

Metodología basada en Aprendizaje Automático para la Detección de Corrosión en una Armadura en Configuración Puente

Machine Learning-Based Methodology for Corrosion Detection in a Truss-Type Bridge

Alan G. Lujan-Olalde¹, Andrea V. Perez-Sanchez¹, Jose M. Machorro-Lopez², Martin Valtierra-Rodriguez¹, Salvador Calderon-Uribe¹, Juan P. Amezcua-Sanchez^{1*}

¹ENAP-RG, CA Sistemas Dinámicos, Facultad de Ingeniería, Departamento de Electromecánica, Universidad Autónoma de Querétaro, Campus San Juan del Río, CP. 76807, San Juan del Río, Querétaro, México.

²Investigador SECIHTI—Instituto Mexicano del Transporte, km 12 Carretera Estatal No. 431 “El Colorado-Galindo” San Fandila, Pedro Escobedo, CP. 76703, Querétaro, México.
jamezcua@uaq.mx

* Autor de correspondencia

Resumen

La detección temprana de la corrosión en estructuras metálicas constituye un reto fundamental dentro del monitoreo de salud estructural, ya que este fenómeno representa una de las principales causas de deterioro en puentes metálicos. En este trabajo se presenta una metodología basada en el análisis de señales vibratorias, obtenidas experimentalmente de una armadura metálica en configuración de puente, tanto en condiciones sanas como en condiciones de daño por corrosión inducida. La respuesta vibratoria monitoreada se descompone mediante la transformada wavelet discreta, lo que permite analizar de manera detallada sus componentes en diferentes bandas de frecuencia y extraer indicadores no lineales basados en la dimensión fractal de cada banda. En particular, en este trabajo se investiga el desempeño de tres indicadores de fractalidad, Katz, Petrosian y Sevcik, con el objetivo de evaluar su capacidad para determinar la condición estructural. Posteriormente, se aplica un análisis de varianza para identificar las características, análisis combinado de wavelets y fractalidad, con mayor capacidad para ser asociadas al fenómeno estudiado. Finalmente, las características seleccionadas son utilizadas para entrenar y validar un clasificador basado en K-vecinos más cercanos, con el fin de automatizar el diagnóstico de la estructura. Los resultados obtenidos demuestran que la propuesta es capaz de distinguir de manera exacta entre una estructura en buen estado y aquella afectada por corrosión, lo que la convierte en una alternativa prometedora para la detección temprana y la gestión del mantenimiento.

Palabras clave: Corrosión estructural; señales vibratorias; Transformada Wavelet Discreta (DWT); selección de características; dimensión fractal; ANOVA; detección de daño.

Introducción

En la última década, el monitoreo de la infraestructura civil, particularmente de los puentes, ha adquirido una creciente relevancia en la investigación, ya que su mantenimiento y la detección de fallas resultan fundamentales (Mishra *et al.*, 2022). En este sentido, el término monitoreo de la salud estructural (MSE) se define como el proceso mediante el cual se evalúa el estado de la infraestructura civil, utilizando principalmente sus propiedades físicas (Yang *et al.*, 2021). De manera particular, MSE integra diversos procedimientos que van desde inspecciones visuales hasta la aplicación de técnicas avanzadas, como radares, dispositivos térmicos o cámaras, entre otros (Yang *et al.*, 2021). Sin embargo, a pesar de los resultados obtenidos, estas metodologías presentan limitaciones para evaluar de manera continua la condición estructural, destacando (1) la necesidad de acceder de forma inmediata a la zona dañada, lo cual no siempre es posible, así como (2) restringir temporalmente, en ciertos casos, la operación de la estructura para llevar a cabo la evaluación, lo que implica pérdidas de tiempo y recursos para los usuarios. Ante estas desventajas, el análisis de las respuestas vibratorias de las estructuras civiles se plantea como una alternativa viable para evaluar su estado de manera continua, evitando los conflictos antes mencionados (Zhang *et al.*, 2022). En particular, un esquema de MSE basado en señales de vibración se compone de tres etapas principales: (1) adquisición o monitoreo de la respuesta vibratoria de la estructura, (2) análisis o procesamiento de los datos adquiridos y (3) su interpretación (Amezcua-Sanchez & Adeli, 2016). La etapa



dos, es decir, el análisis de los datos adquiridos constituye un reto, ya que las respuestas vibratorias medidas en una estructura civil se caracterizan por sus características no estacionarias, variantes a lo largo del tiempo, y embebidas en una gran cantidad de ruido. Cuando la condición física de la estructura sufre una alteración, las señales vibratorias se modifican de cierta manera, de tal modo, que al cuantificar dichos cambios es posible llevar a cabo la detección de daño (Zhang *et al.*, 2022). Por lo tanto, se requiere de métodos o técnicas de procesamiento de señales capaces de identificar características o variaciones relevantes en las respuestas vibratorias, con el fin de evaluar con exactitud el estado de la infraestructura civil (Zhang *et al.*, 2022).

Durante la última década se han presentado diversos métodos para evaluar el estado de las estructuras empleando la respuesta vibratoria de las mismas, siendo la transformada de Fourier la más utilizada para este propósito (He *et al.*, 2021; Telukunta & Bala, 2022). En particular, esta técnica resulta eficaz cuando las señales presentan un comportamiento cuasi estacionario y contienen poco ruido, características que suelen cumplirse en elementos simples, como las vigas, pero condiciones que difícilmente se encuentran en estructuras más complejas. Con el fin de aminorar estas limitaciones, se han investigado otros métodos tales como la transformada Hilbert-Huang (HHT, por sus siglas en inglés) (Mousavi *et al.*, 2022). En particular, la HHT se caracteriza por su adaptabilidad, ya que permite descomponer señales no estacionarias en diferentes bandas de frecuencia de acuerdo con la información frecuencial que la señal contiene, sin embargo, este método presenta una gran desventaja conocida como el fenómeno de mezcla de modos, el cual indica que la técnica puede asignar componentes de frecuencia a bandas incorrectas, afectando la exactitud en la evaluación del estado estructural (Singh *et al.*, 2021). Para reducir este problema, en los últimos años se han propuesto diversos enfoques híbridos que combinan más de una técnica de análisis de datos. Por ejemplo, la integración de la descomposición empírica de modos con la entropía de Shannon (Moreno-Gomez *et al.*, 2018), con indicadores estadísticos o la distancia de Mahalanobis (Yanez-Borjas *et al.*, 2021), entre otras. Sin embargo, estas alternativas, si bien mejoran la caracterización de las señales vibratorias, se mantiene la necesidad de proponer nuevas estrategias de análisis que permitan identificar patrones o cambios relevantes en las respuestas vibratorias, con el objetivo de diagnosticar de forma exacta y oportuna la condición de las infraestructuras civiles.

En particular, la transformada wavelet se ha consolidado en los últimos años como una herramienta efectiva para el análisis de señales no estacionarias, ya que permite descomponer la señal en diferentes niveles multiescalares y distinguir entre componentes de aproximación y de detalle. En este sentido, Piątkowska & Dobrzycki (2020) aplicaron la transformada wavelet para detectar daños en elementos de acero, demostrando su utilidad en el ámbito de las estructuras metálicas. De manera complementaria, en otro estudio propuesto por Huang *et al.* (2010) se exploró la transformada wavelet en conjunto con la dimensión fractal para detectar daños en vigas, concluyendo que la dimensión fractal permite obtener características relevantes en las señales analizadas (Moreno-Gomez *et al.*, 2020; Machorro-Lopez *et al.*, 2025).

De acuerdo con lo expuesto anteriormente, el presente trabajo propone una metodología basada en técnicas de aprendizaje automático para la detección de daños por corrosión en estructuras metálicas, utilizando como caso de estudio una armadura metálica tipo puente, conformada por nueve cubos y sometida a vibraciones forzadas mediante un excitador electrodinámico. La metodología desarrollada se basa en la descomposición de las respuestas vibratorias obtenidas experimentales en diferentes bandas de frecuencia, consideradas como componentes de aproximación y de detalle, mediante la transformada wavelet discreta (DWT, por sus siglas en inglés). Posteriormente, cada banda de frecuencia se analiza mediante la dimensión fractal con la finalidad de extraer e identificar características relevantes. En particular, se analizan tres algoritmos de dimensión fractal: Katz, Petrosian y Sevcik, con el fin de identificar cuáles resultan más representativos para la caracterización del daño por corrosión. Posteriormente, las características obtenidas son evaluadas mediante un análisis de varianza (ANOVA) con el fin de determinar su significancia estadística y, una vez seleccionadas las más relevantes, se emplean en el entrenamiento y validación de modelos de aprendizaje automático orientados al diagnóstico estructural, utilizando como clasificador principal el algoritmo de K-vecinos más cercanos (KNN) para la automatización del diagnóstico. Los resultados muestran que la metodología propuesta alcanza una eficiencia del 100% para distinguir entre una estructura sana y una corroída.

Marco Teórico

Esta sección presenta los fundamentos matemáticos de las técnicas de procesamiento utilizadas para la evaluación de la condición del puente, los cuales son descritos a continuación de manera detallada.



Transformada Wavelet Discreta (DWT)

La DWT es un método de análisis multiresolución que permite descomponer una señal en diferentes escalas de frecuencia, lo que facilita la identificación de singularidades o características que puedan ser relacionadas con la condición de una estructura civil (Huang *et al.*, 2010). Su cálculo se basa en el algoritmo de Mallat, también conocido como algoritmo piramidal, el cual aplica de manera iterativa un par de filtros complementarios: un filtro paso bajas $h(n)$ que genera las aproximaciones y un filtro paso altas $g(n)$ que produce los detalles. En cada iteración, la salida del filtro paso bajas se utiliza como nueva entrada para el siguiente nivel de descomposición, generando así una estructura jerárquica de coeficientes.

Matemáticamente, para una señal discreta $x(n)$, la DWT en el nivel j es definida como:

$$A_j(k) = \sum_n x(n) \cdot h(2k - n) \quad (1)$$

$$D_j(k) = \sum_n x(n) \cdot g(2k - n) \quad (2)$$

donde $A_j(k)$ representa los coeficientes de aproximación y $D_j(k)$ los coeficientes de detalle en el nivel j . El algoritmo de Mallat organiza este proceso en forma de árbol binario, en el cual cada nodo corresponde a un nivel de resolución distinto, permitiendo un análisis eficiente y jerárquico de la señal.

Indicadores de dimensión fractal

La dimensión fractal se caracteriza por evaluar la dimensión geométrica de una señal, aspecto especialmente útil en entornos donde la presencia de daño altera la regularidad de la respuesta estructural. En términos generales, un índice fractal cuantifica la repetitividad geométrica de la señal, es decir, qué tanto se repite un patrón en el tiempo y cómo esta repetición refleja la complejidad de su forma. El valor obtenido se encuentra típicamente entre 1 y 2, donde valores más cercanos a 1 indican que la señal tiene poca repetitividad geométrica, es decir irregularidad, mientras que valores próximos a 2 reflejan una geometría más simple o regular. Para evaluar esta similitud geométrica en señales temporales, se han propuesto diversos algoritmos, entre los que destacan los de Katz, Petrosian y Sevcik, los cuales se describen a continuación:

Katz

El índice de Katz estima la dimensión fractal de una señal midiendo la relación entre su longitud total y la distancia máxima desde el punto inicial. Para una señal discreta $x(t)$ de longitud N , representada por puntos (x_i, y_i) , se define:

$$D_K = \frac{\log_{10}(N)}{\log_{10}(N) + \log_{10}\left(\frac{d}{L}\right)} \quad (3)$$

donde L :

$$L = \sum_{i=1}^{N-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (4)$$

es la longitud euclidiana de la trayectoria de la señal, y d es la distancia máxima entre el primer punto y cualquier otro de la secuencia (Katz, 1988), la cual es estimada de la siguiente manera:

$$d = \max_i \sqrt{(x_i - x_1)^2 + (y_i - y_1)^2} \quad (5)$$

Petrosian

La dimensión de Petrosian se basa en la frecuencia de cambios abruptos en la señal. En particular, para una serie temporal $x(1), x(2), \dots, x(N)$, primeramente, la señal es binarizada con respecto a la media, asignando valores $+1$ o -1 .



$$z_i = \begin{cases} 1, & x_i > \text{media}(x) \\ -1, & x_i \leq \text{media}(x) \end{cases} \quad (6)$$

Posteriormente, es calculado el número de cambios de signo en la secuencia:

$$N_{\Delta} = \sum_{i=1}^{N-1} \frac{|z_{i+1} - z_i|}{2} \quad (7)$$

donde: $z_i \in -1, 1$. Finalmente, la dimensión fractal de Petrosian (1995) es estimada por:

$$D_p = \frac{\log_{10}(N)}{\log_{10}(N) + \log_{10}\left(\frac{N}{N+0.4N_{\Delta}}\right)} \quad (8)$$

Sevcik

La dimensión de Sevcik se basa en la longitud normalizada de la curva de la señal en una ventana unitaria. Dada una señal discreta (x_i, y_i) de longitud N , primeramente es normaliza cada muestra de la señal de la siguiente manera:

$$x_i^* = \frac{x_i - \min(x)}{\max(x) - \min(x)}, y_i^* = \frac{y_i - \min(y)}{\max(y) - \min(y)} \quad (9)$$

Posteriormente, la longitud de la señal normalizada es obtenida por:

$$L = \sum_{i=1}^{N-1} \sqrt{(x_{i+1}^* - x_i^*)^2 + (y_{i+1}^* - y_i^*)^2} \quad (10)$$

Finalmente, la dimensión fractal de Sevcik se calcula de la siguiente manera (Sevcik, 1998):

$$D_s = 1 + \frac{\ln(L) + \ln(2)}{\ln(2(N-1))} \quad (11)$$

Selección de características mediante ANOVA

ANOVA es un método estadístico que se caracteriza por evaluar la capacidad discriminante de un conjunto de características mediante la comparación entre la variabilidad existente entre clases (por ejemplo, estructuras en condición sana y estructuras con daño) y la variabilidad dentro de cada clase (Montgomery, 2013). En otras palabras, una mayor proporción de variabilidad entre clases respecto a la variabilidad intracase implica que la característica analizada posee un mayor poder para distinguir adecuadamente entre los diferentes grupos.

Para cada conjunto de características, el método calcula un valor de probabilidad (p-valor), el cual expresa el grado de significancia estadística de las diferencias observadas entre grupos. De manera particular, un p-valor alto (mayor al umbral comúnmente establecido en 0.05) indica que la característica presenta diferencias estadísticamente significativas y, por lo tanto, resulta relevante para la tarea de clasificación. Por el contrario, un p-valor bajo señala que la característica carece de un adecuado poder discriminante, ya que no permite distinguir de forma confiable entre las condiciones estructurales analizadas.

Por lo tanto, el ANOVA se considera como un criterio de selección de características, ya que permite priorizar aquellas características que presentan mayor capacidad de diferenciación en función de su significancia estadística, el método contribuye a la construcción de modelos de análisis más robustos, basados en descriptores con verdadero valor informativo y capacidad para mejorar el desempeño en tareas de clasificación y diagnóstico estructural.



K-vecinos más cercanos (KNN)

El algoritmo de K-vecinos más cercanos (KNN) es un clasificador supervisado basado en la proximidad entre muestras en el espacio de características. La idea fundamental consiste en asignar a una muestra desconocida la clase más frecuente entre sus K vecinos más cercanos previamente etiquetados (Cover & Hart, 1967).

KNN se basa en analizar un conjunto de entrenamiento formado por pares (x_i, y_i) , donde: x_i es un vector de características con dimensión d y y_i es la etiqueta de clase (por ejemplo, en este caso 0 = sano, 1 = dañado).

Para clasificar una nueva muestra x_q , se calculan las distancias entre x_q y todas las muestras de entrenamiento. La métrica más utilizada es la distancia euclidiana, definida por:

$$d(x_q, x_i) = \sqrt{\sum_{j=1}^d (x_{qj} - x_{ij})^2} \quad (12)$$

Una vez obtenidas las distancias, se seleccionan los K vecinos más cercanos a x_q . La clase asignada se determina por votación mayoritaria: se cuenta cuántos vecinos pertenecen a cada clase y se asigna la más cercana:

$$\hat{y}_q = \arg \max_{c \in \{0,1\}} \sum_{x_i \in N_K(x_q)} 1(y_i = c) \quad (13)$$

En particular, el clasificador KNN es seleccionado en este trabajo porque es simple, no requiere entrenamiento y ofrece buen desempeño con conjuntos de datos pequeños (Cover & Hart, 1967).

Metodología propuesta

La metodología propuesta para la detección de daño por corrosión en armaduras es presentada esquemáticamente en la Figura 1. Esta se compone de cinco etapas principales: (1) preparación de la base de datos, (2) descomposición de señales mediante la DWT, (3) extracción de características fractales, (4) selección de las características más adecuadas para relacionarlas con el fenómeno estudiado (ANOVA) y (5) clasificación mediante el algoritmo de KNN. El uso de KNN se justifica por su simplicidad, baja demanda computacional y capacidad de adaptarse bien cuando se tienen muestras moderadas y características discriminantes claras. En la literatura, se ha observado que los clasificadores KNN pueden lograr buenos desempeños con características bien seleccionadas y menos carga de entrenamiento en comparación con SVM u otros métodos más complejos (Bathia, 2010).

Primeramente, es generada una base de datos a partir de las señales adquiridas mediante un sensor de aceleración triaxial montado en la armadura metálica en configuración de puente. Las señales, correspondientes a la respuesta vibratoria de la estructura, son adquiridas en dos condiciones: estado sano y estado dañado por corrosión. Posteriormente, las señales monitoreadas son descompuestas en diversas bandas de frecuencia utilizando la DWT. Esta técnica ha demostrado ser adecuada para el análisis de señales no estacionarias, como las obtenidas en la respuesta vibratoria, ya que permite resaltar y conservar patrones que pueden asociarse con la condición de una estructura civil (Han *et al.*, 2020; Knitter-Piątkowska & Dobrzycki, 2020).

En la tercera etapa, una vez descompuesta la señal en sus diferentes bandas de frecuencia, se lleva a cabo la extracción de características mediante métricas de complejidad fractal, con el propósito de identificar características relevantes en las señales que puedan ser asociadas con la condición de la estructura. En este trabajo se investigan tres indicadores: Katz, Petrosian y Sevcik, con el fin de evaluar la complejidad geométrica de las señales descompuestas y así identificar características potencialmente asociadas con la condición estructural. Posteriormente, las características obtenidas en el paso anterior son analizadas mediante ANOVA, con el objetivo de seleccionar aquellas con mayor capacidad discriminante entre el estado



sano y el dañado. Finalmente, las características seleccionadas se utilizan como entradas para entrenar y validar un clasificador KNN, encargado de determinar automáticamente la condición de la estructura. De este modo, la integración de la DWT, los indicadores fractales, el análisis ANOVA y el clasificador KNN constituye una metodología robusta para la detección temprana de daño por corrosión en armaduras metálicas.

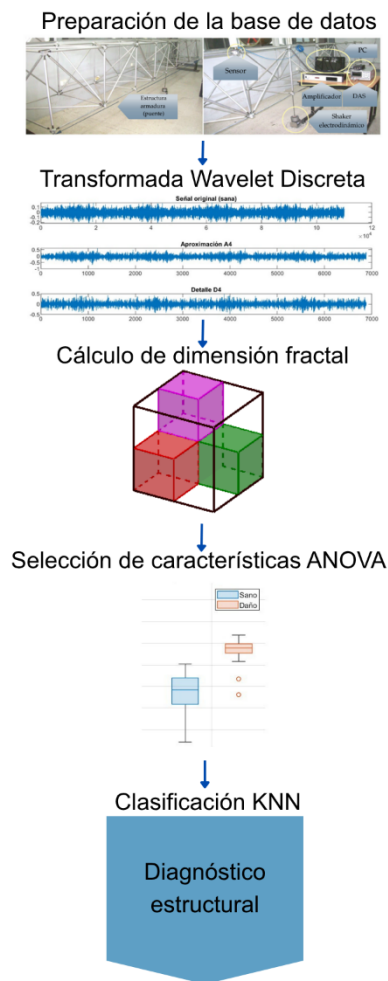


Figura 1. Metodología propuesta.

Puesta experimental

Armadura y disposición de sensores

Con el fin de validar la metodología propuesta, se empleó una armadura metálica modular configurada como puente, integrada por nueve cubos (Figura 2). El montaje experimental se realizó en la Universidad Autónoma de Querétaro, Campus San Juan del Río, México. La estructura fue fabricada con tubos de aluminio 6061-T6 y presenta una longitud total de 6.40 m, una altura de 0.71 m y un ancho de 0.71 m; las barras horizontales y verticales miden 0.70 m, las diagonales $0.70\sqrt{2}$ m (≈ 0.99 m) y el diámetro de las barras es de 19 mm. Las vibraciones se indujeron mediante un excitador electrodinámico Labworks ET-126B, alimentado por un amplificador lineal Labworks PA-138. El sistema de excitación, ubicado en el centro de la estructura, aplicó



ruido blanco gaussiano en el rango de 0–100 Hz, con el objetivo de representar vibraciones asociadas al ruido ambiental y al paso vehicular (Yanez-Borjas, 2021). Por otro lado, la respuesta vibratoria se monitoreó con un acelerómetro triaxial Kistler modelo 8395A, capaz de medir ± 10 g, con una sensibilidad de 400 mV/g y un rango de frecuencia de 0–1000 Hz. La señal monitoreada por el acelerómetro fue adquirida por un sistema de adquisición de 16 bits NI USB-6002. En particular, el sensor se instaló en el cubo 5, aproximadamente en la región central de la estructura, donde se esperan amplitudes de vibración mayores, lo que podría favorecer la detección de cambios sutiles en la respuesta, asociados al estado estructural (Amezquita-Sanchez & Adeli, 2016).

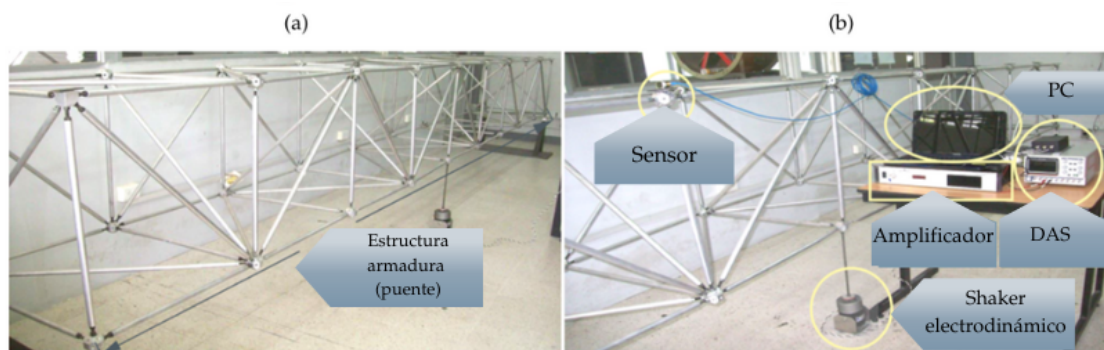


Figura 2. Puesta experimental para validación.

Inducción del daño por corrosión

Las pruebas se realizaron bajo dos condiciones estructurales: estado sano y estado dañado, conformando un conjunto de datos balanceado con 90 muestras en cada caso. El daño fue inducido mediante un proceso de corrosión controlada, ya que los extremos de las barras de aluminio fueron sumergidos en ácido clorhídrico, provocando una pérdida de material y una reducción del diámetro original de 19 mm hasta 11 mm, con una masa final de aproximadamente 360 g frente a los 445 g iniciales. La corrosión fue inducida únicamente en los extremos de las barras (ver Figura 3), los cuales representan zonas críticas de la armadura, como uniones o concentradores de esfuerzo, donde la degradación tiende a iniciarse y comprometer de manera temprana la integridad estructural (Moreno-Gomez *et al.*, 2020). Es muy importante mencionar que la barra dañada fue incorporada en el cubo 1 de la armadura, ubicado en una región alejada del sensor, con el objetivo de validar la metodología propuesta en un escenario donde el daño se presenta distante del punto de monitoreo.




Figura 3. Condiciones de las barras (19 mm de diámetro en toda su longitud) y daño inducido por corrosión con reducción de diámetro de 8 mm en los extremos de la barra.

Adquisición

La respuesta vibratoria del puente fue adquirida empleando una frecuencia de muestreo de 200 Hz durante un tiempo de 20 segundos, lo que permitió obtener 4,000 muestras por prueba. En particular, se realizaron un total de 90 pruebas en condición sana y 90 pruebas en condición dañada, conformando un conjunto balanceado de pruebas experimentales, las cuales sirven como base para el análisis posterior propuesto.

Resultados

En esta sección se presentan los resultados obtenidos a partir de los pasos propuestos en la sección de metodología. En particular, las siguientes subsecciones describen los criterios empleados para la descomposición wavelet, así como ilustraciones que permiten observar gráficamente la descomposición de las señales bajo las condiciones investigadas. Posteriormente, las señales descompuestas son analizadas a través de indicadores fractales, los cuales permiten cuantificar de manera objetiva los cambios sutiles en la geometría de las respuestas vibratorias. Con ello, se procede al proceso de selección de características mediante ANOVA y, finalmente, se presentan los resultados de la etapa de clasificación.

Selección del tipo de mother wavelet y nivel de descomposición

La selección del tipo de ondoleta madre (mother wavelet) y del nivel de descomposición constituye un aspecto clave en el análisis de señales estructurales, especialmente cuando se busca caracterizar respuestas vibratorias sensibles a la presencia de daño. En este trabajo se empleó la transformada wavelet discreta con la ondoleta Daubechies 4 (db4), seleccionada por su eficacia comprobada en aplicaciones de diagnóstico estructural (Han *et al.*, 2020; Zhou *et al.*, 2013). Cabe destacar que la ondoleta db4 se caracteriza por su continuidad suave y su adecuada localización tanto en el dominio temporal como en el frecuencial, cualidades que la hacen apropiada para el análisis de señales no estacionarias, como las que presentan las respuestas dinámicas de estructuras civiles (Han *et al.*, 2020).

En cuanto al nivel de descomposición, en esta investigación se fijó en 4, siguiendo lo reportado en la literatura para señales muestreadas a frecuencias bajas y moderadas, así como para estructuras que presentan modos relevantes en rangos de frecuencia media y baja. Dicho nivel permite capturar de manera adecuada las componentes espectrales donde suelen manifestarse las alteraciones dinámicas inducidas por daño (Zhou *et al.*, 2013).

Extracción de características: análisis DWT y dimensión fractal

Siguiendo los pasos propuestos en la metodología, las respuestas vibratorias de la armadura son analizadas por medio de la DWT con el fin de descomponer la señal en sus diversas bandas de frecuencia.

La Figura 4 y la Figura 5 muestran las señales en condición sana y dañada, respectivamente, junto con sus descomposiciones wavelet hasta el nivel 4. Como se aprecia en estas figuras, existen cambios sutiles en la distribución energética y en la presencia de componentes de alta frecuencia entre ambos estados estructurales. Sin embargo, dichas variaciones son poco evidentes a simple vista y requieren ser cuantificadas mediante un análisis que permita identificar estos cambios sutiles en las descomposiciones.






Figura 4. Aproximaciones y detalles de la señal sana obtenida por medio de la DWT.






Figura 5. Aproximaciones y detalles de la señal correspondiente a corrosión obtenida por medio de la DWT.

Una vez descompuestas todas las señales en sus diferentes bandas de frecuencia, estas son procesadas a través de indicadores de fractalidad, investigándose en este trabajo tres de ellos: Katz, Petrosian y Sevcik. Posteriormente, los valores obtenidos de estos indicadores son evaluados por medio de un análisis estadístico llamado ANOVA con el objetivo de discriminar cuáles presentan mayor capacidad para asociarse al fenómeno de daño por corrosión en la estructura.

Es importante mencionar que de cada señal se descomponen en aproximaciones (A1 a A4) y los detalles (D1 a D4), los cuales capturan las componentes de baja y alta frecuencia respectivamente. Por lo tanto, la combinación de estos tres indicadores aplicados a las 8 bandas de frecuencia, genera en este caso, un total de 72 características por señal, ya que son 8 bandas por 3 indicadores y por 3 ejes de vibración. Por otro lado, si bien la descomposición wavelet genera tanto diferentes bandas de frecuencia de aproximación como de detalle, en este estudio se prioriza el análisis de las diversas bandas de frecuencia de detalle, ya que estos concentran la información de las componentes de alta frecuencia, donde suelen manifestarse las alteraciones locales inducidas por la presencia de daño. En contraste, los coeficientes de aproximación describen las tendencias generales o el comportamiento global de la señal, por lo que resultan menos sensibles a las irregularidades estructurales (Silik *et al.*, 2024). Esta elección permite enfocar el análisis en las variaciones dinámicas más representativas del deterioro. En particular, de acuerdo con el análisis de ANOVA de los diferentes indicadores de fractalidad, el indicador de Petrosian presenta la mayor capacidad discriminante entre las condiciones sana y dañada, mostrando una clara separación en su distribución. Por otro lado, el método de Sevcik también evidencia una diferenciación visible, aunque con menor contraste que Petrosian, mientras que el indicador de Katz manifiesta un ligero traslape entre clases. Estos resultados, ilustrados en la Figura 6 (a, b y c para Katz, Petrosian y Sevcik, respectivamente), sugieren que, aunque la combinación

de múltiples indicadores aporta información complementaria, el índice de Petrosian se posiciona como el más robusto para la caracterización del daño por corrosión en la estructura analizada.




Figura 6. Diagramas de caja de las características fractales más representativas: (a) Katz-D2-X, (b) Petrosian-D2-X y (c) Sevcik-D2-X, comparando la distribución de señales en condición sana y dañada.

Selección de características mediante ANOVA

Para reducir la cantidad de características y conservar únicamente aquellas con mayor capacidad de asociación al fenómeno estudiado, se aplica un análisis ANOVA sobre las 72 características obtenidas a partir de las aproximaciones y detalles de la descomposición wavelet. Sin embargo, dado que los coeficientes de detalle son los que concentran la información dinámica más sensible al daño, por lo que el análisis se enfoca en ellos y la aproximación de nivel 4, resultando en un conjunto final de 45 características. Como métrica se emplea el valor p asociado a cada característica, transformado a escala $-\log_{10}(p)$ para facilitar su interpretación visual.

La Figura 7 presenta el gráfico tipo *bar plot* de $-\log_{10}(p)$, donde una línea punteada roja marca el umbral de significancia estadística ($p = 0.05$). De las 45 características evaluadas, 33 superan dicho umbral, mientras que 12 no alcanzan el criterio establecido. Entre las seleccionadas, destacan particularmente Katz-D2-X, Petrosian-D2-X y Sevcik-D2-X, correspondientes a la banda de frecuencia D2, la cual demuestra la mayor capacidad discriminante para diferenciar entre las condiciones estructurales sana y dañada. Este procedimiento permite reducir el conjunto original, conservando únicamente las características más relevantes para el proceso de clasificación.

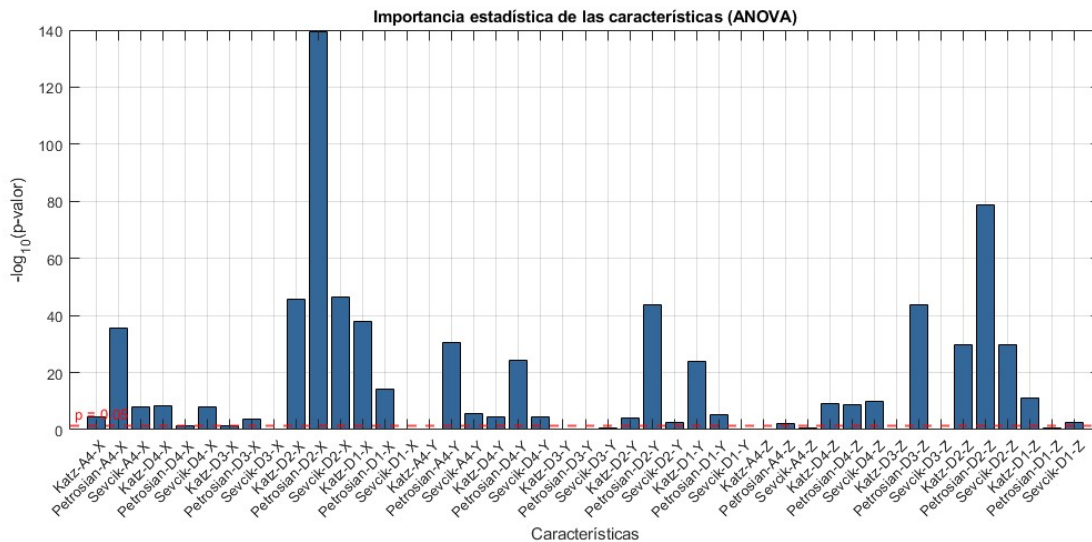


Figura 7. Gráfico de significancia ANOVA.



Clasificación

Con las 33 características más significativas que superan el umbral seleccionadas mediante ANOVA, se evalúa el desempeño del modelo de clasificación supervisada para la detección de daño estructural: KNN. Para ello, el conjunto de datos balanceado de 180 muestras (90 sanas y 90 dañadas) se dividió en 80% para entrenamiento (144 muestras) y 20% para validación (36 muestras, 18 por clase). El modelo KNN logró un desempeño sobresaliente, alcanzando una exactitud del 100.00% en el conjunto de prueba, con 18 verdaderos negativos y 18 verdaderos positivos en la matriz de confusión. Esto indica una clasificación perfecta tanto para estructuras sanas como dañadas en este escenario experimental (ver Figura 8).

Matriz de confusión - KNN

Clase predicha	Sano	Daño	
	18 50.0%	0 0.0%	100% 0.0%
Daño	0 0.0%	18 50.0%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%
	Sano	Daño	
	Clase objetivo		

Figura 8. Matriz de confusión KNN.

Estos resultados demuestran el potencial discriminante de las características fractales extraídas a partir de la transformada wavelet, así como la efectividad del clasificador KNN para la evaluación automática de la condición estructural.

Conclusiones

En este trabajo se propone y valida un enfoque integral para la detección de daños estructurales que combina el procesamiento avanzado de señales, análisis estadístico y técnicas de aprendizaje supervisado. La metodología incluye la descomposición de señales mediante la DWT, la extracción de indicadores de dimensión fractal, específicamente los métodos de Katz, Petrosian y Sevcik, la selección de características mediante ANOVA y la clasificación mediante el algoritmo KNN con el fin de evaluar automáticamente la condición estructural de una armadura en estilo puente.

Los resultados obtenidos demuestran la eficacia del enfoque propuesto, la combinación de las descomposiciones obtenidas por la wavelet con indicadores fractales permite construir un conjunto de características altamente representativas, con capacidad para discriminar de forma robusta entre estructuras sanas y con daño.

El clasificador KNN muestra un desempeño perfecto en este escenario experimental, alcanzando 100% de exactitud para distinguir entre una estructura sana y una expuesta a corrosión. Estos resultados confirman la viabilidad de la metodología propuesta como una herramienta adecuada y confiable para el monitoreo de salud estructural en armaduras metálicas.



Agradecimientos

Este trabajo fue apoyado por el proyecto Fondo para el Fortalecimiento de la Investigación, Vinculación y Extensión (FONFIVE-UAQ 2024), así como por la Secretaría de Ciencias, Humanidades, Tecnologías e Innovación (SECIHTI-México), a través de la beca número 1241417 otorgada a Alan G. Luján-Olalde, y del proyecto número 34/2018 en el marco del programa Investigadoras e Investigadores por México de la SECIHTI (Cátedras SECIHTI). Asimismo, los autores agradecen el apoyo del Sistema Nacional de Investigadoras e Investigadores (SNII)–SECIHTI-México, que otorgó las becas 296574, 161138 y 253652 a Martín Valtierra-Rodríguez, José M. Machorro-López y Juan P. Amézquita-Sánchez, respectivamente.

Referencias

- Amezquita-Sanchez, J. P., & Adeli, H. (2016). Signal processing techniques for vibration-based health monitoring of smart structures. *Archives of Computational Methods in Engineering*, 23(1), 1–15.
- Bhatia, N. (2010). Survey of nearest neighbor techniques. *arXiv Preprint arXiv:1007.0085*.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Han, J., Lee, J. Y., & Park, J. H. (2020). Damage detection in concrete structures using wavelet transform and supervised machine learning. *Automation in Construction*, 110, 102957. <https://doi.org/10.1016/j.autcon.2019.102957>
- He, Y., Chen, H., Liu, D., & Zhang, L. (2021). A framework of structural damage detection for civil structures using fast Fourier transform and deep convolutional neural networks. *Applied Sciences*, 11(19), 9345.
- Huang, Y., Yang, Y., & Li, H. (2010). Fractal theory and wavelet packet transform based damage detection method for beam structures. In *Health Monitoring of Structural and Biological Systems 2010*, 7650, pp. 1058–1065). SPIE.
- Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, 18(3), 145–156. [https://doi.org/10.1016/0010-4825\(88\)90041-8](https://doi.org/10.1016/0010-4825(88)90041-8)
- Knitter-Piątkowska, A., & Dobrzycki, A. (2020). Application of wavelet transform to damage identification in steel structure elements. *Applied Sciences*, 10(22), 8198.
- Machorro-Lopez, J. M., Valtierra-Rodriguez, M., Perez-Quiroz, J. T., & Amezcua-Sanchez, J. P. (2025). Comparative analysis of fractals-homogeneity-entropy algorithms applied on a FEM bridge model to identify damage. *Infrastructures*, 10(2), 36.
- Mallat, S. (1999). *A wavelet tour of signal processing* (2nd ed.). Academic Press.
- Mishra, M., Lourenço, P. B., & Ramana, G. V. (2022). Structural health monitoring of civil engineering structures by using the internet of things: A review. *Journal of Building Engineering*, 48, 103954.
- Montgomery, D. C. (2013). *Design and analysis of experiments* (8th ed.). Wiley.
- Moreno-Gomez, A., Amezcua-Sanchez, J. P., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., & Dominguez-Gonzalez, A. (2018). EMD-Shannon entropy-based methodology to detect incipient damages in a truss structure. *Applied Sciences*, 8(11), 2068.
- Moreno-Gomez, A., Machorro-Lopez, J. M., Amezcua-Sanchez, J. P., Perez-Ramirez, C. A., Valtierra-Rodriguez, M., & Dominguez-Gonzalez, A. (2020). Fractal dimension analysis for assessing the health condition of a truss structure using vibration signals. *Fractals*, 28(7), 2050127.
- Mousavi, A. A., Zhang, C., Masri, S. F., & Gholipour, G. (2022). Damage detection and characterization of a scaled model steel truss bridge using combined complete ensemble empirical mode decomposition with adaptive noise and multiple signal classification approach. *Structural Health Monitoring*, 21(4), 1833–1848.
- Petrosian, A. (1995). Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns. In *Proceedings of the IEEE Symposium on Computer-Based Medical Systems*, (pp. 212–217). <https://doi.org/10.1109/CBMS.1995.465426>



- Sevcik, C. (1998). A procedure to estimate the fractal dimension of waveforms. *Complexity International*, 5(1), 1–19.
- Silik, A., Noori, M., Wu, Z., Altabey, W. A., Dang, J., & Farhan, N. S. (2024). Wavelet-based vibration denoising for structural health monitoring. *Urban Lifeline*, 2(1), 15.
- Singh, P., Keyvanlou, M., & Sadhu, A. (2021). An improved time-varying empirical mode decomposition for structural condition assessment using limited sensors. *Engineering Structures*, 232, 111882.
- Telukunta, J. K., & Bala, M. M. (2021). A comparison of classical machine learning approaches for early structural damage identification. In C. K. Mai, A. B. Reddy, & K. S. Raju (Eds.), *Machine learning technologies and applications. Algorithms for Intelligent Systems*. Springer.
- Yang, Y., Zhang, Y., & Tan, X. (2021). Review on vibration-based structural health monitoring techniques and technical codes. *Symmetry*, 13(11), 1998.
- Yanez-Borjas, J. J., Machorro-Lopez, J. M., Camarena-Martinez, D., Valtierra-Rodriguez, M., & Amezquita-Sanchez, J. P. (2021). A new damage index based on statistical features, PCA, and Mahalanobis distance for detecting and locating cables loss in a cable-stayed bridge. *International Journal of Structural Stability and Dynamics*, 21(9), 2150127.
- Zhang, C., Mousavi, A. A., Masri, S. F., Gholipour, G., Yan, K., & Li, X. (2022). Vibration feature extraction using signal processing techniques for structural health monitoring: A review. *Mechanical Systems and Signal Processing*, 177, 109175.
- Zhang, T., Shi, D., Wang, Z., Zhang, P., Wang, S., & Ding, X. (2022). Vibration-based structural damage detection via phase-based motion estimation using convolutional neural networks. *Mechanical Systems and Signal Processing*, 178, 109320.
- Zhou, Q., Ning, Y., Zhou, Q., Luo, L., & Lei, J. (2013). Structural damage detection method based on random forests and data fusion. *Structural Health Monitoring*, 12(1), 48–58.

