

Red neuronal artificial para estimar la resistencia a compresión, en concretos fibro-reforzados con polipropileno*¹

[Artificial neural network to predict the compressive strength, in polypropylene fiber-reinforced concrete]

LUIS OCTAVIO GONZÁLEZ SALCEDO², AYDEE PATRICIA GUERRERO ZÚÑIGA³,
SILVIO DELVASTO ARJONA⁴, ADRIÁN LUIS ERNESTO WILL⁵

RECIBO: 20.02.2012 - APROBACIÓN: 20.05.2012

Resumen

En diseño y construcción de estructuras de concreto, la resistencia a compresión lograda a los 28 días, es la especificación de control de esta-

- * Modelo para citación de este artículo de investigación científica y tecnológica:
GONZÁLEZ SALCEDO, Luis Octavio; GUERRERO ZÚÑIGA, Aydee Patricia; DELVASTO ARJONA, Silvio y WILL, Adrián Luis Ernesto (2012). Red Neuronal Artificial para estimar la resistencia a compresión, en concretos fibro-reforzados con polipropileno. En: Ventana Informática. No. 26 (ene. – jun., 2012). Manizales (Colombia): Facultad de Ciencias e Ingeniería, Universidad de Manizales. p. 11-28. ISSN: 0123-9678
- 1 Artículo proveniente del proyecto *Diseño de mezclas de concreto reforzado con fibras metálicas y de polipropileno, usando Inteligencia Artificial*, ejecutado para el periodo Agosto 2006 – Agosto 2013, e inscrito en el grupo de investigación Grupo de Materiales Compuestos – GMC, de la Universidad del Valle [Tesis Doctoral (Doctor en Ingeniería: Ingeniería de Materiales). Investigador: Luis Octavio González Salcedo. Directores: Aydee Patricia Guerrero Zúñiga y Silvio Delvasto Arjona].
 - 2 Ingeniero Civil, MSc. en Ingeniería Civil, PhD(c). en Ingeniería de Materiales. Profesor Asociado, Departamento de Ingeniería, Grupo de Investigación en Materiales y Medio Ambiente, Facultad de Ingeniería y Administración, Universidad Nacional de Colombia Sede Palmira (Palmira, Colombia). Correo electrónico: logonzalezsa@unal.edu.co
 - 3 Ingeniera Civil, MSc., PhD. En Ingeniería Civil. Profesora Titular, Escuela de Geomática e Ingeniería Civil, Grupo de Investigación en Ingeniería Sísmica, Ingeniería Eólica y Estructuras Inteligentes, Facultad de Ingenierías, Universidad del Valle (Cali, Colombia). Correo electrónico: aydeegzu@univalle.edu.co
 - 4 Ingeniero Químico, MSc. en Ingeniería Civil y manejo de materiales; PhD. en Ingeniería Industrial. Nuevos Materiales y sus Tecnologías de Fabricación. Profesor Titular, Escuela de Ingeniería de Materiales, Grupo de Materiales Compuestos, Facultad de Ingenierías, Universidad del Valle (Cali, Colombia). Correo electrónico: silviodelvasto@hotmail.com
 - 5 Matemático, PhD. en Matemáticas. Profesor Adjunto, Departamento de Matemáticas, Facultad de Ciencias Exactas y Tecnología, Universidad Nacional de Tucumán; Co-Director Centro de Investigación en Tecnologías Avanzadas de Tucumán, de la Universidad Tecnológica Nacional – Facultad Regional Tucumán (San Miguel de Tucumán, Argentina). Correos electrónicos: adrian.will.01@gmail.com, adri_will_1@yahoo.com

bilidad de la obra. La inclusión de fibras como reforzamiento de la matriz cementicia, ha permitido una ganancia en sus propiedades, además de la obtención de un material de alto desempeño; sin embargo, la resistencia a compresión sigue siendo la especificación a cumplir en la normatividad de la construcción. Las redes neuronales artificiales, como un símil de las neuronas biológicas, han sido utilizadas como herramientas de predicción de la resistencia a compresión en el concreto sin fibra. Los antecedentes en este uso, muestran que es de interés el desarrollo de aplicaciones en los concretos reforzados con fibras. En el presente trabajo, redes neuronales artificiales han sido elaboradas para predecir la resistencia a compresión en concretos reforzados con fibras de polipropileno. Los resultados de los indicadores de desempeño muestran que las redes neuronales artificiales elaboradas pueden realizar una aproximación adecuada al valor real de la propiedad mecánica, abriendo una futura e interesante agenda de investigación.

Palabras Claves: Resistencia a compresión; concreto reforzado con fibras; fibra de polipropileno; predicción; inteligencia artificial; redes neuronales artificiales.

Abstract

In concrete structures' design and construction, the compressive strength achieved at 28 days, is the work's stability control specification. The inclusion of reinforcing fibers into the cementitious matrix, has allowed a gain in their properties, as well as obtaining a high performance material, however, the compressive strength remains the specification to meet the construction regulations. Artificial neural networks as a biological neurons' simile have been used as tools for predicting the plain concrete compressive strength. The backgrounds in this application show that interest is the development of applications in fiber-reinforced concrete. In this paper, artificial neural networks have been developed to predict the compressive strength in polypropylene fiber reinforced concrete. The results of the performance indicators show that the developed artificial neural networks can perform an adequate approximation to the actual value of the mechanical property, opening an interesting future research.

Keywords: Compressive strength, fiber-reinforced concrete, polypropylene fiber, prediction, artificial intelligence, artificial neural networks.

Introducción

El concreto es uno de los más importantes materiales de ingeniería, el cual es usado en la construcción de edificaciones, puentes, túneles, y otras estructuras de infraestructura, según Sánchez (2000, 15). El concreto es elaborado a partir de agregados y cemento con una adecuada y controlada cantidad de agua, así como otros componentes denominados adiciones minerales y aditivos químicos (Mehta & Monteiro, 2006). Una de las propiedades mecánicas usada como referencia de especificación en el concreto, de acuerdo con Sánchez (2000, 53) es su resistencia de diseño a compresión, para lo cual se necesita normalmente de un periodo de curado de 28 días para medirla en probetas.

La curva esfuerzo – deformación unitaria del concreto, muestra que éste es un material quebradizo; la incorporación de fibras como reforzamiento de la matriz cementicia ha permitido extender el área de dicha curva más allá de la aparición de la primera grieta y seguir soportando esfuerzos a pesar de haber alcanzado su máxima resistencia, afirman Oucief, Habita & Redjel (2006, 77). Esto es conocido como un comportamiento cuasi-dúctil que les otorga al material, propiedades adicionales como control de grietas, mayor durabilidad a agentes corrosivos, adecuado comportamiento en áreas sometidas a vibración, entre otras, plantea The Aberdeen Group (1983, 2-3).

En el concreto, la resistencia a compresión está influenciada además de las proporciones de la mezcla, por la calidad de los diferentes ingredientes de dicha mezcla, las condiciones de curado, la relación agua cemento, y los métodos de mezclado, transporte, colocación y vibración, según considera Sánchez (2000). Debido a la importancia en conocer la resistencia de diseño antes de los 28 días, métodos convencionales de modelación matemática usando ecuaciones de regresiones lineales y no lineales han sido construidas para modelar la predicción, en los cuales la alta dependencia no lineal entre sus factores o variables influyentes en la propiedad mecánica, no fue considerada, como se reporta en los trabajos de Popovics (1998), Wang, Ni & He (1999), Yeh (1999) y Nath & Barua (2004).

Esta complejidad conlleva la estimación de la resistencia a compresión del concreto al campo de la Inteligencia Artificial, la cual reúne una serie de técnicas aplicadas en el ordenador para realizar funciones de aprendizaje y autocorrección, mediante algoritmos o códigos de programación computacional para resolver diversos problemas, de forma similar a como lo haría el ser humano, asegura Ponce (2010). Los principales paradigmas de la inteligencia artificial son: las redes neuronales artificiales, los algoritmos evolutivos y la lógica difusa.

En el campo de la modelación, las redes neuronales artificiales, RNA, son modelos de caja negra, desarrollados para resolver problemas en los que las relaciones de los diferentes componentes son complejas, las variables o reglas de relación no son fáciles de obtener, existe escaso conocimiento, pero sí existe la experiencia de una serie de datos, de acuerdo con López & Caicedo (2006). Las RNA, son sistemas inteligentes inspirados en los sistemas neurales biológicos, y funcionalmente son procesadores de información, con un canal de entrada de información y un canal de salida, con alta capacidad de comunicarse y unirse entre sí, cuya unión es denominada sinapsis.

La literatura muestra diversos reportes sobre el uso de RNA para la estimación de la resistencia a la compresión en concretos planos (Oh, Lee & Lee (1997); Garg (2003); Wang, Wang & Ni (2003); Alshihri; Azmy & El-Bisy (2009); Yeh (2009); Alilou & Teshnenlab (2010) y Abdeen & Hodhod (2011)), donde las variables de entrada se han enfocado hacia las cantidades de los componentes de la mezcla; siendo entonces de interés usar la técnica mencionada en concretos reforzados con fibras. En el presente trabajo, se explora el uso de RNA en la estimación de la resistencia de diseño a compresión en concretos fibrorreforzados con polipropileno, y considerando además de la dosificación de la mezcla, características propias de sus componentes.

1. Fundamento teórico

1.1 Redes Neuronales Artificiales (RNA)

La RNA es un modelo matemático que emula al sistema neuronal biológico en el procesamiento de la información, y en cuyo símil la integración de las neuronas artificiales se realiza mediante funciones matemáticas que procesan y envían información entre sí; la información que se transmite a través de las conexiones de la red se pondera en pesos de importancia modulándose así la intensidad de la relación entre neuronas. La fundamentación matemática para estructurar una RNA está basada en el teorema de Kolmogorov, presentado por (Kurkova (1992) y Haykin (1999), de tal forma que a partir de tres capas (de entrada, oculta y de salida) se puede aproximar hasta el nivel deseado cualquier función continua en un intervalo, haciendo de la red multicapa una apropiadora universal de funciones (Leshno et al., 1992). Hecht-Nielsen (1987, 11-12), indica que el uso de dos o más capas ocultas hace más operativa la red porque permite flexibilizar la elección de las funciones de transferencia o disminuir el número de neuronas.

La elaboración de una RNA involucra la definición del número de capas ocultas, el número de neuronas en las capas ocultas, el tipo de

conexiones entre neuronas, la función de transferencia o respuesta de las neuronas y el mecanismo de aprendizaje. Con respecto al tipo de conexiones, una tipología es la *feedforward*, definida por Rumelhart, Hinton & Williams (1986), la cual corresponde a un tipo de estructura de computación paralela donde muchas pequeñas unidades de cálculo llamadas neuronas están masivamente interconectadas con la capa anterior de donde reciben información, y con la capa posterior hacia donde la transmiten. Sus capas ocultas poseen una función de activación que limita la salida a un rango cercano y desde ésta la capa de salida puede producir todos los valores de estimación. La salida de cada capa es representada como:

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

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 (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. La función de activación no-lineal corresponde a una función sigmoidea expresada como:

$$f(Z) = \frac{1}{1+e^{-Z}} \quad (2)$$

Siendo Z la expresión contenida dentro del paréntesis de la ecuación 1. La cantidad mínima de neuronas de las capas ocultas pueden ser obtenidas entre los valores obtenidos a partir de la regla de la pirámide, ecuación (3) (Master, 1993; Tabares, Branch & Valencia, 2006), y la aplicación del Teorema de Kolmogorov, ecuación (4) (Hecht-Nielsen, 1987):

$$k = \text{Redondeo}(\sqrt{n \cdot m}) \quad (3)$$

$$k = 2n + 1 \quad (4)$$

Donde, k es el número de neuronas de la capa oculta, n es el número de neuronas de la capa de entrada (variables de entrada), y m es el número de neuronas de la capa de salida (variables de la capa de salida). Un procedimiento muy usado es iniciar la red con el número mínimo de neuronas ocultas, y si los resultados no son satisfactorios se va aumentando progresivamente el número de éstas hasta que el indicador de evaluación es aceptable (Brockett et al., 1997).

La técnica de aprendizaje de *backpropagation* consiste en utilizar una optimización basada en derivadas, donde el error es derivable no solamente en función de los pesos de la capa de salida, sino también en función de los pesos de la capa oculta utilizando la regla de la cadena (Hinton, 1989), que permite minimizar el error de entrenamiento de la red

neuronal (la diferencia entre los valores calculados por la red neuronal utilizando un determinado conjunto de pesos, y los valores originales). El error y las correcciones efectuadas a los pesos se trasladan desde la capa de salida hacia atrás hasta la capa de entrada, de donde surge su nombre de propagación hacia atrás. El método de descenso por gradiente o gradiente conjugado, correspondiente al gradiente conjugado con escalamiento SCG (*Scale Conjugate Gradient*), ha sido definido por Moller (1993, 25-30), y sustituye la búsqueda lineal por un escalamiento de paso, que depende del éxito en la reducción del error y buen desempeño de la aproximación cuadrática de éste. El método de entrenamiento denominado Algoritmo de Levenberg-Marquardt LMA (*Levenberg-Marquardt Algorithm*), ha sido definido por Lourakis (2005, 1-6), y corresponde a una técnica iterativa que localiza el mínimo de una función que es expresada como la suma de los cuadrados de funciones no lineales.

Para el reconocimiento de patrones, la RNA divide la información en tres grupos, siendo una técnica de división, *K-Fold Cross Validation* con $k = 3$, la cual divide cada base de datos específica en tres grupos de igual extensión con vectores de información escogidos al azar, usando alternativamente dos grupos como conjunto de educación de la red (entrenamiento y prueba) y el tercero como validación (Díaz, Will & González, 2011). La técnica, que utiliza adicionalmente una regulación estadística bayesiana, elimina los sesgos de elección, da una mejor idea de los errores de validación y de la existencia de valores extremos o atípicos (*outliers*) que normalmente quedan ocultos por la división de datos y otros efectos (Díaz, Will & González, 2011).

1.2 Dependencia de la resistencia a compresión

De acuerdo con Noguchi, Maruyama & Kanetmasu (2003, 1921-1930), la resistencia a la compresión de los concretos depende de la resistencia del mortero (mezcla de cemento, agua y arena) y los efectos que sobre ésta tienen el agregado grueso y la interfase entre estos dos compuestos, el contenido de aire y las adiciones minerales; manifiestan que dentro de las variables influyentes de la resistencia del mortero, se consideraron los contenidos de cemento y agua, y el tipo de cemento. Con respecto al tipo de cemento, en Colombia hay una producción de cinco principales tipos de cementos, presentados por Sánchez (2000): de uso general, de moderado calor de hidratación y de resistencia moderada a los sulfatos, de altas resistencias a temprana edad, de bajo calor de hidratación, y de alta resistencia a los sulfatos.

El comportamiento de la zona de transición es influenciada, además de la cantidad, por las características de las partículas del agregado tales como el tamaño, la forma, la textura de la superficie y el tipo de

mineral (Alsayed & Amjad (1996); Cetin & Carrasquillo (1998); Chan, Solís & Moreno (2003); Noguchi, Maruyama & Kanetmasu (2003) y Mills & Ioannides (2007)).

Noguchi, Maruyama & Kanetmasu (2003), manifiestan que el efecto del contenido del aire es influenciado por la cantidad del agente entrador de aire, usado en la mezcla de concreto; y afirman que las cantidades de las adiciones de humo de sílice, de cenizas volantes y de escoria de alto horno, cuando son utilizadas como materiales cementantes en reemplazo de parte del cemento, influyen en la resistencia a compresión. Algunos reportes, como el presentado por Tsai et al. (2009), muestran también que la cantidad de agentes reductores de agua influyen en la resistencia del concreto.

Una aproximación a la mecánica del concreto reforzado con las fibras considera que las propiedades del compuesto están relacionadas con las propiedades de las fibras y de la interfase entre los dos componentes, donde se resalta el volumen de fibra incorporado en la matriz cementicia y un parámetro de adherencia de la fibra (Kluits (2005); Richardson (2006) y Richardson & Landless (2009)). La fibra de polipropileno se encuentra disponible comercialmente de manera general en monofilamentos y fibriladas, y en cintas (Kluys, 2005), y pueden ser lisas o de forma ondulada. Richardson (2006) y Richardson & Landless (2009), consideran que la cantidad de fibra, el diámetro de la fibra y la relación de aspecto son variables que influyen en la resistencia del concreto.

2. Metodología

2.1 Elaboración de la base de datos para entrenamiento de la RNA

Se usó una base general de datos elaborada a partir de información disponible en reportes experimentales de ensayos de resistencia a la compresión para diversos diseños de mezclas (Kim (2003); Bennie (2004); Won (2004); Adomavicius et al. (2005); Sharif (2005); Myers (2006); Oucief, Habita & Redjel (2006); Richardson (2006); Roesler et al. (2006); Trocónis et al. (2006); Bhise (2008); Myers, Kang & Ramseyyer (2008) y Salih & Jasim (2009)). La base de datos es utilizada para enseñanza, entrenamiento y validación computacional de las redes neuronales artificiales, y se encuentra conformada por 114 registros que constituyen los vectores de información completa del arreglo matricial de la base de datos para las variables involucradas. La resistencia a compresión está basada en la metodología del ensayo estandarizado ASTM C39, presentada por Huang et al. (2006), en el cual especímenes

cilíndricos, con edades de 28 días después de realizada la mezcla, son sometidos a esfuerzos de compresión.

Para la selección de las variables de entrada y conformación de los vectores de información (registros de información), se tuvieron en cuenta las consideraciones sobre la dependencia de la resistencia a compresión en concretos reforzados con fibras de polipropileno. Para representar la influencia de la forma y la textura de la superficie se diferenciaron entre agregado triturado y de canto rodado. Para representar el tipo de mineral, se consideró como variable el tipo litológico como un parámetro del agregado grueso, clasificado en tres grupos, de acuerdo con la afectación sobre las propiedades mecánicas del concreto (Noguchi et al., 2009); en el presente trabajo, se han adaptado estos tipos litológicos para representar la procedencia del agregado grueso.

Las 20 variables contenidas en la base de datos se agruparon de la siguiente manera (Tabla 1): cemento, adiciones minerales, agua total, agregados, aire incluido, fibra de polipropileno y resistencia de diseño a la compresión. Ésta última corresponde a la variable de salida, en la RNA.

2.2 Elaboración de las redes neuronales artificiales

En el Laboratorio Computacional del Departamento de Matemáticas de la Universidad Nacional de Tucumán, se elaboró un conjunto de programas de ordenador con el algoritmo para la RNA usada en la estimación de la resistencia a compresión del concreto. La información recopilada en la base de datos general fue arreglada para conformar tres subconjuntos, el primero con 98, y los dos restantes con 114 vectores de información cada uno, que a su vez constituyeron tres nuevas bases de datos específicas y que relacionan como información de interés para su estimación los valores de resistencia a compresión del concreto ($f'c$). Como lenguaje de programación para la escritura del algoritmo de la RNA se usó Matlab®; la RNA se creó usando la caja de herramientas de redes neuronales del lenguaje mencionado (Beale, Hagan & Demuth, 2012) y los vectores de información fueron leídos directamente en el programa en una matriz creada para almacenar la base de datos. La tipología de la RNA usada corresponde a una red multicapa (*feedforward*) y se usó una metodología de educación o aprendizaje de propagación hacia atrás (*backpropagation*), utilizando una técnica de división de datos para enseñanza-entrenamiento-validación denominada validación cruzada (*K-Fold Cross Validation*) con $k = 3$. El conjunto de programas se estructuró con seis módulos, que comprende un programa principal para entrenar la RNA y cinco programas auxiliares.

Tabla 1. Detalles de las variables incorporadas en la base de datos para el entrenamiento de la Red Neuronal Artificial

Grupo	Concepto	Variable	Unidad	Símbolo	Representación RNA
Cementos	Cemento	Cantidad	Kg/m ³	C	Numérica real
		Tipo I		C-1	[1 0 0 0 0]
		Tipo II		C-2	[0 1 0 0 0]
		Tipo III	-	C-3	[0 0 1 0 0]
		Tipo IV		C-4	[0 0 0 1 0]
		Tipo V		C-5	[0 0 0 0 1]
Adiciones	Humo de Sílice	Cantidad	Kg/m ³	SF	Numérica real
	Cenizas volantes	Cantidad	Kg/m ³	FA	Numérica real
	Escoria	Cantidad	Kg/m ³	GBFS	Numérica real
Agua total	Agua	Cantidad	Kg/m ³	W	Numérica real
	Agente reductor	Cantidad	Kg/m ³	HWR	Numérica real
		Sin aditivo			[0 0]
		Plastificante	-	HWR-P	[1 0]
		Superplastificante		HWR-SP	[0 1]
Agregados	Arena	Cantidad	Kg/m ³	S	Numérica real
		Lecho de río	-	S-CR	[1 0]
		Cantera		S-TR	[0 1]
	Grava	Cantidad	Kg/m ³	G	Numérica real
		Lecho de río	-	G-CR	[1 0]
		Cantera		G-TR	[0 1]
		Tamaño máximo	Kg/m ³	G-TMA	Numérica real
		Clase 1		LTCA-1	[1 0 0]
		Clase 2	-	LTCA-2	[0 1 0]
		Clase 3		LTCA-3	[0 0 1]
Aire incluido	Agente entrador	Cantidad	Kg/m ³	AEA	Numérica real
		Cantidad	Kg/m ³	PPFR	Numérica real
Fibra	Fibra de polipropileno	<u>Tipo:</u>			
		Sin fibra			[0 0 0]
		Clase 1	-	PPFR-1	[1 0 0]
		Clase 2		PPFR-2	[0 1 0]
		Clase 3		PPFR-3	[0 0 1]
		<u>Anclaje:</u>			
		Sin fibra			[0 0]
		Clase 1	-	APPFR-1	[1 0]
		Clase 2		APPFR-2	[0 1]
		Longitud	mm	Lf	Numérica real
Propiedad	Resistencia a compresión	Resistencia de diseño	MPa	f _c	Numérica real

En la tabla 2, se hace una breve descripción de la función de cada módulo, y en la figura 1, se presenta un esquema gráfico de la interrelación de los módulos dentro del conjunto de programas.

Tabla 2. Descripción de los módulos que conforman el conjunto de programas (principal y cinco auxiliares) para el entrenamiento de la Red Neuronal Artificial

Denominación genérica	Función
Redes	Carga y entrena las redes neuronales artificiales, y constituye el programa principal para el entrenamiento de la RNA.
Configurar variables	Carga las variables y parámetros necesarios para correr Leave-One-Out-CrossValidation de la RNA, con un procesamiento previo de los datos utilizados.
Preparar datos	Prepara los datos, realiza Leave-One-Out_CrossValidation, hace la división de datos de Entrenamiento y Validación, y carga los resultados en las variables globales.
Validación cruzada	Ejecuta la técnica de validación cruzada denominada Leave-One-Out-CrossValidation. La técnica consiste en elegir un dato del conjunto de chequeo, y todos los demás datos disponibles son seleccionados como conjunto de entrenamiento. Si el error de predicción es grande, el dato es evaluado con respecto a su anormalidad, es decir si es muy distante de los demás, y es eliminado.
Insertar red	Diseñado como una herramienta para separar exactamente donde está la creación de la RNA. Esta herramienta permite que con el mismo sistema se pueda probar en futuras aplicaciones otros tipos de redes. El objetivo del programa es construir y entrenar la RNA.
Entrenamiento	Simula la RNA.




Figura 1. Esquema gráfico de interrelación de los módulos dentro del conjunto de programas (principal y cinco auxiliares) para entrenar una RNA de estimación de la resistencia a compresión

2.3 Arquitectura y entrenamiento de la red neuronal artificial

En el presente trabajo, se ha configurado la RNA con una capa de entrada, dos capas ocultas y una capa de salida. La tabla 3 muestra para el caso de estudio las pruebas realizadas en una de las redes conformadas, para definir el número de neuronas en las capas ocultas, eligiéndose una red con dos capas ocultas de 50 y 10 neuronas, respectivamente. Para la preparación de los datos se eligió como forma de entrenamiento, el método de descenso por gradiente o gradiente conjugado, correspondiente al gradiente conjugado con escalamiento SCG, y una vez se ejecuta el programa principal para la RNA se eligió como método de entrenamiento el Algoritmo de LMA).

Tabla 3. Prueba para la selección del número de neuronas en las dos capas ocultas, usando como indicador de evaluación el factor de correlación R^2

Conjunto	Entrenamiento	Prueba	Validación	Total
Arquitectura de la RNA*	R^2	R^2	R^2	R^2
[05 05]	1	0,7663	0,8524	0,9236
[10 10]	1	0,5947	0,7979	0,7643
[20 20]	1	0,7103	0,7643	0,9231
[30 30]	1	0,5306	0,6644	0,8711
[40 40]	1	0,6436	0,8939	0,9045
[50 50]	1	0,5832	0,4898	0,7363
[50 40]	1	0,7646	0,7053	0,8361
[50 30]	1	0,6385	0,3361	0,8292
[50 20]	1	0,3835	0,7535	0,7994
[50 10]	1	0,8847	0,9712	0,9573
[50 05]	1	0,9323	0,8107	0,9496

* La arquitectura de la RNA descrito como [k1 k2] se refiere al número de neuronas en las dos capas ocultas, respectivamente.

2.4 Evaluación del desempeño de la red neuronal artificial

El desempeño de una RNA se puede evaluar usando diversas técnicas, entre ellas la raíz del error promedio cuadrado RMSE (*Root Mean Square Error*), el total de los cuadrados de los errores SSE (*Sum of Squares of Error*), el error relativo promedio MER (*Mean Error Ratio*), el error promedio cuadrado MSE (*Mean Square Error*), y el factor de correlación R^2 (R^2 *Correlation Factor*) de acuerdo con Goyal & Goyal (2011).

En el presente trabajo, la preparación de datos se diseñó para utilizar como indicador de desempeño el SSE, mientras que para las fases de aprendizaje (entrenamiento y prueba) y validación de la RNA se usaron el MSE y el factor R^2 ; adicionalmente para la simulación del conjunto total datos se usó el factor de correlación R^2 , el cual es reportado en este documento. Los indicadores mencionados fueron calculados como:

$$SSE = \sum_{t=1}^T (O_t - \bar{O}_t)^2 \quad (5)$$

$$MSE = \sum_{t=1}^T \left(\frac{Y_t - O_t}{T} \right)^2 \quad (6)$$

$$R^2 = 1 - \frac{\sum_{t=1}^T (Y_t - O_t)^2}{\sum_{t=1}^T (Y_t - \bar{O}_t)^2} \quad (7)$$

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.

2.5 Conformación de las redes neuronales artificiales

Para el caso en estudio se elaboraron y se entrenaron tres redes neuronales artificiales, con tipología multicapa conformada por una de entrada, una primera oculta con 50 neuronas, una segunda oculta con 10 neuronas, y una de salida con una única neurona correspondiente al valor de la resistencia de diseño a compresión. Las variables (neuronas) de entrada y salida en cada red neuronal artificial elaborada y entrenada, se muestran en la tabla 4.

Tabla 4. Conformación de las RNA para la estimación de la resistencia de diseño a compresión

RNA	Entradas	Salida
RNA_1	C, C-i, SF, FA, GBFS, W, HWR, HWR-i, S, S-i, G, G-i, G-TMA, LTCA-i, AEA, PPFR, PPFR-i, APPFR-i, Lf	f_c
RNA_2	C, C-i, SF, FA, GBFS, W, HWR, HWR-i, S, S-i, G, G-i, G-TMA, AEA, PPFR, PPFR-i, APPFR-i, Lf	f_c
RNA_3	C, C-i, SF, FA, GBFS, W, HWR, HWR-i, S, S-i, G, G-i, AEA, PPFR, PPFR-i, APPFR-i, Lf	f_c

3. Resultados

Las tres redes neuronales artificiales para estimación de la resistencia de diseño a compresión en concretos reforzados con fibras de polipropileno fueron elaboradas y entrenadas siguiendo el procedimiento antes mencionado. Para las redes elaboradas se analizó el comportamiento

computacional de los datos en las fases de aprendizaje (entrenamiento y prueba) y de validación; en la tabla 5 se reporta el factor de correlación R^2 tanto para las fases mencionadas como para la simulación con la base de registros completa.

Tabla 5. Comportamiento computacional de los datos en las fases de entrenamiento (aprendizaje y prueba) y de validación, así como de la base de registros completa, para tres redes neuronales artificiales para estimar la resistencia a compresión en concretos reforzados con fibras de acero.

Fase	Entrenamiento	Prueba	Validación	Total datos
RNA	R2	R2	R2	R2
RNA_1	1	0,73193	0,63714	0,73444
RNA_2	0,99997	0,91429	0,89605	0,93671
RNA_3	1	0,97963	0,66138	0,96957

Los resultados en términos generales muestran un adecuado comportamiento de estimación en las tres redes neuronales artificiales elaboradas, y es significativo que para la red RNA_1 los indicadores de evaluación sean aceptables, y en la cual la estimación de la resistencia a compresión se hace a partir de la mayor consideración de características en las variables de entrada; lo cual es concordante con la teoría sobre el diseño de mezclas de concreto (Sánchez, 2000), donde un alto número de variables relacionadas con los materiales usados influyen en el valor de dicha propiedad mecánica.

4. Conclusiones y trabajo futuro

La posibilidad del acercamiento con redes neuronales artificiales fue explorada para predecir la resistencia a compresión en concretos reforzados fibras de polipropileno. Las redes neuronales artificiales con tipología *feedforward*, con aprendizaje *backpropagation* y arquitectura multicapa fueron elaboradas y evaluadas usando como indicadores de desempeño el error MSE y el factor de correlación R^2 en la fase de validación. De acuerdo con los indicadores de desempeño mencionados, en términos generales las redes tienen un buen comportamiento para realizar dicha estimación, siendo significativa una amplia consideración de características en las variables de entradas.

El trabajo realizado y los resultados obtenidos, permiten trazar los siguientes aportes:

- La consideración de variables de entrada consistentes en la diferenciación del tipo de cemento, de la procedencia del agregado (triturado,

canto rodado), del perfil litológico del agregado grueso, del tipo de agente reductor de agua (plastificante, superplastificante), y del tipo de fibra plástica, adicionales a las dosificaciones de sus componentes (incluyendo adiciones minerales), hacen de la RNA una herramienta de predicción universal de la resistencia a compresión del concreto reforzado con fibra de polipropileno.

- La inclusión de registros sin adición de fibra, hacen que la herramienta de predicción, pueda ser usada también para estimar la resistencia a compresión en concretos no reforzados con fibras.
- Se abre una agenda futura de investigación en la tecnología del concreto reforzado con fibra de polipropileno, sobre exploraciones en:
 - Realizar ajustes en la RNA para predicción de la resistencia a compresión, de tal forma que se obtengan mejores indicadores de desempeño.
 - Usar la RNA como una herramienta de optimización en los componentes de la mezcla de concreto, mediante la evaluación de la variación de la resistencia a compresión considerando la variación en las cantidades de un componente en particular.
 - Usar la RNA como herramienta de optimización en el volumen de la fibra de polipropileno como refuerzo de la matriz cementicia, mediante la evaluación de la variación de la resistencia a compresión considerando no sólo la variación de la cantidad, sino también la morfología y adherencia de la fibra.

Bibliografía

- ABDEEN, M. A. M & HODHOD, H. (2011). Analytic Formulae for Concrete Mix Design Based on Experimental Data Base and Predicting the Concrete Behavior using ANN Technique [on line]. In: International Journal of Engineering, Vol. 4, No. 5, Kuala Lumpur (Malaysia): CSC Journal. p. 368-386. ISSN: 1985-2312. <<http://www.cscjournals.org/csc/manuscript/Journals/IJE/volume4/Issue5/IJE-210.pdf>> [consult: 09/03/2012].
- ALILOU, V. K. & TESHNEHLAB, M. (2010). Prediction of 28-day compressive strength of concrete on the third day using artificial neural networks [on line]. In: International Journal of Engineering, Vol. 3, No. 6, Kuala Lumpur (Malaysia): CSC Journal. p. 565-576. ISSN: 1985-2313. <<http://www.cscjournals.org/csc/manuscript/Journals/IJE/volume3/Issue6/IJE-126.pdf>> [consult: 17/03/2012].
- ALSAYED, S. H. & AMJAD, M. A. (1996). Strength, water absorption and porosity of concrete incorporating natural and crushed aggregate [on line]. In: Journal of King Saud University, Engineering Science, Vol. 8, No. 1, Riyadh (Kingdom of Saudi Arabia): King Saud University, p. 109-120. ISSN: 1018-3639. <<http://www2.arnes.si/~surzjagl/sola/Gradbenafizika-Stavbarstvo/PoroznostBetona.pdf>> [consult: 17/03/2012].
- ALSHIHRI, M. M.; AZMY, A. M. & EL-BISY, M. S. (2009). Neural Networks for predicting compressive strength of structural light weight concrete [on line]. In: Construction and Building Materials, Vol. 23, No. 6, Edinburgh (UK): Elsevier Science Ltd., p. 2214-2219. ISSN: 0950-0618. <<http://www.sciencedirect.com/science/article/pii/S0950061808003528>> [consult: 17/03/2012].
- BEALE, M. H.; HAGAN, M. T. & DEMUTH, H. B. (2012). Neural Networks Toolbox: User's Guide. Natick (USA): The Math Works Inc. 404p. ISBN: 0-9717321-0-8.
- BENNIE, S. D. (2004). Development of a performance based, integrated design/selection mixture methodology for fiber reinforced concrete airfield pavements. Thesis (PhD in Civil Engineering), College Park (USA), University of Maryland, 221p.
- BHISE, P. B. (2008). Performance of fiber reinforced concrete in acidic environment. Thesis (M. Eng: Structural Engineering), Delhi (India), University of Delhi, 92p.
- BROCKETT, P. L.; COOPER, W. W.; GOLDEN, L. L.; & XIA, X. (1997). A case study in applying networks to predicting insolvency for property and casualty insurers [on line]. In: Journal of Operations Research Society, Vol. 48, No. 12, Birmingham (UK): Palgrave McMillan Journals, p. 1153-1162. ISSN: 0160-5682. <<http://www.jstor.org/stable/3010746>> [consult: 13/12/2011].
- CETIN, A. & CARRASQUILLO, R.L. (1998). High-Performance Concrete: Influence of Coarse Aggregates on Mechanical Properties. In: ACI Materials Journal, Vol. 95, No. 3, Farmington Hills (USA): American Concrete Institute, p. 252-261. ISSN: 0889-325X.
- CHAN Y., J. L.; SOLÍS C., R. & MORENO, E. I. (2003). Influencia de los agregados pétreos en las características del concreto [en línea]. En: Ingeniería, Vol. 7, No. 2, Mérida (México): Universidad Autónoma de Yucatán, p. 39-46. ISSN: 1665-529X. <<http://www.revista.ingenieria.uady.mx/volumen7/influencia.pdf>> [consult: 17/03/2012].
- DÍAZ, W.; WILL, A. & GONZÁLEZ S., L. (2011). Un método para estimación de calidad de datos en redes neuronales y aplicación a problemas de hormigón de alto performance. En: XIX Congreso sobre Métodos Numéricos y sus Aplicaciones – ENIEF 2011 (1-4/11/2011), Rosario (Argentina): Asociación Argentina de Mecánica Computacional – AMCA. Mecánica Computacional [MÖLLER, O.; SIGNORELLI, J.W. & STORTI, M.A. (Editores)], Vol. 30, No. 43, p. 3381-3381.
- GARG, R. (2003). Concrete Mix Design using Artificial Neural Network. Thesis (Master of Engineering: Civil Engineering), Patiala (India): Thapar Institute of Engineering - Deemed University, 50p.
- GOYAL, S. & GOYAL, G. K. (2011). Cascade and feedforward backpropagation artificial neural network models for prediction of sensory quality of instant coffee flavoured sterilized drink. In: Canadian Journal on Artificial Intelligence, Machine Learning and Pattern Recognizing, Vol. 2, No. 6, Toronto (Canada): AM Publishers Corporation Canada, p. 78-82. ISSN: 0840-8688.
- HAYKIN, S. (1999). Neural networks: a comprehensive foundation. 2 ed. Upper Saddle River (USA): Prentice Hall. 842 p. ISBN: 978-0132733502.
- HECHT-NIELSEN, R. (1987). Kolmogorov's mapping neural network existence theorem. In: IEEE 1st International Conference on Neural Networks. Proceedings, Vol. 3, New York (USA): IEEE Press, p. 11-14.

- HINTON, G. E. (1989). Connectionist learning procedures [on line]. In: Artificial Intelligence, Vol. 40, No. 1-3, Essex (UK): Elsevier Science Ltd., p. 185-234. ISSN: 0004-3702. <<http://www.csri.utoronto.ca/~hinton/absps/clp.pdf>> [consult: 17/03/2012].
- HUANG, B.; CAO, J.; CHEN, X. & SHU, X. (2006). Laboratory and analytical study of permeability and strength properties of pervious concrete. In: National Ready Mix Concrete Association, Concrete Technology Forum: Focus on Pervious Concrete (24-25/05/2006). Proceedings, Nashville (USA).
- KIM, H. (2003). Behavior and performance of high performance concrete for pavements. Thesis (MSc Civil Engineering), College Park (USA): University of Maryland, 140p.
- KLUITES, G. (2005). Investigation of the effect of selected polypropylene fibres and ultra-fine aggregate on plastic shrinkage cracks on South African roads. Thesis (Magister Technologiae: Civil Engineering), Port Elizabeth (South Africa): Nelson Mandela Metropolitan University (Port Elizabeth Technikon), 193 p.
- KURKOVA, V. (1992). Kolmogorov theorem and multilayer neural networks. In: Neural Networks, Vol. 5, No. 3, Oxford (UK): Elsevier Science Ltd., p. 501-506. ISSN: 0893-6080.
- LESHNO, M.; LIN, V. Y.; PINKUS, A. & SCHOCKEN, S. (1992). Multilayer feedforward networks with nonpolynomial activation function can approximate any function. In: Working Paper Series STERN IS-92-13 (Mar.). New York (USA): New York University, Center for Research on Information Systems.
- LÓPEZ, J. A. & CAICEDO, E. (2006). Una aproximación práctica a las redes neuronales artificiales. Conferencias del Curso de Redes Neuronales Artificiales. Cali (Colombia): Universidad del Valle.
- LOURAKIS, M. I. A. (2005). A brief description of the Levenberg-Marquardt Algorithm implemented by levmar. February, Heraklion (Greece): Institute of Computer Science, Foundation for Research and Technology – Hellas (FORTH), 6p.
- MEHTA, P. K. & MONTEIRO, P. J. M. (2006). Concrete: Microstructure, Properties and Materials. 3 ed. Blacklick (USA): McGraw-Hill, 659p. ISBN: 978-0071462891.
- MILLS, J.C. & IOANNIDES, A.M. (2007). Laboratory study of larger sized aggregate in Portland cement concrete. In: International Journal of Pavement Engineering, Vol. 8, No. 4, London (UK): Taylor & Francis, p. 253-263. ISSN: 1029-8436
- MOLLER, M. (1993). Efficient training of feed-forward neural networks. Thesis (Ph.D Computer Science). Arhus (Denmark): Arhus University. 136p.
- MYERS, D. S. (2006). Fiber-reinforced concrete and bridge deck cracking. Thesis (MSc.), Norman (USA): University of Oklahoma, 241p.
- MYERS, D.; KANG, T. H. K. & RAMSEYER, C. (2008). Early-age properties of polymer fiber-reinforced concrete [on line]. In: International Journal of Concrete Structures and Materials, Vol. 2, No. 1, Seoul (Korea): Korea Concrete Institute, p. 9-14. ISSN: <http://www.ceric.net/wonmun2/kci/KCI_3_2008_2_1_9%28C%29.pdf> [consult: 17/03/2012].
- NATH, U. K. & BARUA, P. B. (2004). Optimization of concrete mixture proportioning using Taguchi's method. In: The Indian Concrete Journal, Vol. 78, No. 9, Maharashtra (India): ACC Ltd., p. 52-56.
- NOGUCHI, T.; MARUYAMA, I. & KANEMATSU, M.; (2003). Performance based design for concrete mixture with multi-optimizing Genetic Algorithm. In: The 11th International Congress on the Chemistry of Cement (ICCC): "Cement's contribution to the development in the 21st Century (11-16/05/2003), Durban (South Africa): Cement & Concrete Institute. Proceedings (Editors: G. Grieve & G Owens), p. 1921-1930. ISBN: 0-9584085-8-0. Publication by Tech Books International, ISBN: 8-1883051-0-3
- NOGUCHI, T.; TOMOSAWA, F.; NEMAT, K. M.; CHIAIA, B. M. & FANTILLI, A. P. (2009). A practical equation for elastic modulus of concrete [on line]. In: ACI Structural Journal, Vol. 106, No. 5, Farmington Hills (USA): American Concrete Institute: p. 690-696. ISSN: 0889-3241 <http://faculty.washington.edu/nemati/aci_str1.pdf> [consult: 17/03/2012].
- OH, J.W.; LEE, G.W. & LEE, I.W. (1997). The Proportioning of Concrete Mixture using Artificial Neural Networks. In: Seventh International Conference on Computing in Civil and Building Engineering – ICCCBE VII 1997 (19-21/08/1997), Seoul (Korea): The International Society for Computing in Civil and Building Engineering. Proceedings, p. 1057-1512. ISBN: 978-8995004234.
- OUICIEF, H.; HABITA, M.F. & REDJEL, B. (2006). Hybrid fiber reinforced self-compacting concrete: hardened properties [on line]. In: International Journal of Civil Engineering, Vol. 4, No. 2, Tehran

- (Iran): Iran University of Science and Technology (IUST) & Iranian Society of Civil Engineering, p. 77-85. ISSN: 1735-0522. <http://ijce.iust.ac.ir/browse.php?a_id=346&sid=1&slc_lang=en> [consult: 17/03/2012]
- PONCE C., P. (2010). Inteligencia artificial con aplicaciones a la ingeniería. México D.F. (México): Alfaomega. ISBN: 978-6077854838.
- POPOVICS, S. (1998). History of a mathematical model for strength development of Portland cement concrete. In: *ACI Materials Journal*, Vol. 95, No. 5, Farmington Hills (USA): American Concrete Institute, p. 593-600. ISSN: 0889-325X.
- RICHARDSON, A.E. & LANDLESS, S. (2009). Synthetic fibres and steel fibres in concrete with regard to bond strength and toughness [on line]. In: *Northumbria Built Environment Research Papers*, Vol. 2, No. 2, Newcastle upon Tyne (UK): Northumbria University, p. 128-140. ISSN: 1756-2473. <<http://nrl.northumbria.ac.uk/2269/1/Synthetic%20fibres%20and%20steel%20fibres%20in%20concrete%20with%20regard%20to%20bond%20strength%20and%20toughness.pdf>> [consult: 17/03/2012].
- RICHARDSON, A. E. (2006). Compressive strength of concrete with polypropylene fibre additions [on line]. In: *Structural Survey*, Vol. 24, No. 2, Newcastle upon Tyne (UK): Northumbria University, p. 138-153. ISSN: 0263-080X. <<http://nrl.northumbria.ac.uk/360/1/Compressive%20strength%20of%20concrete%20with%20polypropylene%20fibre%20additions.pdf>> [consult: 17/03/2012].
- ROESLER, J.; PAULINO, G.; GAEDICKE, C.; BORDELON, A. & PARK, K. (2006). Fracture behavior of functionally graded concrete materials (FGCM) for rigid pavements. *Tech Note 33. Urbana (USA): Center Excellence Airport Technology, University of Illinois, (Jul.)*, 18 p.
- RUMELHART, D.E.; HINTON, G.E. & WILLIAMS, R.J. (1986). Learning internal representations by error propagation. In: D. E. RUMELHART, D. E. & McCLELLAND, J. L. (eds.). *Parallel distributed processing: Explorations in the microstructure of cognition*, Vol. 1, Chapter 8, p. 318-362. Cambridge (USA): MIT Press. ISBN: 0-262-68053-X.
- SALIH, S.A. & JASIM, A.T. (2009). Performance of fiber ligh-weigh aggregate concrete exposed to elevated temperatures [on line]. In: *Engineering and Technology Journal*, Vol. 27, No. 13, Baghdad (Iraq): University of Technology Iraq, p. 2393-2410. ISSN: 1681-6900. <http://uotechnology.edu.iq/tec_magaz/volume272009/No.13,2009/researches/Text%20%2810%29.pdf> [consult: 17/03/2012].
- SÁNCHEZ DE GUZMÁN, D. (2000). *Tecnología del concreto y del mortero*. Bogotá (Colombia): Bhandar Editores, 349p. ISBN: 978-9589247044.
- SHARIF, Mohammad Showkat Hossain. (2005). *Resistance of plain and fibre-reinforced high-strength concrete to projectile impact*. Thesis (Master of Engineering), Kent Ridge (Singapore): National University of Singapore, 125p.
- TABARES, H.; BRANCH, J. & VALENCIA, J. (2006). Generación dinámica de la topología de una red neuronal artificial del tipo Perceptrón multicapa. En: *Revista Facultad de Ingeniería*, No. 38, Medellín (Colombia): Universidad de Antioquia, p. 146-162. ISSN: 0120-6230.
- THE ABERDEEN GROUP (1983). Concrete reinforced with polypropylene fibers: Used as secondary reinforcement, plastic fibers help reduce shrinkage and control cracking. In: *Concrete Construction*, June 1983, 3p. Publication No. C830468. Boston (USA): The Aberdeen Group.
- TROCÓNIS DE RINCÓN, O.; CONTRERAS, D.; SÁNCHEZ, M.; FERNÁNDEZ DE ROMERO, M.; BRAVO, J.; MORÓN DE BRAVO, O.; VEZGA, C.; FERNÁNDEZ, R.; NAVARRO, A.; SARCOS, A.; (2006). Avaliação/reabilitação de estruturas em ambientes marítimos. Caso histórico: Ponte de Maracaibo [on line]. Em: *Corrosão e Protecção de Materiais*, Vol. 25, No. 3, Lisboa (Portugal): Instituto Nacional de Engenharia, Tecnologia e Inovação, p. 74-91. ISSN: 0870-1164. <<http://www.scielo.oces.mctes.pt/pdf/cpm/v25n3/v25n3a01.pdf>> [consult: 17/03/2012].
- WANG, J. Z.; NI, H. G. & HE, Y. J. (1999). The application of automatic acquisition of knowledge to mix design of concrete [on line]. In: *Cement and Concrete Research*, Vol. 29, No. 12, Laussane (Switzerland): Pergamon, Elsevier Ltd., p. 1875-1880. ISSN: 0008-8846. <http://ac.els-cdn.com/S0008884699001520/1-s2.0-S0008884699001520-main.pdf?_tid=8285c828452ac2546b28aa627e375d40&acdnat=1332252027_472a3a49006c0df2e9a8e655a470d02d> [consult: 17/03/2012].
- WANG, J. Z.; WANG, X. J. & NI, H. G. (2003). An Algorithm of Neural Network and Application to Data Processing in Concrete Engineering [on line]. In: *Informatika*, Vol. 14, No. 1, Vilnius (Lithuania):

- Institute of Mathematics and Informatics, IOS Press Amsterdam (The Netherlands) p. 95-110. ISSN: 0868-4952. <<http://www.mii.lt/informatica/pdf/INFO430.pdf>> [consult: 17/03/2012].
- WON, C. M. (2004). Use of short fibres in structural concrete to enhance mechanical properties. Thesis (Bachelor of Engineering Civil), Toowoomba (Australia): University of Southern Queensland, 182p.
- YEH, I. C. (1999). Design of high-performance concrete mixture using neural networks and nonlinear programming [on line]. In: Journal of Computing in Civil Engineering, Vol. 13, No. 1, Reston (USA): ASCE, p. 36-42. ISSN: 0877-3801. <<http://civilprojects.files.wordpress.com/2007/03/design-of-hpc-288.pdf>> [consult: 17/03/2012].
- YEH, I. C. (2009). Optimization of concrete mix proportioning using a flattened simplex-centroid mixture design and neural networks [on line]. In: Engineering with Computers, Vol. 25, No. 2, New York (USA): Springer p. 179-190. ISSN: 1435-5663. <<http://www.springerlink.com/content/q0t10j2372648050/fulltext.pdf>> [consult: 17/03/2012].