

El uso de las Redes Neuronales Artificiales en la modelización de la evolución temporal de la resistencia del concreto de altas prestaciones

Artificial Neural Networks in modelling the time evolution of high performance concrete resistance

Francisco García Fernández¹, Ana Torre Carrillo², Pedro Espinoza Haro³, Luis Acuña Pinaud³, Isabel Moromi Nakata²

¹ Dpto. Ingeniería Forestal. Universidad Politécnica de Madrid. Ciudad Universitaria S/N, 28040 Madrid, España

² Facultad de Ingeniería Civil, Universidad Nacional de Ingeniería. Av. Túpac Amaru, 210. Lima 25, Perú

³ Facultad de Ingeniería Industrial y de Sistemas. Universidad Nacional de Ingeniería. Av. Túpac Amaru, 210. Lima 25, Perú

DOI: <https://doi.org/10.33017/RevECIPeru2014.0001/>

Resumen

El concreto de altas prestaciones es un material relativamente reciente ya que su utilización data de finales de los 60s. Sin embargo, innumerables ventajas hacen que cada vez sea utilizado más en la construcción. Su fabricación parte del concreto estándar al que se le añaden una serie de aditivos como microsílíce o cementantes que le confieren unas mejores prestaciones respecto al concreto estándar como un aumento de la resistencia cercano al 100%.

Las propiedades de este concreto recién están siendo estudiadas en detalle y actualmente no hay muchos estudios acerca de la influencia de los aditivos en la resistencia, optimización de las formulaciones o su evolución de la resistencia a compresión con el tiempo de curado. De todas las propiedades mecánicas del concreto, la resistencia a compresión a los 28 días es la más utilizada para su control de calidad.

En este estudio se va a analizar la evolución de dicha propiedad en función del tiempo y de la cantidad de cemento por metro cúbico mediante el uso de una red neuronal artificial.

Las redes neuronales artificiales son unas estructuras matemáticas con una gran capacidad de modelización numérica, especialmente cuando las relaciones entre las variables implicadas en el proceso son complejas o no obedecen a ecuaciones matemáticas sencillas. Se pueden considerar como conjunto complejo de funciones no lineales (funciones de transferencia o neuronas) interconectadas entre si, capaces de autoajustarse a partir de unas variables de entrada y salida conocidas. Podríamos decir que son modelos de regresión múltiple en los que no se conoce el algoritmo o la expresión que permita alcanzar la solución, o éstos sean tan sumamente complicados que imposibilitan su utilización. Se inspiran en las redes neuronales biológicas. Son capaces de aprender a partir de una serie de ejemplos, sin necesidad de conocer a priori las relaciones que pudieran existir entre las variables implicadas en el proceso, ajustando los pesos de las relaciones entre ellas, para posteriormente predecir un resultado coherente cuando se introducen nuevos desconocidos en la red.

Estas estructuras han sido ampliamente utilizadas para la obtención de las propiedades mecánicas de distintos materiales como el cemento en los que se busca predecir la resistencia a la compresión después del proceso de curado a partir de datos iniciales; algunos metales o el basalto. Para el tablero de partículas también se han utilizado para modelizar su cohesión interna a partir de parámetros de fabricación o sus propiedades mecánicas de resistencia a la flexión, módulo de elasticidad y resistencia interna a partir de ensayos físicos a fin de predecir posibles fallos en la producción sin tener que esperar a realizar dichos ensayos mecánicos.

La red obtenida en este estudio presenta un coeficiente de correlación de 0.90 lo que la hace especialmente apta para la modelización que se pretende llevar a cabo. La modelización se ha realizado con periodos de curado entre 7 y 56 días. Estudios posteriores con periodos de curado superiores permitirán ratificar los resultados iniciales de este estudio.

Descriptores: *Concreto de altas prestaciones, resistencia a compresión, redes neuronales artificiales*

Abstract

The high performance concrete is a relatively recent material and its use dates of final of the 60's. However, countless advantages make it to be used more and more in the construction. Its manufacturing comes from the standard concrete to which a series of additives as microsilica or cementitious are added. These additives confer the concrete some better benefits regarding the standard concrete as an increase of the near resistance up to 100%.

The mechanical properties of this concrete newly are being studied in detail and at the moment there are not many studies about the influence of the additives in the resistance, formulation optimizations or the evolution of the resistance to compression with the time of curing. Over all the mechanical properties of the concrete, the resistance to compression after 28 days of curing is the most used one in control of quality.

In this study the influence of curing time and cement quantity in the compression resistance are studied by means an artificial neural network.

Artificial neural networks can be regarded as a complex group of interconnected non-linear functions (transfer functions or neurons) capable of self-adjusting using known input and output data. It could be said that these networks are multiple regression models in which the algorithm allowing a solution to be reached is unknown, or where the enormous complexity of the algorithm makes it impossible to use. These networks are based on biological neural networks. They are capable of learning by using a series of examples, without the need to know beforehand the relations which may exist between the variables involved in the process, by adjusting the weight of the relations between the variables in order to then predict a coherent result when new data unknown to the network is entered.

These structures have been widely used to obtain the mechanical properties of different materials as cement where have been used to predict the compression resistance after the curing process by means of the initial data; some metals or the basalt. They have been used too in wood-based panels to predict their internal bond strength by means of parameters of production or their mechanical properties of modulus of rupture, modulus of elasticity or internal bond strength by means of physical tests in order to predict possible shortcomings in the production without having to wait to carry out those mechanical tests.

The net obtained in this study presents a coefficient of correlation of 0.90 that makes it especially capable for the present modelling. The modeling of resistance has been carried out with curing periods between 7 and 56 days. Later studies with superior curing periods will allow to ratify the initial results of this study.

Keywords: *High performance concrete, compression resistance, artificial neural networks*

1. Introducción

El Instituto Americano del Concreto (ACI) declara al concreto de alta resistencia cómo aquel cuya resistencia a compresión es superior a 420 kg/cm². Su uso es relativamente reciente, ya que no fue hasta 1968 cuando fue utilizado por primera vez en la construcción de las columnas inferiores del edificio Lake Point Tower en Chicago, arrojando una resistencia a compresión de 520kg/cm².

Sus principales mejoras respecto al concreto estándar radican en un aumento de la resistencia, tanto a compresión, a tracción, a flexión o de comportamiento frente al impacto y perforación.

Una de sus principales ventajas relacionadas con su aumento de la resistencia es la reducción de los tamaños de los elementos estructurales y, por consiguiente, el peso de la estructura y el precio de la misma. Así mismo, también consecuencia de su mayor fluidez, es posible bombearlo a mayores alturas o colocarlo en zonas congestionadas de acero de refuerzo.

Es ideal para proyectos que soporten altas demandas de carga como por ejemplo, muros de rigidez, columnas y vigas de edificios de gran altura, bóvedas de seguridad o estructuras costeras o militares.

Sin embargo, no todo son ventajas, ya que exige de un control de calidad de las materias primas muy riguroso y de un curado muy vigilado.

Así mismo, este aumento de uso en los últimos años, no ha llevado consigo un aumento en la investigación de sus propiedades en función de sus componentes o de la evolución de la resistencia en función del tiempo.

Este estudio ofrece una primera aproximación de la evolución de la resistencia a compresión del concreto mediante el uso de redes neuronales artificiales a partir de la cantidad de cemento utilizado y del tiempo de curado.

En este aspecto, las redes neuronales han demostrado su alta capacidad de modelización especialmente cuando las relaciones entre las variables implicadas en el proceso son complejas o no obedecen a ecuaciones matemáticas sencillas [1]

En los últimos años han tenido un gran desarrollo en el control de procesos industriales debido, principalmente, a su capacidad de modelar relaciones complejas que los sistemas tradicionales no han sido capaces de hacer y predecir satisfactoriamente si las características de un producto se adecuan o no a las especificaciones correspondientes [2].

Estas estructuras han sido ampliamente utilizadas para la obtención de las propiedades mecánicas de distintos materiales como el cemento [3-6] en los que se busca predecir la resistencia a la compresión después del proceso de curado a partir de datos iniciales; algunos metales [7-11] o el basalto [12].

2. Materiales y Métodos

Para la realización de este estudio se han fabricado de acuerdo a la norma ASTM C 192/C 192M [13] 296 probetas de concreto fabricados con distintos tipos y cantidades de cemento, arena, cementante y microsílíce. Los ensayos de compresión se han realizado en el Laboratorio de Ensayo de Materiales de la Universidad Nacional de Ingeniería, según la norma ASTM C39/C 39M [14] tras diferentes periodos de curado.

Los ensayos de compresión axial se realizaron en una máquina TONI-TECHNIK provista de una célula de 3.000KN y TINIUS OLSEN DE 1.500KN. De todas las probetas se tomaron datos, que actuaron como variables de entrada, de cantidad de cemento, cantidad de arena, cantidad de cementante, cantidad

de microsílíce, así como periodo de curado. Como variable de salida se tomó la resistencia a la compresión. La cantidad de agua, cantidad de piedra, los módulos de finura de arena y piedra, el tamaño nominal máximo de la piedra y los pesos específicos de la piedra y arena se mantuvieron constantes.

- 1) Cemento de altas prestaciones: En este estudio se han utilizado cementos de altas prestaciones de acuerdo a la guía ACI 211.4R [15].
- 2) Agua: En este estudio se ha utilizado agua potable acorde a los requisitos de fabricación del concreto
- 3) Módulo de finura: En este estudio se ha utilizado arena de módulo de finura de 2.87 y piedra de módulo de finura de 6.5.
- 4) TNM piedra: En este estudio se ha utilizado un tamaño nominal máximo de piedra de 1".
- 5) Arena: En este estudio se ha utilizado arena de un peso específico de 2.7Ton/m³
- 6) Piedra: En este estudio se ha utilizado piedra de un peso específico de 2.7 Ton/m³
- 7) Peso específico de los agregados: Se define como el peso por unidad de volumen. En el presente estudio se han utilizado agregados del país con valores dentro del rango de 2.500 a 2.800 kg/m³
- 8) Cementante: Se ha utilizado porcentajes de cementante entre 1.6% y 2.5%
- 9) Microsílíce: Se ha utilizado porcentajes de microsílíce entre 5% y 10%
- 10) Edad de ensayo: En el presente estudio se han tomado un rango de periodos de curado entre 7 y 56 días.

Para un óptimo control del proceso de curado las probetas se mantuvieron en balsas de agua en el laboratorio.

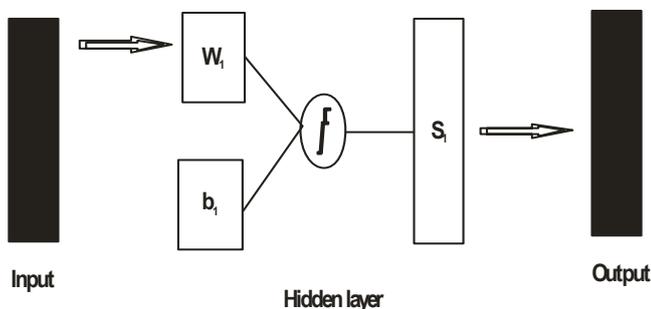
Previo al desarrollo de la red neuronal se procedió a un análisis de componentes principales, Tomando como criterio de corte que la contribución a la variabilidad de la muestra fuera inferior al 2% [16]

El perceptrón multicapa (Figura. 1) lo podríamos definir como un sistema computacional que imita las capacidades computacionales de los sistemas biológicos utilizando un gran número de elementos interconectados. Su carácter de aproximador universal de funciones [17] le permite modelizar complejas relaciones no lineales, extrayendo el conocimiento a partir de una serie de ejemplos para luego aplicarlo a situaciones desconocidas.

Se compone de tres capas denominadas capa de entrada, capa oculta y capa de salida. La capa de entrada es la que recibe las señales de las variables de entrada y las distribuye a la siguiente capa, la capa oculta. La capa oculta, formada por una o más subcapas, es la encargada de realizar las operaciones matemáticas destinadas a obtener una salida. Finalmente la capa de salida es la encargada de mostrar el resultado de las operaciones realizadas en la capa oculta.

el de comprobación. Los dos primeros se utilizaron durante la fase de entrenamiento y en la prevención del sobreentrenamiento respectivamente. El tercer subconjunto se utilizó para evaluar el grado de fiabilidad de la red [23].

Como función de transferencia se ha utilizado la tangente hiperbólica sigmoidea (Ecuación 1), matemáticamente equivalente a la tangente hiperbólica pero que mejora el funcionamiento de la red [16].



$$f(x) = \frac{2}{1 + e^{(-2x)}} - 1 \tag{1}$$

$f(x)$.- Valor de salida de la neurona
 x .- Valor de entrada de la neurona

Figura1. Esquema de un perceptrón multicapa.

Todos los valores de las variables, tanto las independientes como la dependiente, se normalizaron para una mejor efectividad de la función de transferencia (Ecuación 2) [16].

El diseño de perceptrón multicapa es un proceso lento y complejo. El número de neuronas de la capa de entrada está delimitado por la dimensión de los vectores de entrada. De la misma forma, el número de neuronas de la capa de salida está determinado por la dimensión del vector salida. Sin embargo, no hay una regla definida para determinar si la capa oculta debe tener una o varias subcapas, ni cuántas neuronas debe tener cada una, por lo que el único método para configurar la capa oculta es mediante prueba y error [18]. Sí existen algunas recomendaciones para garantizar la convergencia de la solución optimizando sus parámetros internos en función del número de datos disponibles [19-21]. Por otra parte, también hay que tener en cuenta que un número muy pequeño de neuronas en las capas ocultas impide una buena generalización por parte de la red y que excesivo número de neuronas en las capas internas puede dificultar enormemente el proceso de aprendizaje sin mejorar sustancialmente los resultados finales [22].

$$X' = \frac{X - X_m}{s} \tag{2}$$

X' : Valor después de normalización del vector X
 X_m : Media del vector del vector X
 s : Desviación típica del vector del vector X

A esto hay que añadirle a una serie de condiciones que se deben cumplir para que la red realice su función con las garantías suficientes, entre ellas evitar el sobreentrenamiento [23] que redundaría negativamente en la capacidad de generalización de la red.

Como algoritmo de entrenamiento se ha utilizado la retropropagación resiliente, el cuál mejora notablemente los resultados para el caso de funciones de transferencia sigmoidea [16].

Para evaluar el resultado final se va a utilizar el coeficiente de regresión (R), el coeficiente de determinación (R^2), la raíz del error cuadrático medio ($RMSE$).

3. Resultados y Discusión

Los resultados obtenidos en el ensayo a compresión se detallan en la siguiente tabla (Tabla 1).

Tabla 1: Resultados de los ensayos. Mf_a : módulo de finura de arena; Mf_p : módulo de finura de piedra; TNM : Tamaño nominal máximo de piedra; PE_a : peso específico arena; PE_p : Peso específico piedra; E_{ens} : Edad del ensayo; R : Resistencia a compresión.

Constantes			
Agua (L/m^3)	Mf_a	Mf_p	TNM
186.4	2.87	6.5	1
Stone (kg/m^3)	PE_a (Ton/m^3)	PE_p (Ton/m^3)	

Para evitar el sobreentrenamiento y calcular el grado de fiabilidad de la red, el conjunto inicial de datos se ha dividido en tres subconjuntos de forma aleatoria: el subconjunto de entrenamiento, el de validación y

1066.2	2.7	2.7
--------	-----	-----

modelización de las propiedades mecánicas de aleaciones de aluminio

Por lo tanto, dado que los resultados obtenidos están dentro de los márgenes considerados por otros autores como aceptables en sus trabajos de investigación, podemos considerar la red desarrollada como apta para la modelización del ensayo de compresión del concreto de altas prestaciones.

El resultado de la modelización temporal de la resistencia se puede ver en el siguiente gráfico (Figura 2).

Variables			
Cemento (kg/m ³)	Arena (kg/m ³)	% cementante	
632.5	376.2	2.1	Media
63.3	82.3	0.3	D.Típica
506.0	282.5	1.6	Min.
708.3	546.9	2.5	Max
% microsílíce	E _{ens} (días)	R (kg/cm ²)	
7.2	-	752.3	Media
2.1	-	95.8	D.Típica
5	7	565	Min.
10	56	1022	Max

El análisis de componentes principales determinó que la contribución de cada una de las variables a la variabilidad de la muestra era superior al 2%

La red óptima obtenida es un perceptrón multicapa con tres capas ocultas de 7, 7 y 5 neuronas cada una.

Los resultados de los procesos de entrenamiento, validación y comprobación se recogen en la siguiente tabla (Tabla 2).

Tabla 2: Resultados del proceso de desarrollo de la red.

RED	Conjunto	R	R ²	RMSE
Perceptron [5 7 7 5 1]	Entrenamiento	0.92	0.84	36.6
	Validación	0.94	0.88	32.5
	Comprobación	0.90	0.82	34.6

Los coeficientes de determinación obtenidos, superiores a 0.82, indican que el modelo desarrollado es capaz de explicar al menos el 82% de la variabilidad de la muestra.

Los coeficientes de correlación, comprendidos entre 0.93 y 0.98, que se han obtenido durante el proceso de desarrollo de la red, son coherentes con los obtenidos por otros autores consultados, los cuales obtuvieron coeficientes de correlación entre 0.81 y 0.98 [6, 24-27].

Así mismo, estos resultados son similares a los que otros autores han obtenido al aplicar las redes neuronales artificiales a otros materiales. Así Malinov et al., [8] obtuvieron correlaciones entre 0.60 y 0.97 y Mc Bride et al., [28] obtuvieron coeficientes de correlación entre 0.94 y 0.97 ambos en la

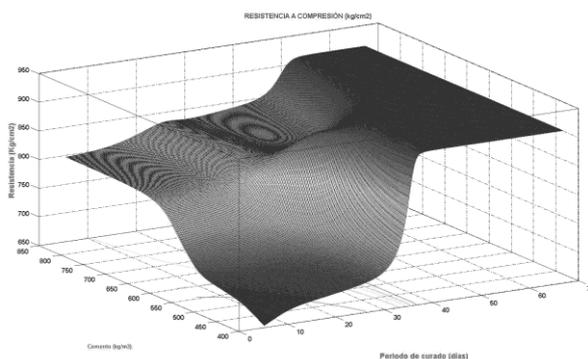


Figura 2. Evolución de la resistencia en función de la cantidad de cemento y el periodo de curado.

La resistencia media alcanzada, 752 kg/cm², es muy superior a la del concreto estándar que oscila alrededor de 224 kg/cm², así mismo la resistencia mínima obtenida, 565 kg/cm², es un 50% superior a la resistencia máxima del concreto estándar (369 kg/cm²) [27].

Se observa una evolución de la resistencia a compresión del concreto que parece alcanzar su máximo entre los 35 y los 50 días de curado dependiendo de la cantidad de cemento utilizada en su fabricación, alcanzando resistencias superiores a 890 kg/cm² (Figura 3).

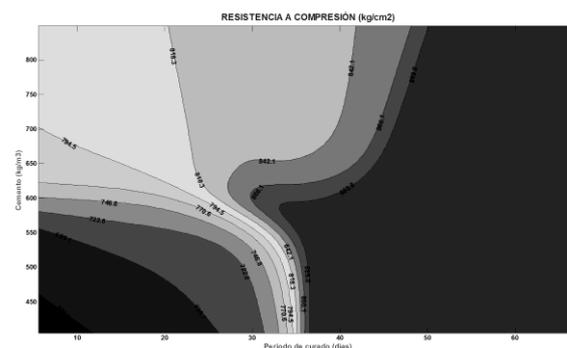


Figura 3. Curvas de nivel de la evolución de la resistencia en función de la cantidad de cemento y el periodo de curado.

Esto parece estar en consonancia con la bibliografía consultada [15, 29] en los cuales, dependiendo del tipo de concreto, se puede apreciar cómo a partir de los 40 días se ha alcanzado casi la resistencia máxima.

Investigaciones posteriores servirán para afianzar los resultados de este estudio.

4. Conclusiones

Las redes neuronales se han mostrado como una herramienta eficaz en la modelización de la evolución con el tiempo de la resistencia del concreto de altas prestaciones.

La resistencia del concreto de altas prestaciones es superior en un 100% a la del concreto estándar.

Todo parece indicar que la resistencia máxima de este tipo de concreto se alcanza pasados los 50 días de curado independientemente de la cantidad de cemento utilizada en su fabricación.

5. Agradecimientos

Este trabajo desarrollado se enmarca dentro del Proyecto de Investigación Proyecto PIAP-1-P-676-13 financiado por FINCyT, dentro del Programa de Proyectos de Investigación Aplicada 2013.

6. Referencias

- [1] E. Martinelli, A.B. Koenders, A.Caggiano, A numerical recipe for modelling hydration and heat flow in hardening Concrete, *Cement & Concrete Composites*: 40, 48–58 (2013).
- [2] Sukthomya, W. y J. Tannock, The training of neural networks to model manufacturing processes, *Journal of Intelligent Manufacturing*: 16, 39-51 (2005).
- [3] Baykasoğ, A., T. Delhi y S. Tanış, Prediction of cement strength using soft computing techniques, *Cement and Concrete Research*: 34, 2083-2090 (2004).
- [4] Bilim, C., C.D. Atış, H. Tanyildizi, y O. Karahan, Predicting the compressive strength of ground granulated blast furnace slag concrete using artificial neural networks, *Advances in Engineering Software*: 40, 334-340 (2009).
- [5] Saridemir, M., Prediction of compressive strength of concretes containing metakaolin and silica fume with neural networks, *Advances in Engineering Software*: 40, 350-355 (2009).
- [6] Oztas, A., M. Pala, E. Ozbay, E. Kanka, A. Caglar y M.A. Bhatti, Predicting the compressive strength and slum of high strength concrete using neural network, *Construction and Building Materials*: 20-9, 769-775 (2006).
- [7] Mukherjee, A.; Schmauder, S.; Rühle, M. Artificial neural networks for the prediction of mechanical behaviour of metal matrix composites. *Acta Metallurgica et Materialia*: 43, 4083-4091 (1995).
- [8] Malinov, S.; Sha, W.; McKeown, J.J. Modelling the correlation between processing parameters and properties in titanium alloys using artificial neural networks. *Computational Materials Science*: 21-3, 375-394 (2001).
- [9] Hassan, A.M.; Alrashdan, A.; Hayajneh, M.T.; Mayyas, A.T. Prediction of density, porosity and hardness in aluminium-cooper-based composite materials using artificial neural network. *Journal of Materials Processing Technology*: 209-2, 894-899 (2009).
- [10] Ozerdem, M.S.; Kolukisa, S. Artificial neural network approach to predict the mechanical properties of Cu-Sn-Pb-Zn-Ni cast alloys. *Materials & Design*: 30-3, 764-769 (2009).
- [11] Reddy, N.S.; Krishnaiah, J.; Hong, S.G.; Lee, J.S. Modeling medium carbon steels by using artificial neural networks. *Materials Science and Engineering A-Structural Materials Properties Microstructure and Processing*: 508, 93-105 (2009).
- [12] Çanakci, H. y M. Pala, Tensile strength of basalt from a neural network, *Engineering Geology*: 94, 10-18 (2007).
- [13] ASTM C 192/C 192M: The American Society for Testing Materials Standard Practice for Making and Curing Concrete Test Specimens in the Laboratory, West Conshohocken (PA), USA (2000).
- [14] ASTM C 39/C 39M: The American Society for Testing Materials, Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens, West Conshohocken (PA), USA (2001).
- [15] ACI 211.4R: American Concrete Institute. Guide for selecting proportions for high-strength concrete with Portland cement and fly ash. Farmington Hills (MI), USA. (1993)
- [16] Demuth, H., M. Beale y M. Hagan, *Neural Network Toolbox User's Guide, Version 4*, The MathWorks Inc., Natick, USA (2002).

- [17] Hornik, K., Multilayer Feedforward Networks are Universal Approximators, *Neural Networks*: 2, 359-366 (1989).
- [18] Lin T.Y. y C.H. Tseng, Optimum design for artificial networks: an example in a bicycle derailleur system, *Engineering Application of Artificial Intelligence*: 13, 3-14 (2000).
- [19] Lawrence, S.; Giles, C.G.; Tsoi, A.C. 1996. What size neural network gives optimal generalization? Technical Reprot UMIACS-TR-96-22 and CS-TR-3617, Institute for Advanced Computer Studies, University of Maryland, College Park MD 20742. <http://clgiles.ist.psu.edu/papers/UMD-CS-TR-3617.what.size.neural.net.to.use.pdf> Acceso: 12 de mayo (2014).
- [20] Sha, W.; Edwards, K.L. The use of artificial neural networks in materials science based research. *Materials & Design*: 28-6, 1747-1752 (2007).
- [21] Xu, J. A genetic neural network for predicting materials mechanical properties. *Third International Conference on Natural Computation ICNC 2007*, 710-714 (2007)
- [22] Cheng C.S., A multi-layer neural network model for detecting changes in the process mean, *Computers and Industrial Engineering*: 28, 51-61 (1995)
- [23] Bishop, C.M., *Neural networks for pattern recognition*, Oxford University Press, Oxford, Gran Bretaña (1995)
- [24] Lee, S.C., Prediction of concrete strength using artificial neural networks, *Journal of Engineering Structure*: 25, 849-857 (2003).
- [25] Ukrainczyk, N. y V. Ukrainczyk; A neural network method for analysing concrete durability, *Magazine of Concrete Research*: 60(7), 475-486 (2008).
- [26] Yaprak, H., A. Karaci, y I. Demir, Prediction of the effect of varying cure conditions and w/c ratio on the compressive strength of concrete using artificial neural networks, *Neural Computing and Applications*: 22, 133-141 (2013).
- [27] L. Acuña Pinaud, A. Torre Carrillo, I. Moromi Nakata, F. García Fernández. El uso de las Redes Neuronales Artificiales en la modelización del ensayo a compression del concreto según la norma ASTM C39/C 39M. *Información Tecnológica*. 25(4). En prensa.
- [28] McBride, J., S. Malinov, y W. Sha, Modelling tensile properties of gamma-based titanium aluminides using artificial neural network, *Material Science and Engineering A*: 384, 129-135 (2004).
- [29] Yeh, I.C., Modeling of strength of high-performance concrete using artificial neural networks, *Cement and Concrete Research*: 28(12), 1797-1808 (1998).