

Estimación de la respuesta probabilística de edificios de acero utilizando redes neuronales artificiales

Estimation of the probabilistic response of steel buildings using artificial neural networks

Juan Bojórquez Mora^{1*}, Alfredo Reyes Salazar¹, Francisco López Almansa²

RESUMEN

Se presenta un enfoque para obtener con una precisión aceptable factores de transformación probabilísticos mediante el entrenamiento de un modelo de red neuronal artificial (RNA). Los factores de transformación probabilísticos se definen como la relación entre la respuesta sísmica de estructuras de múltiples grados de libertad (SMGL) y sus sistemas equivalentes de un grado de libertad (S1GL), asociadas a una tasa de excedencia anual prescrita. El enfoque se utiliza para predecir la respuesta sísmica de edificios de acero. Se proponen ecuaciones útiles para obtener factores de transformación probabilísticos en términos de la ductilidad y la distorsión máxima de entrepiso, se establecen como función de la tasa media anual de excedencia y del período fundamental de vibración. Se muestra que las redes neuronales artificiales son una herramienta útil para los procedimientos de diseño sísmico basados en la confiabilidad estructural y para mejorar la próxima generación de metodologías de diseño sísmico.

Recibido: septiembre 2017
Aceptado: octubre 2017
Publicado: marzo 2018

ABSTRACT

An approach to obtain with acceptable accuracy probabilistic response transformation factors by training an artificial neural network (ANN) model is presented. The transformation factors are defined as the ratio of the seismic response of multi-degree-of-freedom structures and their equivalent single-degree-of-freedom systems, associated with a given annual exceedance rate. The approach is used for predicting the seismic response of steel framed buildings. Closed-form expressions to obtain probabilistic response transformation factors for maximum ductility and inter-story drift, as functions of their mean annual rate of exceedance, and of the fundamental vibration period of the structure, are proposed. It is shown that artificial neural networks are a useful tool for reliability-based seismic design procedures of framed buildings and for the improvement toward the next generation of earthquake design methodologies based on structural reliability.

Palabras Clave:

redes neuronales artificiales, confiabilidad estructural, edificios de acero, factores de transformación probabilísticos de respuesta sísmica.

Keywords:

artificial neural network, structural reliability, steel buildings, probabilistic seismic response transformation factors

1. INTRODUCCIÓN

La mayoría de los códigos de diseño sísmico se basan en parámetros que se centran en satisfacer restricciones deterministas para lograr un diseño satisfactorio; sin embargo, debido a la naturaleza incierta de los terremotos y sus efectos sobre las estructuras, estos criterios de diseño no pueden ser considerados como la mejor alternativa para resolver el problema del diseño sísmico. Un diseño más realista debe tener en cuenta todos los parámetros aleatorios, incluyendo la probabilidad de falla de la estructura durante un intervalo de tiempo dado; es decir, su confiabilidad estructural. En las últimas décadas varios investiga-

*Autor para correspondencia.

Dirección de correo electrónico: Juan Bojórquez Mora, juanbm@uas.edu.mx

¹Universidad Autónoma de Sinaloa, FIC, Culiacán Rosales, Sinaloa, México. C.P. 80040

²Universidad Politécnica de Cataluña, España

dores han desarrollado procedimientos para resolver problemas de confiabilidad estructural utilizando diferentes métodos [1, 2]. Hoy en día, a pesar de que las metodologías de confiabilidad estructural son muy comunes, hay serios obstáculos en las implementaciones prácticas, especialmente porque uno de los principales requisitos de los códigos de diseño sísmico es su fácil aplicación por los ingenieros estructurales. Por lo tanto, el uso de modelos prácticos o modelos simplificados como SIGL que representan con suficiente precisión el comportamiento estructural de SMGL, es una buena alternativa para la implementación práctica de la confiabilidad estructural. La relación entre la respuesta sísmica de SMGL y la de su sistema equivalente, de un grado de libertad asociado a una tasa de excedencia similar de un parámetro de respuesta se define como el factor de transformación probabilística (Tp). Bojórquez et al.[3] encontró factores de transformación probabilística entre la respuesta sísmica de SMGL y su equivalente SIGL; sin embargo, los resultados se limitaron a algunos modelos. En el presente trabajo se presenta un nuevo enfoque para reducir el trabajo computacional necesario en el análisis, de tal manera que es posible analizar cientos de edificios de acero. La metodología utilizada se basa en el uso de modelos redes neuronales artificiales.

En los últimos años los métodos de RNA han sido utilizados ampliamente para tratar problemas de confiabilidad estructural. Papadrakakis et al.[4] aplicaban las RNA para estimar la confiabilidad de estructuras con un modelo elástico-plástico; Papadrakakis y Lagaros[5] utilizaron un modelo de red neural de retropropagación orientado a la optimización sistemas estructurales complejos. Un dispositivo numérico para la evaluación de la confiabilidad de sistemas estructurales se desarrolló utilizando el modelo “feed-forward” [6]. Cardoso et al.[7] utilizó una metodología para calcular la probabilidad de falla estructural mediante la combinación de RNA y la simulación Montecarlo. Möller et al.[8] utilizó un modelo de RNA para optimizar el costo total de una estructura bajo restricciones relacionadas con confiabilidades mínimas especificadas para diferentes estados límite. La predicción del daño estructural inducida por sismo se estimó mediante un modelo de RNA utilizando el entrenamiento “backpropagation” [9]. Serkan et al.[10] propuso un modelo eficiente para predecir la capacidad de vigas de concreto reforzado. Chin-Sheng y I-Cheng desarrollaron un programa de cómputo para la optimización estructural que se basa en la teoría de RNA [11].

Por lo tanto, las redes neuronales artificiales se pueden utilizar para dar una respuesta razonable a los problemas que tienen soluciones no lineales y complejas. Información adicional sobre RNA se puede encontrar en [12, 13]. El objetivo del presente estudio es desarrollar un conjunto de ecuaciones aplicables a la evaluación de los factores de transformación probabilísticos de la respuesta sísmica mediante un modelo basado en la teoría de las RNA.

2. REDES NEURONALES ARTIFICIALES

Las Redes Neuronales Artificiales surgen de la necesidad de dar solución a problemas complejos, no como una secuencia de pasos, sino como la evolución de unos sistemas computacionales inspirados en el cerebro humano, y dotados por tanto de cierta “inteligencia”. Una RNA es un modelo matemático o un modelo computacional que se inspira en la estructura y aspectos funcionales de redes neuronales biológicas. La estructura de una RNA es la siguiente: las neuronas son el elemento principal de procesamiento estas se conectan con otras neuronas por medio de una señal de peso (sinapsis), las entradas son las dendritas y el resultado es el axón (ver Figura 1). Al igual que los seres vivos las RNA parten de un proceso de aprendizaje para establecer relaciones entre las variables que definen un fenómeno específico. La potencia de procesamiento de una RNA se debe a su estructura paralela distribuida, y su capacidad de aprender de algunos ejemplos, obteniendo resultados aceptables

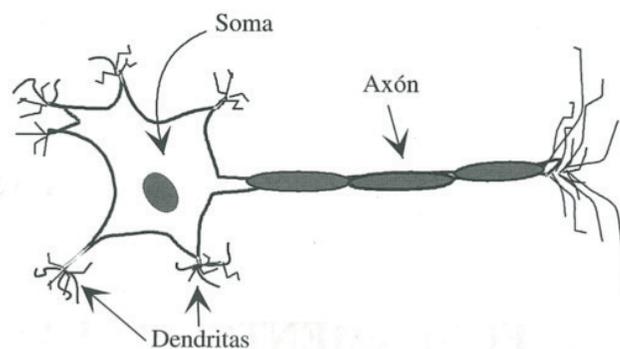


Figura 1. Estructura de una neurona

para patrones nunca antes presentados a la misma.

Existen diferentes topologías establecidas por diferentes autores para definir la estructura de las RNA; sin embargo, en este trabajo se seleccionó el Perceptrón Multicapa con conexión hacia adelante [14]. En

la Figura 2 se muestra la arquitectura correspondiente al Perceptrón Multicapa. La arquitectura comienza con una capa de entrada la cual se conecta a una capa oculta, a su vez esta puede estar conectada a otra capa oculta o directamente a la capa de salida. Debido a que el flujo de información es siempre de la capa de entrada hacia la capa de salida, la información de las neuronas es únicamente con los elementos de la capa siguiente.

El entrenamiento de la RNA utilizada en este estu-

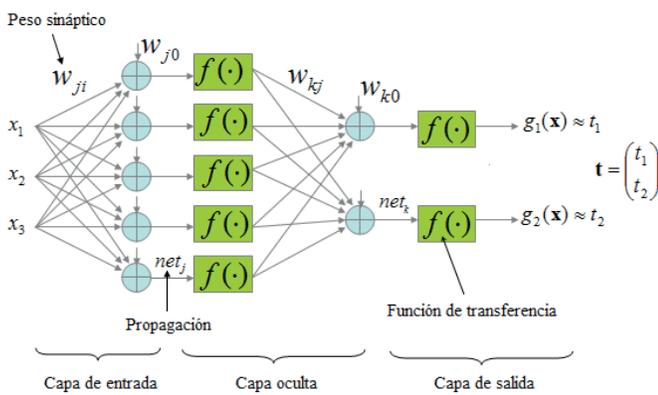


Figura 2. Perceptrón Multicapa

dio se llevó a cabo mediante el algoritmo “Backpropagation” propuesto por Rumelhart et al. [15]. El procedimiento es el siguiente:

1) Se proporciona a la red para su aprendizaje un conjunto de patrones constituidos por pares de entradas y salidas.

2) La información de los datos de entrada se introduce a través de la primera capa. Esta información se propaga por la red mediante una regla de propagación, las entradas se multiplican por los pesos de la conexión entre capas, la salida es transformada por una función no lineal y transferida a la siguiente capa (existen varias funciones de transferencia entre las que se pueden señalar: escalón, lineal, mixta, Gaussiana, tangente hiperbólica, secante hiperbólica y sigmoidea). Es importante mencionar que muchas de las investigaciones han utilizado una función de transferencia sigmoidea en las capas ocultas y una función lineal en la capa de salida obteniendo resultados satisfactorios. Por este motivo aquí se seleccionan estas

funciones de transferencia. El mismo procedimiento se aplica para las siguientes capas hasta obtener la salida de la red.

3) El resultado obtenido se compara con los valores objetivo y se estima el error.

4) El error en la capa de salida se propaga hacia atrás partiendo de la capa de salida, pasando por las capas ocultas hasta alcanzar la entrada, de tal manera que todas las neuronas reciben un cierto porcentaje de error.

5) Considerando la cantidad recibida, cada neurona realiza un ajuste a los pesos de sus conexiones con otras.

6) El procedimiento se repite con otros pares de entradas hasta que el error es menor que una tolerancia establecida.

3. CONFIABILIDAD ESTRUCTURAL

La confiabilidad estructural puede ser estimada mediante diferentes enfoques, en este artículo se utiliza la curva de peligro sísmico que representa el número medio anual de eventos sísmicos cuya intensidad excede a cierto valor dado. A partir de esta curva se puede calcular la probabilidad condicional de que un evento sísmico aleatorio presente una intensidad mayor o igual a un valor dado en cierto intervalo de tiempo. Esta probabilidad se puede obtener como la relación entre el número medio anual de sismos cuya intensidad excede el valor de interés, y el número medio anual del total de los eventos.

Si se supone que la ocurrencia de los eventos sísmicos (que provocan daño estructural) puede representarse por un proceso homogéneo de Poisson, es posible plantear una ecuación que permita evaluar el número medio de sismos por unidad de tiempo, que causan en la estructura daños superiores a cierto valor d , como sigue [16], (ver Ecuación 1):

$$\lambda_D(d) = \int_0^{\infty} -\frac{d}{dy} \lambda(y) P[D > d | Y = y] dy \quad (1)$$

donde:

$\lambda_y(y)/dy$ es la derivada de la curva de peligro sísmico, y es la intensidad.

$P[D > d | Y = y]$ es la probabilidad condicional de que la demanda exceda cierto valor, dado que se presentó una intensidad $Y=y$.

$\lambda(d)$ es el número de veces por año que se excede el parámetro d , probabilidad anual de excedencia.

4. FACTORES DE TRANSFORMACIÓN PROBABILÍSTICOS

La probabilidad anual de excedencia de un SMGL puede estimarse si se conoce la probabilidad anual de excedencia de su S1GL equivalente. Para ello, es necesario conocer la relación entre las respuestas de ambos sistemas estructurales para una misma tasa de excedencia λ_0 , que en este trabajo se denominan factores de transformación. Estos toman en cuenta la diferencia entre ambos sistemas estructurales (ver Figura 3), dada la misma probabilidad de excedencia.

En estudios previos se han calculado funciones de transformación que relacionan las respuestas máximas entre marcos estructurales de SMGL y S1GL en tér-

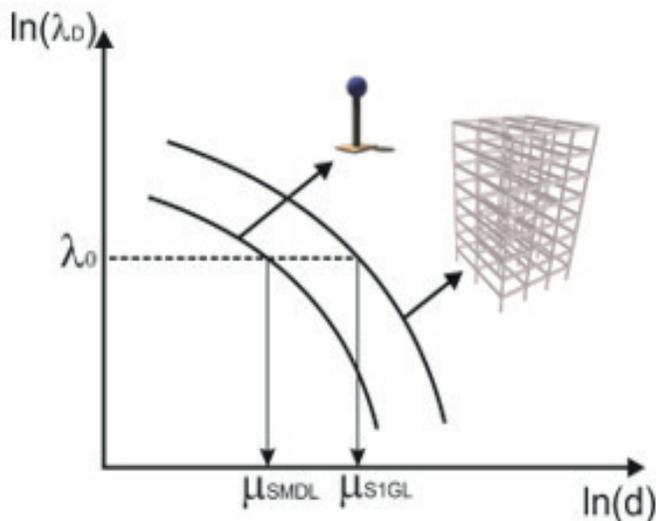


Figura 3. Ejemplo de curvas de peligro de demanda estructural para un SMGL y su correspondiente S1GL equivalente

minos de distintos parámetros [17-19] para una misma tasa anual de excedencia; sin embargo, hasta ahora no se ha obtenido ninguna función de transformación que relacione las respuestas en términos de ductilidad máxima y distorsiones máximas de entrepiso y que sean aplicables a edificios de mediana altura ubicados en la zona blanda del valle de México. Además, tampoco se han utilizado RNA para este tipo de estudios.

En el presente estudio, el T_p para la ductilidad máxima y para la distorsión máxima de entrepiso se obtienen a través de las ecuaciones (2) y (3). En estas ecuaciones, $T_{p\mu}$ y $T_{p\gamma}$ son el factor de transformación probabilístico para la ductilidad máxima y para la distorsión máxima de entrepiso, respectivamente; $\mu_{SMGL}(\lambda_\mu)$ y $\mu_{S1GL}(\lambda_\mu)$ son los valores de la demanda de ductilidad máxima para los SMGL y S1GL asociados con alguna tasa anual específica de excedencia de la ductilidad máxima; $\mu_{MGDL}(\lambda_\gamma)$ y $\mu_{S1GL}(\lambda_\gamma)$ son los valores de la máxima demanda de distorsión máxima de entrepiso para los SMGL y S1GL asociados con alguna tasa anual específica de excedencia de la distorsión máxima de entrepiso, respectivamente.

$$T_{P\mu} = \frac{\mu_{SMGL}(\lambda_\mu)}{\mu_{S1GL}(\lambda_\mu)} \quad (2)$$

$$T_{P\gamma} = \frac{\mu_{MGDL}(\lambda_\gamma)}{\mu_{S1GL}(\lambda_\gamma)} \quad (3)$$

5. MODELOS ESTRUCTURALES Y REGISTROS SÍSMICOS

En este trabajo se analizan cinco marcos de acero de 4, 6, 8, 10 y 14 niveles diseñados con el Reglamento de Construcciones del Distrito Federal. Para todos los marcos se utilizó un factor de comportamiento sísmico de $Q=3$. Como se muestra en la Figura 4, los marcos tienen tres crujías de 8m cada una, y una altura de entrepiso de 3.5m. Se usó acero A-36 en las vigas y columnas de los marcos. Las características geométricas globales de los marcos se muestran en la Figura 4.

Para cada marco estructural se obtuvo un S1GL equivalente que representa sus características dinámicas. La manera en que se obtuvieron los S1GL equivalentes fue igualando tanto el periodo de vibración, como el cortante basal a la fluencia y el porcentaje de amortiguamiento crítico de los marcos estructurales

de acero y los S1GL (5% del amortiguamiento crítico). Tanto el cortante basal resistente como el des-

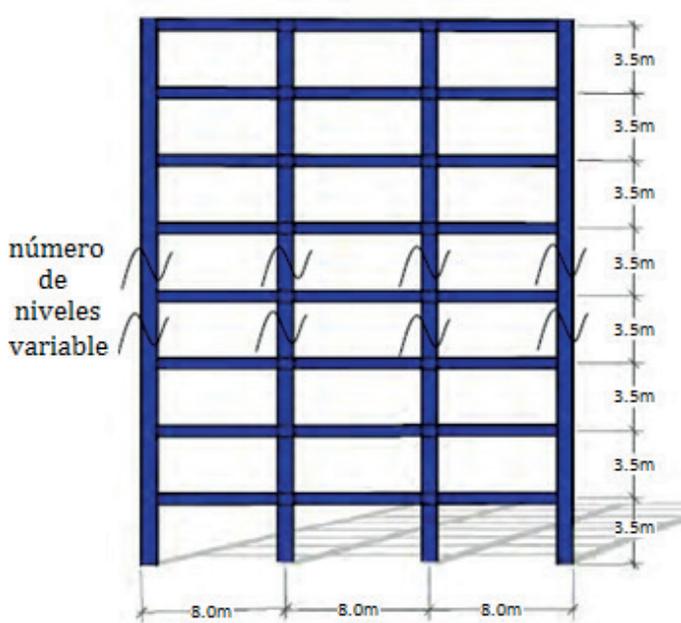


Figura 4. Geometría de los marcos utilizados

plazamiento de fluencia de cada marco se obtuvieron mediante un análisis de empuje lateral estático no-lineal (“push-over”, en inglés) utilizando el programa RUAUMOKO [20] (ver Figura 5). Para el análisis, se consideró un modelo hysterético bilineal con 3% de rigidez de post-fluencia.

Tabla 1. Periodo fundamental de vibración (T_0), coeficiente sísmico resistente (C_y) y desplazamiento de fluencia (δ_y), correspondientes a los marcos analizados

Marco	T_1 (seg)	C_y	δ_y (m)
F4	0.9	0.48	0.13
F6	1.07	0.42	0.17
F8	1.2	0.38	0.19
F10	1.37	0.36	0.23
F14	1.91	0.25	0.3

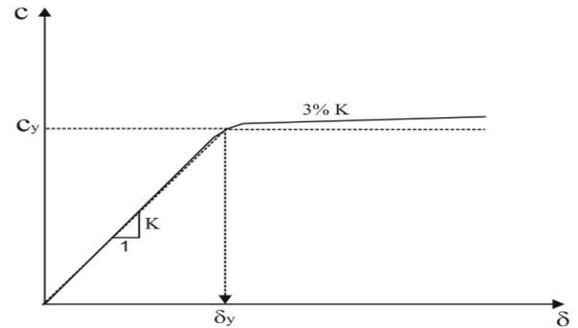


Figura 5. Gráfica coeficiente basal vs desplazamiento de azotea. Modelo de comportamiento bilineal

5.1 Registros sísmicos

Los dos enfoques descritos anteriormente para obtener los factores de transformación probabilísticos se aplican a cinco estructuras de acero regulares que fueron diseñadas de acuerdo con el Código de Diseño de la Ciudad de México, 2004 [21] y sometidas a 30 movimientos de suelo blando registrados en la Zona del Lago de la Ciudad de México. El suelo tiene un período dominante (T_s) de dos segundos. En particular, todos los movimientos se registraron en la Ciudad de México durante eventos sísmicos con magnitudes cercanas a 7 o mayores. La Tabla 2 resume las características principales de los registros sísmicos. En esta tabla, A_{ms} y V_{ms} representa la aceleración y velocidad máxima del terreno.

6. MODELO DE RED NEURAL ARTIFICIAL

La selección de una arquitectura de modelo ANN adecuada es una tarea compleja. La selección del número de capas ocultas y neuronas es importante para desarrollar o entrenar una RNA. Esta selección depende de la naturaleza del problema a investigar y, a menudo, se sigue un proceso de ensayo y error para determinar la estructura adoptada del modelo de RNA. En este trabajo se probaron varios modelos de RNA preliminares considerando de 1 a 30 capas y 10 a 30 neuronas en la capa oculta. Se propusieron dos modelos de RNA para la máxima ductilidad y el otro para la máxima distorsión de entrepiso.

Tabla 2. Registros sísmicos utilizados

Registro	Fecha	Magnitud	A_{ms} (cm/s ²)	V_{ms} (cm/s)
1	19/09/1985	8.1	178.0	59.5
2	21/09/1985	7.6	48.7	14.6
3	25/04/1989	6.9	45.0	15.6
4	25/04/1989	6.9	68.0	21.5
5	25/04/1989	6.9	44.9	12.8
6	25/04/1989	6.9	45.1	15.3
7	25/04/1989	6.9	52.9	17.3
8	25/04/1989	6.9	49.5	17.3
9	14/09/1995	7.3	39.3	12.2
10	14/09/1995	7.3	39.1	10.6
11	14/09/1995	7.3	30.1	9.62
12	14/09/1995	7.3	33.5	9.37
13	14/09/1995	7.3	34.3	12.5
14	14/09/1995	7.3	27.5	7.8
15	14/09/1995	7.3	27.2	7.4
16	09/10/1995	7.5	14.4	4.6
17	09/10/1995	7.5	15.8	5.1
18	09/10/1995	7.5	15.7	4.8
19	09/10/1995	7.5	24.9	8.6
20	09/10/1995	7.5	17.6	6.3
21	09/10/1995	7.5	19.2	7.9
22	09/10/1995	7.5	13.7	5.3
23	09/10/1995	7.5	17.9	7.18
24	11/01/1997	6.9	16.2	5.9
25	11/01/1997	6.9	16.3	5.5
26	11/01/1997	6.9	18.7	6.9
27	11/01/1997	6.9	22.2	8.6
28	11/01/1997	6.9	21.0	7.76
29	11/01/1997	6.9	20.4	7.1
30	11/01/1997	6.9	16.0	7.2

La arquitectura seleccionada se basa en una capa de entrada, una capa oculta y una capa de salida. En la fase de entrenamiento del modelo neural propuesto la capa de entrada se compone de dos neuronas que representan T_0 y la tasa media anual para superar el parámetro de respuesta seleccionado, las capas ocultas están compuesta por 25 neuronas en ambos modelos, la capa de salida tiene una sola neurona que representa los factores de transformación de la respuesta probabilística.

6.1. Fase de entrenamiento del modelo de RNA

El algoritmo “backpropagation” se utilizó para el entrenamiento, la función de transferencia en la capa oculta fue sigmoidea y la capa de salida fue la función lineal. El marco F8 no fue incluido en la fase de entrenamiento porque se utiliza para evaluar el rendimiento del modelo de RNA. Es importante remarcar que las entradas y salidas de la red no fueron normalizadas. Se formaron dos modelos, uno para las distorsiones máximas de entrepisos y el otro para la ductilidad máxima. Los resultados de la etapa de entrenamiento muestran una excelente relación con los valores reales, el error medio cuadrático no es mayor que 4% para todos los modelos. Las Figuras 6 y 7 muestran la fase de entrenamiento de la red, se comparan los resultados obtenidos de los análisis reales contra el enfoque del modelo de RNA, para la máxima ductilidad y para la distorsión máxima de entrepiso, respectivamente.

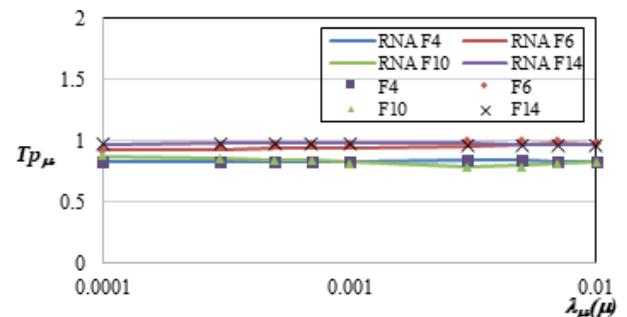


Figura 6. Comparación del Tp real para la ductilidad máxima y los obtenidos a través de RNA

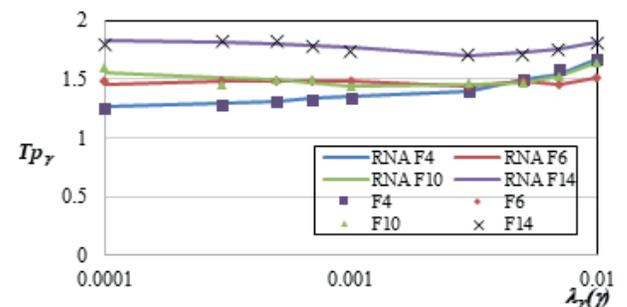


Figura 7. Comparación del Tp real para la distorsión máxima de entrepiso y los obtenidos a través de RNA

6.2 Fase de prueba del modelo de RNA

Una vez finalizado el entrenamiento, se llevó a cabo la fase de prueba. Los resultados obtenidos en la fase de prueba no alcanzaron el mismo nivel de precisión encontrado durante el entrenamiento; sin embargo, se puede observar un grado aceptable de similitud entre los T_p obtenidos mediante las RNA y los obtenidos con el enfoque tradicional en términos de ambos parámetros de respuesta. Es importante recordar que el modelo presentado en la fase de prueba nunca fue mostrado al modelo de RNA, por lo que se puede concluir que la precisión obtenida con el modelo de RNA es satisfactoria. La comparación entre los modelos de RNA y los valores reales para el marco F8, en términos de ductilidad máxima y de distorsión máxima de entrepiso se muestran en las Figuras 8 y 9.

Los resultados indican que la estimación con el

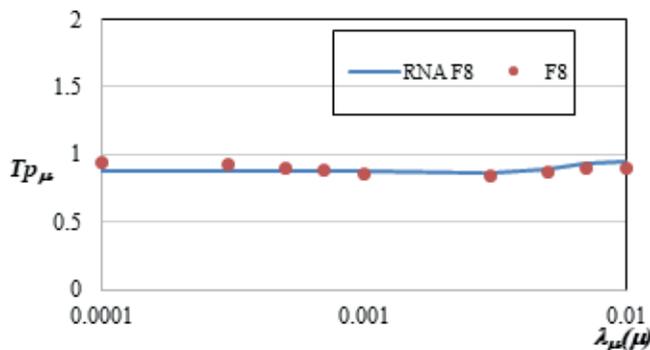


Figura 8. Error en la prueba del marco F8 para la ductilidad máxima

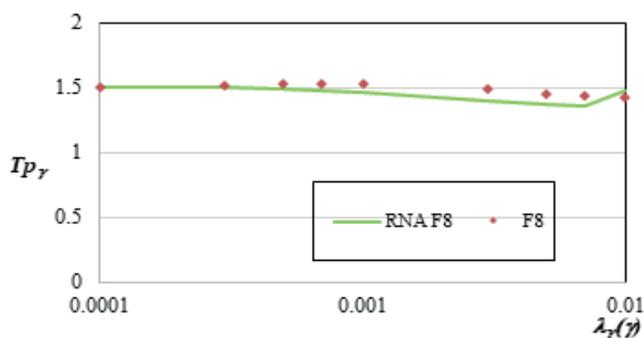


Figura 9. Error en la prueba del marco F8 para la distorsión máxima de entrepiso

modelo de RNA tiene un error máximo del 7% para todos los casos de prueba. Por lo tanto, el modelo de

RNA puede reemplazar el modelo matemático de los marcos de acero para estimar T_p .

7. EXPRESIONES PARA ESTIMAR T_p

El tiempo requerido para estimar los factores probabilísticos es considerablemente grande, por este motivo es en este estudio se utilizan los modelos de RNA para reducir el tiempo a solo unos pocos segundos, obteniendo resultados de un gran número de edificios en un tiempo relativamente pequeño con el fin de proponer expresiones que relacionen el periodo fundamental de vibración y la tasa anual de excedencia con su respectivo factor de transformación probabilístico. Para encontrar la relación entre estructuras de acero modeladas como SMGL y su respectivo SIGL se analizó una gran base de datos de edificios. Se analizó un conjunto de 40 estructuras de acero utilizando los modelos de RNA. El período de vibración fundamental T_1 de los edificios se consideró en un intervalo de 0.5 a 2.0s, y la tasa media anual de excedencia entre 0.001 y 0.01. Se realizó un análisis de regresión para encontrar expresiones cercanas que puedan ser utilizadas con fines prácticos en la ingeniería sísmica. Los resultados correspondientes a la ductilidad y a las distorsiones máximas de entrepiso se muestran en las Figuras 10 y 11, respectivamente.

El análisis de regresiones se resume en las ecuaciones (4) y (5). El error máximo obtenido fue aproximadamente del 10% del valor real. Obsérvese que estas ecuaciones están muy bien relacionadas con el T_p en términos de ductilidad máxima y distorsión máxima de entrepiso.

$$T_{p\mu} = 0.2T_1 + 0.038\lambda + 0.69 \quad (4)$$

$$T_{p\gamma} = 0.287T_1 + 0.056\lambda + 1.325 \quad (5)$$

8. CONCLUSIONES

Este artículo presenta el uso de Redes Neuronales Artificiales con el objetivo de proporcionar una herramienta para el análisis basado en la confiabilidad de sistemas estructurales de acero. El enfoque se aplicó para obtener factores de transformación de respuesta probabilística para evaluar la respuesta en términos de la máxima ductilidad y la distorsión máxima de

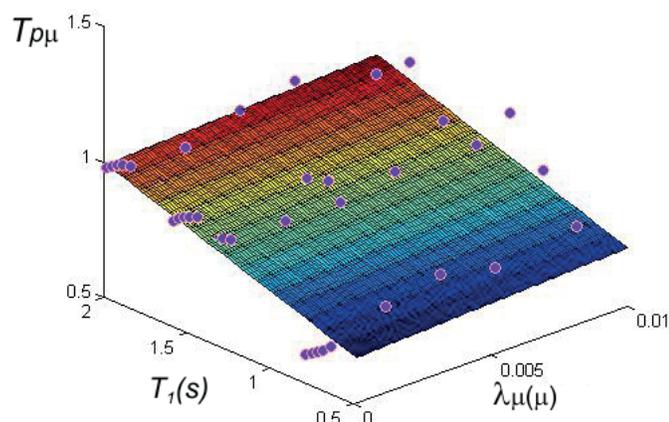


Fig. 10. Regresión para estimar el T_p en términos de la ductilidad máxima

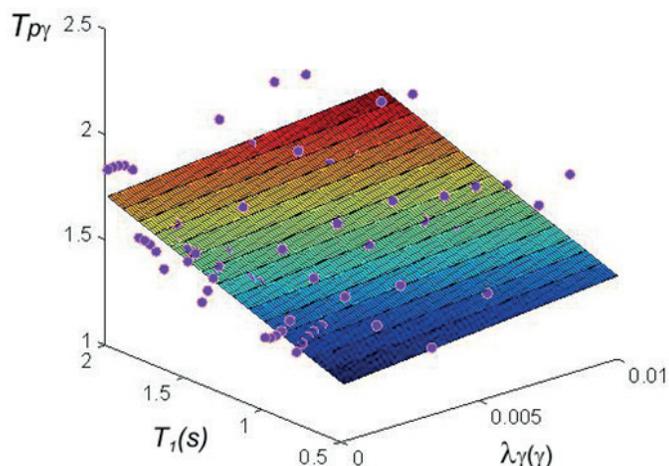


Fig. 11. Regresión para estimar el T_p en términos de la distorsión máxima de entrepiso

entrepiso de los marcos de acero, SMGL, basándose en la respuesta del S1GL equivalente. La estimación de los factores requiere varios análisis no lineales, por lo que el esfuerzo computacional involucrado en la tarea es considerablemente alto; sin embargo, aquí se muestra que el uso de Redes Neuronales Artificiales es una buena alternativa para el análisis práctico de estructuras, obteniendo resultados dentro de una tolerancia aceptable. El esfuerzo computacional se reduce considerablemente con el uso de RNA. Además, se proponen ecuaciones aplicables para obtener factores de transformación de respuesta probabilística para la ductilidad máxima y la distorsión máxima de entrepiso, como funciones de la tasa media de excedencia de

un parámetro de respuesta y del período de vibración fundamental de la estructura. Es importante mencionar que los nuevos factores propuestos podrían ser usados para estimar la respuesta sísmica de edificios de acero a través de la respuesta sísmica de modelos S1GL simplificados que tienen probabilidad de falla similar. Finalmente, las expresiones cerradas propuestas pueden ser muy útiles en la implementación de nuevos procedimientos de diseño sísmico basados en confiabilidad estructural, o en la mejora hacia la próxima generación de metodologías de diseño sísmico.

REFERENCIAS

[1] Fragiadakis M., Vamvatsikos D., Karlaftis M.G., Lagaros N.D., Papadrakakis M. Seismic assessment of structures and lifelines. *Journal of Sound and Vibrations*, Vol. 334, 2015, p. 29-56.

[2] Chojaczyk AA., Teixeira AP., Neves L.C., Cardoso J.B., Guedes-Soares C. Review and application of Artificial Neural Networks models in reliability analysis of steel structures. *Structural Safety*, Vol. 52, 2015, p. 78-89.

[3] Bojórquez E., Ruiz SE., Terán-Gilmore A. Reliability-based evaluation of steel structures using energy concepts. *Engineering Structures*, Vol. 30, Issue 6, 2008, p. 745-759.

[4] Papadrakakis M., Papadopoulos V., Lagaros D.L. Structural reliability analysis of elastic-plastic structures using neural networks and Monte Carlo simulation. *Computer Methods in Applied Mechanics and Engineering*, Vol. 136, 1996, p. 145-163.

[5] Papadrakakis M., Lagaros D.L. Reliability-based structural optimization using neural networks and Monte Carlo simulation. *Computer Methods in Applied Mechanics and Engineering*, Vol. 191, 2002, p. 3451-3507.

[6] Hurtado JE., Alvarez DA. Neural network-based reliability analysis: a comparative study. *Computer Methods in Applied Mechanics and Engineering*, Vol. 191, 2002, p. 113-132.

[7] Cardoso J.B., Almeida J.R., Dias J.M., Coelho P.G. Structural reliability analysis using Monte Carlo simulation and neural networks. *Advances in Engineering Software*, Vol. 39, Issue, 6, 2007, p. 505-513.

[8] Möller O., Foschi R.O., Quiroz L.M., Rubinstein M. Structural optimization for performance-based design in earthquake engineering: applications of neural networks. *Structural Safety*, Vol. 31, Issue 6, 2009, p. 490-499.

[9] Lautour O.R., Omenzetter P. Prediction of seismic-induced structural damage using artificial neural networks. *Engineering Structures*, Vol. 31, Issue 2, 2009, p. 600-606.

[10] Serkan E., Onur O., Fuad O. Estimation of ultimate torque capacity of the SFRC beams using ANN. *Structural Engineering and Mechanics*, Vol. 53, Issue 5, 2015, p. 939-956.

[11] Chin-Sheng K., I-Cheng Y. Optimal design of plane frame structures using artificial neural networks and ratio variables. *Structural Engineering and Mechanics*, Vol. 52, Issue 4, 2014, p.739-753.

[12] Haykin S. *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, Englewood Cliffs, 1999.

[13] Martín del Brio M., Molina SM. *Redes Neuronales y Sistemas Difusos*. Alfaomega, Madrid, Spain, 2002.

[14] Shepherd G. M. *The synaptic organization of the brain*. 4a edición, 1997, Oxford University Press.

[15] Rumelhart DE., Hinton GE., Williams RJ. Learning internal representation by error backpropagation. *Parallel distributed processing: explorations microstructure*

of cognition 1, MIT Press Cambridge, MA, 1986, pp. 318-362.

[16] Cornell CA. Engineering seismic risk analysis. *Bulletin of the Seismological Society of America*, Vol. 58, Issue 5, 1968, p. 1583-1606.

[17] Inoue T., Cornell CA. Seismic hazard analysis of multi-degree-of-freedom structures. *Reliability of marine structures RMS-8 Technical Report*, Stanford, California, 1990.

[18] Esteva L., Ruiz S.E., Rivera J. Reliability and performance-based seismic design of structures with energy-dissipating devices. *9th World Seminar on Seismic Isolation, Energy Dissipation and Active Vibration Control of Structures*, 2005, Kobe, Japan.

[19] Bojórquez E., Ruiz S.E., Esteva L. Funciones de transformación de respuestas máximas entre marcos estructurales y sus correspondientes SIGL con probabilidades de falla similares. *XV Congreso Nacional de Ingeniería Sísmica*, 2005, Ciudad de México.

[20] Carr A. RUAUMOKO, inelastic dynamic analysis software. University of Canterbury, 2000, Department of Civil Engineering.

[21] Reglamento de Construcciones para el Distrito Federal. *Gaceta Oficial del Gobierno del Distrito Federal*. 29 de enero de 2004.

Semblanzas

Juan Bojórquez Mora

Profesor Investigador Titular B de la Facultad de Ingeniería de la Universidad Autónoma de Sinaloa. Obtuvo el grado de Licenciatura en Ingeniería Civil por la Facultad de Ingeniería de la Universidad Autónoma de Sinaloa con mención honorífica. Es maestro en Ingeniería Civil por la División de Estudios de Posgrado de la Facultad de Ingeniería de la UNAM, grado obtenido con Mención Honorífica. Posteriormente cursó estudios de Doctorado en el Instituto de Ingeniería de la UNAM. Realizó una estancia doctoral en el Departamento de Ingeniería Civil y Ambiental de la Universidad Estatal de Colorado en Estados Unidos. PREMIO a la mejor tesis Doctoral en el décimo Concurso Nacional de Tesis de Doctorado (2017) otorgado durante el Congreso Nacional de Ingeniería Sísmica Guadalajara 2017. Es miembro del Sistema Nacional de Investigadores. Autor de casi 30 artículos en Revistas Científicas y Congresos Nacionales e Internacionales. Ha sido director de 5 tesis de Licenciatura, actualmente dirige algunas tesis de Licenciatura y de Maestría. Entre sus aportaciones científicas, destaca su propuesta para la optimización y calibración de códigos para el diseño sísmico de edificios utilizando inteligencia artificial, la cual será adoptada en la nueva versión del Reglamento de Construcción de la Ciudad de México.



Alfredo Reyes Salazar

Licenciatura en Ingeniería Civil, Facultad de Ingeniería, Universidad Autónoma de Sinaloa, Culiacán, Sinaloa, 1978-1983. **Maestría** en Ingeniería Estructural, Facultad de Ingeniería Universidad Autónoma de Sinaloa, Culiacán, Sinaloa, 1985-1987. **Doctorado** en Ingeniería Estructural, Departamento de Ingeniería Civil e Ingeniería Mecánica, Universidad de Arizona, Tucson, Arizona, U.S.A., 1993-1996. Profesor e Investigador de Tiempo completo Titular C, de la Universidad Autónoma de Sinaloa con una antigüedad de 36 años. **64 artículos** en revistas indexadas-arbitradas, la mayoría de ellas indexadas en el Journal Citation Reports (JCR) y más de **130 artículos en Congresos** Nacionales e Internacionales. Sus trabajos han sido **citados cerca de 800 veces** (Google scholar). Ha impartido más de 20 materias distintas a nivel Licenciatura y Posgrado y es Profesor de la Maestría y el Doctorado en Ciencias de la Ingeniería, calificados por el CONACYT como posgrados de Excelencia. Ha participado como responsable o co-responsable en **más de 28 proyectos de investigación**, varios de ellos con financiamiento externo y en **más de 10 proyectos de desarrollo institucionales** (FOMES y PIFIs). Ha sido director de más de **40 tesis**, entre Licenciatura, Maestría y Doctorado. Entre sus principales distinciones se tienen: (a) Miembro del Sistema Nacional de Investigadores por más de 22 años; (b) “Profesor Emérito” por la Universidad Autónoma de Sinaloa en 2012. (c) “Ingeniero Civil del Año” otorgado por el Colegio de Ingenieros Civiles del Estado de Sinaloa A.C. en junio de 2012; (d) Líder del Cuerpo Académico consolidado Estructuras y Mecánica Básica de la Facultad de Ingeniería de la Universidad Autónoma de Sinaloa.



Francisco López Almansa

Ingeniero civil desde 1974, Maestría y doctorado en 1987 y 1988, respectivamente. Docente en la Universidad Politécnica de Cataluña desde 1976; catedrático desde 2007. Ingeniero consultor profesional de 1976 a 1987; desde 1987 sólo consultoría avanzada de transferencia de tecnología. Enseñanza en matemáticas y en los campos relacionados con análisis estructural. Promotor y director de varios programas de Maestría y Doctorado. Actualmente docente en varias instituciones extranjeras. Sus principales áreas de investigación son: dinámica de estructuras, ingeniería sísmica, control activo y pasivo de estructuras (aislamiento de base, disipadores de energía), análisis numérico y experimental de estructuras de hormigón y mampostería. Publicaciones principales: 42 trabajos en revistas indexadas por la Web of Science, 15 artículos en otras revistas, 11 monografías, 136 presentaciones en conferencias científicas, y 7 libros. Tesis doctorales supervisadas 15 y alrededor de 65 de maestría. Participación en 23 proyectos de investigación nacionales y 14 internacionales; entre ellos, promoción y coordinación (investigador principal) de 6 proyectos de investigación nacionales y 6 internacionales.

