

Estudio experimental y simulación del comportamiento inelástico de paneles compuestos usando redes neuronales artificiales

Experimental and simulation study of compose panels inelastic behavior using Artificial Neural Networks

Wilmer Barreto ^{(*)(**)}, Ricardo Picón ^{(*)(**)}

RESUMEN

El análisis de estructuras complejas, como los paneles compuestos de varios materiales, es difícil de modelar producto de la variabilidad en las propiedades mecánicas de los materiales. Lo anterior, aunado a la no-linealidad en el comportamiento de los materiales, hace que la aplicación de los métodos tradicionales de cálculo numérico sea difícil y demande mayor tiempo de cómputo. El presente trabajo introduce técnicas menos convencionales de cómputo como lo son las redes neuronales artificiales (RNA) para la modelación de la deformación permanente y daños en una losa compuesta sujeta a flexión. Se entrenaron y verificaron 400 modelos de RNA, los cuales fueron capaces de modelar la no linealidad del elemento estructural a flexión, reproducir exitosamente los daños por agrietamiento y pandeo del panel, así como reproducir la deformación permanente global del elemento estudiado.

Palabras clave: Daños, Redes Neuronales Artificiales, análisis no lineal, paneles compuestos, estructuras no tradicionales, desplazamientos permanentes, experimentos a flexión.

ABSTRACT

The analysis of complex structures, such as panels composed of various materials, is difficult to model due to the variability in the mechanical properties of the materials. The foregoing, coupled with non-linearity in the behavior of materials, makes the application of traditional numerical methods difficult and highly demanding in computational time. The present work introduces a less conventional technique like the artificial neural networks (ANN) for the modeling of the permanent deformation and damages in a compose slab subjected to flexion. 400 ANN models were trained and verified, which were able to model the non-linearity of the structural element, successfully reproduce the damages due to cracking and buckling of the panel, as well as reproduce the global permanent deformation of the element.

Keywords: Damage, Artificial Neural Networks, no lineal behavior, compose panels, no traditional structures, permanent displacement, experimental test subject to bending.

(*) Dpto. Obras Civiles y Geología. Facultad de Ingeniería. Universidad Católica de Temuco, Temuco (Chile).

(**) Decanato de Ingeniería Civil. Universidad Lisandro Alvarado, Barquisimeto (Venezuela).

Persona de contacto/Corresponding author: rpicon@uct.cl (Ricardo Picón).

ORCID: <https://orcid.org/0000-0002-1861-0742> (W. Barreto); <https://orcid.org/0000-0001-6356-7360> (R. Picón).

Cómo citar este artículo/Citation: Barreto, W.; Picón, R. (2020). Estudio experimental y simulación del comportamiento inelástico de paneles compuestos usando redes neuronales artificiales. *Informes de la Construcción*, 72(558): e343. <https://doi.org/10.3989/ic.70957>.

Copyright: © 2020 CSIC. Este es un artículo de acceso abierto distribuido bajo los términos de la licencia de uso y distribución Creative Commons Reconocimiento 4.0 Internacional (CC BY 4.0).

Recibido/Received: 15/02/2019
Aceptado/Accepted: 05/08/2019
Publicado on-line/Published on-line: 09/06/2020

1. INTRODUCCIÓN

En la construcción de edificaciones se han incorporado nuevos materiales y técnicas constructivas, lo que ha conducido al desarrollo de diversos tipos sistemas estructurales cada día más complejos y difíciles de analizar. Esto hace que las herramientas de análisis deban evolucionar en la misma medida. Los sistemas estructurales se clasifican como sistemas tradicionales y no tradicionales, así mismo las herramientas que se emplean para su cálculo. Entre las herramientas numéricas de análisis, podemos citar el Método de Elementos Finitos (MEF). Las estructuras tradicionales están conformadas con materiales homogéneos y dimensiones regulares, por esta razón el método de análisis empleado en preferencia es el MEF (1, 2, 3). Por el contrario, las estructuras No Tradicionales están conformadas por elementos heterogéneos que combinan diferentes tipos de materiales y con secciones transversales compuestas por diversos materiales, lo que dificulta definir las propiedades mecánicas de la sección transversal de los elementos que lo conforman. Usar los MEF para analizar numéricamente estructuras no tradicionales, requiere de ajustes de diversos parámetros de los modelos usados en los elementos finitos para lograr reproducir los resultados experimentales. Este proceso es complicado, y aún más complejo al tomar en cuenta la no linealidad en el comportamiento de los materiales producto del daño (pérdida de rigidez) y de las deformaciones permanentes (elongaciones permanentes o pandeo local) (4, 5). Para estos casos se deben emplear métodos que puedan facilitar la simulación y reproducir estos fenómenos complejos. Otra de las desventajas del MEF, para estructuras compuestas, es que los métodos de análisis actuales requieren de muchas iteraciones para la inclusión de la no linealidad, por lo que el proceso es demorado en tiempo de cálculo, limitando su aplicabilidad.

Los sistemas tipo Sándwich son sistemas constructivos no tradicionales. Este sistema Sándwich es rápido y fácil de construir, capaz de soportar cargas externas y tener un buen comportamiento mecánico (6, 7). Los muros de corte de un sistema tipo sándwich pueden comportarse de buena forma bajo cargas laterales (8), así como también a fuerzas de impacto (9). La sección transversal de los elementos tipo sándwich está conformada por variedad de materiales, lo que dificulta realizar su modelación numérica mediante el MEF. En los elementos tipo sándwich es difícil definir las propiedades mecánicas entre los planos de contacto de los materiales que la conforman.

El avance tecnológico computacional ha permitido desarrollar algunos modelos numéricos para el análisis de estas estructuras sándwich (10). En el comportamiento de las estructuras sándwich se reflejan varios mecanismos de fallas, los cuales son analizados y explicados experimental y numéricamente en varios artículos de investigación (11). Entre algunos mecanismos de fallas se encuentran la inestabilidad local (12), el esfuerzo de corte en el núcleo, la pérdida global de la estabilidad (13). El análisis de estos mecanismos de falla requiere el uso de modelos numéricos apropiados que son difíciles de implementar, producto de la incertidumbre en la definición de los parámetros requeridos en los modelos numéricos. Producto del planteamiento anterior, se requiere desarrollar nuevos métodos que representen los mecanismos de fallas antes citados.

En este artículo se presenta el desarrollo de un modelo basado en redes neuronales artificiales (RNA), el cual consiste en un programa de recolección de datos experimentales para conocer el comportamiento inelástico de una losa de techo tipo

sándwich sujeta a flexión pura. El mismo pretende emular la evolución de las deformaciones permanentes y la caída de la rigidez inicial según el daño producido en los materiales. Otro aspecto que se aborda es la disipación de energía producida por el amortiguamiento de los materiales que conforman el elemento (14). Este efecto de amortiguamiento se evidencia al observar la curva de Carga vs. Desplazamiento, donde se aprecia que el recorrido del ciclo de descarga y recarga no es el mismo, como se observará en la sección de ensayo experimental.

El uso de RNAs facilitaría el análisis, ya que emplea un conjunto de ecuaciones más simples y eficientes, para resolver el problema (15, 16), mientras que los métodos convencionales requieren del uso de un conjunto de ecuaciones más complejas. Los métodos de RNA ha sido aplicado no solo en análisis estructural, sino también en el área de geotecnia, estructuras, hidráulica y nanotecnología (17, 18, 19, 20), pero poco empleado para modelar el comportamiento de estructuras de tipo compuesto, como los paneles tipo sándwich, que se analizan en el presente trabajo.

Las variables de daños en elementos de hormigón armado miden el nivel de fisuración o agrietamiento que sufre el hormigón (4, 5), mientras que en las estructuras de acero, las variables de daño miden el grado de pandeo local del elemento de acero (1). Ambos fenómenos físicos (grietas o fisuras en el hormigón y pandeo local del perfil de acero) provocan la pérdida de rigidez del elemento y por ende de la estructura. También se propone la evaluación del daño global del panel tipo sándwich experimentalmente. Por ser un panel compuesto con diferentes materiales, el daño global que se presentan al ser sometido a acciones externas son la combinación de fisuras, grietas y pandeo del panel de techo tipo sándwich. Al final del artículo, se presenta una evaluación y comparación de esta variable de daño global obtenidas mediante simulaciones usando las RNA y los observados experimentalmente.

2. ENSAYO EXPERIMENTAL

Se construyeron y ensayaron un grupo de paneles compuestos en el Laboratorio de Mecánica Estructural de la Universidad Centroccidental "Lisandro Alvarado", UCLA - Venezuela. Cada panel es un elemento básico estructural no tradicional que conforma la losa de techo de una estructura más compleja. El tipo de ensayo experimental realizado a cada panel construido es el mostrado en la figura 3 y el análisis solo se realizó a flexión, ya que las variables principales a evaluar son la fuerza aplicada y la flecha que alcanza el panel hasta su falla, al someter cada panel a esfuerzos a flexión pura.

2.1. Especificaciones del panel compuesto

La losa de techo está conformada por el ensamblaje de varios paneles compuestos (Figura 1a). Cada panel tiene dimensiones de 340 cm x 40 cm x 10 cm (Figura 1b), para cubrir una luz libre de 300 cm.

El panel compuesto está conformado por varios materiales (Figura 2b). Uno de los materiales son dos placas de hormigón reforzado de alta resistencia de espesor de 14 mm, ubicadas en la parte superior e inferior del panel. Estas dos placa de hormigón están separadas por material de Poliuretano Expandido (EPS) y estos dos materiales son confinados por una lámina de acero doblada en frío obteniendo una forma especial de su sección transversal (Figura 2a).




Figura 1. a) Losa de techo. b) Dimensiones del Panel Compuesto.

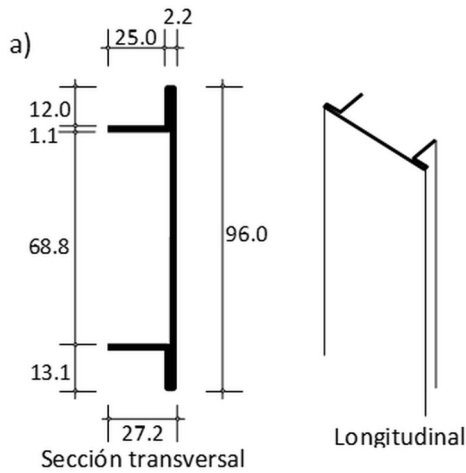


Lámina de acero doblada en frío con forma especial




Figura 2. a) Lámina de acero doblada en frío. b) Sección Transversal.

2.2. Propiedades mecánicas de los materiales del panel compuesto

La placa de hormigón de alta resistencia de espesor de 14 mm es reforzada por una malla de fibra de carbono ubicada el medio de la placa de hormigón. La resistencia del hormigón alcanza valores de 30 MPa. La lámina de acero doblada en frío fue sujeta a ensayos a tensión y se obtuvo un esfuerzo último promedio de 283 MPa.

2.3. Implementación del ensayo experimental

Varios ensayos experimentales se realizaron, evaluando el comportamiento de los paneles sometidos a esfuerzos de flexión pura. Este tipo de ensayo experimental fue hecho debido a la complejidad de la sección transversal. Conocer el comportamiento real del panel compuesto a flexión y encontrar la máxima carga resistente es importante. Los paneles fueron

implementados para los ensayos experimentales usando dos soportes simples y puntos de aplicación de carga a $L/3$ del panel (21, 22) (Figura 3). Este esquema de ensayo permite identificar el comportamiento a flexión pura en el tercio central (figura 3 – Momento).

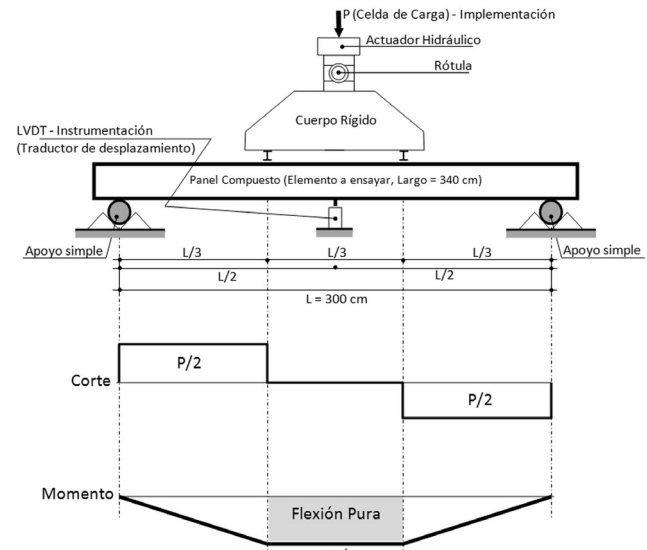


Figura 3. Esquema del ensayo experimental del Panel Compuesto y Diagramas de Corte y Momento.

Los paneles compuestos son sometidos a una historia de desplazamientos cíclicos positivos, como se muestran en la figura 4. Al realizar el ensayo experimental, la variable de control es el desplazamiento y es aplicado con un actuador hidráulico como se observa en el esquema 4 y la figura 6. Durante la descarga, el desplazamiento es controlado y se detiene en el momento que la carga en el actuador alcanza el valor de cero. La figura 5a y 5b, muestra la implementación del ensayo experimental en el Laboratorio propuesto en la figura 3. El desplazamiento fue medido justo en el centro de la luz del panel usando el transductor de desplazamiento LVDT (figura 5).

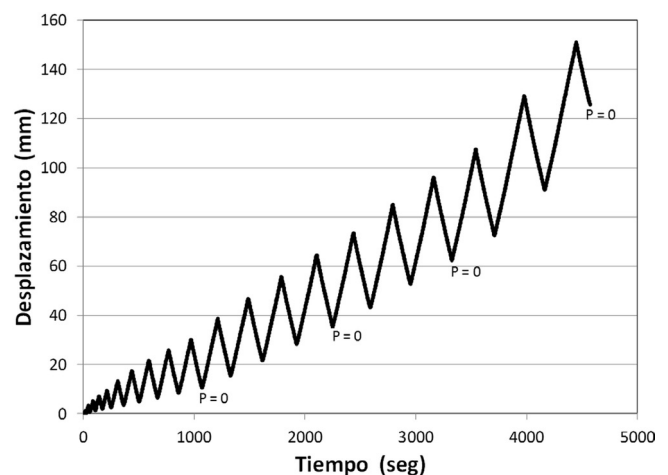


Figura 4. Historia de desplazamiento.

2.4. Resultados experimentales

Todos los paneles compuestos ensayados experimentalmente arrojaron resultados similares y se presenta en este artículo uno de ellos. La curva de comportamiento (Fuerza vs. Desplazamiento) del panel compuesto sometido a ensayos a flexión




Figura 5. a) Vista global de la implementación experimental. b) LVDT ubicado en el centro de la luz del panel.

tura se muestra en la figura 6. Se tiene un registro que alcanza una fuerza máxima de 7139 N a un desplazamiento de 140 mm. Se puede representar la evolución de las deformaciones permanentes a lo largo del ensayo y se muestra en la figura 7.

Los resultados mostrados en la figura 6, donde se refleja una rigidez inicial del panel compuesto, también se observa que la rigidez disminuye a medida que se avanza en el ensayo experimental (ver figura 8b). Esta rigidez se logra obtener al determinar

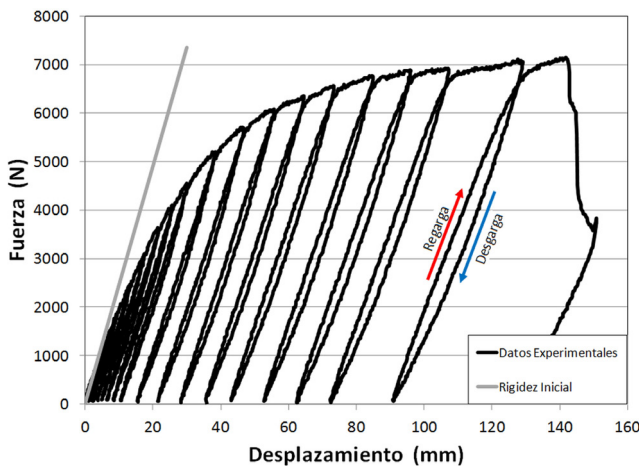


Figura 6. Curva de comportamiento del panel compuesto.

la pendiente de la línea recta en la descarga de cada ciclo, por ser una descarga elástica (Z_n). La disminución de la rigidez es producto de la presencia de fisuras o grietas que presenta la lámina inferior de hormigón y el inicio de un pandeo local que comienza a sufrir la lámina de acero que refuerza al panel en todo su perímetro (figura 8b y 9a). Los valores máximos de fuerza se obtienen justo antes de presentar la falla (figura 8a). El tipo de falla frágil presentada se genera en el último ciclo de carga aplicada en el panel compuesto. Y se produce por el incremento del pandeo local de la lámina de acero doblada en frío y la grieta brusca de la lámina superior de hormigón reforzado (ver figura 9a y 9b).

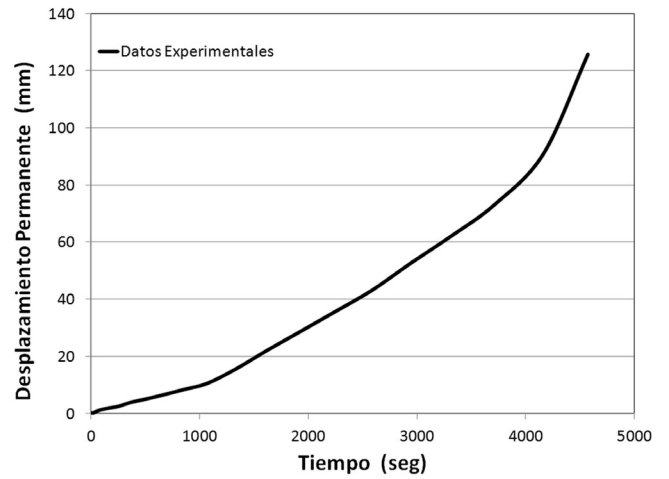


Figura 7. Evolución de los desplazamientos permanentes.

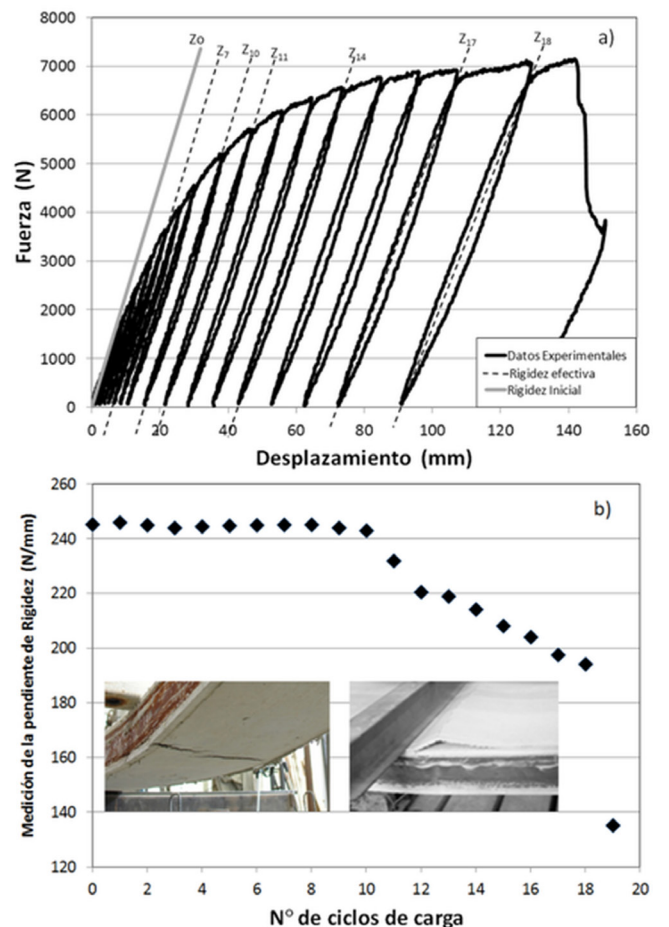


Figura 8. a) Medición de la rigidez en cada ciclo. b) Variación de la rigidez a lo largo del ensayo.




Figura 9. a) Pandeo local de la lámina de acero. b) Falla frágil, fractura brusa de la placa superior.

Analizando la variación de la rigidez a lo largo del ensayo experimental, las pendientes calculadas en la figura 8, se propone determinar la evolución de una variable de daño global “dG”. Esta variable de daño global se determina de acuerdo a la comparación de la rigidez en cada ciclo de descarga “Zi” con la rigidez inicial “Zo” [4, 5]. La evolución del “dG” medido experimentalmente puede ser determinada usando la expresión matemática de la ecuación [1].

$$[1] \quad dG = 1 - Zi / Zo$$

La figura 10 representa la evolución del “dG” experimental, observándose una evolución lineal del daño global después de superar el décimo ciclo de carga.

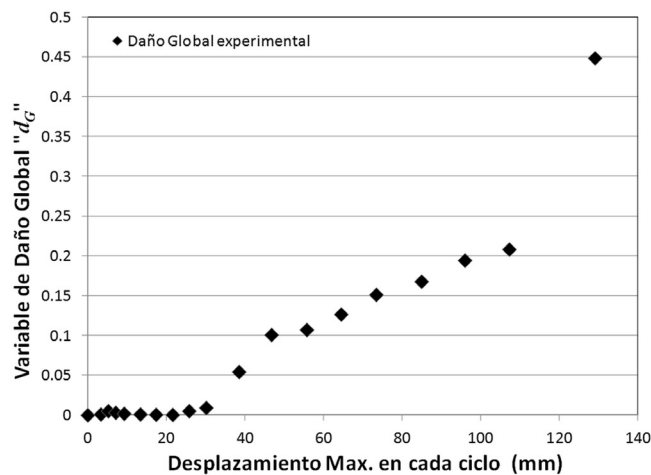


Figura 10. Evolución del Daño Global experimentalmente y tendencia.

3. REDES NEURONALES ARTIFICIALES

Una red neuronal artificial (RNA) es una técnica basada en el comportamiento biológico del cerebro y desarrollada para ser utilizada en aplicaciones de aprendizaje automático. La neurona es la unidad básica del cerebro y en el aprendizaje de máquinas se imita utilizando el llamado perceptrón (23). El perceptrón introducido inicialmente por Rosenblatt, se ha ido mejorando a lo largo de los años y ha evolucionado en una compleja red de perceptrones para convertirse en lo que hoy denominamos las RNA. Las RNA están compuestas principalmente por tres capas: una capa de entrada vectorial, una o más capas ocultas y una capa de salida vectorial, como se muestra en la Figura 11.

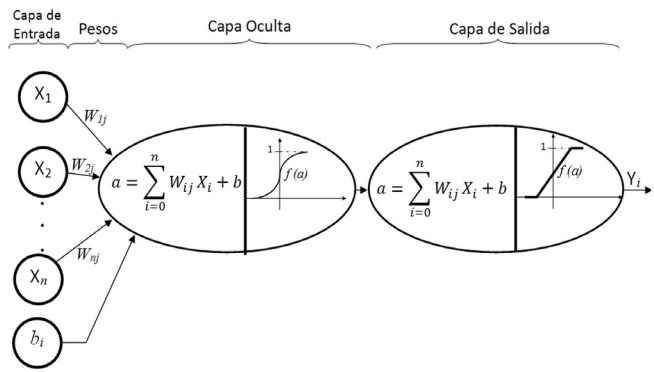


Figura 11. Estructura de RNA: Capas de entrada, ocultas y de salida.

Las RNAs más conocidas y utilizadas son las de alimentación hacia delante (Feedforward), una red de este tipo suele entrenarse utilizando un algoritmo de propagación hacia atrás. La capa de entrada (Xi) está conectada a la capa oculta por medio de pesos (wij). El resultado del producto escalar, entre entradas y pesos, se pasa a una función de transferencia para activar la capa de salida (Yi). Estos resultados de salida se comparan con un conjunto de objetivos durante la fase de entrenamiento, y los errores se calculan y corrigen cambiando el valor de los pesos, esto se realiza mediante un algoritmo de optimización que minimiza los errores en forma iterativa, este proceso se conoce con el nombre de “entrenamiento” de la red.

En el presente trabajo los datos experimentales se pre-procesaron antes de la construcción del modelo RNA. Esto se efectuó con la finalidad de eliminar el ruido introducido en los datos adquiridos de los equipos electrónicos. Los valores de fuerza y desplazamiento se “suavizaron” utilizando una media móvil, con un marco de 100 valores de datos, tanto para el desplazamiento como para la fuerza. Los datos posteriores al fallo del elemento estructural se eliminaron del conjunto de entrenamiento para no afectar la generalización de la misma, con estos valores pre-procesados se entrena la RNA. En total, se utilizaron 2555 pares de valores de fuerza y deformación en el proceso de entrenamiento.

3.1. Implementación de modelos RNA sin y con efecto de amortiguación

Para la elaboración de los modelos se dividieron los datos pre-procesados en tres conjuntos: un conjunto (70%) para entrenamiento propiamente dicho, un segundo conjunto (15%) para validación cruzada y el restante (15%) fue utilizado para la verificación de la red entrenada. El error medio cuadrático (EMC) se seleccionó como indicador del rendimiento o buen ajuste de la red. También se usó con los datos de validación cruzada en la fase de entrenamiento como criterio de parada del proceso de aprendizaje.

La Figura 6 muestra los datos medidos sin procesar, se puede observar que para cada ciclo de carga y descarga existen dos ramas. La rama a la izquierda corresponde al ciclo de carga y la rama a la derecha correspondiente al ciclo de descarga, este efecto se debe al coeficiente de amortiguamiento del elemento y a la capacidad de absorción de energía. Debido a este efecto de amortiguación en los materiales, se decidió construir dos modelos: uno con amortiguación y el otro sin amortiguación.

Los dos modelos instanciados se diferencian en la capa de entrada de cada modelo de RNA, ambos modelos están contruidos para obtener la fuerza dada la deformación vertical. La capa de entrada para el modelo sin amortiguación está compuesta por dos entradas: la deformación vertical (δ_i) y la deformación vertical máxima (δ_{MAX}) aplicada al elemento estructural. El modelo con amortiguación tiene las mismas dos entradas del modelo sin amortiguación, más la deformación vertical aplicada en el paso de carga anterior (δ_{i-1}).

Como se explicó anteriormente, la RNA usada fue “*Feedforward*” y entrenada usando un algoritmo de propagación hacia atrás. Se escribió un código script en MATLAB© para entrenar la red. Este script entrena 50 redes neuronales artificiales que cambian la semilla inicial y obtienen varios modelos con diferentes pesos y rendimientos (EMC). Estos 50 modelos se clasificaron utilizando un algoritmo de agrupación usando “*k-mean*”, en función del número de epochs y el EMC. El resultado originó tres grupos (figura 12), cuyos centros de clúster indican el mejor número de epochs a usar para el entrenamiento de la red y su rendimiento asociado (EMC).

El procedimiento descrito en el párrafo precedente se repite para 1, 2, 3 y 4 nodos en la capa oculta de la RNA. En total se elaboraron 400 modelos con y sin amortiguación. De este conjunto se seleccionaron los dos mejores modelos, uno sin amortiguación y el otro con amortiguación. Cada modelo fue validado de nuevo utilizando una historia sintética de desplazamiento, esto con la finalidad de observar el rendimiento de los modelos con datos que nunca se usaron para el entrenamiento o validación cruzada. Se llevaron a cabo dos pruebas: la primera se realizó con el propósito de verificar el comportamiento del modelo bajo interpolación y la segunda para verificar las capacidades de extrapolación.

3.2. Entrenamiento de los Modelos de RNA

Los 400 modelos fueron agrupados para ayudar a identificar los mejores parámetros para el entrenamiento de la RNA. Las figuras de la 12 a la 15 muestran los resultados del agrupamiento para el modelo con amortiguación para 1, 2, 3 y 4 nodos en la capa oculta. Al comparar y analizar estas figuras, se puede observar que el modelo mejora el rendimiento (EMC) cuando aumenta el número de nodos en la capa oculta. Este comportamiento puede explicarse porque cuanto mayor es el número de nodos mejor capacidad de aprendizaje tiene el modelo ANN, producto de los mayores grados de libertad para el ajuste.

Inicialmente, los centros de los grupos comienzan con un bajo rendimiento, alto valor del EMC, cuando el número de epochs es bajo (menos de 150) y mejora para un rango entre 150 y 500 epochs. Luego, el rendimiento comienza a disminuir para valores superiores a 500 epochs. El comportamiento visto en las figuras 12 al 15, en relación con el número de epochs, da una indicación de la capacidad de generalización del modelo de RNA. Esta disminución del rendimiento para valores de epochs mayores de 500 indica que la red está sufriendo de sobre-aprendizaje, por lo que va perdiendo su capacidad de generalización y de reproducir el fenómeno físico. Así mismo, entre más grande la pendiente de crecimiento del EMC del centro del grupo 2 al 3, más pérdida de confiabilidad tendrá esa red.




Figura 12. Centro de grupos para el modelo con 1 nodo oculto.




Figura 13. Centro de grupos para el modelo con 2 nodos ocultos.




Figura 14. Centro de grupos para el modelo con 3 nodos ocultos.

El grupo con el mejor rendimiento en la validación cruzada, para 1, 2, 3 y 4 nodos ocultos, se muestra en la Tabla 1. Se puede observar que el número de epochs con el mejor rendimiento varía entre 200 y 250 epochs, esto es independiente del número de nodos ocultos. El modelo con 4 nodos ocultos tiene el EMC más bajo y por lo tanto el mejor rendimiento promedio. Los mejores modelos individuales para 1, 2, 3 y 4 nodos ocultos se muestran también en la Tabla 1. El mejor modelo individual pertenece al modelo con dos nodos ocultos, con un valor de EMC de 4548.85 y se obtuvo para 425 epochs.

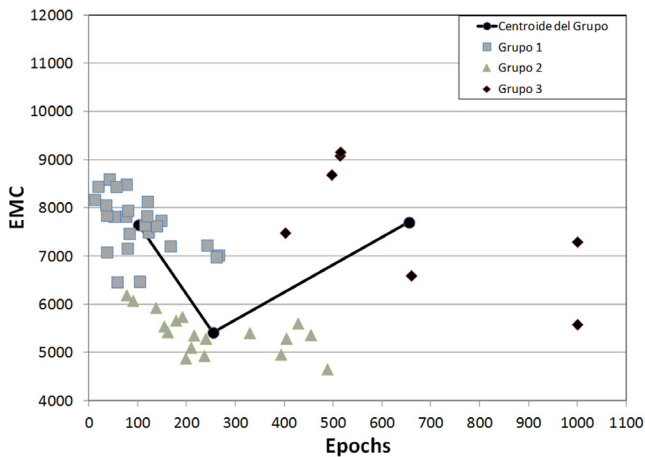


Figura 15. Centro de grupos para el modelo con 4 nodos ocultos.

Tabla 1. Rendimiento para los centros de grupo y mejor modelo.

Modelo	Centroide del grupo		Mejor modelo	
	Epochs	EMC	Epochs	EMC
1 Nodo Oculto	205.54	6117.32	245.00	4899.43
2 Nodos Ocultos	252.50	6015.32	425.00	4548.85
3 Nodos Ocultos	204.26	6023.58	459.00	5073.43
4 Nodos Ocultos	254.50	5411.47	488.00	4654.68

Los resultados muestran que el mejor rendimiento promedio pertenece a los modelos con 4 nodos ocultos. Sin embargo, estos modelos perdieron generalización rápidamente cuando aumenta el número de epochs, mostrando sobre aprendizaje de la red. Al comparar los modelos con 2 y 3 nodos ocultos estos muestran un rendimiento y generalización promedio similar, pero los modelos con 2 nodos ocultos presentan un mejor desempeño individual. Similar condición se observa en los modelos sin amortiguación. Finalmente, los modelos seleccionados como los de mejor desempeño, según su EMC y capacidad de generalizar el problema, son los modelos de 2 nodos en su capa oculta, tanto los que consideran amortiguación como los que no cuentan con ella.

4. VALIDACIÓN DE LOS MODELOS RNA

Para validar los modelos, se realizaron tres pruebas para cada modelo seleccionado con y sin amortiguación. La primera prueba tiene que ver con el proceso de entrenamiento de la RNA. El entrenamiento de los modelos usando RNAs se realizó aplicando tres conjuntos de datos como se explicó en párrafos precedentes: un conjunto para el entrenamiento, otro conjunto para validación cruzada y el último conjunto para la verificación. Luego, los resultados del modelo se confrontaron con todo el conjunto de datos observados. La Figura 16 muestra el historial de desplazamiento usado para alimentar el modelo, se puede observar que los modelos con y sin amortiguación reproducen con precisión los datos medidos en el laboratorio, ver Figuras 17 y 18. El modelo con amortiguación puede reproducir con mayor precisión los datos observados al compararlo con el modelo sin amortiguación.

La segunda prueba tiene como objetivo verificar la capacidad de los modelos de RNAs para la interpolación. Esta es una prueba complementaria para verificar si el modelo obtuvo una buena generalización. El modelo fue sometido a una nueva his-

toria de desplazamientos; la historia de desplazamiento se seleccionó de tal manera que no coincida con los datos previamente utilizados en el entrenamiento, prueba o verificación del modelo de RNA, ver Figura 16. La última prueba realizada fue la representación de la curva de comportamiento extrapolando los datos de entrenamiento del modelo. Similar a la interpolación, la extrapolación es una forma de verificar la generalización en el entrenamiento de la red neuronal artificial.

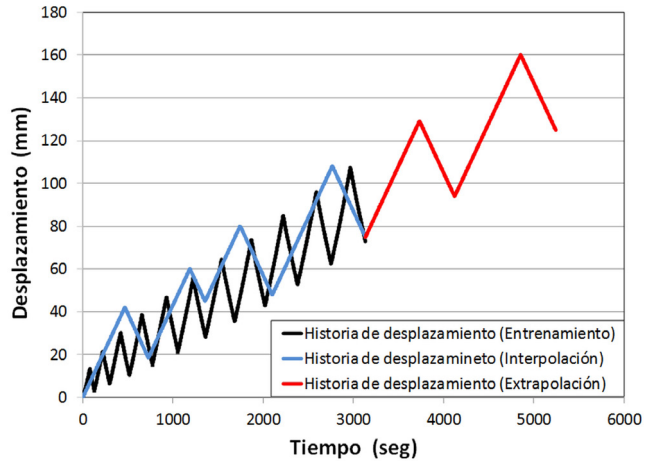


Figura 16. Historial de desplazamiento utilizado para el entrenamiento de la RNA y validaciones.

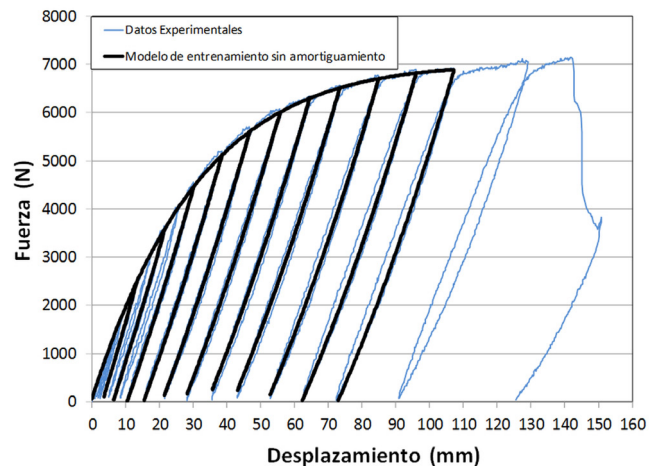


Figura 17. Entrenamiento del modelo vs. datos medidos sin efecto de amortiguación.

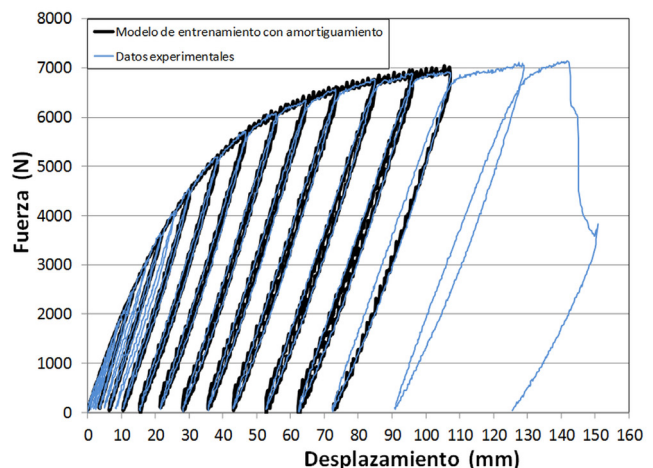


Figura 18. Modelo de entrenamiento con amortiguamiento.

Las figuras 19 y 20, muestran los resultados gráficos de la interpolación y extrapolación para los modelos con y sin amortiguación respectivamente. Se puede observar que ambos modelos pueden representar el comportamiento inelástico con la interpolación y la extrapolación. El modelo con amortiguación pudo extrapolar un 20% más allá del rango utilizado para el entrenamiento con buena precisión, mientras que el modelo sin amortiguación pudo extrapolar el mismo 20% pero con menos precisión. En el modelo sin amortiguación, la curva se vuelve casi horizontal cuando extrapola, mientras que el modelo con amortiguación tiene un comportamiento más estable y realista al comprar con los datos experimentales.

Los resultados muestran cómo la red neuronal artificial puede modelar el comportamiento no lineal de la curva de Fuerza vs. Desplazamiento. Una de las características importantes a destacar, es cuando el modelo está sujeto a un ciclo de carga y descarga, se puede evidenciar que al descargar no regresa a su deformación inicial, sino que tiene una deformación permanente o residual. Todas las simulaciones realizadas con los dos modelos de RNA representaron de muy buena forma la deformación permanente y la caída de la rigidez al ser comparados con la curva experimental. Demostrando que ambos modelos, con y sin amortiguación, pueden replicar las curvas de comportamiento inelástico de los paneles compuestos. Al

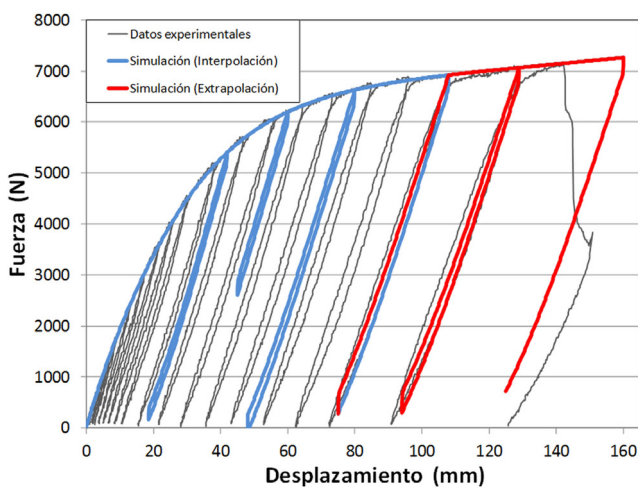


Figura 19. Modelo de interpolación y extrapolación con efecto de amortiguación.

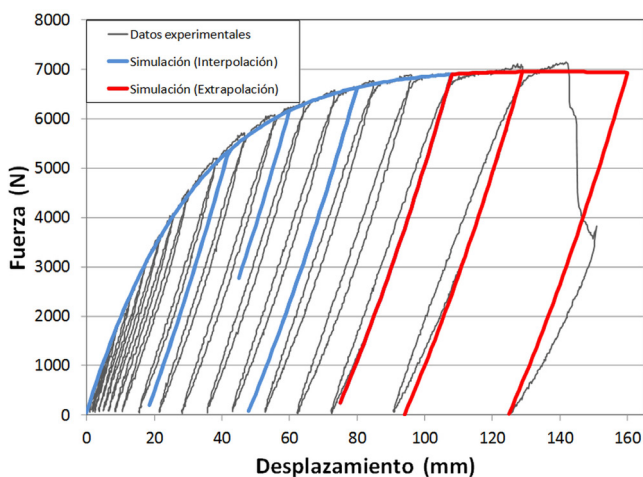


Figura 20. Modelo de interpolación y extrapolación sin efecto de amortiguación.

medir la evolución de las deformaciones permanentes y las fisuras o grietas de los materiales que conforman el panel, se puede deducir que el modelo tiene “memoria” de las cargas y deformaciones anteriores a las que ha sido sometido el elemento y considera el daño global producido.

En el momento del entrenamiento de las RNAs, con y sin tomar el efecto de amortiguación del material, se puede apreciar que la evolución de las deformaciones permanentes es idéntica a la evolución durante el ensayo experimental del panel (figura 21a). También se comparó la evolución de la variable de daño global entre los resultados experimental y los resultados durante el entrenamiento de las RNAs (figura 21b), y se puede apreciar que el modelo de RNA con efecto de amortiguación se ajusta mejor al comportamiento real del sistema no tradicional evaluado en este trabajo.

Al realizar las simulaciones, con y sin efecto de amortiguación, con una historia de desplazamiento arbitraria en el rango de los datos de entrenamiento (interpolación) (figura 16 color azul) y otros datos más allá del entrenamiento (extrapolación) (figura 16 color rojo) se observa que los modelos representan el comportamiento inelástico de forma adecuada. Al analizar los resultados de las simulaciones y ver la evolución de las deformaciones permanentes se puede apreciar que se ajusta muy bien a los resultados experimentales (figura 22a). Otra variable a analizar de los resultados simulados es la degradación de la rigidez y la obtención de la evolución del daño global del panel compuesto. Observando esta varia-

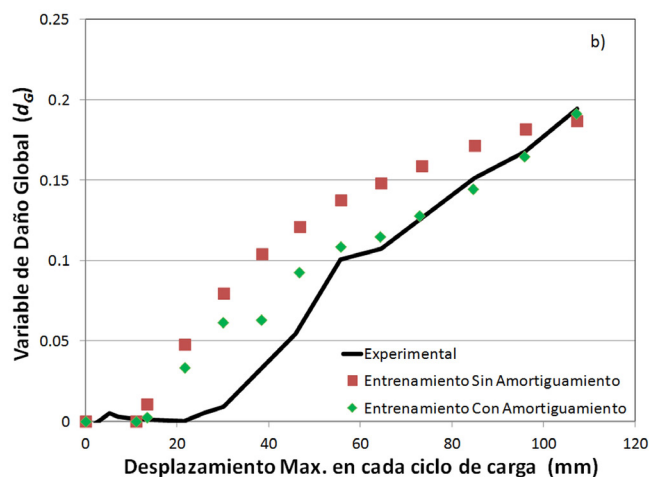
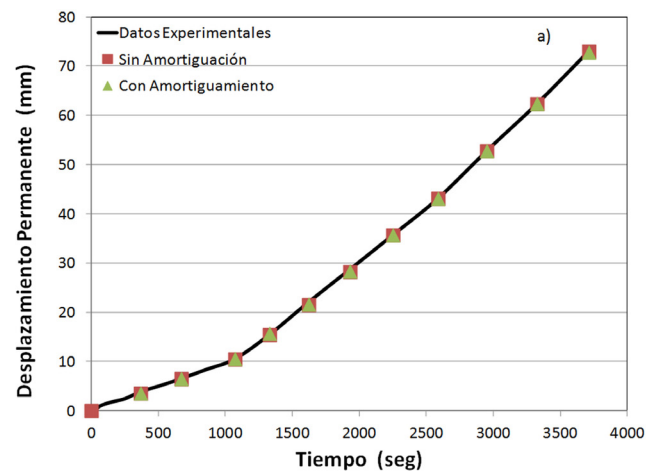


Figura 21. a) Evolución de las deformaciones permanentes y b) Evolución de la variable de daño global.

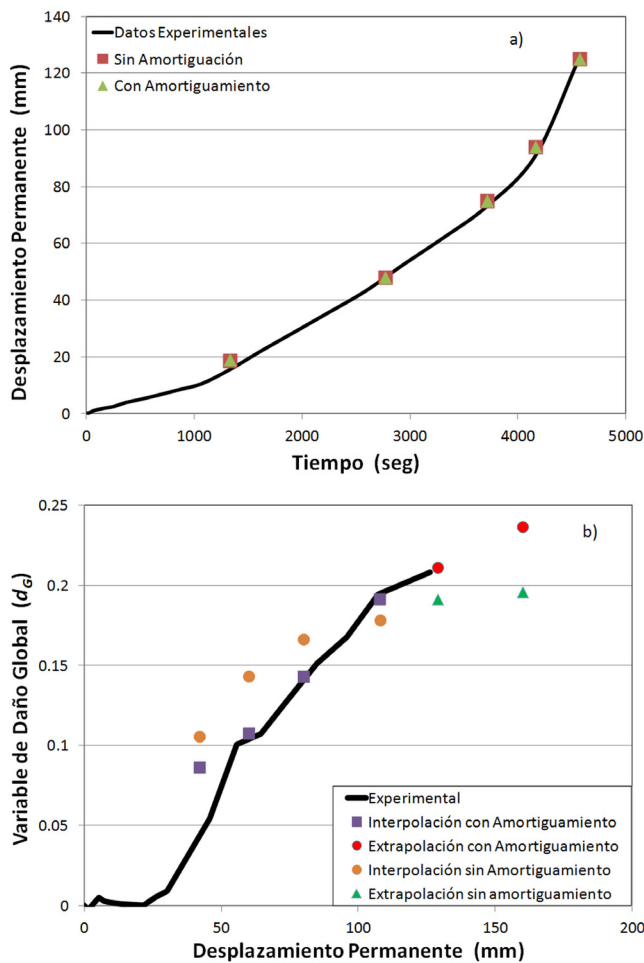


Figura 22. Resultados durante las simulaciones a) Evolución de las deformaciones permanentes y b) Evolución de la variable de daño global.

ble se aprecia que el modelo con amortiguación, considerando los datos de interpolación y extrapolación, se ajusta mucho mejor a los resultados experimentales (figura 22b).

El excelente rendimiento de ambos modelos, demuestra la viabilidad de utilizar modelos RNA para el análisis y evaluación estructural conformadas por elementos compuestos. Aunque se requiere de más investigación sobre la incorporación de otras variables, como la resistencia del mortero, la malla de refuerzo y el perfil de acero, ya que estas ayudarían a mejorar el comportamiento predictivo de los modelos de RNAs. Estas variables también ayudarían a usar el modelo no solo para la simulación sino también para el diseño y evalua-

ción de estructuras tradicionales y no tradicionales. Debido al rendimiento obtenido, se puede argumentar que es factible construir un modelo híbrido para el análisis de estructuras más complejas. Los cuales podrían combinar esquemas numéricos y redes neuronales artificiales trabajando conjuntamente. Esto podría mejorar la modelación en términos de no linealidad, así como también ahorrar tiempo de cálculo.

5. CONCLUSIONES

Dos modelos de ANN han sido exitosamente instanciados y validados. Los mismos permiten calcular la fuerza aplicada dado el desplazamiento de un elemento estructural complejo y viceversa. Los modelos instanciados son capaces de simular los efectos no lineales producidos en los materiales debido a las deformaciones plásticas en el acero y las grietas en el hormigón reforzado. Además, los modelos pueden determinar la deformación residual al descargar el elemento, lo que permite estimar el daño global producido en el elemento.

Para el elemento compuesto estudiado, el mejor rendimiento promedio (EMC) se obtuvo para las RNAs con 2 nodos ocultos y 200-250 epochs en ambos modelos. Estos valores proporcionan la mejor generalización en la fase de entrenamiento de los modelos. El modelo que considera la amortiguación interna de los materiales tiene un rendimiento ligeramente superior que el modelo sin amortiguación (EMC de 4548.85), este reproduce las ramas en bucle, lo que significa que el modelo tiene en cuenta la disipación de energía en los materiales así como el daño que se produce.

Otra de las características resaltante en los modelos entrenados, es que los mismos son capaces de interpolar y extrapolar, demostrando que las RNAs poseen una buena generalización y es posible elaborar modelos complejos. Las RNAs pueden representar el comportamiento inelástico de paneles compuestos. Representando la evolución de las deformaciones permanentes y el daño global del panel de manera adecuada. Se abre la posibilidad de emplear las RNA en combinación con modelos de tipo numérico o método de elementos finitos para la incorporación de los efectos inelásticos, creando así un modelo de tipo híbrido.

AGRADECIMIENTO

Los resultados presentados en este artículo son producto de una investigación financiada por la EMPRESA INGENIERIA CREATIVA (IC), C.A., por la Universidad Centroccidental "Lisandro Alvarado" (UCLA - Venezuela) y la Universidad Católica de Temuco, (UCT - Chile).

REFERENCIAS

- (1) Guerrero, N., Marante, M.E., Picón, R., and Flórez-López, J. (2007). Model of local buckling in steel hollow structural elements subjected to biaxial bending. *Journal of Constructional Steel Research*, 63(6): 779–790. <https://doi.org/10.1016/j.jcsr.2006.08.006>
- (2) Perdomo, M.E., Picón, R., Marante, M.E., Hild, F., Roux, S., and Flórez-López, J. (2013). Experimental analysis and mathematical modeling of fracture in RC elements with any aspect ratio. *Engineering Structures*, 46: 407–416. <https://doi.org/10.1016/j.engstruct.2012.07.005>
- (3) Thomson, E.D., Perdomo, M.E., Picón, R., Marante, M.E., and Flórez-López, J. (2009). Simplified model for damage in squat RC shear walls. *Engineering Structures*, 31(10): 2215–2223. <https://doi.org/10.1016/j.engstruct.2009.05.020>
- (4) Cipollina, A., López-Inojosa, A., and Flórez-López, J. (1995). A simplified damage mechanics approach to nonlinear analysis of frames. *Computers & Structures*, 54(6): 1113–1126. [https://doi.org/10.1016/0045-7949\(94\)00394-I](https://doi.org/10.1016/0045-7949(94)00394-I)

- (5) Alarcón, E. *et al.* (2001). A reparability index for reinforced concrete members based on fracture mechanics. *Engineering Structures*, 23(6): 687–697. [https://doi.org/10.1016/S0141-0296\(00\)00075-4](https://doi.org/10.1016/S0141-0296(00)00075-4)
- (6) Mohamed, M., Hussein, R., Abutunis, A., Huo, Z., Chandrashekhara, K., and Sneed, L. (2016). Manufacturing and evaluation of polyurethane composite structural insulated panels. *Journal of Sandwich Structures & Materials*, 18(6): 769–789. <https://doi.org/10.1177/1099636215626597>
- (7) Poluraju, P. and Rao, G.A. (2014). Behaviour of 3D-Panels for Structural Applications under General Loading: A State-of-the-Art. *International Journal of Research in Engineering and Technology*, 3(16): 173-181. <https://doi.org/10.15623/ijret.2014.0328027>
- (8) De Matteis, G. and Landolfo, R. (1999). Structural behaviour of sandwich panel shear walls: An experimental analysis. *Materials and Structures*, 32(5): 331–341. <https://doi.org/10.1007/BF02479624>
- (9) Rotaru, F., Rosculeț, R., Chirica, I., and Beznea, E.-F. (2016). Experimental Analysis of the Sandwich Composites Loaded to Mechanical Impact. In *Advanced Composite Materials Engineering*, pp. 198–203.
- (10) Pozorska, J. (2018). Numerical modelling of sandwich panels with a non-continuous soft core. *MATEC Web Conferences*, 157(06007): 1-9.
- (11) Hohe, J. and Librescu, L. (2004). Advances in the Structural Modeling of Elastic Sandwich Panels. *Mechanics of Advanced Materials and Structures*, 11(4–5): 395–424. <https://doi.org/10.1080/15376490490451561>
- (12) Koissin, V., Shipsha, A., and Skvortsov, V. (2010). Effect of Physical Nonlinearity on Local Buckling in Sandwich Beams. *Journal of Sandwich Structures & Materials*, 12(4): 477–494. <https://doi.org/10.1177/1099636209104521>
- (13) Steeves, C.A. and Fleck, N.A. (2004). Collapse mechanisms of sandwich beams with composite faces and a foam core, loaded in three-point bending, Part II: experimental investigation and numerical modelling. *International Journal of Mechanical Sciences*, 46(4): 585–608. <https://doi.org/10.1016/j.ijmecsci.2004.04.004>
- (14) Darendeli, M.B. (2001). *Development of a New Family of Normalized Modulus Reduction and Material Damping Curves*. The University of Texas at Austin. Retrieved from <http://hdl.handle.net/2152/10396>
- (15) Hadi, M. N. S. (2003). Neural networks applications in concrete structures. *Computers & Structures*, 81(6): 373–381. [https://doi.org/10.1016/S0045-7949\(02\)00451-0](https://doi.org/10.1016/S0045-7949(02)00451-0)
- (16) Zopf, C. and Kaliske, M. (2017). Numerical characterisation of uncured elastomers by a neural network based approach. *Computers & Structures*, 182: 504–525. <https://doi.org/10.1016/j.compstruc.2016.12.012>
- (17) Haj-Ali, R., Kim, H.-K., Koh, S.W., Saxena, A., and Tummala, R. (2008). Nonlinear constitutive models from nanoindentation tests using artificial neural networks. *International Journal of Plasticity*, 24(3): 371–396. <https://doi.org/10.1016/j.ijplas.2007.02.001>
- (18) Freitag, S., Cao, B.T., Ninić, J., and Meschke, G. (2018). Recurrent neural networks and proper orthogonal decomposition with interval data for real-time predictions of mechanised tunnelling processes. *Computers & Structures*, 207: 258–273. <https://doi.org/10.1016/j.compstruc.2017.03.020>
- (19) Šćepanović, B., Knežević, M., and Lučić, D. (2014). Methods for determination of ultimate load of eccentrically patch loaded steel I-girders. *Informes de la Construcción*, 66(Extra-1): m018. <https://doi.org/10.3989/ic.13.076>
- (20) Núñez Tabales, J.M., Rey Carmona, F.J., Caridad y Ocerin, J.M. (2017). Redes neuronales (RN) aplicadas a la valoración de locales comerciales. *Informes de la Construcción*, 69(545): e179. <https://doi.org/10.3989/ic.15.053>
- (21) ASTM E564-06 (2018). Standard Practice for Static Load Test for Shear Resistance of Framed Walls for Buildings. ASTM International, West Conshohocken, PA.
- (22) ASTM E72-15 (2015). Standard Test Methods of Conducting Strength Tests of Panels for Building Construction. ASTM International, West Conshohocken, PA.
- (23) Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6): 386–408. <https://doi.org/10.1037/h0042519>

* * *