

Aplicación de un modelo de redes neuronales en la identificación del daño estructural en un puente vehicular

Carlos Alberto González Pérez* y Jesús Valdés González*

Recepción: 16 de julio de 2007

Aceptación: 10 de marzo de 2008

*Facultad de Ingeniería, Universidad Autónoma del Estado de México.

Correo electrónico:
albertglezp@yahoo.com.mx y
jvaldes@uaemex.mx

Resumen. En este artículo se presenta el desarrollo y aplicación de un modelo de redes neuronales en la detección del daño estructural a flexión en las traveses de un puente vehicular. El entrenamiento y evaluación de las redes se llevó a cabo a partir de la generación de 12 801 y 2 560 escenarios de daño “artificiales”, respectivamente. En la generación de estos escenarios se modificó aleatoriamente la rigidez a flexión de uno o varios de los elementos en que se discretizaron las traveses del puente. Como parámetro de entrada en el entrenamiento de las redes se utilizaron las diferencias en la energía de deformación modal y, como parámetro de salida, las rigideces a flexión de los elementos en que se discretizaron las traveses del puente. El algoritmo de entrenamiento utilizado fue el Scaled Conjugate Gradient. En general, se observó que las redes son capaces de predecir en forma confiable la localización y severidad del daño.

Palabras clave: detección de daño, redes neuronales, elemento finito, puentes vehiculares.

Application of a Neural Networks Model in the Identification of the Structural Damage in a Vehicular Bridge

Abstract. This article presents the development and application of an Artificial Neural Networks-based model for the detection of structural damage to bending in the girders of a vehicular bridge. The training and evaluation of the networks were carried out starting from the generation of 12801 and 2560 “artificial” damage scenarios, respectively. In the generation of these scenarios the flexural stiffness of one or several elements were randomly modified such that the bridge’s girders were discretized. In training the networks, the differences in the modal strain energy were used as input parameters, and the flexural stiffness of the elements as output parameters in which the bridge’s girders were discretized. The training algorithm used was the Scaled Conjugate Gradient. In general, it was observed that the networks are able to predict in a reliable way the location and severity of the damage.

Key words: damage detection; neural networks; finite element; vehicular bridges.

Introducción

La detección oportuna del daño estructural de las construcciones, tales como: edificios, puentes, presas, líneas de conducción y transmisión, plataformas petroleras, etc., es una tarea que resulta de especial interés, ya que puede prevenir la falla o colapso de dicha construcción, evitándose de esta forma pérdidas tanto materiales como humanas. Actualmente se han desarrollado distintos métodos para la evaluación del

daño estructural, tanto “convencionales” como “dinámicos”. Dentro de los métodos “convencionales”, se tienen: *a)* los de inspección visual, *b)* los de emisión acústica, *c)* los radiográficos, *d)* los ultrasónicos, entre otros. Sin embargo, el mayor inconveniente que presentan estos métodos es que su aplicación no resulta práctica, ya que requieren que la región alrededor del daño sea conocida *a priori*, o que la porción de la estructura a inspeccionar sea de fácil acceso, lo cual no sucede en todos los casos. Por lo que se refiere a los métodos

dinámicos, los cuales se basan en la medición de la respuesta de la estructura (vibración), aún resultan en la mayoría de los casos poco confiables debido a que tienen el inconveniente de no ser lo suficientemente precisos para detectar el daño, localizarlo y determinar la severidad de éste, por lo que su aplicación se encuentra aún limitada.

El objetivo de este trabajo es determinar la localización y severidad del daño estructural de manera confiable, utilizando un método dinámico, para lo que se analiza un modelo de redes neuronales con el objeto de estimar el daño a flexión en las trabes de un puente.

1. Antecedentes

En la actualidad, las redes neuronales han sido aplicadas satisfactoriamente en muchos campos de la ciencia. En el caso de la detección del daño estructural en las construcciones, las redes neuronales empiezan a ser utilizadas como una herramienta prometedora. A continuación se comentan algunos de estos casos.

Wu *et al.* (1992) emplearon una red neuronal entrenada con un algoritmo backpropagation y una sola capa oculta (hidden) para identificar el daño en un marco estructural de tres niveles; el daño se modeló reduciendo la rigidez de sus elementos. Se utilizaron como datos de entrada a la red neuronal las funciones de respuesta en el dominio de la frecuencia (FRFS) y como salida el nivel de daño en cada uno de los miembros. Los resultados mostraron que la red fue capaz de predecir en forma confiable el daño del primer y tercer nivel del marco.

Leath y Zimmermam (1993), emplearon una red neuronal multicapa perceptron, para identificar el daño de una viga en voladizo compuesta por cuatro elementos. El daño se modeló mediante una reducción en el módulo de elasticidad del material. Se utilizaron como datos de entrada a la red las dos primeras frecuencias naturales a flexión y como salida el nivel de daño en cada miembro. El algoritmo de entrenamiento propuesto fue capaz de identificar el daño con un error máximo del 35%.

Szewczyk y Hajela (1994) utilizaron una red neuronal counter-propagation para identificar el daño en armaduras. El daño se modeló mediante una reducción en la rigidez de alguna de las barras de la armadura, el análisis fue estático y la carga se mantuvo constante, variando únicamente la rigidez de determinada barra y midiendo el desplazamiento estático de algún punto de la armadura. Se utilizó como dato de entrada a la red la deformación estática bajo determinada carga y como salida el módulo de elasticidad del material. El error máximo obtenido en la identificación del daño fue del 30% aproximadamente.

Masri *et al.* (1996) llevaron a cabo un estudio analítico en el cual se buscó detectar cambios en los parámetros estructurales en un sistema lineal, y otro no lineal. Este trabajo está dividido en dos etapas: en la primera, se entrena la red neuronal a partir de los datos obtenidos de un sistema sin daño; en la segunda (detección de daño) se alimenta la red entrenada, con la misma excitación de entrada, y el error se establece entre las respuestas obtenidas de ambos sistemas (sin daño y con daño, en caso de que lo esté). Si las propiedades dinámicas del sistema han cambiado, la salida del sistema no corresponderá a la salida de la red neuronal entrenada, lo cual indicará la presencia de daño. En su investigación emplearon una red neuronal *feedforward* de dos capas ocultas, de 15 y 10 neuronas respectivamente, se eligieron como entradas los desplazamientos y velocidades relativas del sistema y como salida de la red la fuerza restauradora; las funciones de activación utilizadas fueron del tipo sigmoideal. El entrenamiento se llevó a cabo empleando un método de búsqueda del gradiente del error, aleatorio, y con capacidad de adaptarse el tamaño del paso en la búsqueda del mínimo global en la superficie del error. Para simular el daño del sistema emplearon los cambios en la rigidez y amortiguamiento. Finalmente, evaluaron la red propuesta en un sistema no lineal y ante la presencia de ruido en las mediciones. Los resultados mostraron que el enfoque propuesto era aún capaz de identificar cambios relativamente pequeños en los parámetros dominantes del sistema estructural. Sin embargo, el enfoque propuesto no fue capaz de determinar cuál componente de la fuerza restauradora cambió y en qué cantidad.

Nakamura *et al.* (1998) presentaron un enfoque basado en redes neuronales aplicado al estudio de la identificación de daño en un edificio de acero a base de marcos de 7 niveles, con geometría rectangular de 11 x 13 m y una altura total de 23 m, el cual se vio afectado por el terremoto de Hyogo-Ken Nambu en enero de 1995. Debido a que el enfoque presentado depende de las vibraciones ambientales en un sistema sin daño y otro con daño, éstas fueron medidas antes y después de las reparaciones realizadas en el edificio dañado durante el temblor. En este estudio se entrenaron siete redes neuronales, en donde cada red correspondió a un nivel específico del edificio analizado. En los entrenamientos se utilizaron como datos de entrada a la red, los desplazamientos y velocidades relativas, y como datos de salida la fuerza restauradora, correspondientes a cada nivel del edificio reparado (“sin daño”). Una vez entrenadas estas redes, fueron capaces de encontrar diferencias entre un sistema sin daño y uno dañado. Sin embargo, debido a la naturaleza no paramétrica del enfoque presentado, éste no fue capaz de identificar cuál componente específico (i.e., cuál componente estructural de los múltiples que contribuyen a

la resistencia global de la estructura) es el que concentraba el daño detectado. La arquitectura de las redes empleadas en este estudio es idéntica a la utilizada por Masri *et al.* (1996).

Zapico *et al.* (2000) desarrollaron un procedimiento para valorar el nivel de daño de un marco tridimensional de acero de dos niveles y pisos compuestos (concreto-acero). El procedimiento está basado en una red neuronal perceptron multicapa con 2 neuronas de entrada, 4 en la capa oculta y 2 de salida, con funciones de activación tangente hiperbólicas en la capa oculta y lineales en la capa de salida. Los datos de entrenamiento de la red se obtuvieron a partir de un modelo de elemento finito, en el cual la rigidez de los elementos varió de manera aleatoria. Los datos de entrada de la red correspondieron a las frecuencias naturales y formas de modo, mientras que tres enfoques correspondientes a diferentes definiciones de daño (secciones, barras y pisos) se probaron como salidas. El único enfoque que tuvo éxito fue el índice de daño en pisos, en donde se alcanzaron coeficientes de correlación entre lo predicho por la red y el daño real en la estructura, de 0.9862 y 0.9919 para el segundo y primer piso, respectivamente.

En el caso específico de puentes, no se han utilizado modelos de redes neuronales para la identificación del daño. En el presente trabajo se busca aplicar un modelo de redes neuronales que utilice las diferencias en la energía de deformación modal como datos de entrada a la red, y como salida el nivel de daño de un modelo simplificado de un puente. De las investigaciones referidas anteriormente, se puede constatar que las diferencias en la energía de deformación modal o la energía de deformación, no han sido utilizadas en el entrenamiento de redes neuronales para detectar daño estructural. Sin embargo, éstas ya han sido utilizadas como medida para cuantificar el daño en vigas de madera simplemente apoyadas, esto, en un trabajo presentado por Peterson *et al.* (2001), en donde los autores pudieron identificar únicamente la presencia del daño en 4 de los 5 escenarios de daño analizados.

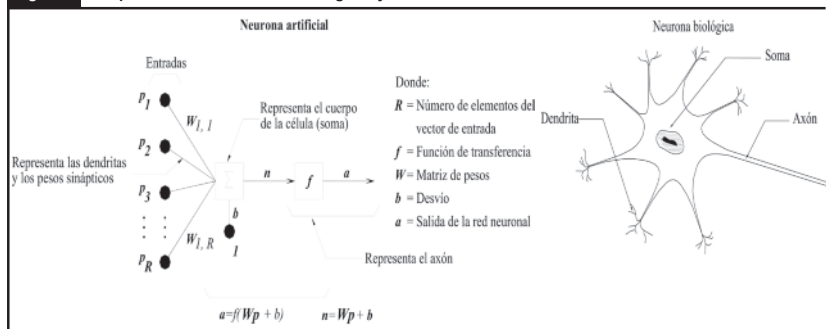
2. Redes neuronales

Las redes neuronales artificiales son modelos computacionales inspirados en la arquitectura de las neuronas y operación del cerebro humano. Las neuronas biológicas están compuestas por: a) dendritas, las cuales reciben las señales de entrada, b) el cuerpo de la célula (soma), el cual se encarga de procesar dichas señales y c) el axón, el cual es una fibra que lleva la señal desde el cuerpo de la célula hacia otras neuronas. El punto de contacto

entre el axón de una célula y la dendrita de otra célula, se conoce como sinapsis. De manera semejante a las neuronas biológicas, las neuronas artificiales están formadas por un vector de entradas (dendritas), una matriz de pesos sinápticos (obtenida a partir de las conexiones entre cada dendrita y el axón de la neurona), una operación que suma todas las entradas afectadas por cada uno de los pesos sinápticos más un desvío, además de una función de transferencia, la cual afecta la salida del cuerpo de la neurona y lleva la señal de salida a otras neuronas. La figura 1 muestra la comparación entre la neurona artificial y la biológica; así como sus componentes.

En la figura 1, el vector de entradas $\{P\} = [p_1 p_2 \dots p_R]^T$ representa las señales de entrada al sistema; imitando la función de las dendritas en la neurona biológica. Los pesos sinápticos, a los cuales se les refiere de aquí en adelante como “pesos”, pueden ser positivos (excitatorios), o negativos (inhibitorios) y representan la intensidad de la sinapsis que conecta la salida de una neurona con otra o un vector de entradas con la primera capa de neuronas. El desvío es un peso adicional, el cual tiene una entrada unitaria y su poder reside en la capacidad para representar relaciones entre entradas y salidas más fácilmente que en redes sin desvíos (Demuth y Beale, 2002). Las funciones de activación (tabla 1) se encargan de modular la salida del cuerpo de la neurona y llevan dicha señal a otra neurona, o a la salida de la red. Éstas se eligen de acuerdo con el mapeo (relación entre las señales de entrada y salida de la red) requerido por el problema. Si se requiere un mapeo lineal, se utilizan funciones de activación lineales (de primer orden); sin embargo, si se desea que la red sea capaz de establecer relaciones no-lineales entre la entrada y la salida, entonces se utilizan funciones de activación no-lineales (funciones de orden superior a uno). En el presente trabajo se emplean las funciones de activación lineal y tangente hiperbólica, ya que éstas en conjunto con una red *feedforward* multicapa, son capaces de representar cualquier función continua de múltiples variables (Atalla, 1996).

Figura 1. Comparación entre neuronas biológicas y artificiales.



En cuanto al “conocimiento” adquirido por las redes neuronales, éste se obtiene mediante un algoritmo de aprendizaje, en el cual los pesos y desvíos se ajustan por iteraciones hasta obtener las salidas deseadas (para cada grupo de entradas) dentro del nivel de precisión establecido. Siendo el algoritmo *backpropagation* o algoritmo de propagación inversa el método de entrenamiento más empleado en la literatura de redes neuronales. No obstante, se han ido desarrollando y

aplicando nuevas técnicas que caen dentro de los algoritmos *backpropagation*, las cuales permiten mayores velocidades de convergencia y son más estables, como lo son: el algoritmo *backpropagation* con *momentum*, el algoritmo *backpropagation* con una razón de aprendizaje variable, el algoritmo *resilient backpropagation*, el algoritmo del gradiente conjugado, el algoritmo del gradiente conjugado escalado (*Scaled Conjugate Gradient*), los algoritmos cuasi-Newton, el algoritmo Levenberg-Marquardt, entre otros. Una descripción de estos algoritmos es presentada por Demuth y Beale, (2002). En el presente trabajo se emplea el algoritmo de entrenamiento *Scaled Conjugate Gradient* para entrenar la red *feedforward* multicapa.

Para evitar que las redes analizadas memoricen los escenarios de daño de los entrenamientos, y éstas no tengan la capacidad de aprender a generalizar ante escenarios de daño desconocidos, suele utilizarse ruido blanco que altera o modifica los datos de entrenamiento; sin embargo en este trabajo se utilizó el método de regularización, el cual consiste en modificar la función de desempeño (ecuación 1), adicionando un término que consiste en la suma de los cuadrados de los pesos (ecuación 2) y afectando ambos términos por un factor γ (factor de desempeño o de regularización) tal que $0 \leq \gamma \leq 1$, de tal manera que la función para evaluar el desempeño de la red estará dada por la ecuación 3.

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (1)$$

$$msw = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (2)$$

$$F = msereg = \gamma \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 + (1 - \gamma) \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (3)$$

donde: F es la función que evalúa el desempeño de la red neuronal, N es el número de vectores de entrenamiento, t_i es la función objetivo (*Target*) correspondiente al i -ésimo vector de entrenamiento, a_i es la salida dada por la red para el i -ésimo vector de entrenamiento, n es el número de pesos la red neuronal y w es el peso.

3. Aplicación de redes neuronales en la identificación de daño

En esta sección se analiza la posibilidad de emplear un método de identificación de daño basado en redes neuronales. Para ello, se desarrolla un modelo analítico de elemento finito, correspondiente a un puente de concreto reforzado. Las características geométricas y de los materiales son similares a las del trabajo presentado por Lertpaitoonpan (2000). Dicho

Figura 2. Vista en perspectiva y transversal del puente vehicular modelado.




Tabla 1. Funciones de activación.

Nombre de la función de activación	Definición
Lineal	$f(n) = kn$
Limitador fuerte (Hardlim). También llamada función umbral, Heaviside o función escalón.	$f(n) = \begin{cases} \rho & \text{si } n \geq \rho \\ n & \text{si } n < \rho \\ -\rho & \text{si } n \leq -\rho \end{cases}$ comúnmente: $\beta = 1, \delta = 0, n_k = 0$
Rampa	$f(n) = \frac{1}{1 + e^{-\alpha n}}, \alpha > 0$
Logarítmico sigmoidal	$f(n) = \begin{cases} \beta & \text{si } n \geq n_k \\ \delta & \text{si } n < n_k \end{cases}$
Tangente hiperbólica sigmoidal	$f(n) = \tanh(\gamma n) = \frac{1 - e^{-2\gamma n}}{1 + e^{-2\gamma n}}, \gamma > 0$
Racional	$f(n) = \begin{cases} \frac{x^2}{1 + x^2} & \text{si } x > 0 \\ 0 & \text{si } x \leq 0 \end{cases}$
Gaussiana	$f(n) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(n-\mu)^2}{2\sigma^2}}$

puente cuenta con un claro de 27.40 m y un ancho de 14.60 m; está constituido por 4 traveses, 2 parapetos, 2 diafragmas y una superficie de rodamiento (figura 2). En dicho modelo se emplearon elementos viga en el modelado de traveses, parapetos y diafragmas; elementos membrana en el modelado de la losa y elementos barra para modelar las conexiones entre los elementos estructurales (losa, traveses, diafragmas y parapetos). Las traveses del modelo se discretizaron en 20 elementos viga por cada travesa. En la tabla 2 se presentan las propiedades geométricas y del material que fueron utilizadas.

Una vez desarrollado el modelo analítico del puente, se generaron 12 801 escenarios de daño artificiales para llevar a cabo el entrenamiento de las redes neuronales analizadas, y otros 2 560 escenarios de daño (no presentados en los entrenamientos de las redes), para evaluar el desempeño de éstas una vez entrenadas. En estos escenarios únicamente se disminuyeron las rigideces a flexión de las traveses con el objeto de representar el daño. Asimismo, se consideró que uno o varios elementos de una travesa estuviesen dañados, mientras que el resto de las traveses permanecía sin daño, además, se consideró que las traveses centrales (T2 y T3) tuviesen daño en uno o varios de sus elementos, mientras que las traveses T1 y T4 permanecían sin daño. En estas simulaciones analíticas las rigideces a flexión de los distintos elementos dañados se mantuvieron en el rango del 60 al 100% de su rigidez a flexión inicial (6.3606×10^{12} kg-cm²). En la tabla 3 se presenta el elemento o elementos, la travesa o traveses que presentaron dicho daño, así como el número de escenarios de daño creados “artificialmente”. Refiérase a la figura 3 para identificar el número del elemento o elementos que fueron dañados.

La generación del modelo analítico, así como los análisis de los distintos escenarios de daño simulados, se realizaron mediante el software de elemento finito provisto por ANSYS® (2005). Para cada escenario, se obtuvieron los parámetros modales, tales como: frecuencias de vibración y formas de modo. Con base en estos resultados, la energía de deformación modal y las diferencias en la energía de deformación modal se calcularon a partir de las ecuaciones 4

Tabla 2. Propiedades geométricas y de los materiales utilizados en el modelo de elemento finito del puente vehicular que se analiza.

Traveses	
Área transversal	6535.47080 cm ²
Momento de inercia a flexión	21693000.00000 cm ⁴
Momento de inercia torsional	1850481.00060 cm ⁴
Módulo de elasticidad	293208.92000 kg/cm ²
Densidad del material	0.00264 kg/cm ³
Losa	
Espesor de la losa	20.00000 cm
Densidad del material	0.00269 kg/cm ³
Módulo de elasticidad	293208.92000 kg/cm ²
Diafragmas y parapetos	
Área transversal	2578.06000 cm ²
Momento de inercia a flexión	1488843.16000 cm ⁴
Momento de inercia torsional	580001.51000 cm ⁴
Módulo de elasticidad	293208.92000 kg/cm ²
Densidad del material	0.00242 kg/cm ³
Conectores	
Área transversal	100000 cm ²
Módulo de elasticidad	1000000 kg/cm ²

Tabla 3. Escenarios de daño creados de manera aleatoria.

Número de elemento dañado	Número de travesa dañada	Número de escenarios de daño creados artificialmente (entrenamiento / evaluación)
1*		1
1	[T1], [T2], [T3], [T4]	160/32
2	[T1], [T2], [T3], [T4]	160/32
3	[T1], [T2], [T3], [T4]	160/32
4	[T1], [T2], [T3], [T4]	160/32
5	[T1], [T2], [T3], [T4]	160/32
6	[T1], [T2], [T3], [T4]	160/32
7	[T1], [T2], [T3], [T4]	160/32
8	[T1], [T2], [T3], [T4]	160/32
9	[T1], [T2], [T3], [T4]	160/32
10	[T1], [T2], [T3], [T4]	160/32
11	[T1], [T2], [T3], [T4]	160/32
12	[T1], [T2], [T3], [T4]	160/32
13	[T1], [T2], [T3], [T4]	160/32
14	[T1], [T2], [T3], [T4]	160/32
15	[T1], [T2], [T3], [T4]	160/32
16	[T1], [T2], [T3], [T4]	160/32
17	[T1], [T2], [T3], [T4]	160/32
18	[T1], [T2], [T3], [T4]	160/32
19	[T1], [T2], [T3], [T4]	160/32
20	[T1], [T2], [T3], [T4]	160/32
10,11	[T1], [T2], [T3], [T4]	640/128
9,10,11,12	[T1], [T2], [T3], [T4]	960/192
8,9,10,11,12,13	[T1], [T2], [T3], [T4]	1280/256
7,8,9,10,11,12,13,14	[T1], [T2], [T3], [T4]	1600/320
6,7,8,9,10,11,12,13,14,15	[T1], [T2], [T3], [T4]	1920/384
7,8,9,10	[T1], [T2], [T3], [T4]	640/128
11,12,13,14	[T1], [T2], [T3], [T4]	640/128
10,11	[T2-T3]	160/32
9,10,11,12	[T2-T3]	320/64
8,9,10,11,12,13	[T2-T3]	400/80
7,8,9,10,11,12,13,14	[T2-T3]	480/96
6,7,8,9,10,11,12,13,14,15	[T2-T3]	560/112
Escenarios de daño creados en forma aleatoria para el entrenamiento de las redes neuronales: 12 801		
Escenarios de daño creados en forma aleatoria para la evaluación de las redes neuronales: 2 560		
*Corresponde al escenario Inicial, i.e., no existe daño alguno en la viga		
[T1], [T2], [T3], [T4]: Escenarios de daño correspondientes a la travesa 1, 2, 3 y 4 en los cuales únicamente se daña una travesa a la vez.		
[T2-T3]: Escenarios de daño simultáneo en las traveses centrales (T2 y T3).		

y 5 respectivamente. En el trabajo, sólo se utilizaron como parámetro de entrada a la red neuronal las diferencias en la energía de deformación modal.

$$Umod_{ab} = \frac{1}{2} EL \int_a^b \{\phi_i(x)\}^2 \{\phi_i(x)\}^m dx \quad (4)$$

$$\Delta Umod_{ab} = Umod_{ab}^U - Umod_{ab}^D \quad (5)$$

donde $Umod_{ab}$ es la energía de deformación modal calculada en el intervalo de a-b, EI es la rigidez a flexión de la sección transversal correspondiente al escenario sin daño, $\{\phi_i(x)\}$ es el vector de la i -ésima forma de modo, $\{\phi_i(x)\}''$ es el vector de la i -ésima curvatura modal (obtenida a partir de las segundas derivadas de las formas de modo). $Umod_{ab}^D$ son las diferencias en la energía de deformación modal. Los superíndices U y D se refieren a los casos sin daño y con daño, respectivamente.

Posteriormente, se procedió a entrenar las redes neuronales a partir de los 12 801 escenarios de daño creados (las arquitecturas ensayadas se muestran en la figura 4). Para ello se utilizó la *Neural Networks Toolbox* provista por MATLAB® (2004). En lo que concierne al algoritmo de entrenamiento, se utilizó el Scaled Conjugate Gradient con un factor de regularización de $\gamma = 0.25, 0.50$ y 0.75 ; y un criterio de paro establecido en 20 000 periodos (epochs); el cual indica el número de veces en que los pares de vectores de entrenamiento entrada-salida (12 801 escenarios de daño) son presentados a la red para el cálculo de sus pesos y desvíos. En estas redes se utilizaron como parámetro de entrada las diferencias en la energía de deformación modal obtenidas de los modelos de elemento finito correspondientes a los puentes dañados artificialmente, y como parámetro de salida de las redes las rigideces a flexión de cada uno de los elementos en que se discretizaron las traves del puente. Únicamente se empleó el vector de energía de deformación correspondientes al primer modo. De tal manera que las redes entrenadas a partir del parámetro anterior constan de 80 neuronas de entrada que corresponden al vector de energía de deformación y de 80 neuronas de salida, las cuales están en correspondencia con el número de elementos en que se discretizaron las traves del puente. Como resultado, la capa de neuronas de salida arroja las rigideces a flexión de cada uno de los elementos en que se discretizaron las traves del modelo.

Figura 3. Discretización del modelo de elemento finito utilizado en el entrenamiento de las redes neuronales.




Figura 4. Arquitecturas entrenadas a partir de las diferencias en la energía de deformación modal correspondiente al primer modo.

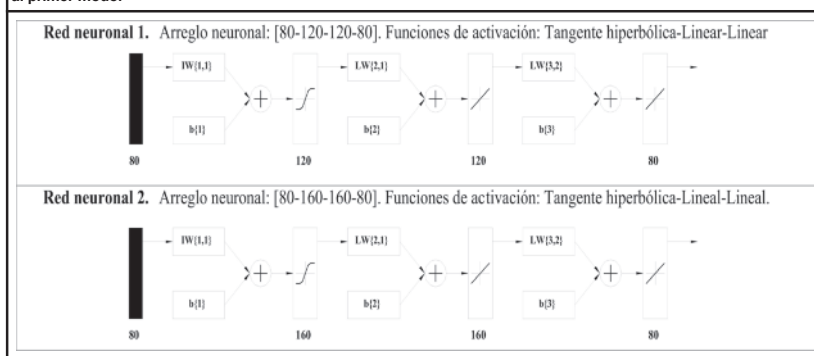


Tabla 4. Valores estadísticos correspondientes a los coeficientes de correlación obtenidos de los análisis de regresión llevados a cabo a partir de los escenarios de entrenamiento.

	Arquitectura neuronal 1			Arquitectura neuronal 2		
Mínimo	0.2500*	0.5000*	0.7500*	0.2500*	0.5000*	0.7500*
Máximo	0.9954	0.9973	0.9972	0.9969	0.9975	0.9963
Promedio	0.9468	0.9698	0.9893	0.9513	0.9892	0.9870
D.E.	0.1878	0.1326	0.0256	0.1838	0.0269	0.0275

* Parámetro de regularización, D.E. = Desviación estándar.

Tabla 5. Valores estadísticos correspondientes a las pendientes de los ajustes lineales obtenidos de los análisis de regresión llevados a cabo a partir de los escenarios de entrenamiento.

	Arquitectura neuronal 1			Arquitectura neuronal 2		
Mínimo	0.2500*	0.5000*	0.7500*	0.2500*	0.5000*	0.7500*
Máximo	0.0153	0.0208	0.6837	0.0194	0.6169	0.6870
Promedio	0.9766	0.9889	0.9921	0.9849	0.9911	0.9959
D.E.	0.9012	0.9435	0.9721	0.9186	0.9671	0.9719
D.E.	0.2092	0.1577	0.0585	0.2095	0.0709	0.0583

* Parámetro de regularización, D.E. = Desviación estándar.

Una vez entrenadas las redes neuronales, se llevaron a cabo análisis de regresión, en los cuales se evaluó la calidad de los resultados vertidos por las redes, *i.e.*, la respuesta predicha (rigideces a flexión de los elementos) por la red ya entrenada, comparada contra las rigideces a flexión de los pares de entrenamiento: diferencias en la energía de deformación-rigideces.

En las tablas 4 y 5 se muestran para las dos arquitecturas analizadas los valores estadísticos (media, máximo, mínimo y desviación estándar) correspondientes a los coeficientes de correlación y pendientes de los ajustes lineales, obtenidos de los análisis de regresión llevados a cabo para los escenarios de entrenamiento. Mientras que en las tablas 6 y 7 se presentan los valores estadísticos correspondientes a los escenarios de evaluación, utilizados para evaluar el desempeño de las redes ante escenarios de daño no presentados durante los entrenamientos. De estas tablas se puede observar cómo influye la arquitectura neuronal; el parámetro de regularización, el cual fue de 0.25, 0.50 y 0.75, en el desempeño de las redes analizadas, tanto en los escenarios de entrenamiento como en los de evaluación. También se puede advertir que no existe una diferencia sustancial entre la arquitectura neuronal 1 usando un parámetro de regularización igual 0.75, y arquitectura neuronal 2 con un parámetro de 0.50, ya que los coeficientes de correlación promedio, pendientes de los ajustes lineales, así como sus desviaciones estándar, entre las rigideces a flexión que la red predice para cada uno de los elementos en que las traveses del puente se discretizaron, y las rigideces a flexión empleadas en los escenarios de entrenamiento, así como también en aquellos utilizados para evaluar el desempeño de las redes.

De los análisis mencionados previamente se obtuvo que la red neuronal 2, entrenada a partir de las diferencias en la energía de deformación modal y utilizando un parámetro de regularización $\gamma = 0.50$, presenta los coeficientes de correlación más altos con respecto a las demás redes; estos coeficientes de correlación se calcularon a partir de la ecuación 6.

$$\rho_{K_o, K_T} = \frac{Cov(K_o, K_T)}{\sigma_{K_o} \cdot \sigma_{K_T}} \quad (6)$$

donde ρ_{K_o, K_T} es el coeficiente de correlación tal que $-1 \leq \rho_{K_o, K_T} \leq 1$, K_o son las rigideces a flexión predichas por la red para el j -ésimo elemento, una vez entre-

nada. K_T son las rigideces a flexión para el j -ésimo elemento con el que fue entrenada la red. σ_{K_o} y σ_{K_T} son las desviaciones estándar de las rigideces a flexión predichas y de las rigideces a flexión con que la red se entrenó, respectivamente. K^o es la media del vector $k_i^o - \bar{k}^T$ es la medida del vector K_T . $Cov(k_o, k_T)$ es la covarianza, la cual está dada por la ecuación 7.

$$Cov(K_o, K_T) = \frac{1}{n} \sum_{i=1}^n (k_i^o - \bar{k}^T) \quad (7)$$

En las figuras 5a, 5b, 5c y 5d se muestran algunos de los análisis de regresión llevados a cabo para cada uno de los 20 elementos que constituyeron cada trabe del puente, para la red neuronal 2 con un parámetro de regularización $\gamma = 0.50$. En la columna izquierda de estas figuras se presentan los análisis de regresión correspondientes a aquellos escenarios de daño que fueron utilizados para el entrenamiento de la red neuronal, mientras que en la columna de la derecha se muestran los análisis correspondientes al desempeño de la red ante escenarios de daño no presentados durante los entrenamientos de la red (escenarios de evaluación). En el eje x se grafican las rigideces a flexión con que fue entrenada la red, que corresponden a la función objetivo (*target*), mientras que en el eje y se muestran las rigideces predichas por la red una vez entrenada (*outputs*). De lo anterior, se deduce que si la respuesta de la red es igual a los datos de entrenamiento, entonces éstos se ajustarán a una línea recta representada en las figuras 5a, 5b, 5c y 5d (ver anexo) como $A = T$ con pendiente unitaria. En estas figuras se incluyen datos como la ecuación de la recta obtenida de ajustar los datos a un modelo lineal por el método de mínimos cuadrados, la cual se muestra en línea continua; así como el coeficiente de correlación entre la salida predicha por la red (*outputs*) y la función objetivo (*targets*).

Tabla 6. Valores estadísticos correspondientes a los coeficientes de correlación obtenidos de los análisis de regresión llevados a cabo a partir de los escenarios de evaluación.

	Arquitectura neuronal 1			Arquitectura neuronal 2		
	0.2500*	0.5000*	0.7500*	0.2500*	0.5000*	0.7500*
Mínimo	0.1236	0.1284	0.2112	0.1390	0.2132	0.2242
Máximo	0.9952	0.9969	0.9969	0.9958	0.9971	0.9950
Promedio	0.9438	0.9593	0.9769	0.9473	0.9778	0.9706
D.E.	0.1865	0.1580	0.0959	0.1824	0.0948	0.1011

* Parámetro de regularización, D.E. = Desviación estándar.

Tabla 7. Valores estadísticos correspondientes a las pendientes de los ajustes lineales obtenidos de los análisis de regresión llevados a cabo a partir de los escenarios de evaluación.

	Arquitectura neuronal 1			Arquitectura neuronal 2		
	0.25*	0.5*	0.75*	0.25*	0.5*	0.75*
Mínimo	0.0146	0.0227	0.4649	0.0159	0.4161	0.4713
Máximo	0.9870	1.0055	1.0228	0.9927	1.0117	1.0610
Promedio	0.8980	0.9399	0.9685	0.9153	0.9644	0.9703
D.E.	0.2089	0.1605	0.0777	0.2092	0.0847	0.0793

* Parámetro de regularización, D.E. = Desviación estándar.

Tabla 8. Coeficientes de correlación obtenidos para los escenarios de entrenamiento y evaluación. Red neuronal 2.

	Coeficientes de correlación							
	TRABE 1		TRABE 2		TRABE 3		TRABE 4	
	[R]Train	[R]Eval	[R] Train	[R] Eval	[R] Train	[R] Eval	[R] Train	[R] Eval
1	0.8883	0.2132	0.9766	0.9808	0.9736	0.9716	0.8588	0.8848
2	0.9925	0.9936	0.9956	0.9838	0.9957	0.9897	0.9916	0.9882
3	0.9963	0.9950	0.9963	0.9937	0.9963	0.9940	0.9961	0.9955
4	0.9967	0.9936	0.9973	0.9849	0.9966	0.9936	0.9971	0.9955
5	0.9963	0.9953	0.9960	0.9941	0.9963	0.9937	0.9966	0.9923
6	0.9961	0.9945	0.9971	0.9954	0.9970	0.9953	0.9967	0.9956
7	0.9972	0.9966	0.9972	0.9957	0.9974	0.9966	0.9972	0.9967
8	0.9965	0.9953	0.9973	0.9962	0.9968	0.9961	0.9969	0.9967
9	0.9967	0.9957	0.9972	0.9965	0.9970	0.9964	0.9964	0.9954
10	0.9966	0.9964	0.9973	0.9954	0.9970	0.9965	0.9968	0.9964
11	0.9967	0.9959	0.9970	0.9947	0.9971	0.9965	0.9965	0.9954
12	0.9962	0.9956	0.9972	0.9961	0.9961	0.9952	0.9962	0.9959
13	0.9958	0.9942	0.9969	0.9965	0.9969	0.9961	0.9957	0.9954
14	0.9961	0.9957	0.9972	0.9965	0.9970	0.9957	0.9971	0.9970
15	0.9966	0.9960	0.9975	0.9967	0.9969	0.9959	0.9966	0.9960
16	0.9966	0.9970	0.9959	0.9939	0.9952	0.9940	0.9968	0.9962
17	0.9971	0.9959	0.9972	0.9849	0.9963	0.9952	0.9971	0.9958
18	0.9962	0.9956	0.9963	0.9961	0.9969	0.9916	0.9961	0.9962
19	0.9918	0.9898	0.9952	0.9946	0.9947	0.9971	0.9919	0.9954
20	0.8959	0.9534	0.9752	0.9505	0.9729	0.9727	0.8610	0.6721
media	0.9856	0.9539	0.9947	0.9908	0.9942	0.9927	0.9825	0.9736
D.E.	0.0320	0.1746	0.0065	0.0107	0.0072	0.0073	0.0419	0.0752
[R]Train	Coeficiente de correlación obtenido de los escenarios utilizados en los entrenamientos de la red.							
[R]Eval	Coeficientes de correlación obtenidos de los escenarios de daño desconocidos por la red, utilizados para evaluar el desempeño de la red.							

En la tabla 8 se muestran los coeficientes de correlación obtenidos de los análisis de regresión obtenidos para los escenarios de entrenamiento y evaluación. De esta tabla se observa que los resultados arrojados entre la respuesta predicha por la red y aquella con la que se alimentó a la red (escenarios de entrenamiento y evaluación), son muy cercanos a la unidad, lo cual indica que el patrón de entrenamiento utilizado en esta red (diferencias en la energía de deformación modal), es un patrón que permite identificar en forma razonable y confiable, tanto la localización como la severidad del daño, presentada en cada uno de los elementos en que se discretizaron las traves del puente.

Con el objeto de tener una medida de la calidad de la base de datos (escenarios de entrenamiento y de evaluación), se obtuvieron los histogramas de frecuencia relacionados a los escenarios de daño, de donde se pudo observar una tendencia uniforme en el intervalo de interés (60% al 100%) en el cambio de la rigidez a flexión de las traves del puente.

Aunque los resultados que se presentan en este artículo corresponden a una simulación completamente analítica, debe comentarse que su aplicación práctica es posible, ya que las formas de modo y frecuencia de vibración pueden ser obtenidas de un análisis experimental modal, a partir de cuyos resultados se pueden calcular analíticamente las curvaturas, la energía de deformación modal y las diferencias en la energía de deformación modal entre el estado sin daño y el estado

actual del puente vehicular analizado. Como se puede apreciar en esta investigación, se requiere de un modelo de elemento finito del puente vehicular analizado en su estado inicial, *i.e.*, sin daño alguno, en esta etapa se requiere que el modelo de elemento finito del puente empate adecuadamente con el real, *i.e.*, que las propiedades dinámicas de ambos modelos (experimental y analítico) sean las mismas. Una vez construido el modelo de elemento finito, se generarían escenarios de daño aleatorios tanto para el entrenamiento de la red como para la evaluación de la misma, en los cuales se fije un rango de interés en las rigideces a flexión de las traves del puente (en esta investigación se manejo un intervalo de 60% al 100% de la rigidez a flexión inicial). Una vez generados los escenarios aleatorios, se extraería la primera forma modal a flexión de todos los escenarios y se

calcularían las diferencias en la energía de deformación modal a partir de la ecuación 5. Posteriormente, se entrenaría la red neuronal (en esta investigación la arquitectura neuronal con mejores resultados fue la segunda, utilizando el algoritmo de entrenamiento Scaled Conjugate Gradient y empleando un parámetro de regularización $\gamma = 0.5$). Una vez entrenada la red, se harían monitoreos al puente con el objeto de determinar los posibles cambios en las frecuencias y formas de modo, se calcularían las diferencias en la energía de deformación modal para el primer modo a flexión entre el estado inicial y el actual, y se introduciría este vector (diferencias en la energía de deformación) como entrada a la red entrenada. Se espera que bajo esta metodología, se pueda construir un modelo de redes neuronales que sea capaz de establecer la localización y severidad del daño en cada uno de los elementos en que se discreticen las traves del puente que se analice.

Conclusiones

En esta investigación se desarrolló, aplicó y evaluó un modelo basado en redes neuronales para identificar el daño estructural a flexión de las traves de un puente. Para ello, se llevó a cabo un estudio analítico en el cual el modelo de elemento finito de un puente vehicular simplemente apoyado fue analizado. Una vez creado este modelo, y generados aleatoriamente 12 801 escenarios de daño, se

procedió a entrenar una red neuronal en la cual se emplearon como parámetro de entrada las diferencias en la energía de deformación modal correspondientes al primer modo a flexión del puente analizado, y como parámetro de salida, las rigideces a flexión de los elementos en los cuales se discretizó el puente.

Finalmente las conclusiones de esta investigación son:

- Se observó que una red feedforward multicapa con un arreglo neuronal [80-160-160-80], con funciones de activación: tangente hiperbólica-lineal-lineal (figura 4), empleando el algoritmo de entrenamiento Gradient Conjugate Scaled y utilizando un parámetro de regularización de $\gamma=0.5$ entrenada a partir de las diferencias en la energía de deformación modal, es capaz de predecir la localización y severidad del daño en forma aceptable. Lo anterior, en función del coeficiente de correlación promedio obtenido por ésta (0.9892 y con una desviación estándar del 0.0269).

- En lo referente al desempeño de la red 2 ante patrones de daño nunca antes presentados en su entrenamiento, se obtuvo para los 2 560 escenarios de daño analizados, un coeficiente de correlación promedio de 0.9778, con una desviación estándar de 0.0948.

- A partir de los resultados obtenidos en este trabajo, se observa que la aplicación de modelos de redes neuronales entrenados a partir de las diferencias en la energía de deformación modal, pudieran ser aplicados en forma confiable para identificar la localización y severidad del daño en las trabes de un puente.

- En cuanto al rango de reducciones en la rigidez a flexión, que en los ensayos analizados fue del [0-40%] de la rigidez inicial, se recomienda analizar el desempeño de modelos basados en redes neuronales cuando este rango se ve reducido, con el objeto de evaluar qué tan precisa se vuelve la red en sus estimaciones ante niveles de daño bajos.

obie

Bibliografía

- ANSYS® (2005). User's manual, revision 10.0. Swanson Analysis System Inc.
- Atalla, M. (1996). "Model Updating Using Neural Networks", Ph.D. Thesis, Faculty of the Virginia Polytechnic Institute and State University.
- Demuth, H., Beale, M. (2002). "Neural Network Toolbox 4.0", The Math Works Inc.
- Leath, W. and D. Zimmermam (1993). "Analysis of Neural Network Supervised Training with Application to Structural Damage Detection", Damage and Control of Large Structures, Proc. Of the 9th VPI&SU Symposium: 583-594.
- Lertpaitoonpan, W. (2000). "Bridge Damage Detection Using a System Identification Method", Ph.D. Thesis, University of Florida.
- Masri, S.; M. Nakamura; A. Chassiakos and T. Caughey (1996). "Neural Network Approach to Detection of Changes in Structural Parameters", *Journal of Engineering Mechanics*, ASCE, Vol. 122, Núm. 4: 350-360
- MATLAB® (2004). Using MATLAB, revision 7.0. The Mathworks Inc., Natick, MA.
- Nakamura, M.; S. Masri; A. Chassiakos and T. Caughey (1998). "Method for Non-Parametric Damage Detection Through the Use of Neural Networks", *Earthquake Engineering and Structural Dynamics*, John Wiley & Sons, Ltd.: 997-1010
- Peterson, S.; D. McLean; M. Symans; D. Pollock; W. Cofer; R. Emerson and K. Fridley, (2001). "Application of Dynamic System Identification to Timber Beams I", *Journal of Structural Engineering*, ASCE, Vol. 127, Núm. 4: 418-425
- _____ (2001). "Application of Dynamic System Identification to Timber Beams II", *Journal of Structural Engineering*, ASCE, Vol. 127, Núm. 4: 426-432
- Szewczyk, P. and P. Hajela (1994). "Damage Detection in Structures Based on Feature-Sensitive Neural Networks", *ASCE Journal of Computing in Civil Engineering*, Vol 8, Núm. 2: 163-178
- Wu, X.; J. Ghaboussi and J. Garret (1992). "Use of Neural Networks in Detection of Structural Damage", *Computer and Structures*. Vol. 42, Núm. 4, 649-659.
- Zapico, J.; K. Worden and F. Molina (2000). "Structural Damage Assessment Using Neural Networks", *Conference on System Identification & Structural Health Monitoring 2000*. 387-396.

Figura 5a. Análisis de regresión de los resultados obtenidos por la red neuronal entrenada a partir de las diferencias en la energía de deformación modal.

Trabe 1

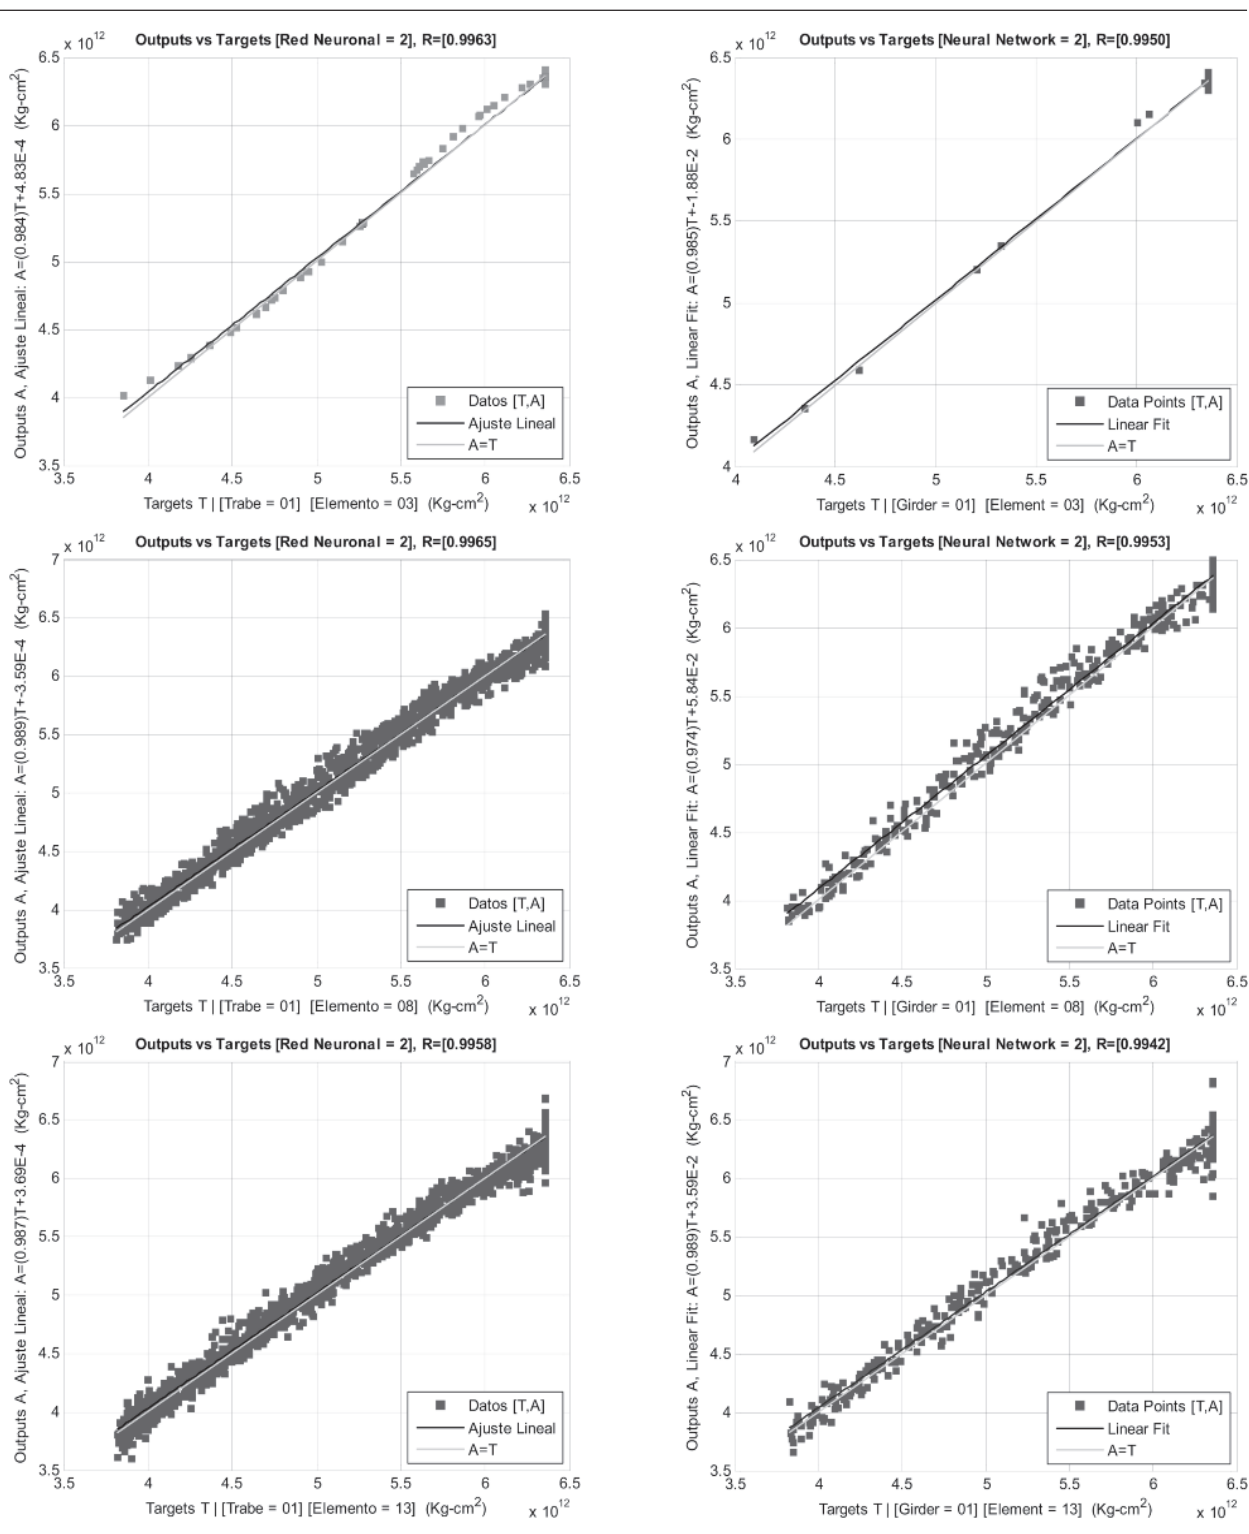


Figura 5b. Análisis de regresión de los resultados obtenidos por la red neuronal entrenada a partir de las diferencias en la energía de deformación modal.

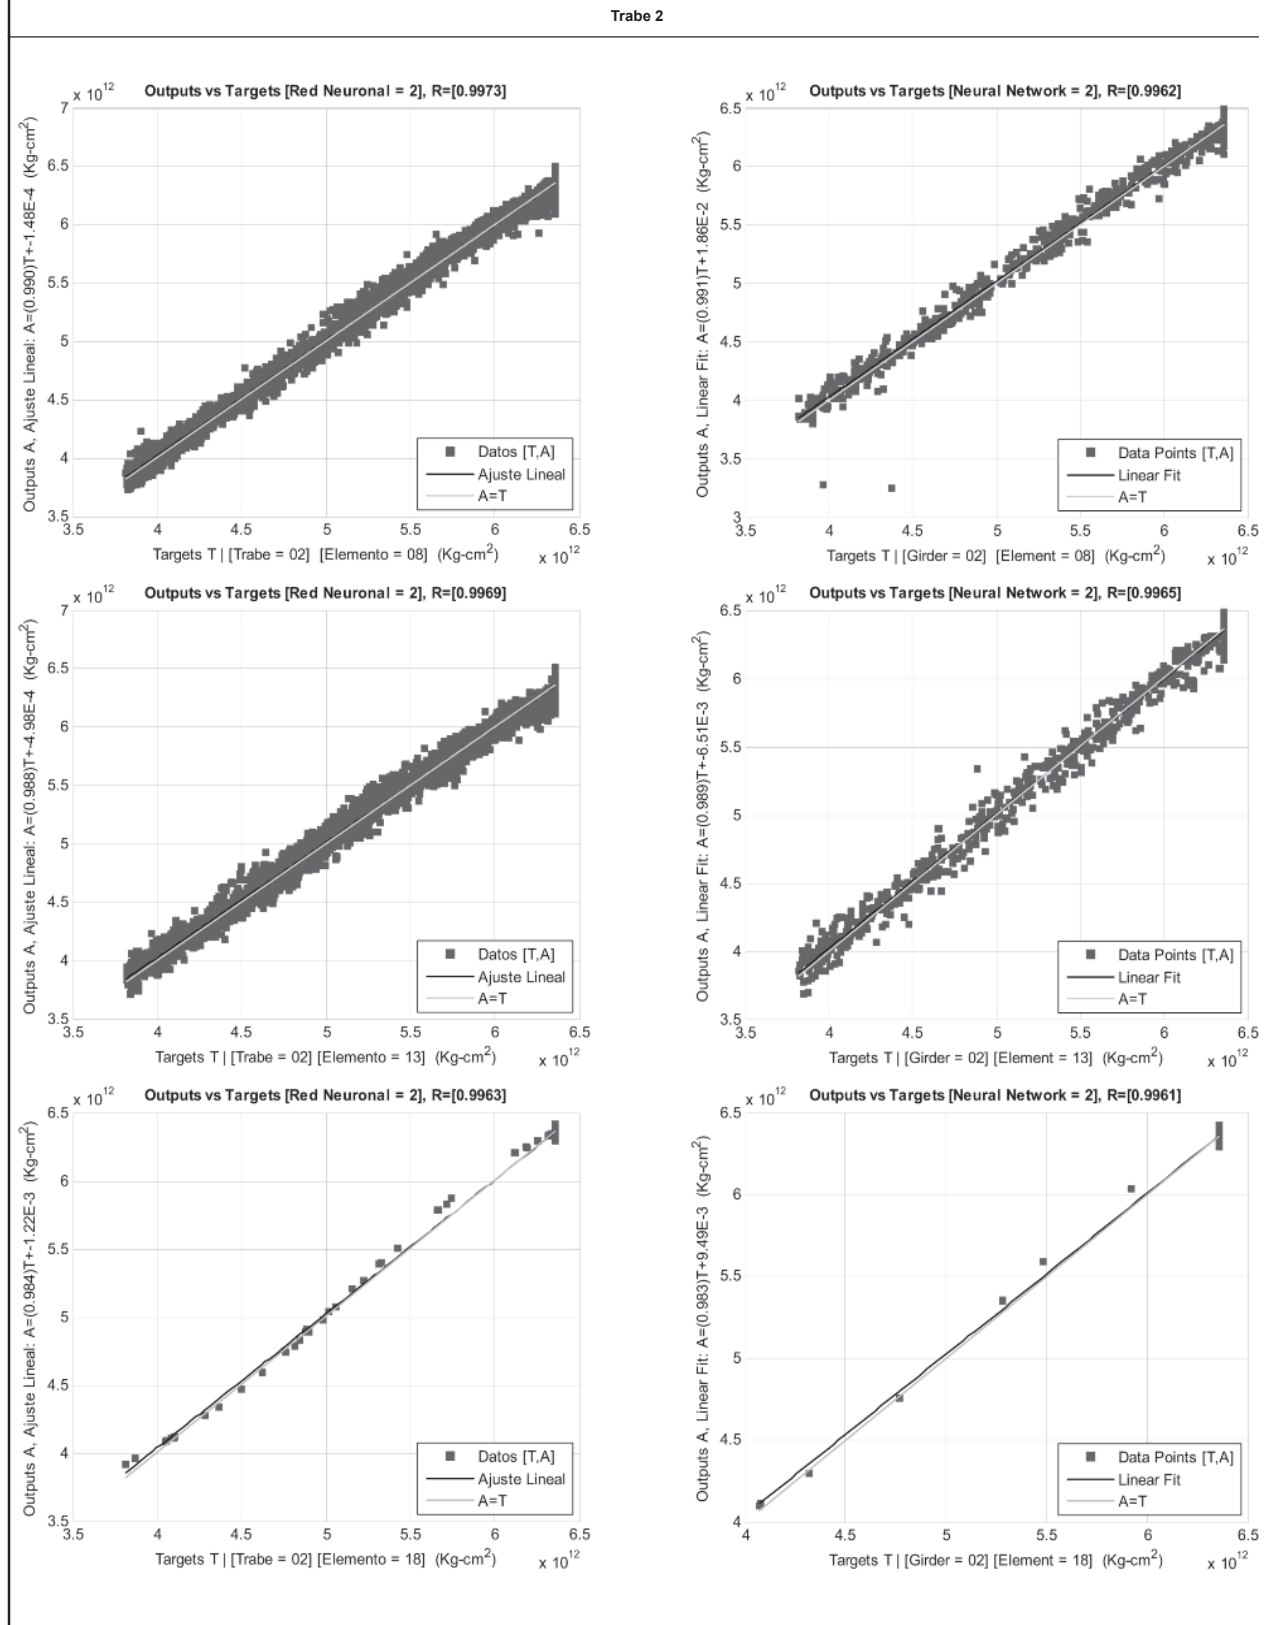


Figura 5c. Análisis de regresión de los resultados obtenidos por la red neuronal entrenada a partir de las diferencias en la energía de deformación modal.

Tabla 3

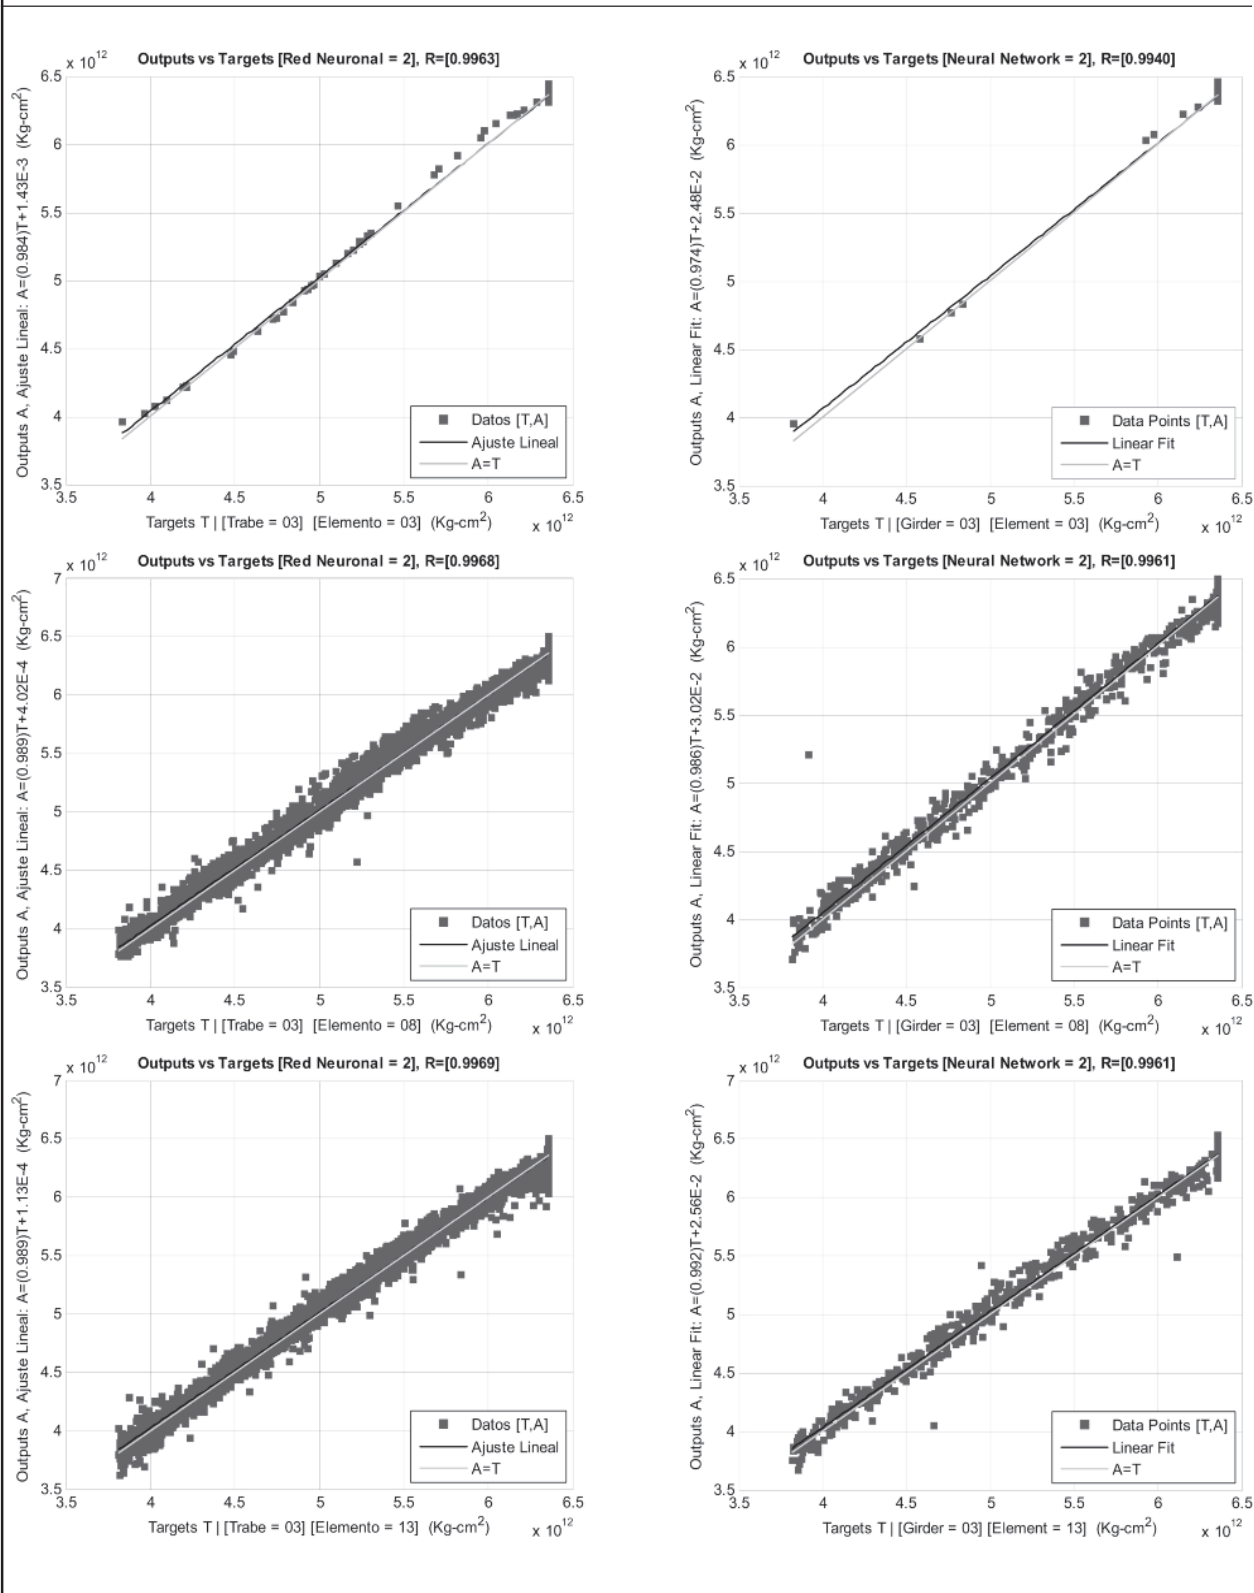


Figura 5d . Análisis de regresión de los resultados obtenidos por la red neuronal entrenada a partir de las diferencias en la energía de deformación modal.

