

MODELIZACIÓN DE LA RESISTENCIA A LA COMPRESIÓN DEL CONCRETO MEDIANTE REDES NEURONALES ARTIFICIALES

MODELIZACIÓN OF THE COMPRESSIVE STRENGTH OF CONCRETE USING ARTIFICIAL NEURAL NETWORKS

Leoncio Luis Acuña Pinaud¹, Ana Victoria Torre Carrillo², Isabel Moromi Nakata³, Pedro Celino Espinoza Haro⁴, Francisco García Fernández⁵

RESUMEN

El uso del concreto como elemento estructural va aumentando año tras año. Sin embargo, este producto requiere de unos estrictos controles de calidad sobre sus propiedades mecánicas para el uso como elemento estructural. Este tipo de control implica la existencia de equipos de ensayo con una capacidad de carga de hasta 3.000KN. Sería de gran utilidad para el control de producción la utilización de un método alternativo de gran fiabilidad, que permitiera conocer las propiedades mecánicas a partir de otras propiedades físicas y mecánicas más fáciles de obtener. La alta capacidad de las redes neuronales artificiales (ANN) para modelar los más diversos procesos industriales, las convierte en una herramienta de gran utilidad en el ámbito de la industria del concreto. En este estudio se ha desarrollado una red neuronal para obtener la resistencia a compresión del concreto y se ha modelado dicha propiedad a partir de la composición del concreto y de sus parámetros de fabricación. La red neuronal diseñada, un perceptrón multicapa, ha permitido obtener la resistencia a compresión del concreto con un coeficiente de correlación de 0,97. Esto demuestra la capacidad de las redes neuronales artificiales para obtener la resistencia a compresión del concreto.

Palabras clave.- Concreto, Resistencia a compresión, Redes neuronales artificiales.

ABSTRACT

The use of concrete as a structural element increases year by year. However, this product needs very stringent control of its mechanical properties in order to be used as structural element. This type of control requires to have very large testing equipment with a load capacity of up to 3.000KN. Production control would benefit greatly from the use of a highly reliable alternative method that would enable the mechanical properties to be found through more easily obtained physical and mechanical properties. The high capacity of artificial neural networks (ANN) to model a broad range of industrial processes makes them a very useful instrument in the concrete industry. In this study, one neural network was developed to obtain the properties of compressive strength. This property was then modeled through the composition of concrete and manufacturing parameters. The network designed, a multilayer perceptron, allowed the compression strength to be obtained with a regression coefficient of 0,97. This demonstrates the effectiveness of ANN for obtaining the mechanical properties of compression strength of concrete.

Key words.- Concrete, Compression strength, Artificial neural networks.

¹Mag. Investigador de la Facultad de Ingeniería Industrial y de Sistemas de la Universidad Nacional de Ingeniería, ²Ing. de la Facultad de Ingeniería Civil de la Universidad Nacional de Ingeniería, ³Ing. Docente investigadora de la Facultad de Ingeniería Civil de la Universidad Nacional de Ingeniería, ⁴Doctor de la Universidad Politécnica de Madrid. Departamento de Ingeniería Forestal, ⁵Investigador de la Universidad Politécnica de Madrid. Departamento de Ingeniería Forestal.

INTRODUCCIÓN

El ensayo de compresión de concreto es uno de los más importantes a la hora de comprobar la aptitud de los bloques fabricados y un parámetro muy empleado por los ingenieros para el control de calidad.

Las características y propiedades del concreto, como material compuesto, dependen de las proporciones y características de sus componentes. Existen diversos procedimientos para determinar las proporciones de estos componentes, en base a los módulos de finura de los agregados, el tamaño máximo de la piedra y los pesos específicos del cemento y los agregados. Aunque en la práctica la referencia para la estimación de la resistencia del concreto es la relación agua cemento, la influencia de los otros factores es innegable. La resistencia a la compresión del concreto se determina ensayando las probetas a distintas edades. Se obtienen así valores que se pueden graficar observándose que, a los 7 días el concreto presenta una resistencia del 70-75% de su resistencia a los 28 días, considerando que a los 28 días se ha obtenido el 100% de su resistencia.

Los resultados de las pruebas de resistencia a partir de cilindros moldeados se utilizan para fines de control de calidad, aceptación y/o rechazo del concreto, para estimar la resistencia del concreto de las estructuras, para programar las operaciones de construcción (desencofrados), etc. Por esta razón, la obtención de modelos matemáticos que relacionen las características de los componentes del concreto con su resistencia a compresión permitiría agilizar el control en obra reduciendo considerablemente los tiempos de espera y aumentando la seguridad.

Las redes neuronales artificiales son unas estructuras matemáticas que intentan imitar el funcionamiento de un cerebro biológico. Se componen de una serie de nodos o neuronas, interconectados entre sí, y estructurados en una serie de capas. La capa de entrada recibe las señales del exterior y es la encargada de distribuir dichas señales hacia la capa interna (Figura 1). La capa interna es la que realiza los cálculos necesarios a fin de obtener una salida. Y finalmente la capa de salida es la que muestra los resultados de la red. Estas estructuras son capaces de extraer conocimiento de una serie de datos de

ejemplo, para luego aplicarlo a datos desconocidos. Las podemos asimilar a 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 imposibiliten su utilización [1]. El número de neuronas en la capa de entrada se corresponde con la dimensión del vector de los datos de entrada y el número de neuronas de la capa de salida se corresponde con la dimensión del vector salida. Por el contrario, no existe una regla definida que nos indique cuántas neuronas debe tener la capa oculta y si ésta debe estar formada por una o más subcapas, sólo una serie de recomendaciones respecto al número de neuronas que debe haber en función de los datos disponibles, por lo que la única forma de obtener su estructura es mediante prueba y error [2].

Este método de análisis ha sido ampliamente utilizado en muy diversos campos, desde sistemas de guiado automático de aviones o automóviles, a sistemas de identificación de armamento o evolución de los mercados bursátiles [3 y 4]. En el campo de la resistencia de materiales se ha aplicado a diferentes propiedades y materiales. Así se ha utilizado para modelizar la resistencia de diferentes tipos de aleaciones [5-9], del basalto [10], de la madera y derivados [11-13] y por supuesto del concreto [14 y 15].

PROCEDIMIENTO EXPERIMENTAL / METODOLOGÍA

Para este estudio se tomaron datos de la cantidad de cemento, la cantidad de agua, el módulo de finura de la arena, el módulo de finura de la piedra, el Tamaño Máximo Nominal (TNM) de la piedra, la densidad de la arena, la densidad de la piedra, el peso específico de la arena, el peso específico de la piedra, así como el tipo de cemento con el que estaba fabricada, periodo de curado y resistencia a la compresión de 409 bloques cilíndricos de concreto procedentes de 44 empresas diferentes. Los bloques cilíndricos se prepararon y curaron de acuerdo a la norma ASTM C192/C 192M [16].

El ensayo a compresión axial se realizó según la norma ASTM C39/C 39M [17] después de diferentes periodos de curado. El curado se realizó sumergiendo totalmente las probetas en pozas de agua y los ensayos se realizaron en edades entre 3 y 28 días.

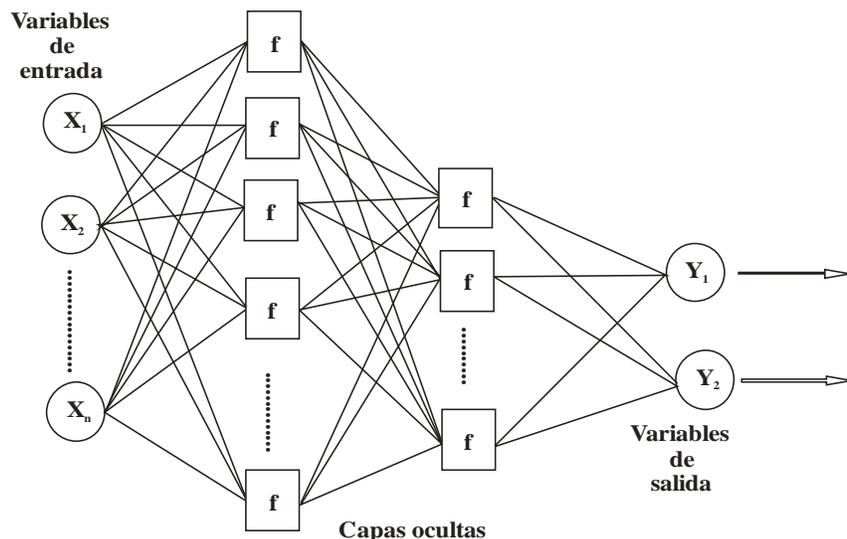


Fig. 1 Esquema general de una red neuronal artificial

Para la realización de los ensayos se utilizó una máquina de compresión axial TONI-TECHNIK provista de una célula de 3.000KN y TINIUS OLSEN DE 1.500KN.

Las características de los componentes influyen en las proporciones utilizadas en la fabricación: tamaños de piedra mayores, requerirán menos agua, arenas mas finas requerirán mas agua en la mezcla, la forma y textura superficial de las piedras influyen en la trabajabilidad y en la adherencia con la pasta, entre otros factores, razón por la cual se tomaron estos datos para relacionarlos con la resistencia.

La caracterización de la red neuronal artificial se basa en la definición del tipo de red y funciones de transferencia. Para la red se ha utilizado un perceptrón multicapa hacia delante entrenado mediante el algoritmo de retropropagación, este tipo es uno de los más comúnmente utilizados en toda la literatura consultada.

Como función de transferencia se ha utilizado una variante de la tangente hiperbólica, la tangente hiperbólica sigmoidea la es matemáticamente equivalente a la tangente hiperbólica pero mejora el funcionamiento de la red [4].

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

$f(x)$: Valor de salida de la neurona

x : Valor de entrada de la neurona

A fin de mejorar el rendimiento de la red y debido a que los valores de salida de la función de transferencia están en el intervalo (-1, 1) se transformaron los datos mediante las funciones *mapstd* y *processpca* de MATLAB que transforman de forma afín y unívoca los datos de entrada al intervalo [0, 1] y realizan un análisis de componentes principales eliminando las variables redundantes dentro del conjunto de entrada.

El método de entrenamiento de la red se ha realizado mediante aprendizaje supervisado basado en técnicas de minimización local de funciones de varias variables [1-3].

Para el entrenamiento se ha utilizado el algoritmo de retropropagación resiliente, el cual mejora los resultados del aprendizaje para el caso de funciones de transferencia sigmoidea [4].

El conjunto inicial de datos ha sido dividido en tres grupos elegidos aleatoriamente y sin repetición; el de entrenamiento (254 datos, 62% del total), el de validación (73 datos, 18% del total) y el de

comprobación (82 datos, 20% del total) porcentaje muy similar al utilizado por García Fernández et al. [13] en su estudio. El proceso de desarrollo de la red neuronal artificial se resume en la Figura 2.

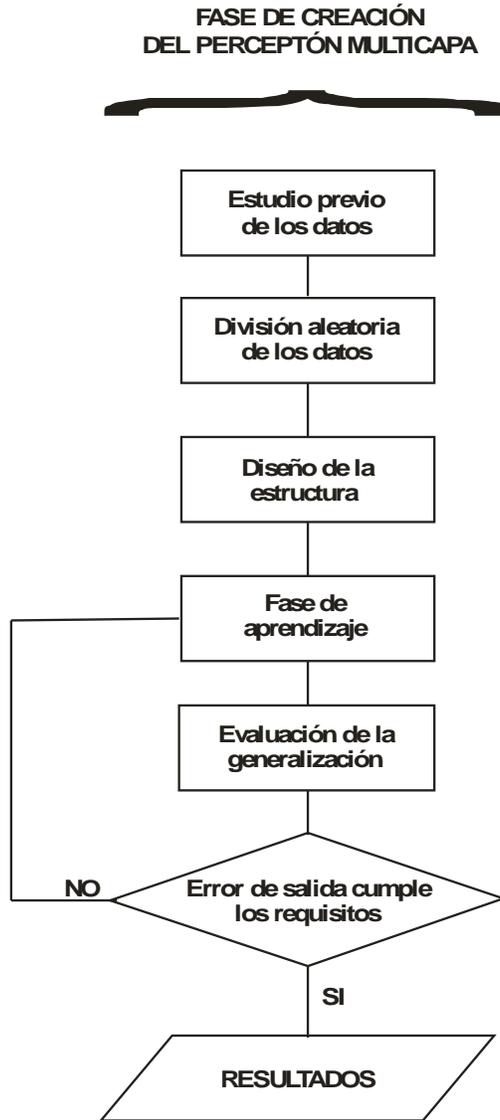


Fig. 2 Proceso de desarrollo de la red neuronal artificial.

Para evaluar los resultados se van a utilizar coeficientes de determinación (R^2), coeficientes de correlación (R) y los porcentajes medios de error ($E\%$) entre los valores experimentales y los simulados por la red.

Finalmente, para los datos del conjunto de comprobación, se va a realizar un análisis de varianza y un análisis *LSD* entre los datos de los conjuntos experimental y simulado por la red a fin

de detectar la existencia de diferencias significativas entre ambos.

Para el desarrollo de la red neuronal artificial se ha utilizado la utilidad Neural Network Toolbox® V. 5.1, para el estudio estadístico se ha utilizado la utilidad StatisticToolbox V. 6.1, ambas pertenecientes al programa MATLAB® 2007 de la empresa TheMathworks Inc.

RESULTADOS Y DISCUSIÓN

Como red óptima se ha desarrollado una red con dos capas ocultas de 10 y 4 neuronas cada una (Figura 3). De acuerdo a Sha [19] puede afirmarse

que la red neuronal está matemáticamente definida ya que el número de datos disponibles durante el entrenamiento (254 datos) es superior al número de incógnitas de la red (165 incógnitas).

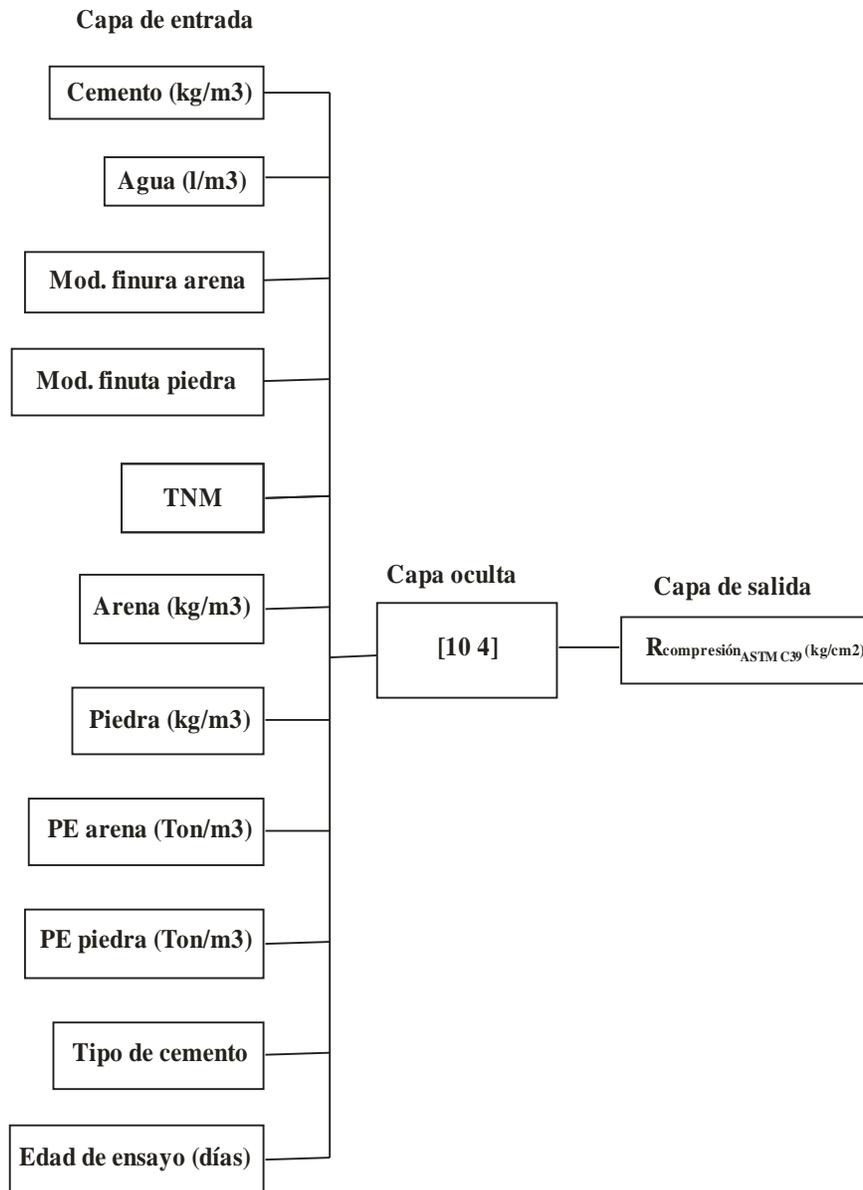


Fig. 3 Esquema de la red neuronal desarrollada.

Los resultados obtenidos por la red se recogen en

La Tabla 1.

Tabla 1. Resultados del proceso de generación de la red neuronal artificial.

Proceso	Ecuación	R	R ²	Error medio (%)
Entrenamiento	$Y = 0,93 \cdot X + 16$	0,97	0,95	6,17
Validación	$Y = 0,92 \cdot X + 18$	0,93	0,86	9,05
Comprobación	$Y = 0,95 \cdot X + 29$	0,93	0,86	11,55

Las siguientes figuras (Figuras 4-6) muestran los gráficos de correlación para los conjuntos de

entrenamiento, validación y comprobación.

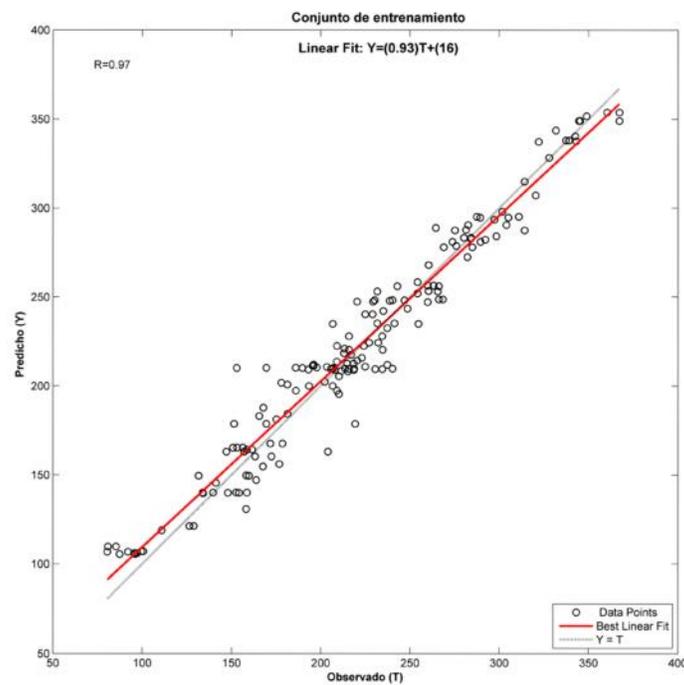


Fig. 4 Correlación para el conjunto de entrenamiento.

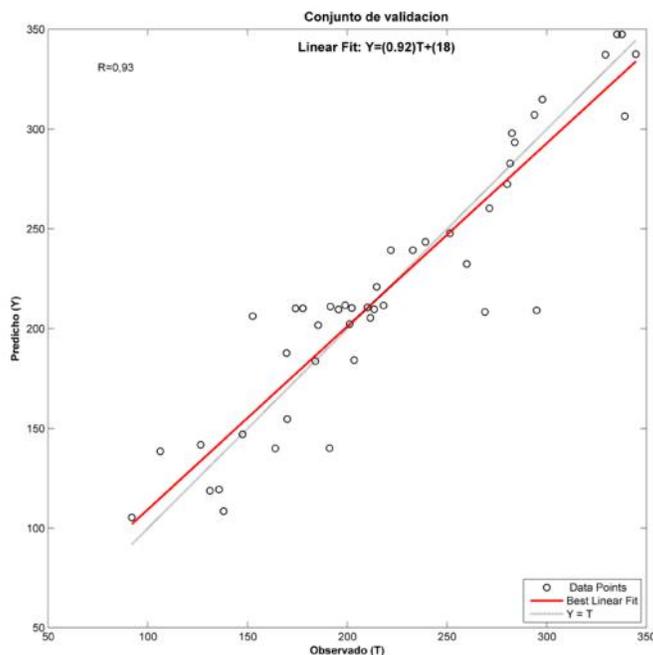


Fig. 5 Correlación para el conjunto de validación.

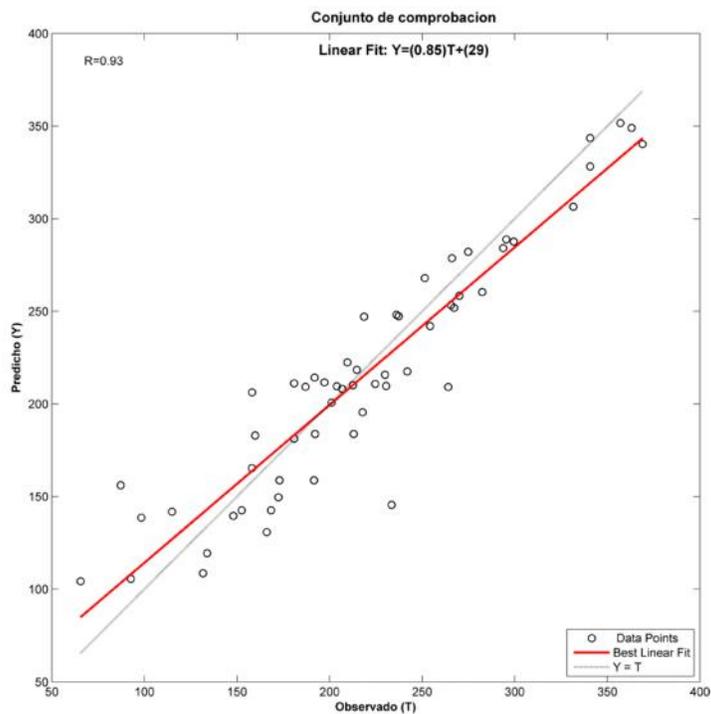


Fig. 6 Correlación para el conjunto de comprobación.

El coeficiente de determinación obtenido para el conjunto de comprobación nos indica que el

modelo desarrollado es capaz de explicar al menos el 86% de la variabilidad de las muestras.

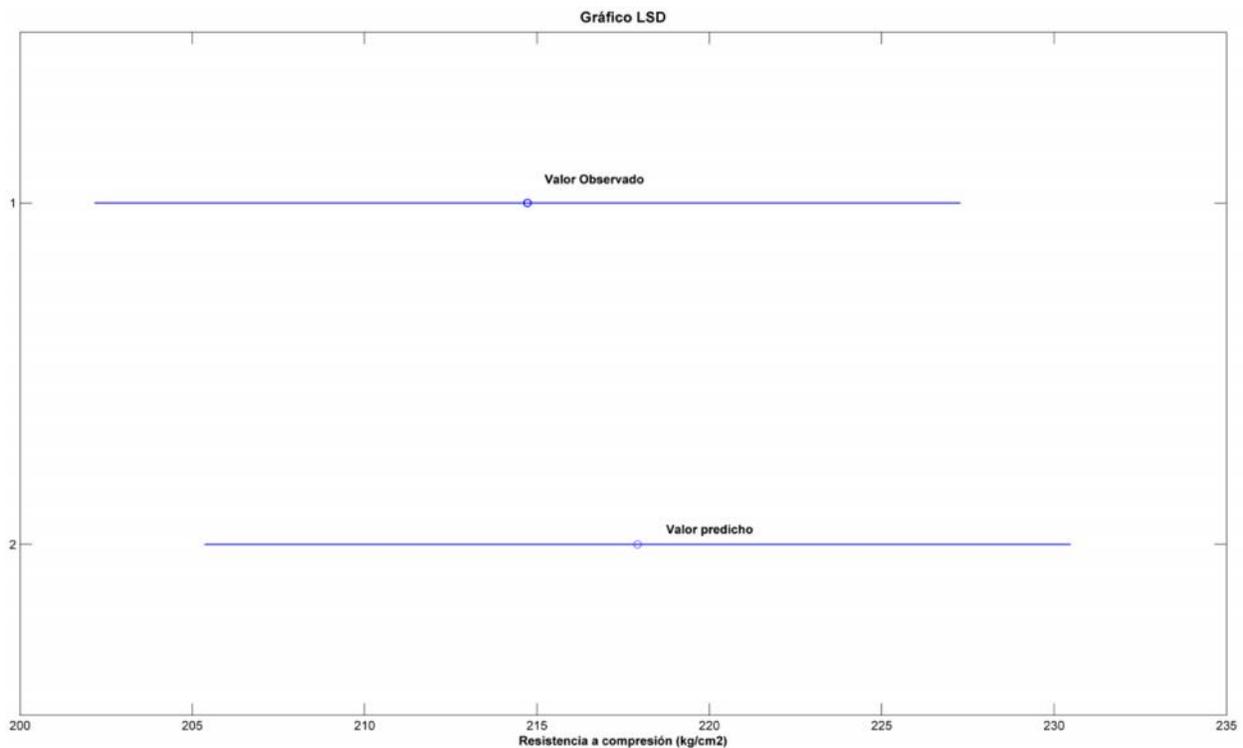
Tabla 2. Análisis de varianza sobre el conjunto de comprobación.

Fuente	SS	g.l.	MS	F	Prob> F
Columnas	290,1	1	290,13	0,06	0,8017
Error	512951,9	112	4579,93		
Total	513242	113			

Dado que el *p-valor* es superior a 0,05 se puede afirmar que no existen diferencias significativas para el grupo de comprobación entre los valores simulados y los experimentales. La siguiente Figura 7 muestra el gráfico *LSD* para el conjunto de comprobación.

La Figura 6 muestra la no existencia de diferencias significativas para entre los datos experimentales y simulados para el conjunto de comprobación con un nivel de confianza del 95%. Los coeficientes de correlación obtenidos durante el proceso de entrenamiento ($R=0,98$), validación ($R=0,93$) y comprobación ($R=0,93$) son similares a los obtenidos por otros autores [15, 20-23], los cuáles oscilan entre 0,81 y 0,98. Los errores medios obtenidos, por Ukrainczyk y Ukrainczyk [23](9,29%-16,67%) son muy similares a los obtenidos en esta investigación, 6,17% en

entrenamiento, 9,05% en validación y 11,55% en comprobación. Por otra parte, los resultados se encuentran dentro de los márgenes obtenidos por otros autores al aplicar las redes neuronales artificiales a la caracterización de otros materiales. García Fernández et al, [12] obtuvieron coeficientes de correlación en el conjunto de comprobación de 0,87 para la modelización de la resistencia del tablero de partículas P2, García Fernández et al, [13] obtuvieron coeficientes de correlación en el conjunto de comprobación de 0,81 a 0,87 para la modelización de la resistencia a flexión del tablero contrachapado estructural. Malinov et al, [6] obtuvieron correlaciones entre 0,60 y 0,97 en su modelización de las propiedades mecánicas de las aleaciones de titanio. Mc Bride et al, [24] obtuvieron coeficientes de correlación entre 0,94 y 0,97 en la modelización de las propiedades mecánicas de aleaciones de aluminio.

**Fig. 7** Gráfico *LSD* para los datos del conjunto de comprobación.

Por tanto ya que los resultados conseguidos se encuentran dentro de los márgenes obtenidos por otros autores, tanto en el campo del concreto como de otros materiales podemos dar como aceptable la red neuronal artificial conseguida.

CONCLUSIONES

Las redes neuronales artificiales se presentan como una potente herramienta en la modelización del ensayo de resistencia a compresión de bloques cilíndricos de concreto por la norma ASTM C39/C 39M, abriendo la puerta a su utilización en el control de calidad y en el desarrollo de nuevos productos mejorando la competitividad de las empresas fabricantes de concreto.

AGRADECIMIENTOS

El Grupo de Investigación quiere agradecer al Ayudante-Alumno, Anthony Pajuelo del Laboratorio de Ensayo de Materiales de la Facultad de Ingeniería Civil perteneciente a la Universidad Nacional de Ingeniería (LEM-FIC-UNI) por su contribución en la realización de los ensayos y el mantenimiento de la base de datos. Este trabajo se ha desarrollado con el soporte del Instituto General de Investigación de la Universidad nacional de Ingeniería (Concurso de Proyectos de Investigación Interdisciplinario 2012 – II).

REFERENCIAS

1. **Pérez Delgado, M. L., Martín Martín, Q.** “Aplicaciones de las redes neuronales a la estadística. Cuadernos de Estadística”; Ed. La Muralla, S.A. 1993.
2. **Isasi Viñuela, P., Galván León, I. M.,** “Redes Neuronales Artificiales, un enfoque práctico”; Pearson Educación, S.A., 2004.
3. **Hagan, M. T., Demuth, H. B., Beale, M.,** “Neural Network Design”; PWS Pub. Co.; 1st edition. 1995.
4. **Demuth, H., Beale, M., Hagan, M.,** “Neural Network Toolbox User’s guide, version 4”; The Mathworks Inc. 1996.
5. **Mukherjee, S., Schmauder, M., Rühle, M.,** “Artificial neural networks for the prediction of mechanical behaviour of metal matrix composites”; *Acta Metallurgica Materialia* Vol. 43-11, pp. 4083-4091. 1995.
6. **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* Vol. 21, pp. 375-394. 2001.
7. **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* Vol. 209, pp. 894-899. 2009.
8. **Ozderem, M. S., Kolukisa, S.,** “Artificial neural network approach to predict the mechanical properties of Cu-Sn-Pb-Zn-Ni cast alloys”; *Materials and Design* Vol. 30, pp. 764-769. 2009.
9. **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.*, Vol. 508, pp. 93-105. 2009.
10. **Çanakci, H., Pala, M.,** “Tensile strength of basalt from a neural network”; *Engineering Geology* Vol. 94 (2007), pp. 10-18.
11. **Cook, D. F., Chiu, C. C.,** “Predicting the internal bond strength of particleboard, utilizing a radial basis function neural network”; *Engineering Applications of Artificial Intelligence* Vol. 10-2, pp.171-177, 1997.
12. **García Fernández, F., Esteban, L. G., De Palacios, P., Navarro, N., Conde, M.,** “Prediction of standard particleboard mechanical properties utilizing an artificial neural network and subsequent comparison with a multivariate regression model”; *Investigación Agraria: Sistemas y Recursos Forestales* Vol. 17-2, pp. 178-187. 2008.
13. **García Fernández, F., De Palacios, P., García Esteban, L., García-Iruela, A., González Rodrigo, B., Menasalvas, E.,** “Prediction of MOR and MOE of structural

- plywood board using an artificial neural network and comparison with a multivariate regression model”; *Composites: Part B*. Vol. 43, pp. 3528-3533. 2012.
14. **Ba yigit, C., Akkurt, I., Kilincarsian, S., Beycioglu, A.**, “Prediction of compressive strength of heavyweight concrete by ANN and FL models”; *Neural Computing and Applications* Vol. 19, pp.507-513. 2010.
 15. **Yaprak, H., Karaci, A., Demir, I.**, “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* Vol. 22, pp. 133-141. 2013.
 16. **ASTM C 192/C 192M**, “Standard Practice for Making and Curing Concrete Test Specimens in the Laboratory”; The American Society for Testing Materials. 2000.
 17. **ASTM C 39/C 39M**, “Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens”; The American Society for Testing Materials. 2001.
 18. **ASTM C 150**, “Standard Specification for Portland Cement”; The American Society for Testing Materials. 2002.
 19. **Sha, W.**, “Comment on the issues of statistical modelling with particular reference to the use of artificial neural networks”. *Applied Catalysis A: General* Vol. 324, pp. 87-89. 2007.
 20. **Yeh, I. C.**, “Modeling of strength of HPC using ANN”; *Journal of Cement and Concrete Research* Vol. 28-12, pp. 1797-1808. 1998.
 21. **Lee, S. C.**, “Prediction of concrete strength using artificial neural networks”; *Journal of Engineering Structure* Vol. 25, pp. 849-857. 2013.
 22. **Oztas, A., Pala, M., Ozbay, E., Kanka, E., Caglar, N., Bhatti, M. A.**, “Predicting the compressive strength and slump of high strength concrete using neural network”; *Construction and Building Materials* Vol. 20-9, pp. 769-775. 2006.
 23. **Ukrainczyk, N., Ukrainczyk, V.**, “A neural network method for analysing concrete durability”. *Magazine of Concrete Research* Vol. 60-7, pp. 475-486. 2008.
 24. **Mc Bride, J., Malinov, S., Sha, W.**, “Modelling tensile properties of gamma-based titanium aluminides using artificial neural network”; *Material Science and Engineering A* Vol.384, pp. 129-1. 2004.

Correspondencia: lacuna@uni.edu.pe

Recepción de originales: octubre 2013

Aceptación de originales: diciembre 2013