

# Real-time monitoring system for damage diagnosing on civil structures using the Internet of Things (IoT)

Jesús Morales-Valdez\* Hoover Mujica-Ortega\*\*

\* *Colegio de Ciencia y Tecnología, Universidad Autónoma de la Ciudad de México, Calzada Ermita Iztapalapa No. 4163, Col. Lomas de Zaragoza, Alcaldía Iztapalapa, C.P. 09620, CDMX, México, (e-mail: [jesus.morales@uacm.edu.mx](mailto:jesus.morales@uacm.edu.mx))*

\*\* *Facultad de Ingeniería, Universidad Nacional Autónoma de México, Alcaldía Coyoacán 04510, CDMX, México, (e-mail: [hmujica@unam.mx](mailto:hmujica@unam.mx))*

---

**Abstract:** This article presents the evaluation of a real-time monitoring system based on acceleration data obtained from a reduced-scale 5-story building prototype. Development is achieved under the Internet of Things (IoT) approach through the cloud using the MQTT messaging protocol. The damage evaluation is achieved by comparing 2 different states of the structural system, for this, the parameters of the civil structure model are used, which are estimated using the normalized least squares algorithm with forgetting factor. In this stage, the algorithms are programmed in Matlab-Simulink and executed on a Raspberry PI 4. The experimental results confirm the versatility of the proposal and the relevance of the used decentralized communication architectures for real-time monitoring.

*Keywords:* Structural health monitoring, buildings, internet of things.

---

## 1. INTRODUCCIÓN

A pesar de los esfuerzos científicos y tecnológicos destinados a proteger las estructuras civiles de los efectos adversos que provocan los sismos, estos continúan causando un número importante de víctimas humanas y grandes pérdidas económicas alrededor del mundo. Estos eventos han demostrado la gran importancia de mitigar este tipo de amenazas latentes y la de sumarse al desarrollo tecnológico y de investigación en protección de infraestructura civil. De manera particular, la evaluación de daño en edificios después de un evento debe hacerse de manera oportuna para evitar poner en peligro vidas humanas.

En consecuencia, el interés en las técnicas para monitorear la salud estructural (SHM, por sus siglas en inglés) de inmuebles ha incrementado en los últimos años, tiene como objetivo principal la determinación y seguimiento de la integridad estructural y la evaluación de la naturaleza del daño en la misma.

La mayor parte de la investigación en ésta área se basa en el estudio de los cambios globales en los parámetros

\* Agradecimiento al Colegio de Ciencia y Tecnología de la Universidad Autónoma de la Ciudad de México por el apoyo otorgado a través del proyecto UACM CCYT-2023-INI-02

modales como las frecuencias de vibración (Doebling et al., 1996; Das et al., 2016) y las formas modales (Farrar et al., 2001; Farrar and Worden, 2007), ambos ampliamente estudiados en la literatura. Sin embargo, la mayoría de estos métodos se basan en el seguimiento de los cambios en las propiedades dinámicas de las estructuras que no son sensibles a los daños locales. Además, estos métodos no son robustos a cambios en las condiciones ambientales como la temperatura y la lluvia, según se reporta en (Clinton et al., 2006), ya que, variaciones pequeñas pueden suceder aún sin la presencia de daño. Adicionalmente, en ambos casos, estos métodos requieren excitar la edificación a altas frecuencias, lo que no es fácil de conseguir y, por tanto, el daño puede pasar desapercibido. En el caso de una estructura real, obtener formas modales de manera precisas es muy difícil y requiere muchos sensores, cuyas mediciones pueden estar sesgadas por el ruido de medición (Carden and Fanning, 2004).

Otros estudios, como el de Loh et al. (2011), sugieren que durante sismos intensos o vientos fuertes, las estructuras suelen exhibir un comportamiento no lineal y de histéresis. Una revisión exhaustiva de estos métodos con base en redes neuronales se puede encontrar en Sohn et al. (2003). Alguno ejemplo de aplicación se pueden con-

sultar en Liu et al. (2011); Abdeljaber et al. (2017); Atha and Jahanshahi (2018), entre otras. Una limitante de este enfoque es que, su desempeño depende de grandes volúmenes de datos para el entrenamiento de la red, información de la cual no se dispone previo al daño estructural. Bajo este contexto, el análisis se puede simplificar relacionando los cambios físicos con los parámetros estructurales del modelo. Algunas metodologías para la identificación en línea son discutidas en los trabajos de Ceravolo et al. (2013); Wan et al. (2018). El daño estructural se puede determinar analizando dos estados diferentes del sistema.

Es importante señalar que la mayoría de los métodos descritos anteriormente operan fuera de línea, una vez que disponen de los datos de edificios instrumentados, por lo cual su análisis no puede ser en tiempo real. Además, esta información únicamente está disponible en un concentrador de manera local. Hoy en día, el Internet de las cosas (IoT, por sus siglas en inglés) es una tecnología innovadora de rápido crecimiento que, nos permite disponer de la información en todo momento y en cualquier lugar para ser analizada (Lampropoulos et al., 2018). Esta tecnología nos permite realizar un monitoreo continuo y remoto que, con una arquitectura adecuada, permitiría la ejecución de algún algoritmo para el diagnóstico de daño en tiempo real. Como resultado, se tendría un sistema inteligente de toma de decisiones autónomo, con capacidad para alertar a la población en la etapa más temprana.

En este artículo se propone desarrollar un algoritmo de diagnóstico de daño con base en un sistema de identificación y comparación de los parámetros estructurales estimados, ya que se ha demostrado que los cambios en la rigidez están intrínsecamente relacionados con la cantidad de daño estructural (Morales-Valdez et al., 2018, 2020). Se emplea el algoritmo de mínimos cuadrados modificado para la identificación y se diseña de un esquema de umbrales adaptables para la detección de daño, los cuales sin implementados a través del dispositivo Raspberry Pi modelo 4. Adicionalmente, bajo el enfoque IoT se realiza un seguimiento de los cambios en las características dinámicas del sistema estructural para detectar y localizar el daño. SHM ayuda proporcionar una evaluación inmediata y la información necesaria de la condición de salud de las estructuras instrumentadas después de los eventos sísmicos, lo cual es importante para la evaluación de la seguridad residual y para prevenir fallas estructurales catastróficas, los programas de mantenimiento preventivo son fundamentales para garantizar eficiencia operativa segura y luego prolongar su vida útil. Además de que son robustos al ruido de medición.

Los resultados experimentales a partir de un prototipo de edificios de 5 niveles a escala reducida, confirman la viabilidad de la propuesta. El resto del artículo está organizado de la siguiente manera: la sección 2 describe el modelo matemático empleado para resolver el problema planteado, y las consideraciones correspondientes. El de-

desarrollo del esquema para el diagnóstico de daño se describe en la Sección 3, mientras que la arquitectura IoT para el monitoreo continuo se exponen en la Sección 4. La evaluación experimental se lleva a cabo en la Sección 4. Finalmente, las conclusiones y observaciones finales se proporcionan en la Sección 6.

## 2. MODELO MATEMÁTICO

Sea el modelo de edificio a cortante de múltiples pisos, excitado sísmicamente en una dirección, como se muestra en la fig. 1. El cual está construido sobre piso firme, y se caracteriza por un comportamiento lineal, cuya dinámica es gobernada por (1)




Fig. 1. Edificio a cortante

$$M(\ddot{x} + l\ddot{x}_g) + C\dot{x} + Kx = 0 \quad (1)$$

donde  $M$  es la matriz de masas, definida

$$M = \text{diag} [m_1 \ m_2 \ \dots \ m_n] > 0 \quad \in R^{n \times n}$$

mientras  $C$  y  $K$  que representan las matrices de amortiguamiento y rigidez respectivamente, que cumplen con la siguiente forma

$$Q = \begin{bmatrix} q_1 + q_2 & -q_2 & \dots & 0 \\ -q_2 & q_2 + q_3 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & q_n \end{bmatrix} \geq 0 \quad \in R^{n \times n}$$

$$\begin{aligned} x &= [x_1, x_2, \dots, x_n]^T \in R^{n \times 1}, \\ \dot{x} &= [\dot{x}_1, \dot{x}_2, \dots, \dot{x}_n]^T \in R^{n \times 1}, \\ \ddot{x} &= [\ddot{x}_1, \ddot{x}_2, \dots, \ddot{x}_n]^T \in R^{n \times 1}, \\ l &= [1, 1, 1, \dots, 1] \in R^{n \times 1} \end{aligned} \quad (2)$$

donde,  $n$  representa el número de pisos, tal que,  $c_i$  y  $k_i$  con  $i = 1, 2, \dots, n$ , son respectivamente, la masa, el amortiguamiento y la rigidez lateral de entre-pisos. Las entradas del vector  $x$ ,  $\dot{x}$ ,  $\ddot{x}$  son los desplazamientos, las velocidades y las aceleraciones de cada piso, respectivamente, mientras que  $\ddot{x}_g$  representan la aceleración del suelo inducida por el sismo.

Suponiendo que el edificio presenta daño estructural, se agrega un término de incertidumbre paramétrica

$$(M + \Delta M)(\ddot{x} + l\ddot{x}_g) + (C + \Delta C)\dot{x} + (K + \Delta K)x = 0, \quad (3)$$

En este trabajo, las variables  $\Delta M$ ,  $\Delta C$  y  $\Delta K$  son desconocidas y se suponen que que modifican la respuesta estructural a partir de la acción sísmica.

### 3. DISEÑO DEL ESQUEMA PARA EL DIAGNÓSTICO DE DAÑO

Asumiendo que los parámetros del edificio son desconocidos, en esta sección se diseña un sistema de identificación capaz de estimar los parámetros en tiempo real para llevar a cabo la evaluación de daño en la etapa más temprana posible. Posteriormente, se diseña un algoritmo para detectar y localizar daño estructural a partir de los cambios entre los parámetros de referencia y los estimados.

#### 3.1 Identificación de parámetros

Sea la ecuación de movimiento (1), reescrita como

$$\mathbf{z}_{obs} = -\mathbf{M}^{-1}\mathbf{K}\mathbf{x} - \mathbf{M}^{-1}\mathbf{C}\dot{\mathbf{x}}, \quad \mathbf{z}_{obs} = (\ddot{\mathbf{x}} - l\ddot{\mathbf{x}}_g) \quad (4)$$

donde  $\mathbf{z}_{obs}$  es la salida ó aceleración absoluta, que es medible. De manera que (4) se puede reescribir como

$$\mathbf{z}_{obs} = \psi\Theta_k + \dot{\psi}\Theta_c \quad (5)$$

con

$$\psi = \begin{bmatrix} x_1 & x_1 - x_2 & 0 & 0 & \dots & 0 \\ 0 & 0 & x_2 - x_1 & x_2 - x_3 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \dots & x_n - x_{n-1} \end{bmatrix} \quad (6)$$

$$\dot{\psi} = \frac{d}{dt}(\psi) \in \mathbb{R}^{n \times 2n-1} \quad (7)$$

y

$$\Theta_k = \begin{bmatrix} \frac{k_1}{m_1} & \frac{k_2}{m_1} & \frac{k_2}{m_2} & \frac{k_3}{m_2} & \frac{k_3}{m_3} & \dots & \frac{k_n}{m_n} \end{bmatrix} \in \mathbb{R}^{2n-1} \quad (8)$$

$$= [\Theta_{k1} \ \Theta_{k2} \ \Theta_{k3} \ \Theta_{k4} \ \Theta_{k5} \ \dots \ \Theta_{k(2n-1)}]$$

$$\Theta_c = \begin{bmatrix} \frac{c_1}{m_1} & \frac{c_2}{m_1} & \frac{c_2}{m_2} & \frac{c_3}{m_2} & \frac{c_3}{m_3} & \dots & \frac{c_n}{m_n} \end{bmatrix} \in \mathbb{R}^{2n-1} \quad (9)$$

$$= [\Theta_{c1} \ \Theta_{c2} \ \Theta_{c3} \ \Theta_{c4} \ \Theta_{c5} \ \dots \ \Theta_{c(2n-1)}]$$

suponiendo que  $m_1$  es conocida, los parámetros restantes se pueden calcular como sigue

$$k_1 = \Theta_{k1} * m_1, \quad c_1 = \Theta_{c1} * m_1$$

⋮

$$k_{(i)} = \prod_2^{(2i-2)} \Theta_{ki}^{(-1)^i} * m_1, \quad i = 2, 3, \dots, n \quad (10)$$

$$c_{(i)} = \prod_2^{(2i-2)} \Theta_{ci}^{(-1)^i} * m_1, \quad i = 2, 3, \dots, n$$

$$m_{(i)} = \prod_2^{(2i-1)} \Theta_{ki}^{(-1)^i} * m_1, \quad i = 2, 3, \dots, n$$

Usando la transformada de Laplace, la ecu. (5) puede ser reescrita como

$$\mathbf{Z}_{obs}(s) = \Psi(s)\Theta_k + s\Psi(s)\Theta_c \quad (11)$$

Al aplicar tres derivadas temporales a (5), se eliminan las perturbaciones constantes, produciendo

$$\begin{aligned} \mathbf{z}_{obs}^{(3)} &= \psi^{(3)}\Theta_k + \psi^{(4)}\Theta_c \\ s^3\mathbf{Z}_{obs}(s) &= s^3\Psi(s)\Theta_k + s^4\Psi(s)\Theta_c \\ s^3\mathbf{Z}_{obs}(s) &= s\mathcal{L}[\ddot{\psi}]\Psi(s)\Theta_k + s^2\mathcal{L}[\ddot{\psi}]\Psi(s)\Theta_c \end{aligned} \quad (12)$$

Observe que, mientras (5) depende de señales no medibles, por el contrario (12) está construida de señales medibles de aceleración. Además, el ruido de medición contenido en los datos de aceleración se reduce mediante la introducción de filtros integrales lineales (LIF) en un intervalo de tiempo finito, definido por el operador:

$$I_q\{\varphi(t)\} = \frac{1}{\delta^q} \int_{t-\delta}^t \int_{\tau_1-\delta}^{\tau_1} \dots \int_{\tau_{q-1}-\delta}^{\tau_{q-1}} \varphi(\tau_q) d\tau_q \dots d\tau_1 \quad (13)$$

donde,  $q$  indica el número de integrales, y  $\delta \in \mathbb{R}^+$  es el período de tiempo de integración definido por  $\delta = \bar{n}T_s$ , mientras  $T_s$  indica el tiempo de muestreo. Note que,  $\bar{n} > 0$  es seleccionado para hacer que el ancho de banda del sistema coincida con la frecuencia de corte del filtro. Aplicando el operador  $I_5[\cdot]$  a (12), se obtiene

$$\Xi(t) = \Upsilon_k(t)\Theta_k + \Upsilon_c(t)\Theta_c \quad (14)$$

con

$$\Xi(t) = \frac{\vartheta}{\delta^3} I_2 \left\{ \sum_{j=0}^3 \binom{3}{j} (-1)^j z(t-j\delta) \right\} \in \mathbb{R}^{n \times 1} \quad (15)$$

$$\Upsilon_k(t) = \frac{\vartheta}{\delta} I_4 \left\{ \sum_{j=0}^1 \binom{1}{j} (-1)^j \dot{\psi}(t-j\delta) \right\} \in \mathbb{R}^{n \times 2n-1} \quad (16)$$

$$\Upsilon_c(t) = \frac{\vartheta}{\delta^2} I_3 \left\{ \sum_{j=0}^2 \binom{2}{j} (-1)^j \ddot{\psi}(t-j\delta) \right\} \in \mathbb{R}^{n \times 2n-1} \quad (17)$$

donde  $\binom{n}{j}$  es el coeficiente binomial y  $\vartheta \in \mathbb{R}^+$  es un término que normaliza la amplitud de la señal filtrada. Finalmente, se presenta la parametrización resultante a partir de (14)

$$\Xi(t) = \Upsilon(t)\Theta, \quad \Upsilon = [\Upsilon_k, \Upsilon_c], \quad \Theta = [\Theta_k^T, \Theta_c^T]^T \quad (18)$$

**Mínimos Cuadrados:** Los parámetros del vector  $\hat{\Theta} = [\hat{\Theta}_k^T, \hat{\Theta}_c^T]^T$  son estimados empleando el algoritmo de mínimos cuadrados normalizado con factor de olvido, definido por (19)

$$\dot{P} = \alpha P - \frac{P\Upsilon^T\Upsilon P}{m^2}, \quad \dot{\hat{\Theta}} = P\Upsilon^T\varepsilon \quad (19)$$

donde,  $\alpha$  es el factor de olvido,  $P$  es la matriz de covarianza, con  $P = P^T > 0 \in \mathbb{R}^{4n-2 \times 4n-2}$ ,  $P(0) > 0$ ,

$1 > \alpha \geq 0 \in \mathbb{R}^+$ ,  $m^2 = 1 + \|\Upsilon\Upsilon^T\|$ , que satisface  $\Upsilon/m \in \mathcal{L}_\infty$ , asegurando que

$$\varepsilon = \frac{\Xi - \hat{\Xi}}{m^2} \rightarrow 0 \quad \text{cuando } t \rightarrow \infty, \quad \hat{\Xi} = \Upsilon \hat{\Theta} \quad (20)$$

Además, se introduce la siguiente proyección paramétrica  $\hat{\Theta}_{ki+}(t)$ ,  $\hat{\Theta}_{ci+}(t)$  con  $i = 1, 2, \dots, n$ , para garantizar estimaciones positivistas

$$\hat{\Theta}_{ki}(t) = \begin{cases} \hat{\Theta}_{ki+}(t) \approx \varsigma_1 & \text{if } \hat{\Theta}_{ki}(t) < 0 \\ \hat{\Theta}_{ki+}(t) \approx \hat{\Theta}_{ki}(t) & \text{if } \hat{\Theta}_{ki}(t) > \varsigma_1 \end{cases} \quad (21)$$

$$\hat{\Theta}_{ci}(t) = \begin{cases} \hat{\Theta}_{ci+}(t) \approx \varsigma_1 & \text{if } \hat{\Theta}_{ci}(t) < 0 \\ \hat{\Theta}_{ci+}(t) \approx \hat{\Theta}_{ci}(t) & \text{if } \hat{\Theta}_{ci}(t) > \varsigma_1 \end{cases} \quad (22)$$

$$\begin{aligned} \hat{\Theta}_{ki+}(t) &= \hat{\Theta}_{ki}(t) + (\varsigma_1 - \hat{\Theta}_{ki}(t)) \left( \frac{1 - \tanh(\hat{\Theta}_{ki}(t))}{2} \right) \\ \hat{\Theta}_{ci+}(t) &= \hat{\Theta}_{ci}(t) + (\varsigma_2 - \hat{\Theta}_{ci}(t)) \left( \frac{1 - \tanh(\hat{\Theta}_{ci}(t))}{2} \right) \end{aligned} \quad (23)$$

donde  $\varsigma_1 = \varsigma_2 = 0.0001$ , es el límite inferior para los parámetros estimados.

### 3.2 Metodología para el diagnóstico de daño

El procedimiento es como se indica a continuación:

- Definiendo  $\beta_i = k_i/m_i$  y  $\eta_i = c_i/m_i$
- Se obtienen las relaciones entre pares de parámetros nominales<sup>1</sup>

$$\beta_{N_i} = \frac{\hat{\beta}_i}{\hat{\beta}_{i+1}}, \quad \eta_{N_i} = \frac{\hat{\eta}_i}{\hat{\eta}_{i+1}}, \quad i = 1, \dots, n-1, \quad (24)$$

para  $i = n$

$$\beta_{N_i} = \frac{\hat{\beta}_i}{\hat{\beta}_{i-1}}, \quad \eta_{N_i} = \frac{\hat{\eta}_i}{\hat{\eta}_{i-1}} \quad (25)$$

- También se obtienen las relaciones entre pares de parámetros que pueden indicar daño

$$\beta_{D_i} = \frac{\hat{\beta}_{d_i}}{\hat{\beta}_{d_{i+1}}}, \quad \eta_{D_i} = \frac{\hat{\eta}_{d_i}}{\hat{\eta}_{d_{i+1}}}, \quad i = 1, \dots, n-1, \quad (26)$$

para  $i = n$

$$\beta_{D_i} = \frac{\hat{\beta}_{d_i}}{\hat{\beta}_{d_{i-1}}}, \quad \eta_{D_i} = \frac{\hat{\eta}_{d_i}}{\hat{\eta}_{d_{i-1}}} \quad (27)$$

- Se calculan los errores relativos entre los parámetros de referencia y los que indican un posible comportamiento con daño, es decir

$$\varepsilon_{\beta_i} = \frac{\beta_{N_i} - \beta_{D_i}}{\beta_{N_i}} \times 100, \quad \varepsilon_{\eta_i} = \frac{\eta_{N_i} - \eta_{D_i}}{\eta_{N_i}} \times 100 \quad (28)$$

- Se determina la desviación estándar del vector de errores relativos

$$s_{\beta} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{\varepsilon}_{\beta} - \varepsilon_{\beta_i})^2}, \quad \bar{\varepsilon}_{\beta} = \sum_{i=1}^n \varepsilon_{\beta_i}/n \quad (29)$$

$$s_{\eta} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{\varepsilon}_{\eta} - \varepsilon_{\eta_i})^2}, \quad \bar{\varepsilon}_{\eta} = \sum_{i=1}^n \varepsilon_{\eta_i}/n \quad (30)$$

donde  $\bar{\varepsilon}_{\beta}$  y  $\bar{\varepsilon}_{\eta}$  son la media aritmética de los errores relativos de  $\varepsilon_{\beta}$  y  $\varepsilon_{\eta}$ . Si el error relativo  $\varepsilon_{\beta_i} > (\bar{\varepsilon}_{\beta} + s_{\beta}/2)$ , entonces  $\tilde{\varepsilon}_{\beta_i} = [\varepsilon_{\beta_i} - (\bar{\varepsilon}_{\beta} + s_{\beta}/2)] > 0$ , en caso contrario, la diferencia anterior se considera nula. Condiciones similares se aplican con los valores de  $\varepsilon_{\eta_i}$ .

- Finalmente, el daño es localizado empleando la siguiente expresión

$$P_D = \tilde{\varepsilon}_{\beta_i} + 1/\tilde{\varepsilon}_{\eta_i} \quad (31)$$

Note que cuando  $\tilde{\varepsilon}_{\eta_i} = [\varepsilon_{\beta_i} - (\bar{\varepsilon}_{\beta} + s_{\beta}/2)] < 0$ , entonces se considera  $\tilde{\varepsilon}_{\eta_i} = 100000$  para evitar indeterminación en la Ec. (31).

## 4. ARQUITECTURA IOT PARA EL SUPERVISIÓN CONTINUA

La plataforma de supervisión continua está compuesta por una tarjeta de desarrollo RaspBerry Pi 4, la cual evalúa el algoritmo de diagnóstico de daño, a partir de las mediciones de aceleraciones en cada uno de los pisos del edificio, como se muestra en la fig. 2. Como resultados

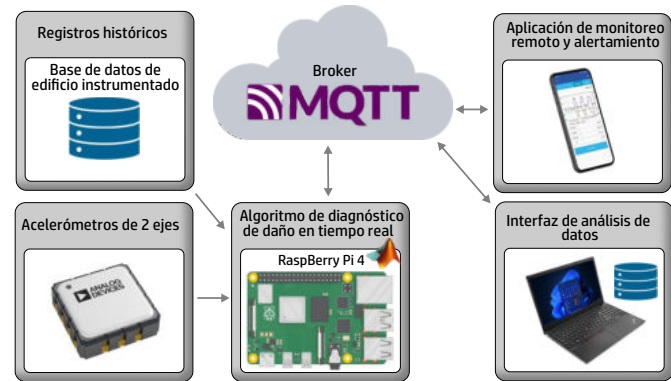


Fig. 2. Arquitectura de plataforma IoT para diagnóstico en tiempo real.

de la identificación, el sistema publica a través de un *broker* MQTT (Message Queuing Telemetry Transport) los parámetros  $\hat{\Theta}_{ki}$  y  $\hat{\Theta}_{kc}$ ; los cuales representan a los parámetros estimados de rigidez y amortiguamiento respectivamente; en caso de que ambos superen el umbral adaptable, se activan alarmas que indican por cada piso cuando las estructuras presentan daño estructural, esto ocurre cuando el régimen de elasticidad cambia a la zona plástica.

<sup>1</sup> El subíndice  $N$  indica nominal y se refiere a la ausencia de daño

Por otro lado, para la visualización de los parámetros de interés y las alarmas que identifican los posibles daños permanentes, se desarrolló una interfaz que puede ejecutarse en dispositivos móviles con sistema operativo Android o IOS y una aplicación de escritorio para Windows, como se observa en la fig. 3. Ambas aplicaciones fueron desarrolladas en el entorno Embarcadero RAD Studio Delphi y son capaces de establecer la comunicación MQTT como clientes seguros, logrando así, monitorear remotamente la salud del edificio.

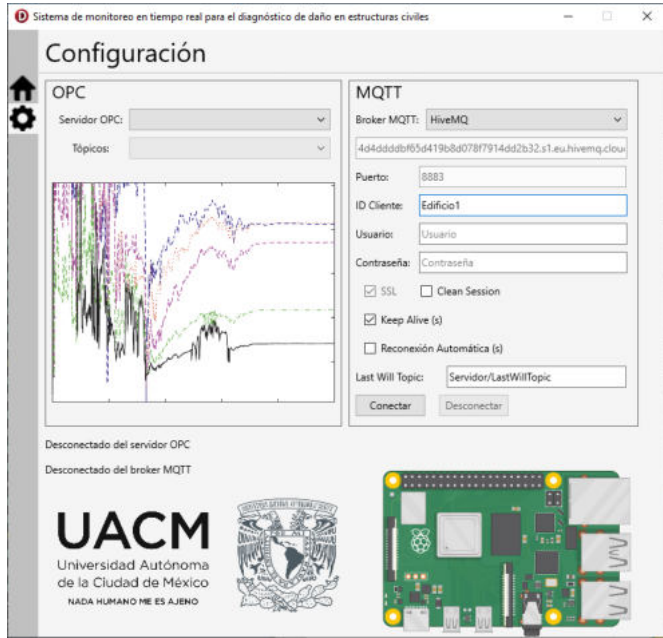


Fig. 3. Interfaz de diagnóstico y contextualización de datos

## 5. EVALUACIÓN EXPERIMENTAL

Los experimentos para evaluar el desempeño del algoritmo de estimación propuesto se llevaron a cabo utilizando los datos de un prototipo de edificio de cinco niveles, cuyos parámetros se presentan en la Tabla 1. La simulación se llevó a cabo en Matlab 2019. Los experimentos se llevaron a cabo con un tiempo de muestreo de 0.001 s.

Tabla 1. Parámetros estructurales nominales.

	Piso 1	Piso 2	Piso 3	Piso 4	Piso 5
$\hat{m}_i$ [Kg]	10.78	9.17	9.14	9.12	9.08
$\hat{c}_i$ [Ns/m]	700.14	278.18	546.84	372.54	375.97
$\hat{k}_i$ [N/m]	19011	12108	11966	11850	12406

Para emular daño, se redujo la rigidez del segundo y del quinto piso, que corresponden a reducir la sección transversal de las columnas que lo componen. Inicialmente se suponen de dimensión cuadrada de 635 mm y luego del maquinado quedan en 500 mm. Lo que produce los siguientes parámetros estimados (ver Tabla 2).

Tabla 2. Parámetros estructurales en presencia de daño

	Piso 1	Piso 2	Piso 3	Piso 4	Piso 5
$\hat{m}_{Di}$ [Kg]	10.78	9.17	9.14	9.12	9.08
$\hat{c}_{Di}$ [Ns/m]	700.14	278.18	546.84	372.54	375.97
$\hat{k}_{Di}$ [N/m]	14000	9322	9372	9339	9250

## 6. CONCLUSIÓN

En este trabajo se ha presentado un sistema de monitoreo en tiempo real para el diagnóstico de daño en estructuras civiles, cuya ventaja es la disposición de la información en todo momento y en cualquier lugar. Se ha mostrado que es posible diagnosticar a través del análisis de los parámetros estructurales. El algoritmo de mínimos cuadrados resulta viable para este tipo de aplicaciones pues es un método fácil de programar, y además, no requiere de gran costo computacional para su implementación, como así se demuestra en esta investigación. En este sentido, el uso de La arquitectura IoT proporciona una alternativa interesante a los métodos de monitoreo tradicional. Sin embargo, también reconocemos que es necesario realizar una investigación más exhaustivas para evaluar el potencial de este enfoque y de otras plataformas. No obstante, consideramos que los resultados experimentales obtenidos son un buen paso en esa dirección.

## AGRADECIMIENTOS

Los autores desea expresar su agradecimiento al Colegio de Ciencia y Tecnología de la Universidad Autónoma de la Ciudad de México por el apoyo otorgado para llevar a cabo esta investigación, la cual fue patrocinada mediante el proyecto UACM CCYT-2023-INI-02.

## REFERENCIAS

- Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., and Inman, D.J. (2017). Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. *Journal of Sound and Vibration*, 388, 154–170.
- Atha, D.J. and Jahanshahi, M.R. (2018). Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection. *Structural Health Monitoring*, 17(5), 1110–1128.
- Carden, E.P. and Fanning, P. (2004). Vibration based condition monitoring: a review. *Structural health monitoring*, 3(4), 355–377.
- Ceravolo, R., Erlicher, S., and Fragonara, L.Z. (2013). Comparison of restoring force models for the identification of structures with hysteresis and degradation. *Journal of Sound and Vibration*, 332(26), 6982–6999.
- Clinton, J.F., Bradford, S.C., Heaton, T.H., and Favela, J. (2006). The observed wander of the natural frequencies in a structure. *Bulletin of the seismological society of America*, 96(1), 237–257.
- Das, S., Saha, P., and Patro, S. (2016). Vibration-based damage detection techniques used for health

- monitoring of structures: a review. *Journal of Civil Structural Health Monitoring*, 6, 477–507.
- Doebling, S.W., Farrar, C.R., Prime, M.B., and Shevitz, D.W. (1996). Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review.
- Farrar, C.R., Doebling, S.W., and Nix, D.A. (2001). Vibration-based structural damage identification. *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 359(1778), 131–149.
- Farrar, C.R. and Worden, K. (2007). An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 365(1851), 303–315.
- Lampropoulos, G., Siakas, K., and Anastasiadis, T. (2018). Internet of things (iot) in industry: contemporary application domains, innovative technologies and intelligent manufacturing. *people*, 6(7).
- Liu, Y.Y., Ju, Y.F., Duan, C.D., and Zhao, X.F. (2011). Structure damage diagnosis using neural network and feature fusion. *Engineering applications of artificial intelligence*, 24(1), 87–92.
- Loh, C.H., Mao, C.H., Huang, J.R., and Pan, T.C. (2011). System identification and damage evaluation of degrading hysteresis of reinforced concrete frames. *Earthquake Engineering & Structural Dynamics*, 40(6), 623–640.
- Morales-Valdez, J., Alvarez-Icaza, L., and Sanchez-Sesma, F.J. (2018). Shear building stiffness estimation by wave traveling time analysis. *Structural Control and Health Monitoring*, 25(1), e2045.
- Morales-Valdez, J., Lopez-Pacheco, M., and Yu, W. (2020). Automated damage location for building structures using the hysteretic model and frequency domain neural networks. *Structural Control and Health Monitoring*, 27(9), e2584.
- Sohn, H., Farrar, C.R., Hemez, F.M., Shunk, D.D., Stinemates, D.W., Nadler, B.R., and Czarnecki, J.J. (2003). A review of structural health monitoring literature: 1996–2001. *Los Alamos National Laboratory, USA*, 1, 16.
- Wan, Z., Wang, T., Li, S., and Zhang, Z. (2018). A modified particle filter for parameter identification with unknown inputs. *Structural Control and Health Monitoring*, 25(12), e2268.