

ESTIMACIÓN DEL ÍNDICE DE TENACIDAD FLEXURAL I_5 EN CONCRETOS FIBRO-REFORZADOS, USANDO REDES NEURONALES ARTIFICIALES

Luis Octavio González-Salcedo ^{1*}, Aydee Patricia Guerrero Zúñiga ², Silvio Delvasto Arjona ²,
Adrián Luis Ernesto Will ³

1: PhD (Candidato), Universidad Nacional de Colombia Sede Palmira. Palmira, Colombia

2: PhD, Universidad del Valle. Cali, Colombia

3: PhD, Universidad Nacional de Tucumán & Centro de Investigación de Tecnologías Avanzadas de Tucumán. San Miguel de Tucumán, Argentina

* Contacto: logonzalezsa@unal.edu.co

RESUMEN

El concreto es un material frágil, cuya característica es contrarrestada con la inclusión de un volumen de fibras, determinado experimentalmente, como refuerzo de la matriz cementicia. Adicional a la resistencia a la compresión, en los concretos fibrorreforzados otras especificaciones son consideradas como la ganancia en la resistencia a la flexión y en la tenacidad. La capacidad del concreto, en estado agrietado, de seguir soportando cargas es conocida como tenacidad. La curva fuerza – deflexión en el ensayo a flexión realizado sobre probetas estandarizadas a edades de 28 días de realizada la mezcla, muestran un extensión de la curva más allá de la aparición de la primera grieta, y ofreciendo un comportamiento similar a la ductilidad. La tenacidad es medida como el área bajo la curva mencionada, existen diversos métodos de medición siendo uno de ellos la determinación a partir de relaciones de índices de tenacidad flexural, y en la mayoría de los concretos se usa como especificación el índice I_5 . La dificultad de involucrar características cualitativas de los materiales, sus altas relaciones y dependencias no lineales, y de obtener un modelo matemático convencional para la tenacidad flexural, conlleva esta predicción al campo de la Inteligencia Artificial. En el presente trabajo, una red neuronal artificial (RNA) para predecir el índice de tenacidad flexural I_5 en concretos reforzados con fibras de acero se realizó. Los resultados de desempeño de la RNA muestran que la predicción es confiable y abre una agenda futura para la investigación.

Palabras Claves: *Materiales compuestos, Concretos reforzados con fibras, Tenacidad flexural, Redes neuronales artificiales, Modelación.*

ABSTRACT

Concrete is a brittle material whose characteristic is counteracted by the inclusion of an experimentally-determined-fiber-volume as reinforcement of cement matrix. In addition to the compressive strength in the fiber reinforced concrete other specifications are considered as the gain in the flexural strength and toughness. The ability of cracked-state-concrete to continue supporting loads is known as toughness. The load-deflection graphic relationship in bending test conducted on standardized specimens aged 28 days after of mixing, show an extension of the curve beyond the occurrence of the first crack, and offers a similar behavior to the ductility. Toughness is measured as the area under the curve above, there are various methods of measuring one of them from determining relationships flexural toughness index, and most

concrete is used as the index specification I_5 . The difficulty of involving qualitative characteristics of the materials, their high non-linear relationships and dependencies, and to obtain a conventional mathematical model for flexural toughness, this prediction leads to the field of Artificial Intelligence. In this paper, an artificial neural network (ANN) to predict the I_5 flexural-toughness-index in steel-fiber-reinforced-concrete was performed. The performance results show that the predicted ANN is reliable and opens a future agenda for research.

Keywords: *Composites, Fiber reinforced concrete, Flexural toughness, Artificial neural networks, Modeling*

1 INTRODUCCIÓN

El concreto es un material estructural por excelencia, elaborado a partir de cemento portland, agua, agregados, adiciones minerales y aditivos químicos [1]. El concreto es conocido como un material frágil y esta característica es reducida mediante la incorporación de fibras como refuerzo de la matriz cementicia [2]. La resistencia a la compresión es la principal propiedad mecánica requerida como especificación, y en concretos fibrorreforzados otras propiedades son deseadas como la ganancia en la resistencia a la tensión y a la flexión, en la ductilidad y la tenacidad, y en el control del agrietamiento y de la abrasión [3]. La curva fuerza – deflexión en el ensayo a flexión muestra una extensión más allá de la aparición de la primera grieta, con un comportamiento similar a la ductilidad de los materiales, soportando carga aún en el estado agrietado [4]. Esta capacidad es denominada tenacidad flexural la cual se calcula como el área bajo la curva mencionada, y existen diversos métodos de medición siendo uno de ellos la determinación a partir de relaciones de índices de tenacidad flexural [4], como se muestra en la figura 1.




Figura 1. Determinación gráfica de los índices de tenacidad a partir de la curva fuerza de flexión – deflexión sobre vigas de concreto reforzado con fibras. El índice I_5 corresponde a la relación de las áreas OACD/OAB [4].

Los ensayos para las propiedades mecánicas están estandarizados y sus resultados son obtenidos a los 28 días de realizadas las mezclas; de igual manera, la optimización de la cantidad de fibra es obtenida de manera experimental [5]. La necesidad de conocer con antelación sus propiedades mecánicas y determinar mediante otra vía la cantidad óptima de fibra, promueven el desarrollo de

modelos matemáticos. Sin embargo, la dificultad de involucrar características cualitativas de los materiales, sus altas relaciones y dependencias no lineales [6], y de obtener un modelo matemático convencional para la tenacidad flexural, conlleva esta predicción al campo de la Inteligencia Artificial, siendo una de sus técnicas las redes neuronales artificiales (RNA), las cuales son similares de los modelos neuronales biológicos [7].

En este artículo, el desarrollo de una RNA para predecir el índice de tenacidad flexural I_5 de concretos reforzados con fibras de acero se presenta. A partir de 77 resultados experimentales en ensayos estandarizados a la flexión sobre vigas [4], para mezclas de concreto reportadas en la Literatura [8], se conformó un conjunto de entrenamiento de la RNA. Los parámetros de entrada corresponden a las cantidades y características del cemento, adiciones minerales, agua, agregados, aditivos químicos, y de la fibra de refuerzo, mientras que el parámetro de salida es el índice de tenacidad flexural I_5 , obtenido gráficamente como se muestra en la figura 1 de acuerdo con el procedimiento establecido por la ASTM C1018 [9]. Un conjunto de programas escritos en lenguaje de programación MATLAB® & Simulink® para ambiente Windows® [10] se elaboró para la sistematización de la RNA usando el procedimiento establecido en la Neural Network Toolbox del mismo lenguaje [11]. La arquitectura de la RNA corresponde a una tipología de red multicapa, como se muestra en la figura 2, cuyo algoritmo de aprendizaje es de alimentación hacia adelante de la información y de propagación hacia atrás para la corrección y ajuste del error de estimación [8]. El algoritmo de entrenamiento es el gradiente escalonado [12] y como indicador de desempeño se usó el error medio cuadrático [13] calculado a partir de la ecuación 1. Para los resultados de estimación del I_5 por parte de la RNA, se usó como indicador de desempeño el factor de correlación R [13] calculado con la ecuación 2. La función de transferencia para las capas correspondió a una función sigmoide calculada con la ecuación 3 [14].




Figura 2. Arquitectura de la RNA usada para estimar el índice de tenacidad flexural I_5 [8].

$$MSE = \sum_{t=1}^T \left(\frac{Y_t - O_t}{T} \right)^2 \quad (1)$$

$$R^2 = 1 - \frac{\sum_{t=1}^T (Y_t - O_t)^2}{\sum_{t=1}^T (Y_t - \bar{O}_t)^2} \rightarrow R = \sqrt{1 - \frac{\sum_{t=1}^T (Y_t - O_t)^2}{\sum_{t=1}^T (Y_t - \bar{O}_t)^2}} \quad (2)$$

Donde, Y_t es la salida deseada, O_t es la salida obtenida, \bar{O}_t es el promedio de las salidas obtenidas y T es el número de registros tomados en cada fase (aprendizaje y validación), y en la simulación con el total de la base de datos.

$$f(Z) = \frac{1}{1+e^{-Z}} \quad (3)$$

Siendo Z la expresión contenida dentro del paréntesis de la ecuación 4:

$$Y_{N \times 1} = f(W_{N \times M} X_{M,1} + b_{N,1}) \quad (4)$$

Donde, Y es un vector que contiene la salida desde cada una de las N neuronas en una capa dada, W es la matriz que contiene los pesos sinápticos (peso, relevancia o importancia) para cada una de las M salidas para todas las N neuronas, X es el vector que contiene las entradas, b es el vector que contiene los sesgos (biases), y f es la función de activación.

2 RESULTADOS

De acuerdo con el factor de correlación R , el modelo neuronal muestra un adecuado indicador de desempeño para las redes neuronales artificiales en la estimación del índice de tenacidad flexural I_5 (en adelante en esta sección, se denominará como la estimación del índice de tenacidad I_5). Es importante mencionar que los valores del indicador de desempeño considerado (el factor de correlación R) son sensibles a la división de datos dentro del conjunto de entrenamiento evaluado en cada fase (entrenamiento, prueba y validación), es decir que estos valores son los obtenidos para el mejor aprendizaje después de realizar varias corridas (en el término usado para poner a funcionar un código computacional); sin embargo, este es un proceso válido en la elaboración y entrenamiento de los modelos neuronales, puesto que la RNA queda grabada para posteriormente ser usada y realizar futuras estimaciones. Se infiere que esta situación es debida a que el conjunto de patrones para el entrenamiento es pequeño, y el modelo neuronal no alcanza a hacer una adecuada aproximación a los valores reales de una manera constante en el tiempo (en razón a que para cada corrida, se hace una división aleatoria del conjunto de datos). La figura 3 muestra la relación de los datos reportados y estimados para el modelo neuronal entrenado.

3 CONCLUSIONES

El modelo neuronal desarrollado muestra un indicador de desempeño que lo hace confiable, sin embargo para los Autores de la presente Investigación es aún exploratorio, y no ha sido definido completamente en la estimación del índice de tenacidad I_5 , lo cual se infiere por lo siguiente: 1.- el conjunto de datos para el entrenamiento es pequeño (77 diseños de mezclas de concretos sin refuerzo y con refuerzo de fibra); 2.- la metodología para la estimación del índice de tenacidad, que corresponde a una metodología definida para valores relativos, conlleva un problema intrínseco de aprendizaje del modelo neuronal, de tal forma que para la RNA le es difícil asociar para diversas mezclas de concreto no reforzado (de resistencia normal o alta, para valores

diferentes en el contenido de cemento, en la relación agua/cemento o agua/cementante, y otras más, también de tipo cualitativo) un resultado idéntico (el valor de 1.0). Se sugiere para esta estimación involucrar un algoritmo computacional que permita asociar un valor de 1.0 en el índice de tenacidad I_5 a los concretos no reforzados con fibras, o entrenar el modelo neuronal con datos que usen una metodología diferente de estimación del índice de tenacidad, por ejemplo en valores absolutos.

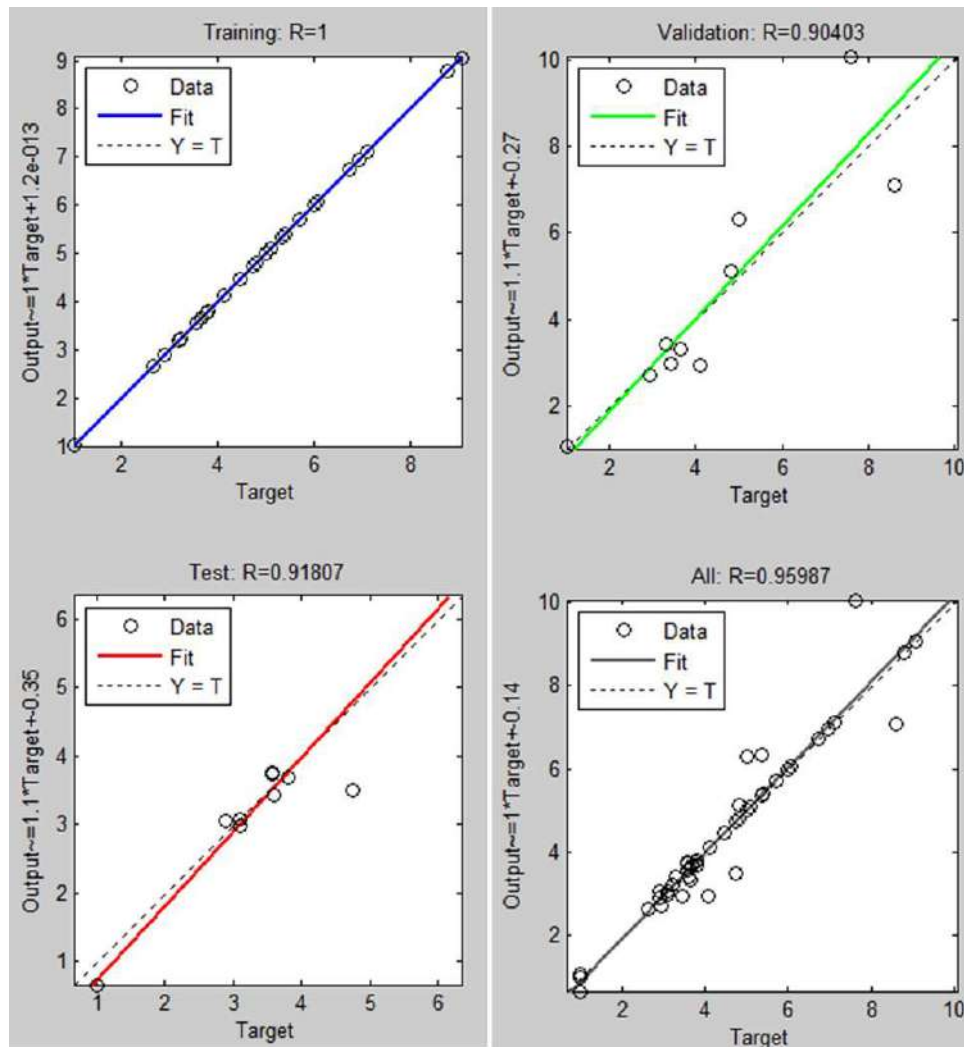


Figura 3. Relación entre los valores reportados y estimados, en las fases de entrenamiento, prueba, validación y del conjunto total de datos, para el modelo neuronal entrenado con el segundo conjunto de datos, en la estimación del índice de tenacidad I_5 .

Se destaca, con este modelo neuronal exploratorio, que es primera vez que se hace una estimación del índice de tenacidad I_5 usando RNA, ya que no se encontró reporte alguno en la Literatura. De igual manera, no se ha encontrado en la Literatura reporte alguno relacionado con la realización de modelos para estimar el índice de tenacidad I_5 usando otros tipos de técnicas.

4 REFERENCIAS BIBLIOGRÁFICAS

1. Siddique, R.; Khan, M.I., “Supplementary Cementing Materials”, New York, Springer, 2011.
2. Naman, S.N., et al., “Fibre Reinforced Concrete and High Performance Fibre Reinforced Cementitious Composites: An Overview”, Jurutera, July, 32-35, 2007.
3. Ramli, M., Dawood, E.T., “Effect of Steel Fibers on the Engineering Performance of Concrete”, Asian Journal of Applied Sciences, Vol. 4, No. 1, 97-100, 2011.
4. Barr, B., et al., “Toughness Measurement – the Need to Think Again”, Cement and Concrete Composites, Vol. 18, 281-297, 1996.
5. Moreno, E., Fernández, M., “Dosificación de hormigón reforzado con fibras de acero”, Materiales de Construcción”, Vol. 47, No. 247-248, 11-26, 1997.
6. Jevtic, D., et al., “Modeling of Properties of Fiber Reinforced Cement Composites”, Facta Universitatis: Architecture and Civil Engineering, Vol. 6, No. 2, 165-172, 2008.
7. Lu, P., et al., “Artificial Intelligence in Civil Engineering”, Mathematical Problems in Engineering, 1-22, 2012.
8. González S., L.O., “Diseño de mezclas de concreto reforzado con fibras metálicas y de polipropileno, usando Inteligencia Artificial”. Tesis Doctoral (Dr. Ing.: Ing. Materiales). Universidad del Valle. Santiago de Cali, Colombia, 2013.
9. Sukontasukkul, P., “Toughness evaluation of steel and polypropylene fibre reinforced concrete beams under bending”. Thammasat Int. J. Sc. Tech., Vol. 9, No. 3, July-September, 35-41, 2004.
10. The Mathworks Inc., “MATLAB® & Simulink® Release 2008a, Installation Guide for Windows”. The MathWorks Inc., Natick, MA, USA, March, 2008.
11. Beale, M.H., et al., “Neural Network Toolbox™”, User’s Guide. R2012a. The MathWorks Inc., Natick, MA, USA, March, 2012.
12. Moller, M., “Efficient training of feed-forward neural networks”. Thesis (Ph.D Computer Science). Arhus University, Arhus, Denmark, 1993.
13. Wackerly, D., Scheaffer, W., “Mathematical Statistics with Applications”. 7th edition, Thomson Higher Education, Belmont, CA, USA, 2008.
14. Hinton, G.E., “Connectionist learning procedures”. Artificial Intelligence, Vol. 40, No. 1-3, 185-234, 1989.