

CONSTRUCCIÓN DE GEMELO DIGITAL ESTRUCTURAL PARA LA IDENTIFICACIÓN SUPERVISADA DE UN PUENTE DE CARRETERA

Construction of a Structural Digital Twin for the Supervised Identification of a Road Bridge

Enrique García-Macías^a, Rafael Castro Triguero^b, Alejandro E. Martínez Castro^c, y Rafael Gallego Sevilla^d

^aDr. Ingeniero de Caminos, Canales y Puertos. Universidad de Granada. Profesor Titular de Universidad. enriquegm@ugr.es

^bDr. Ingeniero de Caminos, Canales y Puertos. Universidad de Granada. Catedrático de Universidad. me1catrr@uco.es

^cDr. Ingeniero de Caminos, Canales y Puertos. Universidad de Granada. Profesor Titular de Universidad. amcastro@ugr.es

^dDr. Ingeniero Industrial. Universidad de Granada. Catedrático de Universidad. gallego@ugr.es

RESUMEN

Esta comunicación presenta los estudios de investigación realizados para la construcción de un gemelo digital estructural para la identificación de daños en continuo de un puente de carretera, el viaducto de la circunvalación de Granada a la altura de Méndez Núñez. El procesamiento de los registros de vibración ambiental se realiza mediante técnicas de Análisis Modal Automatizado. Asimismo, se presenta la construcción de un modelo numérico del puente, su calibración inversa, y su uso para la construcción de un modelo subrogado de bajo coste computacional mediante técnicas de inteligencia artificial, el cual da origen a un gemelo digital estructural de la obra.

ABSTRACT

This paper presents the research studies carried out for the construction of a structural digital twin for the continuous damage identification of a road bridge, the viaduct of the Granada ring road near Méndez Núñez. The processing of ambient vibration records is performed using Automated Modal Analysis techniques. Additionally, the construction of a numerical model of the bridge, its inverse calibration, and its use for the development of a computationally efficient surrogate model through artificial intelligence techniques are presented. This surrogate model forms the basis of the structural digital twin of the structure.

PALABRAS CLAVE: Actualización de modelos, Análisis Modal, Puentes, Modelos Subrogados.

KEYWORDS: Model Updating, Modal Analysis, Bridges, Surrogate Models.

1. Introducción

Trágicos colapsos como el puente de Génova en 2018 o el puente de Nanfang'ao en 2019, son ejemplos devastadores del gran riesgo que supone el envejecimiento de la infraestructura civil. No obstante, a pesar de que desde la década

de 1970 se han ido realizado inversiones considerables para el desarrollo de tecnologías de mantenimiento de la salud estructural (SHM, por sus siglas en inglés), los métodos tradicionales basados en inspecciones visuales

periódicas y mantenimiento correctivo siguen siendo predominantes [1]. Entre las causas que explican esta limitada transferencia tecnológica, cabe notar la alta complejidad de la mayoría de los algoritmos de identificación de daños y la falta de herramientas accesibles para traducir los registros de monitorización en información efectiva que asista la toma de decisiones. En este contexto, los avances recientes en inteligencia artificial (IA) podrían marcar un punto de inflexión hacia la implementación extensiva de sistemas SHM [2].

La gestión de sistemas SHM a largo plazo requiere la integración de tres etapas clave según el paradigma del SHM como un problema de reconocimiento de patrones estadísticos [3]: (i) *extracción de características*, (ii) *normalización de datos*, e (iii) *identificación de daños*. La extracción de características implica identificar a partir de las mediciones en bruto ciertas características sensibles al daño. Entre los sistemas de existentes en este respecto, las metodologías basadas en vibraciones y técnicas de Análisis Modal Operacional (OMA, por sus siglas en inglés) son especialmente populares debido a su capacidad para detectar daños globales y su mínima afección sobre la estructura [4]. Por otra parte, la caracterización y eliminación de los efectos operacionales y ambientales (EOC, por sus siglas en inglés) mediante técnicas de normalización suele ser crucial, ya que estos inducen variaciones diarias y estacionales en la respuesta estructural, pudiendo enmascarar la aparición de daño estructural [5]. Finalmente, las características normalizadas pueden emplearse para abordar el problema de identificación de daños mediante métodos basados en datos (no supervisados) o basados en modelos (supervisados) [6]. Las estrategias no supervisadas emplean exclusivamente de los datos de monitorización para detectar anomalías estructurales, mientras que las técnicas basadas en modelos implican la calibración inversa de un modelo de aprendizaje automático o un modelo físico de la estructura monitorizada. Si bien los

algoritmos de identificación basados en modelos permiten proporcionar una identificación integral de patologías, estos están sujetos a un alto coste computacional, por lo su aplicación a la práctica ingenieril sigue siendo muy residual.

En este contexto, los últimos avances en el campo de los Gemelos Digitales (GD) e IA ofrecen un vasto campo de desarrollo. En términos generales, un GD es un modelo basado en física o en aprendizaje automático que utiliza de manera continua los datos de monitorización para inferir y clasificar el estado de salud del activo físico, permitiendo la implementación de intervenciones preventivas [7]. Los avances recientes en modelos subrogados o metamodelos han facilitado enormemente el desarrollo de GDs. Estos modelos ofrecen una alternativa de bajo coste computacional, compatible con esquemas de monitorización continua, a modelos numéricos de alta fidelidad y alto coste computacional (frecuentemente modelos de elementos finitos (MEFs)) [8]. En este sentido, ha habido un número creciente de publicaciones sobre el desarrollo de GDs tanto deterministas [9] como probabilísticos [10], capaces de proporcionar una identificación rápida e integral de daños mediante la calibración inversa de parámetros estructurales locales, también conocida como actualización de modelos. Si bien estas técnicas aún se encuentran en fases tempranas de desarrollo, trabajos recientes como los de Jayasinghe et al. [11] y Huang et al. [12] evidencian el potencial de las técnicas de la IA para desarrollar GDs ultrarrápidos, con gran capacidad para modelar respuestas complejas con alta precisión.

En este contexto, la presente comunicación presenta los estudios de investigación realizados para la construcción de un GD estructural para la identificación de daños en continuo de un puente de carretera, el viaducto de la circunvalación de Granada a la altura de Méndez Núñez. El puente se encuentra instrumentado con una red densa de acelerómetros y cuatro sondas térmicas. Los

registros de vibración ambiental se procesan mediante técnicas de Análisis Modal Automatizado, y los registros de temperatura se emplean para caracterizar variabilidad observada en las propiedades modales identificadas. Asimismo, se presenta la construcción de un modelo numérico del puente y su calibración inversa, el cual sirve de base para la construcción de un GD de bajo coste computacional basado en IA. A continuación, se presenta en la Sección 2 la descripción del caso de estudio. A continuación, la Sección 3 describe los resultados obtenidos, y finalmente la Sección 4 concluye el trabajo.

2. Descripción de la estructura: Puente de Méndez-Núñez en Granada




Figura 1. Puente Méndez-Núñez: (a) vistas generales del puente, (b) disposición de los sensores (unidades en metros), y (c) sistema de monitorización.

El puente de Méndez-Núñez es una estructura continua de hormigón postesado con sección variable, compuesta por cinco vanos y una longitud total de 122,5 metros. Se encuentra en la ciudad de Granada, en la Comunidad Autónoma de Andalucía, España (Figura 1(a)). Construido en marzo de 1989 por la Dirección General de Carreteras de la provincia de

Granada, el puente soporta actualmente el tráfico sobre la Avenida de Andalucía, conectando los municipios de Jaén y Motril.

El tablero del puente está sustentado por cuatro pilas centrales de sección 3.40 m x 1.50 m, cimentadas sobre pilotes y encepados, así como por dos estribos formados por muros de contención de hormigón armado. Todos los apoyos descansan sobre neoprenos elastoméricos.

Como parte del proyecto nacional de I+D BRIDGEXT (Ref: PID2020-116644RB-I00), el 27 de septiembre de 2023 se instaló un sistema permanente de SHM basado en vibraciones. El sistema de monitorización está compuesto por 10 acelerómetros piezoeléctricos uniaxiales modelo KB12VD ($\mu 10\%$ 10.0 V/g, resolución en banda ancha: 1 μ g rms y $\pm 0,5$ g pk), etiquetados como A1 a A10 en la Figura 1(b). Los registros de vibración ambiental se almacenan en ficheros binarios individuales de 30 minutos a una frecuencia de muestreo de 100 Hz, utilizando un sistema de adquisición de datos (SA) de National Instruments modelo cDAQ-9184, ubicado en una de las pilas. El sistema de monitorización también registra datos de temperatura mediante cuatro sondas modelo Pt 1000/3850 colocadas en el tablero del puente, y datos de humedad mediante un higrómetro modelo AM2315, controlado con un microcontrolador Arduino Uno independiente, ambos con una frecuencia de adquisición de 5 minutos. Cabe destacar que el sistema de monetización genera aproximadamente 19 GB de datos al mes, lo que implica la gestión de este sistema como un problema de Big Data.

Los registros de aceleración se procesan mediante un algoritmo de OMA automatizado con un ordenador estándar localizado in situ con el software MOVA/MOSS desarrollado en [13], y las propiedades modales identificadas se transmiten automáticamente a través de Internet para su visualización y control. Aunque el sistema de monitorización continúa activo a día de hoy, en este trabajo se analizan los registros

de monitorización recopilados desde el 27/09/23 hasta el 18/10/2023.

3. Resultados numéricos y discusión

3.1 Identificación dinámica.

Las propiedades dinámicas del puente Méndez-Núñez se identificaron utilizando el método de identificación de subespacios estocásticos basado en covarianza (CoV-SSI) implementado en MOVA/MOSS. Como hiperparámetros, se extrajeron las matrices de covarianza entre las señales considerando un retardo temporal máximo de 3.2 s, y la lista de polos estables se obtuvo para órdenes del modelo estado-espacio comprendidos entre 2 y 180, con criterios de tolerancia del 0.1% para las frecuencias resonantes, del 0.5% para las tasas de amortiguamiento y de 0.005 para los valores de MAC (Modal Assurance Criterion).




Figura 2. Diagrama de estabilización del puente de Méndez-Núñez a partir de las aceleraciones registradas el 30/11/23 a las 10:00 a.m.

Tras ello, la interpretación automática de los diagramas de estabilización resultantes se realizó mediante una técnica de agrupamiento jerárquico, considerando una distancia de corte de 0.01 (definida por la suma de las variaciones relativas en frecuencia y los valores de 1-MAC) y un tamaño mínimo de agrupación de 20 polos para considerar un clúster como un modo físico. Sobre esta base, se identificaron un total de once 24 modos globales bien definidos en el rango de frecuencias de hasta 25 Hz. La Figura 2 muestra uno de los diagramas de estabilización extraídos con los resultados del agrupamiento de polos en

el rango de frecuencias de 0 a 10 Hz. En este rango, se identificaron un total de 11 modos globales claramente interpretables, tal y como se muestra en la Figura 3. En concreto, los modos identificados incluyen cinco modos globales de flexión y seis modos de torsión.




Figura 3. Comparación entre los modos experimentales y numéricos tras la actualización del modelo (f_i^{exp} y f_i^{num} denotan las frecuencias experimentales y las del modelo MEF calibrado).

Este procedimiento de identificación se aplicó de manera a todos los registros de aceleración analizados, extrayendo las series temporales de frecuencias resonantes mostradas en la Figura 4. En este gráfico, se muestran todas las frecuencias identificadas (a), así como un zoom de los primeros once modos en el rango de frecuencias hasta 10 Hz (b). Nótese que, efectivamente, las frecuencias de resonancia experimentan una notable variabilidad diaria, así como ciertas variaciones estacionales. Esto es particularmente evidente a partir de mediados de octubre, cuando las temperaturas en Granada experimentaron un descenso considerable.




Figura 4. Series temporales de frecuencias de resonancia identificadas en el puente.

Para arrojar mayor luz sobre los efectos ambientales, la Figura 5 muestra los gráficos de correlación entre las primeras cuatro frecuencias de resonancia y los sensores de temperatura. Nótese que las cuatro frecuencias muestran una correlación negativa. Este tipo de correlación es común en puentes de hormigón, y se atribuye a reducciones en el módulo elástico del material al aumentar la temperatura (véase por ejemplo [14]). Cabe también destacar que la dependencia con la temperatura aumenta conforme aumenta la frecuencia, obteniendo coeficientes de correlación de Pearson desde -0.65 hasta -0.73.

La Figura 5 también muestra un cierto desfase entre los sensores de temperatura. En concreto, mayores temperaturas se registran en el sensor T_1 localizado bajo el tablero en el ala suroeste del puente, donde incide con mayor intensidad la radiación solar. La distribución de temperatura se observa con mayor claridad en la

Figura 6, donde se muestran las temperaturas en el tablero a lo largo del día 1 de octubre de 2023. Nótese como, efectivamente, la temperatura aumenta progresivamente desde el ala noroeste hasta el suroeste, registrando mayores concentraciones de temperatura en esta última.




Figura 5. Análisis de correlación entre las frecuencias de resonancia y los sensores de temperatura.




Figura 6. Distribución de temperatura en el tablero del puente a lo largo del día 1 de octubre de 2023.

3.2 Modelo de elementos finitos y calibración

Para generar un GD estructural del puente, se construyó un modelo MEF 3D del mismo utilizando SAP2000, como se muestra en la Figura 7.

La geometría del modelo se construyó a partir de los planos estructurales disponibles. El tablero se modeló mediante elementos de viga de

sección variable y masas torsionales concentradas. Los pilares interiores también se modelaron con elementos de viga de sección variable, conectados al tablero a través de resortes verticales y longitudinales, con valores de rigidez extraídos de las propiedades mecánicas de los aparatos de apoyo. Para extraer los desplazamientos en los puntos del borde del tablero donde se ubican los sensores reales, también se introdujeron elementos infinitamente rígidos y sin masa. Asimismo, se incluyeron elementos infinitamente rígidos y sin masa para simular las excentricidades reales entre el tablero y los pilares, los estribos y las cimentaciones. Por último, los cables de postensado se modelaron mediante fuerzas internas que siguen sus perfiles parabólicos reales. Análisis de efectos P-delta confirmaron que las fuerzas de pretensado desempeñan un papel insignificante en las propiedades modales del puente, por lo que su efecto se descarta en la posterior calibración del modelo. Como propiedades materiales, se asumieron propiedades elásticas isotrópicas para todo el modelo, con un módulo de elasticidad de 35.0 GPa, un coeficiente de Poisson de 0.2 y una densidad de masa de 2.35 t/m³.




Figura 7. Modelo MEF del puente de Méndez-Núñez en SAP2000.

Con los resultados de identificación modal presentados en la Sección 3.1., el modelo MEF fue calibrado en el módulo implementado MOVA/MOSS [13] específico para el ajuste de modelos de SAP2000 en base a información modal. Para ello, el tablero del puente se discretizó en once secciones y considerando sus módulos de elasticidad E_i como parámetros de ajuste (véase la Figura 7).

En general, notemos que se desean calibrar t variables $x_i \in \mathbb{R}$, $i = 1, \dots, t$, restringidas dentro de un cierto rango de

variación $D = \{x \in \mathbb{R}^t : a_i \leq x_i \leq b_i\}$. Con ello, el valor ajustado de estos parámetros se puede estimar a partir de un problema de minimización $\hat{x} = \arg \min_{x \in D} J(x)$, donde $J(x)$ representa la función de coste que cuantifica la discrepancia entre los datos experimentales y las predicciones del modelo. Si el análisis modal identifica n modos de vibración, $J(x)$ se puede definir como:

$$J(x) = \sum_{i=1}^n [\alpha \varepsilon_{f,i}(x) + \beta \varepsilon_{\phi,i}(x)] + \eta \mathcal{R}(x), \quad (1)$$

donde los términos $\varepsilon_{f,i}(x)$ y $\varepsilon_{\phi,i}(x)$ representan los errores en la i -ésima frecuencia resonante y forma modal, respectivamente. Los términos α , β y η en la Ecuación (1) son coeficientes de ponderación, mientras que el último término, $\mathcal{R}(x)$, actúa como un término de regularización para mitigar problemas de mal condicionamiento en la optimización. En este trabajo, se ha implementado una versión modificada de la regularización de Tikhonov:

$$\mathcal{R}(x) = \frac{1}{t} \sum_{i=1}^t \frac{(x_i - x_i^0)^2}{b_i - a_i}. \quad (2)$$

donde x_i^0 representa el valor de referencia del parámetro i .

Suponiendo que los módulos de elasticidad pueden variar entre 31.5 GPa y 45.5 GPa, el modelo MEF del puente se calibró utilizando los once modos globales previamente identificados. En particular, para el término de error en frecuencias $\varepsilon_{f,i}(x)$, se incluyó el error relativo máximo. En cuanto al error las formas modales, se adoptó el valor medio de $1 - MAC(\varphi_{MEF}, \varphi_{exp})$, donde $MAC(\varphi_{MEF}, \varphi_{exp})$ denota el valor MAC entre las formas modales predichas por el modelo y las formas modales experimentales. Los coeficientes de ponderación se definieron como $\alpha = 1$, $\beta = 2$, $\eta = 0$, $\alpha_m = 1$, $\beta_m = 0.8$, y para resolver el problema de optimización resultante se empleó el algoritmo de enjambre de partículas (PSO) con 60 partículas y 65 generaciones. Las Tablas 1 y 2

recogen la comparación entre los modos experimentales y numéricos antes y después de la calibración en términos de errores relativos en frecuencias y valores MAC. La comparación en las formas modales se muestra visualmente en la Figura 3. En general, se obtuvo una calibración de muy alta calidad para todos los modos, obteniendo un error relativo máximo de -1.75%.

Tabla 1. Comparación entre las propiedades modales experimentales y numéricas previo ajuste del modelo.

Mode Num.	f_i^{exp} [Hz]	f_i^{MEF} [Hz]	Err. Rel. [%]	MAC
1	2.87	2.86	-0.46	1.00
2	3.76	3.78	0.59	1.00
3	4.53	4.13	-8.75	0.95
4	5.05	5.01	0.19	0.99
5	5.31	4.79	-9.95	0.95
6	6.14	5.73	-6.60	0.98
7	6.42	6.39	-0.60	0.95
8	6.81	6.88	0.95	0.99
9	7.24	6.84	-5.61	0.99
10	8.31	8.20	-1.35	0.99
11	9.51	9.39	-1.24	0.99

Tabla 2. Comparación entre las propiedades modales experimentales y numéricas tras el ajuste del modelo.

Mode Num.	f_i^{exp} [Hz]	f_i^{MEF} [Hz]	Err. Rel. [%]	MAC
1	2.87	2.87	-0.07	1.00
2	3.76	3.79	0.87	1.00
3	4.53	4.61	1.75	0.95
4	5.05	5.07	0.50	0.99
5	5.31	5.22	-1.75	0.96
6	6.14	6.13	-0.05	0.98
7	6.42	6.42	-0.07	0.95
8	6.81	6.93	1.74	0.98
9	7.24	7.23	-0.25	0.99
10	8.31	8.33	0.17	0.99
11	9.51	9.67	1.74	1.00

3.2 Modelo subrogado basado en IA

Para definir el GD del puente, se diseñó una red neuronal feedforward (FNN) profunda en TensorFlow como un metamodelo del modelo MEF descrito en la Sección 3.1. Dado que el objetivo principal es su uso para la identificación continua del sistema, el modelo MEF se parametrizó con $l = 20$ parámetros, correspondientes a los módulos de elasticidad de las secciones obtenidas al discretizar los cinco vanos en cuatro elementos de igual longitud. En concreto, se consideraron 20 multiplicadores de rigidez k_i , con $i = 1, \dots, l$, que afectan directamente a los módulos de elasticidad y se emplean como parámetros de ajuste. Estos multiplicadores actúan como las variables de entrada de la FNN, mientras que la salida está compuesta por las frecuencias de resonancia y los modos de vibración.




Figura 8. Arquitectura de la FNN para la generación de un gemelo digital impulsado por IA para el puente de Méndez-Núñez.

La arquitectura de la FNN, mostrada en la Figura 8, comienza con una capa de entrada para los l multiplicadores de rigidez k_i , seguida de varias capas totalmente conectadas (densas) con funciones de activación hiperbólicas tangentes, diseñadas para capturar las dependencias complejas entre los parámetros de entrada y las firmas modales. A continuación, la red se ramifica en caminos especializados: uno para la predicción de las frecuencias naturales f_j ($j = 1, \dots, n$, donde $n = 11$ en este caso de estudio)

y otro compuesto por n bloques independientes, cada uno dedicado a predecir una forma modal específica. Las capas de salida de estas ramas representan los desplazamientos modales en los m grados de libertad monitorizados ($m = 10$ en este caso de estudio).




Figura 9. Resultados del entrenamiento y prueba de la red neuronal. (a) Función de coste para la población de entrenamiento y validación. (b) Comparación entre las frecuencias predichas por el GD (f_{GD}) y el MEF (f_{MEF}).

Suponiendo que los multiplicadores de rigidez k_i pueden variar en el rango $[0.7, 1.1]$, se utilizó el método de muestreo Latin Hypercube (LHS) implementado en MOVA/MOSS para generar un conjunto de entrenamiento de 2048 muestras. Las propiedades modales correspondientes se extrajeron mediante simulación de Monte Carlo del modelo MEF del puente. A continuación, la red neuronal se entrenó durante 1000 iteraciones, utilizando el 15% de las 2048 muestras para análisis de validación. Se definió una función de coste personalizada basada en la suma no ponderada de los errores cuadrados en las frecuencias y los valores de $1 - MAC$. Los hiperparámetros del modelo se seleccionaron tras análisis paramétricos, controlando la convergencia de la función de pérdida en los conjuntos de entrenamiento y prueba, así como la precisión global en términos de errores relativos en frecuencia y valores de MAC en comparación con los resultados obtenidos por el modelo MEF. Para el entrenamiento, se utilizó el optimizador adaptativo Adam con una tasa de aprendizaje inicial de 10^{-4} y un valor de

momento de 0.98. Se empleó un tamaño de lote de 16 muestras para el entrenamiento, con barajado de datos en cada iteración. La convergencia de la función de coste se muestra en la Figura 9(a), indicando una rápida estabilización a partir de la época 150, con un buen comportamiento tanto en el conjunto de entrenamiento como en el de prueba.

Para evaluar la precisión de la FNN, se utilizó un conjunto de validación independiente de 1024 muestras. Para este conjunto, la Figura 9(b) compara las frecuencias predichas por la red con las evaluaciones del modelo MEF. Nótese la alta precisión del metamodelo, obteniendo un coeficiente de determinación R^2 para las frecuencias de cada modo por encima 99%. También se alcanza una alta precisión en formas modales, con valores MAC por encima de 0.999, omitidos aquí por brevedad. Es importante resaltar que el modelo MEF requiere alrededor de 3.5 segundos para un único análisis modal lineal, mientras que la FNN entrenada completa la misma tarea en tan solo 0.01 segundos, es decir una reducción del 99.71%.

Una vez entrenado, el GD se utilizó para la identificación continua del puente. Para ello, se emplearon las series temporales de los primeros once modos mostrados anteriormente en la Figura 4 desde el 27/09/23 hasta el 18/10/23 (921 identificaciones). Para cada identificación, el GD se calibró siguiendo la formulación introducida en la Sección 3.1. En este caso, en la función de coste $J(\mathbf{x})$ en la Ecuación (1), se consideraron los errores relativos medios en frecuencia y los valores medios de $1 - MAC$, con coeficientes de ponderación $\alpha = 1$, $\beta = 1$ y $\eta = 2$. Para cada registro de 30 minutos, el problema de calibración inverso se resolvió mediante el algoritmo PSO (40 partículas y 90 iteraciones). Cabe destacar que cada identificación del sistema tardó solo unos 8 segundos, gracias a la alta eficiencia computacional del GD basado en IA.




Figura 10. Identificación continua del puente de Méndez-Núñez mediante un GD impulsado por IA, del 27 de septiembre de 2023 al 18 de octubre de 2023 (921 identificaciones).




Figura 11. Series temporales de frecuencias experimentales del puente de Méndez-Núñez y estimadas mediante calibración inversa del GD basado en IA.

Las series temporales resultantes de los multiplicadores de rigidez se muestran en la Figura 10. Es interesante observar que las oscilaciones diarias presentes en las series temporales de las frecuencias resonantes se traducen en fluctuaciones en los multiplicadores k_i . Al igual que las frecuencias resonantes, todos los multiplicadores muestran correlaciones negativas con la temperatura ambiental (es decir, temperaturas más bajas tienden a hacer que la estructura responda de manera más rígida). Cabe destacar que el GD logra replicar las oscilaciones diarias en las frecuencias resonantes con una precisión considerable como se observa en la Figura 11, con niveles de error coherentes con los reportados en la calibración inicial del modelo MEF en la Tabla 2. No obstante, en la Figura 10 se aprecia que algunos parámetros alcanzan el límite superior de definición (1.10) en ciertos puntos, a pesar de la inclusión del término de regularización $R(x)$. Esto podría indicar problemas de mal condicionamiento en la optimización, o bien que el límite superior de definición es insuficiente para capturar

completamente la variabilidad de las frecuencias. No obstante, es importante subrayar que estos resultados se presentan únicamente con el propósito de ilustrar el potencial del GD desarrollado. En su uso para la identificación de daños, podría ser preferible minimizar la variabilidad en las propiedades modales debida a cambios ambientales previo a la calibración inversa del GD, para lo cual un rango de variación de $0.7 \leq k_i \leq 1.7$ parece razonable.

4. Conclusiones

Este trabajo ha presentado el desarrollo de un gemelo digital del puente de Méndez-Núñez en Granada basado en IA. El gemelo digital se define como una red neuronal profunda que relaciona parámetros locales de la estructura con las características modales del puente, y ha sido entrenado con un modelo de elementos finitos. Se ha presentado la identificación dinámica continua del puente, así como el análisis de influencia de la temperatura ambiental. Con ello,

se ha demostrado la alta eficiencia computacional del gemelo digital desarrollado, pudiendo realizar la actualización del modelo con veinte parámetros de ajuste en tiempos de computación compatibles con sistemas de monitorización continua a largo plazo.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación de España con el proyecto de investigación “BRIDGEXT - Life-extension of ageing bridges: Towards a long-term sustainable Structural Health Monitoring” (Ref. PID2020-116644RB-I00). También se agradece la colaboración de la doctoranda Elisa Tomassini en el desarrollo de la IA para el metamodelado del caso de estudio.

Referencias

- [1] Cawley, P. (2018). Structural health monitoring: Closing the gap between research and industrial deployment. *Structural Health Monitoring*, 17(5), 1225-1244.
- [2] Di Mucci, V. M., Cardellicchio, A., Ruggieri, S., Nettis, A., Renò, V., & Uva, G. (2024). Artificial intelligence in structural health management of existing bridges. *Automation in Construction*, 167, 105719.
- [3] Farrar, C. R., & Worden, K. (2012). Structural health monitoring: a machine learning perspective. John Wiley & Sons.
- [4] Hassani, S., Mousavi, M., & Dackermann, U. (2023). Effects of environmental and operational conditions on structural health monitoring and non-destructive testing: A systematic review. *Buildings*, 13(4), 918.
- [5] García-Macías, E., & Ubertini, F. (2021). Integrated SHM systems: Damage detection through unsupervised learning and data fusion. In *Structural health monitoring based on data science techniques* (pp. 247-268). Cham: Springer International Publishing.
- [6] Zar, A., Hussain, Z., Akbar, M., Rabczuk, T., Lin, Z., Li, S., & Ahmed, B. (2024). Towards vibration-based damage detection of civil engineering structures: overview, challenges, and future prospects. *International Journal of Mechanics and Materials in Design*, 20(3), 591-662.
- [7] Torzoni, M., Tezzele, M., Mariani, S., Manzoni, A., & Willcox, K. E. (2024). A digital twin framework for civil engineering structures. *Computer Methods in Applied Mechanics and Engineering*, 418, 116584.
- [8] Kudela, J., & Matousek, R. (2022). Recent advances and applications of surrogate models for finite element method computations: a review. *Soft Computing*, 26(24), 13709-13733.
- [9] Cabboi, A., Gentile, C., & Saisi, A. (2017). From continuous vibration monitoring to FEM-based damage assessment: Application on a stone-masonry tower. *Construction and Building Materials*, 156, 252-265.
- [10] García-Macías, E., & Ubertini, F. (2022). Real-time Bayesian damage identification enabled by sparse PCE-Kriging meta-modelling for continuous SHM of large-scale civil engineering structures. *Journal of Building Engineering*, 59, 105004.
- [11] Jayasinghe, S. C et al. (2024). Innovative digital twin with artificial neural networks for real-time monitoring of structural response: A port structure case study. *Ocean Engineering*, 312, 119187.
- [12] Huang, Z., Yin, X., Liu, Y., & Liu, Y. (2024). Damage identification of truss bridges based on feature transferable digital twins. *Measurement*, 233, 114735.
- [13] García-Macías, E., & Ubertini, F. (2020). MOVA/MOSS: Two integrated software solutions for comprehensive Structural Health Monitoring of structures. *Mechanical Systems and Signal Processing*, 143, 106830.
- [14] Magalhães, F., Cunha, Á., & Caetano, E. (2012). Vibration based structural health monitoring of an arch bridge: From automated OMA to damage detection. *Mechanical Systems and signal processing*, 28, 212-228.