

APLICACIÓN DE REDES NEURONALES A LA ESTIMACIÓN DE VIDA A FATIGA EN FRETTING Y EN PROBETAS ENTALLADAS

Z. Conde, D. García-Vallejo, C. Navarro*, J. Domínguez

Departamento de Ingeniería Mecánica y Fabricación.
Escuela Técnica Superior de Ingeniería. Universidad de Sevilla
Camino de los Descubrimientos s/n, 41092 Sevilla-España

* Persona de contacto: cnp@us.es

RESUMEN

El presente trabajo aplica una red neuronal entrenada con ensayos de fatiga por fretting en distintos materiales y geometrías a un grupo de ensayos con probetas entalladas con distintos concentradores. A pesar de las diferencias que hay entre fretting y fatiga en entallas, tienen en común la existencia de un gradiente de tensiones. Las redes neuronales utilizan como entrada los valores de tensión y deformación en diferentes profundidades cercanas a la superficie para poder captar el gradiente y la relación entre la curva de fatiga simple del material y la tensión de rotura para tener en cuenta el material. Se plantean tres redes neuronales: primero, se reutiliza la red previa entrenada únicamente con ensayos de fretting, habiendo demostrado su generalización ante diferentes aleaciones además de las bondades de la metodología *k-fold cross-validation* para el entrenamiento del modelo; se entrena posteriormente una segunda red ajustando sistemáticamente hiperparámetros, resultando una arquitectura del modelo más profunda y optimizada; y, por último, se mantiene el enfoque de red pero se refina el conjunto de variables mediante un análisis de correlación y la generación de descriptores derivados de perfiles subsuperficiales para mejorar la representatividad del modelo.

PALABRAS CLAVE: Redes neuronales, cross validation, fatiga en entallas, fatiga por fretting, estimación de vida.

ABSTRACT

The present work applies a neural network trained with fretting fatigue tests in different materials and geometries to a group of tests with notched specimens with different notch geometries. Despite the differences between fretting and fatigue of notched specimens, they have in common the existence of a stress gradient. The neural networks use as input the stress and strain values at different depths near the surface to capture this gradient and the relationship between the simple fatigue curve of the material and the ultimate strength to take the material into account. Three neural networks are proposed: first, the previously developed network trained exclusively on fretting tests is reused, having demonstrated generalization across different alloys in addition to the benefits of the *k-fold cross-validation* methodology for model training; a second network is subsequently trained by systematically tuning hyperparameters, resulting in a deeper and optimized model architecture; and, finally, the neural-network approach is retained but the set of variables is refined through correlation analysis and the generation of derived descriptors from subsurface profiles to improve the model's representativeness.

KEYWORDS: Neural networks, cross validation, notch fatigue, fretting fatigue, life estimation.

1. INTRODUCCIÓN

La fatiga es uno de los mecanismos de fallo más relevantes en componentes sometidos a cargas cíclicas, especialmente cuando existen concentraciones de tensión o contactos mecánicos. En este contexto, la fatiga en entallas y por *fretting* representan dos de los problemas más críticos y complejos desde el punto de vista del diseño y la predicción de vida. La fatiga en entallas aparece en geometrías con cambios bruscos de sección, orificios o defectos geométricos, donde se generan elevados gradientes de tensión que favorecen la iniciación de grietas. Por su parte, la fatiga por *fretting* se produce en contactos sometidos a pequeñas oscilaciones relativas, típicamente en uniones atornilladas, acoplamientos eje-buje, álabes de turbinas o cables, y suele conducir a fallos prematuros incluso bajo niveles de carga moderados. La elevada incidencia industrial de

ambos fenómenos justifica la necesidad de modelos predictivos fiables.

Desde un punto de vista mecánico, la fatiga en entallas y la fatiga por *fretting* comparten ciertas similitudes. En ambos casos existe una concentración de tensiones que favorece la iniciación de grietas. No obstante, existen diferencias sustanciales entre ambos fenómenos. En *fretting*, los gradientes de tensión son generalmente mucho más severos, el daño se inicia inevitablemente en la superficie y está acompañado por procesos de desgaste y daño superficial [1]. Además, el estado tensional es multiaxial y, en muchos casos, no proporcional, debido a la combinación de cargas normales, tangenciales y a la evolución temporal del contacto.

Tradicionalmente, la predicción de vida a fatiga se ha abordado mediante tres enfoques principales: modelos

basados exclusivamente en la iniciación de grieta, modelos centrados en la propagación y aproximaciones mixtas que combinan iniciación y crecimiento hasta fallo. Los primeros suelen apoyarse en parámetros locales de tensión o deformación, mientras que los segundos emplean mecánica de la fractura. Las formulaciones híbridas tratan de capturar de forma más realista el proceso completo de daño. Paralelamente, se observa un incremento notable en el uso de redes neuronales, aprendizaje automático y métodos basados en datos aplicados a problemas de fatiga, impulsado por la disponibilidad de bases de datos experimentales y la capacidad de estos métodos para manejar relaciones altamente no lineales y multivariantes [2].

En trabajos previos los autores han propuesto redes neuronales para la predicción de vida a fatiga en condiciones de *fretting* [3], [4], mostrando una buena capacidad predictiva frente a resultados experimentales publicados. Este artículo amplía dichos desarrollos, incluyendo la fatiga en entallas, profundizando en la comparación entre ambos tipos de fatiga y proponiendo un marco de análisis unificado que permita capturar sus similitudes y diferencias, así como evaluar el potencial de enfoques basados en datos en este contexto.

2. REDES NEURONALES APLICADAS A FATIGA

Debido a la variabilidad y la incertidumbre observadas en métodos clásicos de estimación de vida a fatiga y particularmente por *fretting* [5]–[10], las redes neuronales (NNs) se han consolidado como herramientas útiles para problemas de fatiga: permiten capturar relaciones no lineales y multivariantes directamente a partir de datos, lo que resulta atractivo cuando la modelización analítica es costosa o depende de parámetros difíciles de identificar [11]. Su uso se ha intensificado en la última década en múltiples materiales y configuraciones [12]–[14].

Los primeros trabajos aplicando NNs a *fretting* analizaron la influencia de parámetros sobre la ocurrencia de fallo [15]. Posteriormente, se han propuesto modelos con objetivos más directos de estimación de vida, con mejoras progresivas al incorporar descriptores relevantes del contacto y del estado tensional. Estos modelos incluyen predicción de vida y efecto de escala mediante parámetros globales de contacto y carga [2]; estimación de parámetros óptimos asociados a enfoques de distancia crítica y tensiones multiaxiales [16]; integración de algoritmos de optimización [17]; modelos con entradas basadas en tensiones en plano crítico y distancia crítica; extensiones a múltiples aleaciones y geometrías; y comparativas frente a modelos multiaxiales clásicos [18] o enfoques jerárquicos “physics-informed” para configuraciones complejas [19].

Este estudio busca desarrollar y validar modelos de redes neuronales basados en descriptores físicos de la fatiga previamente empleados en el análisis de la fatiga por *fretting* para predecir la vida en ensayos con entallas. Para ello, se utilizarán redes neuronales con arquitectura feed-forward y metodología de entrenamiento k-fold cross-validation [20], evaluando la capacidad de redes neuronales entrenadas con ensayos de *fretting* y otras redes entrenadas con esos ensayos y otros ensayos con entallas, en la búsqueda de un algoritmo robusto en la predicción de vida para ensayos de diferentes materiales y geometrías, incluyendo o no entallas.

Para regresión, como es el caso de la predicción de vida, es habitual emplear una red feed-forward totalmente conectada (FFNN). Cada neurona de la capa k combina linealmente las salidas de la capa $k-1$ y aplica una no linealidad [20]. El incremento de capas ocultas aumenta la capacidad de representación, pero eleva el riesgo de sobreajuste cuando el tamaño muestral es reducido.

2.1. Partición de los datos y métricas de rendimiento

El entrenamiento ajusta iterativamente los parámetros para minimizar una función de pérdida y generalizar a datos no vistos. Se emplea la partición en entrenamiento, validación y test.

En este trabajo, se utiliza RMSE como pérdida estándar y se reporta el Coeficiente de Determinación, R^2 , como métrica adicional. El entrenamiento de las redes se hace aplicando el backpropagation [20]. La actualización puede realizarse mediante SGD o métodos adaptativos como Adam y RMSprop.

2.2. Validación cruzada

Con datos limitados, el sobreajuste es un riesgo central [20]. Para mitigarlo, se adopta validación cruzada k-fold, que reduce la dependencia de un único split y mejora la robustez de la estimación del rendimiento.

En k-fold, el conjunto de entrenamiento se divide en k particiones; se entrenan k modelos $Y_i = f(X_i, \beta_i)$ y se agregan sus estimaciones como $\beta = \left(\frac{1}{k}\right) \sum_{i=1..k} \beta_i$ para obtener $Y = f(X, \bar{\beta})$ [20].

3. DATOS EXPERIMENTALES

En [4] se recogen las propiedades mecánicas y parámetros de ensayo de los ocho materiales utilizados para entrenar la red denominada NN2, que se utilizará para tratar de probar su generalización ante un conjunto de ensayos sobre muestras con entallas.

El conjunto completo de ensayos para entrenar dicha red incluye 228 ensayos de fatiga por *fretting* con 8 aleaciones y tratamientos diferentes: Al 7075-T6, Al 7075-T651, Ti-6Al-4V, Al 4%Cu, Al 2024-T351,[21] Al 2024-T3, Al 7050-T7451 e Inconel 718 [4].

Esta heterogeneidad genera un conjunto rico de gradientes tensión–deformación y fuerzas, constituyendo la base de entrenamiento y evaluación de los modelos que se van a utilizar.

Por otro lado, de los utilizados en [4], se emplearán en este trabajo 106 ensayos con entallas. Se tienen 7 tipos diferentes de entallas que se muestran en la Figura 1, todas ellas circulares con diferentes radios incluyendo agujeros de diámetros diferentes. Se tienen 15 ensayos con entalla tipo I, 13 con la tipo II, 17 con la III, 12 con la IV, 3 con la V y 3 con la VI, además de 22 ensayos con agujeros de 1 mm y 21 con agujeros de 4 mm.

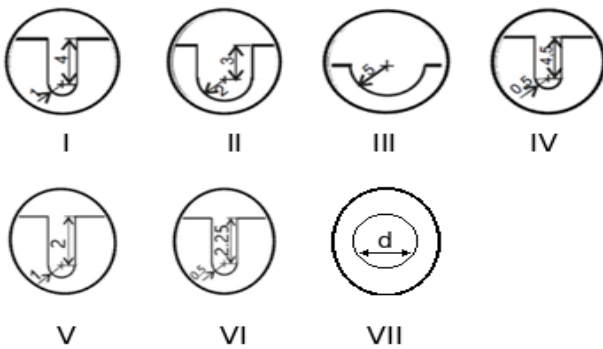


Figura 1. Muestra de las entallas utilizadas en los ensayos.

Los resultados de estos ensayos se muestran en la Figura 2, donde se representa la tensión alterna frente a la vida a fatiga. Esta gráfica muestra un conjunto heterogéneo donde existen ensayos con vidas entre varios miles y 10 millones de ciclos y tensiones alternas desde 20 MPa a casi 160 MPa. Esta heterogeneidad puede provocar una dificultad para redes neuronales que no han sido entrenadas con este tipo de ensayos para la predicción de su vida, sobre todo para redes que han sido entrenadas con ensayos con un rango de vida inferior al que tiene este nuevo conjunto, como es el caso de la red empleada en [4].

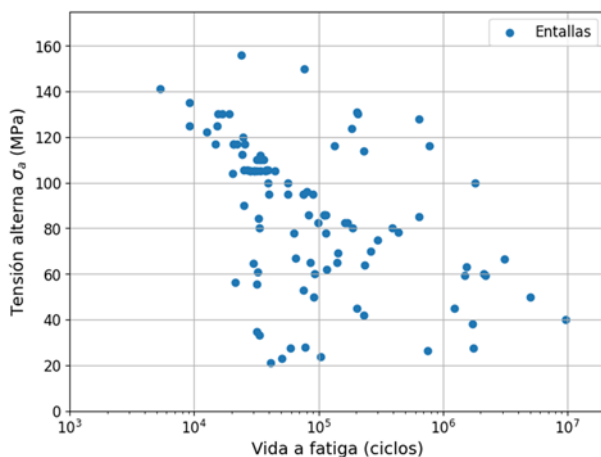


Figura 2. Representación de la tensión alterna frente a la vida a fatiga para los ensayos con entallas.

4. MÉTODO DE ANÁLISIS

El primer análisis (análisis 1) que se realiza es el uso de la red neuronal entrenada en [4] con ensayos de fretting para predecir la vida de los ensayos en entallas presentados en la sección anterior. De esta manera, se quiere analizar la posible generalización de una red que ha demostrado capacidad de generalización ante nuevos materiales, pero no ha sido probada ante ensayos con características tan diferentes como geometrías con entallas.

Esta red es una FFNN que cuenta con una única capa intermedia con 10 neuronas, su función de activación es ReLu y su optimizador Adam y se entrena usando los métodos de cross-validation y early-stopping. Como variables de entradas combina variables globales con descriptores locales de tensiones.

Posteriormente, se realiza un segundo análisis (análisis 2) orientado a mejorar el rendimiento de la red neuronal mediante un ajuste sistemático de hiperparámetros, con el objetivo de optimizar su capacidad predictiva. Para ello, se emplea *RandomizedSearchCV* de *Python*, evaluando distintas combinaciones y obteniendo como configuración óptima un “batch size” de 8,800 épocas de entrenamiento, función de activación ELU, 3 capas ocultas con 58 unidades por capa, sin “batch normalization”, con “dropout” de 0,197, regularización L2 de $1,88 \cdot 10^{-4}$, y una tasa de aprendizaje de $1,87 \cdot 10^{-3}$ en el optimizador.

Esta red se entrena utilizando el 70 % de todos los datos que se utilizan en este trabajo: los 228 ensayos de fretting más los 106 con entallas. El 30 % de datos restante serán los que se predigan con la red descrita y así poder ver sus capacidades. Este uso de todos los ensayos disponibles se realiza debido a la incapacidad de la red neuronal entrenada con los ensayos de fretting de los 8 materiales de predecir la vida de los ensayos de entallas, como se comentará en las secciones 5 y 6.

Esta red mantendrá el mismo conjunto de variables de entrada y sus respectivas normalizaciones para así poder analizar la optimización de los hiperparámetros.

Por último, se realiza un análisis (análisis 3) de correlación de las variables de entrada para eliminar variables altamente correlacionadas entre sí y escoger las que aporten más información para la predicción de la vida.

En esta etapa se generan variables derivadas a partir de los perfiles subsuperficiales de tensión nominal $\sigma_n(d)$ y deformación asociada $\Delta\epsilon(d)$, con el fin de incrementar el conjunto de características antes del análisis de correlación y seleccionar aquellas que aporten más información para la predicción de vida mediante redes neuronales. Las nuevas variables se construyen sobre cuatro profundidades, d , definidas por la longitud característica de el Haddad [22] $a_0: d = \{0, a_0/2, a_0, 2a_0\}$.

En primer lugar, se incorpora el ratio, R , de tensiones, obtenido a partir de las tensiones alterna, σ_a , y media, σ_m .

A continuación, para cada perfil $y(d)$ (tomando $y = \sigma_n$ o $y = \varepsilon$), se calcula un gradiente global mediante mínimos cuadrados lineales a lo largo de las cuatro profundidades. Este descriptor se obtiene a partir de las medias \bar{d} e \bar{y} , y cuantifica la tendencia media con la profundidad.

$$m_y = \frac{(\sum_{j=1}^4 (y_j - \bar{y})(d_j - \bar{d}))}{(\sum_{j=1}^4 (d_j - \bar{d})^2)} \quad (1)$$

Además, se introducen métricas de atenuación entre una profundidad cercana y una profunda, tomando como referencia $a_0/2$ y $2a_0$. Se define un cociente interno y una diferencia absoluta para cada perfil $y(d)$.

$$\rho_y = \frac{y(2a_0)}{y(\frac{a_0}{2})} \quad (2)$$

$$\Delta y = y(2a_0) - y(\frac{a_0}{2}) \quad (3)$$

Para capturar la forma del perfil más allá del gradiente, se añaden dos descriptores de curvatura. La curvatura local se estima como una aproximación a la segunda derivada basada en un esquema de diferencias finitas no uniforme sobre d [23] y se calcula en a_0 para utilizar las 3 profundidades diferentes de la profundidad.

$$\kappa_y^{local}|_{a_0} = (\frac{4}{3a_0^2}) (y(2a_0) - 3y(a_0) + 2y(\frac{a_0}{2})) \quad (4)$$

La curvatura global se obtiene ajustando por mínimos cuadrados un polinomio cuadrático al perfil completo en las cuatro profundidades; a partir del coeficiente A, la curvatura global se define como la segunda derivada del ajuste [24].

$$y(d) \approx A d^2 + B d + C \quad (5)$$

$$\kappa_y^{global} = 2A \quad (6)$$

Una vez añadidas estas variables de tensiones y deformaciones al conjunto de datos anterior, además de las tensiones nominales máximas y sus incrementos de deformación asociadas para el resto de profundidades, se realiza un análisis de correlación de estas variables para eliminar las variables con alta correlación entre sí (mayor de 0.97) y las variables con correlación baja con la vida, N_f , (menor de 0.05). De esta manera las variables finales son σ_a , σ_m , $\sigma_n(a_0/2)$, $\varepsilon(a_0/2)$, $\sigma'_f(10^6)$, R , m_{σ_n} , ρ_ε , $\Delta\sigma_n$, $\Delta\varepsilon$, $\kappa_\varepsilon^{local}|_{a_0}$. Estas variables se normalizan aplicando *StandardScaler()* de *Python* a partir del conjunto de entrenamiento para tener variables con media 0 y desviación estándar 1.

En este análisis se tienen 11 variables explicativas frente a las 7 anteriores y se utiliza la red con los hiperparámetros obtenidos en el análisis 2. El resumen de las variables explicativas utilizadas en cada análisis se muestra en la Tabla 1.

Tabla 1 Resumen de las variables explicativas usadas

Análisis	Variables
Análisis 1	$\sigma_n(a_0), \sigma_n(2a_0), \Delta\varepsilon(a_0), \Delta\varepsilon(2a_0), \sigma_a, \sigma_m, \sigma'_f(10^6), \sigma'_f(10^3)$
Análisis 2	$\sigma_n(a_0), \sigma_n(2a_0), \Delta\varepsilon(a_0), \Delta\varepsilon(2a_0), \sigma_a, \sigma_m, \sigma'_f(10^6), \sigma'_f(10^3)$
Análisis 3	$\sigma_a, \sigma_m, \sigma_n(a_0/2), \varepsilon(a_0/2), \sigma'_f(10^6), R, m_{\sigma_n}, \rho_\varepsilon, \Delta\sigma_n, \Delta\varepsilon, \kappa_\varepsilon^{local} _{a_0}$

5. RESULTADOS

La predicción realizada por la red neuronal del primer análisis se muestra en la Figura 3. Esta predicción ha obtenido un $RMSE$ de 0.7063 y un R^2 de 0.065, resultados muy pobres que también se aprecian en la gráfica. El modelo no es capaz de predecir muchos de estos valores y por lo tanto muchos se encuentran bastante por encima de la línea de predicción perfecta (línea continua), dibujando una banda paralela a esta. Ello permite deducir que el modelo tiene falta de contexto para poder predecir eficazmente este nuevo set de experimentos. Las causas principales podrían ser gradientes menos pronunciados de los ensayos con entallas y mayor influencia de la zona plástica en el borde de la entalla




Figura 3. Predicción del análisis 1 donde se usa la red de [4] para predecir todos los ensayos con entallas.

Debido a estos pobres resultados, se ha realizado el denominado análisis 2. La Figura 4 muestra los resultados de la predicción, donde se ha optimizado los hiperparámetros de la red neuronal como se ha explicado en la Sección 3. Esta red ha obtenido un $RMSE$ de 0.3132 y un R^2 de 0.7487, mejorando por lo tanto significativamente los resultados al optimizar los hiperparámetros de la red. Esta mejora de la predicción no habría sido posible sin la incorporación de ensayos con entallas dentro del set de entrenamiento de la red, ya que la optimización de los hiperparámetros por sí sola solo mejora un poco unos resultados muy pobres, como se ha mostrado en el análisis 1 debido a las diferencias de gradiente e influencia de la zona plástica

Por último, el análisis 3 utiliza los hiperparámetros optimizados de la red del análisis 2, pero además utiliza las 11 variables explicativas de la Tabla 1. La Figura 5 muestra las predicciones realizadas en este análisis, que ha obtenido un $RMSE$ de 0.2415 y un R^2 de 0.8565. De esta manera, esta red ha conseguido una mejora cuantitativa del modelo anterior al eliminar variables altamente correlacionadas entre ellas, variables que no aportan información para la predicción de la vida y que por lo tanto solo aportarían complejidad a la red.

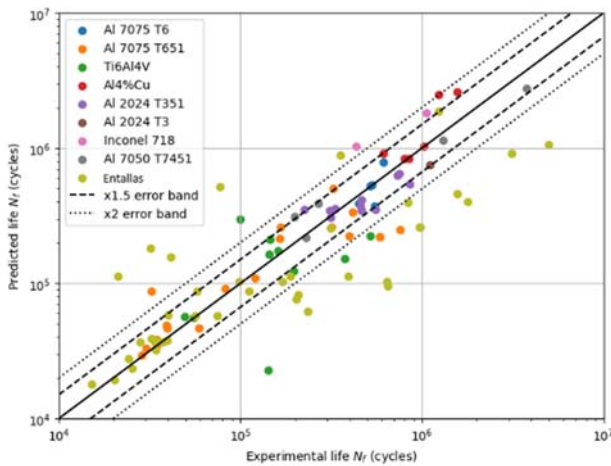


Figura 4. Predicción del análisis 2 donde se usa la red con los hiperparámetros optimizados para predecir el 30 % de todos los ensayos disponibles.




Figura 5. Predicción del análisis 3 donde se usa la red con los hiperparámetros optimizados y las variables explicativas obtenidas mediante correlación para predecir el 30 % de todos los ensayos disponibles.

Sin embargo, se puede apreciar tanto en la Figura 4 como en la Figura 5 que gran parte de ensayos quedan fuera de la banda de error $\times 2$, lo que explica los peores resultados de las redes frente a los obtenidos en artículos previos [3], [4]. Esto se puede deber principalmente, como se ha comentado, a las diferencias de gradiente y a la existencia de zonas plásticas en los bordes de las entallas en muchos de los ensayos realizados. También debe considerarse que se tiene una mayor parte de ensayos sin entalla (228),

que además no tienen una gran dispersión de vidas en los ensayos, frente a ensayos con entallas (106) que tienen desde vidas de miles de ciclos a cercanos a 10 millones de ciclos. Todo ello provoca una mayor adaptación de la red a los ensayos sin entalla, dificultando la predicción de los ensayos más extremos del dataset con entallas.

6. DISCUSIÓN

Se observa un rendimiento muy bajo al predecir entallas con una red entrenada solo con fretting. Como causa probable, aunque ambos casos comparten gradientes de tensión, en fretting suelen ser más severos y superficiales. Además, todos los ensayos de fretting se hicieron sin alcanzar la plastificación, mientras que en los de probetas entalladas, un alto porcentaje de ellos supusieron plastificación en el borde de las entallas, eso hace que pierda similitud con los ensayos de fretting.

Por otro lado, el conjunto con entallas presenta un rango de vidas mucho más amplio, dificultando capturar bien los casos extremos. Puede ser que el modelo aprende relaciones válidas dentro del rango cubierto por los datos de entrenamiento, pero cuando faltan combinaciones representativas (especialmente en entallas), la generalización se degrada.

Incluso en los análisis 2 y 3 (con mejoras sustanciales), una fracción relevante de puntos queda fuera de la banda de error. La combinación de diferencias físicas no completamente capturadas por las variables disponibles y cobertura insuficiente en rangos de vida extremos pueden ser las causas de estas peores predicciones. De esta manera, se plantean las siguientes posibles mejoras para futuros trabajos en este ámbito:

Aumentar el número de ensayos con entallas y, sobre todo, equilibrar su representación frente al conjunto sin entalla o usar estrategias para mitigar el desbalance (por ejemplo, ponderar el error de los ensayos con entallas o emplear particiones que mantengan la distribución de vidas en cada split).

Evaluar esquemas de entrenamiento por etapas: preentrenar con fretting y ajustar después con entallas (fine-tuning) para forzar adaptación al nuevo dominio.

Continuar la línea del Análisis 3: generar descriptores derivados de perfiles subsuperficiales (gradientes, atenuación, curvaturas) y seleccionar variables con criterios cuantitativos.

7. CONCLUSIONES

La red neuronal entrenada únicamente con ensayos de fretting no generaliza a ensayos con entallas, obteniéndose un rendimiento muy pobre en el Análisis 1 ($RMSE$ 0.5783 y R^2 0.095), lo que evidencia que las similitudes por gradiente no son suficientes.

La optimización de hiperparámetros y el entrenamiento con un dataset mixto (fretting + entallas) mejoran de forma clara la predicción, alcanzando en el Análisis 2 un

RMSE de 0.3132 y un R^2 de 0.7487; la incorporación de ensayos con entallas en el entrenamiento resulta clave para la mejora.

La ampliación y selección de variables explicativas basada en descriptores derivados de los perfiles subsuperficiales de tensiones incrementa la precisión, logrando en el Análisis 3 el mejor desempeño (RMSE 0.2415 y R^2 0.8565). Aun así, persisten errores relevantes, especialmente asociados al desbalance entre conjuntos y a la gran dispersión de vidas del dataset con entallas.

REFERENCIAS

- [1] C. Navarro, J. Vázquez, J. Domínguez, A general model to estimate life in notches and fretting fatigue, *Eng. Fract. Mech.*, vol. 78, no. 8, pp. 1590–1601, 2011.
- [2] D. Nowell, P. W. Nowell, A machine learning approach to the prediction of fretting fatigue life, *Tribol. Int.*, vol. 141, 2020.
- [3] Z. Conde, D. García-Vallejo, C. Navarro, J. Domínguez, A Cross-validation approach in Neural Networks for fretting-fatigue prediction on Al 7075-T651, *Theor. Appl. Fract. Mech.*, p. 105129, 2025.
- [4] Z. Conde, D. García-Vallejo, C. Navarro, J. Domínguez, Cross-Validated Neural Network Models for Fretting Fatigue Life Prediction Across Multiple Materials and Contact Geometries, Available <http://dx.doi.org/10.2139/ssrn.5675557>.
- [5] C. Navarro, J. Domínguez, Initiation criteria in fretting fatigue with spherical contact, *Int. J. Fatigue*, vol. 26, no. 12, pp. 1253–1262, 2004.
- [6] C. Navarro, S. Muñoz, J. Domínguez, Propagation in fretting fatigue from a surface defect, *Tribol. Int.*, vol. 39, no. 10, pp. 1149–1157, 2006.
- [7] D. A. Hills, A. Thaitirarot, J. R. Barber, D. Dini, Correlation of fretting fatigue experimental results using an asymptotic approach, *Int. J. Fatigue*, vol. 43, pp. 62–75, 2012.
- [8] M. P. Szolwinski, T. N. Farris, Observation, analysis and prediction of fretting fatigue in 2024-T351 aluminum alloy, *Wear*, vol. 221, no. 1, pp. 24–36, 1998.
- [9] A. L. Pinto, R. Talemi, J. A. Araújo, Fretting fatigue total life assessment including wear and a varying critical distance, *Int. J. Fatigue*, vol. 156, 2022.
- [10] J. Murugesan, Y. Mutoh, Fretting fatigue strength prediction of dovetail joint and bolted joint by using the generalized tangential stress range-compressive stress range diagram, *Tribol. Int.*, vol. 76, pp. 116–121, 2014.
- [11] J. Chen, Y. Liu, Fatigue modeling using neural networks: A comprehensive review, *Fatigue Fract. Eng. Mater. Struct.*, vol. 45, no. 4, pp. 945–979, 2022.
- [12] L. He, Z. Wang, Y. Ogawa, H. Akebono, A. Sugeta, Y. Hayashi, Machine-learning-based investigation into the effect of defect/inclusion on fatigue behavior in steels, *Int. J. Fatigue*, vol. 155, 2022.
- [13] Y.-L. Han, Artificial neural network technology as a method to evaluate the fatigue life of weldments with welding defects, *Int. J. Press. Vessel. Pip.*, vol. 63, no. 2, pp. 205–209, 1995.
- [14] L. Wang, S.-P. Zhu, C. Luo, D. Liao, Q. Wang, Physics-guided machine learning frameworks for fatigue life prediction of AM materials, *Int. J. Fatigue*, vol. 172, 2023.
- [15] P. Orbanić, M. Fajdiga, A neural network approach to describing the fretting fatigue in aluminium-steel couplings, *Int. J. Fatigue*, vol. 25, no. 3, pp. 201–207, 2003.
- [16] C. Wang, Y. Li, N. H. Tran, D. Wang, S. Khatir, M. A. Wahab, Artificial neural network combined with damage parameters to predict fretting fatigue crack initiation lifetime, *Tribol. Int.*, vol. 175, 2022.
- [17] S. Han, S. Khatir, C. Wang, M. Abdel Wahab, An improved Artificial Neural Network for the direct prediction of fretting fatigue crack initiation lifetime, *Tribol. Int.*, vol. 183, 2023.
- [18] G. A. B. Oliveira, R. A. Cardoso, R. C. S. F. Júnior, T. Doca, J. A. Araújo, On the generalization capability of artificial neural networks used to estimate fretting fatigue life, *Tribol. Int.*, vol. 192, 2024.
- [19] Y. Liu, H. Yuan, A hierarchical mechanism-informed neural network approach for assessing fretting fatigue of dovetail joints, *Int. J. Fatigue*, vol. 168, 2023.
- [20] S. L. Brunton, J. N. Kutz, *Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control*. Cambridge University Press, 2019.
- [21] C. Navarro, S. Muñoz, J. Domínguez, On the use of multiaxial fatigue criteria for fretting fatigue life assessment, *Int. J. Fatigue*, vol. 30, no. 1, pp. 32–44, 2008.
- [22] M. H. El Haddad, T. H. Topper, K. N. Smith, Prediction of non propagating cracks, *Eng. Fract. Mech.*, vol. 11, no. 3, pp. 573–584, 1979.
- [23] B. Fornberg, Generation of Finite Difference Formulas on Arbitrarily Spaced Grids, *Math. Comput.*, vol. 51, no. 184, 1988.
- [24] Å. Björck, *Numerical Methods for Least Squares Problems*. 1996.