

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Ciencias de la Tierra

Metodología no supervisada para identificar cambios estructurales en puentes
ferroviarios bajo cargas dinámicas

Proyecto de Titulación

Previo la obtención del Título de:

Magíster en Ciencias de la Tierra

Presentado por:

Juan Pablo Molina Cedeño

Guayaquil - Ecuador

Año: 2025

Agradecimientos

Mi más sincero agradecimiento a mi familia por estar siempre a mi lado, y apoyarme cuando más lo necesite, a mi tutora por darme las oportunidades para desarrollarme como profesional, a mis amigos por darme apoyo y momentos de distracción, a mis docentes por brindarme los conocimientos y herramientas necesarias para llevar a cabo mi proyecto, y por último, a Dios, quien me cuidó a mí, a mi familia y conocidos durante esta etapa de mi vida.

Declaración Expresa

Yo Juan Pablo Molina Cedeño acuerdo y reconozco que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí/nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me/nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi/nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al autor que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 29 de agosto del 2025.

Juan Pablo Molina
Cedeño

Evaluadores

MSc. Guillermo Javier Muñoz Villa

Evaluador

Ph.D. Natividad Leonor García Troncoso

Tutora de proyecto

Resumen

Este estudio se centra en la aplicación de la monitorización estructural basada en datos no supervisada (SHM) de un puente ferroviario de un solo tramo. Se desarrolló un modelo numérico con elementos finitos (FE) con cargas de tren como cargas concentradas móviles incorporando OpenSees para medir la respuesta estructural, aprovechando las cargas de gran magnitud para mejorar la sensibilidad a los cambios estructurales. La metodología propuesta identifica los daños introduciendo la velocidad del tren, las cargas por eje y una reducción de la rigidez del 5% al 20% en secciones críticas localizadas del puente. Para garantizar una evaluación continua, se aplicó a los datos monitorizados una combinación híbrida de modelo autorregresivo multivariante (MAR), análisis de componentes principales, distancia de Mahalanobis y algoritmo de agrupamiento k-means, como algoritmo de aprendizaje automático no supervisado. La estrategia demostró ser robusta a la hora de detectar escenarios sin daños y con daños en diferentes velocidades y cargas de tren. Su sensibilidad a niveles de daño más pequeños, que consisten en pequeñas reducciones de la rigidez, e independencia de los datos de entrenamiento etiquetados como dañados, que lo convierten en una solución fiable para la monitorización continua a largo plazo en puentes ferroviarios instrumentados.

Palabras Clave: Aprendizaje supervisado, SHM, detección de daños, modelo MAR.

Abstract

This study centers in the application of unsupervised data-driven structural health monitoring (SHM) of a single-span railway bridge. A numerical model with finite elements (FE) with train loads as moving concentrated loads was developed incorporating OpenSees to measure structural response, taking advantage of the large-magnitude loads for enhancing sensitivity to structural changes. The proposed methodology identify damage by introducing train speed, axle loadings, and stiffness reduction by 5% to 20% in localized critical sections of the bridge. To ensure a continuous assessment, a hybrid combination of multivariate autoregressive (MAR) model, principal components analysis, mahalanobis distance and k-means clustering algorithm was applied to the monitored data, as a unsupervised machine learning algorithm. The strategy proved to be robust when detecting undamaged and damaged scenarios across varying train speed and train loads. Its sensitivity to smaller damaged levels that consists of small stiffness reductions, and independence from labelled damaged training data, make this a reliable solution for long-term continuous monitoring at instrumented railway bridges.

Keywords: Supervised learning, SHM, Damage detection, MAR model

Índice general

Evaluadores	4
Resumen	5
<i>Abstract</i>	6
Índice general	7
Abreviaturas	9
Simbología	10
Índice de figuras	11
Índice de tablas	12
Capítulo 1	13
1. Introducción	14
1.1. Descripción del Problema	15
1.2. Justificación del Problema	16
1.3. Objetivos	16
1.3.1. <i>Objetivo general</i>	16
1.3.2. <i>Objetivos específicos</i>	16
1.4. Marco teórico	17
Capítulo 2	19
2. Metodología	20
2.1. Marco metodológico	20
2.2. Elaboración y calibración del modelo numérico	22
2.3. Análisis y validación de datos	24
2.4. Simulación de escenarios de daño	24
2.5. Implementación del algoritmo de detección de daños.....	27
Capítulo 3	29
3. Resultados y análisis	30
3.1. Estimación de los modos	30

3.1.1.	<i>Estimación de la masa modal</i>	31
3.1.2.	<i>Valores modales</i>	31
3.1.3.	<i>Discusión sobre los modos obtenidos</i>	32
3.2.	Validación de modelo numérico	32
3.2.1.	<i>Micro deformaciones</i>	32
3.2.2.	<i>Aceleraciones</i>	34
3.2.3.	<i>Efectos de temperatura y humedad relativa</i>	35
3.3.	Detección de daño	35
3.3.1.	<i>Extracción de características</i>	36
3.3.2.	<i>Fusión de características</i>	39
3.3.3.	<i>Discriminación y agrupamiento de características</i>	40
3.4.	Aplicaciones a la industria de hidrocarburos	43
Capítulo 4		44
4.	Conclusiones y recomendaciones	45
4.1.	Conclusiones	45
4.2.	Recomendaciones	45
Referencias		47

Abreviaturas

AR Autoregressive

EOVs Environmental and Operational Variations

ESPOL Escuela Superior Politécnica del Litoral

MD Mahalanobis Distance

ML Machine Learning

OMA Operational Modal Analysis

PCA Principal Component Analysis

SHM Structural Health Monitoring

Simbología

cm	Centímetro
GPa	Giga Pascales
Hz	Hertzios
kgf	Kilogramos
kgf	Kilogramos Fuerza
km	Kilómetros
kN	Kilo Newtons
m	Metro
mm	Milímetro
rad	Radianes
s	Segundos
ton	Toneladas
tonf	Tonelada Fuerza

Índice de figuras

Figura 2.1 Esquema metodológico	20
Figura 2.2 Distribución estadística de velocidades de trenes.....	21
Figura 2.3 Vista del diseño estructural: (a) en planta (b) en elevación	23
Figura 2.4 Vista del Modelo de Elementos Finitos	24
Figura 2.5 Esquema de configuración de parámetros para las simulaciones del Modelo Numérico	26
Figura 2.6 Velocidades de trenes vs. Pesos totales de trenes simulados para escenarios no dañados	27
Figura 2.7 Velocidades de trenes vs. Pesos totales de trenes por tipo de tren	27
Figura 3.1 Deformación vs Tiempo de Viga Principal Oeste medidas en Sensor y Modelo de Elementos Finitos: (a) T3V1; (b) T3V2; (c) T3V3; (d) T5V1; (e) T5V2; (f) T5V3	33
Figura 3.2 Distribución de deformaciones en el tablero del puente.....	33
Figura 3.3 Aceleración vs Tiempo de Viga Principal Oeste medidos en Sensor y Modelo de Elementos Finitos: (a) T3V1; (b) T3V2; (c) T3V3; (d) T5V1; (e) T5V2; (f) T5V3	34
Figura 3.4 Correlación entre desplazamiento medio máximo vertical del puente, y efectos de Temperatura y Humedad Relativa: (a)T3 a 130 km/h; (b) T5 a 130 km/h	35
Figura 3.5 Efectos de daño por variación de niveles de daño en el tiempo	36
Figura 3.6 Precisión media para diferentes ordenes del modelo MAR	37
Figura 3.7 Parámetros MAR (Ad) en el sensor d=2 de la estructura para simulaciones en condición: (a) sin daño y (b) con daño	38
Figura 3.8 Parámetros MAR (Ad) en el sensor d=2 de la estructura para tres parametros representativos	38
Figura 3.9 MDs mediante todas las simulaciones en el nodo d=2.....	39
Figura 3.10 Diagrama de caja de todas las MDs en todos los sensores.....	40
Figura 3.11 Mapa de calor de disimilitudes entre simulaciones para modelo MAR de orden 15 con 4 nodos	41
Figura 3.12 Resultado de agrupaciones de los MDs después de la aplicación de K-means	42

Índice de tablas

Tabla 2.1 Propiedades geométricas y de materiales en el modelo de OpenSees	22
Tabla 2.2 Características de los trenes empleados en análisis numérico	24
Tabla 2.3 Velocidades representativas empleados en análisis numérico.....	25
Tabla 2.4 Elementos dañados empleados en análisis numérico	25
Tabla 2.5 Porcentajes de reducción de rigidez empleados en análisis numérico.....	25
Tabla 3.1 Modos de vibración y frecuencias naturales del modelo numérico.....	30

Capítulo 1

1. Introducción

Actualmente, la red ferroviaria tiene gran relevancia en el transporte y economía, siendo esta una de las infraestructuras más grandes de la Unión Europea, teniendo más de 216,000 km de red activa (Knapcikova & Konings, 2018). El Reino Unido, quien opera una de las redes ferroviarias más antiguas de Europa con más de un millar de puentes, dispone del 30% de sus puentes con un tiempo de servicio de entre 50 a 100 años, y 35% de sus puentes con un tiempo de servicio de más de 100 años (Bell & Rail, 2004). Bajo el peso de trenes con pasajeros y de mercancías, estos puentes presentan daños por fatiga y corrosión, que pueden ser de las condiciones más críticas para el desempeño de la superestructura (Imam & Salter, 2017).

La creciente vulnerabilidad de la infraestructura ferroviaria se debe a la creciente demanda de la red, e impacto del peso de los trenes, lo cual requiere de extensos periodos para el mantenimiento provisto por operadores como Network Rail en Reino Unido (Ison et al., 2012). El Monitoreo de la Salud Estructural (SHM) surge como medida alternativa a la inspección tradicional, cuyo objetivo es detectar a tiempo fisuras o pérdidas de rigidez, pero añadiendo la adquisición y análisis continuo de datos para identificar cambios que puedan afectar la seguridad y el desempeño en tiempo real (Duzgun et al., 2016).

Los métodos como el Operational Modal Analysis (OMA), que representan una alternativa no destructiva con el uso del monitoreo estructural, son aplicables en la predicción de comportamiento de estructuras civiles bajo cargas dinámicas como vehículos, pero son bastante susceptibles a las interacciones provocadas por Variaciones Ambientales y Operacionales (EOVs) como el viento, temperatura o humedad (Rainieri et al., 2020). Además, se disponen de métodos con enfoque de aprendizaje supervisado, que precisan de datos etiquetados con daño y sin daño, pero su adquisición puede ser impráctica al requerir ensayos de laboratorio de estructuras en servicio, o modelos físicos de estructuras poco convencionales (Eltouny et al., 2023).

Por ello, la literatura reciente propone estrategias con metodologías no supervisadas que combinan modelos autorregresivos (AR) con técnicas de extracción de características, normalización, y agrupación (Anastasia et al., 2023). Dada la independencia de datos, el aprendizaje no supervisado está relacionado con la toma de decisiones precisas a través de datos faltantes en condiciones de variabilidad impredecibles debido a las EOVs, por lo que se busca implementar técnicas para remover las EOVs por medio de técnicas como el Análisis de Componentes Principales (PCA) (Entezami et al., 2023).

Aun con estos avances, las aplicaciones en puentes ferroviarios suelen estar limitadas por la captura de características relevantes, variabilidad de las condiciones de carga y ambientales, y la precisión del modelo de aprendizaje no supervisado. Este proyecto aborda esa brecha mediante la implementación de la metodología no supervisada en el puente Norton Bridge, un puente tipo viga metálico de 26,84 m de luz situado en Staffordshire, Reino Unido.

1.1. Descripción del Problema

La descripción del problema que plantea Network Rail parte de tres exigencias: (1) Obtener información de los trenes que cruzan el puente e investigar nuevas formas de analizar los datos para hallar tendencias a largo plazo que puedan ser útiles a los administradores de la red ferroviaria. (2) Monitorear la capacidad del puente ante el incremento de la carga de los trenes, empleando el sistema de monitoreo de carga de trenes y sensores de fibra óptica. (3) Proveer información útil sobre la condición y desempeño de la estructura, que permitan tomar optimas decisiones para la intervención y mantenimiento del puente.

De las señales disponibles a través del sistema de monitoreo, se pueden obtener las aceleraciones, deformaciones, temperatura ambiente, humedad relativa, velocidad del tren, y grabación de cada tren. Además, se dispone del diseño estructural de la superestructura del puente,

que incluye las propiedades, geometrías, ubicación, y cargas de cada uno de los elementos estructurales.

1.2. Justificación del Problema

La relevancia de resolver este problema es múltiple. En primer lugar, la seguridad pública está en juego, puesto que un fallo estructural en los elementos estructurales principales podría llevar una pérdida de capacidad importante para el paso de trenes a alta velocidad. En segundo lugar, pérdidas de al menos 1 millón de libras esterlinas por año se atribuye al fallo de un puente cada 2-5 años en Reino Unido, afectando el propósito inicial del puente que era reducir el cuello de botella ocasionada por la interacción de trenes a diferentes velocidades (Benn, 2013). En tercer lugar, demostrar la viabilidad y beneficios que conlleva la implementación de un modelo predictivo sin necesidad de inspecciones visuales subjetivas e inconsistentes (Ye et al., 2022).

Finalmente, la falta de aplicaciones de un sistema de monitoreo con pesaje en movimiento de trenes dentro de la red ferroviaria de Reino Unido confiere al estudio la importancia de validar metodologías predictivas con modelos AR, ampliando el conocimiento disponible y sirviendo de referencia para otras aplicaciones en puentes ferroviarios.

1.3. Objetivos

1.3.1. Objetivo general

Implementar y validar una metodología no supervisada para la detección temprana de daño en el Norton Bridge mediante el análisis de respuestas dinámicas inducidas por trenes.

1.3.2. Objetivos específicos

1. Caracterizar la respuesta dinámica y el estado actual del Norton Bridge mediante el sistema de monitoreo instalado y el desarrollo de un modelo numérico calibrado en OpenSees.

2. Generar escenarios de daño en el modelo, extrayendo indicadores sensibles mediante modelos MAR y distancias de Mahalanobis, y clasificar automáticamente las condiciones estructurales con K-means sin necesidad de datos etiquetados.
3. Validar la metodología cuantificando su precisión y robustez frente a variaciones de velocidad y peso de tren, y establecer umbrales operativos de alerta para su implementación en línea.

1.4. Marco teórico

El monitoreo de salud estructural (SHM) se apoya en la idea de que los parámetros dinámicos de una estructura como las frecuencias naturales, amortiguamientos, y modos de vibrar, son un reflejo indirecto de su rigidez global. La frecuencia natural y de resonancia están en función de la rigidez, y estas tienden a bajar con reducciones de rigideces locales, provocando cambios medibles que ayudan en el reconocimiento de patrones en algoritmos de Aprendizaje de Máquina (ML) (Worden & Cross, 2018).

Bajo esta premisa, se puede aplicar la metodología de aprendizaje supervisada o la no supervisada. El enfoque supervisado se centra en entrenar clasificadores a partir de bases etiquetadas, sin embargo, su efectividad depende de disponer de datos suficientes de cada patrón de daño, una condición inviable al tener que inducir daño real a la estructura (Meixedo et al., 2022). Por otra parte, el enfoque no supervisado aplica modelos autorregresivos y métodos estadísticos para detectar variaciones sin necesidad de etiquetas previas.

Dentro del grupo de los modelos autorregresivos se encuentran los modelos Autorregresivos (AR), Autorregresivos exógenos (ARX), o Autorregresivos Multivariantes (MAR). El modelo MAR propone captar la dependencia temporal y cruzada entre varios sensores, modelando cada variable objetivo como la suma lineal de sus valores previos y de las demás variables, y, por ende, logrando ser mas sensible a modelos invariables (Quiroz et al., 2025).

Las características extraídas de los modelos AR son medidas por la distancia entre ellas, tomando la correlación entre variables, y redefinidas como la distancia métrica de Mahalanobis (MD) entre las simulaciones dañadas y no dañadas (Zhou et al., 2015). Al ser un algoritmo de aprendizaje no supervisado, se puede aplicar el algoritmo k-means para hallar la distancia entre cada vector y uno de los k centros, formando k agrupamientos, los cuales pueden ser divididos en agrupamientos de datos dañados y no dañados (Bouzenad et al., 2019). Este esquema presenta una ventaja de filtrar automáticamente las componentes naturalmente dispersas y separarlas de aquellas que permanecen estables mientras no exista daño.

Un desafío específico en la predicción de daño en puentes ferroviarios consiste en la presencia de EOVs. Estas variaciones inducen cambios en la respuesta dinámica que pueden ser detectados como daño, por lo que es necesario normalizarlos sin degradar la capacidad del algoritmo para detectar características anómalas. En la aplicación del PCA lineal, se incorporan las características extraídas de los casos no dañados, lo que corresponde implícitamente al número de factores independientes relacionados a variaciones normales (Silva et al., 2018).

Finalmente, las simulaciones numéricas debidamente validadas se han convertido en un soporte esencial para caracterizar la efectividad del algoritmo. Dado que el modelo numérico permite inducir condiciones específicas a los elementos estructurales como cambio en la rigidez local, se puede observar y validar mediante los agrupamientos identificados como elementos dañados y no dañados.

Capítulo 2

2. Metodología

2.1. Marco metodológico




Figura 2.1 Esquema metodológico

La estrategia de supervisión adoptada se apoya en la propuesta no supervisada empleando un modelo autorregresivo multivariante (Quiroz et al., 2025). Su punto de partida consiste en describir la dinámica de la estructura mediante modelos autorregresivos multivariantes y, a partir de ellos, supervisar la coherencia estadística de nuevas observaciones con respecto a una distribución de referencia establecida en servicio. Cuando la distancia, ponderada con la métrica de Mahalanobis, se aparta de esa región de confianza y tal desviación persiste en el tiempo, el sistema infiere la existencia de un cambio en la rigidez. La ventaja radica en que los datos son proporcionados por la instrumentación del puente (SHM) y no depende de bases etiquetadas con daño.

Para llevar esa metodología al Norton Bridge, primero se levantó un modelo numérico a partir del diseño estructural provisto por Network Rail y desarrollado por Atkins. Después se sometió al modelo a combinaciones realistas de trenes, y velocidades estadísticamente representativas Figura 2.2, obtenidas del sistema de pesaje en movimiento instalado en el puente, generando un banco de señales que actúa como representación de los registros de campo. Con ese doble soporte virtual y real se validó la fidelidad del gemelo, se indujeron daños en forma de reducción de rigidez y, por último, se entrenó el algoritmo estadístico siguiendo la secuencia de ML Figura 2.1.




Figura 2.2 Distribución estadística de velocidades de trenes

2.2. Elaboración y calibración del modelo numérico

El puente se reprodujo en OpenSees empleando elementos beam-column con rigidez de cortante para los rieles, y elementos shell en capas para la losa de hormigón armado y vigas de acero estructural Figura 2.3. Esta discretización permitió diferenciar el hormigón comprimido, la armadura longitudinal y la colaboración transversal del tablero. Los apoyos se representaron soportes de extremo fijo y extremo fijado con pasador. Las propiedades numéricas y de los materiales usadas en el modelo se encuentran resumidas en la Tabla 2.1.

Tabla 2.1 Propiedades geométricas y de materiales en el modelo de OpenSees

Descripción de parámetro	Valor
Propiedades geométricas	
Longitud del puente	26.84 m
Ancho del puente	7.30 m
Viga principal	
Ancho de ala	700 mm
Espesor de ala	120 mm
Altura de alma	2,080 mm
Espesor de alma	25 mm
Viga transversal	
Ancho de ala	374.7 mm
Espesor de ala	27 mm
Altura de alma	374.6 mm
Espesor de alma	16.5 mm
Rieles	
Área de sección	76.70 cm ²
Momento de inercia alrededor del eje z	512.30 cm ⁴
Momento de inercia alrededor del eje y	3,038.30 cm ⁴
Momento de inercia polar	209.20 cm ⁴
Losa	
Espesor	250 mm
Propiedades de materiales	
Acero (Vigas principales, vigas transversales y rieles)	
Módulo de Young	210 GPa

Coeficiente de Poisson	0.3
Peso unitario	7,850 kgf/m ³
Hormigón (Losa)	
Módulo de Young	34 GPa
Coeficiente de Poisson	0.3
Peso unitario	2,400 kgf/m ³




Figura 2.3 Vista del diseño estructural: (a) en planta (b) en elevación

Para reproducir la aplicación de la carga viva se adoptó un LoadPattern Plain enlazado a un TimeSeries Path. Cada eje de los trenes se representó como una fuerza vertical concentrada que se desplazaba nodo a nodo siguiendo la tabla de posiciones del tren. El análisis se resolvió en dominio del tiempo con el integrador de Newmark, amortiguamiento de Rayleigh y paso de integración de un milisegundo, valor que garantizó la estabilidad numérica y capturó adecuadamente la respuesta del puente a través del modelo de elementos finitos Figura 2.4.




Figura 2.4 Vista del Modelo de Elementos Finitos

2.3. Análisis y validación de datos

Con las simulaciones completadas, el siguiente paso consistió en calibrar el modelo numérico. Para ello se recurrió a registros de sensores obtenidos durante años pasados. Las aceleraciones calculadas se superpusieron a sus homólogos registradas en el sistema de monitoreo.

Se proyectaron las deformaciones longitudinales que predijo el modelo en las secciones instrumentadas y se compararon con las que recogieron las galgas extensométricas. La discrepancia estadística se mantuvo por debajo de seis micro deformaciones, lo que llevo a validar el modelo como una representación fiel con la que experimentar niveles de daño que, por razones prácticas, no pueden inducirse en el puente real.

2.4. Simulación de escenarios de daño

Una vez verificada la estabilidad del modelo, se diseñó la matriz de simulaciones partiendo de las composiciones que circulan habitualmente sobre la línea. Se incluyeron cinco formaciones distintas: Class 220 de cuatro coches, Class 221 de cinco coches, Class 350 de cuatro coches y dos variantes del Class 390, una de nueve coches y otra de once Tabla 2.2. Cada tren se hizo pasar a tres velocidades representativas de 130, 140 y 170 km/h Tabla 2.3.

Tabla 2.2 Características de los trenes empleados en análisis numérico

Código	Clase de tren	Nro. de coches	Nro. de ejes
--------	---------------	----------------	--------------

T1	Clase 220 Voyager	4	16
T2	Clase 221 Super Voyager	5	20
T3	Clase 350 Desiro	4	16
T4	Clase 390 Pendolino	9	36
T5	Clase 390 Pendolino	11	44

Tabla 2.3 Velocidades representativas empleados en análisis numérico

Código	Velocidad
V1	130 km/h
V2	140 km/h
V3	170 km/h

En la superestructura se definieron dos zonas de deterioro de acuerdo con las zonas de mayor vulnerabilidad: una franja longitudinal en el ala inferior y otra de igual longitud en la parte central del alma de la viga oeste Tabla 2.4. En cada zona se aplicaron reducciones de módulo de elasticidad del 5%, del 10% y del 20%, además del estado sin daño Tabla 2.5. La combinación de cinco trenes, tres velocidades y cuatro estados estructurales produjo 105 casos individuales, 15 casos dañados y 90 casos no dañados según el esquema de configuraciones Figura 2.5. Todos se resolvieron con el mismo esquema de integración y generaron pares de señales de aceleración y deformación que sirvieron para explorar la sensibilidad de los parámetros autorregresivos y para fijar la longitud óptima de la ventana de análisis.

Tabla 2.4 Elementos dañados empleados en análisis numérico

Código	Elemento estructural	Localización
D0	-	-
D1	Viga principal (oeste)	Ala inferior
D2	Viga principal (oeste)	Alma

Tabla 2.5 Porcentajes de reducción de rigidez empleados en análisis numérico

Código	Reducción de rigidez
Dam0	0%
Dam1	5%
Dam2	10%
Dam3	20%




Figura 2.5 Esquema de configuración de parámetros para las simulaciones del Modelo Numérico

2.5. Implementación del algoritmo de detección de daños

La fase final trasladó la metodología de ML al contexto específico del puente. Se seleccionaron los cuatro acelerómetros que capturan la aceleración vertical en posiciones de 1m del apoyo inicial, a 1/4 de la distancia de la viga, 3/4 de la distancia de la viga, y 1 m del apoyo final, pues estos canales ofrecen la relación señal-ruido más alto durante el paso de los trenes.




Figura 2.6 Velocidades de trenes vs. Pesos totales de trenes simulados para escenarios no dañados




Figura 2.7 Velocidades de trenes vs. Pesos totales de trenes por tipo de tren

Además de las simulaciones realizadas anteriormente, se realizó un muestreo basado en las velocidades y peso total de los trenes registrado en el sistema de pesaje en movimiento Figura 2.6, con el fin de proveer al algoritmo de una mayor cantidad de casos sin daño que sirvan para el entrenamiento del modelo base y la obtención de la matriz de covarianza. Como se puede observar en los gráficos de dispersión para los diferentes tipos de tren de la Figura 2.7, se obtuvieron correlaciones promedio de entre 0.11 y 0.60, obteniendo 440 conjuntos con distribución marginal que capturan la aleatoriedad en las cargas operacionales, aún cuando los trenes son los mismos.

Tras haber realizado 440 simulaciones no dañadas, y 120 simulaciones dañadas adicionales, teniendo un total de 665 simulaciones, se extrajeron las características mediante el modelo MAR con los datos del segundo acelerómetro como datos de salida, con cuyos datos se definieron el 25% de los casos no dañados como datos de entrenamiento. Aplicando la normalización por el algoritmo de PCA, se calcularon las distancias de Mahalanobis MDs para cada simulación.

Con las MDs, se puede distinguir la diferencia entre datos dañados y no dañados, por lo que se puede emplear la matriz de disimilitud a través de los sensores y aplicar el algoritmo k-means con dos agrupamientos inicializados.



Capítulo 3




3. Resultados y análisis

3.1. Estimación de los modos

El análisis modal del modelo calibrado mostró que la respuesta del puente está dominada por modos flexionales verticales. El primer modo correspondió al pandeo vertical simétrico del vano con amplitudes máximas en el centro de luz, el segundo presentó una forma flexional antisimétrica con un nodo cercano a la mitad del vano, y el tercero mantuvo carácter flexional con mayor número de nodos y curvaturas Tabla 3.1. En términos cualitativos, estas formas coinciden con lo esperado para una viga continua con tablero colaborante y apoyos elásticos, lo que sugiere que las condiciones de borde implementadas en el modelo representan adecuadamente el comportamiento real.

Tabla 3.1 Modos de vibración y frecuencias naturales del modelo numérico

Modos		
#	Frecuencia natural (Hz)	Forma modal
1	4.095	
2	6.501	

3	9.425	
4	11.094	
5	12.512	

3.1.1. Estimación de la masa modal

La participación modal efectiva se evaluó a partir de los factores de participación y la matriz de masa del modelo. La mayor fracción de masa efectiva en dirección vertical se atribuyó al primer modo, mientras que el segundo y el tercero aportaron una porción menor pero necesaria para reproducir la envolvente de deformaciones bajo carga móvil. Esta distribución es consistente con estructuras de luz intermedia, donde el primer modo gobierna la respuesta cuasi estática amplificada por efectos dinámicos.

3.1.2. Valores modales

Las frecuencias naturales identificadas para los tres primeros modos se situaron, respectivamente, en torno a 4.095 Hz, 6.501 Hz y 9.425 Hz. Las figuras de deformadas asociadas

a estos modos reflejaron dominancia flexional vertical y ausencia de acoplamientos torsionales significativos en las primeras bandas. Estas cifras sirvieron de ancla para la verificación posterior con registros de campo y para fijar los anchos de banda de los filtros aplicados a las señales medidas.

3.1.3. *Discusión sobre los modos obtenidos*

La proximidad entre los valores modales simulados y las estimaciones derivadas de vibración ambiental sugiere que la rigidez equivalente del tablero y de los apoyos ha sido capturada con precisión suficiente. Las ligeras desviaciones detectadas en los modos 2 y 3 pueden atribuirse a incertidumbres en la rigidez transversal del tablero, a la contribución de las cargas, y a pequeños desajustes en el amortiguamiento equivalente. No obstante, al proyectar estos modos sobre la carga móvil, el conjunto reproduce adecuadamente el comportamiento observado durante el paso de trenes, lo que respalda su uso en la fase de validación.

3.2. Validación de modelo numérico

3.2.1. *Micro deformaciones*

La comparación entre las microdeformaciones medidas por las galgas y las estimadas por el modelo mostró una coincidencia estrecha en amplitud y fase durante todo el paso del tren. El FEM sin filtrar conservó picos de alta frecuencia vinculados a la discretización de ejes y a la rigidez numérica del esquema de integración, donde las curvas FEM filtradas se superpusieron a las mediciones, reproduciendo la meseta de esfuerzos cuando el tren ocupa el puente y la caída al abandonarlo. En la Figura 3.1 se aprecia que el modelo capta el crecimiento progresivo de deformación a medida que ingresan los coches y el relajamiento cuando el tren cruza el centro del vano, rasgo característico del comportamiento flexional tal y como se muestra en la Figura 3.2.




Figura 3.1 Deformación vs Tiempo de Viga Principal Oeste medidas en Sensor y Modelo de Elementos Finitos: (a) T3V1; (b) T3V2; (c) T3V3; (d) T5V1; (e) T5V2; (f) T5V3




Figura 3.2 Distribución de deformaciones en el tablero del puente

3.2.2. Aceleraciones

En los acelerómetros, el modelo reprodujo la envolvente y el espectro dominante del registro experimental. Las discrepancias puntuales en picos de corta duración se explican por irregularidades de vía y pequeñas asimetrías de los rieles no representadas explícitamente en la simulación. Tras el paso del último eje en la Figura 3.3, la vibración libre mostró una atenuación con frecuencia y tasa de decaimiento coherentes con el amortiguamiento equivalente adoptado para los casos con el tren T5, lo que confirma que la combinación de rigidez y amortiguamiento del modelo es consistente con la estructura real en el rango de interés.




Figura 3.3 Aceleración vs Tiempo de Viga Principal Oeste medidos en Sensor y Modelo de Elementos Finitos: (a) T3V1; (b) T3V2; (c) T3V3; (d) T5V1; (e) T5V2; (f) T5V3

3.2.3. Efectos de temperatura y humedad relativa

El análisis de sensibilidad ambiental de la Figura 3.4 evidenció una correlación negativa moderada entre la temperatura del acero y el desplazamiento máximo en el centro de vano en uno de los conjuntos de mediciones ($r \approx -0.61$), mientras que la humedad relativa mostró correlaciones positivas altas con el mismo indicador ($r \approx 0.88$ y $r \approx 0.97$ en distintos periodos). En otro conjunto, la relación con temperatura fue prácticamente nula ($r \approx -0.02$), lo que sugiere que la rigidez efectiva del sistema se ve más influida por la condición higrométrica que por la variación térmica dentro del rango observado.




Figura 3.4 Correlación entre desplazamiento medio máximo vertical del puente, y efectos de Temperatura y Humedad Relativa: (a) T3 a 130 km/h; (b) T5 a 130 km/h

Estas tendencias respaldan la decisión metodológica de normalizar las señales con variables ambientales y de incluir controles de varianza antes de declarar una anomalía. Además, resalta la importancia de incluir ciertas variables ambientales en futuros modelos numéricos.

3.3. Detección de daño

En esta sección se aplicó, de extremo a extremo, la estrategia no supervisada presentada en el marco metodológico. El conjunto de trabajo reunió las 665 simulaciones generadas con el modelo

numérico, cinco trenes, tres rangos de velocidad y cuatro estados estructurales que incluyen la condición sin daño y con daño por los cuatro acelerómetros verticales. A partir de los coeficientes se construyó un vector de características y se calculó la distancia de Mahalanobis frente a la distribución de referencia obtenida en estado sano. La Figura 3.5 se utilizó únicamente para visualizar la separación entre grupos de daño, reforzando la decisión identificar agrupamientos de datos con daño y sin daño.




Figura 3.5 Efectos de daño por variación de niveles de daño en el tiempo

3.3.1. Extracción de características

La elección del orden del modelo autorregresivo se hizo con datos de la condición sana para evitar que la presencia de daño sesgara la selección. La curva de precisión media creció con rapidez desde órdenes bajos y se estabilizó alrededor del orden 8, donde se observó un rendimiento sostenido cercano a 98% Figura 3.6. Optar por el orden 15 ofreció un equilibrio claro entre capacidad de ajuste y costo de cómputo, y además dio lugar a coeficientes estables entre pasadas de tipos de trenes con y sin daño. Además, dado al muestreo realizado y el cambio de velocidades y pesos de los trenes, se optó por clasificar los datos no dañados en rangos de velocidades que son VR1:[0 – 130 km/h], VR2:[131 km/h – 160 km/h], y VR3:[161 km/h – 200 km/h].




Figura 3.6 Precisión media para diferentes ordenes del modelo MAR

Una vez fijado el orden, se revisó cómo evolucionaban coeficientes concretos a medida que se introducían pérdidas de rigidez en el modelo, con lo cual se visualizó en la Figura 3.7 como las diferencias entre los parámetros dañados y no dañados fueron mínimas. En el sensor situado a 1/4 de la luz, varios parámetros mostraron un desplazamiento firme cuando el puente pasaba de sano a deteriorado. El cambio fue mínimo pero consistente con 5% de reducción de rigidez, aumentó de manera clara con 10% y terminó completamente separado del estado de referencia cuando la pérdida alcanzó 20% Figura 3.8. Lo más relevante es que el signo y la magnitud del cambio se mantuvieron con independencia del tipo de tren y del rango de velocidad, confirmando que el vector de coeficientes resume información que está verdaderamente ligada a la dinámica de la estructura y no a la composición de la carga que transita, reduciendo la incertidumbre por variabilidad operacional.




Figura 3.7 Parámetros MAR (A_d) en el sensor $d=2$ de la estructura para simulaciones en condición: (a) sin daño y (b) con daño




Figura 3.8 Parámetros MAR (A_d) en el sensor $d=2$ de la estructura para tres parametros representativos

3.3.2. Fusión de características

La distancia de Mahalanobis, calculada por sensor Figura 3.9, permitió medir de manera homogénea la coherencia de cada nueva observación con la nube de referencia. En el sensor de $\frac{1}{4}$ de la luz las distancias de las pasadas sanas se agruparon en un intervalo estrecho. Al introducir daño en las simulaciones, la mediana de las distancias aumentó y la dispersión creció de forma según el nivel de daño. En la Figura 3.10, representación mediante diagramas de cajas en los cuatro sensores confirmó que los puntos instrumentados en posiciones intermedias del vano resultan más sensibles que los cercanos a los apoyos, lo que encaja con la distribución de momentos en una viga simplemente apoyada con losa colaborante.




Figura 3.9 MDs mediante todas las simulaciones en el nodo d=2

Para asegurarnos de que la separación no dependía de una sola combinación de tren y velocidad, se construyó una matriz de disimilitud entre todas las simulaciones usando como métrica la distancia euclídea en el espacio de Mahalanobis. La figura correspondiente muestra bloques fríos bien definidos en los casos sanos y bandas cálidas cuando se agrupan simulaciones con daño, lo que indica que la señal del deterioro domina sobre las variaciones operativas. Esta lectura es coherente con el comportamiento observado en los coeficientes del modelo y explica por qué los umbrales estadísticos fijados con datos sanos se mantienen válidos cuando se combinan trenes y velocidades diferentes.




Figura 3.10 Diagrama de caja de todas las MDs en todos los sensores

3.3.3. Discriminación y agrupamiento de características

Con la fusión anterior se procedió al agrupamiento no supervisado. Se implementó un algoritmo de medias k con dos clústeres, inicializado con simulaciones sin daño. El resultado, proyectado mediante análisis de componentes principales, muestra dos conjuntos compactos y separados Figura 3.11. Esto resultó en que en el primer agrupamiento el 96.25% de los datos fueron identificados como dañados, mientras que en el agrupamiento 2 el 94.44% fueron identificados como datos no dañados.




Figura 3.11 Mapa de calor de disimilitudes entre simulaciones para modelo MAR de orden 15 con 4 nodos

Las disimilitudes residuales se concentraron en el deterioro leve, alrededor de 5%, y en combinaciones de tren y velocidad con menor nivel de excitación. Aun así, la tendencia cuando las simulaciones anómalas aparecen de forma continua, tiende a consolidarlo como un comportamiento nuevo y sostiene la alerta, que si, por el contrario, se presentan de manera aislada y no persisten, y mejora la coherencia de la nube Figura 3.12. Esta regla de persistencia, unida al uso de la distancia de Mahalanobis, reduce el riesgo de avisos causados por variaciones ambientales u operacionales.




Figura 3.12 Resultado de agrupaciones de los MDs después de la aplicación de K-means

En resumen, el flujo que va desde el modelo autorregresivo hasta el agrupamiento no supervisado permite distinguir la condición sin daño de las condiciones con daño medio y alto, mientras demuestra ser estable frente a cambios de composición de tren y de velocidad. Debido a ello, el sistema puede operar en línea con latencias del orden de segundos y entregar un indicador claro y trazable sobre el estado dinámico del puente.

3.4. Aplicaciones a la industria de hidrocarburos

Los métodos actuales de SHM basados en datos de sensores se adaptan a las redes de oleoductos y vías ferroviarias de vagones cisternas, donde la prevención de derrames es vital. Estudios recientes muestran que los modelos de aprendizaje no supervisados pueden aprender las señales de datos relacionados con la corrosión o fugas, lo que mejora la detección temprana en comparación con un mantenimiento basado en riesgo a gran escala (Moreira de Aguiar et al., 2025).

En el caso del transporte ferroviario de hidrocarburos, la exposición a los hidrocarburos altera el comportamiento mecánico de los componentes elastoméricos de la vía, lo que puede tener efectos de degradación, lo que motiva al seguimiento continuo en lugar de inspecciones visuales (Sainz-Aja et al., 2024). Detectar esos cambios de forma temprana puede ayudar a evitar descarrilamientos y prolonga la vida útil de los componentes.

Capítulo 4

4. Conclusiones y recomendaciones

4.1. Conclusiones

- El modelo de elementos finitos captura satisfactoriamente el comportamiento estructural del puente ferroviario frente a cargas de trenes a alta velocidad, lo cual demuestra la validez de los resultados de simulaciones frente a los datos recolectados por los sensores instalados en el puente.
- El modelado MAR generó ajustes consistentes en la condición sin daño. La precisión media ($1 - \text{NRMSE}$) crece rápido con el orden y se estabiliza alrededor de 97–98 % para p mayor o igual a 5, lo que sugiere rendimientos decrecientes al aumentar más los retardos.
- Los parámetros del MAR por sensor muestran patrones coherentes entre velocidades y niveles de daño. Al construir la línea base con simulaciones indemnes y calcular distancias de Mahalanobis (MD), los valores en escala log separan con claridad las simulaciones dañadas: los gráficos de cajas por sensor sitúan las medianas dañadas varios órdenes de magnitud por encima de las indemnes, y el gráfico a lo largo de las simulaciones evidencia la transición entre ambos grupos.
- Al agrupar cada simulación por su vector de MDs, K-means encontró de forma no supervisada dos agrupaciones que, al confrontarlos con los metadatos, corresponden a no dañados vs dañados con solapamiento alrededor del 5%. La matriz de disimilitudes confirma además que ciertos sensores son más discriminativos y que, con más agrupaciones, es posible perfilar subgrupos por severidad de daño.

4.2. Recomendaciones

- Incluir en el análisis las variables ambientales y operativas, con el fin de aplicar una detección más robusta frente a variaciones en los datos recolectados por sensores.
- Aumentar el número de simulaciones con y sin daño, además del número de trenes, con el fin de entrenar mejor al modelo, e incrementar el porcentaje de efectividad del algoritmo.

- Extender las agrupaciones con el método k-means con el fin de identificar agrupamientos de daños según su severidad y tipo de elementos dañados.
- Revisar centroides por sensor para entender qué canales aportan más y planificar el mantenimiento de sensores menos informativos o ruidosos.
- Implementar el algoritmo con los sensores de deformación para validar la efectividad y diferencias con respecto a la aplicación con los acelerómetros.

Referencias

- Anastasia, S., García-Macías, E., Ubertini, F., Gattulli, V., & Ivorra, S. (2023). Damage Identification of Railway Bridges through Temporal Autoregressive Modeling. *Sensors*, 23(21). <https://doi.org/10.3390/s23218830>
- Bell, B., & Rail, N. (2004). European railway bridge demography. *European FP*, 6.
- Benn, J. (2013). Railway bridge failure during flooding in the UK and Ireland. *Proceedings of the Institution of Civil Engineers - Forensic Engineering*, 166(4), 163–170. <https://doi.org/10.1680/feng.2013.166.4.163>
- Bouzenad, A. E., El Mountassir, M., Yaacoubi, S., Dahmene, F., Koabaz, M., Buchheit, L., & Ke, W. (2019). A Semi-Supervised Based K-Means Algorithm for Optimal Guided Waves Structural Health Monitoring: A Case Study. *Inventions*, 4(1). <https://doi.org/10.3390/inventions4010017>
- Duzgun, A., A, R. J., R, M. J., & R, L. I. (2016). Comparison of Visual Inspection and Structural-Health Monitoring As Bridge Condition Assessment Methods. *Journal of Performance of Constructed Facilities*, 30(3), 04015049. [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000802](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000802)
- Eltouny, K., Gomaa, M., & Liang, X. (2023). Unsupervised Learning Methods for Data-Driven Vibration-Based Structural Health Monitoring: A Review. *Sensors*, 23(6). <https://doi.org/10.3390/s23063290>
- Entezami, A., Sarmadi, H., & Behkamal, B. (2023). Long-term health monitoring of concrete and steel bridges under large and missing data by unsupervised meta learning. *Engineering Structures*, 279, 115616. <https://doi.org/https://doi.org/10.1016/j.engstruct.2023.115616>
- Imam, B., & Salter, P. A. (2017). Historical load effects on fatigue of metallic railway bridges. *Proceedings of the Institution of Civil Engineers - Bridge Engineering*, 171(1), 49–62. <https://doi.org/10.1680/jbren.15.00046>
- Ison, S., Frost, M., & Watson, R. (2012). UK rail transport: a review of demand and supply. *Proceedings of the Institution of Civil Engineers - Transport*, 165(3), 225–234. <https://doi.org/10.1680/tran.10.00028>
- Knapcikova, L., & Konings, R. (2018). European railway infrastructure: A review. *Acta Logistica*, 5(3), 71–77.
- Meixedo, A., Santos, J., Ribeiro, D., Calçada, R., & Todd, M. D. (2022). Online unsupervised detection of structural changes using train-induced dynamic responses. *Mechanical Systems*

- and *Signal Processing*, 165, 108268.
<https://doi.org/https://doi.org/10.1016/j.ymssp.2021.108268>
- Moreira de Aguiar, Filipe, de Abreu Corrêa, Lúcio, Tormen Haan de Oliveira, Henrique, Gabriel Rosauo Clarke, Thomas, & Endress Ramos, Julio. (2025). Data-driven structural health monitoring for early corrosion detection in the oil and gas pipelines: enhancing sensitivity with unsupervised dimensionality reduction. *Structural Health Monitoring*, 14759217251326600. <https://doi.org/10.1177/14759217251326601>
- Quiroz, M., A Ponnusami, S., & Bravo-Haro, M. (2025). *Data-Driven Damage Detection on Offshore Wind Turbines Structures Subjected to Environmental and Operational Conditions*.
- Rainieri, C., Notarangelo, M. A., & Fabbrocino, G. (2020). Experiences of Dynamic Identification and Monitoring of Bridges in Serviceability Conditions and after Hazardous Events. *Infrastructures*, 5(10). <https://doi.org/10.3390/infrastructures5100086>
- Sainz-Aja, J. A., Carrascal, I. A., Ferreño, D., Casado, J., Diego, S., Pombo, J., & Rivas, I. (2024). Impact of hydrocarbon exposure on the mechanical properties of rail pads. *Construction and Building Materials*, 419, 135561.
<https://doi.org/https://doi.org/10.1016/j.conbuildmat.2024.135561>
- Silva, Moisés, Santos, Adam, Santos, Reginaldo, Figueiredo, Eloi, Sales, Claudomiro, & Costa, João C W A. (2018). Deep principal component analysis: An enhanced approach for structural damage identification. *Structural Health Monitoring*, 18(5–6), 1444–1463.
<https://doi.org/10.1177/1475921718799070>
- Worden, K., & Cross, E. J. (2018). On switching response surface models, with applications to the structural health monitoring of bridges. *Mechanical Systems and Signal Processing*, 98, 139–156. <https://doi.org/https://doi.org/10.1016/j.ymssp.2017.04.022>
- Ye, C., Kuok, S.-C., Butler, L. J., & Middleton, C. R. (2022). Implementing bridge model updating for operation and maintenance purposes: examination based on UK practitioners' views. *Structure and Infrastructure Engineering*, 18(12), 1638–1657.
<https://doi.org/10.1080/15732479.2021.1914115>
- Zhou, Y.-L., Figueiredo, E., Maia, N., Sampaio, R., & Perera, R. (2015). Damage detection in structures using a transmissibility-based Mahalanobis distance. *Structural Control and Health Monitoring*, 22(10), 1209–1222.