

# Detección de daño en edificios basada en datos de aceleración y redes neuronales convolucionales

Jesús Morales-Valdez<sup>1,2</sup> Mario Lopez-Pacheco<sup>2</sup> Wen Yu<sup>2</sup>

<sup>1</sup>*Cátedras CONACYT, e-mail: jmoralesv@ctrl.cinvestav.mx*

<sup>2</sup>*Departamento de Control Automático, CINVESTAV-IPN, Gustavo A. Madero 07360 Ciudad de México, (e-mail: mlopezp@ctrl.cinvestav.mx, yuw@ctrl.cinvestav.mx)*

---

**Abstract:** Este artículo presenta un enfoque alternativo para la detección de daño en edificios utilizando la energía disipada. Primero, el modelo histórico de Bouc-Wen se presenta como una herramienta útil para describir la energía disipada, que está directamente relacionada con la pérdida de rigidez. Dado que, los parámetros y estados de este modelo son desconocidos, empleamos un algoritmo de identificación no lineal basado en una red neuronal convolucional (CNN). Ésta se caracteriza por su conectividad dispersa, que garantiza que los filtros de convolución puedan detectar la respuesta. Además, los pesos compartidos de la CNN reducen la complejidad del entrenamiento y el número de sus parámetros porque los mismos pesos se aplican a todas las entradas. Por lo tanto, la CNN puede detectar características sin importar dónde se encuentren en los datos de vibración, lo que también reduce la complejidad del entrenamiento. El uso de esta herramienta evita el uso de un observador adaptable, que a diferencia de la CNN, la complejidad del algoritmo aumenta con el número de parámetros y estados desconocidos. Los resultados experimentales confirmaron que el método propuesto es prometedor para aplicaciones prácticas

*Keywords:* Monitoreo de salud estructural, detección de daño, redes neuronales convolucionales, modelo histerético

---

## 1. INTRODUCCIÓN

Los edificios son estructuras civiles susceptibles a diversos tipos de daños durante su vida útil debido principalmente al continuo deterioro, fatiga, fluencia y cargas inesperadas causadas por fenómenos naturales, como terremotos, vientos fuertes, tifones, entre otros. En este sentido, la tecnología de Monitoreo de Salud Estructural (SHM) es un tópico emergente en ingeniería civil que previene fallas estructurales catastróficas, mediante evaluaciones continuas y periódicas de la integridad de las infraestructuras civiles. La mayoría de los métodos de SHM se basan en el análisis de vibraciones que estudia las características globales, como las frecuencias naturales, las formas modales. Una revisión extensa de estos métodos se puede encontrar en (Doebbling et al., 1998; Carden and Fanning, 2004) mientras que una revisión amplia de los métodos de vibración con énfasis en aplicaciones de ingeniería estructural se describen en Das et al. (2016); Kong et al. (2017). De manera similar, los métodos presentados en Kim et al. (2003); Hwang and Kim (2004); Huang et al. (2012) también son técnicas para la detección de daños al analizar los cambios en sus frecuencias de

vibración. Dichos cambios se comparan con un ancho de banda en una situación sin daños. Sin embargo, en ambos casos, estos métodos requieren excitar un edificio a altas frecuencias, lo cual no es fácil de lograr y, por lo tanto, el daño puede pasar desapercibido. Además, las influencias ambientales como la lluvia y la temperatura pueden inducir cambios en las frecuencias de vibración incluso si no hay daños (Clinton et al., 2006; Nayeri et al., 2008; Herak and Herak, 2010).

Por otro lado, el daño progresivo inducido en los componentes estructurales puede significativamente poner la respuesta estructural al régimen no lineal. Recientemente se han desarrollado enfoques para la identificación de sistemas estructurales no lineales. En estudios de identificación basados en un enfoque paramétrico, varios investigadores han adoptado el modelo de Bouc Wen (Smyth et al., 1999; Ikhouane et al., 2005). Sin embargo, estos métodos deben satisfacer la condición de excitación persistente, que es difícil de lograr. Además, la complejidad de los métodos crece de acuerdo con el número de parámetros a identificar. Otros trabajos relacionados se exploran en Farrar et al. (2007); Chatzi et al. (2010) donde se discuten diferentes técnicas de identificación no

lineal para la detección de daños. Entre los esquemas de identificación no paramétricos, las redes neuronales han sido utilizadas recientemente para caracterizar sistemas no lineales de estructura desconocida. Una revisión exhaustiva de estos métodos se puede encontrar en Sohn et al. (2003). Bajo este enfoque, se presenta un método para la localización de daños utilizando modelos autorregulados (AR y ARX) y un conjunto de registros de aceleración. De manera similar, en Nair et al. (2006) se presenta un algoritmo de ubicación de daños, donde las señales de vibración se suponen como la salida de un modelo de promedio móvil autorregresivo (ARMA). La hipótesis es que la reducción de la rigidez induce cambios en los coeficientes de la parte autorregresiva del modelo. En este artículo, se desarrolla un esquema de identificación y extracción de características no lineales del sistema como una solución alternativa a los métodos de análisis modal para la evaluación de la salud de edificios de varios pisos. Se introduce una red neuronal convolucional (CNN) para estimar el desplazamiento histerético del modelo histórico de Bouc Wen, analizando los datos provenientes de los sensores de aceleración. La hipótesis principal es que después de que el edificio se daña, se reduce su capacidad para disipar energía. Este hecho puede ser un claro indicador de la presencia de daños. En este sentido, el modelo de Bouc Wen es capaz de capturar, en forma analítica, una gama de formas de ciclos histeréticos que coinciden con la energía del sistema. Los resultados experimentales de un prototipo a escala reducida de cinco pisos confirman que el método propuesto es prometedor para aplicaciones prácticas. La organización de este trabajo es la siguiente. El modelo matemático del edificio y de histéresis se presentan en la sección 2, mientras que la estructura de CNN se describe en la sección 3. Los resultados experimentales están en la sección 4. Finalmente, se proporciona un resumen de los hallazgos en la sección 5.

## 2. MODELO MATEMÁTICO

Sea el modelo de edificios de múltiples piso sísmicamente excitado, cuya dinámica es gobernada por (1)

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

donde  $M$ ,  $C$  y  $K$  son respectivamente, las matrices de masa, amortiguamiento y rigidez, definidas como

$$M = \begin{bmatrix} m_1 & 0 & \cdots & 0 \\ 0 & m_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & m_n \end{bmatrix} > 0 \quad \in R^{n \times n}$$

$$C = \begin{bmatrix} c_1 + c_2 & -c_2 & \cdots & 0 \\ -c_2 & c_2 + c_3 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & c_n \end{bmatrix} \geq 0 \quad \in R^{n \times n} \quad (2)$$

$$K = \begin{bmatrix} k_1 + k_2 & -k_2 & \cdots & 0 \\ -k_2 & k_2 + k_3 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & k_n \end{bmatrix} > 0 \quad \in R^{n \times n} \quad (3)$$

$$x = [x_1, x_2, \dots, x_n]^T, \quad \dot{x} = [\dot{x}_1, \dot{x}_2, \dots, \dot{x}_n]^T \in R^{n \times 1}, \\ \ddot{x} = [\ddot{x}_1, \ddot{x}_2, \dots, \ddot{x}_n]^T \in R^{n \times 1}, \quad l = [1, 1, 1, \dots, 1] \in R^n \quad (4)$$

donde,  $n$  es el número de pisos,  $c_i$  y  $k_i$  con  $i = 1, 2, \dots, n$ , son respectivamente, la masa, el amortiguamiento y la rigidez lateral entre el  $i$ -ésimo e  $(i - 1)$ -ésimo piso; mientras  $m_i$  corresponde a la  $i$ -ésima masa. Las entradas del vector  $x$ ,  $\dot{x}$ ,  $\ddot{x}$  son los desplazamientos relativos, las velocidades y las aceleraciones de cada piso, respectivamente, medidas con respecto a la base, mientras que  $\ddot{x}_g$  es la aceleración del suelo inducida por el sismo. Suponiendo que el edificio presenta daño estructural, se agrega un término no lineal a la ecuación (1),

$$M(\ddot{x} + l\ddot{x}_g) + C\dot{x} + \rho(x, z) = 0, \quad (5)$$

$$\rho(x, z) = [\rho_1(x_1, z_1) \quad \rho_2(x_2, z_2) \quad \cdots \quad \rho_i(x_n, z_n)]^T, \quad (6)$$

$$(7)$$

donde,

$$\rho_i(x_i, z_i) = ak_i x_i - (1 - \alpha) Dk_i z_i \quad \in \mathcal{R}^{1 \times 1}, \quad (8)$$

$$\dot{z}_i = \frac{A_i \dot{x}_i - \nu_i (\beta_i |\dot{x}_i| z_i^{r-1} - \gamma_i \dot{x}_i |z_i|^r)}{\eta_i} \quad (9)$$

En (9),  $z_i \in \mathcal{R}^{1 \times 1}$  representa el desplazamiento histerético del edificio, mientras que  $A_i$ ,  $\beta_i$  y  $\eta_i$  son parámetros que controlan la forma de los ciclos generados (Wen, 1976). Generalmente  $\beta_i$  y  $\gamma_i$  afectan el tamaño del ciclo, mientras que  $r > 1$  influye en la suavidad del mismo. Además, la degradación de la fuerza y la rigidez se modela mediante los parámetros  $\nu_i$  y  $\eta_i$ , que varían en función de la duración y la severidad de la respuesta sísmica (Ma et al., 2006).

Una manera conveniente para medir el efecto combinado de la duración y la severidad es la energía disipada a través del modelo histerético, tomada en el tiempo inicial  $t = 0$  hasta  $t$

$$e_i(t) = \int_0^t z_i \dot{u}_i du \quad (10)$$

La degradación de la rigidez  $\eta_i(e)$  y de la fuerza  $\nu_i(e)$ , se pueden obtener como

$$\eta_i(e) = 1.0 + \delta_\eta e_i \quad (11)$$

$$\nu_i(e) = 1.0 + \delta_\nu e_i \quad (12)$$

donde  $\delta_\eta$  y  $\delta_\nu$  son parámetros no negativos que representan la relación de degradación de rigidez y resistencia, respectivamente. En este trabajo, estas variables son desconocidas y serán estimadas. Sin embargo, tomando en cuenta que tanto los parámetros como el estado interno  $z$  son desconocidos, ambos deben estimarse. Esto

se logra empleando un observador adaptable. Sin embargo, teniendo en cuenta el número de parámetros a identificar, resulta una tarea difícil de lograr. Además, suponiendo que las mediciones están contaminadas con ruido de medición, no se puede asegurar convergencia paramétrica. Por esta razón, en este artículo se presentan la aplicación de la CNN para superar estos problemas.

### 3. ESTRUCTURA DE LA RED NEURONAL CONVULSIONAL

Para representar el modelo histórico Bouc Wen (9), se utiliza un modelo de media móvil autorregresiva no lineal (NARMA)

$$z(\tau) = \Psi[\chi(\tau)] \quad (13)$$

donde

$$\chi(\tau) = [z(\tau-1), \dots, z(\tau-n_z), \varsigma(\tau), \dots, \varsigma(\tau-n_\varsigma)]^T$$

$\Psi$  es la ecuación de diferencia no lineal desconocida que representa la dinámica del modelo;  $z(\tau)$  y  $\varsigma(\tau)$  son entradas medibles. De manera que la salida del modelo se puede estimar como

$$\hat{z}(\tau) = W^{(\ell)T} \Lambda \quad (14)$$

donde  $W^{(\ell)T}$  es la matriz de peso de la CNN propuesta para el sistema (13). La CNN se muestra en (14), donde  $\hat{z}(\tau)$  es la señal de salida escalar. El tamaño de los pesos de salida es  $W^{(\ell)} \in R^L$  y  $\Lambda$  es un vector que representa el apilamiento de la salida de la capa de submuestreo. La operación de convolución para cada elemento de  $\theta^{(\ell)}$  viene dada por

$$\theta_{i,h}^{(\ell)} = \sum_{\iota=0}^{f_\ell-1} \Delta_{h,\iota}^{(\ell)} \Theta_{h,i+\iota}^{(\ell-1)} \quad (15)$$

$\ell$  representa la capa actual,  $h$ -filtros por capa, definidos como  $\Delta_h^{(\ell)} \in R^{f_\ell}$ , mientras el mapa de características es descrito como  $\theta^{(\ell)}$ . Estos mapas de funciones pasan por una función de activación, que se utiliza es la unidad lineal rectificadora (ReLU), definida como

$$\Theta_{i,h}^{(\ell)} = \max(0, \theta_{i,h}^{(\ell)}) \quad (16)$$

En la capa de submuestreo, la operación utilizada es el maxpool

$$\Theta_h^{(\ell)} = \text{maxpool}(\Theta_h^{(\ell-1)}, s_\ell) \quad (17)$$

donde la reducción  $s_\ell$  depende de la capa. Tal como se definió anteriormente, después de la última capa de submuestreo, las salidas se apilan para crear el vector  $\Lambda$ , como sigue

$$\Lambda = [\Theta_1^{(\ell)T} \ \Theta_2^{(\ell)T} \ \dots \ ; \ \Theta_h^{(\ell)T}]^T \quad (18)$$

Finalmente, la CNN satisface dos propiedades principales: i) conectividad dispersa y ii) los pesos compartidos. El primero de ellos utiliza la conectividad local de las neuronas para ampliar la correlación espacial local.

El cuanto a la entrenamiento de la CNN, se lleva a cabo mediante el algoritmo de *Backpropagation* como se muestra en la Fig. 1. Este algoritmo se utiliza para calcular el gradiente de la función de costo propagada hacia atrás a través de la CNN para actualizar sus parámetros.

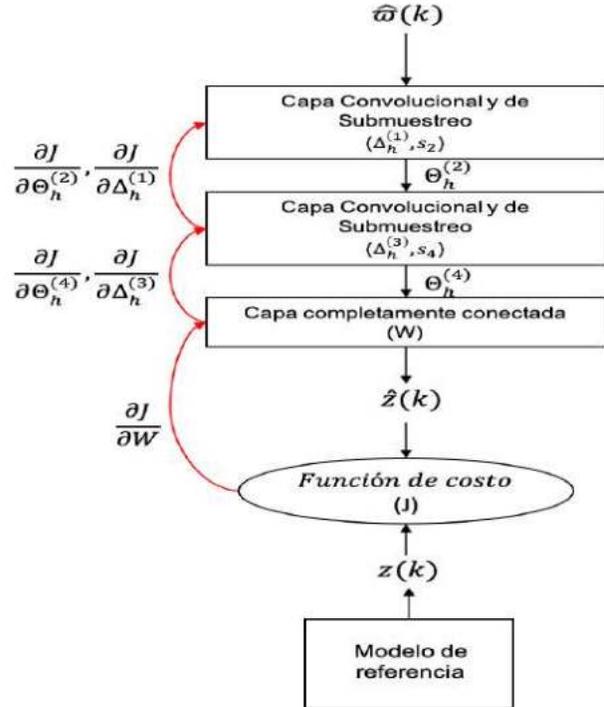


Fig. 1. Proceso de entrenamiento

$$J(k) = \frac{1}{2} \varepsilon^2(\tau) = \frac{1}{2} [\hat{z}(\tau) - z(\tau)]^2 \quad (19)$$

En la capa de salida, los pesos se actualizan usando la regla delta como sigue

$$w_i^{(\ell)}(\tau+1) = w_i^{(\ell)}(\tau) - \mu \frac{\partial J}{\partial w_i^{(\ell)}} \quad (20)$$

para actualizar los filtros en la capa convulsional, definimos.

$$\delta_{h,i}^{(\ell)} = \frac{\partial J}{\partial \Theta_{h,i}^{(\ell)}} f'(\theta_{h,i}^{(\ell)}) \quad (21)$$

con  $f'(\cdot)$  es el derivado de la operación ReLU que se define a continuación,

$$f'(x) = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{otherwise} \end{cases}$$

Así que el gradiente para los filtros se define como

$$\frac{\partial J}{\partial \Delta_h^{(\ell)}} = \Theta_h^{(\ell-1)} \odot \text{rot180}(\delta_h^{(\ell)}) \quad (22)$$

con  $\odot$  representando al operador de convulsión. La ecuación de actualización está definida por

$$\Lambda_h^{(\ell)}(\tau+1) = \Lambda_h^{(\ell)}(\tau) - \eta_N \left( y_h^{(\ell-1)} \odot \text{rot180}(\delta_h^{(\ell)}) \right) \quad (23)$$

con  $\eta_N$  la tasa de aprendizaje definida para cada capa en la CNN. El gradiente a la capa anterior se calcula como

$$\frac{\partial J}{\partial \Theta_h^{(\ell-1)}} = \delta_h^{(\ell)} \odot \text{rot}180(\Lambda_h^{(\ell)}) \quad (24)$$

El operador  $\text{rot}180(\cdot)$  es equivalente a voltear el filtro  $K$  y usarlo de abajo hacia arriba. Para la capa de submuestreo, el gradiente se calcula utilizando la operación opuesta a maxpool, definida como

$$\frac{\partial J}{\partial \Theta^{(\ell-1)}} = \text{up} \left( \frac{\partial J}{\partial \Theta^{(\ell)}} \right) \quad (25)$$

donde  $\text{up}(\cdot)$  aumenta la longitud del degradado para coincidir con la capa anterior y únicamente pasa a las posiciones donde se produce la respuesta más alta en la etapa de avance, dejando todo lo demás en ceros.

#### 4. RESULTADOS EXPERIMENTALES

Los experimentos para evaluar el desempeño del algoritmo de estimación propuesto se llevaron a cabo utilizando un prototipo de edificio de cinco niveles, de dimensiones  $(60 \times 50 \times 180)$  cm, como se muestra en la Fig. 2. El edificio está hecho de aluminio, con la excepción de 3 columnas que están hechas de latón. Las dimensiones de las columnas del primer piso son  $(0.635 \times 0.635 \times 31.5)$  cm y  $(0.635 \times 0.635 \times 36)$  cm para el resto de los pisos. El edificio está montado en una mesa vibradora accionada por servomotores de la marca Parker, modelo 406T03LXR. La mesa está equipada con acelerómetros con tecnología MEMS, modelo ADXL203E con un rango de medición de  $\pm 1.7$  g y ancho de banda de  $(0 - 50)$  Hz. La adquisición de datos se realiza empleando dos tarjetas electrónicas de la serie PCI-6221-3 de National Instruments. La comunicación entre estas tarjetas y Simulink se llevó a cabo utilizando Matlab Real-Time Windows Target Toolbox. Los experimentos se llevaron a cabo con un tiempo de muestreo de 0.001 s.

La excitación sísmica utilizada en los experimentos es el sismo de 1985 en la componente Norte-Sur registrado por la Secretaría de Comunicaciones y Transportes (SCT). La señal de excitación se escala para que coincida con el prototipo experimental, como se ilustra en la Fig. 3.

Para el esquema de identificación propuesto en la sección 3, se usa la velocidad de la estructura  $\zeta(\tau) = \dot{x}(\tau)$  y la salida de la CNN de la iteración anterior  $z(\tau) = \hat{z}(\tau)$  como señales de entrada a la CNN en (13); y órdenes de regresión para la salida y la entrada de la red  $n_y = 10$  y  $n_u = 10$ , respectivamente. Se proponen 2 capas convolucionales y dos de submuestreo, los números de filtros en cada capa son  $h = 10$ , el  $s_2 = s_4 = 2$ , la longitud del vector de peso de salida  $L = 50$ . Esta configuración permite recuperar la respuesta estructural del edificio como se presenta en la Fig. 4, donde la estimación del desplazamiento histórico del segundo piso es lo suficientemente cercana al valor de referencia proporcionado por el modelo analítico, aunque estos no son exactamente



Fig. 2. Edificio de cinco pisos de escala reducida

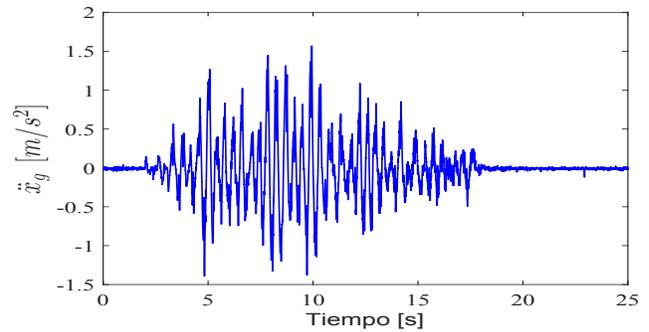


Fig. 3. Sismo de 1985, componente Norte-Sur

iguales. Un comportamiento similar se presentan en los pisos restantes. Los cálculos analíticos se llevaron a cabo considerando  $m = [9.17, 9.17, 9.14, 9.12, 9.08]$  kg,  $k = [12011, 12108 \times 0, 77, 11966, 11850, 19406 \times 0, 77]$  N / m, mientras que  $c$  (Ns /m) se consideraba como 5 % del valor de la rigidez de cada piso. Estos valores se utilizaron únicamente para el entrenamiento de la CNN y no se utilizan en el sistema de identificación.

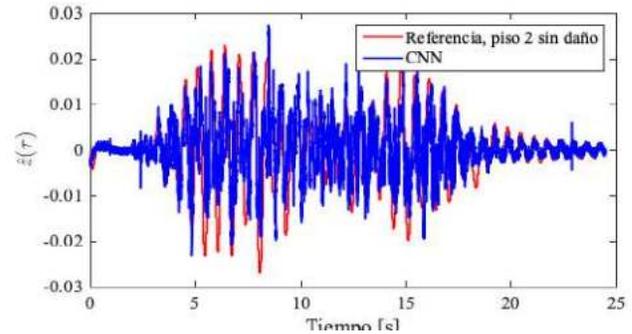


Fig. 4. Estimación del desplazamiento histérico del segundo piso sin daño

Dado que los datos experimentales disponibles tienen una duración de 25 s, con un tiempo de muestreo de 1 ms, se utilizaron 18000 muestras para el entrenamiento de la CNN y 6500 datos más para las pruebas experimentales.

#### 4.1 Escenarios de detección de daño

El primero escenario consiste en inducir daño en el segundo piso, mientras que para el segundo caso el daño se induce en el segundo y quinto piso. En ambos casos, la sección transversal cuadrada de las columnas se redujo aproximadamente 23%, cambiando de 6.35 a 5 mm. Para detectar daño, se utilizó el esquema de identificación presentado en la sección 3 y tres tipos diferentes de datos de vibración. El primero de ellos corresponde a una situación nominal, donde el edificio está libre de daño, otro, donde el piso dos está dañado, y uno más donde el daño está ubicado en el segundo y quinto piso. Para ilustrar el rendimiento del algoritmo, se presenta la salida estimada  $\dot{z}$  que corresponde al segundo piso, ver Fig. 5, que corresponde al primer escenario, donde el daño únicamente ocurre en el segundo piso. Los resultados de la estimación son similares para los pisos restantes.

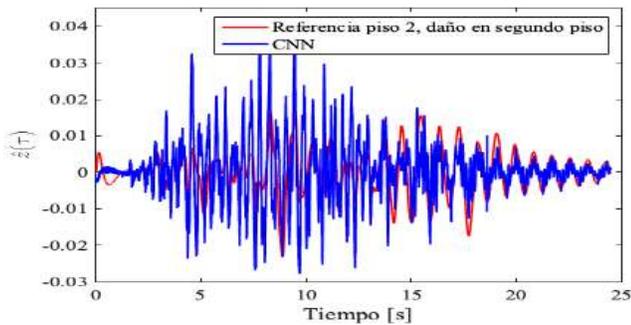


Fig. 5. Estimación del desplazamiento histérico del segundo piso en presencia de daños en el segundo piso

Además, a partir de la estimación de  $\dot{z}$ , se calcularon los ciclos histéricos, donde se puede apreciar la pérdida de energía para el edificio dañado con respecto al modelo sin daño. En las Figs. 6 y 7 se ilustra una comparación entre los ciclos histéricos con y sin daño correspondientes al quinto piso. En ambos casos se observa que en presencia de daño, los ciclos histéricos reducen su área, concentrándose en el centro del ciclo histérico sin daño. Resultados similares fueron obtenidos en los pisos restantes.

Después de que la CNN da el resultado, se calcula la energía disipada por el edificio empleando la ecuación (10). Los resultados se pueden ver en las Figs. 8 y 9. Es evidente que debido al daño, la capacidad del edificio para disipar energía se reduce, lo que indica que el edificio ha cambiado de la zona elástica a la zona plástica. Además, cuando el daño ocurre en una ubicación diferente, la energía histérica es menor, como se muestra en las Figs. 8 y 9.

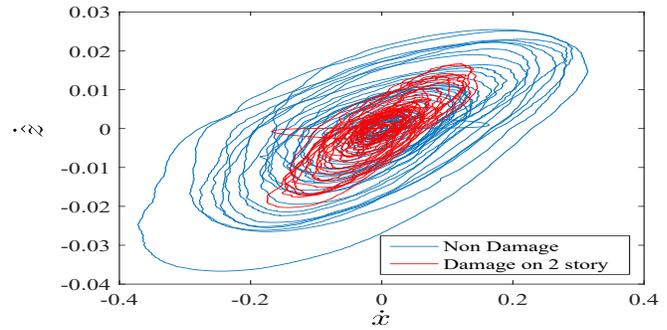


Fig. 6. Diagrama histérico del quinto piso en presencia de daños en el segundo piso

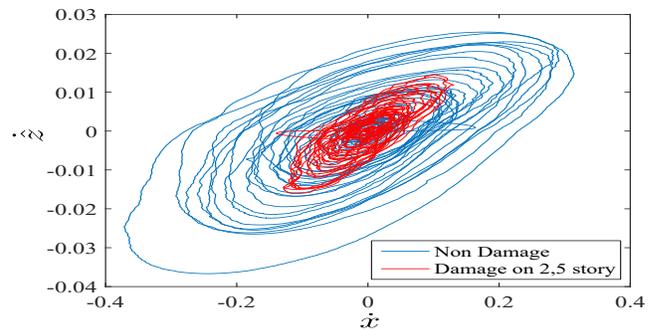


Fig. 7. Diagrama histérico del quinto piso en presencia de daños en el segundo y quinto piso

Es decir, las magnitudes son menores para las líneas en color rojo que corresponden al escenario 2 con daños en el segundo y quinto piso, en contraste con las líneas en naranja, donde el daño ocurre únicamente en el segundo piso. Por lo tanto, el enfoque propuesto basado en la energía disipada puede ser una herramienta alternativa útil para la detección de daño, ya que permite observar la dinámica estructural en términos de energía.

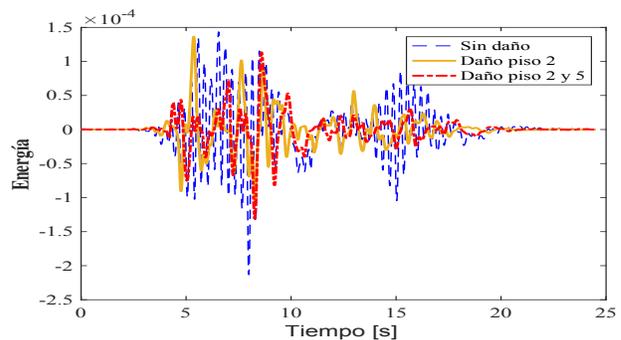


Fig. 8. Comparación de energía en el segundo piso, antes y después del daño

## 5. CONCLUSION

Se ha presentado un sistema de identificación no lineal basado en una red neuronal convolucional (CNN) para

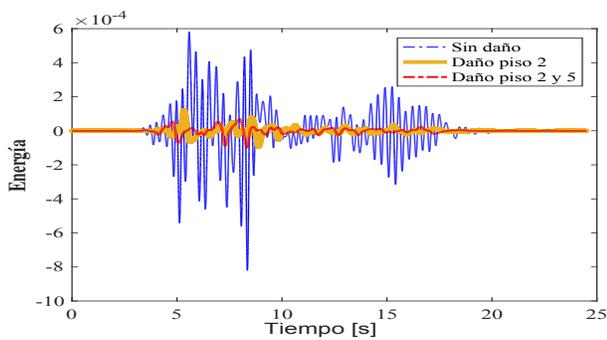


Fig. 9. Comparación de energía en el quinto piso, antes y después del daño

detección de daños en edificios. En este artículo, se ha propuesto un enfoque alternativo para identificar daño estructural en edificios que consiste en analizar la energía disipada utilizando el modelo histerético Bouc Wen. La CNN al no requerir un modelo matemático, evita el problema de la parametrización no-lineal. En comparación con otro tipo de redes, los pesos compartidos de la CNN reducen la complejidad del entrenamiento. Los resultados experimentales han confirmado que cuando un edificio presenta daño estructural, su capacidad para disipar energía se reduce. Este fenómeno es un claro indicador de la presencia de daño, que está directamente relacionado con la pérdida de rigidez. En este sentido, el modelo de Bouc Wen ha sido una herramienta útil para capturar la energía disipada. Además, los resultados experimentales confirman que el método propuesto es prometedor para aplicaciones prácticas.

#### AGRADECIMIENTOS

Los autores aprecian el apoyo del profesor Luis Alvarez-Icaza por los datos experimentales proporcionados. El segundo autor también agradece el apoyo financiero de CONACYT. Jesús Morales-Valdez desea expresar su agradecimiento a Cátedras-CONACyT. Esta investigación fue patrocinada por el proyecto SEP-Cinvestav 62.

#### REFERENCIAS

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

Chatzi, E.N., Smyth, A.W., and Masri, S.F. (2010). Experimental application of on-line parametric identification for nonlinear hysteretic systems with model uncertainty. *Structural Safety*, 32, 326–337.

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, 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(3), 477–507.

Doebling, S.W., Farrar, C., and Prime, M.B. (1998). A summary review of vibration-based damage identification methods. *The Shock and Vibration Digest*, 30(2), 1–34.

Farrar, C.R., Worden, K., Todd, M.D., Park, G., Nichols, J., Adams, D.E., Bement, M.T., and Farinholt, K. (2007). Nonlinear system identification for damage detection. *Report LA-14353, Los Alamos National Laboratory (LANL), Los Alamos, NM.*, 1–161.

Herak, M. and Herak, D. (2010). Continuous monitoring of dynamic parameters of the dgsm building (zagreb, croatia). *Bulletin of Earthquake Engineering*, 8(3), 657–669.

Huang, Q., Xu, Y., Li, J., Su, Z., and Liu, H. (2012). Structural damage detection of controlled building structures using frequency response function. *Journal of Sound and Vibration*, 331(15), 3476–3492.

Hwang, H.Y. and Kim, C. (2004). Damage detection in structures using a few frequency response measurements. *Journal of Sound and Vibration*, 270(1-2), 1–14.

Ikhouane, F., Mañosa, V., and Rodellar, J. (2005). Adaptive control of a hysteretic structural system. *Automatica*, 41, 225–231.

Kim, J.T., Ryu, Y.S., Cho, H.M., and Stubbs, N. (2003). Damage identification in beam-type structures: frequency-based method vs mode-shape-based method. *Engineering Structures*, 25(1), 57–67.

Kong, X., Cai, C.S., and Hu, J. (2017). The state-of-the-art on framework of vibration-based structural damage identification for decision making. *Applied Sciences*, 7(5), 497–510.

Ma, F., Ng, C.H., and Ajavakom, N. (2006). On system identification and response prediction of degrading structures. *Structural Control and Health Monitoring*, 13, 347–364.

Nair, K.K., Kiremidjian, A.S., and Law, K.H. (2006). Time series-based damage detection and localization algorithm with application to the asce benchmark structure. *Journal of Sound and Vibration*, 291, 349–368.

Nayeri, R.D., Masri, S.F., Ghanem, R.G., and Nigbor, R.L. (2008). A novel approach for the structural identification and monitoring of a full-scale 17-story building based on ambient vibration measurement. *Smart Materials and Structures*, 17(2), 1–19.

Smyth, A., Masri, S., Chassiakos, A., and Caughey, T. (1999). On-line parametric identification of mdof nonlinear hysteretic systems. *Journal of Engineering Mechanics*, 125, 133–142.

Sohn, H., Farrar, C., Hemez, F., Devin, D.S., Daniel, W.S., Brett, R.N., and Jerry, J.C. (2003). A review of structural health monitoring literature: 1996–2001. *Los Alamos National Laboratory Report, LA-13976-MS*, 1–331.

Wen, Y.K. (1976). Method for random vibration of hysteretic system. *Journal of the Engineering Mechanics Division*, 102(2), 249–263.