Densidad Text. (%)	Densidad Text. diseño (%)
Elipse 5	211,055	639,982	150,000	600,000	78,000	78,000	15,008	10
Elipse 6	207,575	635,620	150,000	600,000	95,632	100,000	7,330	5
Círculo 14	193,484	193,484	200,000	200,000	67,355	70,000	9,359	10
Círculo 15	218,261	218,261	200,000	200,000	70,000	70,000	10,685	10

A continuación, se muestran las desviaciones relativas promedio de las variables D1 y D2 en la Tabla 3, diferenciando entre probetas fabricadas mediante fotolitografía y láser, así como entre geometrías elípticas y circulares. En cuanto a las elipses, existe mayor desviación para la dimensión 1, resultado coherente al ser el diámetro menor de la elipse en todos los casos, ya que la precisión de la técnica de fabricación se ve afectada al realizar tamaños menores. Si se comparan las técnicas de fabricación, ambas exhiben una precisión bastante similar, excepto en el caso de las probetas con texturas circulares en las que las fabricadas mediante láser muestran una desviación mayor.

**Tabla 3.** Valores promedio de la desviación relativa en porcentaje de cada tipo de textura y técnica de fabricación.

	Desviación relativa de D1 (%)	Desviación relativa de D2 (%)
Elipse fabricada mediante fotolitografía	34,36%	3,71%
Circular fabricada mediante fotolitografía	9,13%	9,13%
Elipse fabricada mediante láser	23,57%	5,12%
Circular fabricada mediante láser	27,89%	27,89%

Habiendo realizado el preprocesamiento de los datos y el entrenamiento de las RNA con las diferentes configuraciones de hiperparámetros, como se ha mencionado en la sección 2, se realiza la Tabla 4 que contiene los resultados de la métrica de calidad MSE para los conjunto de entrenamiento y validación de cada uno de los 8 mejores modelos. En esta tabla puede identificarse de cada modelo el número de capas, neuronas por capa y la tasa de aprendizaje empleada. Los modelos están ordenados de menor a mayor MSE para el conjunto de validación.

En primer lugar, destaca que 3 de los 4 mejores modelos tienen dos capas. Este hecho indica que modelos de 3 capas o más complejos no son necesarios para predecir el coeficiente de fricción en probetas microtexturizadas dentro del rango de variables de trabajo que se están estudiando. Aun así, puede haber configuraciones de RNAs de tres capas que funcionen bien para predecir esta variable. En segundo lugar, se observa que los 8 modelos presentan un valor de MSE muy bajo, siendo mínima la diferencia entre los modelos, lo que quiere decir que serán capaces de predecir el coeficiente de fricción con una precisión similar en este conjunto. En tercer lugar, ningún modelo presenta sobreajuste ya que la diferencia entre el MSE de validación y entrenamiento es escasa en todos los casos. Por último, la tasa de aprendizaje óptima se establece en 1,00E-03 ya que los 8 modelos recopilados muestran el mismo valor. Este hecho puede deberse a que valores mayores como 1,00E-02 hagan que no se haya el mínimo de MSE, quedando por tanto resultados cercanos pero mayores, y de igual forma valores menores como 1,00E-04 pueden hacer que el entrenamiento se estanque en un mínimo local de la función MSE, siendo por tanto modelos subajustados.

Por tanto, en vista a los resultados mostrados en la Tabla 4, se decide considerar que los cuatro primeros modelos de la tabla son los mejores, ya que presentan un MSE menor que el resto y la diferencia de esta métrica entre los conjuntos de entrenamiento y validación no muestra un problema de sobreajuste. Además, al seleccionar los cuatro

primeros modelos se están seleccionando los 3 mejores, todos ellos con dos capas ocultas, y el mejor modelo para predecir el coeficiente de fricción con tres capas ocultas.

**Tabla 4.** Colección de los 8 mejores modelos de RNAs mostrando: el número de capas, neuronas por capa, tasa de aprendizaje, métrica MSE para los conjuntos validación y test, y la diferencia de MSE en valor absoluto entre ambos conjuntos.

Modelo	n1	n2	n3	tr inicial	tr final	MSE entrenamiento	MSE validación	Diferencia MSE
RNA 1	512	256		1,00E-03	1,00E-03	6,01E-05	4,60E-05	1,41E-05
RNA 2	128	256		1,00E-03	1,00E-03	4,65E-05	4,76E-05	1,13E-06
RNA 3	256	512		1,00E-03	1,00E-03	4,74E-05	4,80E-05	5,03E-07
RNA 4	128	256	128	1,00E-03	1,00E-03	4,67E-05	4,81E-05	1,36E-06
RNA 5	512	64		1,00E-03	1,00E-03	3,79E-05	4,85E-05	1,06E-05
RNA 6	256	128	32	1,00E-03	1,00E-03	4,40E-05	4,98E-05	5,75E-06
RNA 7	512	512		1,00E-03	1,00E-03	6,25E-05	5,03E-05	1,22E-05
RNA 8	256	64		1,00E-03	1,00E-03	4,08E-05	5,05E-05	9,76E-06

Seleccionados los mejores modelos desarrollados en este estudio, se emplean para predecir el coeficiente de fricción en un conjunto de probetas de fabricadas mediante láser y que no han sido empleadas para el entrenamiento ni validación de las RNAs.

En la Tabla 5 se recoge el MAE % calculado para cada probeta, así como el promedio de este error para todas las probetas de test. Puede observarse que, las redes neuronales desarrolladas en este trabajo han conseguido obtener mejores resultados de predicción que la red neuronal realizada en un estudio previo de este equipo de investigación, como muestra el promedio del MAE%. En el estudio [19], la red neuronal fue entrenada con el mismo conjunto de probetas pero con los valores de diseño de las dimensiones geométricas de las texturas. Comparando muestra a muestra del conjunto de test, también las RNAs de este estudio consiguen superar la capacidad predictiva en comparación con la RNA de [19] en casi todos los casos, obteniendo un MAE% menor. Este hecho evidencia que el uso de las dimensiones geométricas medidas, y por ende la precisión en las técnicas de fabricación, afecta en gran medida a la correcta predicción del coeficiente de fricción.

Cabe también mencionar, que el uso de las variables geométricas medidas hace que la variabilidad del conjunto de datos sea mayor, es decir, que las muestras texturizadas tengan mayores diferencias entre sí, lo que mejora la predicción del coeficiente de fricción, pero a su vez hace necesarios modelos más complejos de RNAs.

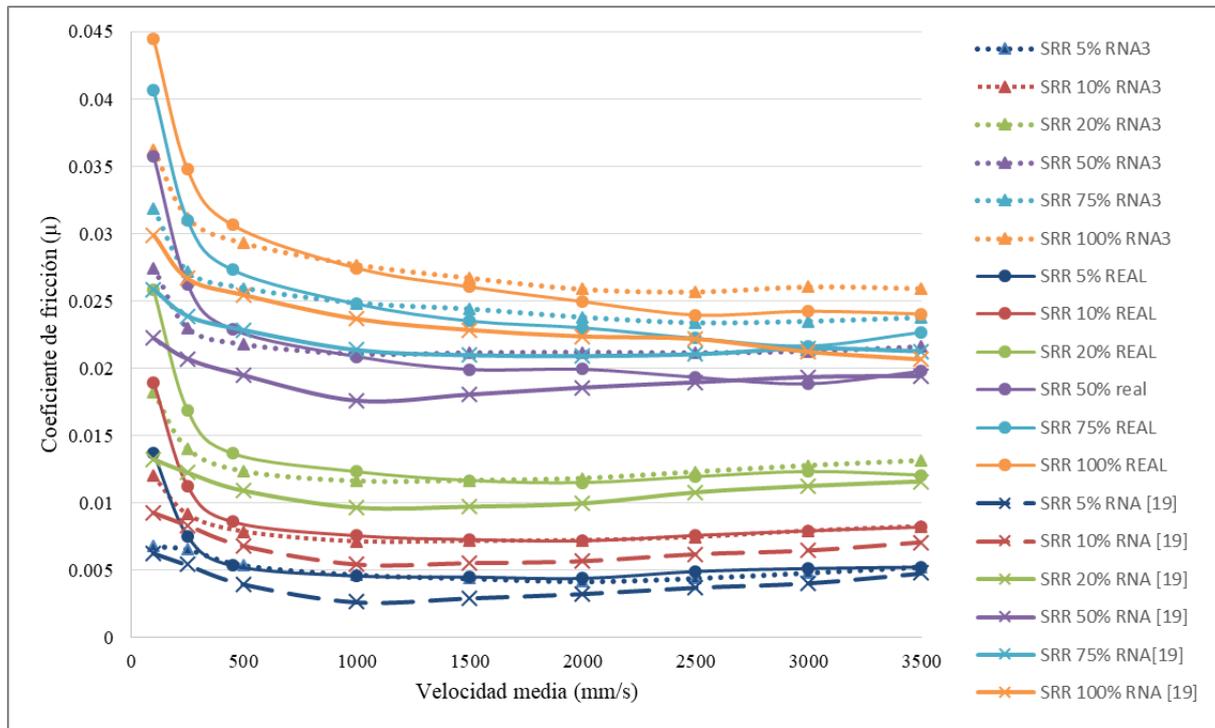
Finalmente, de las nuevas redes se selecciona como la mejor la RNA3 con 256 y 512 neuronas en su primera y segunda capa oculta, respectivamente. Este modelo presenta un MAE% de 11,59%, lo que supone un 4,01% menos de error relativo respecto a la RNA desarrollada en [19]. Comparando ahora la RNA3 con respecto a los otros 3 modelos desarrollados en el presente estudio, ha sido elegida como el algoritmo óptimo considerando las siguientes tres razones en conjunto: en primer lugar, se trata del tercer modelo con mejor resultado de MSE en el conjunto de validación, distanciándose tan solo 0,2E-05 del mejor de los modelos (Tabla 4); en segundo lugar, es la RNA que presenta menor diferencia en la métrica MSE entre los conjuntos de entrenamiento y validación (Tabla 4) y en tercer lugar, es el segundo modelo que mejores predicciones obtiene en el conjunto de test teniendo en cuenta la métrica MAE%, con una diferencia muy baja respecto al modelo que obtiene un mejor resultado.

**Tabla 5.** Error absoluto promedio (MAE %) entre la predicción y el coeficiente de fricción real para cada muestra del conjunto de test. En columnas se muestra la red neuronal desarrollada en el estudio previo con 64 neuronas y una sola capa oculta [19] y las cuatro mejores redes de este trabajo. En la última fila se recoge el promedio de MAE% para cada RNA.

Conjunto de test	RNA 64 nn [19]	RNA1 512, 256 nn	RNA2 128, 256 nn	RNA3 256, 512 nn	RNA4 128, 256, 128 nn
1	8,93 %	7,23 %	7,51 %	7,82 %	7,12 %
2	15,38 %	12,34 %	12,59 %	12,02 %	11,64 %
3	16,10 %	12,05 %	9,38 %	7,54 %	14,13 %
4	13,35 %	10,89 %	10,05 %	8,90 %	12,14 %
5	19,17 %	9,94 %	10,85 %	8,45 %	8,83 %
6	12,00 %	9,22 %	8,70 %	10,61 %	9,56 %
7	14,70 %	7,81 %	14,88 %	12,77 %	9,46 %
8	21,87 %	18,61 %	26,74 %	25,11 %	21,75 %
9	18,52 %	12,38 %	12,17 %	11,87 %	11,09 %
10	16,00 %	13,09 %	9,54 %	10,79 %	10,79 %
<b>Promedio MAE %</b>	<b>15,60 %</b>	<b>11,36 %</b>	<b>12,24 %</b>	<b>11,59 %</b>	<b>11,65 %</b>

A continuación, con la RNA3 seleccionada como mejor algoritmo de predicción, se muestran en la Figura 4 los resultados de predicción obtenidos para la muestra 5 del conjunto de test como ejemplo, comparándose con los resultados obtenidos por la RNA desarrollada en [19] y el coeficiente de fricción real para las 6 condiciones de ensayo con carga 20N y temperatura del baño de lubricante 40°C. Observando esta figura, puede analizarse la capacidad predictiva de la RNA3 y la RNA de [19] mostrando que la RNA3 da un coeficiente de fricción mayor en todos los ensayos y con un aumento más pronunciado a bajas velocidades donde comienza a producirse la lubricación mixta e incluso límite, por lo que captura mejor el comportamiento de las curvas de fricción.

Por otro lado, comparando la predicción obtenida con la RNA3 con el coeficiente de fricción real para cada ensayo, puede verse que los resultados de predicción son en todos los casos muy precisos, hecho que también se refleja al obtener un 8,45% de MAE% según la Tabla 5. Con velocidad media desde 500 hasta 3500 mm/s la predicción del algoritmo es muy precisa, especialmente para los ensayos a SRR desde 5 hasta 20%. A velocidades menores de 500 mm/s la RNA3 muestra una tendencia creciente del coeficiente fricción, pero no tan acusada como el ensayo real. Este factor puede deberse al método de fabricación, ya que las probetas empleadas en el conjunto de test fueron realizadas mediante láser, mientras que las del conjunto de entrenamiento y validación fueron fabricadas mediante fotolitografía y ataque químico. Este cambio del proceso de fabricación puede afectar a la forma del perfil de la cavidad y por tanto, a la capacidad de la textura para reducir la fricción, como se analiza en la referencia [21]. Considerando esta referencia, las texturas con cavidad en forma de tronco de cono (como aquellas generadas mediante ablación láser), presentan una reducción menor de la fricción en comparación con las que tienen forma cilíndrica (como las fabricadas mediante fotolitografía más ataque químico). Por ello, al haber entrenado la RNA solamente con muestras fabricadas mediante fotolitografía, el resultado de la predicción tiende a subestimar el coeficiente de fricción a velocidades inferiores a 500 mm/s, ya que los datos de entrenamiento pueden mostrar una reducción de la fricción mayor que los datos de test.



**Figura 4.** Predicción del coeficiente de fricción para los ensayos a carga 20 N, 40 °C y 6 SRR con la probeta texturizada 5 del conjunto de test. Se muestra en línea punteada la predicción de la RNA3, en línea sólida el coeficiente de fricción real y en línea discontinua la RNA de [19].

## 4. Conclusiones

En este artículo se ha evaluado cómo afecta la precisión de dos procesos de fabricación de texturizados, fotolitografía más ataque químico y ablación láser en el desarrollo de algoritmos de IA, en este caso RNAs, para la correcta predicción del coeficiente de fricción en contactos mecánicos lubricados.

En primer lugar, puede verse que el tamaño medido de las geometrías dista incluso un 34,36% respecto al tamaño de diseño, lo que determina la necesidad de medir el tamaño de las microtexturas tras la fabricación, tanto en el caso de fotolitografía y ataque químico, como ablación láser.

En segundo lugar, se determina que el uso de los valores medidos del tamaño de las geometrías para definir las diferentes probetas texturizadas afecta en gran medida tanto a la capacidad predictiva de los modelos de RNAs, como a su complejidad. Al existir mayor variabilidad en el conjunto de datos y definir de forma más correcta el tamaño real de las microtexturas, las RNAs desarrolladas en este estudio han sido capaces de obtener resultados de coeficiente de fricción más cercanos a la realidad que la RNA obtenida en [19]. Este hecho evidencia la gran influencia de la precisión de los procesos de fabricación de texturizados. Este hecho se ve apoyado por la comparación de las RNAs con nuevos resultados experimentales que conforman el conjunto de test.

En tercer lugar, la predicción de la RNA3, el modelo seleccionado como óptimo en este estudio, muestra gran exactitud para condiciones de trabajo en las que se produce una lubricación en película gruesa o bien, está comenzando la lubricación mixta. En condiciones más severas, la RNA3 predice correctamente el aumento del coeficiente de fricción, pero tiende a subestimarlos, mostrándose mayor diferencia a SRR altos. Este hecho puede deberse al uso de dos procesos de fabricación distintos entre, los conjuntos de entrenamiento y validación en los que se han empleado solamente muestras realizadas mediante fotolitografía y ataque químico, mientras que el conjunto de test las muestras han sido fabricadas mediante láser, pudiendo así afectar a la predicción de algoritmo. Por tanto, se concluye que este factor debe ser investigado y se analizará en futuros estudios tratando de mejorar aún más los algoritmos presentados.

## 5. Agradecimientos

Repsol Technology Lab (Móstoles, Madrid) por su colaboración en el desarrollo de este trabajo.

## 6. Referencias

- [1] P. Jost, "Lubrication (tribology), education and research. A report on the present position and industry's needs", UK government, United Kingdom, mar. (1966)

- [2] K. Holmberg y 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), doi: 10.1016/j.triboint.2019.03.024
- [3] R. Gohar y H. Rahnejat, *Fundamentals Of Tribology (Third Edition)*. World Scientific, (2018)
- [4] M. Wakuda, Y. Yamauchi, S. Kanzaki, y Y. Yasuda, “Effect of surface texturing on friction reduction between ceramic and steel materials under lubricated sliding contact”, *Wear*, **254**, n.º 3, pp. 356-363, (2003) doi: 10.1016/S0043-1648(03)00004-8
- [5] A. Predescu, M. D. Pascovici, T. Cicone, C. S. Popescu, C. Grigoriu, y D. Dragulinescu, “Friction evaluation of lubricated laser-textured surfaces”, *Lubrication Science*. **22**, n.º 10, pp. 431-442, (2010), doi: 10.1002/lis.123
- [6] U. Pettersson y S. Jacobson, “Influence of surface texture on boundary lubricated sliding contacts”, *Tribology International*, **36**, n.º 11, pp. 857-864, (2003), doi: 10.1016/S0301-679X(03)00104-X
- [7] F. Franco Martínez, “Artificial intelligence aided design of microstructured surfaces for tribology and biointerfaces engineering”, Tesis Doctoral, Universidad Politécnica de Madrid, (2023). doi: 10.20868/UPM.thesis.77158
- [8] H. Yu, X. Wang, y F. Zhou, “Geometric Shape Effects of Surface Texture on the Generation of Hydrodynamic Pressure Between Conformal Contacting Surfaces”, *Tribology Letters*, **37**, n.º 2, pp. 123-130, (2010), doi: 10.1007/s11249-009-9497-4
- [9] A. Kovalchenko, O. Ajayi, A. Erdemir, y G. Fenske, “Friction and wear behavior of laser textured surface under lubricated initial point contact”, *Wear*, **271**, n.º 9-10, pp. 1719-1725, (2011), doi: 10.1016/j.wear.2010.12.049
- [10] J. Echávarri Otero, E. de la G. Ochoa, I. B. Vallinot, y E. C. Tanarro, “Optimising the design of textured surfaces for reducing lubricated friction coefficient”, *Lubrication Science*, **29**, n.º 3, pp. 183-199, (2017), doi: 10.1002/lis.1363
- [11] C. Gachot, A. Rosenkranz, S. M. Hsu, y H. L. Costa, “A critical assessment of surface texturing for friction and wear improvement”, *Wear*, **372-373**, pp. 21-41, (2017), doi: 10.1016/j.wear.2016.11.020
- [12] Y. Xu *et al.*, “Characterization of the Tribological Behavior of the Textured Steel Surfaces Fabricated by Photolithographic Etching”, *Tribology Letters*, **66**, n.º 2, p. 55, (2018), doi: 10.1007/s11249-018-1003-4
- [13] A. Rosenkranz, A. Szurdak, C. Gachot, G. Hirt, y F. Mücklich, “Friction reduction under mixed and full film EHL induced by hot micro-coined surface patterns”, *Tribology International*, **95**, pp. 290-297, (2016), doi: 10.1016/j.triboint.2015.11.035
- [14] L. Burstein y D. Ingman, “Pore Ensemble Statistics in Application to Lubrication Under Reciprocating Motion”, *Tribology Transactions*, **43**, n.º 2, pp. 205-212, (2000), doi: 10.1080/10402000008982330
- [15] A. Ronen, I. Etsion, y Y. Kligerman, “Friction-Reducing Surface-Texturing in Reciprocating Automotive Components”, *Tribology Transactions*, **44**, n.º 3, pp. 359-366, (2001), doi: 10.1080/10402000108982468
- [16] M. Marian, P. Grützmacher, A. Rosenkranz, S. Tremmel, F. Mücklich, y S. Wartzack, “Designing surface textures for EHL point-contacts - Transient 3D simulations, meta-modeling and experimental validation”, *Tribology International*, **137**, pp. 152-163, (2019), doi: 10.1016/j.triboint.2019.03.052
- [17] U. M. R. Paturi, S. T. Palakurthy, y N. S. Reddy, “The Role of Machine Learning in Tribology: A Systematic Review”, *Archives of Computing Methods in Engineering*, **30**, n.º 2, pp. 1345-1397, (2023), doi: 10.1007/s11831-022-09841-5
- [18] A. Rosenkranz, M. Marian, F. J. Profito, N. Aragon, y R. Shah, “The Use of Artificial Intelligence in Tribology—A Perspective”, *Lubricants*, **9**, n.º 1, p. 2, (2020), doi: 10.3390/lubricants9010002
- [19] F. Franco-Martínez, J. J. García Moltó, J. Echávarri Otero, E. Chacón Tanarro, y A. Díaz Lantada, “Aplicación de Inteligencia Artificial para la predicción de la fricción lubricada en contactos mecánicos microtexturizados”, *Actas del XV Congreso Iberoamericano de Ingeniería Mecánica*, Madrid (2022) doi: 10.5944/bicim2022.106
- [20] J. Echávarri Otero *et al.*, “Artificial neural network approach to predict the lubricated friction coefficient”, *Lubrication Science*, **26**, n.º 3, pp. 141-162, (2014), doi: 10.1002/lis.1238
- [21] J. Ye *et al.*, “A Simple Analysis of Texture-Induced Friction Reduction Based on Surface Roughness Ratio”, *Tribology Letters*, **69**, n.º 2, p. 67, (2021), doi: 10.1007/s11249-021-01440-y

- 
- [22] I. Bellón Vallinot, “Optimización de la eficiencia en contactos lubricados a través del texturizado superficial”, Trabajo Fin de Grado, Universidad Politécnica de Madrid, Madrid (2015)
- [23] J. J. G. Moltó, “Inteligencia artificial aplicada al análisis tribológico de texturizados superficiales con Python”, Trabajo Fin de Grado, Universidad Politécnica de Madrid (2021)
- [24] I. G. Ayuso, “Aplicación de redes neuronales al análisis tribológico de texturizados superficiales en Python”, Trabajo Fin de Grado, Universidad Politécnica de Madrid (2023)
- [25] J. Echávarri otero *et al.*, “Analytical model for predicting the friction coefficient in point contacts with thermal elastohydrodynamic lubrication”, *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, **225**, n.º 4, pp. 181-191, (2011), doi: 10.1177/1350650111398848