

DISEÑO SÍSMICO PRELIMINAR DE EDIFICIOS DE CONCRETO REFORZADO USANDO REDES NEURONALES ARTIFICIALES

Juan Bojórquez Mora¹, Dante Tolentino², Sonia E. Ruiz¹ y Edén Bojórquez³

Recepción: 29 de junio de 2015

Aprobación: 1 de febrero de 2016

Publicación: 15 de abril de 2016

RESUMEN

Se presenta una aplicación de las Redes Neuronales Artificiales (RNA) para el pre-diseño sísmico de edificios de concreto reforzado. Se entrenan dos modelos de RNA. El primer modelo corresponde a edificios con 8 a 12 niveles, y el segundo a edificios con 4 a 7 niveles, ubicados en el suelo blando de la Ciudad de México. Se usan modelos de RNA con alimentación “hacia adelante” y con un algoritmo de aprendizaje de retroalimentación. Se comparan los diseños de edificios obtenidos mediante RNA con diseños realizados de manera convencional (siguiendo las especificaciones vigentes del Reglamento de Construcciones para el Distrito Federal), y se obtienen diferencias máximas del orden de 15% a nivel de elementos estructurales, por lo que se aceptan los modelos de RNA propuestos.

Palabras clave: redes neuronales artificiales, edificios de concreto reforzado, diseño sísmico, soluciones numéricas.

ABSTRACT

An application of Artificial Neural Networks (ANN) for the seismic design of reinforced concrete buildings is presented. Two models of ANN were trained. The first model corresponds to buildings designed for 8-12 stories and the second model for 4-7 stories. The buildings are located in soft soil of the valley of Mexico. The Feed-Forward Backpropagation network is used for the ANN models. Two models designed by means of ANN were compared with those obtained with the conventional design way. As a result of a comparative analysis, maximum differences around 15% were found in the structural elements; therefore, the proposed ANN models are accepted.

Keywords: Artificial Neural Networks, reinforced concrete structures, seismic design, numerical solutions.

RESUMO

Apresenta-se uma aplicação das Redes Neurais Artificiais (RNA) para o desenho sísmico de edifícios de concreto reforçado. São testados dois modelos de RNA. O primeiro modelo corresponde a edifícios de 8 a 12 andares e o segundo, a edifícios de 4 a 7 andares, localizados no solo brando da Cidade do México. São utilizados modelos de RNA com alimentação “para frente” e com um algoritmo de aprendizagem de retroalimentação. Os desenhos de edifícios obtidos mediante RNA são comparados a desenhos realizados de maneira convencional (seguindo as especificações vigentes do Regulamento de Construções do Distrito Federal), e se obtém diferenças máximas da ordem de 15% ao nível de elementos estruturais, por tanto são aceitos os modelos de RNA propostos.

Palavras chave: redes neurais artificiais, edifícios de concreto reforçado, projeto sísmico, soluções numéricas.

⁽¹⁾ Instituto de Ingeniería, Universidad Nacional Autónoma de México, Circuito Interior, Ciudad Universitaria, Coyoacán, México, D.F., CP. 04510, México, DF. JBojorquezM@iingen.unam.mx, SRuizG@iingen.unam.mx

⁽²⁾ Sección de Estudios de Posgrado e Investigación, ESIA Zacatenco, Instituto Politécnico Nacional, Gustavo A. Madero C.P. 07320, México, DF. dtolentinolsro@gmail.com

⁽³⁾ Facultad de Ingeniería, Universidad Autónoma de Sinaloa, Culiacán, Sinaloa, México. eden_bmseg@hotmail.com

1. INTRODUCCIÓN

El diseño de una estructura implica un proceso iterativo en el cual el ingeniero estructurista ofrece un diseño que se analiza y revisa con las normas establecidas por cierto código de construcción. Lo ideal sería que el primer diseño propuesto cumpliera con todas las regulaciones; sin embargo, en general el ingeniero estructurista tiene que proponer un nuevo diseño y someterlo al proceso de análisis y diseñarlo nuevamente hasta que éste cumpla con las especificaciones establecidas por el código. Este proceso puede llegar a ser lento. Una solución para reducir las iteraciones y el tiempo requerido para el proceso de diseño es mediante el entrenamiento de una red neuronal (la cual requiere cierta cantidad de diseños previamente elaborados) para poder proponer un nuevo diseño (que se basará en un entrenamiento previo). La aplicación de las redes neuronales es muy amplia y puede dar respuesta a problemas que tienen soluciones no lineales y complejas. En los últimos años las Redes Neuronales Artificiales (RNA) han sido utilizadas por un gran número de investigadores en ingeniería para la predicción del comportamiento, la confiabilidad, y la optimización de estructuras. Por ejemplo, Papadrakakis *et al.*, (1996, 2002) utilizan un modelo de red neuronal para la optimización basada en la confiabilidad de sistemas estructurales complejos; Hurtado y Álvarez (2002) aplican diferentes tipos de redes neuronales como dispositivos numéricos para la evaluación de la confiabilidad de sistemas estructurales; Cardoso *et al.*, (2007) utilizan una metodología para calcular la probabilidad de falla de una estructura mediante la combinación de RNAs y simulación de Montecarlo. Un estudio de confiabilidad sísmica utilizando datos experimentales y RNA fue propuesto por Jansen y Foschi (2004); por otro lado, Möller *et al.*, (2009) utilizan un modelo de RNA para optimizar el costo total estructural considerando la confiabilidad estructural asociada a diferentes estados límite; y Lautour y Omenzetter (2009) aplicaron una RNA para la predicción de daños estructurales inducidos por sismos. Serkan *et al.* (2015) propusieron un modelo para predecir la capacidad a la torsión del acero de refuerzo en vigas de concreto reforzado; y Chin-Sheng y I-Cheng (2014) desarrollaron un programa de cómputo que se utiliza para el diseño de marcos planos de concreto reforzado utilizando RNA.

En el presente trabajo se presenta la formulación de dos modelos de RNA para el pre-diseño de edificios compuestos a base de marcos de concreto reforzado. Para entrenar los modelos de RNA se utilizan dos bases de datos compuestas por 50 y por 40 diseños de edificios regulares con 8 a 12 niveles, y con 4 a 7 niveles, respectivamente. Los edificios se suponen ubicados en el valle de México (Zona IIIb) y se diseñan de acuerdo con las especificaciones del Reglamento de Construcciones para el Distrito Federal (RCDF, 2004). Se presenta un ejemplo de aplicación donde se comparan dos diseños obtenidos a través de RNA versus diseños similares realizados de manera convencional.

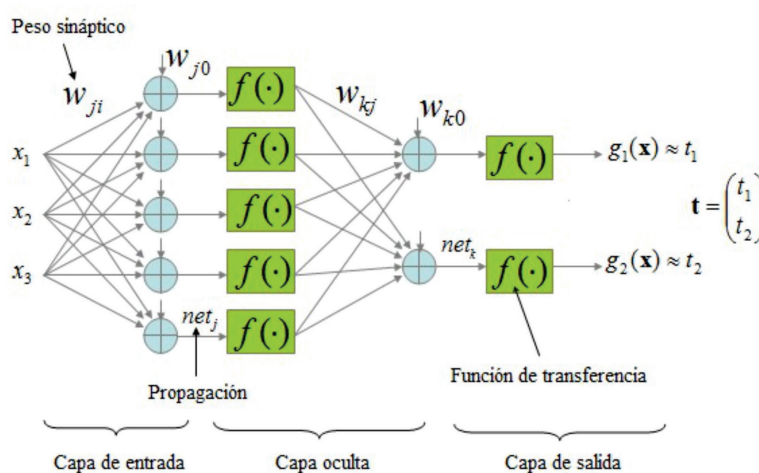


Fig. 1: Percepción multicapa con alimentación hacia adelante

2. CONCEPTOS GENERALES SOBRE REDES NEURONALES ARTIFICIALES

Una Red Neuronal Artificial (RNA) es un modelo matemático o modelo computacional inspirado por la estructura y aspectos funcionales de redes neuronales biológicas. Éstas están conformadas por un gran número de elementos de procesamiento altamente interconectados llamados neuronas, las cuales están conectadas a otras neuronas a través de una señal de peso (sinapsis), las entradas son las dendritas y el resultado es el axón. De manera similar, la RNA necesita un proceso de aprendizaje para establecer relaciones entre las variables que definen un fenómeno específico. El poder de procesamiento de una RNA se debe a su estructura distribuida en paralelo, y su capacidad de aprender de ejemplos que se presentan a la RNA para su entrenamiento. Cuando una red neuronal artificial se entrena correctamente puede generalizarse, lo que significa que la RNA aprendió el mapeo completo para la solución de un problema; es decir, la RNA será capaz de predecir una respuesta correcta para un caso que no fue utilizado para su entrenamiento.

Existen diversas topologías propuestas por diferentes autores para definir la estructura de la RNA (Specht, 1991). En este trabajo se utiliza el Feed-forward Perceptrón Multicapa (PM) (Shepherd, 1997) debido a que los problemas de ingeniería civil son del tipo exacto, es decir una entrada tiene una salida. Este tipo de red es suficiente para la mayoría de problemas de ingeniería, (Hegazy et al. 1994), la topología se configuró con una sola capa oculta comenzando con dos a seis neuronas para generar el menor error y evitar el exceso de entrenamiento. La arquitectura de la PM comienza con una capa de entrada que está conectada a una capa oculta; este puede ser conectado a otra capa oculta o directamente a la capa de salida. Debido a que el flujo de información es siempre desde la capa de entrada a la capa de salida, la salida de una capa es siempre la entrada de la siguiente capa, como se ilustra en la Figura 1.

2.1 ALGORITMO DE ENTRENAMIENTO, PROPAGACIÓN “HACIA ATRÁS”

En el contexto de las redes neuronales el aprendizaje puede ser visto como el proceso de ajuste de los parámetros libres de la red (Yao, 1995). Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. El proceso de aprendizaje es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación suficientemente bueno. La mayoría de los métodos de entrenamiento utilizados en las redes neuronales con alimentación hacia delante consisten en proponer una función de error que mida el rendimiento actual de la red en función de los pesos sinápticos. El objetivo del método de entrenamiento es encontrar el conjunto de pesos sinápticos que minimizan la función. El método de optimización proporciona una regla de actualización de los pesos que en función de los patrones de entrada modifica iterativamente los pesos hasta alcanzar el punto óptimo de la red neuronal. Existen diversos métodos para entrenar a una red neuronal artificial, como por ejemplo: Hebbiano, estocástico, evolutivo o Back-propagation. En el presente estudio se utiliza el algoritmo de propagación “hacia atrás” (“Back-propagation”, en inglés), propuesto por Rumelhart y McClelland (1986). Se trata de un algoritmo en el que la señal viaja en un solo sentido, y es comúnmente utilizado para el entrenamiento de RNAs con aplicación en ingeniería civil. El algoritmo consta de los siguientes pasos (ver Figura 1):

1. Se define un vector de entrada $[x_1, x_2, \dots, x_i]$ para i neuronas de la primera capa.
2. La información que llega a todas la neuronas de la segunda capa se calcula por medio de una regla de propagación, como sigue:

$$net_j = \sum_i w_{ji} x_i \quad (1)$$

3. Se aplica una función de transformación a la entrada total de cada neurona j de la segunda capa, $j = 1, 2, \dots, m$.

$$\tilde{y}_m = f_m(net_j) \quad (2)$$

donde el subíndice m representa la posibilidad de tener diferentes funciones de transformación para cada neurona.

4. Se calcula la entrada y salida de la tercera capa como sigue:

$$net_k = \sum_m w_{km} \tilde{y}_m \quad (3)$$

$$g(x) = f_n(net_k) \quad (4)$$

5. Se estima el error entre la salida de datos (t) y el estimado por la red ($g(x)$) como sigue:

$$d_n = g(x) - t \quad (5)$$

6. Se minimiza el error medio cuadrático (EMC) de la capa de salida (e) y se calcula como:

$$e = \frac{1}{2} \sum_{n=1}^N d_n^2 \quad (6)$$

7. $w_{ji}^{t+1} = w_{ji}^t + \Delta w_{ji}^t$ Se busca el mínimo de la función de error en la dirección negativa del gradiente. Los pesos de la capa oculta en el paso de aprendizaje $t+1$ se pueden calcular mediante la adición de un diferencial del gradiente negativo a los pesos calculados en el paso t . Esto se representa como sigue:

$$w_{ji}^{t+1} = w_{ji}^t + \Delta w_{ji}^t \quad (7)$$

Donde w es el vector de pesos, Δw_{ji} es la variación del peso en términos de la pendiente de la función de error. Después de aplicar esta técnica a la capa de salida se puede calcular la actualización de los pesos que conectan a las otras capas de forma similar.

8. El proceso se repite con nuevos pares de entrada y salida (x , t), hasta que el error es aceptable de acuerdo con la precisión requerida.

3. MODELO DE RED NEURONAL ARTIFICIAL

La arquitectura de un modelo de RNA se conforma principalmente de los siguientes parámetros: 1) de entrada, 2) de salida, 3) regla de propagación, y 4) regla de entrenamiento. En el presente estudio se consideran las dos redes neuronales con propagación “hacia atrás” y retroalimentación multicapa.

El vector de neuronas en la capa de entrada contiene las características generales del edificio (número de crujías y de niveles, espaciamento entre las crujías), y el vector de neuronas en la capa de salida contiene los parámetros de salida del diseño del edificio.

Aquí se considera una función de activación de tipo sigmoideal para la capa oculta y una función de tipo lineal para la capa de salida en ambos modelos. La importancia de la función sigmoideal radica en que toma valores de entrada que pueden estar entre más y menos infinito, y restringe la salida a valores entre cero y uno de tal forma que no importa las unidades de entrada ya que esta función las normaliza, su ecuación es como sigue:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

La función de transferencia lineal o identidad equivale a no aplicar una función de salida, ya que como su nombre lo indica, se trata de una línea recta y por ello no afecta la entrada neta de cada nodo. Las unidades de salida de la red quedan inalteradas y por lo tanto ya no es necesario convertirlas.

La primera red que aquí se formula (modelo 1) es para el diseño de edificios de 8 a 12 niveles con 3 a 5 crujías en dirección X, y con 3 a 5 en dirección Y. La segunda red (modelo 2) es para el diseño de edificios de 4 a 7 niveles con 3 a 5 crujías en dirección X, y con 3 a 5 crujías en dirección Y. Es necesario utilizar dos modelos de RNA porque el

número de salidas que tienen los edificios de 8 a 12 niveles es diferente al número de salidas que tienen los edificios de 4 a 7 niveles, es decir las secciones se agrupan y se distribuyen en la altura de los edificios, los edificios más altos tienen más secciones que los edificios pequeños. En la figura 2 se presenta un esquema general de la distribución de las secciones en la altura de los edificios.

3.1 PARÁMETROS DE ENTRADA

Los parámetros de entrada se refieren a las características estructurales que definen la forma del edificio a diseñar (ej. número de niveles, crujeas, etc.). De acuerdo con lo anterior, en este estudio se definen 5 neuronas para la capa de entrada. Estas son: 1) número de crujeas en la dirección X, 2) número de crujeas en la dirección Y, 3) número niveles, 4) espaciamiento entre la crujía en la dirección X, y 5) espaciamiento entre crujeas en la dirección Y. Estos parámetros se definen como B_x , B_y , SL , S_x y S_y , respectivamente (ver Figura 2).

En la Figura 2a y b muestran los parámetros de entrada para el modelo 1 de RNA que comprende el diseño de edificios de 8 a 12 niveles (modelo 1), y en la Figura 2a y c se muestran los parámetros de entrada para el modelo 2 de RNA (edificios de 4 a 7 niveles). Se hace notar que el parámetro SL (número de niveles) está seccionado tres veces en la figura 2 b (SL 1-4, SL 5-7 y SL 8-10), y dos veces en la figura 2c (SL 1-3 y SL 4-6), esto se debe a que se considera la misma geometría en vigas y columnas para esos niveles. En las tablas 1 y 2 se muestran los intervalos de los parámetros de entrada para la primera y para la segunda RNA, respectivamente.

Tabla 1: Parámetros de entrada para la primera RNA




Fig. 2a b y c: Parametros de entrada

Tabla 1: Parámetros de entrada para la primera RNA

Parámetro de entrada (Modelo 1)	Intervalo
Número de crujías en dirección X (Bx)	3 a 5
Número de crujías en dirección Y (By)	3 a 5
Niveles (SL)	8 a 12
Espaciamiento entre crujías en dirección X (Sx)	5 a 10 (m)
Espaciamiento entre crujías en dirección Y (Sy)	5 a 10 (m)

Tabla 2: Parámetros de entrada para la segunda RNA

Parámetro de entrada (Modelo 2)	Intervalo
Número de crujías en dirección X (Bx)	3 a 5
Número de crujías en dirección Y (By)	3 a 5
Niveles (SL)	4 a 7
Espaciamiento entre crujías en dirección X (Sx)	5 a 10 (m)
Espaciamiento entre crujías en dirección Y (Sy)	5 a 10 (m)

3.2 PARAMETROS DE SALIDA

Los parámetros de salida se refieren a la geometría de secciones (vigas y columnas), área de acero requerido a flexión y separación de estribos. En lo que sigue se definen los parámetros de salida.

3.2.1 VIGAS

En este estudio las vigas se definen por su geometría, acero longitudinal requerido a compresión y tensión en los extremos y al centro del elemento (ver Figura 3). Se consideran estribos con diámetro de 0.95 cm (3/8"). En la tabla 3 se muestran los parámetros considerados para las vigas.

3.2.2 COLUMNAS

Las columnas están definidas por cuatro parámetros: base, altura, acero de refuerzo longitudinal y separación de estribos. En la tabla 4 se muestran los parámetros de salida para las columnas.

En la Figura 4 se muestra un ejemplo del vector de entrada y de salida para: a) el modelo 1 que comprende edificios entre 8 y 12 niveles, y b) el modelo 2 que corresponde a edificios entre 4 y 7 niveles.


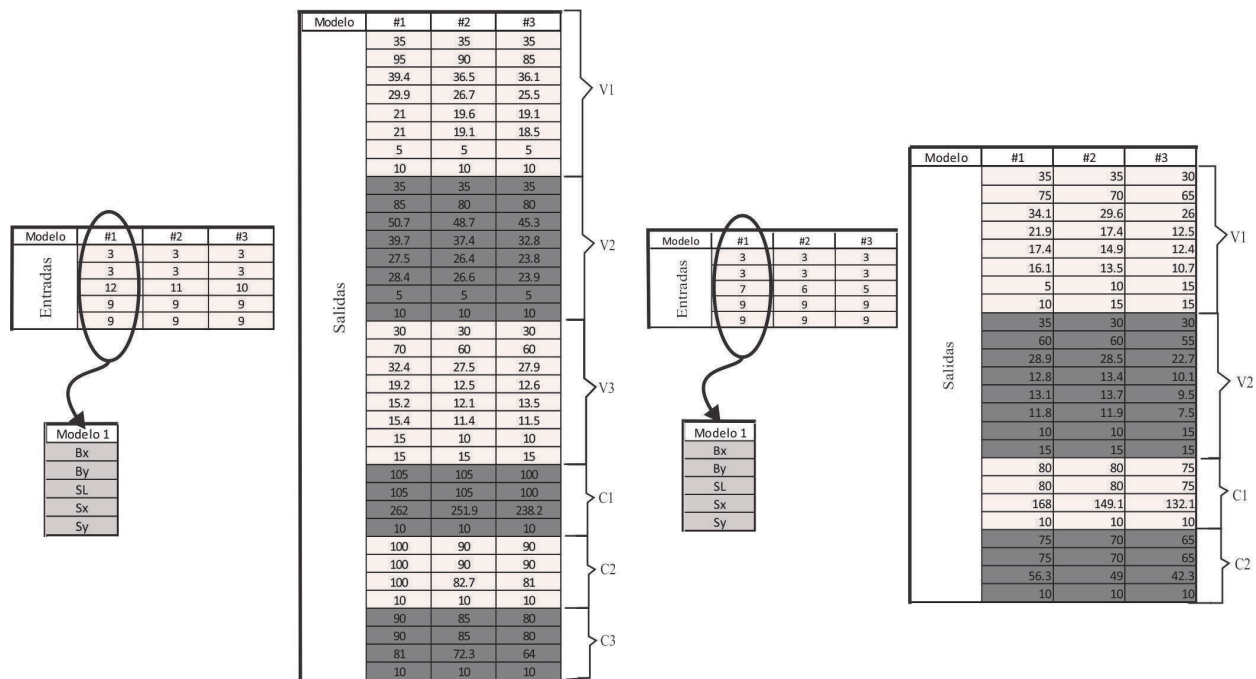


Fig. 3: Parámetros de salida en vigas

Tabla 3: Parámetros considerados en el diseño de vigas

Parámetro	Unidades
b : Base	(cm)
h : Altura	(cm)
As_e : Área de acero longitudinal a compresión en el extremo del elemento	(cm ²)
As'_e : Área de acero longitudinal a tensión en el extremo del elemento	(cm ²)
As_c : Área de acero longitudinal a compresión en el centro del elemento	(cm ²)
As'_c : Área de acero longitudinal a tensión en el centro del elemento	(cm ²)
se : Separación de estribos en el extremo del elemento	(cm)
sc : Separación de estribos en el centro del elemento	(cm)



a) Primera red (8-12 niveles)

b) Segunda red (4-7 niveles)

Fig. 4: Vectores de entrada y de salida

4. CARACTERÍSTICAS DE LOS EDIFICIOS

Se diseñaron 90 edificios de concreto reforzado de los cuales 50 diseños corresponden a edificios de 8 a 12 niveles, y 40 a edificios de 4 a 7 niveles. Los diseños se realizaron de acuerdo con los requerimientos del Reglamento de Construcciones del Distrito Federal (RCDF, 2004) y a sus Normas Técnicas Complementarias (NTC, 2004). En los diseños se revisaron los estados límites de colapso y de servicio, así como lo establecido en el Apéndice A del RCDF-2004. Se consideran ubicados en la zona IIIB del valle de México. Los edificios se diseñaron considerando $f'c = 2500 \text{ ton/m}^2$, un factor de comportamiento sísmico $Q=3$, y su uso es para oficinas. No se consideraron los efectos de interacción suelo-estructura.

5. ARQUITECTURAS Y FASE DE ENTRENAMIENTO

El entrenamiento de la red se llevó a cabo de la siguiente manera: 1) se genera de forma aleatoria la arquitectura de RNA (número de neuronas, capas, funciones de entrenamiento y pesos sinápticos), 2) se presentan a la RNA los pares de entrenamientos de entradas y salidas (con base en información de edificios previamente diseñados), 3) los resultados obtenidos por la RNA se comparan con los resultados “reales” y se estima el error medio cuadrático (EMC), 4) se propone una nueva arquitectura de la RNA (número de neuronas, capas, funciones de entrenamiento y pesos sinápticos utilizando el algoritmo “Back-propagation”), y 5) finalmente se prueban todas las arquitecturas de la RNA para ver cuál de ellas da lugar a un menor porcentaje de error. En este estudio se probaron diferentes arquitecturas con la finalidad de encontrar el mejor modelo de RNA, para ello se utilizó el programa Matlab 2014. El formato para los arreglos de cada arquitectura se muestran en la tabla 5 y se describen con la forma: $I \times H_1 \times H_2 \times \dots \times H_i \times O$, donde I representa el número de neuronas en la capa de entrada; H_i representa el número de neuronas en la i -ésima capa oculta; O el número de neuronas en la capa de salida. Se entrenó un total de 55 arquitecturas de RNA con diferente número de neuronas en la capa oculta. En la tabla 5 se muestran algunos de los modelos que se utilizaron. La tabla 5 también muestra el error medio cuadrático (EMC, ver ecuación 6) correspondiente a cada arquitectura.

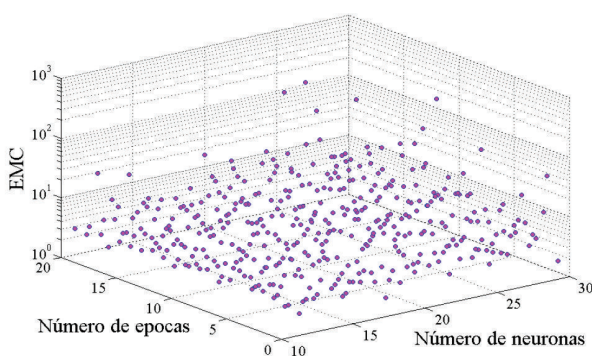
Tabla 5: Arquitecturas propuestas

8-12 niveles		4-7 niveles	
Arquitectura	EMC	Arquitectura	EMC
5x15x36	2.29	5x13x24	2.33
5x18x36	2.42	6x16x24	2.14
5x20x36	2.17	6x21x24	1.99
5x22x36	2.79	6x25x24	2.45
5x28x36	2.13	6x30x24	1.87


En la tabla 5 se puede observar que algunos modelos resultan con un mayor error medio cuadrático (EMC) en la fase de entrenamiento en comparación con modelos con menos neuronas en la capa oculta; sin embargo, estos modelos generaron un error total mayor en la fase de prueba. Una de las consideraciones más importantes para la elección de la mejor red fue el rendimiento, es decir, el número de épocas o iteraciones en donde se encuentra el menor EMC. En la Figura 5 se muestran los resultados obtenidos con diferentes arquitecturas (número de neuronas en la capa oculta), cada una de las arquitecturas fue entrenada 20 veces (épocas), en el eje vertical se muestra el EMC y en los horizontales el número de épocas y de neuronas en la capa oculta, respectivamente. Para el modelo 1 se encontró el mínimo error medio cuadrático en 13 épocas, y para el modelo 2 en 7 épocas (ver Figura 5). La arquitectura final para el modelo 1 corresponde al 5:21:26, es decir, 5 entradas, 21 neuronas en la capa oculta y 36 neuronas en la capa de salida, con función de transferencia tansig en la capa oculta, y función de transferencia identidad en la capa de salida. Para el modelo 2 la arquitectura final de la RNA es 5:25:24, considerando las mismas funciones de transferencia en la capa oculta y salida, respectivamente.

6. VALIDACIÓN DE LOS MODELOS DE RNA

En lo que sigue se diseñan dos edificios de concreto reforzado con las RNA propuestas. Se hace la aclaración que los edificios por diseñar no fueron utilizados en la RNA en la fase de entrenamiento. El primer edificio (correspondiente al modelo 1) tiene 10 niveles con 4 crujías en dirección X, y 4 crujías en dirección Y. El espaciamiento de las crujías en ambas direcciones es de 7.5 m, los edificios poseen un altura de entrepiso de 4 m. De acuerdo a lo anterior, el vector de entrada para el modelo 1 es [4 4 10 7.5 7.5], y el vector de entrada para el segundo edificio por diseñar (correspondiente al modelo 2) es [4 3 6 6.5 7.5]. Los resultados del diseño obtenido a partir de los modelos de RNA para los dos modelos se muestran en las tablas 6 y 7.



a) Modelo 1 (8-12 niveles)



b) Modelo 2 (4-7 niveles)

Fig. 5: Variación del EMC con el número de neuronas y de épocas

Tabla 6: Resultados de la RNA para el modelo 1

Elemento viga								
Nivel	Parámetro	Valor	Nivel	Parámetro	Valor	Nivel	Parámetro	Valor
1-4	b (cm)	29.8	5-7	b (cm)	29.7	8-10	b (cm)	30.3
	h (cm)	75.3		h (cm)	66.5		h (cm)	54.8
	As_e (cm ²)	32.3		As_e (cm ²)	33.8		As_e (cm ²)	21.8
	As'_e (cm ²)	26.2		As'_e (cm ²)	26		As'_e (cm ²)	12.1
	As_c (cm ²)	7.81		As_c (cm ²)	7.75		As_c (cm ²)	3.95
	As'_c (cm ²)	10.3		As'_c (cm ²)	10.1		As'_c (cm ²)	6.55
	se (cm)	4.9		se (cm)	4.73		se (cm)	9.81
	sc (cm)	9.97		sc (cm)	9.92		sc (cm)	14.7
Elemento columna								
Nivel	Parámetro	Valor	Nivel	Parámetro	Valor	Nivel	Parámetro	Valor
1-4	L_x (cm)	81.3	5-7	L_x (cm)	75.7	8-10	L_x (cm)	69.5
	L_y (cm)	79.7		L_y (cm)	75.7		L_y (cm)	69.5
	As_{col} (cm ²)	173		As_{col} (cm ²)	58	As_{col} (cm ²)	48	
	s_{col} (cm)	10		s_{col} (cm)	10	s_{col} (cm)	10	

Con la finalidad de validar los dos diseños que resultaron de los modelos 1 y 2 de RNA, se realizó el análisis y diseño de los mismos edificios con el programa de computo ECOgcw (2014). En la tabla 8 se comparan dos diseños (obtenidos con ECO y con RNA) y se menciona el porcentaje de error entre ambos.

Tabla 8: Comparativa entre los diseños obtenidos con la RNA y ECO

Modelo 1					Modelo 2				
Nivel		ECO	RNA	Error (%)	Nivel		ECO	RNA	Error (%)
1-4 viga	b (cm)	30	29.7	0.9	1-3 viga	b (cm)	25	27.7	-10.8
	h (cm)	75	75.1	-0.1		h (cm)	55	53.0	3.6
	As_e (cm ²)	32.7	32.3	1.4		As_e (cm ²)	15.8	17.7	-12.2
	As'_e (cm ²)	26.7	26.2	1.9		As'_e (cm ²)	7.2	7.1	2.1
	As_c (cm ²)	7.7	7.8	-1.4		As_c (cm ²)	7.3	8.0	-10.1
	As'_c (cm ²)	10.2	10.3	-1.2		As'_c (cm ²)	6.5	7.4	-13.8
	se (cm)	5	4.9	2.2		se (cm)	10	11.5	-14.7
	sc (cm)	10	10.0	0.3		sc (cm)	20	18.7	6.5
5-8 viga	b (cm)	30	29.7	1.0	4-6 viga	b (cm)	25	26.9	-7.7
	h (cm)	65	66.5	-2.3		h (cm)	45	43.1	4.2
	As_e (cm ²)	34	33.8	0.7		As_e (cm ²)	16.8	18.9	-12.4
	As'_e (cm ²)	27.4	26.0	5.0		As'_e (cm ²)	7.7	7.6	1.8
	As_c (cm ²)	7.9	7.8	1.9		As_c (cm ²)	6.8	6.9	-1.2
	As'_c (cm ²)	10.5	10.1	4.3		As'_c (cm ²)	5	5.5	-10.6
	se (cm)	5	4.7	5.4		se (cm)	10	11.0	-9.7
	sc (cm)	10	9.9	0.8		sc (cm)	20	17.8	11.1
7-10 viga	b (cm)	30	30.3	-1.1	1-3 col	L_x (cm)	55	58.8	-6.9
	h (cm)	55	54.8	0.4		L_y (cm)	70	78.7	-12.5
	As_e (cm ²)	22	21.8	0.8		As_{col} (cm ²)	71.6	81.0	-13.2
	As'_e (cm ²)	12	12.1	-0.9		s_{col} (cm)	10	10.0	0.0
	As_c (cm ²)	4.7	4.0	15.1	4-6 col	L_x (cm)	45	47.6	-5.8
	As'_c (cm ²)	6.7	6.6	2.2		L_y (cm)	60	68.5	-14.2
	se (cm)	10	9.8	1.9		As_{col} (cm ²)	33	29.3	11.2
	sc (cm)	15	14.7	2.3		s_{col} (cm)	15	15.1	-0.5
1-4 col	L_x (cm)	80	81.3	-1.6					
	L_y (cm)	80	79.7	0.3					
	As_{col} (cm ²)	173.1	173.1	0.0					
	s_{col} (cm)	10	10.0	0.0					
5-7 col	L_x (cm)	75	75.7	-0.9					
	L_y (cm)	75	75.7	-0.9					
	As_{col} (cm ²)	57.6	58.0	-0.7					
	s_{col} (cm)	10	10.0	0.0					
8-10 col	L_x (cm)	70	69.5	0.7					
	L_y (cm)	70	69.5	0.8					
	As_{col} (cm ²)	49	48.0	2.1					
	s_{col} (cm)	10	10.0	0.0					

Tabla 7: Resultados de la RNA para el modelo 2

Elemento viga					
Nivel	Parámetro	Valor	Nivel	Parámetro	Valor
1-3	$b\text{ (cm)}$	27.7	4-6	$b\text{ (cm)}$	26.9
	$h\text{ (cm)}$	53		$h\text{ (cm)}$	43.4
	$As_e\text{ (cm}^2\text{)}$	17.7		$As_e\text{ (cm}^2\text{)}$	18.9
	$As'_e\text{ (cm}^2\text{)}$	10.1		$As'_e\text{ (cm}^2\text{)}$	7.56
	$As_c\text{ (cm}^2\text{)}$	8.04		$As_c\text{ (cm}^2\text{)}$	6.88
	$As'_c\text{ (cm}^2\text{)}$	7.40		$As'_c\text{ (cm}^2\text{)}$	6.53
	$se\text{ (cm)}$	11.5		$se\text{ (cm)}$	11
	$sc\text{ (cm)}$	18.7		$sc\text{ (cm)}$	17.7
Elemento columna					
Nivel	Parámetro	Valor	Nivel	Parámetro	Valor
1-3	$L_x\text{ (cm)}$	58.8	4-6	$L_x\text{ (cm)}$	54.6
	$L_y\text{ (cm)}$	78.7		$L_y\text{ (cm)}$	68.5
	$As_{col}\text{ (cm}^2\text{)}$	8.1		$As_{col}\text{ (cm}^2\text{)}$	27.5
	$s_{col}\text{ (cm)}$	10.0		$s_{col}\text{ (cm)}$	9.07

En la tabla 8 se puede observar que la máxima diferencia entre los valores correspondientes al diseño obtenido mediante RNA y el que arroja el programa ECOgcw a nivel de elementos estructurales es de 15 %, y se presenta en el modelo 1. Dado que los porcentajes de error son pequeños, se aceptan los modelos de RNA propuestos.

El presente estudio se sintetiza en programas de cómputo que pueden ser utilizados por cualquier persona que necesite diseñar o pre-dimensionar edificios de concreto reforzado a base de marcos, ubicados en la zona IIIb del valle de México. El Manual del Usuario se presenta en el apéndice A, y el link de descarga del programa es: <http://www.mediafire.com/download/9jyd7d516oh8zjs/RNA.mat>

7. CONCLUSIONES

Se presenta el uso de las redes Neuronales Artificiales (RNA) como herramienta para el diseño sísmico preliminar de estructuras de concreto reforzado formadas a base de marcos. La RNA predice las dimensiones geométricas, el acero de refuerzo longitudinal en los extremos y en el centro así como la separación de estribos en vigas y columnas.

El uso de redes neuronales como las que aquí se presentan son útiles para diseños de edificios que presentan regularidad en su construcción, como por ejemplo escuelas, conjuntos de departamentos habitacionales, etc.

Como ejemplo de aplicación se hizo el diseño de dos edificios de concreto reforzado correspondientes a cada uno de los dos modelos de RNA propuestos. Se encontraron diferencias máximas del orden de 15 % entre el modelo de RNA y ECO a nivel de elemento estructural.

La ventaja que ofrece el uso de RNA es la rapidez para la predicción del diseño estructural, ya que una vez que es entrenada, solo necesita unos cuantos segundos para arrojar resultados, mientras que en diseño convencional el proceso es iterativo y toma más tiempo.

Los modelos de RNA propuestos en este estudio son aplicables para el diseño de edificios de 4 a 12 niveles ubicados en una zona específica (zona IIIb del valle de México); sin embargo, usando la misma metodología es posible proponer distintos RNA que consideren edificios con más niveles y/u otra estructuración, ubicados en distintas zonas sísmicas.

AGRADECIMIENTOS

El primer autor agradece la beca recibida por el Consejo Nacional de Ciencia y Tecnología. Este estudio se realizó con apoyo de la DGAPA-UNAM dentro del proyecto PAPIIT-IN102114.

REFERENCIAS

- Cardoso, J. B., Almeida, J. R., Dias J. M., Coelho, P. G. (2007), "Structural Reliability Analysis Using Monte Carlo Simulation and Neural Networks", *Advances in Engineering Software*, Vol. 39, No. 6, pp. 505-513.
- Chin-Sheng, K., I-Cheng, Y. (2014), "Optimal Design of Plane Frame Structures Using Artificial Neural Networks and Ratio Variables", *Structural Engineering and Mechanics*, Vol. 52, No. 4, pp. 739-753.
- Gaceta Oficial del Distrito Federal (2004), "Normas Técnicas Complementarias para Diseño por Sismo", México, DF.
- Hurtado J. E., Alvarez, D. A. (2002), "Neural Network-Based Reliability Analysis: a Comparative Study", *Computer Methods in Applied Mechanics and Engineering*, Vol. 191, pp. 113-132.
- Hegazy, T., Fazio, P., Moselhi, O. (1994), "Developing Practical Neural Network Applications Using Backpropagation", *Microcomputers in Civil Engineering*, Vol. 9, No. 2, pp. 145-159.
- Jiansen, Z., Foschi, R. O. (2004), "Performance-Based Design and Seismic Reliability Analysis Using Designed Experiments and Neural Networks", *Probabilistic Engineering Mechanics*, Vol. 19, No.3, pp. 259-267.
- Lautour, O. R., Omenzetter, P. (2009), "Prediction of Seismic-Induced Structural Damage Using Artificial Neural Networks", *Engineering Structures*, Vol. 31, No. 2, pp. 600-606.
- Möller, O., Foschi, R. O., Quiroz, L. M., Rubinstein, M. (2009), "Structural Optimization for Performance-Based Design in Earthquake Engineering: Applications of Neural Networks", *Structural Safety*, Vol. 31, No. 6, pp. 490-499.
- Papadrakakis, M., Papadopoulos, V., Lagaros, D. L. (1996), "Structural Reliability Analysis of Elastic-Plastic Structures Using Neural Networks and Monte Carlo simulation", *Computer Methods in Applied Mechanics and Engineering*, Vol. 136, pp. 145-163.
- Papadrakakis, M., Lagaros D. L. (2002), "Reliability-Based Structural Optimization Using Neural Networks and Monte Carlo simulation", *Computer Methods in Applied Mechanics and Engineering*, Vol. 191, pp. 3451-3507.
- Reglamento de Construcciones para el Distrito Federal, Diario Oficial de la Federación (2004), México, DF.
- Rumelhart, D. E., McClelland, J. L. (1986), "Parallel Distributed Processing. Vol 1: foundations", MIT Press.
- Serkan, E., Onur, O., Fuad, O. (2015), "Estimation of ultimate torque capacity of the SFRC Beams Using ANN", *Structural Engineering and Mechanics*, Vol. 53, No. 5, pp. 939-956.
- Shepherd, G. M. (1997), "The Synaptic Organization of the Brain", 4a edición, Oxford University Press.
- Specht, D. (1991), "A General Regression Neural Network", *IEEE Transactions on Neural Networks*, Vol. 2, No. 6, pp. 568-576.
- Yao, X. (1995), "Evolutionary Artificial Neural Networks", *Encyclopedia of Computer Science and Technology*, Vol 33, pp. 137-170.

APÉNDICE A

En lo que sigue se ilustra paso a paso el uso de la Red Neuronal Artificial (RNA) propuesta para el diseño de edificios de concreto reforzado ubicados en la zona IIIb de la Ciudad de México. El archivo que contiene el modelo 1 y modelo 2 de la RNA que se propuso en el artículo “DISEÑO SÍSMICO DE EDIFICIOS DE C/R USANDO REDES NEURONALES ARTIFICIALES” se llama RNA.mat. Para poder abrir el archivo RNA.mat es necesario tener previamente instalado el programa de cómputo Matlab 2014.

1. DESCARGAR EL ARCHIVO

La descarga del archivo “RNA.mat” se realiza mediante el siguiente enlace:

<http://www.mediafire.com/download/9jyd7d5l6oh8zjs/RNA.mat>

El enlace se puede descargar con los buscadores Chrome, Mozilla, Safari, Explorer. Al presionar las teclas CTRL + clic, el link nos dirigirá a la siguiente página (ver figura A1):

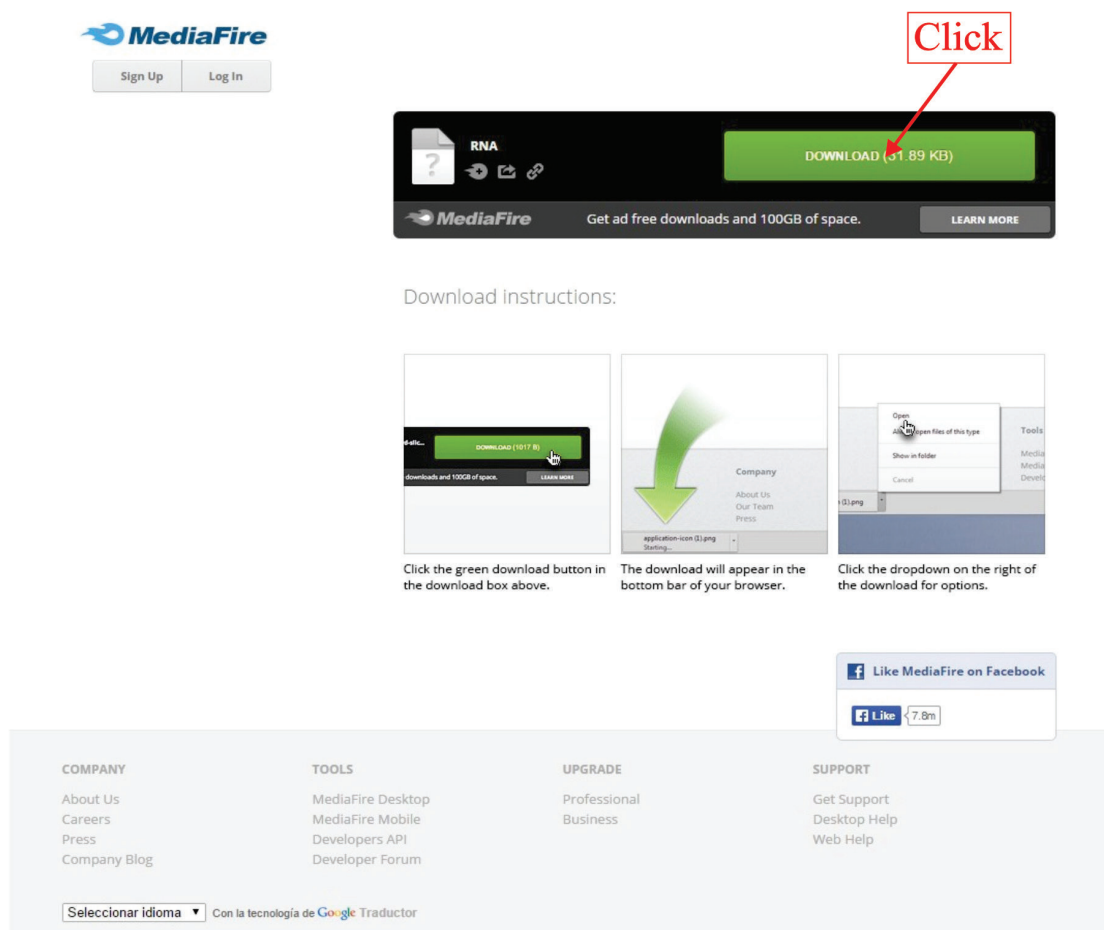


Fig. A1: Enlace de descarga

Para descargar el archivo se debe dar clic en el recuadro verde que lleva la leyenda DOWNLOAD (31.89 KB). A continuación se descargará el archivo a su computadora.

2. ARCHIVO RNA.MAT

Una vez descargado el archivo RNA.mat y previamente instalado el programa Matlab 2014, el archivo automáticamente será reconocido.

Al dar doble click en el archivo RNA.mat, el programa Matlab abre su contenido como se muestra en la figura A2:

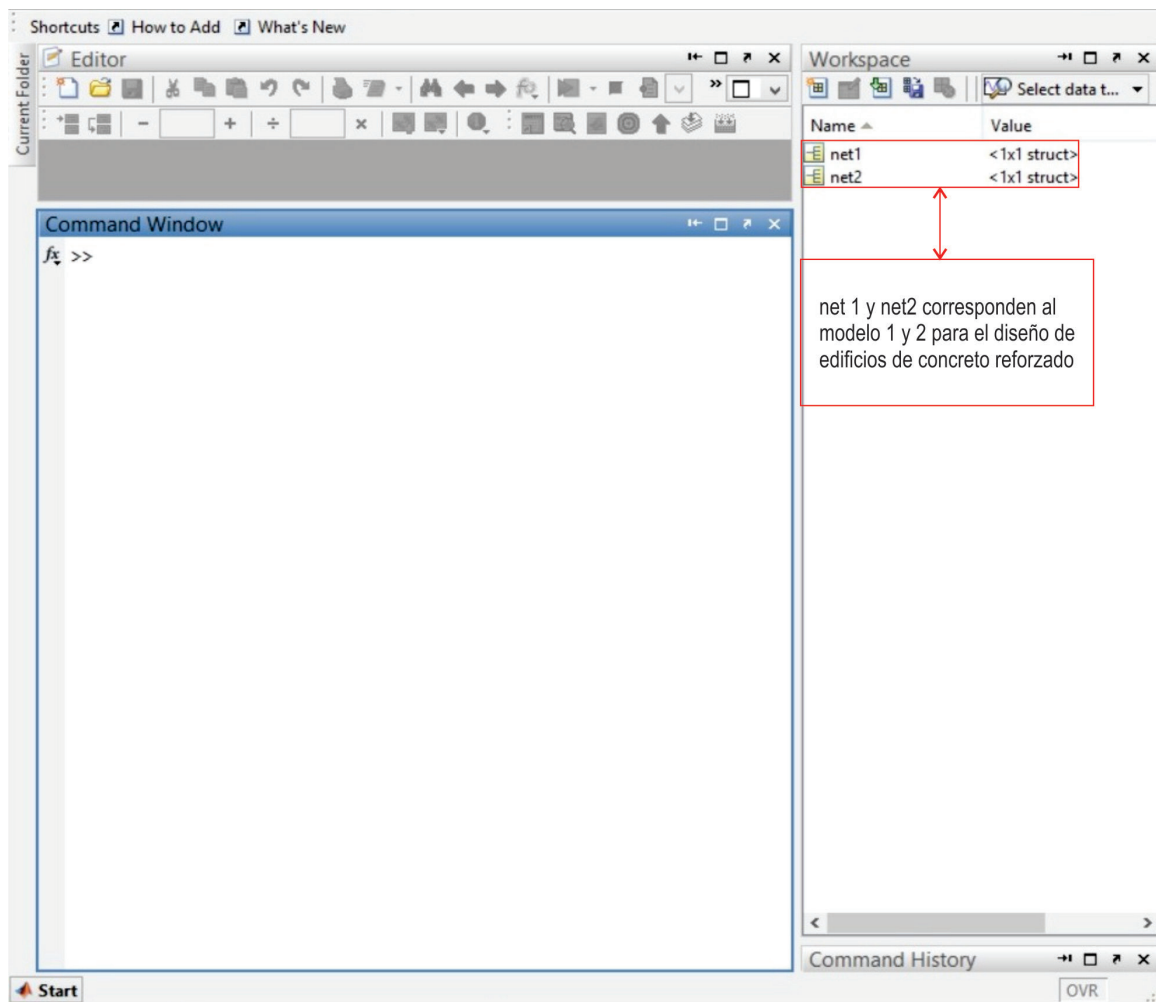


Fig. A2: Archivos net 1 y net 2

Una vez que se abre el archivo RNA.mat, se cargan en el Workspace de Matlab los archivos net1 y net2, que corresponden a la RNA del modelo 1 y modelo 2, respectivamente. En la tabla 1 se muestran los parámetros de entrada de cada modelo.

Tabla A1: Parámetros de entrada para la primera RNA

Parámetro de entrada (Modelo 1)	Intervalo
Número de crujías en dirección X (Bx)	3 a 5
Número de crujías en dirección Y (By)	3 a 5
Niveles (SL)	8 a 12
Espaciamiento entre crujías en dirección X (Sx)	5 a 10 (m)
Espaciamiento entre crujías en dirección Y (Sy)	5 a 10 (m)

Tabla A2: Parámetros de entrada para la segunda RNA

Parámetro de entrada (Modelo 2)	Intervalo
Número de crujías en dirección X (Bx)	3 a 5
Número de crujías en dirección Y (By)	3 a 5
Niveles (SL)	4 a 7
Espaciamiento entre crujías en dirección X (Sx)	5 a 10 (m)
Espaciamiento entre crujías en dirección Y (Sy)	5 a 10 (m)

3. DISEÑO DE EDIFICIOS DE C/R UTILIZANDO RNA.MAT

Para el diseño de un edificio de concreto reforzado es necesario crear un vector con la información de número de crujías en dirección X, número de crujías en Y, número de niveles, longitud de crujía en dirección X y longitud de crujía en dirección Y. De acuerdo con lo anterior, se creará un vector 1x5 en el Command Window del programa Matlab.

Ejemplo: Si se desea diseñar un edificio de 3 crujías en X, 3 crujías en Y, 7 niveles, 9 metros de longitud de crujía en X, y 9 metros de longitud de crujía en Y, el vector que se crea con las características del a estructura es como sigue: $P=[3;3;7;9;9]$ (ver Figura A3).

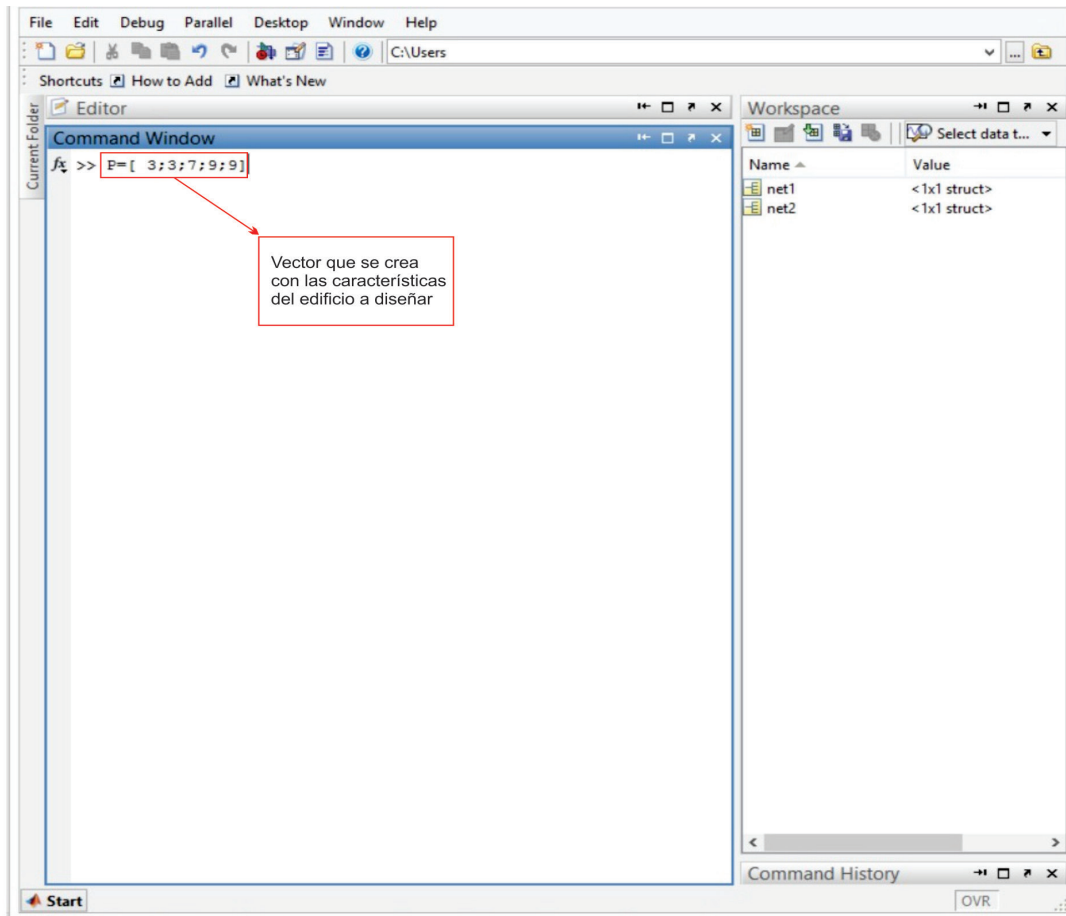


Fig. A3: Ejemplo de entrada

Para ejecutar el programa se introduce en el command window, “`sim(net1,P)`” ó `sim(net2,P)` según el modelo que se desee diseñar. Dando un click a la tecla enter se obtienen los resultados en el vector `ans` como se observa en la Figura A4.



Fig. A4: Simulación de la RNA

4. RESULTADOS

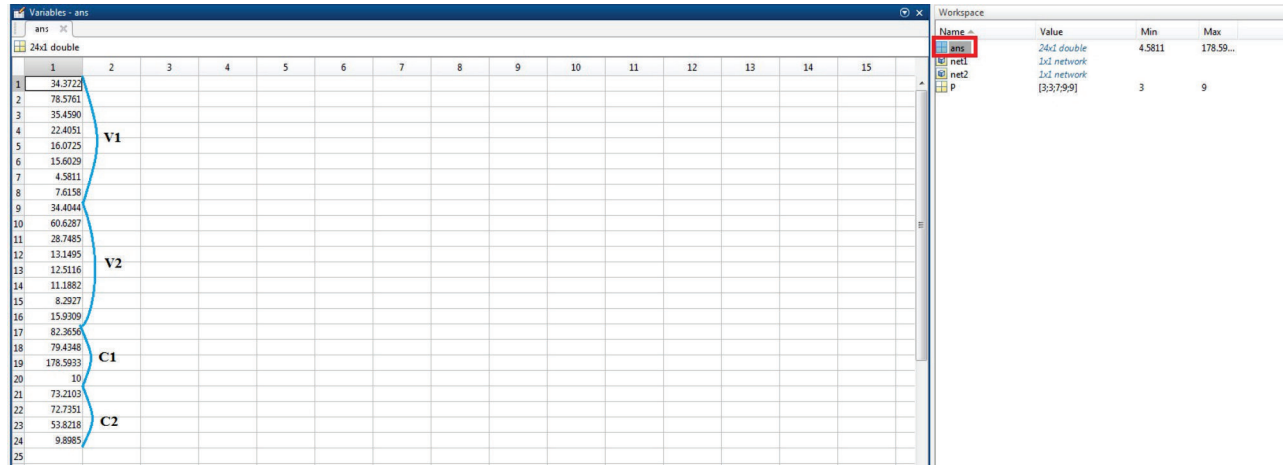


Fig. A5: Resultados de la RNA

El resultado de la RNA se almacena en la variable `ans`, las vigas y columnas se distribuyen según la gráfica, es decir V1, V2, C1 y C2 y distribuidas según lo descrito en el artículo (ver Figura A5).

Para cualquier duda o aclaración comunicarse al correo, JBojorquezM@iingen.unam.mx