



Clasificación de la condición de funcionamiento de un bogie ferroviario mediante redes neuronales

Alejandro Bustos Caballero¹, Marta Zamorano Garzón², Juan Carlos García Prada¹

¹MAQLAB, Departamento de Mecánica, Universidad Nacional de Educación a Distancia, albustos@ind.uned.es, jcgprada@ind.uned.es

²Escuela Politécnica Superior, Universidad Francisco de Vitoria, marta.zamorano@ufv.es

La digitalización del mantenimiento ferroviario como consecuencia de la adopción de la Industria 4.0 puede detectar prematuramente la presencia de defectos en el material rodante y notificárselo a los operadores ferroviarios con tiempo suficiente para actuar antes de que se produzca un incidente. Esta digitalización implica la instalación de sistemas de medida en sistemas críticos como son los elementos de rodadura de los vehículos ferroviarios y, más concretamente, los bogies. Aunque la inversión necesaria para la digitalización del material rodante puede ser elevada, a la larga debería reducir los costes del extensivo mantenimiento que realizan los operadores ferroviarios, así como los posibles efectos sobre las personas y el medio ambiente.

En este trabajo se pretende determinar la condición de funcionamiento de los elementos de un bogie ferroviario de alta velocidad mediante la combinación de técnicas clásicas de tratamiento de la señal vibratoria con sistemas de clasificación automáticos propios de la Industria 4.0. Para ello se han instalado acelerómetros en las cajas de grasa de uno de los ejes del bogie, registrándose las medidas de vibración en diferentes condiciones operativas y en las tres direcciones del espacio.

Las señales de vibración se procesan en los dominios del tiempo y de la frecuencia, extrayendo una serie de predictores que posteriormente se introducirán en un clasificador basado en redes neuronales. Previamente a la introducción de los predictores en el sistema de inteligencia artificial, se utilizan técnicas estadísticas para seleccionar el conjunto de predictores que, a priori, deben garantizar la mayor tasa de acierto del sistema experto. Así mismo, se optimizan los hiperparámetros del sistema clasificador para determinar la configuración que permite obtener la mayor tasa de acierto en la identificación de la condición del eje ensayado. Los resultados muestran un elevado nivel de acierto del clasificador basado en redes neuronales.

1. Introducción

En 2015, las Naciones Unidas adoptaron la Agenda 2030 para el Desarrollo Sostenible y sus 17 Objetivos de Desarrollo Sostenible (ODS) [1] con el propósito de procurar un planeta más habitable y garantizar los derechos y el bienestar de todos los habitantes de la Tierra. El ferrocarril puede desempeñar un papel relevante en la consecución de los ODS (en particular, del ODS 11), ya que se trata de un medio de transporte muy eficiente que puede ayudar a reducir la contaminación y el consumo de energía en el movimiento de personas y mercancías.

Potenciar el ferrocarril implica un mayor uso del material rodante, pero, para hacerlo rentable y sostenible, se deben mantener los elevados índices de confort y seguridad sin incrementar los costes de mantenimiento. Por ello, es fundamental disponer de un sistema de mantenimiento que permita detectar fallos en componentes críticos de seguridad antes de ocurran incidentes que afecten al tráfico ferroviario y, en el peor de los casos, a personas y bienes.

En la literatura científica se pueden encontrar multitud de técnicas experimentales para el análisis de la condición de los elementos críticos de la rodadura del material rodante ferroviario [2], siendo las técnicas acústicas y vibratorias dos de las más utilizadas para detectar fallos en ejes [3]. En este trabajo nos centraremos en el análisis de vibraciones, pues se trata de una herramienta de gran utilidad en el campo de la ingeniería mecánica [4], a la que se pueden aplicar multitud de técnicas de tratamiento de la señal y que, en el ferrocarril, se ha utilizado exitosamente en la detección de defectos no sólo en ejes [5], sino también componentes como los rodamientos [6], los resortes [7], e incluso en las ruedas [8,9].

Para detectar prematuramente los fallos, y más si se quiere avanzar hacia la digitalización del ferrocarril [10], el análisis de vibraciones debe completarse con un sistema inteligente que sea capaz de identificar la condición de funcionamiento del material rodante. De este modo, se reducen los costes económicos y temporales asociados a las tareas de revisión de los vehículos ferroviarios. Las redes neuronales artificiales, cuyos orígenes se remontan a mediados del siglo XX [11], juegan un papel relevante en la automatización del mantenimiento y la identificación de defectos, habiéndose aplicado exitosamente para la detección de defectos en bogies [12] y ejes [13,14].

En este trabajo se propone la aplicación conjunta de técnicas clásicas de análisis de vibraciones y redes neuronales artificiales para la identificación del estado operativo de un bogie de alta velocidad en servicio comercial.

2. Sistema experimental

Se monitorizó un tren de alta velocidad en servicio comercial a fin de estudiar su comportamiento vibratorio. Este tren está compuesto por dos cabezas motrices situadas en los extremos del tren y ocho coches articulados con bogies compartidos entre las dos cabezas motrices. La velocidad máxima del tren es 300 km/h.

Para la adquisición de las señales vibratorias se instaló a bordo del tren un equipo de medida (ver esquema de la Figura 1) compuesto por 6 acelerómetros uniaxiales, un tacómetro, dos unidades IMx-R para el acondicionamiento de la señal, un router 3G y todo el equipamiento eléctrico para el correcto funcionamiento del sistema.



Figura 1: Esquema del sistema de medida.

Los acelerómetros se instalan en el coche número ocho, concretamente en las dos cajas de grasa del último eje remolcado del tren, pegado a la segunda motriz. Los dos tripletes de acelerómetros se orientan en las direcciones longitudinal, lateral y vertical, cubriendo las tres direcciones del espacio en ambos lados del eje. Los acelerómetros número 1 (dirección longitudinal), 2 (dirección lateral o transversal) y 3 (dirección vertical) se instalan en el lado izquierdo del tren, tomando como sentido principal el eje longitudinal del tren en el sentido de avance de la primera motriz. Los acelerómetros número 4 (dirección longitudinal), 5 (dirección lateral o transversal) y 6 (dirección vertical) se instalan en el lado derecho del tren. La localización de los acelerómetros en la caja de grasa es la ideal

para registrar vibraciones debidas a posibles defectos en los componentes de rodadura (rueda, eje, rodamientos, etc.), aunque también permite captar la interacción con la vía. El tacómetro se sitúa en una de las cajas de grasa, embebido en ella.

Las dos unidades IMx-R, proporcionadas por SKF, se encargan de amplificar las señales de los acelerómetros y de la conversión de analógico a digital. Las señales, ya digitalizadas, se envían mediante redes de telefonía móvil (de ahí la necesidad de un router 3G) a una base de datos remota. La recepción de los datos y la gestión de la base de datos se realiza con la suite informática @ptitude Observer, también proporcionada por SKF.

Los parámetros empleados para la adquisición de las señales se muestran en la Tabla 1.

Parámetro	Valor
Frecuencia de muestreo	5120 Hz
Tiempo de medida	3,2 s
Rango de velocidad para la adquisición de datos	75-2000 rpm (13-347 km/h)

3. Tratamiento de los datos

Las señales de vibración se tratan previamente a introducirlas en un clasificador basado en redes neuronales. Para ello se utiliza la técnica EGRSC (Enhanced Graphical Representation of State Configurations) [9], la cual se basa en el análisis en frecuencia de la señales mediante el cálculo de la PSD (Power Spectral Density o Densidad de Potencia Espectral). El primer paso de esta técnica consiste en el cálculo de la PSD de cada una de las señales de vibración analizadas y la posterior división del espectro de potencia en un número determinado de bandas frecuenciales. Una posible definición de la PSD es aquella que parte de una distribución general S , tal que su integración (o suma para el caso discreto) a lo largo de todo el rango de frecuencia sea igual a la potencia P de la señal [15,16], tal y como se detalla en la ecuación (1).

$$P = \sum_{k=0}^{N-1} S(k)\Delta f = \sum_{k=0}^{N/2} S_{unlado}(k)\Delta f \quad (1)$$

$$S(k)_{unlado} = \begin{cases} 2S(k) & k = 1 \dots \frac{N}{2} - 1 \\ S(k) & k = 0, k = \frac{N}{2} \end{cases}$$

Calculando la FFT (Transformada rápida de Fourier) y sustituyendo la ley de Parseval, se obtiene la expresión final dada por la ecuación (2), donde $S(k)$ es la PSD de la señal temporal $x(n)$, Δt es incremento temporal, N es el número de puntos de la señal muestreada y $X(k)$ es la transformada discreta de Fourier de la señal temporal $x(n)$.

$$S(k) = \frac{\Delta t}{N} |X(k)|^2 \quad (2)$$

Una vez se ha obtenido el espectro de potencia de una señal, éste se divide en N bandas de frecuencia, siendo N una potencia de dos. Es decir, el espectro de potencia se divide en mitades sucesivas hasta el nivel deseado. Posteriormente, se calcula la potencia espectral de cada banda de frecuencia. El valor de $N = 2^k$ está limitado por la longitud del espectro M , de tal modo que $N = 2^k \leq M$, con $N, k \in \mathbb{N}$. El algoritmo de descomposición se puede escribir tal y como se muestra en la ecuación (3).

$$P(k, j) = \sum_{j=1}^{j=2^k} \sum_{i=\frac{N}{2^k}(j-1)+1}^{i=\frac{N}{2^k}j} S_x(i) \quad (3)$$

Donde i es el índice del vector de la señal de vibración digitalizada, j es el número de banda para un nivel de descomposición k , k es el nivel de descomposición, N es el número de puntos de la señal, $S_x(i)$ es el valor de la PSD en índice i , y $P(k, j)$ es la potencia de la banda j para el nivel de descomposición k . El resultado de la descomposición de un espectro de potencia genérico puede apreciarse en la Figura 2.

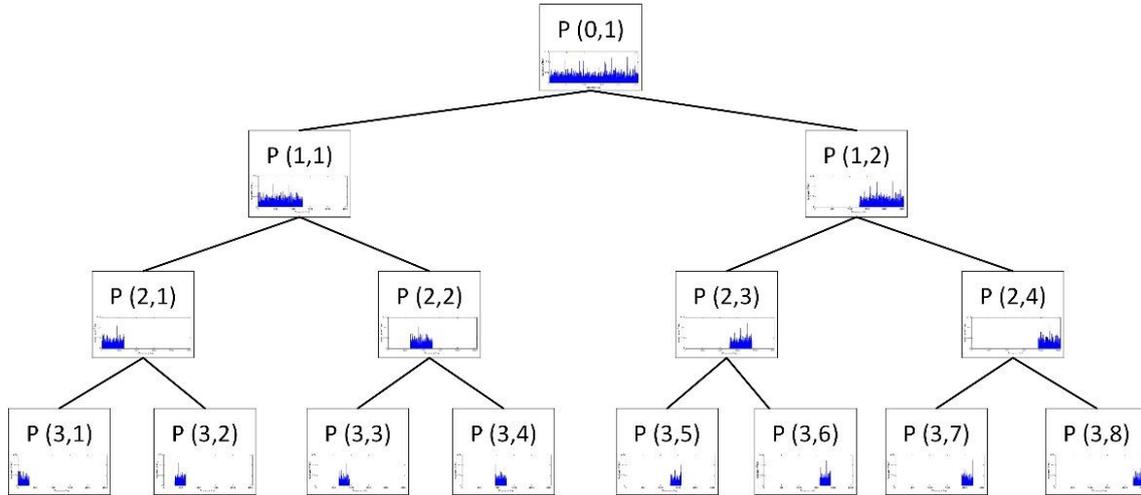


Figura 2: Esquema de descomposición del espectro de potencia hasta nivel k=3 para el EGRSC.

Posteriormente, EGRSC establece tres estados operativos tomando como origen un evento significativo como puede ser una tarea de mantenimiento. Estos tres estados operativos se denominan B (*Before*, antes del evento), A (*After*, justo después del evento) y L (*Later*, tiempo después del evento). En base a estos tres estados, la técnica EGRSC compila la información extraída de las bandas en que se han dividido los espectros de potencia de todas señales registradas en cada uno de los estados y la genera una representación gráfica de la evolución de la potencia espectral de cada banda.

En este artículo únicamente trabajaremos con la descomposición de los espectros en bandas de frecuencia (Figura 2), obviando los pasos posteriores de la técnica EGRSC. Se utilizará la potencia espectral de las diferentes bandas como datos de entrada o predictores para alimentar un clasificador basado en redes neuronales. En concreto, se utilizará una red neuronal FNN (*Feedforward Neural Network*), cuya estructura básica se muestra en la Figura 3.



Figura 3: Estructura básica de la red neuronal FNN.

La primera capa, de entrada, corresponde con los predictores del modelo de red neuronal. En nuestro caso, éstos serán las potencias espectrales de las bandas en que se divide el espectro de potencia. A continuación se encuentra una capa completamente conectada, cuyo número de neuronas se puede modificar, seguida de una función de activación. El número de capas es variable, existiendo siempre una función de activación entre capas. Posteriormente, se encuentra una capa completamente conectada final cuyo número de salidas es el número de clases de la variable de respuesta, una función softmax y la capa de salida, que corresponde con la predicción de las clases (en nuestro caso, serán los tres estados operativos).

El tipo de red neuronal utilizado ofrece cuatro posibilidades de funciones de activación entre una capa y otra: ReLU, sigmoide, tangente hiperbólica y ninguna [17]. La función de activación ReLU (Rectified linear unit) se ejecuta en cada elemento de la entrada si el valor de entrada es mayor que cero. Matemáticamente, esta función se define de acuerdo con la ecuación (4). La activación en la función sigmoide se produce de una forma más suave que en la ReLU, saturando en 0 y en 1, en función del valor de la entrada. Matemáticamente se escribe según la ecuación (5). La activación mediante la tangente hiperbólica es similar a la sigmoide, pero saturando en -1 y +1, de acuerdo con una función de tangente hiperbólica, ecuación (6). Si no se establece una función de activación, no se realiza ninguna transformación en el valor de entrada, como muestra la ecuación (7).

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

$$f(x) = \tanh(x) \quad (6)$$

$$f(x) = x \quad (7)$$

La función softmax tiene como finalidad normalizar la salida de la red neuronal [18]. Para hacer esto con n valores, es necesario encontrar un vector en el que cada elemento del vector esté entre 0 y 1 y tal que la suma total del vector sea 1. La función softmax se define como se indica en la ecuación (8), donde z_i son las entradas y k es el número de clases en la variable de respuesta.

$$\text{softmax}(z)_i = \frac{\exp(z_i)}{\sum_{j=1}^k \exp(z_j)} \quad (8)$$

4. Resultados

Las señales objeto de estudio en este trabajo se toman de continuo durante la operación habitual del tren con pasajeros en la línea de Alta Velocidad Madrid-Sevilla. Con el fin de que las medidas sean lo más uniformes posible, se seleccionan aquellas medidas registradas en un tramo de, aproximadamente, 150 km en los cuales el tren viaja a una velocidad de 270 km/h. Las señales se registran en los dos sentidos de circulación: de Madrid a Sevilla, y de Sevilla a Madrid.

Se selecciona señales de vibración tomadas antes y después de una operación de mantenimiento en la cual se produce el reperfilado de las ruedas del eje monitorizado. Este hecho se identifica como el evento significativo del método EGRSC, definiendo los tres estados operativos como sigue:

- Estado B: agrupa todas las señales de vibración registradas en las dos semanas anteriores a la entrada del tren en los talleres de mantenimiento.
- Estado A: agrupa todas las señales registradas el primer día que el tren circula por la línea Madrid-Sevilla tras el mantenimiento.
- Estado L: compila todas las señales entre el estado A y las 4 semanas posteriores a la salida del tren de los talleres de mantenimiento.

En estudios previos [9] se ha comprobado que la dirección vertical de vibración es la que más información aporta sobre el estado operativo del tren, por lo que únicamente se consideran para este trabajo las vibraciones tomadas en la dirección vertical, en ambos lados del eje. Adicionalmente, y puesto que las medidas vibratorias se registran en entornos reales con gran variabilidad, se opta por alimentar las redes neuronales diferenciando por acelerómetro (ac3 –izquierda– y ac6 –derecha–) y sentido de circulación (Madrid a Sevilla y Sevilla a Madrid).

El nivel de descomposición de los espectros de potencia de las señales tiene un efecto directo en el número de entradas del modelo de red neuronal que se entrenará. Para determinar el nivel de descomposición óptimo, se efectúa un primer análisis en el cual se evalúan niveles de descomposición entre $k=4$ y $k=9$, entrenándose redes neuronales con ayuda del Classification Learner de Matlab para cada uno de esos niveles. Los resultados preliminares muestran que los resultados más prometedores se alcanzan con un nivel de descomposición $k=8$, es decir, dividiendo los espectros de potencia en 256 bandas.

Niveles de descomposición más bajos se descartan en base a los resultados obtenidos en trabajos anteriores aplicando las técnicas EGRSC y ECFB [9,19], en los que se observó que un número reducido de bandas es adecuado para analizar tendencias, pero resulta escaso para apreciar pequeñas variaciones que son necesarias para alimentar sistemas de clasificación inteligentes, como es el caso de las redes neuronales FNN empleadas en este trabajo.

Además de establecer el nivel de descomposición, que determina el número inicial de predictores para la base de datos, se utilizan pruebas estadísticas como ANOVA, Chi2, ReliefF, Kruskal Wallis y Minimum Redundancy Maximum Relevance (MRMR) para ordenar los datos de entrada de acuerdo con su potencial predictivo. Se realizaron varias pruebas seleccionando entre el 50% y el 75% de los predictores mejor clasificados, pero se comprobó que esto empeoraba las tasas de acierto de la red neuronal. Por ello, se decide alimentar las redes neuronales con todos los predictores disponibles.

Una vez determinado el mejor nivel de descomposición y el número total de predictores, se optimizan los hiperparámetros de las redes neuronales, entrenándose éstas con una de las posibles combinaciones de posición de acelerómetro y sentido de viaje, que se modifica en cada caso. En todos los casos se normalizan los datos y se optimizan, entre otros hiperparámetros, el número de capas (entre 1 y 5) y el número de neuronas por capa, la función de activación y el parámetro λ , que define el término de regularización del modelo de red neuronal. Este proceso de optimización se lleva a cabo minimizando la pérdida de entropía cruzada del modelo de red neuronal, para lo cual se recurre a la utilización del algoritmo Broyden-Fletcher-Goldfarb-Shanno de memoria limitada (LBFGS) [20] mediante la función fitnet de MATLAB. De los datos disponibles, se utiliza el 90% para entrenar las redes neuronales y el 10% restante para test.

Los hiperparámetros optimizados de las 6 redes neuronales que mejores resultados arrojaron se muestran en la Tabla 2. El proceso de optimización de la red neuronal se muestra en la Figura 4. En azul se representa el valor mínimo observado de la función objetivo, en verde el valor estimado mínimo y con un cuadro rojo se marca el punto en el que se minimiza el error de los hiperparámetros. Este punto es el que se utiliza para determinar las características de las redes mostradas en la Tabla 2.

Tabla 2: Hiperparámetros de las redes optimizadas: número de neuronas, función de activación y λ .

Red	Capa 1	Capa 2	Capa 3	Capa 4	Capa 5	Activación	λ
Red N°1	506	150	13	61	-	Sigmoid	$1,90 \cdot 10^{-5}$
Red N°2	56	483	466	434	-	Tanh	$9,26 \cdot 10^{-5}$
Red N°3	450	27	-	-	-	ReLU	$3,3053 \cdot 10^{-4}$
Red N°4	205	427	375	175	169	Tanh	$4,2388 \cdot 10^{-5}$
Red N°5	39	232	234	-	-	ReLU	$5,7268 \cdot 10^{-5}$
Red N°6	4	114	274	-	-	Tanh	$1,82 \cdot 10^{-5}$

Una vez se han definido los parámetros óptimos, se entrenan las seis redes neuronales alimentándolas con las cuatro combinaciones de predictores posibles. Durante el proceso de entrenamiento de la red, se valida la salida, obteniéndose una tasa de precisión. Posteriormente, al probar la red con los datos de test, se obtiene otra tasa de precisión. La precisión alcanzada por las redes neuronales en cada uno de los casos estudiados se muestra en la Tabla 3.

En dicha tabla se observa que las tasas de precisión se sitúan en todos los casos por encima del 85%, lo cual es un valor razonable dada la variabilidad de las señales tomadas en condiciones reales de operación, aunque se trate de que sean lo más uniformes posible. Las tasas de precisión en la validación presentan una mayor disparidad, con valores que oscilan entre el 77,78% y el 100%. Los valores máximos de cada columna se han marcado en azul, eligiéndose finalmente la red que presenta el mayor número de valores máximos de todas las probadas. En definitiva, se busca una red neuronal que sea capaz ofrecer los mejores resultados en diferentes situaciones. Ésta resulta ser la red número 4, sombreada en azul en la Tabla 3. Como se observa, las tasas de precisión de esta red neuronal durante la validación del modelo se sitúan en torno al 90%, dependiendo del conjunto de predictores utilizado. En la fase de test, los resultados varían entre el 81% y el 100%.

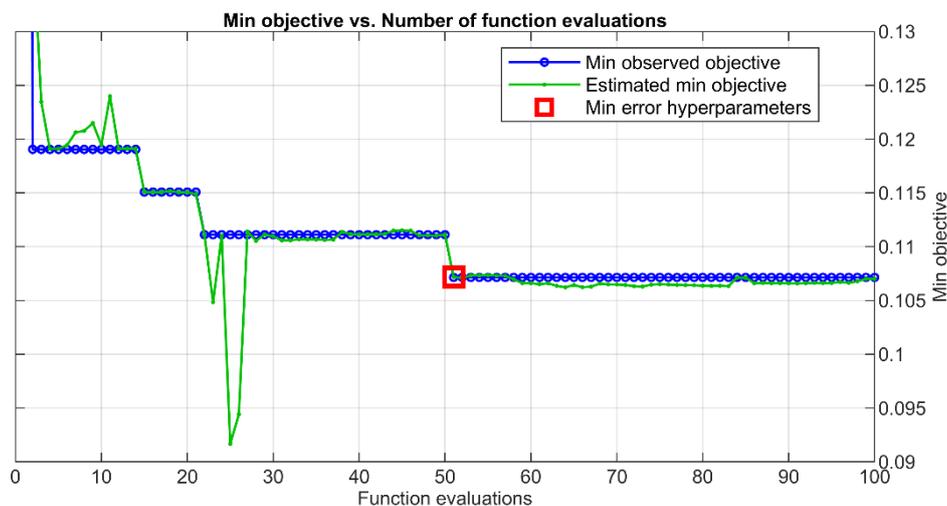


Figura 4: Proceso de optimización de la red neuronal.

Tabla 3: Resultados de precisión de las redes neuronales

Red	Precisión (%)							
	Madrid-Sevilla				Sevilla-Madrid			
	Ac3 validación	Ac3 Test	Ac6 validación	Ac6 Test	Ac3 validación	Ac3 Test	Ac6 validación	Ac6 Test
N°1	90,91	92,59	88,41	85,19	90,45	100	89,29	85,19
N°2	88,43	92,59	88,41	85,19	90	100	89,68	85,19
N°3	85,12	92,59	87,68	85,19	90	100	89,29	88,89
N°4	96,69	100	88,41	85,19	92,27	100	91,27	81,48
N°5	90,08	100	87,68	85,19	92,27	100	87,3	92,59
N°6	91,74	88,89	85,51	85,19	91,82	100	88,89	77,78

En las Figuras 5 a 8 se muestran las curvas ROC [20] obtenidas del entrenamiento y la prueba del clasificador ajustado con los parámetros de la red neuronal número 4. En ellas se ilustra la precisión alcanzada identificando los tres estados operativos (B, A y L).

Para el conjunto de predictores extraídos de las vibraciones registradas por el acelerómetro vertical del lado izquierdo en los viajes de Madrid a Sevilla, las curvas ROC de la Figura 5 muestran que el área bajo la curva (AUC) es superior a 0,9742. Lo cual indica la capacidad de la red neuronal para identificar los tres estados operativos con un acierto superior al 97%. Cuando se introduce al clasificador el conjunto de datos reservado para el test, nuestra FNN es capaz de clasificar correctamente todos los datos, pues el área bajo la curva es 1 para todos los estados operativos.

Las curvas ROC de la Figura 6 muestran la capacidad de la red neuronal para identificar los estados operativos del tren a partir de las medidas registradas en el lado derecho del tren y en los viajes de Madrid a Sevilla. Se aprecia que los resultados son ligeramente peores durante el proceso de validación que en el lado izquierdo, siendo el área bajo la curva mínima de 0,9419, dato correspondiente al estado A. Para los B y L, la capacidad de clasificar correctamente los estados operativos se sitúa por encima del 96%. Sorprendentemente, en la fase de test el AUC máxima corresponde al estado A, mientras que el área mínima se alcanza para el estado L. De cualquier modo, la red neuronal presenta más dificultades para identificar los estados operativos con predictores procedentes del acelerómetro 6 (lado derecho) que con aquellos procedentes del acelerómetro 3 (lado izquierdo).

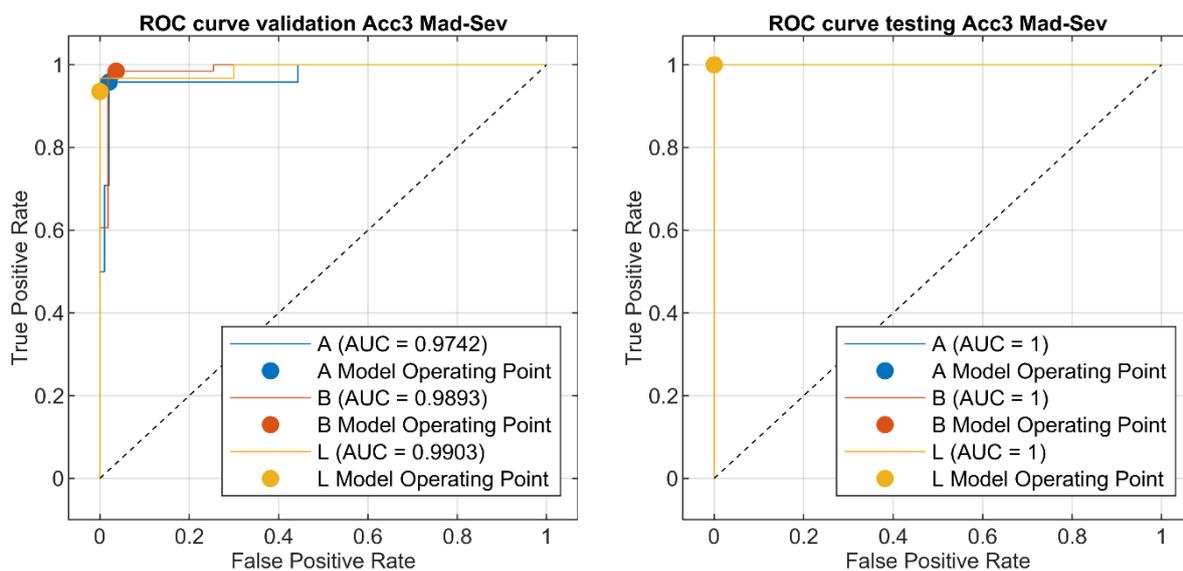


Figura 5: Curvas ROC para las vibraciones verticales, lado izquierdo, sentido Madrid-Sevilla.

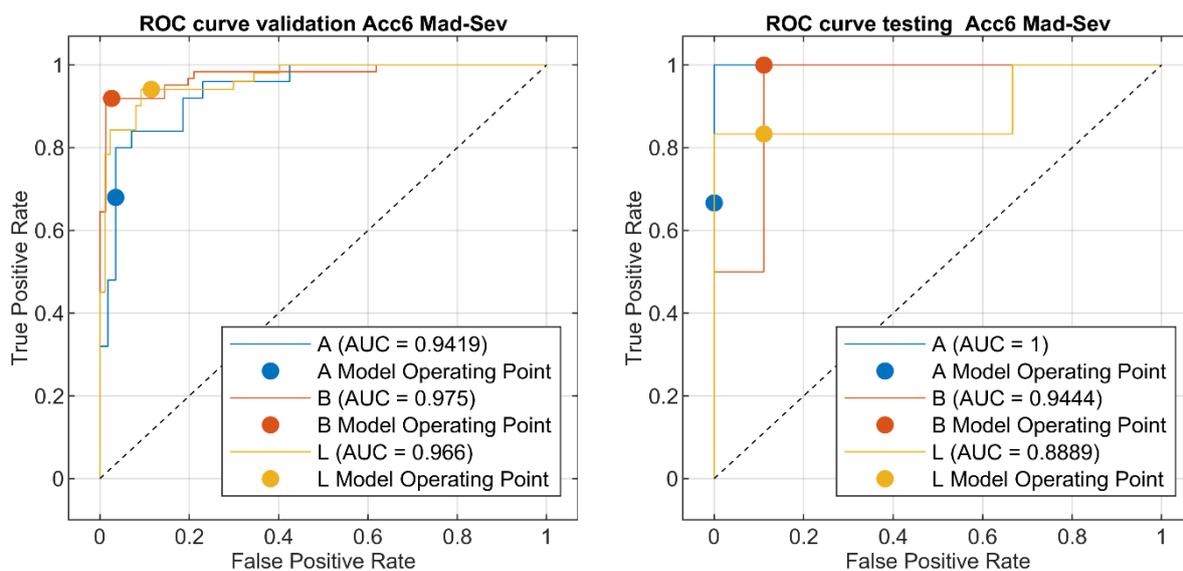


Figura 6: Curvas ROC para las vibraciones verticales, lado derecho, sentido Madrid-Sevilla.

Las curvas ROC obtenidas para los trayectos de Sevilla a Madrid se muestran en las Figuras 7 y 8. En el lado izquierdo (Figura 7), la red neuronal seleccionada es claramente más capaz de identificar correctamente el estado operativo B (99,65%) que los estados A y L, cuya área bajo la curva (AUC) se sitúa en el entorno de 0,94. Sin embargo, en la fase de test la red neuronal es capaz de identificar adecuadamente los tres estados operativos, como se observa en la curva ROC, con un AUC de 1 para los tres estados, y en los resultados de la Tabla 3, donde la tasa de precisión es del 100%.

Los resultados obtenidos en el lado derecho (Figura 8) durante la fase de validación son similares en cuanto a capacidad de clasificación correcta a los obtenidos en el lado izquierdo para el mismo trayecto de Sevilla a Madrid. Las áreas bajo la curva se sitúan por encima del 95%, lo cual es un resultado bastante razonable. Durante la fase de test existe algo más de variabilidad, con áreas que van desde 0,92 a más de 0,97. Sin embargo, la forma de las curvas y los puntos de operación del modelo hacen que el resultado de precisión obtenido sea el más pobre de todos los de esta red, con un escaso 81% (ver Tabla 3).

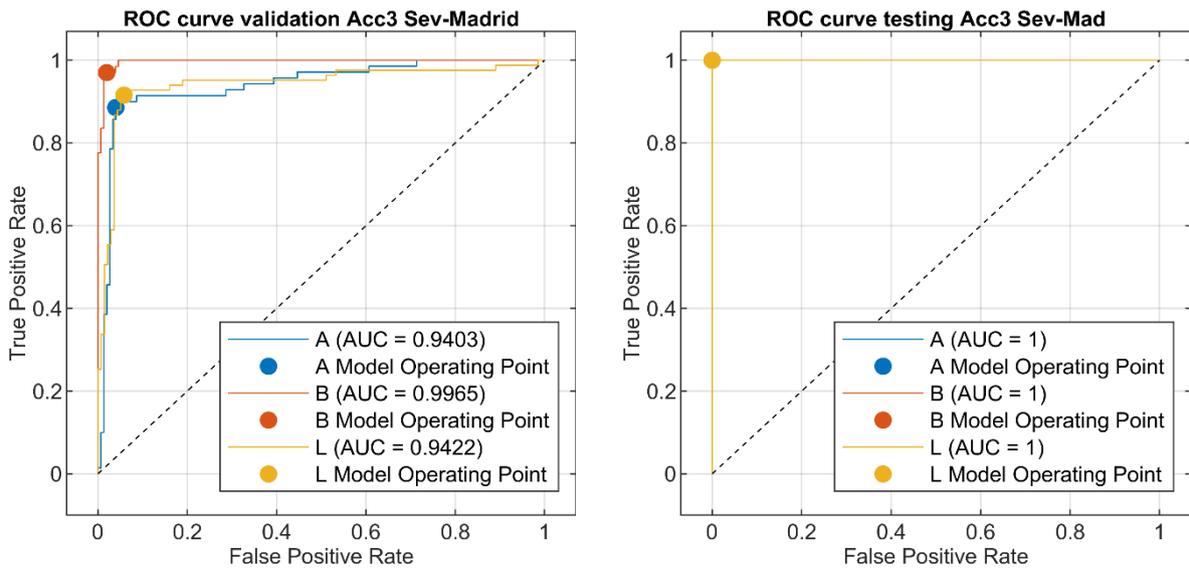


Figura 7: Curvas ROC para las vibraciones verticales, lado izquierdo, sentido Sevilla-Madrid.

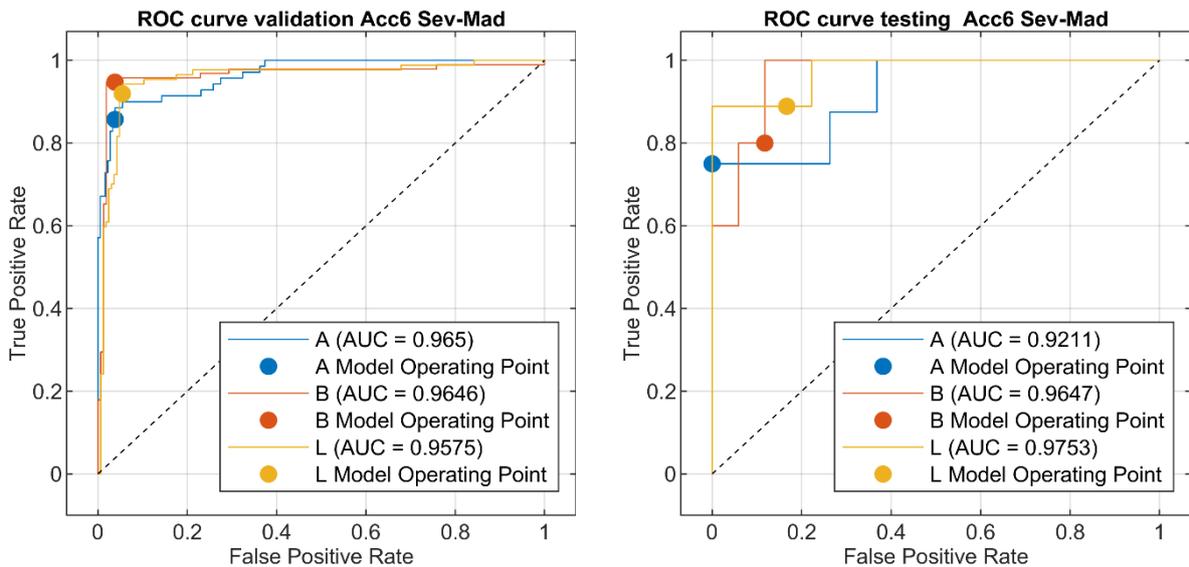


Figura 8: Curvas ROC para las vibraciones verticales, lado derecho, sentido Sevilla-Madrid.

5. Conclusiones

En este trabajo se presenta un modelo de red neuronal alimentado por datos procedentes de señales vibratorias registradas durante la operación normal de un tren de alta velocidad para determinar el estado operativo del tren.

Las señales de vibración se toman antes y después de una operación de mantenimiento consistente en un reperfilado de las ruedas del eje monitorizado con acelerómetros. Las señales de vibración se toman cuando el tren circula a una velocidad aproximada de 270 km/h.

Aplicando los fundamentos de la técnica EGRSC, los espectros de las señales vibratorias medidas se descomponen en 2^k bandas de frecuencia, obteniéndose la potencia espectral de cada una de ellas. También se establecen tres estados operativos, denominados B, A y L. Tras un primer juego de pruebas, se determina que el nivel de descomposición que, potencialmente, ofrece mejores resultados es $k = 8$, por lo que los espectros de las señales se descomponen en 256 bandas, que se utilizarán para alimentar la red neuronal. Los datos de vibración se dividen atendiendo a la localización de los acelerómetros en el eje (lado derecho o izquierdo) y al sentido de viaje en el que se tomaron las medidas: de Madrid a Sevilla, y de Sevilla a Madrid.

El número de predictores que alimentan la red en función del potencial predictor obtenido tras realizar pruebas estadísticas, observándose que los mejores resultados se obtenían alimentando la red neuronal con todos los predictores. La mejor configuración de los hiperparámetros de la red neuronal se determina tras un proceso de optimización en el que se varían el número y profundidad de las capas de la red neuronal, la función de activación y el parámetro de regularización. Tras realizar varias optimizaciones con distintas combinaciones de predictores, se establece que la mejor red neuronal está compuesta por 5 capas, con una función de activación tangente hiperbólica y con $\lambda = 4,2388 \cdot 10^{-5}$.

Los predictores se dividen en dos grupos antes de introducirlos al sistema inteligente de clasificación. El 90% de los datos se utiliza para el entrenamiento y validación de la red FNN, mientras que el 10% restante se utiliza para probar la red. Los resultados obtenidos en la fase de entrenamiento y validación muestran tasas de acierto superiores al 90% en tres de los cuatro conjuntos de datos, siendo superior al 88% en el conjunto restante, y alcanzando un máximo superior al 96%. Las tasas de acierto en la fase de prueba son más dispersas. En los predictores provenientes de los datos del acelerómetro del lado izquierdo, se alcanzan tasas de acierto del 100% en los dos sentidos de viaje. Sin embargo, en el lado derecho las tasas de acierto se sitúan entre el 81% y 86%. De acuerdo con estos resultados, se puede concluir que la combinación de los fundamentos de la técnica EGRSC con una red neuronal FNN parece ser una buena estrategia para identificar el estado operativo del bogie de alta velocidad en condiciones reales de funcionamiento.

6. Agradecimientos

Esta publicación es parte del Proyecto de I+D+I *Diagnosis inteligente de componentes críticos ferroviarios*, financiado por la convocatoria de ayudas para investigadores Tempranos UNED-Santander 2024.

7. Referencias

- [1] Gamez M. J., "Objetivos y metas de desarrollo sostenible", Desarrollo Sostenible. <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/> (accedido 28 de enero de 2025).
- [2] Bernal E. et al., "Onboard Condition Monitoring Sensors, Systems and Techniques for Freight Railway Vehicles: A Review", *IEEE Sensors Journal*, 19, 1, 4-24 (2019), doi: 10.1109/JSEN.2018.2875160.
- [3] Carboni M. et al., "On monitoring fretting fatigue damage in solid railway axles by acoustic emission with unsupervised machine learning and comparison to non-destructive testing techniques", *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 238, 2, 256-267 (2024), doi: 10.1177/09544097231193186.
- [4] Randall R. B., *Vibration-based condition monitoring: industrial, automotive and aerospace applications*, Second edition Wiley, Hoboken, NJ, (2022). doi: 10.1002/9781119477631.
- [5] Sánchez R.-V. et al., "Evaluation of Time and Frequency Condition Indicators from Vibration Signals for Crack Detection in Railway Axles", *Applied Sciences*, 10, 12, 4367 (2020), doi: 10.3390/app10124367.
- [6] Li Y. et al., "Wheelset bearing fault detection using morphological signal and image analysis", *Structural Control and Health Monitoring*, 27, 11, (2020), doi: 10.1002/stc.2619.
- [7] Li C. et al., "Bolster spring fault detection strategy for heavy haul wagons", *Vehicle System Dynamics*, 56, 10, 1604-1621 (2018), doi: 10.1080/00423114.2017.1423090.
- [8] Bernal E. et al., "Wheel flat detectability for Y25 railway freight wagon using vehicle component acceleration signals", *Vehicle System Dynamics*, 1-21 (2019), doi: 10.1080/00423114.2019.1657155.
- [9] Bustos A. et al., "Enhancement of chromatographic spectral technique applied to a high-speed train", *Structural Control and Health Monitoring*, 28, 12, e2842 (2021), doi: 10.1002/stc.2842.

- [10] Bustos A. et al., "Methodology for the integration of a high-speed train in Maintenance 4.0", *Journal of Computational Design and Engineering*, 8, 6, 1605-1621 (2021), doi: 10.1093/jcde/qwab064.
- [11] Rosenblatt F., *Principles of neurodynamics; perceptrons and the theory of brain mechanisms.*, Spartan Books, Washington, (1962). Accedido: 20 de abril de 2023. [En línea]. Disponible en: <https://catalog.hathitrust.org/Record/000203591>
- [12] Zhao Y. et al., "Vibration signal analysis and fault diagnosis of bogies of the high-speed train based on deep neural networks", *Journal of Vibroengineering*, 19, 4, 2456-2474 (2017), doi: 10.21595/jve.2017.17238.
- [13] Huang D. et al., "Fault Diagnosis of High-Speed Train Bogie Based on the Improved-CEEMDAN and 1-D CNN Algorithms", *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11 (2021), doi: 10.1109/TIM.2020.3047922.
- [14] Krummenacher G. et al., "Wheel Defect Detection With Machine Learning", *IEEE Transactions on Intelligent Transportation Systems*, 19, 4, 1176-1187 (2018), doi: 10.1109/TITS.2017.2720721.
- [15] Braun S., *Procesamiento de señales: guía interactiva para ingenieros*, Universidad Nacional de Educación a Distancia, Madrid, (2012).
- [16] Proakis J. G. et al., *Tratamiento digital de señales*, 4a ed Pearson Educación, Madrid, (2007).
- [17] Glorot X. et al., "Understanding the difficulty of training deep feedforward neural networks", *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, 249-256 (2010) Accedido: 13 de abril de 2023. [En línea]. Disponible en: <https://proceedings.mlr.press/v9/glorot10a.html>
- [18] Goodfellow I. et al., *Deep learning*, The MIT press, Cambridge, Mass, (2016).
- [19] Bustos A. et al., "Condition monitoring of critical mechanical elements through Graphical Representation of State Configurations and Chromogram of Bands of Frequency", *Measurement*, 135, 71-82 (2019), doi: 10.1016/j.measurement.2018.11.029.
- [20] Fawcett T., "ROC Graphs: Notes and Practical Considerations for Researchers", *Machine Learning*, 31, 1, 1-38 (2004).