



Utilización de clasificadores automáticos para la categorización y monitorización del estado operativo de material rodante ferroviario

E. Junquera Meana¹, A. Bustos Caballero², H. Rubio Alonso³, E. Soriano Heras⁴, C. Castejón Sisamón⁵, M.J. Gómez García⁶

¹ MAQLAB, Universidad Carlos III de Madrid, España. Email: enrique.junquera@alumnos.uc3m.es

² MAQLAB, Universidad Nacional de Educación a Distancia, España. Email: albustos@ind.uned.es

³ MAQLAB, Universidad Carlos III de Madrid, España. Email: hrubio@ing.uc3m.es

⁴ MAQLAB, Universidad Carlos III de Madrid, España. Email: esoriano@ing.uc3m.es

⁵ MAQLAB, Universidad Carlos III de Madrid, España, Email: castejon@ing.uc3m.es

⁶ MAQLAB, Universidad Carlos III de Madrid, España. Email: mjggarci@ing.uc3m.es

La denominada Cuarta Revolución Industrial o Industria 4.0, momento en el que nos encontramos actualmente, consiste en la integración de sensores avanzados que recogen información, en tiempo real, para ser procesada y analizada por software integrado y optimizar la toma de decisiones. El área del mantenimiento es uno de los campos de la ingeniería que ha experimentado un sensible impulso pues la implementación de técnicas de aprendizaje automático ha conseguido una considerable mejoría en los resultados del diagnóstico de la condición de las máquinas y, en la práctica, ha significado un incremento en la seguridad y eficacia del mantenimiento predictivo.

El aumento de la seguridad en el sector ferroviario mediante el uso de estas técnicas y una considerable reducción de los costos de operación son a la vez objetivo y logro del uso de las metodologías citadas. En el presente artículo se presenta un estudio de la aplicación de técnicas de aprendizaje automático a señales vibratorias obtenidas de un banco de ensayos de bogies ferroviarios.

En trabajos anteriores se aplicaron técnicas de Machine Learning como, por ejemplo, los algoritmos de árboles de decisión, para clasificar las señales vibratorias con el objetivo de la obtención de un clasificador óptimo, mediante el procesamiento de las señales para la obtención de los parámetros propios y, a continuación, desarrollar estudios de selección de cualidades y de optimización de hiperparámetros, realizando finalmente la clasificación y por tanto la determinación las condiciones de operación del sistema mecánico.

Con los estudios realizados se han obtenido clasificaciones próximas al 100% de eficacia mediante determinadas combinaciones de hiperparámetros en la realización de los ensayos comprobando, también, que un mayor número de hiperparámetros en el análisis no solo no supone una mejora en la eficacia global del clasificador si no que en determinadas condiciones ocasiona, incluso, una disminución de la eficacia.

Sirviendo como base los estudios realizados y mediante la obtención de nuevos hiperparámetros, el presente trabajo pretende evaluar si las técnicas de Machine Learning son capaces, en su conjunto, de realizar, con un alto nivel de precisión, la detección de fallos, de forma que se permita el análisis del estado del sistema mecánico con unos niveles de eficacia superiores a los obtenidos anteriormente.

1. Introducción

Los avances en computación que se están llevando a cabo en la actualidad permiten no solo imitar los fenómenos físicos como preconizaba Feynman [1] ya en 1982, también se consigue reproducir elementos y entidades de forma totalmente digital, como por ejemplo los gemelos digitales que la Armada está desarrollando para sus barcos [2] o la generación de dichos gemelos para replicar y someter a ensayos bloques y conjuntos mecánicos como rodamientos [3].

Todo ello supone que nos encontremos en la actualidad en plena expansión de lo que se ha dado en denominar la Cuarta Revolución Industrial o Industria 4.0 [4] que supone la utilización de sensores para recoger información de todo tipo para ser procesada, en tiempo real, de forma que la toma de decisiones se optimiza, esto es, el mejor uso y disposición tanto del tiempo de respuesta como en la utilización de recursos.

Las mejoras y avances de los componentes de los computadores, hardware, al permitir el tratamiento de información y su almacenamiento en cantidades cada vez mayores y en tiempos más reducidos [5] permiten la ejecución de cálculos complejos en fracciones de tiempo cada vez más reducidas [6], todo ello permite la viabilidad de la denominada Inteligencia Artificial, denominada así por ser, esencialmente, técnicas desarrolladas para imitar el funcionamiento del cerebro humano [7].

La aplicación de estas técnicas, los algoritmos que componen los métodos imitadores del cerebro humano, para el mantenimiento en general y en el sector ferroviario en particular supone la consecución de un anhelo de los técnicos puesto que supone no solo una mejora significativa de la seguridad en la operación de los vehículos, también supone un significativo incremento en la mejora del mantenimiento predictivo [8] suponiendo, en consecuencia, una reducción considerable del total de costes derivados de la operativa del sector.

En la actualidad, la Inteligencia Artificial está inmersa en un elevado grado de interés que deriva en una gran expansión y desarrollo, siendo pues su aplicación en diversos campos, ya sea en la gestión y desarrollo de generación de energía [9] o en farmacia [10] así como en los campos ligados a la ingeniería [11].

Dentro del concepto global que supone la Inteligencia Artificial se inserta la disciplina que se denomina Machine Learning, que permite que los computadores identifiquen patrones mediante el análisis de grandes cantidades de información [12] utilizando algoritmos y, por tanto, ser así capaces de realizar predicciones. Existen diferentes tipos de clasificaciones, variando el método de clasificación de acuerdo con los avances que con el tiempo se van desarrollando en el campo, así se pueden clasificar de acuerdo con el entrenamiento del modelo [13] como también según el tratamiento de los algoritmos [14].

Los árboles de decisión son modelos supervisados de clasificadores de Machine Learning, no requieren métodos de parametrización y presentan elevados índices de acierto al realizar clasificaciones mediante la separación de características, a pesar de presentar una cierta tendencia al sobreajuste bajo determinadas condiciones de operación, si bien han sido desarrollados métodos para su optimización [15].

En trabajos anteriores los autores del presente estudio han comprobado la viabilidad del uso de árboles de decisión [16] para la predicción y clasificación de información.

En el presente documento el entrenamiento de los modelos se efectuará mediante el uso del método de la Descomposición de Modo Empírico (EMD por sus siglas en inglés) primeramente enunciado por Huang et al. [17] en 1998.

El método EMD encuentra en la actualidad aplicación en una amplia gama de campos, por ejemplo en medicina [18] o en el diagnóstico de rodamientos por Sahu y Rai en 2022 [19] o en combinación con otros modelos [20] que Huang et al. anticipan ya en 1996.

En la actualidad el método de la Descomposición de Modo Empírico está siendo de amplio uso en un creciente número de campos en combinación con diversos métodos de análisis, como Lin et al. en 2024 [21] en sistemas energéticos.

El modelo ha sido empleado anteriormente de forma exitosa en el análisis de componente mecánicos [22] y, en el presente estudio, se pretende establecer la bondad del modelo para su uso en la categorización de material rodante ferroviario como continuación de trabajos anteriores [16] combinado con el uso de árboles de decisión.

El método seguido en este estudio se similar al utilizado por Bustos et al. en el estudio comparativo del estado operativo de un vehículo ferroviario de alta velocidad [23].

El método consiste en la descomposición de la señal original de modo que se obtienen las denominadas Funciones de Modo Intrínseco (IMF por sus siglas en inglés), de forma que el algoritmo desarrollado determina las envolventes de ajuste de cada señal mediante máximos y mínimos locales y, mediante aproximaciones, se van obteniendo las diferentes IMF de forma sucesiva.

2. Metodología

Para la realización del proyecto se han adquirido una serie de señales vibratorias de un eje ferroviario, que presenta cuatro estados: sin defectos y tres niveles de defectos.

Sometido el sistema a ensayos, las señales obtenidas se almacenan para ser posteriormente procesadas mediante las dos técnicas habituales, la envolvente de la señal y la densidad espectral de potencia (PSD) y, mediante la aplicación MATLAB, extraer, tanto para el dominio del tiempo como para el dominio de la frecuencia, las características de las señales.

En este proyecto, se ha utilizado la descomposición empírica de modos (EMD) para descomponer cada señal en sus componentes significativos, las funciones de modo intrínseco (IMF) mediante la aplicación MATLAB y para cada IMF se han extraído, tanto para el dominio del tiempo como de la frecuencia, sus características.

Finalmente, se realizaron ensayos con las características mediante el uso de algoritmos de árboles de decisión, de la forma que se detalla a continuación.

2.1. Adquisición de las señales vibratorias

Las señales vibratorias se han adquirido en el banco de ensayos para bogies que se muestra a continuación en la **Figura 1**, consistente en un bogie Y-21 en el que se han colocado los sensores.




Figura 1 Banco de ensayos.

En el bogie se dispone de un sistema de carga accionado mediante cilindros hidráulicos, siendo la carga máxima aplicada hasta un máximo de 100 km/h. El eje móvil, sobre el que se efectúan los ensayos, se mueve mediante dos rodillos aplicados a cada una de las ruedas.

Finalmente, se dispone de tres acelerómetros montados sobre cada caja de grasa del eje, dispuestos de acuerdo con las tres direcciones del espacio, vertical, axial y longitudinal, correspondiente esta última al sentido de la marcha.

A continuación, en la **Figura 2**, se representa esquemáticamente el eje y el defecto que, en cada caso, se determina mediante la profundidad “e” en mm, de acuerdo con el esquema. Se muestran, además, las direcciones espaciales en las que se disponen los sensores.




Figura 2 Representación esquemática del eje y efectos.

2.2. Definición de los ensayos

Para la adquisición de las señales se han utilizado acelerómetros CMSS-RAIL-9100, de uso industrial, fabricados por SK, de tipo piezoeléctrico, debido a que presentan baja variación frente a interferencias de tipo electromagnético, dispuestos en las cajas de grasa de acuerdo con las direcciones de referencia, axial, longitudinal

y vertical. Para la realización del trabajo solo se consideraron las señales registradas por los acelerómetros verticales. En la **Tabla 1** se recogen las características de los acelerómetros utilizados en este proyecto.

En la **Tabla 2** se recogen los defectos del eje de acuerdo con el esquema mostrado en la **Figura 1**, realizados mecanizando el eje de forma que se establecen cuatro estados, según el defecto provocado de acuerdo con la profundidad de este, en comparación con el eje que no ha sido sometido mecanizado.

Tabla 1: Características del acelerómetro.

Característica	Unidades
Sensibilidad	10,2mV (m/s ²)
Rango de medida	± 490 m/s ²
Rango de frecuencia	0,52-8 kHz
Rango de temperatura	-54 - 121 °C
Dimensiones (LxAxAlt)	41,9x18,8x21x5 mm

Tabla 2: Caracterización de los defectos en el eje.

Clase	Profundidad del defecto (mm)
Eje Sano (D0)	0,0
Defecto 1 (D1)	5,7
Defecto 2 (D2)	10,9
Defecto 3 (D3)	15,0

Los ensayos se han realizado a una velocidad de 50 km/h, habiendo sido aplicada una carga de 10 toneladas que corresponden al 50% de la carga total axial soportable.

Con el fin de obtener una información representativa que permita abordar el estudio se han configurado los parámetros de muestreo como se muestra seguidamente:

- Frecuencia de muestreo: 12.800 Hz.
- Tiempo de adquisición: 1,28 s.
- Número de puntos N: 16.384 (2¹⁴)

2.3. Elaboración de los ensayos

Una vez obtenidas las señales son procesadas mediante la descomposición empírica de modos (EMD) para descomponer cada señal en sus componentes significativos, las funciones de modo intrínseco (IMF) mediante la aplicación MATLAB.

Este método consiste en la descomposición de la señal original de modo que se obtienen las denominadas Funciones de Modo Intrínseco (IMF por sus siglas en inglés), de forma que el algoritmo desarrollado determina las envolventes de ajuste de cada señal mediante máximos y mínimos locales y, mediante aproximaciones, se van obteniendo las diferentes IMF de forma sucesiva.

A continuación, se describe el modo de funcionamiento del algoritmo:

1. Identificar todos los extremos de una señal dada $x(t)$.
2. Se conectan todos los máximos mediante el uso de una curva spline cúbica, interpolaciones segmentarias de tercer grado, de forma que se obtiene la envolvente superior de la señal $e_{max}(t)$. Análogamente, se repite el proceso con cada uno de los mínimos de la señal dada de forma que se obtiene la envolvente inferior de la señal original $e_{min}(t)$. Una vez obtenidas la envolvente superior e inferior de la señal se obtiene la media de acuerdo con la ecuación:

$$m_1(t) = \frac{e_{max}(t) + e_{min}(t)}{2} \quad (1)$$

3. La diferencia entre la señal original y la media es la posible primera IMF $h_1(t)$ de acuerdo con la ecuación:

$$h_{1(t)} = x(t) - m_1(t) \quad (2)$$

4. Si $h_1(t)$ no cumple las condiciones IMF, se toma $h_1(t)$ como entrada y se repiten los pasos 1-3 hasta que $h_1(t)$ verifique las condiciones de IMF, de acuerdo con la siguiente ecuación:

$$h_{1n}(t) = h_{1(n-1)}(t) - m_1(t) \quad (3)$$

5. Una vez que $h_1(t)$ verifica las condiciones de IMF se renombra c1 y pasa a ser el primer componente IMF.

6. Se calcula el residuo de acuerdo con la ecuación:

$$r_1(t) = x(t) - c_1(t) \quad (4)$$

7. Con el residuo como nueva señal de entrada se repite el proceso definido por los pasos 1-6 hasta que no se puedan extraer más IMF de acuerdo con las siguientes ecuaciones:

$$\begin{aligned} c_k(t) &= r_{k-1}(t) - m_k(t) \\ r_k(t) &= r_{k-1}(t) - c_k(t) \quad (r_0(t) = x(t)) \end{aligned} \quad (5)$$

En este trabajo se han obtenido para cada señal los cinco primeros IMF y, para cada uno de ellos, se han extraído, para el dominio del tiempo, sus características:

- Valor RMS (RMS).
- Valor de pico (PK).
- Curtosis (KUR).
- Factor de cresta (FCR).
- Desviación estándar (DST).

Análogamente, mediante la envolvente de la señal y la densidad espectral de potencia (PSD) se obtienen para cada IMF las siguientes características:

- Valor RMS (RMS-f).
- Valor de pico (PK-f).
- Frecuencia del valor de pico (FR).
- Potencia (P).

Con los datos así obtenidos se utilizaron varios criterios de clasificación, utilizando un hiperparámetro o combinaciones de dos o más a modo de predictores. La evaluación del rendimiento de cada simulación se realiza mediante la extracción de las matrices de precisión y curvas ROC de cada predicción.




Figura 3 Distribución esquemática de árboles de clasificación de tipo Fine Tree. Fuente: MATLAB

Entre los modelos de clasificadores que ofrece el software MATLAB se ha optado por utilizar el tipo *Fine Tree* al permitir el manejo de un elevado número de variables de interpretación de forma que los criterios de selección y división son más ajustados. En la **Figura 3** se muestra una distribución esquemática de árboles de decisión proporcionada por MATLAB.

3. Procesamiento de datos y resultados

Las señales vibratorias obtenidas se procesan, como se ha indicado, mediante descomposición empírica de modos (EMD) para descomponer cada señal en sus componentes significativos, las funciones de modo intrínseco (IMF), como se muestra a continuación en la **Figura 4**, siendo la señal original descompuesta en 5 IMF.




Figura 4 Descomposición de señal mediante EMD en 5 IMF.

Dado que el software MATLAB permite el procesamiento de las señales para posteriormente efectuar los análisis necesarios para su clasificación, la extracción de características y el cálculo de los hiperparámetros correspondientes que, el software, utilizará como predictores, considerando son atributos particulares definidos para cada señal.

Aplicando el algoritmo de la transformada rápida de Fourier (FFT) se obtiene, para cada IMF, el espectro de potencia de la señal (PSD).

3.1. Entrenamiento de los modelos

Una vez obtenidos todos los hiperparámetros, tanto en el dominio del tiempo como en el dominio de la frecuencia, de todas las IMF, que nos permitirán entrenar los modelos, se clasifican y agrupan en tablas para proceder a su procesamiento.

El método de validación cruzada o cross-validation, que consiste en la agrupación de los datos iniciales en varios grupos o paquetes, de los que uno se utiliza inicialmente para el entrenamiento del clasificador, un segundo paquete que se utiliza para la validación de los resultados y el resto de la información agrupada en los paquetes reservados se utilizara para efectuar el análisis propiamente dicho. En este trabajo se ha utilizado la división de los datos en 5 paquetes, 1 de entrenamiento, 3 de análisis y 1 para validación.

El criterio de división utilizado en los nodos es el Índice de diversidad de Gini para asegurar que cada nodo contenga una sola clase.

Se establece un máximo de 100 divisiones.

La opción Surrogate decision splits no es utilizada, debido a que durante el proceso de cálculo y preparación de las características no hay datos faltantes.

Una vez realizado el entrenamiento de los modelos y procesada toda la información, se han obtenido, en cada caso, las matrices de confusión, que muestran los valores que se han obtenido frente a los valores reales y, también, las curvas ROC, que miden la precisión del modelo.

3.2. Resultados

Como inicio del proyecto se entrena el modelo utilizando un predictor y así proceder a un análisis previo que permita, posteriormente, realizar combinaciones para un mejor ajuste.

Se han considerado los hiperparámetros de cada IMF en ambos dominios, tiempo y frecuencia, y realizado los entrenamientos para cada caso.

Se han distinguido ambos extremos del eje, lado izquierdo según el sentido de la marcha, I, y análogamente el lado derecho, D.

En la **Tabla 3** se recogen los resultados de la eficacia del clasificador para cada predictor, para los dominios del tiempo y de la frecuencia y para los lados derecho e izquierdo del eje.

Tabla 3: Eficacia del clasificador en %, resultados por variable única

	Dominio del Tiempo					Dominio de la frecuencia			
	RMS	KUR	PK	FCR	DST	RMS-f	PK-f	FR-f	P
I	49,8	83,1	35,4	69,5	48,8	58,4	47,9	57,8	48,8
D	56,3	82,3	37,8	66,4	57,1	60,9	45,3	62,2	57,8

Posteriormente se entrena el modelo en las mismas condiciones agrupando los hiperparámetros, es decir, para el dominio del tiempo y de la frecuencia se agrupan los hiperparámetros para el lado derecho y el lado izquierdo, haciendo la clasificación considerando el conjunto.

La **Tabla 4** recoge la eficacia del clasificador, porcentual, del entrenamiento de los hiperparámetros agrupados por dominio y lado del eje. También, en la última fila, se recoge el resultado obtenido combinando todos los predictores en cada caso, es decir, en el dominio del tiempo y de la frecuencia el uso en el entrenamiento de todos los predictores. También, en la última fila, se recoge el resultado obtenido combinando todos los predictores en cada caso, es decir, en el dominio del tiempo y de la frecuencia el uso en el entrenamiento de todos los predictores.

Tabla 4: Eficacia del clasificador. Combinados por extremo.

	Dominio del tiempo	Dominio de la frecuencia
I	75	76
D	76,5	83,1
I+D	88,6	87,3

A continuación, el entrenamiento del modelo se realiza mediante la consideración de todos los hiperparámetros combinando los del dominio del tiempo y los del dominio de la frecuencia por cada extremo del eje.

La **Tabla 5** recoge la eficacia del clasificador, porcentual, del entrenamiento de los hiperparámetros agrupados por dominio y lado del eje.

Tabla 5: Eficacia del clasificador. Hiperparámetros por extremo.

	Hiperparámetros combinados
I	83,1
D	84,1

Finalmente, el modelo se entrena con todos los hiperparámetros a modo de predictores, siendo el resultado obtenido del 96%.

A continuación, se muestran las matrices de confusión y una de las curvas ROC de cada uno de los entrenamientos realizados de acuerdo con la **Tabla 5** y también las del entrenamiento realizado con todos los predictores de forma que se puede establecer una comparación de los resultados.

Durante la realización de los entrenamientos se han documentado las diferentes gráficas ilustrativas del resultado de dichos entrenamientos, de las que se muestran a continuación varias a modo de ejemplo.

Se recogen en cada caso 4 gráficas, 3 matrices de confusión y un ejemplo de curva ROC:

- Matriz de confusión: Número de observaciones, muestra en la diagonal principal los aciertos en la predicción.

- Matriz de confusión: Tasa de acierto y error, que muestra la tasa de verdaderos positivos identificados por el modelo, sensibilidad.
- Matriz de confusión: Verdaderos aciertos y falsos errores, la precisión del modelo se muestra con la tasa de acierto en las predicciones.
- Curva ROC (*Receiver Operating Characteristic*), Característica Operativa del Receptor que se trata de la representación gráfica de la sensibilidad frente a las falsas detecciones o, en el caso de Machine Learning, las falsas predicciones.

En el caso de las curvas ROC se representa una a modo de ejemplo.

La **Figura 5** recoge las matrices de confusión del entrenamiento del clasificador utilizando todos los hiperparámetros del lado derecho.

La **Figura 6** recoge las matrices de confusión del entrenamiento del clasificador utilizando todos los hiperparámetros del dominio de la frecuencia del lado izquierdo.




Figura 5: Matrices de confusión y curva ROC. Lado Derecho.

En la **Figura 5**, matrices de confusión y una de las curvas ROC para el lado derecho, se observan los siguientes resultados:

- Número de observaciones, la diagonal corresponde con los aciertos obtenidos para el total de predicciones realizadas y los errores en qué caso se han producido, se observa que el nivel de acierto es elevado. Sobre la diagonal principal de la matriz se anotan los falsos positivos, valores que el modelo identifica como correspondientes al valor objetivo pero que no lo son y corresponden a otro, en este caso se observa que el total de falsos positivos es similar al de falsos negativos, valores recogidos bajo la diagonal principal, resultados que el modelo identifica como distintos al objetivo pero que, en realidad, lo son. Se observa que los mejores resultados corresponden a los casos del eje con los defectos tipos 2 y 3.
- Matriz de confusión: Tasa de acierto y error, sensibilidad del modelo, muestra en forma porcentual, la relación entre los falsos negativos frente a los aciertos del modelo, observando que para los casos del defecto en el eje tipo 1 y el eje sin defecto el resultado es ligeramente superior al 76% mientras para los otros dos casos el valor es próximo al 90%.

- Matriz de confusión: Verdaderos aciertos y falsos errores, la precisión del modelo se muestra con la tasa de acierto en las predicciones. Se observa para este caso que la precisión del modelo es próxima también al 90% para los casos correspondientes a los daños tipos 2 y 3 y ligeramente inferior al 80% para las predicciones sobre el eje sin daño y el daño tipo 1.
- Curva ROC (*Receiver Operating Characteristic*), muestra la sensibilidad frente a las falsas predicciones, significativa al superar el 0,80, pero insuficiente.

A continuación, en la **Figura 6**, matrices de confusión y una de las curvas ROC para el lado izquierdo, se observan los siguientes resultados, que los valores son sensiblemente mejores que los obtenidos en el lado opuesto:

- Número de observaciones, la diagonal corresponde con los aciertos obtenidos para el total de predicciones realizadas y los errores en qué caso se han producido, se observa que el nivel de acierto es superior al del lado derecho. En este caso se observa un número superior de falsos negativos, siendo un 20% más que los falsos positivos, en comparación con el lado derecho, siendo el mejor resultado obtenido para los casos de daño tipos 2 y 3.
- Matriz de confusión: Tasa de acierto y error, la sensibilidad en este modelo es notoriamente superior en el caso del eje con el defecto tipo 3 frente a los otros tres casos, con un valor próximo al 90%; se observa que en los casos del defecto 1 y del defecto 2 la sensibilidad del modelo es prácticamente igual en ambos casos y cercano al 78,5%.
- Matriz de confusión: Verdaderos aciertos y falsos errores, la precisión del modelo se muestra con la tasa de acierto en las predicciones, que salvo para el caso del defecto 3 que es superior al 90%, son valores del entorno del 80% para los casos de defecto 1 y 2 y ya sensiblemente inferior en el caso del eje sano, siendo en este caso la precisión del 77,6%.
- Curva ROC (*Receiver Operating Characteristic*), muestra la sensibilidad frente a las falsas predicciones, significativa al superar el 0,80, pero insuficiente.




Figura 6: Matrices de confusión y curva ROC. Dominio de la Frecuencia. Lado izquierdo.

Finalmente, se entrena el clasificador mediante utilizando todos los predictores, el resultado obtenido es de una eficacia del 96,0%

A continuación, la **Figura 7** muestra las matrices de confusión del clasificador entrenado utilizando todos los clasificadores del estudio, observando los siguientes resultados:

- Número de observaciones, la diagonal principal de la matriz, que corresponde con los aciertos obtenidos para el total de predicciones realizadas, y los errores en qué caso se han producido situados en el predictor correspondiente, se observa que el nivel de acierto es notoriamente elevado, correspondiente con el 96% de eficacia, siendo el número total de falsos positivos similar al de falsos negativos, si bien, al ser un número tan reducido, la relación es sensiblemente elevada; por otra parte, se observa que el caso del defecto tipo 3 el resultado es de un 100% de eficacia.
- Matriz de confusión: Tasa de acierto y error, la sensibilidad del modelo supera el 90%, el mejor resultado se obtiene en el caso del defecto 3, 100% y en los tres casos restantes el resultado es similar, ligeramente superior al 94% para los casos del eje sano y el defecto tipo 2 y próximo al 96% para el eje con defecto de tipo 1.
- Matriz de confusión: Verdaderos aciertos y falsos errores, la precisión en este modelo muestra un valor significativo para el caso del eje con el defecto tipo 3, que es del 100%, muy similar para los casos del defecto tipo 2 y eje sano, 97,2 y 97,1% respectivamente, y ligeramente inferior al 90% para el eje con defecto del tipo 1.
- Curva ROC (Receiver Operating Characteristic), muestra la sensibilidad frente a las falsas predicciones, significativa al superar el 0,95.




Figura 7: Matrices de confusión y curva ROC. Todos los hiperparámetros.

El mismo análisis se ha efectuado para una descomposición EMD considerando los 6 primeros IMF de forma que se permite, así, establecer una primera aproximación al análisis de resultados considerando un mayor número de datos, en este caso la obtención de los hiperparámetros que, por consiguiente, supone el incremento del número de predictores.

La **Figura 8** representa la descomposición mediante EMD de una de las señales en los 6 primeros IMF.

Se ha realizado el mismo proceso que en el caso de la descomposición en los 5 primeros IMF, utilizando los hiperparámetros como predictores en las diferentes combinaciones reseñadas anteriormente, es decir, utilizando

un único hiperparámetro, los predictores, de uno en uno, con los dominios temporales y frecuenciales por separado y combinados y, finalmente, utilizando todos los predictores.

Los resultados en general han sido similares a los obtenidos para la descomposición en los 5 primeros IMF.

Finalmente, el modelo se prueba satisfactorio, superando el 90% de eficacia, alcanzando un 91%, si bien el resultado con 5 IMF se muestra superior.

La **Figura 9** recoge las matrices de confusión del entrenamiento del clasificador utilizando todos los hiperparámetros con las primeras 6 IMF.




Figura 8: Descomposición de señal mediante EMD en 6 IMF.

A continuación, en la **Figura 9**, se muestran matrices y ROC como en los casos discutidos en la descomposición para los 5 primeros IMF:

- Número de observaciones, la diagonal principal de la matriz, que corresponde con los aciertos obtenidos para el total de predicciones realizadas, y los errores en qué caso se han producido situados en el predictor correspondiente, se observa que el nivel de acierto es notoriamente elevado, correspondiente con el 91% de eficacia, siendo el número total de falsos positivos sensiblemente inferior al de falsos negativos, si bien; por otra parte, se observa que en este modelo para el eje sin defecto presenta un 100% de eficacia.
- Matriz de confusión: Tasa de acierto y error, la sensibilidad del modelo supera el 90%, el mejor resultado se obtiene en el caso del eje sano, 100% y en los tres casos restantes el resultado es de un 80% para el eje con defecto tipo 1 y 88,9 y 89,2% para los ejes con defecto tipo 2 y tipo 3 respectivamente, valores muy similares en ambos casos.
- Matriz de confusión: Verdaderos aciertos y falsos errores, la precisión del modelo es del 100% en el caso del eje sin defecto, superan el 80% en los ejes con defectos tipo 1 y 2, 87,2 y 81,5% respectivamente y supera el 90% para el caso del eje con defecto tipo 3.
- Curva ROC (Receiver Operating Characteristic), muestra la sensibilidad frente a las falsas predicciones, significativa al superar el 0,90.




Figura 9: Matrices de confusión y curva ROC. Todos los hiperparámetros. 6 IMF.

4. Conclusiones

La viabilidad del uso de árboles de decisión para la categorización de material rodante ferroviario mediante el análisis de las funciones de modo intrínseco (IMF) obtenidas mediante descomposición empírica de modos (EMD) de las señales vibratorias obtenidas mediante los sensores situados en las cajas de grasa queda verificada.

La primera conclusión que se puede extraer de la utilización de árboles de decisión utilizando un único predictor es que los resultados no son aceptables, pues en ningún caso de obtienen valores siquiera próximos a una tasa de acierto del 80%.

Mediante combinaciones de hiperparámetros a modo de predictores se observa que la tasa de eficacia del modelo mejora, pero sin que la mejoría suponga una tasa de acierto lo suficientemente alta como para considerarse aceptable, tanto en la agrupación de predictores en el dominio del tiempo como del dominio de la frecuencia; tampoco se presenta una tasa aceptable cuando se agrupan todos los predictores por extremo del eje, es decir, por lados derecho e izquierdo.

Finalmente, mediante el uso de todos los hiperparámetros obtenidos a modo de predictores, combinando todos los sensores del eje, se obtiene una tasa de acierto superior al 95% en las predicciones y, por tanto, mediante el análisis de las funciones de modo intrínseco (IMF) obtenidas mediante descomposición empírica de modos (EMD) de las señales vibratorias obtenidas por los sensores es posible determinar, mediante el uso de árboles de decisión y con una reducida tasa de error los errores presentes en el eje sometido a ensayo.

Vistos los resultados se puede afirmar que el uso de árboles de decisión para el análisis de las señales vibratorias obtenidas por los sensores mediante la descomposición empírica de modos (EMD) es un modelo de elevada eficacia.

5. Agradecimientos

Este trabajo fue realizado gracias a la financiación obtenida de la Agencia Estatal de Investigación en sus proyectos TED2021-131372A-I00 (AEI) y MCIN/AEI/10.13039/501100011033 (con números de subvención MC4.0 PID2020-116984RB-C21-C22); al proyecto MEMRIAAP-CM-UC3M, financiado por la Comunidad de Madrid;

y al Proyecto de I+D+I Diagnóstico inteligente de componentes críticos ferroviarios, financiado por la convocatoria de ayudas para investigadores Tempranos UNED-Santander 2024.

6. Referencias

- [1] Feynman, Richard P., "Simulating Physics with Computers", *International Journal of Theoretical Physics*, **21**, 6/7, (1982)
- [2] "La Armada dotará con gemelos digitales a los submarinos S80, las fragatas F100 y los cazaminas", <https://www.infodefensa.com>, (2023)
- [3] Lingli, C., Yongchang, X., Dongdong, L., Honggui, H., "Digital twin-driven graph domain adaptation neural network for remaining useful life prediction of rolling bearing - ScienceDirect", *Reliability Engineering & System Safety*, **245**, 109991, (2024)
- [4] "¿Qué es la Industria 4.0 y cómo funciona? | IBM", <https://www.ibm.com>, (accedido 2024).
- [5] "What Is Quantum Computing? | IBM", <https://www.ibm.com>, (accedido 2025)
- [6] Prati E., "Quantum neuromorphic hardware for quantum artificial intelligence", *8TH INTERNATIONAL WORKSHOP DICE2016: SPACETIME - MATTER - QUANTUM MECHANICS*, Bristol, **880**, 012018 (2017)
- [7] Ahmad I. *et al.*, "A review of artificial intelligence techniques for selection & evaluation", *IOP Conference Series: Materials Science and Engineering*, **853**, 1, 012055 (2020)
- [8] Bustos A., Rubio H., Soriano-Heras E., Castejón C., "Methodology for the integration of a high-speed train in Maintenance 4.0", *Journal of Computational Design and Engineering*, **8**, 6, 1605-1621 (2021)
- [9] Shi Z. *et al.*, "Artificial Intelligence for Biomass Detection, Production and Energy Usage in Rural Areas: A review of Technologies and Applications", *Sustainable Energy Technologies and Assessments*, **60**, 103548 (2023)
- [10] Sessa M. *et al.*, "Artificial Intelligence in Pharmacoepidemiology: A Systematic Review. Part 1—Overview of Knowledge Discovery Techniques in Artificial Intelligence", *Frontiers in Pharmacology*, **11**, (2020)
- [11] Huang Y., Li J., Fu J., "Review on Application of Artificial Intelligence in Civil Engineering", *CMES-COMPUTER MODELING IN ENGINEERING & SCIENCES*, **121**, 3, 845-875 (2019).
- [12] Mosqueira-Rey E. *et al.*, "Human-in-the-loop machine learning: a state of the art", *Artificial Intelligence Review*, **56**, 4, 3005-3054 (2023)
- [13] "Robust semi-supervised extreme learning machine | Elsevier Enhanced Reader", (2022).
- [14] Tufail S., Riggs H., Tariq M., Sarwat A. I., "Advancements and Challenges in Machine Learning: A Comprehensive Review of Models, Libraries, Applications, and Algorithms", *Electronics*, **12**, 8, Art. n.º 8(2023)
- [15] Gambella C., Ghaddar B., Naoum-Sawaya J., "Optimization problems for machine learning: A survey", *European Journal of Operational Research*, **290**, 3, 807-828 (2021).
- [16] Junquera Meana, E. *et al.*, "Categorización del estado operativo de material rodante ferroviario mediante el uso de clasificadores automáticos", *Actas del XVI Congreso Iberoamericano de Ingeniería Mecánica*, Concepción, Chile, (2024)
- [17] Huang, E. N., Shen, Z., Long, S.R., Wu, M.C., Shih, H. H., Zheng, Q., Yen, N., Tung, C. C., Liu, H. H., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*", **454**, (1998)
- [18] Shen, J., Zhang, X., Wang, G., Ding, Z., Hu, B., "An Improved Empirical Mode Decomposition of Electroencephalogram Signals for Depression Detection-All Databases", *IEEE transactions on affective computing*, **13**, 1, (2022)
- [19] Sahu, PK, Rai, RN, "Fault Diagnosis of Rolling Bearing Based on an Improved Denoising Technique Using Complete Ensemble Empirical Mode Decomposition and Adaptive Thresholding Method-All Databases", *Journal of vibration engineering & technologies*, **11**, (2023)
- [20] Pulifiato, V., Vergura, S., Carpenteri, M., "Fourier, Wavelet, and Hilbert-Huang Transforms for Studying Electrical Users in the Time and Frequency Domain", *Energies*, **188**, (2017)
- [21] Lin, Y., Li, H., Shi, Q., He, Z., Chen, B., Zhao, X., Chen, Y., Xiazao, Y., Yao, R., Cuo, W., "Method for predicting renewable load in planning and scheduling departments of power system by using processing device, involves disposing EMD algorithm and system load prediction model on CPU-GPU heterogeneous computing platform-All Databases", *Guangdong grid foshan power supply bureau*, (2024)
- [22] Entezami, Mani *et al.*, "Perspectives on railway axle bearing condition monitoring", , *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, **234**, 1, 17-31, (2019)
- [23] Bustos A., Rubio H., Castejón C., García-Prada J. C., "EMD-Based Methodology for the Identification of a High-Speed Train Running in a Gear Operating State", *Sensors*, **18**, 3, Art. n.º 3, (2018)