

Análisis de sensibilidad de métodos no paramétricos de detección de daño en puentes

José Manuel Machorro López Jesús Joaquín Yáñez Borjas Martín Valtierra Rodríguez Juan Pablo Amézquita Sánchez Francisco Javier Carrión Viramontes David Camarena Martínez Héctor Miguel Gasca Zamora Jorge Alberto Hernández Figueroa Miguel Anaya Díaz Juan Antonio Quintana Rodríguez Luis Álvaro Martínez Trujano Germán Michel Guzmán Acevedo

> Publicación Técnica No. 665 Sanfandila, Qro. 2022

> > ISSN 0188-7297

Esta investigación es el producto final del proyecto de investigación interna El 06/21 *Análisis de sensibilidad de métodos no paramétricos de detección de daño en estructuras* y fue realizada en la Coordinación de Ingeniería Vehicular e Integridad Estructural del Instituto Mexicano del Transporte en colaboración con el Departamento de Ingeniería Electromecánica de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro campus San Juan del Río y con la División de Ingenierías campus Irapuato-Salamanca de la Universidad de Guanajuato. Por parte del Instituto Mexicano del Transporte participaron en su desarrollo: José Manuel Machorro López, Francisco Javier Carrión Viramontes, Héctor Miguel Gasca Zamora, Jorge Alberto Hernández Figueroa, Miguel Anaya Díaz, Juan Antonio Quintana Rodríguez, Luis Álvaro Martínez Trujano y Germán Michel Guzmán Acevedo; por la Universidad Autónoma de Querétaro: Martín Valtierra Rodríguez y Juan Pablo Amézquita Sánchez; y por la Universidad de Guanajuato: Jesús Joaquín Yáñez Borjas y David Camarena Martínez.

Se reconoce y agradece el apoyo del Consejo Nacional de Ciencia y Tecnología (CONACYT) a través del Proyecto No. 34/2018 del Programa "Investigadoras e Investigadores por México" del CONACYT; así como la colaboración de los investigadores del *Engineering Applications Research Group* (ENAP-RG) de la Universidad Autónoma de Querétaro campus San Juan del Río y del CA Procesamiento Digital de Señales de la Universidad de Guanajuato.

Contenido

| ~ ′ | | | |
|------------|----------|------|---|
| Pα | 21 | ins | ב |
| a | M | 1110 | 7 |

| Índice de figuras | iii |
|---------------------------------------------------|-----|
| Índice de tablas | v |
| Sinopsis | vii |
| Abstract | ix |
| Resumen ejecutivo | xi |
| Introducción | 1 |
| 1 Descripción del Puente Río Papaloapan | 5 |
| 2 Método STF-PCA-MD | 9 |
| 2.1 Metodología | 9 |
| 2.2 Configuración experimental | 17 |
| 2.3 Resultados y discusión | 19 |
| 2.4 Conclusiones parciales | 28 |
| 3 Método de acumulación de energía wavelet (MAEW) | 31 |
| 3.1 Metodología | 31 |
| 3.2 Resultados y discusión | 32 |
| 3.3 Conclusiones parciales | 35 |
| 4 Análisis y discusión de resultados | 37 |
| Conclusiones generales | 39 |
| Bibliografía | 41 |

Índice de figuras

Página

| Figura 0.1 | Colapso del Cypress Street Viaduct en California, EUA el 17 de octubre de 1989 | 1 |
|------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1.1 | Fotografías del Puente Río Papaloapan | 5 |
| Figura 1.2 | Dibujo del PRP mostrando dimensiones generales e identificación de semiarpas | 6 |
| Figura 1.3 | Diseño de ensamble del sistema de anclaje superior: (a) diseño general y (b) ensamble antes de la instalación | 6 |
| Figura 1.4 | Falla en elemento de anclaje del tirante 1 semiarpa 5 (T1S5) | 7 |
| Figura 1.5 | Diagrama de distribución de sensores colocados en el PRP | 8 |
| Figura 2.1 | Distribución de datos resultantes de la prueba KWT para: (a) modo, (b) mediana, (c) rango, (d) RMS, (e) μ , (f) σ 2, (g) σ , (h) asimetría, (i) kurtosis, (j) 5M, (k) 6M, (l) SFRMS, (m) CF, (n) IF y (o) LF, para condición sana (<i>Healthy</i>) y de daño (<i>Damage</i>) | 12 |
| Figura 2.2 | Ubicación de los sensores utilizados para monitorear el comportamiento dinámico del puente (sensores: S1-S12; semiarpas: SH3-SH6) | 17 |
| Figura 2.3 | Tirante removido para generar la condición de daño: (a) condición real y (b) esquemática | 18 |
| Figura 2.4 | Acelerómetro colocado en el tablero del puente aguas arriba y adquiriendo datos con tránsito bajo condiciones de operación normal | 18 |
| Figura 2.5 | Respuestas dinámicas para la condición sana correspondientes a los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12 | 19 |
| Figura 2.6 | Respuestas dinámicas para la condición dañada correspondientes a los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12 | 20 |
| Figura 2.7 | Señales ACF de la condición sana para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12 | 21 |

- Figura 2.8 Señales ACF de la condición dañada para los sensores: (a) 22 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12
- Figura 2.9 Modelos de entrenamiento basados en PCA para los 23 sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12
- Figura 2.10 Modelos de validación basados en PCA de la condición 24 sana para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12
- Figura 2.11 Modelos de validación basados en PCA de la condición 25 dañada para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12
- Figura 2.12 Resultados de valores DI en los 12 sensores para: (a) 27 condición sana y (b) condición de daño
- Figura 3.1 Diagramas CWT a partir de las señales experimentales 33 filtradas de puente sano para el área de interés: (a) mostrando la escala en el eje vertical y (b) mostrando los coeficientes en el eje vertical. Tres diferentes posiciones de medición para cada caso (de arriba a abajo: R1, R2 y R4)
- Figura 3.2 Diagramas CWT a partir de las señales experimentales 33 filtradas de puente con tirante dañado T1S5 para el área de interés: (a) mostrando la escala en el eje vertical y (b) mostrando los coeficientes en el eje vertical. Tres diferentes posiciones de medición para cada caso (de arriba a abajo: R1, R2 y R4)
- Figura 3.3 Diagrama CWT a partir de la señal experimental filtrada de 34 la posición de medición R2 alrededor del momento del colapso del tirante T1S5: (a) mostrando la escala en el eje vertical y (b) mostrando los coeficientes en el eje vertical
- Figura 3.4 EW total a partir de las señales experimentales filtradas 34 para: (a) puente sano y (b) puente con tirante dañado T1S5. Tres diferentes posiciones de medición para cada caso (de arriba a abajo: R1, R2 y R4)
- Figura 3.5 EW total promedio a partir de las señales experimentales 35 filtradas para puente sano vs. puente con tirante dañado T1S5

Página

| Tabla 2.1 | Valores de probabilidad obtenidos de la prueba KWT | 11 |
|-----------|-----------------------------------------------------------------------------------------------------------|----|
| Tabla 2.2 | Indicadores obtenidos para pruebas de condición sana y de daño | 26 |
| Tabla 2.3 | Resultados del sensor 5 usando la metodología propuesta en base al estado de salud y condición de daño | 27 |
| Tabla 4.1 | Comparación del método STF-PCA-MD y MAEW | 37 |

Sinopsis

utilizan ampliamente en todo el mundo; Los puentes vehiculares se desafortunadamente estas estructuras están expuestas a condiciones adversas que pueden provocar deterioro y, en consecuencia, colapsos. En esta publicación se analiza la sensibilidad de dos métodos no paramétricos de detección daño en puentes usando datos del monitoreo del Puente Río Papaloapan (PRP): (1) El método STF-PCA-MD, el cual se desarrolló para identificar la ausencia de un tirante en el PRP durante trabajos de mantenimiento. Este método se basa en la extracción de un conjunto de características estadísticas de tiempo (STF) a partir de señales de vibración; posteriormente, se calculan los modelos basados en análisis de componentes principales (PCA) para mejorar la localización de daño y se propone un índice de daño basado en la distancia Mahalanobis (MD) para indicar si existe daño y su ubicación. (2) El método de acumulación de energía wavelet (MAEW) previamente desarrollado y aplicado para detectar un tirante dañado/colapsado en el PRP. A pesar del gran reto para identificar ambos escenarios de daño con técnicas basadas en monitoreo de vibraciones/deformaciones. la aplicación de ambos métodos fue exitosa, por lo que se pueden considerar como alternativas prometedoras para identificar daño en puentes debido a su gran sensibilidad.

Abstract

Vehicular bridges are widely used all around the world; unfortunately, these structures are exposed to adverse conditions that may cause deterioration and, consequently, collapses. This publication analyzes the sensitivity of two nonparametric methods for detecting damage in bridges using data from the monitoring of the Rio Papaloapan Bridge (RPB): (1) The STF-PCA-MD method, which was developed to identify the absence of a cable in the RPB during maintenance works. This method is based on the extraction of a set of statistical time features (STFs) from vibration signals; then, principal component analysis (PCA)-based models are computed to improve the damage location and a damage index based on the Mahalanobis distance (MD) is proposed to indicate if a damage exists and its location. (2) The wavelet energy accumulation method (WEAM) previously developed and applied to detect a damaged/collapsed cable in the RPB. Despite the great challenge to identify both damage scenarios with techniques based on vibrations/deformations monitoring, the application of both methods was successful, therefore they can be considered as promising alternatives to identify damage in bridges due to their great sensitivity.

Resumen ejecutivo

Los puentes atirantados se encuentran entre las estructuras civiles más vulnerables a sufrir diversos tipos de daño debido a sus elementos críticos que los componen y a las condiciones exigentes de operación; en este sentido, los tirantes son elementos estructurales críticos que se deben inspeccionar detalladamente, y cualquier tipo de daño o defecto se debe detectar y localizar a tiempo para evitar derrumbes de puentes y tragedias que provoquen pérdidas humanas y económicas. Por tanto, la investigación realizada y presentada en esta publicación se enfoca en evaluar métodos de detección de daño que contribuyan a identificar problemas en estos elementos estructurales de manera oportuna.

Los métodos basados en el monitoreo y posprocesamiento de señales de vibraciones se consideran actualmente como los más prometedores y eficientes para identificar daño en estructuras civiles sin la necesidad de tener que interrumpir la operación de esas construcciones, y de forma general se clasifican en métodos paramétricos y no paramétricos. Los métodos paramétricos trabajan con datos en el dominio modal, mientras que los métodos no paramétricos utilizan datos en el dominio del tiempo o de la frecuencia.

Existe una tendencia que indica que los métodos paramétricos cada vez se usan menos, en gran medida debido a sus desventajas que incluyen la pérdida de gran parte de la información, los errores numéricos provocados por un ajuste de curva inexacto y la sensibilidad al ruido.

Por tanto, en este trabajo se aplican y analizan dos métodos no paramétricos desarrollados para detectar y localizar dos escenarios reales de daño relacionados con pérdidas de diferentes tirantes en el Puente Río Papaloapan (PRP), lo cual representa un gran reto debido a que por el diseño/construcción de este puente, los métodos deben tener sensibilidad suficiente para ser capaces de identificar daño a partir de los datos del sistema de monitoreo instalado en el puente.

El primer método, llamado método STF-PCA-MD, se desarrolló para identificar la ausencia de un tirante en el PRP y se basa en la obtención de un conjunto de características estadísticas de tiempo (STF) a partir de los datos de vibración del puente, usando la función de autocorrelación (ACF) para eliminar ruido y fortalecer los patrones que se encuentran en ellas; posteriormente, se utiliza el análisis de componentes principales (PCA) para obtener modelos, basados en las STF definidas, a fin de mejorar el proceso de identificación de daño y; finalmente, se propone un índice de daño basado en la distancia de Mahalanobis (MD) para establecer si existe daño y su ubicación.

El segundo método, nombrado método de acumulación de energía *wavelet* (MAEW), que se desarrolló y presentó previamente en el año 2020, se retoma para ser comparado con el método STF-PCA-MD; para ello, el MAEW se orienta en este caso para poder analizar su sensibilidad al aplicarlo en un caso real de accidente en el PRP ocasionado por un tirante dañado que colapsó.

Ambos métodos resultaron ser lo suficientemente sensibles, ya que la aplicación de ellos fue exitosa para identificar los escenarios de daño presentados en el PRP; por tanto, son métodos promisorios que tienen el potencial para ser utilizados inicialmente de forma simultánea a fin de asegurar la detección y localización de tirantes dañados en puentes atirantados y reducir el número de falsas alarmas. Asimismo, cabe destacar que estos métodos tienen la ventaja, sobre otros métodos, de ser de bajo costo y que se probaron en un puente real, identificando uno de los tipos de daño más peligrosos de forma eficiente y con gran precisión.

Introducción

Como cualquier estructura civil, los puentes vehiculares están diariamente expuestos a vibraciones ambientales causadas por terremotos, viento, tránsito, etc., generando deterioros inevitables y daños en sus elementos, los cuales deben detectarse y corregirse a tiempo para evitar el colapso de dichas construcciones con las correspondientes devastadoras pérdidas humanas y económicas, como ha ocurrido en muchos países a lo largo de la historia [1-8]. Por ejemplo, el 15 de diciembre de 1967, el puente Silver Bridge se derrumbó en Ohio, EUA durante la hora de mayor tráfico vehicular, matando a 46 personas [5]. El 5 de abril de 1987 colapsó el puente Schoharie Creek Bridge en Nueva York, EUA, provocando la muerte de 10 personas [8]. El 17 de octubre de 1989, una gran parte del Cypress Street Viaduct en California, EUA colapsó durante un terremoto, debido al movimiento del suelo y defectos estructurales que no se detectaron previamente, causando la muerte de 42 personas [8], ver figura 0.1. Por ello, la implementación de un método de gran sensibilidad para detectar y localizar la existencia de cualquier defecto peligroso en las primeras etapas (intensidad incipiente) es de vital importancia para asegurar la integridad de las estructuras de ingeniería y evitar potenciales catástrofes.



Figura 0.1. Colapso del Cypress Street Viaduct en California, EUA el 17 de octubre de 1989.

En las últimas décadas, se han propuesto en la literatura diversas estrategias SHM (*Structural Health Monitoring*) para estructuras civiles basadas en el análisis de las respuestas vibratorias para la detección de daño, usando para ello sus parámetros globales (métodos paramétricos) [9–13]. Estas estrategias emplean los parámetros modales de las estructuras (es decir, frecuencias naturales, formas modales, relaciones de amortiguamiento, etc.) y sus derivados o índices de daño (por ejemplo, criterio de aseguramiento modal, factor de escala modal, criterio de desplazamiento-frecuencia, energía de deformación, curvatura de la forma modal, etc.) para evaluar el estado de salud [14–25]. Estas técnicas han mostrado algunos

resultados promisorios para determinar la condición de las estructuras; sin embargo, son susceptibles a las condiciones ambientales (es decir, temperatura, humedad, etc.) y generalmente requieren de un modelo matemático robusto de la estructura civil, lo cual es una tarea desafiante [2,26–28]. Para reducir estas limitaciones, los métodos no paramétricos o métodos modernos; es decir, los métodos basados en la transformada de ondeleta (*wavelet transform*, WT), descomposición de modo empírico (*empirical mode decomposition*, EMD), modelos de series de tiempo (*time series models*, TSM), clasificación de señal múltiple (*multiple signal classification*, MUSIC), índice de entropía de Shannon (Shannon *entropy index*, SEI), redes neuronales (*neural networks*, NN), dimensión fractal (*fractal dimension*, FD), análisis de componentes principales (*principal component analysis*, PCA), etc. se han empleado para evaluar el estado de salud de las estructuras civiles [29–82].

En particular, los métodos basados en WT, como la transformada *wavelet* continua, discreta y sincronizada, son herramientas adecuadas para identificar singularidades en las señales de tiempo [29–41], que se pueden asociar a la condición de la estructura [2,38]. Para evaluar correctamente el estado estructural, estos métodos requieren un proceso de prueba y error para encontrar la onda madre más conveniente para cada aplicación, así como la selección adecuada del rango de escala para aumentar la evidencia de daño; además, es necesario eliminar los efectos de borde mediante el uso de técnicas de extensión de señal, ya que éstos producen altos coeficientes *wavelet* al principio y al final de cualquier señal debido a las discontinuidades inherentes en estas partes de la propia señal y que se pueden interpretar como daño [2,39].

Por otro lado, los métodos basados en EMD se utilizan para descomponer la señal de tiempo en sus componentes principales, los cuales están destinados a extraer picos de daño provocados por cambios repentinos de rigidez estructural a partir de los datos medidos [28,42–45]. A pesar de esta ventaja, los métodos basados en EMD presentan algunas desventajas para evaluar correctamente la condición estructural, una de ellas es el efecto llamado "mezcla de modos" (componentes de frecuencia que se mezclan en diferentes bandas de frecuencia), lo que limita encontrar patrones característicos adecuados para evaluar la condición de la estructura; mientras que la otra desventaja es la cantidad de carga computacional que depende de la técnica EMD seleccionada [28,46,47].

Los métodos basados en TSM (representados por el método de la familia *Auto-Regressive* (AR), como los modelos AR o *Auto-Regressive Moving Average* (ARMA), entre otros) dependen de conceptos estadísticos bien establecidos en vez de la experiencia humana para extraer patrones característicos que cambian con el inicio del daño, lo que elimina posibles prejuicios individuales y requieren pocas suposiciones sobre la estructura física [28,48–51]. Estos métodos son de uso directo con las respuestas en el dominio del tiempo, eliminan la necesidad de realizar transformaciones de frecuencia y no tienen errores asociados como fugas y truncamiento; no obstante, presentan complicaciones para interpretar la información de la señal y evaluar correctamente los comportamientos no lineales de las estructuras medidas por los sensores, requieren la adecuada selección del orden y

son susceptibles a efectos de ruido, lo que complica la correcta estimación del estado de la estructura [28].

Los métodos MUSIC se desarrollan con algoritmos basados en el sub-espacio, manipulando señales de tiempo ruidosas para determinar sus componentes de frecuencia. Estos métodos muestran una mayor detectabilidad de frecuencias de amplitud débil; además, requieren de una alta carga computacional y la selección adecuada del orden para evaluar correctamente el estado de salud de una estructura civil [52–54].

En los últimos años, la entropía de Shannon, que es una medida no lineal, se ha utilizado para diagnosticar: (a) enfermedades [55,56], (b) sistemas eléctricos [57,58], (c) el estado de salud de estructuras y modelos académicos [59,60], entre otras aplicaciones. La entropía de Shannon mide la incertidumbre en una variable aleatoria; en otras palabras, el SEI provee una medida de la cantidad de información contenida en la ocurrencia de un evento [61]. Por lo tanto, el SEI es una medida confiable para detectar y localizar daño en una estructura civil, ya que las señales adquiridas cambian de acuerdo con el nivel de daño y su ubicación, produciendo una variación en el valor de la entropía de Shannon [59,60,62–66].

Por otra parte, los métodos basados en NN combinan la extracción y clasificación de patrones característicos en un solo esquema de aprendizaje, evitando la necesidad de establecer una relación exhaustiva entre los patrones/clasificadores discriminatorios y las condiciones de salud de los sistemas [67,68]. Debido a esta ventaja, se han empleado en variadas aplicaciones, incluyendo la identificación de daño en vigas, muros y otros elementos estructurales [69–73].

Asimismo, los métodos basados en FD han demostrado ser competentes para identificar patrones en diversas aplicaciones, incluido el monitoreo de la integridad de diversas estructuras [74,75]. FD proporciona una medida de la complejidad geométrica de una señal, lo que la convierte en una herramienta útil para evaluar la condición de una estructura civil, ya que cualquier daño en la estructura modificará el contenido de frecuencia y, por lo tanto, la complejidad geométrica de la señal.

Finalmente, los métodos basados en PCA [76] han sido ampliamente adoptados para detectar daño en elementos estructurales utilizando los datos obtenidos de los sistemas SHM [77–79]. Con la técnica de descomposición ortogonal, PCA es adecuado para establecer el modelo estadístico base (patrón o *baseline*) usando los datos medidos de las estructuras en condiciones sanas, y luego, la condición dañada se puede detectar utilizando las técnicas de reconocimiento de patrones [80,81]. Además, los métodos PCA requieren un proceso de cálculo simple, por lo que también se han implementado para detectar daño en estructuras bajo temperaturas ambientales cambiantes como los puentes vehiculares [82].

En la presente publicación se presentan, analizan y comparan dos métodos no paramétricos de identificación de daño en puentes, los cuales fueron desarrollados para tener suficiente sensibilidad a fin de identificar los escenarios de daño presentados en el puente seleccionado y estudiado para este trabajo (PRP), a partir del posprocesamiento de los correspondientes datos del sistema de monitoreo de vibraciones/deformaciones.

Primero, en el capítulo 1, se presenta la descripción del puente utilizado para el desarrollo y aplicación de los dos métodos no paramétricos de detección de daño propuestos, el cual es el puente atirantado Puente Río Papaloapan (PRP). Posteriormente, en el capítulo 2, se presenta de manera detallada el nuevo método STF-PCA-MD y su aplicación, dicho método se desarrolló para identificar la ausencia de un tirante en el PRP, el cual fue removido durante trabajos de mantenimiento. Asimismo, en el capítulo 3, se da seguimiento al método de acumulación de energía *wavelet* (MAEW) previamente desarrollado [35] y aplicado para detectar un tirante dañado/colapsado en el PRP, con la finalidad de compararlo con el nuevo métodos STF-PCA-MD. Finalmente, en el capítulo 4 se presenta la comparación de los métodos de detección de daño mencionados; analizando la sensibilidad de cada uno, tipos de daño incluidos, ventajas y desventajas. De tal manera que esta comparativa permita determinar si se pueden usar como métodos redundantes o complementarios para incrementar la eficiencia en la identificación de daño y aumentar así la confiabilidad en el uso de los puentes.

1. Descripción del Puente Río Papaloapan

El Puente Río Papaloapan (PRP) es un puente atirantado construido en 1994 y se encuentra ubicado en el Estado de Veracruz, México (ver figura 1.1). Tiene una longitud total de 407.21 m y un claro principal de 203 m, con 112 tirantes distribuidos en 8 semiarpas indicadas con la nomenclatura SH en la figura 1.2. Cada semiarpa está constituida por 14 tirantes, siendo el primer tirante, identificado con el número 1, el más corto; y el último tirante, identificado con el número 14, el más largo. Con el fin de anclar los tirantes en las torres se utilizan sistemas de anclaje superior, cuyo diseño consiste en una placa de acero soldada a los elementos de anclaje, los cuales son cilíndricos por un lado y planos por el lado soldado (ver figura 1.3). El lado cilíndrico está roscado para atornillar el collar que sujeta el tirante en la parte superior [83].



Figura 1.1. Fotografías del Puente Río Papaloapan.



Figura 1.2. Dibujo del PRP mostrando dimensiones generales e identificación de semiarpas.



Figura 1.3. Diseño de ensamble del sistema de anclaje superior: (a) diseño general y (b) ensamble antes de la instalación.

Este puente, hasta ahora, ha tenido dos fallas principales en los elementos de anclaje superior. El primer accidente ocurrió en enero de 2000, cuando el tirante T11S7 (correspondiente al tirante 11 de la semiarpa7) colapsó debido a deficiencias microestructurales del acero usado para fabricar el elemento de anclaje superior. A pesar de que el acero satisfacía la resistencia de diseño solicitada, un proceso de fundición deficiente resultó en un material frágil de baja tenacidad con una microestructura de gran tamaño de grano (ASTM 2) y un alto contenido de poros e inclusiones [84,85]. En este caso, los defectos en la zona afectada por el calor crecieron debido a la fatiga hasta la fractura completa [86]. Desafortunadamente, ningún sistema SHM estaba implementado cuando ocurrió este accidente.

La segunda falla ocurrió el 10 de junio de 2015. En este caso, tuvo lugar en la interfaz de soldadura entre el elemento de anclaje y la placa de acero del tirante T1S5 (correspondiente al tirante 1 de la semiarpa 5). Los análisis mostraron que una grieta inicial creció debido a la fatiga hasta que alcanzó un tamaño de casi el

65% del área de la sección transversal. En la figura 1.4 se pueden identificar claramente dos zonas diferentes; en la primera, que es característica del crecimiento por fatiga, se presentó oxidación en su superficie después de la falla, lo que indica que hubo tiempo suficiente para filtrar agua dentro de la grieta. La segunda, típica de la fractura dúctil, correspondió a la ruptura final por sobrecarga [87].



Figura 1.4. Falla en elemento de anclaje del tirante 1 semiarpa 5 (T1S5).

Después de la primera falla del puente, se instaló en 2013 un sistema SHM de alcance completo y el PRP se convirtió en el primer puente atirantado en México con un sistema de monitoreo remoto. El diseño del sistema se basó en sensores FBG (*Fiber Bragg Grating*) y se configuró en tres subsistemas: sensores, monitoreo local y fotovoltaico.

El subsistema de sensores se compone de 24 sensores de deformación, 24 acelerómetros, un sensor de desplazamiento, ocho sensores de inclinación y cinco sensores de temperatura, todos FBG; el subsistema de monitoreo local incluye un interrogador FO, un multiplexor y una computadora; y el subsistema fotovoltaico tiene 96 celdas solares, 36 baterías de ciclo profundo y sus controladores. Además, el sistema SHM incluye dos cámaras de video, una estación meteorológica y una estación sismológica. El sistema SHM se comunica vía satélite al Instituto Mexicano del Transporte.

Los sensores se distribuyeron para analizar la dinámica del tablero del puente y de las cuatro torres; así, 10 galgas extensométricas están ubicadas debajo de cada una de las vigas principales del tablero del puente, y una en el costado a media altura de cada torre. En la parte superior de cada una de las cuatro torres, se encuentran dos sensores de inclinación y dos acelerómetros. Los otros 16 acelerómetros se colocaron a la mitad de los tirantes 4 y 11 de cada semiarpa (figura 1.5).



Figura 1.5. Diagrama de distribución de sensores colocados en el PRP.

Aunque el sistema completo SHM descrito anteriormente estaba funcionando en el puente antes de que ocurriera la segunda falla, el daño no se detectó. Desde que se implementó el sistema SHM, se ha llevado a cabo un seguimiento histórico detallado de los valores de los parámetros típicos, tales como frecuencias naturales, formas modales, deformaciones, inclinaciones y tensión de los tirantes; sin embargo, ninguno de ellos tuvo variaciones anormales para advertir que había un elemento importante dañado.

Por lo tanto, en este trabajo se estudian métodos modernos (no paramétricos) de detección y localización de daño aplicados en un puente atirantado (PRP), los cuales se desarrollaron para contar con la suficiente sensibilidad que permita identificar daño/ausencia de tirantes en dicho puente y, poder así, evitar colapsos de este tipo de estructuras, con las correspondientes fatalidades humanas y millonarias pérdidas económicas que causan estas tragedias.

2. Método STF-PCA-MD

Las técnicas de monitoreo de la salud estructural basadas en vibraciones se han convertido en las alternativas más prometedoras para detectar y localizar daño de manera eficiente en las estructuras civiles. Por tanto, se desarrolló el método STF-PCA-MD, el cual es un método no paramétrico basado en características estadísticas de tiempo (STF), análisis de componentes principales (PCA) y distancia de Mahalanobis (MD) para detectar y localizar la pérdida de un tirante en el Puente Río Papaloapan (PRP) a partir de las correspondientes señales de vibración. Los resultados muestran la capacidad y eficiencia de este método para detectar y localizar daño en un puente de la vida real en operación, incluso con el ruido significativo contenido en las señales adquiridas; por lo tanto, este método se podría implementar permanentemente en puentes atirantados para evitar catástrofes ocasionadas por tirantes fracturados.

2.1 Metodología

El método consiste básicamente de tres pasos: 1) se adquiere la respuesta vibratoria del puente sometido a excitaciones ambientales (principalmente tráfico y viento) mediante el uso de acelerómetros distribuidos uniformemente en el tablero, luego se extraen las STF de las señales de vibración para dos condiciones, sano y dañado, las cuales se analizan mediante la función de autocorrelación (ACF) para eliminar ruido fortalecer los patrones encontrados en las señales; 2) se desarrollan y aplican modelos basados en PCA como técnica de clasificación para decidir si los datos actuales bajo análisis presentan anomalías respecto a los datos correspondientes a la condición sana (*baseline*), y 3) se propone y utiliza un nuevo indicador de daño (DI) basado en MD para determinar si existe daño y su ubicación. Para validar el método, se utilizan los datos de vibración recopilados del puente atirantado PRP para dos escenarios diferentes (puente sano y puente dañado por la pérdida de un tirante) mientras el puente operaba bajo condiciones normales. En las siguientes subsecciones se presenta una descripción más detallada de la metodología.

2.1.1 Extracción de características estadísticas de tiempo

Primero, la estructura debe estar sujeta a vibraciones ambientales generadas principalmente por el tránsito y el viento. Posteriormente, se miden las respuestas vibratorias para dos condiciones: sana y dañada por la pérdida de un tirante, usando para ello un arreglo de sensores distribuidos en el puente y adquiriendo datos en ventanas de muestra de *t* segundos.

Por lo tanto, estas ventanas de muestras se indican mediante $S_{c,i}^{(j)}$, w, donde *c* indica la condición sana (*h*) o dañada (*d*); *i* es el número de sensor que va del 1 a 12 (en este caso, el puente analizado se monitorea por 12 sensores), (*j*) indica el número de muestra, que varía de 1 a *H* para la condición sana y de 1 a *D* para la dañada, donde *H*>>*D*. Esta diferencia se debe a que existe una cantidad considerablemente mayor de muestras para la condición sana que para condiciones de daño o desconocidas [88]. Posteriormente, estas muestras de tiempo se procesan empleando la ACF.

2.1.1.1 Función de autocorrelación

La ACF es una técnica utilizada para eliminar ruido [89] e incluso intensificar los patrones o características que se encuentran en las señales [90]. ACF se define como la correlación entre una señal y una versión retrasada de ella misma, matemáticamente se expresa de la siguiente manera [91,92]:

$$\mathbf{\hat{S}} = \frac{\frac{1}{M} \sum_{l=1}^{M-k} \left(\mathbf{S}_{l} - \overline{S} \right) \left(\mathbf{S}_{l+k} - \overline{S} \right)}{\sigma^{2}}$$
(1)

donde, para mayor claridad, la muestra $S_{c,i}^{(j)}$ se simplifica como **S**; entonces, **S**_{*l*} y **S**_{*l+k*} son una muestra medida y su versión retrasada, respectivamente; \overline{S} es la media de **S**_{*l*} y σ^2 es la varianza, *k* es el desfase desde 0 a *K*, y *l* es el número de puntos de datos en **S** desde 1 hasta *M*. Una vez que se obtienen las señales autocorrelacionadas, $\widehat{S}_{c,i}^{(j)}$, de ellas se extrae un conjunto de características estadísticas.

2.1.1.2 Características estadísticas de tiempo

La extracción de características estadísticas está asociada con la conversión de datos medidos en indicadores alternativos correlacionados con las condiciones estudiadas, es decir, condiciones sanas y de daño de un sistema [93]. En los últimos años, las características estadísticas han demostrado ser indicadores adecuados para evaluar la integridad de máquinas eléctricas [94,95], diagnosticar enfermedades humanas [96,97], determinar la condición de estructuras civiles [98,99], entre otras aplicaciones. Por otro lado, su cálculo no requiere transformaciones de dominio e implica menos procesos matemáticos, lo que permite su uso para aplicaciones en línea en esquemas SHM. Por tanto, esta técnica se emplea en este trabajo para evaluar la integridad estructural del puente atirantado.

Para ello, se realiza la prueba de Kruskal-Wallis (KWT) [99–101] a todas las características extraídas de los sensores para determinar cuáles STF (modo (MO), mediana (ME), rango (RG), *root-mean-square* (RMS), media (μ), varianza (σ 2), desviación estándar (σ), Asimetría (AS), kurtosis (K), quinto momento (5M), sexto momento (6M), factor de forma con RMS (SFRMS), factor de cresta (CF), factor de impulso (IF) y factor de latitud (LF)) son los más adecuados para evaluar la condición estructural.

En general, KWT es una prueba no paramétrica que se aplica para analizar las variaciones de dos o más conjuntos de datos con el fin de determinar si presentan datos similares o no [99,101]. En este sentido, KWT calcula un valor de probabilidad de acuerdo al promedio de los conjuntos de datos evaluados, donde un valor de probabilidad cercano a cero indica que se obtiene una diferencia importante entre los datos analizados. Por lo tanto, esta probabilidad puede determinar los STF más útiles para evaluar el estado de salud del PRP. En la tabla 2.1 se muestran los valores de probabilidad obtenidos de las 15 STF estudiadas para el sensor 5 donde se ubica el daño. Aunque la mayoría de los STF estudiados muestran valores de baja probabilidad (ver tabla 2.1), el RMS, el rango, la desviación estándar y la varianza, los cuales se resaltan en color gris, otorgan los valores más bajos, lo que indica que son las características más adecuadas para evaluar el estado del PRP. Además, para complementar los resultados mostrados en la tabla 2.1, la figura 2.1 muestra la distribución de datos resultante del KWT para los 15 STF, correspondientes al sensor 5. Los STF seleccionados se resaltan en color gris. En consecuencia, se utilizan cuatro índices estadísticos junto con el método PCA para la extracción de características: la varianza, la desviación estándar, el rango y el RMS. Estos índices también demostraron ser eficientes para identificar información relevante en señales de tiempo, especialmente señales de vibraciones [99-103].

| Característica | Valor de probabilidad | Característica | Valor de probabilidad | Característica | Valor de probabilidad |
|----------------|--------------------------|----------------|--------------------------|----------------|--------------------------|
| Modo | 6.71x10 ⁻²⁷ | σ2 | 2.33x10 ⁻⁵⁴ | 6M | 3.14x10 ⁻⁴⁴ |
| Mediana | 1.09x10 ⁻⁰⁸ | σ | 2.33x10 ⁻⁵³ | SFRMS | 6.42x10 ⁻²⁷ |
| Rango | 6.71x10 ⁻⁵⁷ | Asimetría | 1.14x10 ⁻¹⁴ | CF | 2.33x10 ⁻²¹ |
| RMS | 2.33x10 ⁻⁵⁴ | Kurtosis | 5.62x10 ⁻²³ | IF | 1.66x10 ⁻¹⁹ |
| μ | 6.70x10 ⁻⁰¹ | 5M | 2.02x10 ⁻¹⁵ | LF | 8.72x10 ⁻³² |

Tabla 2.1. Valores de probabilidad obtenidos de la prueba KWT.



Figura 2.1. Distribución de datos resultantes de la prueba KWT para: (a) modo, (b) mediana, (c) rango, (d) RMS, (e) μ , (f) σ^2 , (g) σ , (h) asimetría, (i) kurtosis, (j) 5M, (k) 6M, (l) SFRMS, (m) CF, (n) IF y (o) LF, para condición sana (*Healthy*) y de daño (*Damage*).

Para los resultados mencionados anteriormente, las características seleccionadas con las siguientes definiciones: $\hat{S}_{c.i}^{(j)}$ se designa como \hat{S} para simplificar, por lo que \hat{S}_l representa las muestras de tiempo autocorrelacionadas y *l* es el número de puntos de datos de 1 a *M*, realizando los cálculos de la siguiente manera:

1) La varianza (x_{σ^2}) es una medida de la variabilidad; indica cómo se separan los puntos de datos de la media [95]. Se establece como:

$$x_{\sigma^2} = \frac{1}{M-1} \sum_{l=1}^{M} \left| \widehat{S}_l - X_{\mu} \right|^2$$
(2)

2) La desviación estándar (x_{σ}) es una medida de la energía contenida en la señal de vibración [98,104]. Se expresa como:

$$X_{\sigma} = \sqrt{X_{\sigma^2}} \tag{3}$$

3) El rango (x_{rg}) mide la diferencia entre el pico de amplitud positiva y el pico de amplitud negativa de la ventana de tiempo de vibración; sus valores normalmente aumentan cuando el daño provoca una reducción de la rigidez [93]. Se denota como:

$$x_{rg} = \max(\mathbf{S}) - \min(\mathbf{S}) \tag{4}$$

4) El *root-mean-square* (x_{rms}) es una medida del nivel de energía en la señal de vibración o el nivel de vibración [105,106]; se define como:

$$x_{rms} = \sqrt{\frac{1}{M} \sum_{l=1}^{M} \mathbf{S}_l^2}$$
(5)

Así entonces, para cada sensor, las matrices $H_i \in \mathbb{R}^{Hx4}$ y $D_i \in \mathbb{R}^{Dx4}$ se construyen con las características extraídas para las condiciones sana y dañada, respectivamente, y H y D son el número de muestras para cada matriz. Los datos de las matrices H_i y D_i se normalizan mediante el método Z-score para eliminar la influencia del orden de dimensión y magnitud [107]. Por lo tanto, los elementos normalizados \tilde{z}_{ij} que componen una matriz normalizada \tilde{Z} se calculan como:

$$\tilde{z}_{ij} = \frac{z_{ij} - \overline{\mathbf{Z}}_j}{\sigma_j}$$
(6)

donde, z_{ij} son los elementos en una matriz de características Z, \overline{Z}_j y σ_j son la media y la desviación estándar de cada columna en Z. En consecuencia, se obtienen las matrices \tilde{H}_i and \tilde{D}_i .

Una vez analizados todos los datos, la información correspondiente a la condición sana se separa en datos de entrenamiento y validación. Por otro lado, los datos correspondientes a la condición de daño también se utilizan como validación. En consecuencia, la información de validación se separa y se utiliza para pruebas de validación independientes para las condiciones sanas y dañadas. Finalmente, el conjunto de entrenamiento se emplea para la etapa de construcción del modelo y se obtienen modelos individuales que se ajustan a los datos relacionados con cada sensor.

2.1.2 Etapa de construcción del modelo

Para clasificar los datos nuevos y determinar si pueden considerarse anómalos, se propone un modelo basado en PCA que se ajusta a los datos sanos. Además, se calcula un modelo individual para cada sensor distribuido en el puente, proporcionando así un mapa para localizar daño. En este sentido, cada modelo determina una región donde se ubican los datos. Esta región está definida por un isocontorno de MD constante que tiene la forma de una elipse. En consecuencia, las dimensiones de las elipses están definidas por los parámetros del modelo basado en PCA.

2.1.2.1 Análisis de componentes principales

PCA es una técnica basada en la descomposición de valor único (*single value decomposition*, SVD) que proporciona una forma precisa para transformar datos de alta dimensión en una aproximación de baja dimensión con más factores descriptivos estadísticamente [108–110]. Específicamente, los datos se transforman de una dimensión alta de orden *n* a una dimensión más baja de orden *m* mediante un procedimiento estadístico. En este sentido, se calculan los eigenvectores y eigenvalores de la matriz de covarianza **C***i* de **X***i* [111,112]. Aquí, *i* es el número de sensor, **X***i* son los datos de referencia de entrenamiento $X_i = \tilde{H}_i \in \mathbb{R}^{N \times n}$, *N* es el número de muestras de datos de entrenamiento N=1,...,H/2.

La transformación se realiza de la siguiente manera:

$$\mathbf{Y}_i = \mathbf{X}_i \mathbf{T}_i \tag{7}$$

donde, $Y_i \in \mathbb{R}^{N \times m}$ es la matriz de puntuación, y $T_i \in \mathbb{R}^{n \times m}$ es la matriz de transformación, que se compone de *m* eigenvectores de **C**. Además, la matriz de covarianza se construye como [113]:

$$\mathbf{C}_{i} = \frac{1}{N-1} \mathbf{X}_{i}^{T} \mathbf{X}_{i}$$
(8)

donde, X_i tiene datos centrados en la media y, como se mencionó anteriormente, X_i son los datos de referencia de entrenamiento. Posteriormente, T_i se construye realizando la SVD de C_i ,

$$\mathbf{C} = \mathbf{V}\mathbf{S}\mathbf{V}^T \tag{9}$$

donde, **S**=diag($\lambda_1, \lambda_2, ..., \lambda_n$) es una matriz que contiene los valores singulares en los elementos diagonales, y están clasificados en orden descendente; **V**=[$\varphi_1, \varphi_2, ..., \varphi_n$] es la matriz de eigenvectores. Además, las columnas en **V** se clasifican en orden descendente de acuerdo a los valores singulares, y se denominan componentes principales del modelo de referencia [111,112]. Por lo tanto, la matriz de transformación **T***^{<i>i*} se construye tomando las primeras *m* columnas de **V**:

$$\mathbf{T}_{i} = \left[\varphi_{1}, \varphi_{2}, \dots, \varphi_{m}\right]$$
(10)

Como se observa en la ecuación (7), como resultado, T_i proyecta la matriz X_i en un espacio de orden *m*.

2.1.2.2 Distancia de Mahalanobis

MD se utiliza para diferentes propósitos, uno de ellos es la detección de valores atípicos. Indica a cuántas desviaciones estándar se encuentra una muestra de la media de la distribución de datos [114,115]. En consecuencia, la MD de un vector **y** de un conjunto de datos con respecto al vector medio \bar{y} del conjunto de datos se define como [116]:

$$MD = \sqrt{\left(\mathbf{y} - \overline{\mathbf{y}}\right)^T \mathbf{S}^{-1} \left(\mathbf{y} - \overline{\mathbf{y}}\right)}$$
(11)

donde, **S** es la matriz de covarianza.

Dados estos puntos, el modelo basado en PCA describe una región delimitada por una elipse correspondiente a dos MD de la media. Esta elipse se define en los ejes x y y como:

$$x_{ellipse} = centroid_{x} + MjrAxis_{x}\cos\theta + MnrAxis_{x}\sin\theta$$

$$y_{ellipse} = centroid_{y} + MjrAxis_{y}\cos\theta + MnrAxis_{y}\sin\theta$$
(12)

donde, las coordenadas x y y del centroide de la elipse se obtienen calculando las medias de la primera y segunda columnas de las puntuaciones de PCA; θ es un vector de ángulo en radianes de 0 a 2π ; *MjrAxis*_x y *MjrAxis*_y son las orientaciones de los ejes principales en x y y, respectivamente, y están definidos por el primer eigenvector φ_1 del modelo y el primer eigenvalor λ_1 como:

$$MjrAxis_{x} = \varphi_{1}(1) * 2\sqrt{\lambda_{1}}$$

$$MjrAxis_{y} = \varphi_{1}(2) * 2\sqrt{\lambda_{1}}$$
(13)

De manera similar, *MnrAxis*_x y *MnrAxis*_y, las orientaciones de los ejes menores, se definen por el segundo eigenvector φ_2 y el segundo eigenvalor λ_2 como:

$$MnrAxis_{x} = \varphi_{2}(1) * 2\sqrt{\lambda_{2}}$$

$$MnrAxis_{y} = \varphi_{2}(2) * 2\sqrt{\lambda_{2}}$$
(14)

En la siguiente etapa, se validan los modelos basados en PCA y las elipses se utilizan para la visualización. Asimismo, los modelos se emplean para determinar el estado estructural y la ubicación del daño, si existe, mediante un nuevo DI, que se explica en el siguiente apartado.

2.1.3 Etapa de validación y estimación de indicadores de daños.

En esta etapa, primero se utilizan los modelos basados en PCA para determinar valores atípicos de datos mediante la MD. Se aplica un valor atípico de detección de anomalías para determinar los datos que se desvían lo suficiente de los datos normales o regulares, o que parecen ser incongruentes con el resto de los datos [116,117]. Además, los valores atípicos o anomalías en los datos pueden deberse a cambios en la estructura, presencia de daños o incluso situaciones adversas por condiciones ambientales, entre otras razones. Estos cambios pueden reflejarse en la respuesta vibratoria y, por tanto, en las características estimadas. En segundo lugar, para validar los modelos basados en PCA, los datos de validación se dividen en pruebas de 10 muestras para la condición sana y pruebas de 10 muestras para la condición de daño. Luego, para cada prueba, se calculan las MD de cada muestra. A continuación, conociendo estas MD, se determinan las muestras que son atípicas para el modelo PCA calculado. En tercer lugar, para las muestras determinadas como valores atípicos, se determinan dos nuevas variables: a) la media de sus MD (MDµ) y b) la tasa de daño (DR) calculada como el número de muestras encontradas como valores atípicos entre el total de muestras. En cuarto lugar, para evaluar si los valores atípicos se pueden considerar como daño y dónde se encuentra el daño, se propone un DI que se calcula como:

$$DI = MD\mu * DR$$
(15)

Posteriormente, $MD\mu$ indica qué tan lejos están las muestras atípicas, y DR otorga una relación de cuántas muestras atípicas existen. En este sentido, si no se detectan valores atípicos, el DI es igual a cero. Si todas las muestras son valores atípicos, DR es igual a 1 y el DI es igual a la media de la MD de las muestras. Por otro lado, si sólo hay pocas muestras atípicas, el DI calculado puede ser menor; por lo tanto, es posible que la prueba no se considere dañada. En consecuencia, para determinar si un DI de una prueba puede verse como daño, se calcula un umbral DI empleando sólo los datos de validación correspondientes a la condición sana. Por lo tanto, solamente los DI calculados por encima del umbral se reconocen como daño. Finalmente, una vez calculados todos los DI para los 12 sensores, la localización del daño se puede estimar observando los sensores con el DI más alto.

2.2 Configuración experimental

El método propuesto para detectar y localizar daño se aplica en un puente atirantado real con el fin de validar su funcionalidad y efectividad. Por tanto, los datos adquiridos experimentalmente del PRP se utilizan para este fin.

Durante el mantenimiento del puente en 2019, se monitoreó su respuesta vibratoria en dirección vertical mediante el uso de 12 acelerómetros inalámbricos fabricados por G-Link-LXRS[©] con un rango de medición de ± 2 g; esos sensores se colocaron sobre el tablero entre las semiarpas 3, 4, 5 y 6 (indicados por círculos azules en la figura 2.2). En primer lugar, se midió la respuesta dinámica del puente sano sometido a excitaciones ambientales y condiciones de operación normal (principalmente viento, tráfico y peatones) tomando 180 ventanas de tiempo de 10 segundos cada una con una frecuencia de muestreo de 64 Hz, generando un total de 115,200 muestras por sensor. Luego, para producir una condición de daño en el puente, el tirante No. 6 de la semiarpa No. 3 (T6S3) se removió por completo (ver figura 2.3 (a)), el cual está representado por una línea roja en la figura 2.3 (b). Esta segunda condición se monitoreó tomando 90 ventanas de tiempo de 10 segundos cada una, utilizando la misma disposición experimental de la condición sana. Es importante notar que sólo hay un conjunto de datos para cada condición del puente con 180 y 90 muestras para las condiciones sanas y dañadas, respectivamente.

La figura 2.4 muestra dos fotografías de uno de los acelerómetros colocados en el tablero del puente aguas arriba mientras se adquieren datos con tránsito bajo condiciones de operación normal para el escenario dañado (tirante T6S3 destensado).



Figura 2.2. Ubicación de los sensores utilizados para monitorear el comportamiento dinámico del puente (sensores: S1-S12; semiarpas: SH3-SH6).



(a)



Figura 2.3. Tirante removido para generar la condición de daño: (a) condición real y (b) esquemática.



Figura 2.4. Acelerómetro colocado en el tablero del puente aguas arriba y adquiriendo datos con tránsito bajo condiciones de operación normal.

2.3 Resultados y discusión

Siguiendo los pasos de la metodología propuesta, primero se realizó la etapa de extracción de características. Una vez que se obtuvieron las respuestas dinámicas medidas del PRP, se analizaron empleando la ACF. Para ilustrar las respuestas de vibración adquiridas, la figura 2.5 y la figura 2.6 muestran un conjunto de señales correspondientes a la condición sana y dañada para cada sensor, respectivamente. Es importante notar que las amplitudes de las señales de vibración mostradas en esas figuras son bajas; además, de que contienen un alto nivel de ruido. Por tanto, es evidente que no se pueden observar diferencias importantes en las mismas y resulta imposible determinar dónde podría estar el daño en el puente.



Figura 2.5. Respuestas dinámicas para la condición sana correspondientes a los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.



Figura 2.6. Respuestas dinámicas para la condición dañada correspondientes a los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.

Siguiendo la metodología propuesta, es importante el uso de una técnica que reduzca la cantidad de ruido en las señales e intensifique los patrones o características que se encuentran en ellas. Por tanto, las señales de la figura 2.5 y la figura 2.6 procesadas con la ACF se muestran en la figura 2.7 y la figura 2.8, respectivamente. Así entonces, como se muestra en la figura 2.8 para la condición de daño, a diferencia de la condición sana en la figura 2.7, algunas de las señales ACF resultantes muestran un comportamiento diferente, principalmente para el sensor donde se supone se encuentra el daño.



Figura 2.7. Señales ACF de la condición sana para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.





Figura 2.8. Señales ACF de la condición dañada para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.

Una vez que se obtienen las señales de ACF para las muestras de la condición sana y con daño, se extraen las características propuestas. Posteriormente, para cada sensor, se construye una matriz H_i y D_i con dimensiones de 180 x 4 (muestras x características) y 90 x 4, respectivamente, las cuales contienen las características extraídas. A continuación, las matrices H_i se normalizan mediante el método Z-score para eliminar la influencia del orden de dimensión y magnitud. Después de eso, las matrices D_i se normalizan con respecto a las matrices H_i , tomando la media y la desviación estándar de sus respectivas matrices H_i .

Enseguida, se procede a construir los modelos basados en PCA para cada sensor. Para ello, las matrices normalizadas \tilde{H}_i se dividen en 50% para entrenamiento (X_i) y 50% para validación (V_{Hi}). La figura 2.9 muestra los modelos obtenidos para los sensores 1 a 12. En consecuencia, en cada figura se describen los modelos basados en PCA por el área dentro de las elipses formadas por una línea negra continua, las muestras transformadas correspondientes a las dos primeras filas (PC1-eje horizontal y PC2-eje vertical) de la matriz de puntuación Y_i se indican con símbolos "x" azules. Esta región tiene un radio de dos MD y coincide con el 95% de las muestras.

Posteriormente, para validar los modelos propuestos, los datos de validación compuestos a partir de la matriz de validación sana V_{Hi} y la matriz de daño \tilde{D}_i se dividen en un conjunto de pruebas. En consecuencia, se tienen nueve pruebas para evaluar la condición sana y nueve pruebas para evaluar la condición de daño. Cada prueba de condición sana se compone de diez filas aleatorias de la matriz de validación sana V_{Hi} y, de manera similar, cada prueba de condición de daño se compone de diez muestras aleatorias de \tilde{D}_i . Así, cada prueba se analiza empleando el método PCA, reflejando las muestras en el nuevo espacio. La figura 2.10 muestra un ejemplo de las pruebas de condición sana para cada sensor. En estas pruebas, la mayoría de las muestras, indicadas por asteriscos azules, están dentro de los



modelos indicados por las líneas negras continuas y un círculo magenta rodea las muestras atípicas.

Figura 2.9. Modelos de entrenamiento basados en PCA para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.



Figura 2.10. Modelos de validación basados en PCA de la condición sana para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.

De la misma manera, la figura 2.11 muestra ejemplos de la condición de daño. En esta figura, las muestras se indican con asteriscos rojos. A continuación, se procede a calcular los indicadores de daño para determinar la condición estructural del puente. Primero, para cada sensor y cada prueba, se determinan las muestras



atípicas, luego, se calculan sus MD para determinar la MD μ . Después de eso, se calcula la DR. Una vez obtenidos estos dos indicadores, se estima el DI.

Figura 2.11. Modelos de validación basados en PCA de la condición dañada para los sensores: (a) 1, (b) 2, (c) 3, (d) 4, (e) 5, (f) 6, (g) 7, (h) 8, (i) 9, (j) 10, (k) 11, (l) 12.

En la tabla 2.2 se muestran los valores de MD μ , DR y DI obtenidos para los sensores 1 a 12 de las pruebas de los ejemplos mostrados en la figura 2.10 y figura 2.11. Se puede observar que para la condición sana existen muestras atípicas, pero están muy cercanas a la línea modelo; por lo tanto, los valores de MD μ se encuentran cerca del límite de dos MD. Por ende, las DR que se obtienen son bajas porque el número de muestras atípicas no es mayor que uno para los sensores 2, 3, 4, 10 y de dos para el sensor 11. Además, después de observar todas las pruebas de condición sana, un límite de umbral de daño (DTh) se obtiene experimentalmente con un valor de DI = 1.5. En este sentido, para las pruebas presentadas en la tabla 2.2 para la condición sana, los DI que se obtienen no superan el umbral. Por otro lado, los resultados presentados para la condición de daño muestran que para el sensor 5, todas las muestras son atípicas obteniendo un DR de 1, y multiplicado por el MD μ , se obtiene un DI de 4.73 que está por encima del DTh, indicando así la presencia de daño en el sensor 5.

| Sensor | Condición sana | | | Condición dañada | | |
|--------|----------------|------|------|------------------|------|------|
| Gensor | MDμ | DR | DI | MDμ | DR | DI |
| 1 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| 2 | 2.05 | 0.11 | 0.23 | 0.00 | 0.00 | 0.00 |
| 3 | 2.10 | 0.11 | 0.23 | 2.08 | 0.11 | 0.23 |
| 4 | 2.19 | 0.11 | 0.24 | 0.00 | 0.00 | 0.00 |
| 5 | 0.00 | 0.00 | 0.00 | 4.73 | 1.00 | 4.73 |
| 6 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| 7 | 0.00 | 0.00 | 0.00 | 2.62 | 0.11 | 0.29 |
| 8 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| 9 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| 10 | 2.18 | 0.11 | 0.24 | 2.41 | 0.11 | 0.27 |
| 11 | 2.41 | 0.22 | 0.54 | 0.00 | 0.00 | 0.00 |
| 12 | 0.00 | 0.00 | 0.00 | 2.14 | 0.11 | 0.24 |

Tabla 2.2. Indicadores obtenidos para pruebas de condición sana y de daño.

Asimismo, los DI obtenidos para los sensores 3, 7, 9 y 12 no superan el DTh. Es fundamental mencionar que el valor de DR disminuye el DI cuando existe un número pequeño de muestras atípicas y cercanas a los límites del modelo. Pero, si existen muchas muestras atípicas, el DI tiende a exceder el DTh, incluso cuando las muestras atípicas están lejos de los límites del modelo. Para tener una vista rápida de la ubicación del daño, la figura 2.12 muestra los resultados de la prueba anterior para la condición sana (a) y la condición de daño (b). Los ejes verticales indican el DI y los ejes horizontales indican el número de sensor, que están ordenados como si estuvieran colocados en el puente. Las líneas discontinuas rojas simbolizan el umbral de daño. Finalmente, en la tabla 2.3 se muestran los resultados del sensor 5 para la metodología propuesta en función del estado de salud y la condición de la estructura. No se presentan los resultados para otros sensores porque el daño se estableció sólo en la ubicación del sensor 5. Sin embargo, debido a la proximidad al daño, los sensores 3 y 7 podrían tener DI cerca o sobre el DTh.



Figura 2.12. Resultados de valores DI en los 12 sensores para: (a) condición sana y (b) condición de daño.

| Tabla 2.3. Resultados del sensor 5 usando la metodología propuesta en base al estado de |
|-----------------------------------------------------------------------------------------|
| salud y condición de daño. |

| Condición de la estructura | Estado o | Efectividad (%) | |
|----------------------------|----------|-----------------|-----|
| | Sano | Dañado | |
| Sana | 9 | 0 | 100 |
| Dañada | 0 | 9 | 100 |
| Efectividad total (%) | 100 | 100 | 100 |

Es importante mencionar que la metodología propuesta se aplicó en un puente de la vida real bajo condiciones de operación normal; por esta razón, se puede considerar un instrumento práctico de SHM para evaluar el estado de las estructuras civiles. Por otro lado, considerando que este método utiliza únicamente señales de vibración sanas para construir el modelo basado en PCA, se podría caracterizar otro tipo de daño, ya que el daño modifica la respuesta vibratoria y puede reflejarse con este tipo de estudio. La propuesta presenta un enfoque descentralizado que identifica y localiza daño, empleando un bajo número de muestras por cada sensor. Las operaciones matemáticas necesarias, como la autocorrelación de las señales, la estimación de características y el PCA, son de baja complejidad y carga computacional. En este sentido, es posible implementar el método en sistemas tipo *hardware* que monitoreen e indican permanentemente el estado del puente. Por tanto, cuando se detecte daño con este método, se pueden sugerir análisis más rigurosos para programar el adecuado mantenimiento de la estructura.

2.4 Conclusiones parciales

En este capítulo se presentó una nueva metodología basada en STF, PCA y MD para detectar y localizar daño en un puente atirantado (PRP) bajo condiciones de operación normal. Primero, se realizó un procedimiento de extracción de características donde la ACF procesa las señales de vibración medidas y se extrae un conjunto de 4 STF; estos 4 STF se seleccionan de un conjunto de 15 STF realizando una prueba KWT. En segundo lugar, los STF extraídos se analizaron mediante el método PCA para construir un conjunto de modelos relacionados con cada sensor colocado en el puente, y todos los modelos tienen radios de 2 MD. Estos modelos representan el estado sano del puente. En tercer lugar, para la validación de los modelos, se propuso la observación de los datos de validación atípicos al modelo mediante la estimación de un DI a través de los DM y DR. Después de analizar los datos sanos, se encontró que un valor de DTh de 1.5 indica que valores por encima de éste se pueden considerar como daño, este umbral puede variar según la estructura en estudio. La prueba presentada obtiene un valor DI de 4.73 para la condición de daño, siendo el valor más bajo para esta condición. Los datos de validación se componen de los datos obtenidos cuando el puente está sano y dañado (donde el tirante 6 de la semiarpa 3 se retiró por completo, lo que corresponde al 100% de daño en el tirante). Por otro lado, debido al enfoque descentralizado de la propuesta, es posible identificar y localizar daño empleando 12 sensores, que es un número bajo considerando el número de tirantes en el tramo estudiado del PRP. Finalmente, los resultados obtenidos muestran que es posible detectar y localizar el daño con una precisión del 100% con el DI propuesto utilizando sólo 4 STF.

La metodología propuesta se creó con operaciones matemáticas de baja complejidad y carga computacional, lo que la hace ideal para ser implementada en sistemas tipo *hardware* que monitorean e indican permanentemente la condición estructural del puente. Por tanto, una vez que se detecta el daño, se puede sugerir un análisis más riguroso para programar el adecuado mantenimiento de la estructura. A futuro, se estudiarán otros tipos de daños para evaluar la capacidad

del método propuesto para identificarlos, además de usar otras características estadísticas potenciales en el tiempo o la frecuencia.

3. Método de acumulación de energía wavelet (MAEW)

El método de acumulación de energía *wavelet* (MAEW) se desarrolló previamente en el año 2020 con el objetivo de identificar daño en puentes y se publicó en [35]. Este método se basa en el posprocesamiento, mediante la transformada *wavelet* continua (*continuous wavelet transform*, CWT), de las señales adquiridas en el puente (vibración, desplazamiento y/o deformación) cuando un vehículo lo cruza.

En la publicación [35] se puede consultar detalladamente esta metodología y los resultados de su aplicación en un modelo numérico basado en el método del elemento finito (MEF) para identificar dos tipos diferentes de daño (daño en tablero y tirantes) en diversas ubicaciones y niveles de severidad.

Debido a los alentadores resultados que se obtuvieron aplicando el MAEW, en el presente capítulo de esta publicación se retoma este método en su aplicación en un caso real de daño/colapso/ausencia de un tirante en el PRP, a fin de analizar/valorar su sensibilidad y poder compararlo con el método STF-PCA-MD presentado en el capítulo anterior.

Por tanto, a continuación, se presenta una breve descripción de la metodología, los correspondientes resultados de su aplicación en el caso de la falla real y las conclusiones.

3.1 Metodología

El MAEW consiste en registrar las señales de vibración, desplazamiento y/o deformación en diferentes puntos a lo largo del tablero del puente, mientras un vehículo cruza éste; luego, esas señales y las del puente sano se restan y la CWT se aplica tanto a las señales sanas como a las restadas. Posteriormente, la comparación entre los diagramas CWT sanos y posiblemente dañados (restados) debe proporcionar evidencia sobre dónde se encuentra el daño (en caso de existir) y, por lo tanto, se debe considerar un rango conveniente de escala para hacer más notoria la presencia de daño. Finalmente, la energía *wavelet* (EW) se obtiene calculando el área bajo la curva para el rango de escala seleccionado y a lo largo del tablero del puente. La EW de un puente sano es baja y plana, mientras que para un puente dañado existe acumulación de EW en la ubicación del daño. Cabe destacar que es de primordial importancia la aplicación de un filtro adecuado en las señales antes de la resta y la selección de la onda madre (*mother wavelet*) más conveniente (filtro Savitzky-Golay y *Mexican hat mother wavelet*, para los casos aquí estudiados) para obtener la máxima eficacia y precisión al aplicar este método.

3.2 Resultados y discusión

El MAEW está diseñado para obtener su máxima efectividad en la identificación de daño a partir de una prueba controlada con el paso de un vehículo por el puente a velocidad baja y constante; no obstante, la falla que se analiza con este método, correspondiente al colapso del tirante T1S5, ocurrió el 10 de junio de 2015 (ver capítulo 1), es decir, antes del desarrollo del MAEW en el año 2020, por lo que una prueba controlada para su aplicación antes del accidente no fue posible; sin embargo, los datos disponibles con los que se contaba meses antes de la falla en condición sana (el 22 de agosto de 2014), así como instantes previos a la falla, durante la falla e instantes posteriores a la falla, fueron útiles para validar el potencial del MAEW para identificar este tipo de daño, aún incluso con tráfico aleatorio y no con una prueba controlada.

Así, los datos usados para la aplicación del MAEW corresponden con las mediciones con tráfico aleatorio obtenidas en el tablero con galgas extensométricas (125 Hz de frecuencia de muestreo) en los puntos de medición R1, R2 y R4 (ver figura 1.5).

La EW siempre fue significativamente mayor para las mediciones de puente dañado respecto a las mediciones de puente sano, lo cual representó un índice categórico para establecer que el puente se encontraba dañado.

En la figura 3.1 se muestran los diagramas CWT para el puente sano usando los datos de 120 segundos de monitoreo del 22 de agosto de 2014; mientras que, en la figura 3.2 se muestran los diagramas CWT para el puente dañado usando los datos de 120 segundos de monitoreo del 10 de junio de 2015, correspondiendo a 9.2 minutos antes del instante exacto del colapso del tirante T1S5; es decir, el tirante aún no caía sobre el tablero del PRP pero ya se encontraba dañado y su ruptura era inminente.

Ambos diagramas se obtuvieron después de seguir la metodología detallada como se menciona en [35], incluyendo el filtrado correcto de señales, además de aplicar la adecuada *mother wavelet* y rango de escala, y eliminar los efectos de borde.

Comparando esos diagramas mostrados en la figura 3.1 y figura 3.2, resulta muy evidente que los coeficientes son claramente mayores para el caso dañado respecto al sano, en cualquier punto de medición; y, además, el punto de medición R2, que es el más cercano al tirante dañado, es donde se presenta mayor actividad *wavelet* y los coeficientes más altos para el caso dañado. Estos resultados son muy importantes, ya que los coeficientes representan el parámetro principal usado para la obtención de la EW y determinar la condición estructural del puente. Por lo que, de inicio, con estos diagramas CWT se pudo haber alertado de una anomalía, donde la detección y localización de daño era posible.

Adicionalmente, en la figura 3.3 se muestra el diagrama CWT del punto de medición R2 que permite apreciar el momento exacto de la ruptura del tirante al segundo 674,

es decir, 554 segundos después del periodo de 120 segundos mostrado en la figura 3.2. Además, en esa figura 3.3 se pueden apreciar los 50 segundos antes y después del colapso del tirante. Así entonces, en la figura 3.3 se distinguen claramente los elevados coeficientes *wavelet* en el instante del colapso, además de que en los 50 segundos previos (tirante dañado) y 50 segundos posteriores (ausencia de tirante) se mantienen los coeficientes *wavelet* en magnitudes similares a los de los diagramas de la figura 3.2; por lo que esas tres etapas de daño (tirante dañado, colapso de tirante y ausencia de tirante) se podrían haber identificado.



Figura 3.1. Diagramas CWT a partir de las señales experimentales filtradas de puente sano para el área de interés: (a) mostrando la escala en el eje vertical y (b) mostrando los coeficientes en el eje vertical. Tres diferentes posiciones de medición para cada caso (de arriba a abajo: R1, R2 y R4).



Figura 3.2. Diagramas CWT a partir de las señales experimentales filtradas de puente con tirante dañado T1S5 para el área de interés: (a) mostrando la escala en el eje vertical y (b) mostrando los coeficientes en el eje vertical. Tres diferentes posiciones de medición para cada caso (de arriba a abajo: R1, R2 y R4).



Figura 3.3. Diagrama CWT a partir de la señal experimental filtrada de la posición de medición R2 alrededor del momento del colapso del tirante T1S5: (a) mostrando la escala en el eje vertical y (b) mostrando los coeficientes en el eje vertical.

Finalmente, las EW totales obtenidas de los correspondientes diagramas CWT para cada punto de medición del caso sano y dañado de las figuras 3.1 y 3.2 se muestran en la figura 3.4; mientras que en la figura 3.5 se presenta la EW total promedio correspondiente para el caso sano y para el caso dañado. Las EW para mediciones individuales son claramente mayores para los casos dañados (figura 3.4) y la máxima EW total promedio es casi cinco veces mayor para el caso dañado con respecto al caso sano (figura 3.5). Además, se puede notar en la figura 3.4 que la mayor EW para el caso dañado se obtuvo para el punto de medición más cercano al daño (R2), es decir, la ubicación de esta medición era la más cercana al anclaje del tirante T1S5 en el tablero. Estos resultados confirman los resultados obtenidos en las figuras 3.1 y 3.2 de forma aún más clara y tuvieron que alertar de que el puente estaba dañado debido al incremento significativo de la EW respecto al caso sano; y, además, podrían haber sugerido que el daño estaba ubicado alrededor de R2, tal como ocurrió.



Figura 3.4. EW total a partir de las señales experimentales filtradas para: (a) puente sano y (b) puente con tirante dañado T1S5. Tres diferentes posiciones de medición para cada caso (de arriba a abajo: R1, R2 y R4).



Figura 3.5. EW total promedio a partir de las señales experimentales filtradas para puente sano vs. puente con tirante dañado T1S5.

3.3 Conclusiones parciales

En este capítulo se retomó el MAEW aplicado a un caso real de falla de un tirante en el PRP para poder compararlo con el método STF-PCA-MD presentado en el capítulo anterior. A pesar de la aleatoriedad del tráfico con el que se adquirieron los datos usados para aplicar el MAEW para este estudio y no a partir de una prueba controlada (como sugiere dicho método para obtener su mayor efectividad), se observaron EW significativamente mayores para el puente dañado y la identificación del tirante defectuoso fue posible. Asimismo, se demostró la importante sensibilidad del MAEW para detectar y localizar el escenario real de una falla de un tirante en el PRP en sus tres etapas: tirante dañado, colapso de tirante y ausencia de tirante. Los resultados obtenidos muestran que el MAEW puedo haber alertado del daño en un tirante del PRP y haber evitado el accidente, por lo que resulta un método promisorio y atractivo para implementarse en puentes reales con un bajo costo.

4. Análisis y discusión de resultados

En esta publicación se analizó la sensibilidad de dos métodos no paramétricos de detección de daño ante escenarios reales de daño en tirantes del PRP. El primer método, llamado método STF-PCA-MD, es un método basado en características estadísticas de tiempo (STF), la función de autocorrelación (ACF), análisis de componentes principales (PCA) y la distancia de Mahalanobis (MD); el cual fue capaz de detectar y localizar con precisión la ausencia del tirante T6S3 en el PRP. El segundo método, es el método de acumulación de energía *wavelet* (MAEW) presentado en la Publicación Técnica IMT [35], del cual se analizó su sensibilidad para identificar el daño/colapso/ausencia del tirante T1S5 del mismo PRP. En la tabla 4.1 se presenta una comparativa de ambos métodos, los cuales resultaron exitosos para el cumplimiento de sus objetivos por los cuales fueron desarrollados.

| Método | Tipo de análisis | Tipo de puente | Tipo de daño | Alcance | Sensibilidad |
|--------------------------------------------------------------------|-----------------------------------|-------------------------------|--------------------------------------------------|-----------------------------|-----------------------------------------------------------------------|
| Método STF- PCA-MD | Experimental en puente real | Puente atirantado (PRP) | Ausencia del tirante T6S3 | Detección y localización | Suficiente para detectar y localizar el escenario de daño |
| Método de acumulación de energía <i>wavelet</i> (MAEW) | Experimental en puente real | Puente atirantado (PRP) | Daño / colapso / ausencia del tirante T1S5 | Detección y localización | Suficiente para detectar y localizar el escenario de daño |

 Tabla 4.1. Comparación del método STF-PCA-MD y MAEW.

En la tabla 4.1 se puede apreciar que ambos métodos se probaron de forma real en el mismo puente atirantado y cumplieron con tener la sensibilidad necesaria para detectar y localizar los correspondientes escenarios de daño presentados en el PRP. Adicionalmente, los dos métodos tienen las ventajas de ser de bajo costo y baja complejidad, además de poder identificar daño con significativa precisión, de forma eficiente y mediante el uso de un solo índice; por lo que resultan muy atractivos para implementarse en puentes reales.

Por otra parte, entre las desventajas se tiene que la precisión en la identificación de daño para ambos métodos depende del número de sensores colocados a lo largo del tablero del puente, y, aunque los sensores usados no son de un costo elevado, para reducir aún más el costo de instrumentar/monitorear el puente para la

aplicación de los métodos, se contempla usar a corto plazo datos de sensores que son todavía de menor costo y que actualmente se están desarrollando, así como datos basados en imágenes de video, por lo que la precisión mejoraría al contar con un gran número de puntos de medición y a un bajo costo; de esta manera, los tramos/zonas en los que se sugeriría la presencia de daño serían relativamente cortos, facilitando así las tareas de inspecciones finales para la localización exacta del daño. Por otra parte, el método STF-PCA-MD aún tiene que probarse para el escenario previo a la ausencia del tirante (tirante dañado antes del colapso o remoción) para analizar si su sensibilidad se conserva ante un escenario más complicado; mientras que el MAEW se tiene que seguir probando y mejorando ante los casos de adquisición de datos con tráfico aleatorio donde una prueba controlada con un solo vehículo no es posible.

Así entonces, al resultar exitosa la aplicación de ambos métodos ante los escenarios de daño presentados, se continuará la investigación de ellos, para lo cual se contempla aplicar el método STF-PCA-MD usando los datos del escenario de daño/colapso/ausencia del tirante T1S5; mientras que el MAEW se usará para identificar el escenario de la ausencia del tirante T6S3; para poder así compararlos bajo los mismos escenarios de daño. Además, se aplicarán los dos métodos usando datos de simulaciones numéricas, experimentales en laboratorio y experimentales en puente real bajo condiciones de operación normal, para detectar y localizar diferentes tipos de daño, en diversas ubicaciones y con varios niveles de intensidad. De esta manera, los métodos se usarán simultáneamente bajo las mismas condiciones con la finalidad de continuar analizando la sensibilidad y precisión en la identificación de daño ante diversos escenarios y, poder así, determinar si es factible usarlos al mismo tiempo como métodos de respaldo mutuos para asegurar la correcta identificación de daño y reducir el número de falsas alarmas, consolidando un esquema SHM completo de uso continuo y sistemático en puentes reales.

Conclusiones generales

En esta publicación se analizó la sensibilidad de dos métodos no paramétricos desarrollados para detectar y localizar daño en tirantes de puentes atirantados (método STF-PCA-MD y MAEW). Para ello, ambos métodos se aplicaron en un puente atirantado real (PRP) bajo condiciones de operación normal, usando los datos del monitoreo de vibraciones/deformaciones del puente, tanto en condiciones sanas como en dos escenarios de daño: ausencia del tirante T6S3 y daño/colapso/ausencia del tirante T1S5, respectivamente.

Los escenarios de daño estudiados representaron un gran desafío para identificarse con métodos basados en el monitoreo de vibraciones/deformaciones sin tener que interrumpir la operación del puente y, más aún, cuando el diseño/construcción del puente provoca que el daño ocasionado por la pérdida de un tirante se "enmascare" debido a que la carga que tendría que soportar el tirante ausente se distribuye en los tirantes aledaños. Por tanto, las condiciones de daño analizadas son escenarios ideales para inicialmente saber si los métodos aplicados tienen la suficiente sensibilidad para identificar esas condiciones de daño y, por tanto, el potencial para continuar investigándolos en condiciones de mayor exigencia aún y, en un futuro, aplicarlos de forma sistemática en los puentes como parte de un esquema SHM completo.

Los resultados indicaron que los dos métodos propuestos y aplicados tienen una significativa sensibilidad ante los escenarios de daño analizados, ya que pudieron detectar y localizar los correspondientes tirantes dañados con gran eficiencia y precisión; por lo que resultan muy atractivos para implementarse en puentes reales de forma sistemática, ya que, adicionalmente, son de bajo costo y baja complejidad. Así entonces, se continuará en trabajos futuros la investigación de estos métodos ante otras ubicaciones, tipos y severidades de daño, usándolos simultáneamente como métodos de respaldo bajo las mismas condiciones.

Bibliografía

[1] Chupanit, P., Phromsorn, C. (2012). The importance of bridge health monitoring, *International Journal of Civil and Environmental Engineering*, 6(6), 135–138.

[2] Malekjafarian, A., McGetrick, P., OBrien, E. (2014). A review of indirect bridge monitoring using passing vehicles, *Shock and Vibration*, 2015, 1–16.

[3] Casas, J.R., Moughty, J.J. (2017). Bridge damage detection based on vibration data: past and new developments, *Frontiers in Built Environment*, 3(4), 1–12.

[4] Zhu, X., Cao, M., Ostachowicz, W., Xu, W. (2019). Damage identification in bridges by processing dynamic responses to moving loads: features and evaluation, *Sensors*, 19(463), 1–26.

[5] LeRose, C. (2001). The collapse of the Silver Bridge, West Virginia Historical *Society Quarterly*, 15(4), 1.

[6] Davey, M., Wald, M.L. (2007). Potential flaw is found in design of fallen bridge, *The New York Times*, USA.

[7] AFP. (2018). Why the Morandi Bridge collapsed in Genoa, Italy?, *El Universal*, Mexico.

[8] Penn, A. (2018). The deadliest bridge collapses in the US in the last 50 years, *CNN*, USA.

[9] Russillo, A.F., Failla, G. (2020). On the free vibrations of locally-resonant structures, *Computers and Structures*, 241, 1–10.

[10] Quintana, J.A. (2004). A global search method for damage detection in general structures, Master's Thesis, *Purdue University*, USA.

[11] Carden, E.P., Fanning, P. (2004). Vibration based condition monitoring: A review, *Structural Health Monitoring*, 3, 355–377.

[12] Fan, W., Qiao, P.Z. (2011). Vibration-based damage identification methods: a review and comparative study, *Structural Health Monitoring*, 10(1), 83–111.

[13] Miyamoto, A., Yabe, A. (2011). Bridge condition assessment based on vibration responses of passenger vehicle, *Journal of Physics: Conference Series*, 305, 1–10.

[14] Kato, M., Shimada, S. (1986). Vibration of PC bridge during failure process, *Journal of Structural Engineering*, 112(7), 692–1703.

[15] Turner, J.D., Pretolve, A.J. (1988). A study of the spectrum of traffic-induced bridge vibration, *Journal of Sound and Vibration*, 122, 31–42.

[16] Allampalli, S., Fu, G., Dillon, E.W. (1995). On the use of measured vibration for detecting bridge damages, in: Proceedings of the *Fourth International Bridge Engineering Conference*.

[17] Allemang, R.J., Brown, D.L. (1982). A correlation coefficient for modal vector analysis, in: Proceedings of the 1st International Modal Analysis Conference.

[18] Ewins, D.J. (2000). Modal testing, practice and application, 2nd edition, *Research Studies Press LTD*, Hertfordshire, England.

[19] Bert, C.W. (1993). Relationship between fundamental natural frequency and maxim static deflection for various linear vibratory systems, *Journal of Sound and Vibration*, 162(3), 547–557.

[20] Linag, Z., Lee, G.C. (1994). Damping of structures part I, NCEER Report, *NCEER* 91-0004.

[21] Abdel-Wahab, M.M., De Roeck, G. (1999). Damage detection in bridges using modal curvatures: application to a real damage scenario, *Journal of Sound and Vibration*, 222(2), 217–235.

[22] Salawu, H.J. (1997). Detection of structural damage through changes in frequency: a review, *Engineering Structures*, 19(9), 718–723.

[23] Saitoh, M., Takei, B.T. (1996). Damage estimation and identification of structural faults using modal parameters, in: Proceedings of the *14th International Modal Analysis Conference*.

[24] Pandey, A.K., Biswas, M., Samman, M.M. (1991). Damage location from changes in curvature mode shape, *Journal of Sound and Vibration*, 145(2), 321–332.

[25] Zimmerman, D.C., Kaouk, M. (1994). Structural damage detection using a minimum rank update theory, *Journal of Vibration and Acoustics*, 116, 222–231.

[26] Doebling, S.W., Farrar, C., Prime, M.B. (1998). A summary review of vibrationbased damage identification methods, *The Shock and Vibration Digest*, 30(2), 91– 105.

[27] Zhang, Z., Liu, G., Wu, Z. (2011). Disadvantage of modal analysis for safety assessment shown by vibration examples in concrete structures, in: Proceedings of the *International Conference on Electric Technology and Civil Engineering*.

[28] Kong, X., Cai, C.S., Hu, J. (2017). The state-of-the-art on framework of vibrationbased structural damage identification for decision making, *Applied Sciences*, 7(497), 1–31.

[29] Liew, K.M., Wang, Q. (1998). Application of wavelet theory for crack identification in structures, *Journal of Engineering Mechanics*, 124(2), 152–157.

[30] Vadlamani, S., Arun, C.O. (2020). A stochastic B-spline wavelet on the interval finite element method for beams, *Computers and Structures*, 233, 1–16.

[31] Hou, Z., Noori, M., Amand, R.S. (2000). Wavelet-based approach for structural damage detection, *Journal of Engineering Mechanics*, 126(7), 677–683.

[32] Lee, Y.Y., Liew, K.M. (2001). Detection of damage locations in a beam using the wavelet analysis, *International Journal of Structural Stability and Dynamics*, 1(3), 455–465.

[33] Hong, J.C., Kim, Y.Y., Lee, H.C., Lee, Y.W. (2002). Damage detection using the Lipschitz exponent estimated by the wavelet transform: Applications to vibration modes of a beam, *International Journal of Solids and Structures*, 39(7), 1803–1816.

[34] Machorro-Lopez, J.M., Amezquita-Sanchez, J.P., Valtierra-Rodriguez, M., Carrion-Viramontes, F.J., Quintana-Rodriguez, J.A., Valenzuela-Delgado, J.I. (2021). Wavelet energy accumulation method applied on the Rio Papaloapan Bridge for damage identification, *Mathematics*, 9(422), 1–30.

[35] Machorro-López, J.M., Carrión-Viramontes, F.J., Quintana-Rodríguez, J.A., Valenzuela-Delgado, J.I., Anaya-Díaz, M., Martínez-Trujano, L.A., Gasca-Zamora, H.M., Hernández-Figueroa, J.A., Hernández-Guzmán, A., Martínez-Madrid, M. (2020). Desarrollo del método de acumulación de energía wavelet para la identificación de daño y su aplicación en el Puente Río Papaloapan, *Publicación Técnica IMT* No. 579, 1-79.

[36] Alvandi, A., Bastien, J., Grégoire, E., Jolin, M. (2009). Bridge integrity assessment by continuous wavelet transforms, *International Journal of Structural Stability and Dynamics*, 9(1), 11–43.

[37] Zhu, X.Q., Hao, H. (2009). Damage detection of RC slabs using nonlinear vibration features, *International Journal of Structural Stability and Dynamics*, 9(4), 687–709.

[38] Beheshti-Aval, S.B., Taherinasab, M., Noori, M. (2011). Using harmonic class loading for damage identification of plates by wavelet transformation approach, *Smart Structures and Systems*, 8(3), 253–274.

[39] Machorro-Lopez, J.M., Bellino, A., Marchesiello, S., Garibaldi, L. (2012). Damage detection for beams subject to moving loads based on wavelet transforms,

in: Proceedings of the *Eleventh International Conference on Computational Structures Technology*.

[40] Law, S.S., Zhu, X.Q., Tian, Y.J., Li, X.Y., Wu, S.Q. (2013). Statistical damage classification method based on wavelet packet analysis, *Structural Engineering and Mechanics*, 46(4), 459–486.

[41] Perez-Ramirez, C.A., Amezquita-Sanchez, J.P., Adeli, H., Valtierra-Rodriguez, M., Camarena-Martinez, D., Romero-Troncoso, R.J. (2016). New methodology for modal parameters identification of smart civil structures using ambient vibrations and synchrosqueezed wavelet transform, *Journal of Engineering Applications of Artificial Intelligence*, 48, 1–12.

[42] Xu, Y.L., Chen, J. (2004). Structural damage detection using empirical mode decomposition: experimental investigation, *Journal of Engineering Mechanics*, 130(11), 1279–1288.

[43] Chen, J. (2009). Application of empirical mode decomposition in structural health monitoring: some experience, *Advances in Adaptive Data Analysis*, 1(4), 601–621.

[44] Yinfeng, D., Yingmin, L., Ming, L. (2010). Structural damage detection using empirical-mode decomposition and vector autoregressive moving average model, *Soil Dynamics and Earthquake Engineering*, 30(3), 133–145.

[45] Obrien, E.J., Malekjafarian, A., Gonzalez, A. (2017). Application of empirical mode decomposition to drive-by bridge damage detection, *European Journal of Mechanics - A/Solids*, 61, 1–21.

[46] Gao, Y., Ge, G., Sheng, Z., Sang, E. (2008). Analysis and solution to the mode mixing phenomenon in EMD, in: Proceedings of the *Congress on Image and Signal Processing*.

[47] Xu, B., Sheng, Y., Li, P., Cheng, Q., Wu, J. (2019). Causes and classification of EMD mode mixing, *Vibroengineering*, 22, 158–164.

[48] Omenzetter, P., Brownjohn, J.M. (2006). Application of time series analysis for bridge monitoring, *Smart Materials and Structures*, 15(1), 129–138.

[49] Kopsaftopoulos, F.P., Fassois, S.D. (2010). Vibration based health monitoring for a lightweight truss structure: experimental assessment of several statistical time series methods, *Mechanical Systems and Signal Processing*, 24(7), 1977–1997.

[50] Mei, Q., Gul, M. (2016). A fixed-order time series model for damage detection and localization, *Journal of Civil Structural Health Monitoring*, 6, 763–777.

[51] Kang, J., Liu, L., Zhou, S.D., Wang, D.Y., Ma, Y.C. (2020). A novel recursive modal parameter estimator for operational time-varying structural dynamic systems

based on least squares support vector machine and time series model, *Computers and Structures*, 229, 1–14.

[52] Jiang, X., Adeli, H. (2007). Pseudospectra, MUSIC, and dynamic wavelet neural network for damage detection of highrise buildings, *International Journal for Numerical Methods in Engineering*, 71(5), 606–629.

[53] Osornio-Rios, R.A., Amezquita-Sanchez, J.P., Romero-Troncoso, R.J., Garcia-Perez, A. (2012). MUSIC-ANN analysis for locating structural damages in a truss-type structure by means of vibrations, *Computer-Aided Civil and Infrastructure Engineering*, 27(9), 687–698.

[54] Perez-Ramirez, C.A., Machorro-Lopez, J.M., Valtierra-Rodriguez, M., Amezquita-Sanchez, J.P., Garcia-Perez, A., Camarena-Martinez, D., Romero-Troncoso, R.J. (2020). Location of multiple damage types in a truss-type structure using multiple signal classification method and vibration signals, *Mathematics*, 8(932), 1–16.

[55] Monaco, A., Amoroso, N., Bellantuono, L., Lella, E., Lombardi, A., Monda, A., Tateo, A., Bellotti, R., Tangaro, S. (2019). Shannon entropy approach reveals relevant genes in Alzheimer's disease, *PLoS ONE*, 14(12), 1–29.

[56] Alafeef, M., Fraiwan, M., Alkhalaf, H., Audat, Z. (2020). Shannon entropy and fuzzy C-means weighting for AI-based diagnosis of vertebral column diseases, *Journal of Ambient Intelligence and Humanized Computing*, 11, 2557–2566.

[57] Sun, Z., Liu, P., Wang, Z. (2017). Real-time fault diagnosis method of battery system based on Shannon entropy, *Energy Procedia*, 105, 2354–2359.

[58] Alvarez-Monroy, G., Mejia-Barron, A., Valtierra-Rodriguez, M., Granados-Lieberman, D., Olivares-Galvan, J., Escalera-Perez, R. (2017). A new EMD-Shannon entropy-based methodology for detection of inter-turn faults in transformers, in: Proceedings of the *IEEE International Autumn Meeting on Power*, *Electronics and Computing*.

[59] Moreno-Gomez, A., Amezquita-Sanchez, J.P., Valtierra-Rodriguez, M., Perez-Ramirez, C.A., Dominguez-Gonzalez, A., Chavez-Alegria, O. (2018). EMD-Shannon entropy-based methodology to detect incipient damages in a truss structure, *Applied Sciences*, 8(2068), 1–16.

[60] Amezquita-Sanchez, J.P. (2020). Entropy algorithms for detecting incipient damage in high-rise buildings subjected to dynamic vibrations, *Journal of Vibration and Control*, 1, 1–11.

[61] Shannon, C.E. (1948). A mathematical theory of communication, *Bell System Technical Journal*, 27, 379–423.

[62] Zhong, K.X., Guo, H.L., Zi, H.Z. (2012). Damage detection of concrete structure based on approximate entropy, *Applied Mechanics and Materials*, 226(228), 920–925.

[63] Martins, A.M.B., Simões, L.M.C., Negrão, J.HJ. (2019). Optimization of concrete cable-stayed bridges under seismic action, *Computers and Structures*, 222, 36–47.

[64] An, Y.H., Ou, J.P. (2014). Structural damage localization for a frame structure from changes in curvature of approximate entropy feature vectors, *Nondestructive Testing and Evaluation*, 29, 80–97.

[65] Machorro-Lopez, J.M., Valtierra-Rodriguez, M., Amezquita-Sanchez, J.P., Carrion-Viramontes, F.J., Quintana-Rodriguez, J.A. (2021). A Shannon entropybased methodology to detect and locate cables loss in a cable-stayed bridge, *International Journal of Applied Mechanics*, 13(5), 1–25.

[66] Lin, T.K., Laínez, A.G. (2018). Entropy-based structural health monitoring system for damage detection in multi-bay three-dimensional structures, *Entropy*, 20(1), 1–26.

[67] Kiranyaz, S., Ince, T., Abdeljaber, O., Avci, O., Gabbouj, M. (2019). 1-D convolutional neural networks for signal processing applications, in: Proceedings of the *IEEE International Conference on Acoustics, Speech and Signal Processing*.

[68] Kiranyaz, S., Ince, T., Gabbouj, M. (2016). Real-time patient-specific ECG classification by 1-D convolutional neural networks, *IEEE Transactions on Biomedical Engineering*, 63, 664–675.

[69] Khodabandehlou, H., Pekcan, G., Fadali, M.S. (2019). Vibration-based structural condition assessment using convolution neural networks, *Structural Control and Health Monitoring*, 26, 1–6.

[70] Sarawgi, Y., Somani, S., Chhabra, A., Sangwan, D. (2020). Nonparametric vibration-based damage detection technique for structural health monitoring using 1D CNN, in: Proceedings of the *International Conference on Computer Vision and Image Processing*.

[71] Dorafshan, S., Azari, H. (2020). Evaluation of bridge decks with overlays using impact echo, a deep learning approach, *Automation in Construction*, 113, 1–40.

[72] Gao, Y., Mosalam, K.M. (2018). Deep transfer learning for image-based structural damage recognition, *Computer-Aided Civil and Infrastructure Engineering*, 33, 748–768.

[73] Ren, Y., Huang, J., Hong, Z., Lu, W., Yin, J., Zou, L., Shen, X. (2020). Imagebased concrete crack detection in tunnels using deep fully convolutional networks, *Construction and Building Materials*, 234, 1–12. [74] Lei, G., Liao, Q., Patil, S. (2019). A fractal model for relative permeability in fractures under stress dependence, *Fractals*, 27(6), 1–27.

[75] Moreno-Gomez, A., Machorro-Lopez, J.M., Amezquita-Sanchez, J.P., Perez-Ramirez, C.A., Valtierra-Rodriguez, M. (2020). A. Dominguez-Gonzalez, Fractal dimension analysis for assessing the health condition of a truss structure using vibration signals, *Fractals*, 28(7), 1–14.

[76] Candès, E., Li, X., Ma, Y., Wright, J. (2011). Robust principal component analysis?, *Journal of the ACM*, 58, 1–37.

[77] Bellino, A., Fasana, A., Garibaldi, L., Marchesiello, S. (2010). PCA-based detection of damage in time-varying systems, *Mechanical Systems and Signal Processing*, 24, 2250–2260.

[78] Bellino, A., Machorro-Lopez, J.M., Marchesiello, S., Garibaldi, L. (2012). Damage detection in structures under variations of temperature and clamping conditions, in: Proceedings of the *XVIIIth Symposium on Vibrations, Shocks & Noise*.

[79] Machorro-Lopez, J.M., Bellino, A., Garibaldi, L., Adams, D.E. (2011). PCAbased techniques for detecting cracked rotating shafts including the effects of temperature variations, in: Proceedings of the *6th International Conference on Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques*.

[80] Mujica, L.E., Ruiz, M., Pozo, F., Rodellar, J., Güemes, A. (2014). A structural damage detection indicator based on principal component analysis and statistical hypothesis testing, *Smart Materials and Structures*, 23, 1–12.

[81] Mujica, L.E., Rodellar, J., Fernandez, A., Guemes, A. (2011). Q-statistic and T2statistic PCA-based measures for damage assessment in structures, *Structural Health Monitoring*,10, 539–553.

[82] Wang, X., Gao, Q., Liu, Y. (2020). Damage detection of bridges under environmental temperature changes using a hybrid method, *Sensors*, 20, 1–20.

[83] Astiz, M.A. (1997). Composite construction in cable-stayed bridge towers, *The International Conference on Composite Construction-Conventional and Innovative*, Innsbruck, Austria.

[84] ASTM Standard A148/A 148M-15a. (2015). Standard specification for steel castings, high strength, for structural purposes, *ASTM International*, West Conshohocken, Pensilvania, EUA.

[85] Aguirre, A., Carbajal, J. (2000). Análisis en el tirante 11 del Puente Papaloapan, *Corporación Mexicana de Investigación de Materiales S.A. de C.V.*, Reporte interno AF-IFT/00087, Saltillo, Coahuila, México. [86] López, A., Poblano, C. (2000). Análisis de falla y pruebas de fatiga del anclaje desprendido del tirante 11, lado agua, torre 3, del Puente Río Papaloapan, *Instituto Mexicano del Transporte*, Reporte interno EQ001/00, Sanfandila, Querétaro, México.

[87] Terán, J., Arroyo, M., Lomelí, M., Martínez, M. (2015). Análisis de falla del elemento de sujeción del tirante 1, semiarpa 5, *Instituto Mexicano del Transporte*, Informe de servicio E-010/2015, Sanfandila, Querétaro, México.

[88] Sierra-Pérez, J., Torres-Arredondo, M.A., Alvarez-Montoya, J. (2017). Damage detection methodology under variable load conditions based on strain field pattern recognition using FBGs, nonlinear principal component analysis, and clustering techniques, *Smart Materials and Structures*, 27(1), 1–8.

[89] Liu, E. et al. (2017). Microseismic events enhancement and detection in sensor arrays using autocorrelation-based filtering, *Geophysical Prospecting*, 65(6), 1496–1509.

[90] Rangel-Magdaleno, J. et al. (2016). Vibration analysis of partially damaged rotor bar in induction motor under different load condition using DWT, *Shock and Vibration*, 2016, 1–12.

[91] Box, G. et al. (2015). Time series analysis: forecasting and control, *John Wiley* & *Sons*.

[92] Yanez-Borjas, J.J. et al. (2019). Nonlinear mode decomposition-based methodology for modal parameters identification of civil structures using ambient vibrations, *Measurement Science and Technology*, 31(1), 1–8.

[93] Farrar, C., Worden, K. (2013). Structural health monitoring: a machine learning perspective, *Wiley*.

[94] Saucedo-Dorantes, J.J. et al. (2019). Multiple-fault detection and identification scheme based on hierarchical self-organizing maps applied to an electric machine, *Applied Soft Computing*, 81, 1–8.

[95] Toma, R.N., Prosvirin, A.E., Kim, J.M. (2020). Bearing fault diagnosis of induction motors using a genetic algorithm and machine learning classifiers, *Sensors*, 20(7), 1–19.

[96] Alotaiby, T.N. et al. (2019). ECG-based subject identification using statistical features and random forest, *Journal of Sensor and Actuator Networks*, 2019, 1-13.

[97] Asadur Rahman, M. et al. (2020). Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal, *Egyptian Informatics Journal*, 21(1), 23-35.

[98] Finotti, R.P. et al. (2019). An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements, Latin American *Journal of Solids and Structures*, 16(2), 1-17.

[99] Yanez-Borjas, J.J. et al. (2020). Statistical time features for global corrosion assessment in a truss bridge from vibration signals, *Measurement*, 160, 1-8.

[100] Wang, X. et al. (2015). Bearing fault diagnosis based on statistical locally linear embedding, *Sensors*, 15(7), 16225-16247.

[101] Yanez-Borjas, J.J. et al. (2020). Statistical time features-based methodology for fatigue cracks detection in a four-story building, in: Proceedings of the *International Autumn Meeting on Power, Electronics and Computing*.

[102] Saucedo-Dorantes, J.J. et al. (2018). Diagnosis methodology for identifying gearbox wear based on statistical time feature reduction, in: Proceedings of the *Institution of Mechanical Engineering Part C*.

[103] Sharma, A., Amarnath, M., Kankar, P. (2016). Feature extraction and fault severity classification in ball bearings, *Journal of Vibration and Control*, 22(1), 176-192.

[104] Hadiyoso, S., Rizal, A., Aulia, S. (2019). ECG based person authentication using empirical mode decomposition and discriminant analysis, *Journal of Physics: Conference Series*, 1367, 1-10.

[105] Igba, J. et al. (2016). Analysing RMS and peak values of vibration signals for condition monitoring of wind turbine gearboxes, *Renewable Energy*, 91, 90-106.

[106] Zhang, W., Zhu, J., Gao, T. (2016). Dynamic problems, in Topology Optimization Engineering Structure Design, *Elsevier*, 1, 61–105.

[107] Xu, S. et al. (2020). The fuzzy comprehensive evaluation (FCE) and the principal component analysis (PCA) model simulation and its applications in water quality assessment of Nansi Lake Basin, China, *Environmental Engineering Research*, 26(2), 1–1.

[108] Brunton, S.L., Kutz, J.N. (2019). Data-driven science and engineering: machine learning, dynamical systems, and control, *Cambridge University Press*.

[109] Kouadri, A. et al. (2020). Hidden Markov model based principal component analysis for intelligent fault diagnosis of wind energy converter systems, *Renewable Energy*, 150, 1–8.

[110] Ma, H.W., Lin, Y.Z., Nie, Z.H. (2019). Physical interpretation of principal component analysis for structural dynamics through string vibration, *International Journal of Structural Stability and Dynamics*, 19(9), 1–8.

[111] Kumar, K., Biswas, P.K., Dhang, N. (2020). Time series-based SHM using PCA with application to ASCE benchmark structure, *Journal of Civil Structural Health Monitoring*, 10(5), 899–911.

[112] Li, W., Huang, Y. (2020). A combined method of cross-correlation and PCAbased outlier algorithm for detecting structural damages on a jacket oil platform under random wave excitations, *Applied Ocean Research*, 102, 1–8.

[113] De Maesschalck, R., Jouan-Rimbaud, D., Massart, D.L. (2000). The Mahalanobis distance, *Chemometrics and Intelligent Laboratory System*, 50(1), 1–18.

[114] Kotu, V., Deshpande, B. (2019). Anomaly Detection, *Elsevier*, 1, 307–342.

[115] Schwarz, D.M. et al. (2012). Semi-supervised spike sorting using pattern matching and a scaled Mahalanobis distance metric, *Neuroscience Methods*, 206(2), 120–131.

[116] Han, J., Kamber, M., Pei, J. (2012). Outlier detection, *Data Mining*, 1, 543–584.

[117] Worden, K., Manson, G., Fieller, N.R.J. (2000). Damage detection using outlier analysis, *Journal of Sound and Vibration*, 229(3), 647-667.



Km 12+000 Carretera Estatal 431 "El Colorado Galindo" Parque Tecnológico San Fandila, Mpio. Pedro Escobedo, Querétaro, México. C.P. 76703 Tel: +52 (442) 216 97 77 ext. 2610 Fax: +52 (442) 216 9671

publicaciones@imt.mx

http://www.imt.mx/