

Redes neuronales artificiales para estimar propiedades en estado fresco y endurecido, para hormigones reforzados con fibras metálicas.^δ

(Artificial neural networks to estimate fresh and hardened state properties, for metal fiber reinforced concrete).

Luis Octavio González-Salcedo*
Aydee Patricia Guerrero Zúñiga**
Silvio Delvasto-Arjona***
Adrián Luis Ernesto Will****



UNIVERSIDAD
NACIONAL
DE COLOMBIA
SEDE PALMIRA



UNIVERSIDAD
NACIONAL
DE TUCUMÁN

Recibido: 20 de septiembre de 2016

Aceptado: 09 de enero de 2017

Tipo de artículo: artículo de Investigación

Resumen

El hormigón se elabora con cemento, agua, agregados, aditivos y adiciones minerales. Una de sus propiedades en estado fresco, es el asentamiento. Por su parte, en estado endurecido, sus propiedades mecánicas se alcanzan a una edad de 28 días, después del mezclado de las materias primas. Como material frágil, requiere de la incorporación de fibra para adquirir ductilidad. Tanto sin fibra como con fibras, se ha extendido el uso de redes neuronales artificiales (RNA) para predecir principalmente la resistencia a la compresión, lo cual hace interesante aplicarlo también para otras propiedades mecánicas, así como para el asentamiento. En el presente artículo se reporta la elaboración de RNA, entrenadas con los algoritmos de Levenberg-Maquardt y Gradiente Conjugado Escalonado, usando el software MATLAB, para predecir el asentamiento y las resistencias de diseño a la compresión, a la tensión, a la cortante, y a la flexión, así como la tenacidad flexural en hormigones reforzados con fibras de acero. Los resultados de correlación entre los valores obtenidos y reales, muestran que la herramienta computacional elaborada es confiable para su uso predictivo.

Palabras Clave: Asentamiento del hormigón, Hormigón reforzado con fibra, Inteligencia Artificial, Propiedades mecánicas del hormigón, Redes Neuronales Artificiales.

Abstract

Concrete is made from cement, water, aggregates, additives and mineral additions. In its fresh state, one of its properties is the settlement. Meanwhile, when hardened, its mechanical properties are reached at an age of 28 days after the mixing of the raw materials, as a brittle material it requires fiber to be incorporated to acquire ductility. Both in concrete, without fiber and with fiber, the use of artificial neural networks (ANNs) to predict mainly compressive strength has been expanded, which, as well as for its settlement properties, it also makes its other properties interesting. In this paper, the development of ANN is reported in combination with training from Levenberg-Maquardt and Scaled Conjugated Gradient Algorithms, using MATLAB software to predict the settlement and design strengths of compression, tension, shear, and flexural strength, flexural toughness, and for steel fiber reinforced concrete. The results of correlation between actual and predicted values show that the computational tool developed is reliable for predictive use.

Key Words: Concrete's settlement, Fiber reinforced concrete, Artificial Intelligence, Predictive tool, Concrete's mechanical properties, Artificial Neural Network.

^δ Este artículo es resultado del Proyecto "Diseño de mezclas de concreto reforzado con fibras metálicas y de polipropileno, usando Inteligencia Artificial". Tesis Doctoral en Ingeniería de Materiales, 2006-2014. Universidad del Valle, Cali, Colombia.

*PhD, Profesor Asociado, Grupo de Investigación en Materiales y Medio Ambiente, Departamento de Ingeniería, Facultad de Ingeniería y Administración, Universidad Nacional de Colombia Sede Palmira, logonzalezsa@unal.edu.co

**PhD, Profesor Titular, Grupo de Investigación en Ingeniería Sísmica, Ingeniería Eólica y Estructuras Inteligentes, Escuela de Ingeniería Civil y Geomática, Facultad de Ingeniería, Universidad del Valle, patricia.guerrero@correounivalle.edu.co

***PhD, Profesor Titular, Grupo de Materiales Compuestos, Escuela de Ingeniería de Materiales, Facultad de Ingeniería, Universidad del Valle, silvio.delvasto@correounivalle.edu.co

****PhD, Profesor Adjunto, Facultad de Ciencias Exactas y Tecnología, Universidad Nacional de Tucumán, y Grupo de Investigación en Tecnologías Informáticas Avanzadas, Facultad Regional de Tucumán, Universidad Tecnológica Nacional, adrian..will.01@gmail.com

Introducción

El hormigón es un conglomerado elaborado a partir de cemento, agregados, agua y otros componentes denominados adiciones minerales y aditivos químicos (Niño, 2010). Es un material estructural y de construcción por excelencia, y sus especificaciones para tal fin son expresadas en el asentamiento del Cono de Abrams y en la resistencia de diseño a la compresión, las cuales son propiedades en estado fresco y endurecido, respectivamente. Con respecto al estado endurecido, sus propiedades mecánicas de diseño son alcanzadas a una edad de 28 días después de realizada la mezcla y se determina con ensayos estandarizados. El hormigón es un material frágil y la incorporación de fibra le permite seguir soportando esfuerzos a pesar de haber alcanzado su máxima resistencia, experimentando un comportamiento cuasi-dúctil, lo cual es denominado como tenacidad (González *et al.*, 2014).

La predicción de diversas propiedades del concreto, tanto en estado fresco como endurecido, se ha realizado mediante modelos matemáticos, sin embargo, la complejidad y la alta relación de dependencia no lineal entre las variables de entrada sugieren que esta estimación sea llevada al campo de la Inteligencia Artificial (González *et al.*, 2012). La literatura reporta diversos desarrollos con redes Neuronales Artificiales (RNA) para estimar principalmente, la resistencia a la compresión en hormigones planos, siendo de interés la temática en hormigones reforzados con fibras, extendiendo la predicción en otras propiedades mecánicas como la resistencia a la tensión, a la cortante y a la tenacidad flexural. Así como también a la estimación del asentamiento del Cono de Abrams, que corresponde a una especificación para mezclas recién realizadas, es decir en estado fresco.

En este artículo se reporta la elaboración de RNA con el objetivo de predecir propiedades mecánicas en estado endurecido, como las resistencias de diseño a la compresión, a la tensión, a la cortante, a la flexión, y la tenacidad flexural, así como el asentamiento del Cono de Abrams, como propiedad en estado fresco, para hormigones reforzados con fibras de acero. Las RNA se entrenaron usando los algoritmos de Levenberg-Maquardt (Lourakis,

2005) y del Gradiente Conjugado Escalonado (Möller, 1993). Como indicador de confiabilidad del uso de las RNA, se evalúa el factor de correlación entre los valores reales y los valores estimados.

Marco teórico

Redes neuronales artificiales

La red neuronal artificial (RNA) es un modelo matemático que emula el sistema neuronal biológico en el procesamiento de la información, y en cuyo símil la integración de las neuronas artificiales se realiza mediante funciones que procesan y envían información entre sí (Bishop, 2006); la información que se transmite a través de las conexiones de la red se ponderan en pesos de importancia modulándose así la intensidad de la relación entre neuronas, como se muestra en la figura 1 (Bertona, 2005; Isasi, 2007). El poder computacional que las RNA han demostrado en muchas aplicaciones en diversos campos de la ingeniería, que éstas solucionan una gran cantidad de problemas de difícil tratamiento con métodos convencionales, a partir de su capacidad para aproximar funciones (Torres, 1994-1995), desarrollando una arquitectura específica que corresponde a las redes neuronales llamadas perceptrones multicapa, cuyo fundamento matemático como aproximadoras universales de funciones, se basa en el teorema de Kolmogorov, presentado por Kurkova, 1992. De esta manera, a partir de tres capas se puede aproximar hasta el nivel deseado cualquier función continua en un intervalo dado, haciendo de esta RNA la topología más adecuada como estimadora universal de funciones (Leshno *et al.*, 1992).

La elaboración de una RNA, con topología multicapa, involucra la definición del número de capas ocultas, el número de neuronas en cada una de 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 *et al.*, (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

donde reciben información, y con la capa posterior hacia donde la transmiten. Sus capas poseen una función de activación, cuya salida es representada como se muestra en la fórmula (1)

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

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 to-

das las N neuronas, X es el vector que contiene las entradas, b es el vector que contiene los sesgos, y f es la función de activación. Una de las funciones de activación no lineal frecuentemente usada es la función sigmoidea expresada en la fórmula (2)

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

Siendo Z la expresión contenida dentro del paréntesis de la ecuación 1.

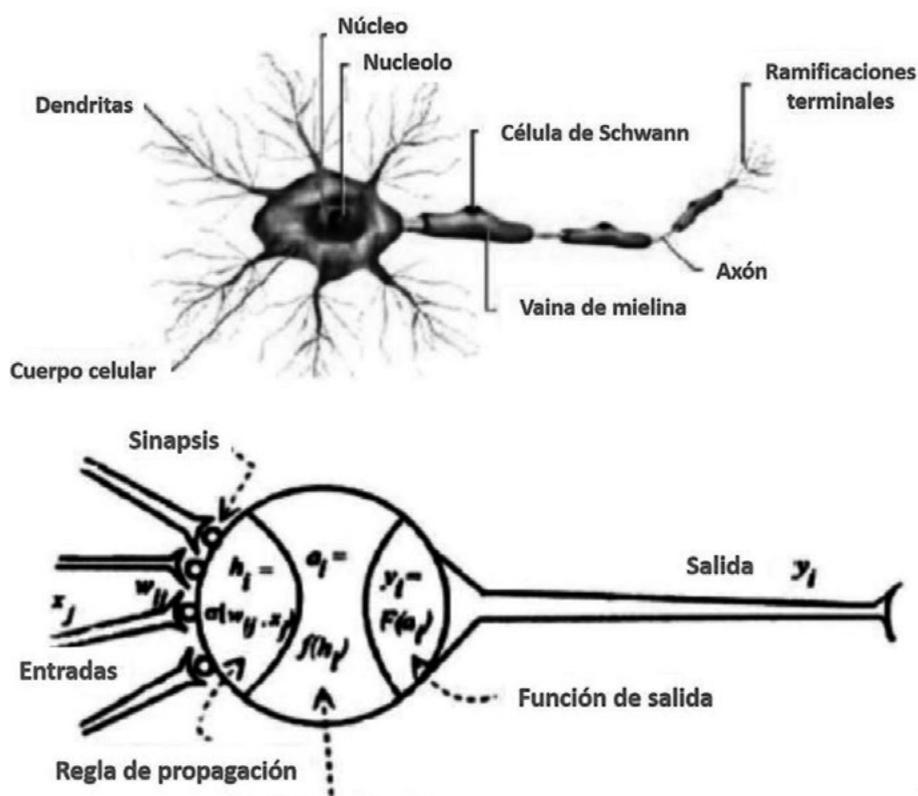


Figura 1. Similitud entre una neurona biológica y una computacional, a partir de la comparación de las estructuras biológicas y computacionales respectivamente.

Fuente: (Bertona, 2005; Isasi, 2007).

La técnica de aprendizaje de *backpropagation* consiste en utilizar una optimización basada en las derivadas del error, no solamente en función de los pesos de cada capa de salida, sino también en función de los pesos de la capa oculta utilizando la regla de la cadena (Hinton, 1988), y que permite minimizar el error de entrenamiento

de la RNA (la diferencia entre los valores estimados utilizando un determinado conjunto de pesos, y los valores originales). El error y las correcciones efectuadas a los pesos se trasladan desde la capa salida hacia atrás hasta la capa de entrada, de donde surge su nombre de propagación hacia atrás.

Nocedal (1992), Moreira & Fiesler (1995), Chopra *et al.*, (2015), entre otros, reportan que diversos métodos de entrenamiento/aprendizaje bajo el funcionamiento del proceso de alimentación de información hacia adelante y corrección y ajuste del error hacia atrás (*feedforward – backpropagation*) han sido diseñadas, entre los cuales se encuentran: Gradiente conjugado de Fletcher-Powell (Fletcher & Reeves, 1964; Powell, 1977; Fletcher, 1980); gradiente conjugado de Polak-Ribière (Polak & Ribière, 1969); gradiente conjugado de Powell-Beale (Beale, 1972; Powell, 1977); gradiente conjugado de Cuasi-Newton (Buckley, 1978; Buckley & Lenir, 1983); gradiente descendiente de tasa de entrenamiento variable (Jacobs, 1988; Minai y Williams, 1990); gradiente conjugado escalonado (Möller, 1993), Levenberg-Maquardt (Lourakis, 2005); propagación resiliente hacia atrás (Kişi & Uncuoğlu, 2005; Chen & Su, 2010); secante un paso (Constantinescu *et al.*, 2008), y regulación bayesiana (Unger & Könke, 2011; Ceballos *et al.*, 2011).

El método de entrenamiento denominado algoritmo de Levenberg-Marquardt LMA, ha sido definido por Lourakis, 2005, 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. Por su parte, el método de descenso por gradiente o gradiente conjugado, correspondiente al gradiente conjugado con escalonamiento SCG, ha sido definido por Möller, 1993, y sustituye la búsqueda lineal por un escalonamiento de paso, que depende del éxito en la reducción del error y buen desempeño de la aproximación cuadrática de éste.

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 *et al.*, 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 que normalmente quedan ocultos por la división de datos y otros efectos (Díaz *et al.*, 2011).

mente 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 que normalmente quedan ocultos por la división de datos y otros efectos (Díaz *et al.*, 2011).

Dependencia de las propiedades del hormigón reforzado con fibras

Dependencia de las propiedades mecánicas

De acuerdo con Noguchi *et al.*, (2003), la resistencia a la compresión de los hormigones depende de la resistencia del mortero (mezcla de cemento, agua y arena) y los efectos que sobre ésta tienen el agregado grueso y la interface entre estos dos compuestos, el contenido del aire y las adiciones minerales; estos autores manifiestan que, dentro de las variables influyentes de la resistencia del mortero, se consideran 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 clases 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 influenciado, 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 del mineral constituyente del agregado (Chan *et al.*, 2003, Noguchi *et al.*, 2003, & González, 2014).

Noguchi *et al.*, (2003), manifiestan que el efecto del contenido del aire es influenciado por la cantidad del agente retenedor de aire, usado en la mezcla de hormigón; y afirman que las cantidades de las adiciones de humo de sílice, de cenizas volantes y de escoria de alto horno, cuando son utilizados como materiales cementantes en reemplazo de parte del cemento, influyen en la resistencia a la compresión. Algunos reportes, como el presentado por Sánchez (2000), muestran también que

la cantidad de agentes reductores de agua influyen en la resistencia del hormigón.

Una aproximación a la mecánica del hormigón reforzado con fibras considera que las propiedades del compuesto están relacionadas con las propiedades de las fibras y de la interface entre los dos componentes, donde se resalta el volumen de fibra incorporado en la matriz cementicia y un parámetro de adherencia de la fibra (González, 2014). La fibra metálica se encuentra disponible comercialmente de manera general en monofilamentos, y pueden ser lisas o de forma ondulada (Benavides y González, 2012). Adicionalmente, la cantidad de fibra, el diámetro y la relación de aspecto son variables que influyen en la resistencia del hormigón, como lo reporta Richardson & Landless, (2009), y Benavides y González (2012).

De acuerdo con González (2014), la resistencia a la compresión es la propiedad mecánica que es tomada como referencia en las especificaciones del diseño estructural y de la construcción de obras en hormigón; a partir de esta propiedad, otras propiedades mecánicas son especificadas como una fracción de la resistencia a la compresión. Finalmente, González *et al.*, 2014, reportan que la tenacidad flexural, calculado a partir de métodos gráficos, depende también de la cantidad, tipo y anclaje en los extremos de las fibras de reforzamiento.

Dependencia del asentamiento del Cono de Abrams

Las propiedades en estado fresco del hormigón, principalmente, la trabajabilidad y el asentamiento del Cono de Abrams, como una medida de la misma, están directamente asociadas a propiedades reológicas como la viscosidad plástica y el esfuerzo cortante; sin embargo, estas propiedades están relacionadas con parámetros de los materiales componentes de la mezcla diseñada. Es así, como el cemento, las adiciones minerales, los agregados (incluyendo su forma y tamaño), los aditivos químicos (reductores de agua y entradores de aire), y la fibra (material, longitud, relación de aspecto, y adherencia con la matriz cementicia), tienen efecto sobre dichas propiedades (González, 2014).

Materiales y Métodos

Base de datos y construcción del conjunto de entrenamiento de la RNA

Los Autores usaron una base de datos con una amplia información de resultados de ensayos mecánicos y del asentamiento del Cono de Abrams, reportados en publicaciones especializadas y recopilados por González, 2014. En la base cada registro es un vector de información completa con datos sobre las dosificaciones de la materia prima, y características cualitativas como el tipo de cemento, el origen de los agregados, el perfil litológico del agregado grueso, y el tipo de fibra de acero. En los datos se incluyeron tres clases de adiciones minerales (humo de sílice, ceniza volante y escoria) y dos tipos de aditivos químicos (reductor de agua y entrador de aire). La tabla 1, muestra el tamaño para cada conjunto de entrenamiento, con información completa de mezclas de hormigón reforzado con fibras de acero, asociadas a una propiedad específica. En la tabla 2, se presentan las variables relevantes del problema de dosificación, para cada vector de información en cada conjunto de entrenamiento.

Tabla 1. *Tamaño de cada conjunto de entrenamiento.*

Propiedad del Hormigón	Número de diseños de mezclas
Resistencia a la compresión, $f'c$	601
Resistencia a la tensión, $f'ct$	307
Resistencia a la cortante, $f'cv$	31
Resistencia a la flexión, MOR	301
Tenacidad flexural, Índice I5	77
Tenacidad flexural, Índice I10	61
Asentamiento del Cono de Abrams	158

Fuente: Elaboración Propia (2016).

Tabla 2. Variables relevantes del problema de dosificación, consideradas en cada conjunto de entrenamiento.

Variable	Unidad (variable cuantitativa)	Atributo (variable cualitativa representada como variable discreta)
Contenido de cemento ¹	Kg/m ³	-
Tipo de cemento	-	Tipos I, II, III, IV, V
Contenido de humo de sílice ¹	Kg/m ³	-
Contenido de cenizas volantes ¹	Kg/m ³	-
Contenido de escoria ¹	Kg/m ³	-
Contenido de agua ¹	Kg/m ³	-
Contenido de agente retenedor de agua ¹	Kg/m ³	-
Tipo de agente retenedor de agua	-	Plastificante, Superplastificante
Contenido de arena ¹	Kg/m ³	.
Origen de procedencia de la arena	-	Río, Cantera
Contenido de grava ¹	Kg/m ³	-
Origen de procedencia de la grava	-	Río, Cantera
Origen geológico de la grava	-	Perfil litológico I, II, III
Tamaño máximo de grava	mm	-
Contenido de agente entrador de aire ¹	Kg/m ³	-
Contenido de fibra metálica ¹	Kg/m ³	-
Tipo de fibra metálica	-	Tipo I, II, III, IV
Longitud de la fibra	mm	-
Relación de aspecto de la fibra	adimensional	-

Fuente: Elaboración Propia (2016)

Elaboración, entrenamiento, puesta en marcha, validación y selección de la RNA

Los autores usaron los conjuntos de entrenamiento mencionados en la sección 3.1, en los cuales se relacionan las variables de entrada con la variable de salida (la propiedad a estimar), se elaboran propuestas de RNA multi-capas con alimentación hacia adelante y con metodología de entrenamiento/aprendizaje hacia atrás (figura 2), cuyas características son definidas por Rumelhart *et al.*, 1986, & Hinton, 1987, 1988, respectivamente, usando los algoritmos de LMA y SCG mencionados en la sección 2.

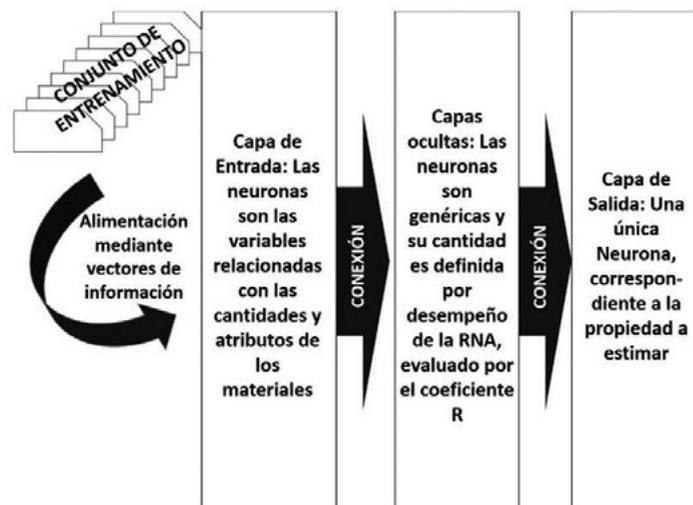


Figura 2. Propuesta del modelo neuronal artificial para la estimación de la propiedad en el concreto reforzado con fibra metálica.
Fuente: Elaboración Propia (2016).

¹Los contenidos de los materiales están expresados en Kg por m³ de mezcla de hormigón reforzado con fibra metálica.

Las conexiones entre las neuronas de la capa de entrada a cada capa oculta, se hacen usando la función sigmoidea descrita por Hinton, 1987, 1988. Las conexiones entre las neuronas de la última capa oculta y la neurona a estimar ubicada en la capa de salida, se hace usando una función lineal, de tal forma que se permita la comparación de la estimación y del resultado verdadero, como es descrito en el entrenamiento supervisado (Rumelhart *et al.*, 1986, & Hinton, 1987, 1988). Para tal fin, se realizan diversas conformaciones no mostradas en este reporte de RNA, y se evalúan a partir del factor de correlación lineal R y de los errores estadísticos relativo (ER), absoluto (EA), total cuadrático (SSE), medio del total cuadrático (MSE), y la raíz media del total cuadrático

(RMSE). Para su funcionamiento computacional, las RNA se codifican en un algoritmo usando el lenguaje de programación M, propio de la herramienta de software matemático MATLAB® para plataforma Windows®, y el código usa la librería contenida en el Neural networks toolbox del mismo software, lo cual permite implementar los modelos del tipo de RNA que se han descrito.

Los resultados de este proceso, no presentado en este artículo, mostró que arquitecturas con dos y tres capas ocultas, y usando los métodos de aprendizaje de LMA y SCG, obtuvieron desempeños adecuados y confiables ($R > 0.90$); en la tabla 3, se muestran las configuraciones finales de las RNA para la estimación de cada propiedad y para cada método de aprendizaje.

Tabla 3. Configuraciones finales de las RNA para la estimación de cada propiedad usando cada método de aprendizaje.

Propiedad estimada	Método de aprendizaje	Mejor Arquitectura RNA*	(1) R	(2) R	(3) R	(4) R
Compresión	LMA	10_10	0.99573	0.98081	0.95304	0.98286
	SCG	20_10_10	0.96071	0.95483	0.93200	0.95476
Tensión	LMA	15_5	0.99925	0.98727	0.86320	0.97441
	SCG	20_10_10	0.96976	0.98839	0.96813	0.97642
Cortante	LMA	10_5	0.99669	0.99080	0.99170	0.99393
	SCG	20_10_10	0.99777	0.99701	0.98751	0.99346
Flexión	LMA	10_10	0.98954	0.97156	0.96160	0.97856
	SCG	20_10_5	0.94981	0.91299	0.92177	0.92952
Índice de Tenacidad I_5	LMA	20_10_10	0.99559	0.99842	0.93392	0.98978
	SCG	10_5	0.93225	0.93717	0.98182	0.93687
Índice de Tenacidad I_{10}	LMA	20_10_5	0.99996	0.99842	0.96814	0.98495
	SCG	10_10_10	0.97991	0.96581	0.94558	0.96660
Asentamiento	LMA	15_10	0.99283	0.97961	0.96511	0.98338
	SCG	20_10_10	0.95471	0.96075	0.92955	0.95153

Fuente: Elaboración Propia (2016)

*La arquitectura de la RNA referida en esta columna, corresponde a la cantidad de neuronas genéricas en cada capa oculta, por ejemplo, 20_10_10 significa que la RNA configura 3 capas ocultas con 20, 10 y 10 neuronas en cada capa, respectivamente.

(1) Fase de Entrenamiento, (2) Fase de Prueba, (3) Fase de Validación Computacional y, (4) Fase de Simulación con todo el conjunto de entrenamiento.

Resultados y discusión

A partir de la elaboración de RNA, correspondientes a la topología de red neuronal supervisada Perceptron multicapa, con alimentación hacia adelante y entrenamiento/aprendizaje para la propagación del error hacia atrás, los autores realizaron la estimación de propiedades en estado fresco y endurecido para hormigones reforzados con fibras metálicas. Los modelos neuronales artificiales consistieron de RNA conformadas por una capa de entrada con 19 variables de entrada (de las cuales seis son de tipo cualitativa con tratamiento a variable numérica discreta de clase, ampliando el problema de decisión a 31 variables de entrada), y diversas configuraciones comprendidas entre dos y tres capas ocultas (con diversas cantidades de neuronas genéricas en cada capa oculta, como se muestra en la tabla 3), una capa de salida con la variable de respuesta a estimar (resistencia a la compresión, resistencia a la tensión, resistencia a la cortante, resistencia a la flexión, índice de tenacidad flexural I_5 , índice de tenacidad flexural I_{10} , y asentamiento del cono de Abrams), y algoritmos de aprendizaje de Levenverg-Marquardt y gradiente conjugado escalonado.

La tabla 3, muestra los resultados de desempeño de cada RNA, para cada una de las etapas o fases de entrenamiento de las mismas (entrenamiento, prueba, validación computacional y simulación con todo el conjunto de entrenamiento). Para todas las etapas, se hace una comparación entre el resultado obtenido por la RNA y el valor obtenido en el ensayo experimental reportado en la base de datos recopilada, para lo cual se le asocia a dicha comparación el factor de correlación lineal. De acuerdo con Ascombe, (1973) & Aschen (1982), los resultados muestran una relación lineal positiva fuerte entre los valores reportados experimentalmente y los obtenidos mediante la predicción de las RNA, lo cual permite inferir que la herramienta computacional es adecuada y confiable para hacer dichas estimaciones.

Los autores han seleccionado algunos resultados de la fase de simulación con el total del conjunto de entrenamiento, en los cuales se representan simultáneamente los valores estimados por las RNA, en cada caso, y los obtenidos experimentalmente reportados en la base de datos recopilada, con el fin de verificar la bondad en el ajuste de la predicción, a partir de la comparación gráfica entre los dos resultados, como es sugerido por Martínez (2005, p22). Se muestra esta selección en las figuras desde la 3 hasta la 9.

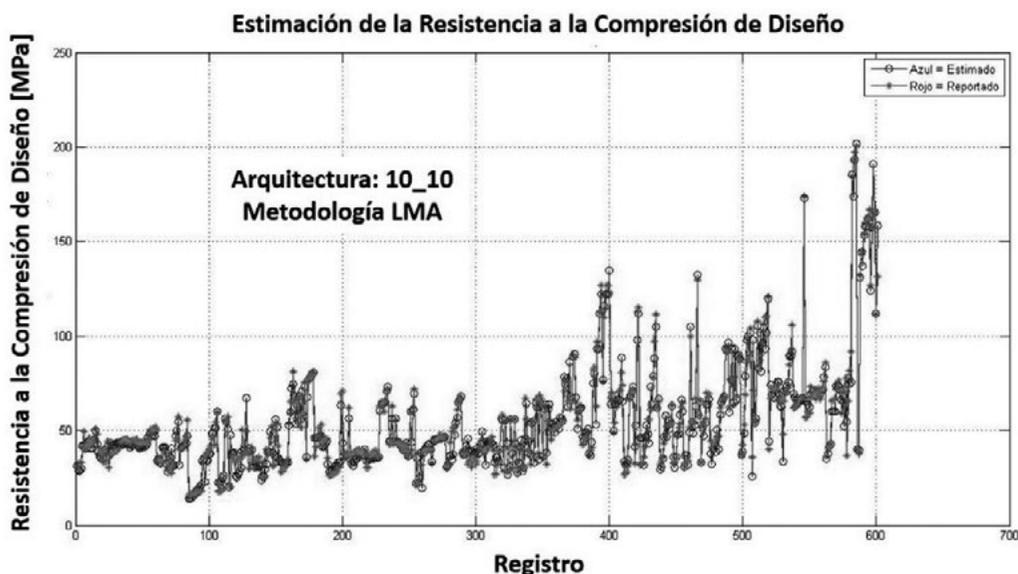


Figura 3. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación de la resistencia a la compresión.

Fuente: Elaboración Propia (2016)

En las figuras que se mencionan, la corroboración para cada registro en la aproximación del resultado obtenido por predicción, permite inferir que el modelo computacional basado en las RNA propuestas puede ser usado como herramienta computacional para predecir las propiedades en estado endurecido y fresco, para las cuales se entrenaron dichas RNA.

La literatura reporta el uso de RNA en la predicción de propiedades para hormigones sin reforzamiento y con reforzamiento de fibras, mencionados por González -Salcedo *et al.*, 2012. Los resultados obtenidos en el indicador de desempeño, el factor de correlación lineal R, son similares a los reportados, entre otros, por Chopra *et al.* (2005) ($R = 0.965$) para concretos sin fibra, González *et al.*, 2015 ($R = 0.93119$) para concretos con fibra.

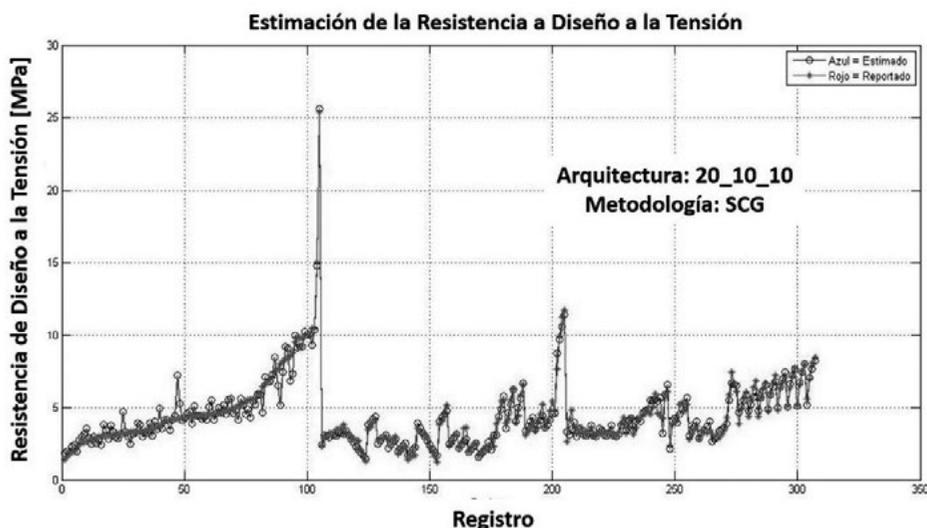


Figura 4. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación de la resistencia a la tensión.

Fuente: Elaboración Propia (2016)

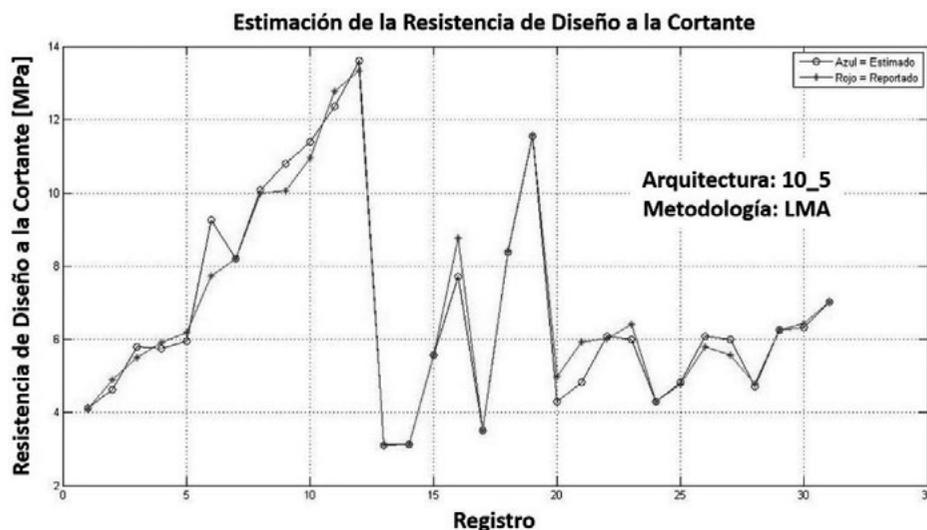


Figura 5. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación de la resistencia a la cortante.

Fuente: Elaboración Propia (2016)

Con respecto a la resistencia de diseño a la cortante, el comportamiento gráfico entre los valores reportados y estimados del modelo neuronal propuesto, es concordante con el comportamiento presentado en el modelo neuronal propuesto por Cladera, 2002 (no reporta el valor de R), en concretos sin fibra, y el reportado por González, 2014 ($R = 0.9483$), en concretos con fibra. Con respecto a la resistencia a la flexión – módulo de rotura, el modelo neuronal propuesto realiza una mejor estimación que el modelo reportado por Karahan *et al.*, 2008 ($R = 0.84$), para concretos sin fibra.

Con respecto a la estimación del índice de tenacidad flexural I_5 , el modelo neuronal propuesto mejora el de los mismos Autores, en trabajos previos, González *et al.*, 2013 ($R = 0.90403$). Con respecto a la estimación del asentamiento del Como de Abrams, el resultado es concordante con el reportado por Agrawal y Sharma (2010), ($R = 0.9991$) para concretos sin fibra. Se menciona que no han sido reportados en la literatura, la elaboración de modelos neuronales para la estimación de la resistencia a la tensión, y para la estimación del índice de tenacidad flexural I_{10} .

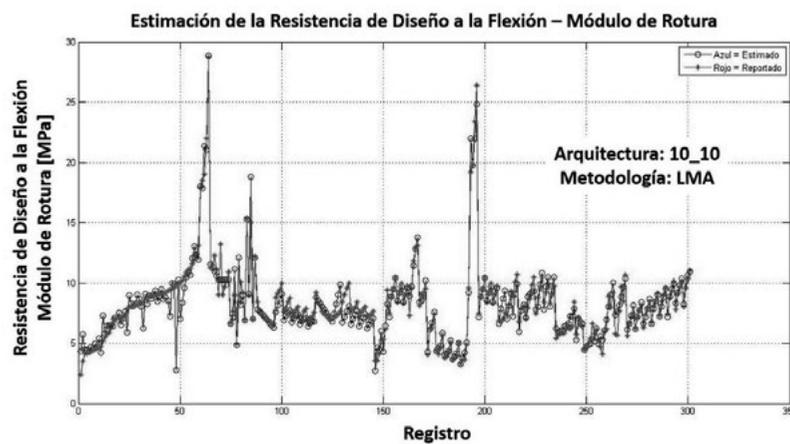


Figura 6. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación de la resistencia a la flexión – Módulo de Rotura.
Fuente: Elaboración Propia (2016)

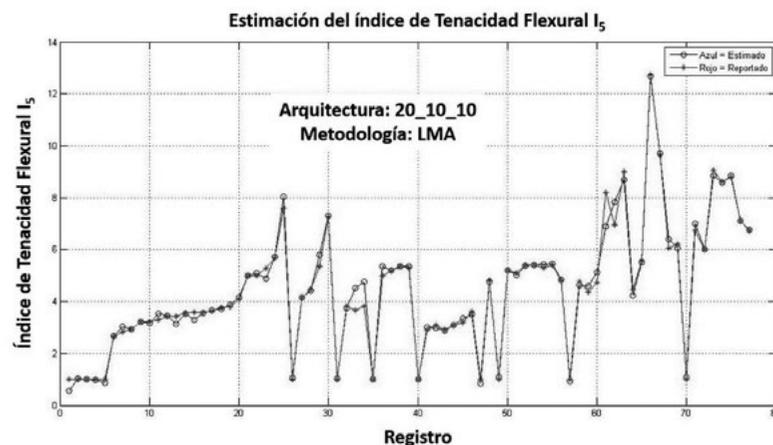


Figura 7. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación del índice de tenacidad flexural I_5 .
Fuente: Elaboración Propia (2016)

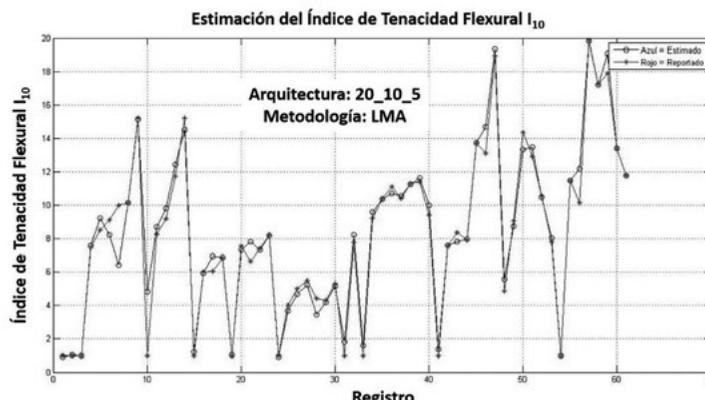


Figura 8. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación del índice de tenacidad flexural I_{10} .
Fuente: Elaboración Propia (2016).

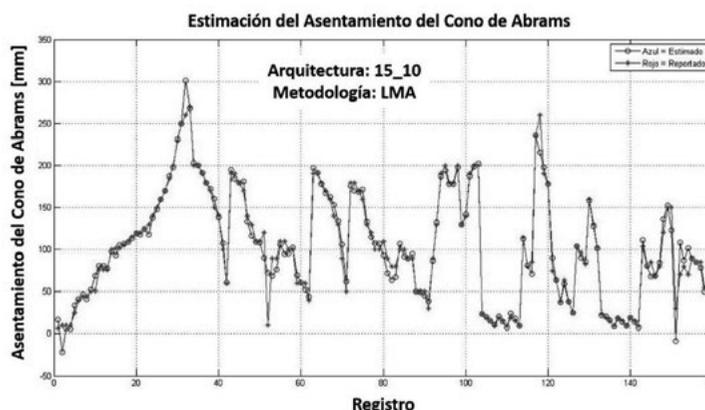


Figura 9. Comparación gráfica de los resultados entregados por la RNA seleccionada y los obtenidos experimentalmente, para la estimación del asentamiento del cono de Abrams.
Fuente: Elaboración Propia (2016).

Conclusiones y trabajos futuros

Esta investigación permitió elaborar un conjunto de códigos computacionales que usa la técnica de red neuronal artificial para predecir propiedades mecánicas y en estado fresco, en hormigones reforzados con fibras metálicas. El indicador de la correlación (a partir del factor de correlación lineal), entre los valores de las propiedades estimadas usando las RNA y los valores de éstas reportadas en los conjuntos de entrenamiento, permite inferir el uso de una herramienta confiable para tal fin. El trabajo realizado y los resultados obtenidos permiten trazar las siguientes conclusiones:

- 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, y del tipo de fibra metálica, adicionales a las dosificaciones de sus componentes (incluyendo adiciones minerales), hacen de la red neuronal artificial una herramienta de predicción universal de algunas propiedades del concreto reforzado con fibras metálicas.

- La inclusión de registros sin adición de fibra, hacen que la herramienta de predicción, pueda ser usada también para estimar estas propiedades mecánicas y en estado fresco, en concretos no reforzados con fibras.

Con respecto a los trabajos futuros, los modelos neuronales, pueden ser usados como componentes de un software diseñado para la estimación de propiedades

del concreto con y sin reforzamiento de fibra, así como herramientas de predicción en sistemas híbridos para el diseño de mezclas multiobjetivos, como en el caso de la utilización de algoritmos genéticos, por ejemplo, como es reportado por los autores en trabajos previos (González *et al.*, 2015).

Referencias

- Agrawal, V. & Sharma, A. (2010). Prediction of slump in concrete using artificial neural networks. *World academy of science, engineering and technology*, (69), 25-32.
- Aschen, C. (1982). Interpreting and using regression. *Sage University Paper*. (029), 89p.
- Ascombe, T. (1973). Graphs in statistical analysis. The american statistician. *A direction of conjugate gradients. Numerical Methods for Nonlinear Optimization*, (27), 17-21.
- Benavides, C. y González, S. (2012). Fibras de acero para reforzamiento de matrices cementicias: Una recopilación sobre fibras comercialmente disponibles. Universidad Nacional de Colombia Sede Palmira, 73.
- Bertona, L. (2005). Entrenamiento de redes neuronales basado en algoritmos evolutivos. Tesis (Ingeniería Informática). Universidad de Buenos Aires, Buenos Aires, 256.
- Bishop, C. (2006). Pattern recognition and machine learning. *Springer*, 805.
- Buckley, A. (1978). A combined conjugate gradient Quasi-Newton minimization algorithm. *Mathematical Programming*, No. 15, pp. 200-210.
- Buckley, A. G. & Lenir, A. (1983). QN-like variable storage conjugate gradient. *Mathematical Programming*, (27), 190-212.
- Ceballos, F., Muñoz, L. y Moreno C. (2011). Selección de perceptrones multicapa usando aprendizaje bayesiano. *Scientia et Technica*, 16 (49), 110-115.
- Chan, Y. Solís, C. y Moreno, E. (2003). Influencia de los agregados pétreos en las características del concreto. *Ingeniería*, 7 (2), 39-46.
- Chen, C. & Su, S. (March 2010). Resilient back-propagation neural network for approximation 2-D GDOP. *Proceedings of the international multiconference of engineers and computer scientists*. Hong Kong.
- Chopra, P., Sharma, R. & Kumar, M. (2015). Artificial neural networks for the prediction of compressive strength of concrete. *International journal of applied science and engineering*, 13 (3), 187-204.
- Cladera, B. (2002). Shear design of reinforced high-strength concrete beams. Doctoral Thesis. Universitat Politecnica de Catalunya, Barcelona.
- Constantinescu, R., Lazarescu, V. & Tahboub, R. (2008). Geometrical form recognition using "One-Step-Secant" Algorithm in case of Neural Network. *U.P.B. Scientific* 70 (2), 15-28.
- Díaz, W., Will, A. y González, S. (2011). Un método para estimación de calidad de datos en redes neuronales y su aplicación a problemas de hormigón de alto performance. *Mecánica computacional*, 30 (43), 3381-3381.
- Fletcher, R. (1980). Unconstrained optimization. *Wiley*, 6, 609.
- Fletcher, R. & Reeves, C. (1964). Function minimization by conjugate gradients. *Computer Journal*, (7), 149-154.
- González, L., Guerrero A., Delvasto, S. & Will, A. (2012). Exploración con redes neuronales artificiales para estimar la resistencia a la compresión, en concretos fibroreforzados con acero. *Ciencia e ingeniería neogranadina*, 22 (1), 19-41.
- González, L., Guerrero, A. y Delvasto, S. (2012). Aplicación de la inteligencia artificial en el diseño de mezclas de concreto. Estado del Arte. *Cuaderno Activa*, (4), 55-65.
- González, L. (2014). Diseño de mezclas de concreto reforzado con fibras metálicas y de polipropileno, usando Inteligencia artificial. Tesis Doctoral (Ingeniería de Materiales). Universidad del Valle, Cali, Colombia.
- González, L., Guerrero, A., Delvasto, S. & Will, A. (2014). Estimación del índice de tenacidad flexural I_s en concretos fibro-reforzados, usando redes neuronales artificiales. *Revista Colombiana de Materiales*, (5), 24-29.

- Hinton, G. (1987). Connectionist learning procedure. Computer Science Department, Carnegie-Mellon University, Pittsburg, 58p.
- Hinton, G. (1989). Connectionist learning procedures. *Artificial Intelligence*, 40 (1-3), 185-234.
- Isasi, V. (2007). Redes de Neuronas. Universidad Carlos III de Madrid, Departamento de Informática. 59.
- Jacobs, R. (1988). Increased Rates of Convergence Through Learning Rate Adaptation. *Neural Networks*, 1 (4), 295-307.
- Karahan, O., Tanyildizi, H. & Atis, C. D. (2008). An artificial neural networks approach for prediction of long-term strength properties of steel fiber reinforced concrete containing fly ash. *Journal of Zhejiang University SCIENCE A*, 9 (11), 1514-1523.
- Kiş, O. & Uncuoğlu, E. (2005). Comparison of three back-propagation training algorithms for two case studies. *Indian Journal of Engineering & Materials Sciences*, 12, 434-442.
- Kurkova, V. (1992). Kolmogorov theorem and multilayer neural networks. *Neural Networks*, 5 (3), 501-506.
- Leshno, M., Lin, V., Pinkus, A. & Schocken, S. (1992). Multilayer feedforward networks with nonpolynomial activation function can approximate any functions. *Working Papers Series. New York University*, 26.
- Lourakis, M. (2005). A brief description of the levenberg-mardquardt algorithm implemented by Levmar. February. *Institute of Computer Science, Heraklion*, 7.
- Martínez, R. (2005). Errores frecuentes en la interpretación del coeficiente de determinación lineal. *Anuario Jurídico y Económico Escurialense*, (38), 315-332.
- Minai, A. & Williams, R. (January 1990). Acceleration of back-propagation through learning rate and momentum adaptation. Proceedings of the International Joint Conference on Neural Networks. Caudill, M. (Editor). Washington, D. C.
- Möller, M. (1993). Efficient training of feed-forward neural networks. Thesis Ph.D. (Computer Science), Aarhus University, Aarhus, Denmark.
- Moreira, M. & Fiesler, E. (1995). Neural networks with adaptive learning rate and momentum terms. Technical report. *Institut Dalle Molle D'Intelligence Artificielle Perceptive*, 30p.
- Niño, J. (2010). Tecnología del concreto. Tomo 1 Materiales, propiedades y diseño de mezcla. Asociación Colombiana de Productores de Concreto, Asocreto. Bogotá, 227.
- Nocedal, J. (1992). Updating Quasi-Newton metrics with limited storage. *Mathematics of Computation*, (35), 773-782.
- Noguchi, T., Maruyama, I. & Kanematsu, M. (May 2003). Performance based design system for concrete mixture with multi-optimizing genetic algorithm. Proceedings of the 11th International Congress on the Chemistry of Cement "Cement's Contribution to the Development in the 21st Century", Durban, South Africa.
- Polak, E. & Ribière, G. (1969). Note sur la convergence de méthodes de directions conjuguées. *Rev. Française Informât Recherche Opérationnelle*, 3 (16), 35-43.
- Powell, M. (1977). Restart procedures for the conjugated gradient method. *Mathematical Programming*, 12, 241-254.
- Richardson, A. & Landless, S. (2009). Synthetic fibres and steel fibres en concrete with regard to bond strength and toughness. *Nothumbria Built Environment Research Papers*, 2, (2), 128-140.
- Rumelhart, D., Hinton, G. & Williams, R. (1986). Learning internal representation by error propagation. *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, 1, 318-362.
- Torres, L. (1994,1995). Redes neuronales y aproximación de funciones. *Boletín de Matemáticas*, 1, 2 (1,2), 35-58.
- Unger, J. & Könke, C. (2011). An inverse parameter identification procedure assessing the quality of the estimates using Bayesian neural networks. *Applied soft computing*, 11 (4), 3357-3367.

“SI NO SABEMOS HACIA
DÓNDE QUEREMOS IR,
NINGÚN VIENTO NOS
SERÁ FAVORABLE.”

Séneca