



Modelado sencillo del comportamiento dinámico del material rodante ferroviario para el mantenimiento conectado

Cristina Castejon^{1,2}, M. Jesús Gómez^{1,2}, Eduardo Corral^{1,2}, Jesús Meneses^{1,2}

¹ Universidad Carlos III de Madrid, Departamento de Ingeniería Mecánica, Avenida de la Universidad, 30 28911 Leganés (Madrid), España.

² Instituto Pedro Juan de Lastanosa, Escuela Politécnica Superior, Avda. de la Universidad, 30. 28911 Leganés (Madrid) España

En la actualidad, la integración de los diferentes pilares en los que se basa el paradigma de la industria 4.0 permite digitalizar todas las tareas relacionadas con el ciclo de vida de un producto o servicio. Sin embargo, la mayoría de los esfuerzos de la industria en esta línea se han realizado en el ámbito organizativo y de toma de decisiones. En este sentido, las tareas de mantenimiento, y en particular las actividades relacionadas con el análisis del estado de funcionamiento de los elementos de un sistema mecánico deben reformularse y orientarse hacia la digitalización. Para lograr este objetivo con éxito, una de las posibilidades es el desarrollo de gemelos digitales para la monitorización del estado. En particular, la implantación de este tipo de sistemas en la industria ferroviaria tiene el potencial de reducir significativamente los costes de mantenimiento tanto del ferrocarril como del material rodante y predecir su vida útil. En este trabajo se presenta un método para estimar fallos en los componentes del material rodante ferroviario. Este método implica el uso de técnicas que conducen al desarrollo de un gemelo digital de este complejo sistema mecánico. El modelo propuesto comprende un modelo dinámico de masas distribuidas y un filtro de Kalman para predecir el comportamiento dinámico del sistema a partir de la información obtenida con datos reales de un banco de pruebas que han sido utilizadas para su validación. Se ha realizado un análisis de los parámetros de configuración del filtro para optimizar la estimación. Los resultados demuestran la solidez de la investigación ya que el modelo sigue el comportamiento real en el tiempo y permite detectar cambios ante fallos.

1. Introducción

La digitalización del mundo actual se extiende por todos los aspectos de la sociedad en los que el uso masivo de datos tiene gran importancia. Esta tendencia se ha manifestado como una revolución industrial en la conocida *Industria 4.0* (I4.0), que se caracteriza, entre otras cosas, por el tratamiento de grandes cantidades de datos (*Big Data*) y la comunicación entre máquinas (*Internet of Things*, IoT). Dentro de esta tendencia, el Mantenimiento 4.0 ha surgido de la aplicación de las tecnologías de la I4.0 a sus tareas. El mantenimiento se define como la combinación de todas las acciones técnicas, administrativas y de gestión que se llevan a cabo durante el ciclo de vida de un elemento con el objetivo de conservarlo o devolverlo a un estado en el que pueda realizar la función requerida [1]. En los últimos años, algunos investigadores han intentado sentar las bases del mantenimiento como tarea integrada en la I4.0 [2], [3]. Las nuevas tecnologías de la I4.0 permiten incluir multitud de sensores cada vez más asequibles en los diferentes procesos de ensayo y fabricación de máquinas que, junto con los protocolos de manejo de información y comunicación, permiten obtener gran cantidad de datos para las tareas de mantenimiento. Desde el punto de vista mecánico, este nuevo paradigma integra estas tareas utilizando el mantenimiento correctivo y preventivo como fuente de información para desarrollar el mantenimiento predictivo a través de la monitorización de la condición. Esto permite detectar anomalías en los sistemas en servicio generando alarmas en estado incipiente de fallo e incluso prediciendo su aparición [1].

En el campo de la monitorización de estado, el Gemelo Digital (DT del inglés *Digital Twin*) destaca como uno de los pilares de la I4.0 con un potencial considerable [4]. La NASA introdujo por primera vez el concepto de DT en los años 80 para referirse a las simulaciones relativas al comportamiento de las aeronaves. El término DT comenzó a aplicarse a la I4.0 en 2003, cuando el ingeniero informático Michael Grieves lo utilizó en una conferencia en la Universidad de Michigan sobre gestión del ciclo de vida del producto [5]. Su definición se actualizó posteriormente, en 2012, para abarcar una simulación probabilística multifísica, multiescala e integrada de un vehículo o sistema que utiliza los mejores modelos físicos disponibles, sensores actualizados, historial de flotas, etc., para reflejar la vida de su correspondiente gemelo (físico) [6]. El uso del DT permite supervisar y predecir el estado de un sistema mecánico, así como su vida útil restante, en función de las condiciones de funcionamiento y el tiempo de uso.

El sector ferroviario es uno de los más beneficiados por este cambio de paradigma. El sistema ferroviario constituye uno de los modos de transporte terrestre más importantes, tanto para pasajeros como para mercancías. Su fiabilidad, seguridad y sostenibilidad sitúan al ferrocarril como la principal alternativa al transporte por carretera. Sin embargo, la explotación y el mantenimiento de los equipos y las infraestructuras ferroviarias generan importantes costes. En línea con el resto de la industria, el sector ferroviario se beneficia considerablemente de la digitalización de los procesos y la implantación de infraestructuras inteligentes. En particular, el cambio hacia el mantenimiento predictivo, como el uso del DT para la monitorización del estado, será de especial interés dado el elevado coste de mantenimiento de los equipos ferroviarios. Un mejor conocimiento del rango de evolución de un defecto en elementos mecánicos proporcionado por dichas aplicaciones de DT permitiría reducir el número de intervenciones de mantenimiento a realizar y, por tanto, disminuir el coste económico.

Sin embargo, la naturaleza dinámica del material rodante dificulta la implementación del DT para aplicaciones de monitorización de estado del tren en servicio. Un posible enfoque teórico propuesto por Ganguli y Adhikari en el campo de la aeronáutica [7] consiste en el desarrollo de un modelo matemático que representa la dinámica del sistema a escalas de tiempo cortas con parámetros que varían a escalas de tiempo mayores. Por otro lado, el Filtro de Kalman, que actúa como un observador óptimo para sistemas dinámicos, surge como una implementación práctica natural de dicho enfoque.

En 1960, R.E. Kalman publicó su innovador artículo en el que definía un filtro capaz de encontrar la estimación óptima del estado de un sistema a partir de su modelo dinámico y sus medidas [8]. El filtro de Kalman utiliza una formulación de variables de estado discretas para describir la dinámica del sistema y distribuciones gaussianas para describir la naturaleza estocástica de la estimación. Estas cualidades hacen que el filtro de Kalman sea extremadamente accesible desde el punto de vista de la ingeniería debido a su sencilla implementación y a sus reducidos requisitos de memoria. Esto, en combinación con su alta precisión, ha consolidado la técnica como un medio práctico de filtrado de señales para el control de sistemas dinámicos, especialmente en la navegación [9].

El Filtro de Kalman funciona combinando el estado obtenido mediante la propagación de un modelo dinámico con medidas reales de forma que se minimice el error cuadrático medio de la estimación. Recientemente ha surgido un renovado interés en la aplicación de variantes del Filtro de Kalman para la estimación de parámetros. Uno de estos enfoques se centra en la estimación lineal de un estado expandido que incorpora parámetros en el estado a través del Filtro de Kalman Extendido (EKF *Extended Kalman Filter*) y el Filtro de Kalman No Centrado (UKF *Unscented Kalman Filter*) [10], [11]. Alternativamente, puede utilizarse un enfoque basado en los residuos tanto para la estimación de los parámetros del sistema [12] como para la optimización de los parámetros del filtro [13], [14], [15]. Dicha aplicación de los Filtros de Kalman sirve para incorporar la dinámica a escala de tiempo corta para los estados, con la variación a escala de tiempo larga de los parámetros del modelo a través de los datos de los sensores, dando un primer paso hacia un DT para sistemas mecánicos.

La aplicación de estos filtros al material rodante requiere, en primer lugar, el desarrollo de un modelo dinámico. La dinámica de los vehículos ferroviarios puede modelarse mediante sistemas multicuerpo, como el modelo no lineal desarrollado por Bustos y otros en [16], o modelos de elementos finitos para el análisis de vibraciones. Debido a la complejidad y gran cantidad de datos utilizados en estos modelos, su carga computacional y densidad de información, los hacen inviables para la mayoría de los usos de monitorización de estado. En estos casos, es habitual trabajar con el estudio de la dinámica vertical, longitudinal y lateral de forma independiente utilizando modelos multicuerpo simplificados. La dinámica vertical de un vehículo ferroviario puede estudiarse mediante diversos modelos bidimensionales. Dichos modelos pueden clasificarse en función de los componentes y movimientos considerados [17]. Estos modelos, que se muestran en la Figura 10, son:

- Modelo de cuarto de vehículo: Considera un octavo del coche, un cuarto de un bogie y la mitad de un eje, así como las suspensiones primaria y secundaria. Puede utilizarse para estudiar el desplazamiento vertical del bogie y del coche [18].
- Modelo de medio vehículo: Considera una cuarta parte del coche, la mitad de un bogie y sus ejes, así como las suspensiones primaria y secundaria. Puede utilizarse para estudiar el desplazamiento vertical del bogie y del coche, así como el cabeceo del bogie [19].
- Modelo de vehículo completo: Considera la mitad del coche, los bogies y los ejes, así como las suspensiones primaria y secundaria. Permite estudiar el desplazamiento vertical y el cabeceo el bogie y del coche [20].

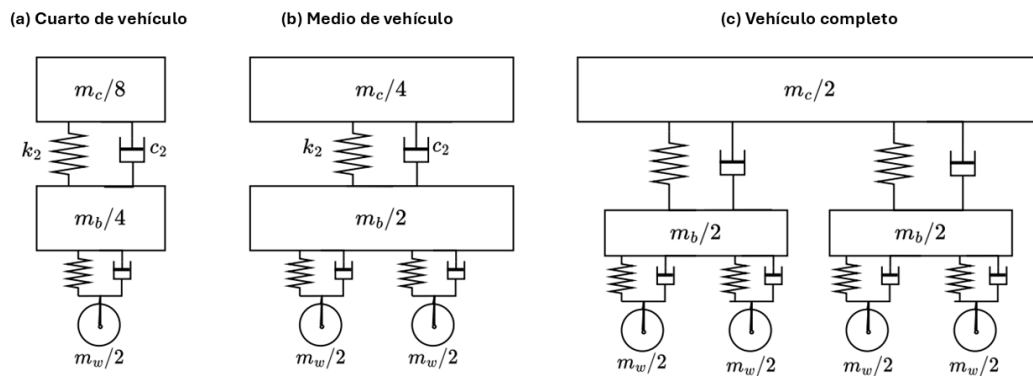


Figura 1. Modelos de masas distribuidas utilizadas para el modelado de vehículos ferroviarios.

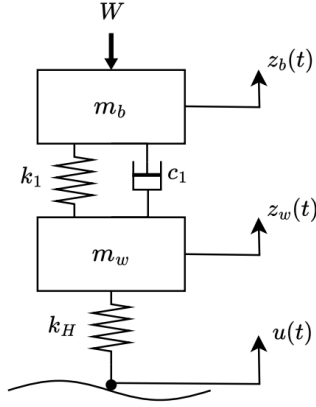
De acuerdo con lo anterior, el objetivo de este trabajo es estudiar la viabilidad para desarrollar un DT del material rodante ferroviario que permita predecir el comportamiento ante fallos de los elementos del sistema. Para ello, se ha obtenido un modelo analítico clásico de un cuarto de vehículo y se ha implementado un filtro de Kalman como identificador del sistema que predice el comportamiento del mismo a partir del modelo y de las medias obtenidas de un sistema real. En el caso de este trabajo se utilizan medidas de aceleración obtenidas en un banco de ensayos de bogies ferroviarios a escala real. El estudio de los parámetros relacionados con la incertidumbre del modelo y de las medidas será también objeto de esta investigación.

2. Modelo del vehículo

El sistema físico estudiado en este trabajo se corresponde con un bogie Y21-Cse sin vagón montado y con una carga vertical aplicada en el eje delantero. Dicho bogie se ha modelado con un sistema de cuarto de vehículo como se muestra en la Figura 2 (a). En este modelo, m_f corresponde a un cuarto de la masa del bastidor (del inglés frame) del bogie, m_w corresponde a la mitad de la masa del eje montado (wheelset), k_1 y c_1 corresponden a los coeficientes de rigidez y amortiguación de la suspensión primaria respectivamente y k_H corresponde a la rigidez de contacto rueda-carril.

En lo referente al modelo, que se ha realizado como un sistema entrada-salida, utiliza como entradas la carga sobre el bastidor del bogie W expresada en kg y la rugosidad del carril $u(t)$ expresada en m. La dinámica del sistema puede así expresarse en términos de los desplazamientos verticales del bastidor y del eje montado $z_f(t)$ y $z_w(t)$ según la ecuación (1).

$$\begin{pmatrix} m_f & 0 \\ 0 & m_w \end{pmatrix} \begin{pmatrix} \ddot{z}_f \\ \ddot{z}_w \end{pmatrix} + \begin{pmatrix} c_1 & -c_1 \\ -c_1 & c_1 \end{pmatrix} \begin{pmatrix} \dot{z}_f \\ \dot{z}_w \end{pmatrix} + \begin{pmatrix} k_1 & -k_1 \\ -k_1 & k_1 + k_H \end{pmatrix} \begin{pmatrix} z_f \\ z_w \end{pmatrix} = \begin{pmatrix} -g & 0 \\ 0 & k_H \end{pmatrix} \begin{pmatrix} W \\ u \end{pmatrix} \quad (1)$$



(a) Modelo de bogie (1/4 de vehículo)

(b) Sistema físico bogie Y21 sobre banco de ensayos

Figura 2. Modelos de masas distribuidas y sistema real utilizado.

La ecuación (1) se representa como modelo en el espacio de estados (según la ecuación (2)) considerando como variables de estado los desplazamientos y velocidad del eje montado y del bastidor $\mathbf{x} = (z_f, \dot{z}_f, z_w, \dot{z}_w)^T$, donde \mathbf{x} es el vector de estados, vector de entrada los valores de la carga vertical sobre el eje montado (W) y el desplazamiento vertical del rail ($u(t)$), $\mathbf{u} = (W, u)^T$ y vector de salida el valor de la aceleración medida en el eje montado $\mathbf{y} = (\ddot{z}_w)$, ya que es la medida obtenida en el sistema experimental, dicho valor se obtiene a partir de la ecuación de salida del modelo presentado en la ecuación (3).

$$\dot{\mathbf{x}} = \mathbf{A} \cdot \mathbf{x} + \mathbf{B} \cdot \mathbf{u} \quad (2)$$

$$\mathbf{y} = \mathbf{C} \cdot \mathbf{x} + \mathbf{D} \cdot \mathbf{u} \quad (3)$$

Con:

$$\mathbf{A} = \begin{pmatrix} 0 & 1 & 0 & 0 \\ -k_1/m_f & -c_1/m_f & k_1/m_f & c_1/m_f \\ 0 & 0 & 0 & 1 \\ k_1/m_w & c_1/m_w & -(k_1 + k_H)/m_w & -c_1/m_w \end{pmatrix} \quad \mathbf{B} = \begin{pmatrix} 0 & 0 \\ -g/m_f & 0 \\ 0 & 0 \\ 0 & k_H/m_w \end{pmatrix}$$

$$\mathbf{C} = (k_1/m_w \quad c_1/m_w \quad -(k_1 + k_H)/m_w \quad -c_1/m_w) \quad \mathbf{D} = (0 \quad k_H/m_w)$$

Los parámetros correspondientes a los elementos del sistema físico se estiman a partir de las especificaciones del fabricante y de trabajos previos [16], [21] y se presentan en la

Tabla 1. Para la rigidez de contacto se considera un contacto lineal de Hertz mediante la ecuación (4), donde E y ν corresponden al módulo de Young y al coeficiente de Poisson del material de la rueda y del carril, respectivamente, y r , A y B son parámetros intermedios obtenidos de tablas de referencia en función de las geometrías de la rueda y del carril [22].

$$k_H = \frac{3}{2} W^{1/3} \left[\frac{2}{3} \left(\frac{1}{r^3(A+B)} \right)^{1/2} \frac{E}{1-\nu^2} \right]^{2/3} \quad (4)$$

Tabla 1: Valores de los parámetros del Bogie Y21-Cse utilizado.

Parámetro	Descripción	Valor
m_f	¼ de la Masa del bastidor	255,5 kg
m_w	½ de la masa del eje montado	579,5 kg
k_1	coeficiente de rigidez de la suspensión primaria	758,52 kN/m
c_1	coeficiente de amortiguamiento de la suspensión primaria	5 kNs/m
k_H	coeficiente de rigidez en el contacto	$9,1 \times 10^8$ N/m

2.1. Modelo enriquecido.

En el presente estudio, se emplea el modelo de ¼ de vehículo con dos grados de libertad para estimar su comportamiento dinámico. Con el objetivo de obtener los valores realistas de las variables del proceso, se incorpora el filtro de Kalman. Este algoritmo de estimación se alimenta de las señales de entrada y salida reales, obtenidas a partir del banco de ensayos representado en la Figura 2(b).

Específicamente, las señales registradas durante el ensayo corresponden a la aceleración vertical de la caja de grasa y la carga vertical constante aplicada. Cabe destacar que, debido a la configuración del ensayo con el bogie rodando sobre rodillos, se asume un valor nulo de irregularidad entre la rueda y el rodillo.

Para estimar el comportamiento del sistema físico utilizando datos reales y el estimador de Kalman, es necesario determinar previamente el ruido de medida y de proceso:

- El ruido de medida puede estimarse a partir de las propiedades del sensor o experimentalmente.
- Para el ruido de proceso se considera que el error del modelo proviene de las aceleraciones no caracterizadas completamente por el sistema, por lo que éste afecta a las variables 2 y 4, de la derivada del vector de estados ($\dot{\mathbf{x}}$) correspondientes a los valores de aceleración del eje montado y del bastidor.

La caracterización del ruido del proceso no es una tarea sencilla. Puede determinarse experimentalmente, pero requiere un amplio conocimiento del sistema real. Como alternativa, la covarianza del ruido del proceso puede estimarse durante el proceso de estimación con un filtro adaptativo. Como norma general, el ruido del proceso se deja como un parámetro de diseño que se ajusta en la fase de diseño del filtro mediante un análisis de sensibilidad. El análisis consiste en analizar los resultados obtenidos para diferentes valores de la varianza del ruido del proceso σ_w respecto a la varianza fija del ruido de medida σ_v para determinar su impacto en la estimación. Una vez seleccionado su valor, se obtiene la covarianza del proceso \mathbf{Q}_k en función de esta varianza según la ecuación (5).

$$\mathbf{Q}_x = \int_0^{T_s} e^{A\tau} \cdot S \cdot (e^{A\tau})^T d\tau \quad (5)$$

Donde: $S = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & s_f & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & s_w \end{pmatrix}$, $s_f = s_w = \sigma_w T_s$ y T_s es el periodo de muestreo.

En la Figura 3 se presenta el diagrama de bloques del sistema que parte del modelo de 2 grados de libertad y se estima su valor de salida con las medidas obtenidas del sistema experimental. Las variables marcadas con acento circunflejo corresponden a los valores estimados por el filtro de Kalman.

3. Aplicación a la monitorización de fallos

El modelo presentado en la sección anterior se basa en un modelo de funcionamiento en condiciones de operación óptimas a las que se le enriquece con las medidas del sistema real de manera que éste es capaz de seguir el comportamiento dinámico de la señal. De esta manera, cuando al modelo se le presentan señales que difieren de su comportamiento habitual debido, por ejemplo, a la aparición de un fallo, dicho modelo tratará de seguir a su gemelo, pero se podrá comprobar la dificultad de seguimiento a partir de los residuos de en la medida (determinado por la diferencia entre el valor de salida estimada y el valor real).

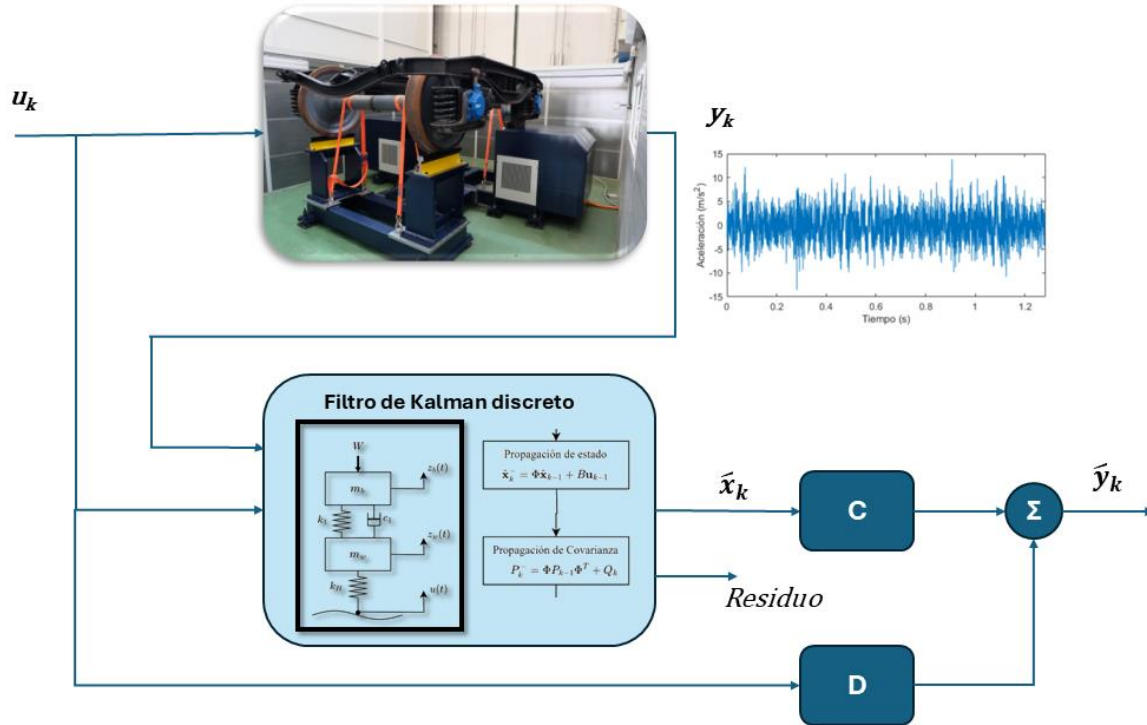


Figura 3. Modelo diagrama de bloques para la simulación del modelo.

El concepto aplicado es similar al que utiliza un filtro adaptativo para la identificación de parámetros: cuando las señales de medida presentan fenómenos que no comprende el modelo, aparecen picos en los residuos que se pueden caracterizar mediante el parámetro denominado verosimilitud (\mathcal{L} , *likelihood*), que describe la probabilidad de obtener la medida en un cierto instante de tiempo dada la estimación a priori del modelo. Esta variable se obtiene a partir de las matrices de covarianza de las variables de ruido de la medida, de la matriz de covarianza de la estimación del estado y del residuo de la medida. La representación de dicha variable para cada medida de aceleración proporciona señales poco descriptivas del estado del sistema como las presentadas en la Figura 4.




Figura 4. Variable de verosimilitud para una señal de vibración estimada de un sistema que presenta un defecto tipo 3.

Por ello para el establecimiento de alarmas y posible detección de fallos se propone como parámetro a monitorizar el valor mínimo del logaritmo de la función en valor absoluto: $FV = |\min(\log(\mathcal{L}))|$. Como primera aproximación, se considerará la monitorización de dicho parámetro para el establecimiento de umbrales de alarma.

4. Resultados Experimentales

Para la obtención de medidas reales tomadas del banco de ensayos previamente descrito se han realizado una serie de ensayos experimentales consistentes en el rodaje del bogie Y-21Cse sobre los rodillos del banco de ensayos de bogies ferroviarios BOGLAB (Figura 2 (b)). Como sistema de medida se dispone de un acelerómetro montado sobre la caja de grasas que mide aceleraciones en la dirección vertical modelo CMSS-RAIL-9100. Las condiciones de operación del ensayo son: transmisión de movimiento a través de los rodillos hasta alcanzar velocidad constante de 20 km/h y carga vertical del eje montado de 10 Tn.

Las señales de vibración se obtuvieron de manera secuencial, durante el transcurso de cada ensayo con las condiciones de medida mostradas en la Tabla 2.

Tabla 2: Parámetros de medida

Parámetro	Valor
Frecuencia de muestreo	12.800 Hz
Tiempo de adquisición	1,28 seg
Número de muestras	2^{14}

4.1. Estimación del ruido de proceso y de medida

El ruido de medida se puede estimar a partir de la ficha técnica de los sensores utilizados, aunque puede resultar difícil derivar una varianza equivalente dado que los sensores reales presentan no-linealidades y la distribución de su error no suele ser gaussiana. En este caso se ha obtenido de manera experimental a partir del espectro de potencia de las medidas obteniendo un valor aproximado para la varianza de medida σ_v de $0,5 \text{ (m/s}^2\text{)}^2$.

Para la estimación del ruido del proceso se realiza, como se comentó en la sección anterior un análisis de sensibilidad de la variación del ruido del proceso respecto del ruido de la medida (σ_w/σ_v). Para ello se han realizado simulaciones del modelo con variaciones de la relación σ_w/σ_v que van de 10^{-1} a 10^4 y se han comparado los residuos obtenidos entre las medidas reales obtenidas y las estimadas. Dichos resultados se presentan en la Figura 5.

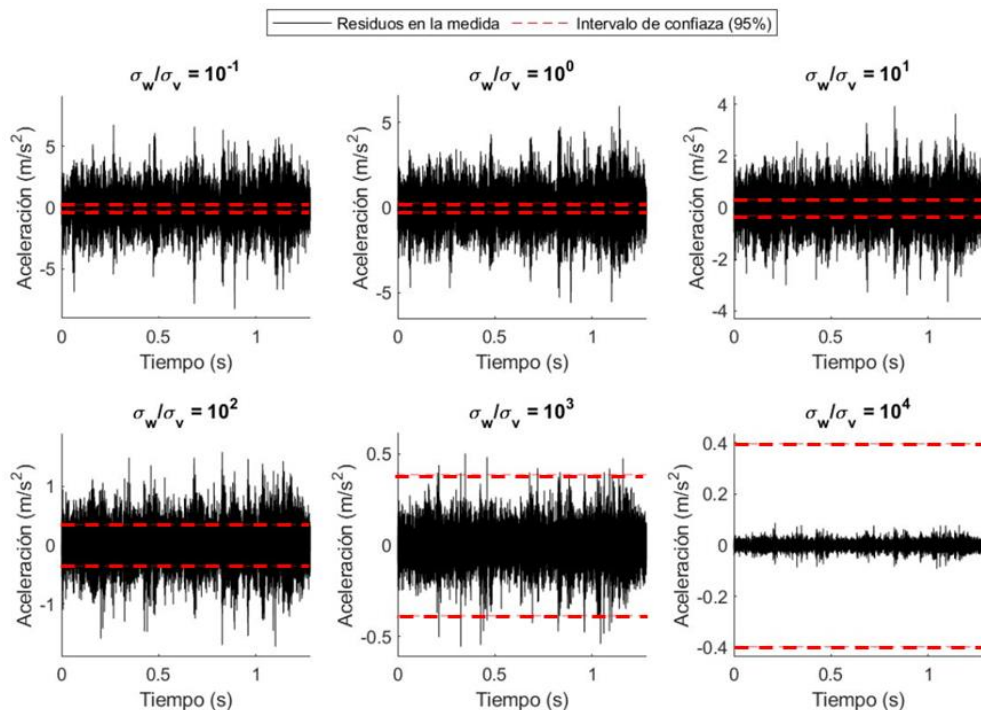


Figura 5. Efecto del ruido de proceso sobre el residuo en la medida.

Como se puede observar, valores bajos del ruido de proceso con respecto al ruido de medida dan lugar a picos en los residuos muy por encima del error esperado al no tener en cuenta los fenómenos de alta frecuencia. Por el contrario, valores altos del ruido de proceso con respecto al ruido de medida resultan en una sobrestimación del error debido a que el filtro incorpora el ruido de medida en el estado. Por ello se decide utilizar un valor del error relativo de $\sigma_w/\sigma_v = 10^2$.

Con estas condiciones se procede a la simulación del sistema para validar el modelo. Los resultados se presentan en la Figura 6 donde se representan en la primera gráfica los valores de las señales de aceleración estimadas y reales junto con los residuos de medida correspondientes (en la parte inferior).

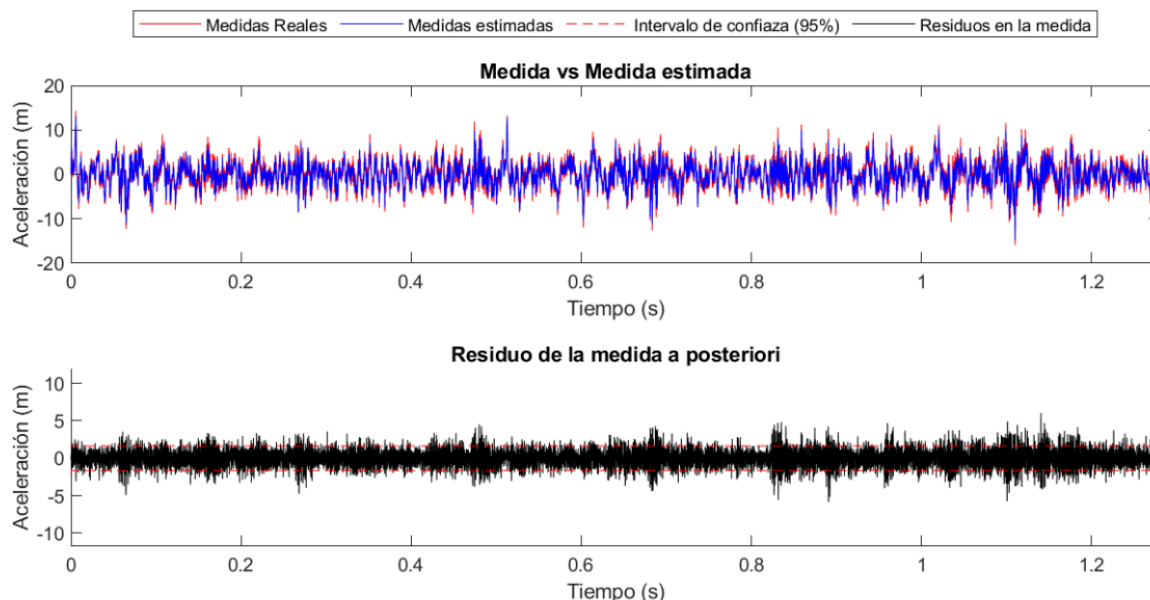


Figura 6. Valores de aceleración reales (rojo) y estimadas (azul) y residuo de la medida estimada (negro).

La aceleración estimada parece seguir correctamente la señal real, y los residuos de medida coinciden en su mayoría con el intervalo de confianza estimado. Los picos en los residuos fuera del intervalo de confianza corresponden a aceleraciones en el sistema real no consideradas por el modelo, que se corrigen rápidamente gracias a la adaptabilidad del filtro.

Con el fin de evaluar el comportamiento dinámico del sistema en la Figura 7 se presenta la comparación entre la PSD (densidad de potencia espectral) de las aceleraciones real y estimada. Se observa que las componentes de alta frecuencia se atenúan significativamente, ya que el modelo de masas desarrollado sólo tiene en cuenta la baja frecuencia debido al bajo número de grados de libertad. Esto se debe a que los picos en alta frecuencia probablemente provengan de fenómenos ajenos al modelo, como pueden ser las frecuencias propias de elementos no modelados o excitaciones externas que no se han tenido en cuenta en la entrada.

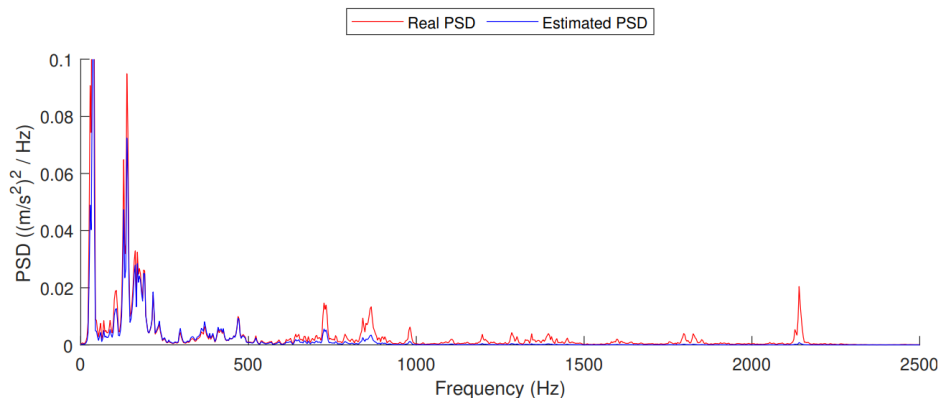


Figura 7. PSD de las señales reales (rojo) y estimadas (azul).

4.2. Detección de fallos y monitorización del sistema

Para evaluar la viabilidad de aplicar dicho modelo como sistema para detección de cambios en el comportamiento dinámico del sistema real se realizaron ensayos con las mismas condiciones de operación sobre el bogie con fisura en la parte central del eje con diferentes profundidades. Las condiciones de eje sano y eje con defecto se presentan en la Tabla 3.

Tabla 3: Condiciones de funcionamiento del eje montado

Defecto	Profundidad (mm)
Eje Sano	0
Defecto 1	5,7
Defecto 2	10,9
Defecto 3	15

En la Figura 8 se presentan los valores obtenidos para cuatro medidas correspondientes a eje sano y a tres niveles de defecto en eje. Se puede observar como a medida que el tamaño del defecto aumenta, el parámetro definido a partir de la función de verosimilitud aumenta pudiéndose establecer umbrales relativos respecto del valor del eje sano.

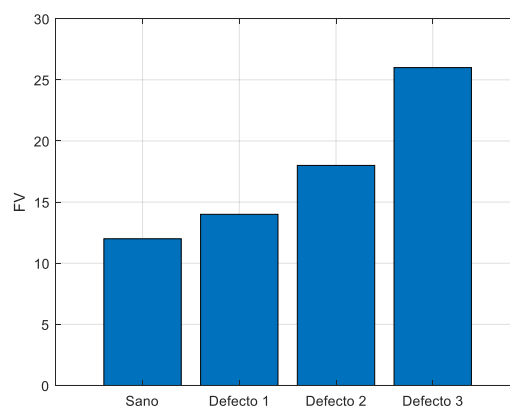


Figura 8. Valor *FV* para diferentes condiciones de funcionamiento.

5. Conclusiones

A raíz de los resultados obtenidos se puede concluir que el método aplicado para la obtención de un modelo del comportamiento dinámico de un bogie que es capaz de seguir el comportamiento real de un sistema es viable. Dicho método permitirá definir, con la incorporación de técnicas basadas en aprendizaje automático, posibles aplicaciones como el uso de Gemelos digitales en tareas concretas de mantenimiento predictivo en sistemas mecánicos complejos, en particular del material rodante ferroviario. Se ha comprobado las dificultades de aplicar modelos con Filtro de Kalman en cuanto a la definición del ruido de proceso y de medida. Por otra parte, se ha comprobado que el modelo durante su funcionamiento es capaz de detectar cambios en el funcionamiento real del sistema a partir de los residuos del proceso. Esto se ha comprobado mediante la validación del modelo con datos reales del sistema con diferentes estados de funcionamiento. En cuanto al método de validación propuesto, el análisis del error de estimación, los residuos de medida y el dominio de la frecuencia caracterizan adecuadamente la aptitud del filtro. De esta manera se concluye que el filtro de Kalman y el modelo propuesto caracterizan correctamente el estado del sistema real, dando un primer paso hacia un gemelo digital para el material rodante ferroviario.

Reconocimientos

Este trabajo ha sido realizado gracias a la financiación obtenida de MCIN/AEI/10.13039/501100011033, a través del proyecto MC4.0 PID2020-116984RB-C22 y el proyecto MEMRIAAP-CM-UC3M financiado por la comunidad de Madrid.

Los autores quieren agradecer al D. Enrique Ruiz el trabajo realizado en su Trabajo fin de Máster en el desarrollo del código y presentación de resultados.

6. Referencias

- [1] A. Diez-Olivan, J. A. Pagan, R. Sanz, y B. Sierra, «Data-driven prognostics using a combination of constrained K-means clustering, fuzzy modeling and LOF-based score», *Neurocomputing*, vol. 241, pp. 97-107, 2017, doi: 10.1016/j.neucom.2017.02.024.
- [2] K. T. Koskinen *et al.*, «Maintenance 4.0 in Railway Transportation Industry», en *PROCEEDINGS OF THE 10TH WORLD CONGRESS ON ENGINEERING ASSET MANAGEMENT (WCEAM 2015)*, en Lecture Notes in Mechanical Engineering. , Springer International Publishing AG, 2016, pp. 317-331.
- [3] R. Sahal, J. G. Breslin, y M. I. Ali, «Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case», *J Manuf Syst*, vol. 54, pp. 138-151, 2020, doi: 10.1016/j.jmsy.2019.11.004.
- [4] I. Errandonea, S. Beltrán, y S. Arrizabalaga, «Digital Twin for maintenance: A literature review», *Comput Ind*, vol. 123, p. 103316, 2020.
- [5] M. Grieves y J. Vickers, «Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems», en *Transdisciplinary Perspectives on Complex Systems*. , Springer International Publishing, 2016, 4, pp. 85-113. doi: 10.1007/978-3-319-38756-7_4.
- [6] E. H. Glaessgen y D. S. Stargel, «The Digital Twin Paradigm for Future NASA and U.S. Air Force Vehicles», en *NASA Center for AeroSpace Information (CASI). Conference Proceedings*, NASA/Langley Research Center, 2012, pp. 1-14. [En línea]. Disponible en: <https://search.proquest.com/docview/2128291978?pq-origsite=primo>
- [7] R. Ganguli y S. Adhikari, «The digital twin of discrete dynamic systems: Initial approaches and future challenges», *Appl Math Model*, vol. 77, pp. 1110-1128, 2020, doi: 10.1016/j.apm.2019.09.036.
- [8] R. E. Kalman, «A New Approach to Linear Filtering and Prediction Problems», *Journal of Basic Engineering*, vol. 82, n.º 1, pp. 35-45, 1960, doi: 10.1115/1.3662552.
- [9] R. G. Brown y P. Y. C. Hwang, *Introduction to Random Signals and Applied Kalman Filtering with Matlab Exercises*, 4.ª ed. Wiley, 2012.
- [10] E. N. Chatzi y A. W. Smyth, «The unscented Kalman filter and particle filter methods for nonlinear structural system identification with non-collocated heterogeneous sensing», *Struct Control Health Monit*, vol. 16, n.º 1, pp. 99-123, 2009.
- [11] Y.-H. Park, H.-B. Lee, y G.-W. Kim, «Crack Monitoring in Rotating Shaft Using Rotational Speed Sensor-Based Torsional Stiffness Estimation with Adaptive Extended Kalman Filters», *Sensors*, vol. 23, n.º 5, p. 2437, 2023.
- [12] M. Impraimakis y A. W. Smyth, «A new residual-based Kalman filter for real time input–parameter–state estimation using limited output information», *Mech Syst Signal Process*, vol. 178, p. 109284, 2022.
- [13] S. Akhlaghi, N. Zhou, y Z. Huang, «Adaptive adjustment of noise covariance in Kalman filter for dynamic state estimation», en *2017 IEEE Power & Energy Society General Meeting*, 2017, pp. 1-5. doi: 10.1109/PESGM.2017.8273755.
- [14] P. Matisko y V. Havlena, «Noise covariances estimation for Kalman filter tuning», *IFAC Proceedings Volumes*, vol. 43, n.º 10, pp. 31-36, 2010, doi: <https://doi.org/10.3182/20100826-3-TR-4015.00009>.
- [15] M. Karasalo y X. Hu, «An optimization approach to adaptive Kalman filtering», *Automatica*, vol. 47, n.º 8, pp. 1785-1793, 2011, doi: <https://doi.org/10.1016/j.automatica.2011.04.004>.
- [16] A. Bustos, M. Tomas-Rodriguez, H. Rubio, y C. Castejon, «On the nonlinear hunting stability of a high-speed train bogie», *Nonlinear Dyn*, vol. 111, n.º 3, pp. 2059-2078, 2023, doi: 10.1007/s11071-022-07937-y.

- [17] X. Lei, *High Speed Railway Track Dynamics: Models, Algorithms and Applications*, Second edition. en *Advances in High-speed Rail Technology*. Springer Singapore Pte. Limited, 2021. doi: 10.1007/978-981-16-4593-8.
- [18] M. Melis Maynar, *Apuntes de introducción a la dinámica vertical de la vía y a las señales digitales en ferrocarriles: con 151 programas en Matlab, Simulink, Visual C++, Visual Basic y Excel*. Toledo: Escuela de Ingenieros de Caminos, Canales y Puertos, 2008.
- [19] J. C. O. Nielsen y A. Igeland, «Vertical Dynamic Interaction Between Train and Track Influence of Wheel and Track Imperfections», *J Sound Vib*, vol. 187, n.º 5, pp. 825-839, 1995, doi: 10.1006/jsvi.1995.0566.
- [20] M. Dumitriu, «Analysis of the Dynamic Response in the Railway Vehicles to the Track Vertical Irregularities. Part I: The Theoretical Model and the Vehicle Response Functions», *Journal of engineering science and technology review*, vol. 8, n.º 4, pp. 24-31, 2015, doi: 10.25103/jestr.084.04.
- [21] M. J. Gómez, E. Corral, C. Castejón, y J. C. García-Prada, «Effective Crack Detection in Railway Axles Using Vibration Signals and WPT Energy», *Sensors*, vol. 18, n.º 5, p. 1603, 2018, doi: 10.3390/s18051603.
- [22] K. Knothe y S. Stichel, *Rail Vehicle Dynamics*, 1st ed. Springer International Publishing, 2017.