

Desarrollo de un modelo de redes neuronales artificiales para predecir la resistencia a la compresión y la resistividad eléctrica del concreto

Developing an artificial neural network model for predicting concrete's compression strength and electrical resistivity

Juan Manuel Lizarazo Marriaga¹ y José Gabriel Gómez Cortés²

RESUMEN

En esta investigación se busca obtener un método para predecir la resistencia a la compresión mediante el peso unitario y la velocidad de pulso ultrasónico usando 41 mezclas de concreto diferentes. El estudio ha sido por la necesidad de obtener un método rápido para predecir la resistencia a la compresión del concreto. De la misma manera, la investigación también busca predecir la resistividad eléctrica del concreto mediante el peso unitario, la velocidad de pulso ultrasónico y la resistencia a la compresión. El modelo para predecir se realizó utilizando una regresión simple y un modelo de redes neuronales. Los resultados mostraron que los modelos de redes neuronales para predecir la resistencia a la compresión y la resistividad eléctrica del concreto funcionan adecuadamente.

Palabras clave: redes neuronales, resistencia a la compresión del concreto, resistividad del concreto, velocidad de pulso en el concreto.

ABSTRACT

The present study was conducted for predicting the compressive strength of concrete based on unit weight ultrasonic and pulse velocity (UPV) for 41 different concrete mixtures. This research emerged from the need for a rapid test for predicting concrete's compressive strength. The research was also conducted for predicting concrete's electrical resistivity based on unit weight ultrasonic, pulse velocity (UPV) and compressive strength with the same mixes. The prediction was made using simple regression analysis and artificial neural networks. The results revealed that artificial neural networks can be used for effectively predicting compressive strength and electrical resistivity.

Keywords: neural network, concrete strength, concrete resistivity, concrete ultrasonic pulse velocity.

Recibido: diciembre 20 de 2006

Aceptado: marzo 5 de 2007

Introducción

La presente investigación tiene como objetivo general desarrollar un modelo de redes neuronales para predecir la resistencia a la compresión y la resistividad del concreto, y como objetivos específicos implementar un programa experimental sobre 41 mezclas de concreto con diferentes características para medir la resistencia a la compresión, la velocidad de pulso ultrasónico, el peso unitario y la resistividad eléctrica de las probetas de concreto a los 28 días de edad.

Se pretende crear una red neuronal artificial utilizando el modelo de *back-propagation* de manera que la red neuronal construida sea entrenada y validada a partir de los resultados experimentales obtenidos. Se propone el uso de un modelo de redes neuronales para predecir la resistencia a la compresión a partir de variables como la velocidad de pulso ultrasónico y el peso unitario, variables no destructivas y de fácil obtención. De la misma forma, generar otro modelo de redes neuronales para predecir la resistividad del concreto

¹ Ingeniero civil. Especialista y M.Sc., en estructuras, Universidad Nacional de Colombia. Estudios sobre construcción y materiales, Instituto de Ciencias de la Construcción Eduardo Torroja, Madrid, España. Research student, Coventry University, Coventry, Reino Unido. Profesor, Departamento de Ingeniería Civil y Agrícola, Universidad Nacional de Colombia, Bogotá. Investigar, grupo de investigación en estructuras y materiales GIES. jmlizarazom@unal.edu.co

² Ingeniero civil. M.Sc., en estructuras, Universidad Nacional de Colombia. Especialista, Patología de la edificación, Instituto de Ciencias de la Construcción Eduardo Torroja, Madrid, España. Profesor, Departamento de Ingeniería Civil y Agrícola, Universidad Nacional de Colombia, Bogotá. Investigar, grupo de investigación en estructuras y materiales GIES. jggomez@unal.edu.co

a partir de la resistencia a la compresión, la velocidad de pulso y el peso unitario del concreto.

Resistencia del concreto

La resistencia a la compresión es el parámetro más usado para definir las características del concreto en estado endurecido su valoración se puede realizar mediante la fabricación de cilindros en el momento de la mezcla o mediante la extracción de núcleos una vez el elemento de concreto se encuentra en servicio. Los ensayos se realizan con el fin de determinar el cumplimiento de una especificación de resistencia o el de medir la variabilidad de la mezcla.

La Norma Técnica Colombiana NTC 2275 "Procedimiento recomendado para la evaluación de los resultados de los ensayos de resistencia del concreto" acepta una variabilidad en el concreto y muestra su relación con la resistencia. La variación en los ensayos realizados sobre muestras de concreto puede ser originada por dos grupos de factores, el control y utilización de los materiales y la realización de los ensayos propiamente dichos.

La resistencia no debe ser considerada como una propiedad intrínseca del material ya que durante la realización de un ensayo de control pueden existir variables como la geometría del espécimen, preparación de la muestra, contenido de humedad, temperatura, refrentado y velocidad de carga, que afectan los resultados obtenidos. La experiencia ha demostrado que el uso de ensayos diferentes para evaluar la misma propiedad, produce resultados diferentes.

Se asume que la resistencia del concreto tiene un comportamiento similar al de una curva de distribución normal de frecuencias. En la medida en que exista un control adecuado en los procesos de producción los datos se encontrarán agrupados sobre la media, mientras que si hay variaciones en los resultados la curva será aplanada y alargada.

La función de densidad que establece una distribución normal de la variable aleatoria X de la población es:

$$f(x) = f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}\right] \quad (1)$$

Siendo μ y σ^2 la media y la varianza respectivamente. La gráfica de la Ecuación se puede observar en la Figura 1.

Resistencia a la compresión y velocidad de pulso

La aplicación del método de velocidad de pulso ultrasónico a la tecnología del concreto está basada en el hecho de que la velocidad de las ondas de compresión V en una masa de concreto se relaciona con las propiedades elásticas del material mediante la siguiente ecuación:

$$V = \sqrt{\frac{E_d(1-\nu_d)}{\rho(1+\nu_d)(1-2\nu_d)}} \quad (2)$$

Donde E_d = módulo de elasticidad dinámico, ν_d = relación dinámica de Poisson y ρ = densidad (Ramachandran y Beaudoin, 1999).

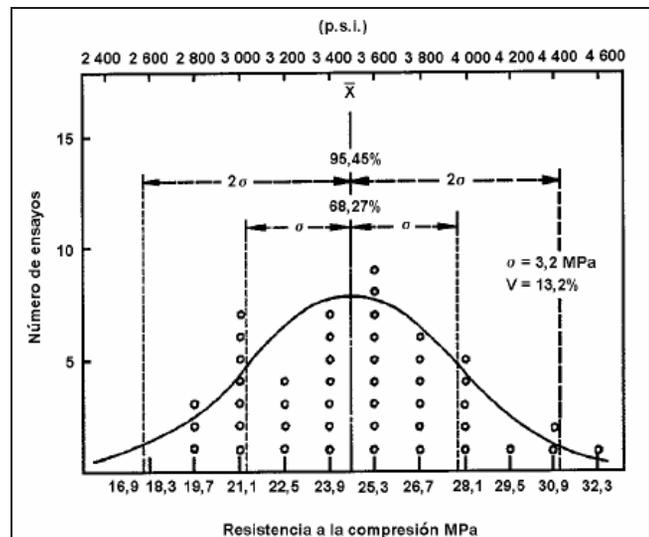


Figura 1. Curva de distribución normal de frecuencias

Teóricamente la velocidad de pulso depende únicamente de las propiedades del material y no de la geometría, por lo que se ha considerado un procedimiento adecuado para evaluar la calidad del concreto. Estas técnicas de transmisión fueron aplicadas por primera vez por Obert en 1940. Actualmente, el ensayo se encuentra normalizado por la ASTM C-597, "Standard Test Method for Pulse Velocity Through Concrete" (American Society of Testing Materials ASTM C-597), donde se especifican las características del instrumento utilizado y el procedimiento de ensayo.

Un impulso mecánico sobre un material puede generar tres tipos diferentes de ondas: longitudinal (compresionales), transversales (cortante) y de superficie (Rayleigh). Las ondas de compresión son las más rápidas, siendo las empleadas en el ensayo.

La velocidad de pulso ha sido utilizada en el concreto como una medida de control de calidad y en muchas áreas de investigación, aunque no se ha alcanzado un acuerdo total sobre la interpretación de los resultados. Normalmente se correlaciona con la resistencia o con el módulo de elasticidad; sin embargo, algunos trabajos recientes han mostrado que su correlación con la resistencia no parece ser la mejor (Mindess y Darwin, 2003).

Resistividad eléctrica del concreto

La resistividad se define como la resistencia eléctrica de un conductor de volumen unitario y área transversal constante, en la cual la corriente está continua y uniformemente distribuida. Puede ser interpretada como la resistencia eléctrica entre dos caras opuestas de un cubo de volumen unitario. En la Figura 2 se puede observar una caja construida con un material aislante con dos placas conductoras, rellena de un material que se quiere estudiar (Portland Cement Associa-

tion, 2003). Si se aplica una diferencia de potencial (voltaje) y se mide la corriente producida, la resistividad puede ser calculada con la siguiente Ecuación:

$$\rho = \frac{RA}{L} [\text{ohms} - m] \quad (3)$$

Siendo

$$R = \frac{V}{I} [\text{ohms}] \quad (4)$$

El inverso de la resistividad es la conductividad, que corresponde a una medida de la facilidad con la que la corriente pasa a través de un material.

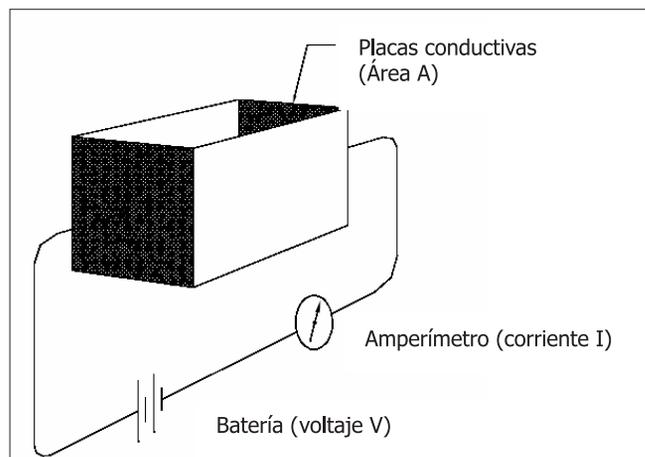


Figura 2. Circuito eléctrico

Dependiendo del tipo y de las características del material, los valores de resistividad pueden variar de forma importante. Valores de 10^{-6} ohms-cm pueden obtenerse para un material altamente conductor como la plata, mientras que valores de hasta 10^{19} , para materiales aislantes como el caucho y algunos polímeros.

Redes neuronales

Desde siempre, y paralelo al desarrollo de la civilización, el hombre ha sido capaz de conceptualizar la naturaleza, abstrayéndola a través de modelos que le han permitido entenderla y dominarla. En tal sentido, la modelación del concreto en estado fresco y endurecido mediante herramientas teóricas y matemáticas es un área que ha venido creciendo en los últimos años. En la actualidad el poder de cálculo que ofrecen los computadores personales ha permitido desarrollar tareas que eran impensables hace algún tiempo.

Entre las técnicas de inteligencia artificial que más se ha difundido y aplicado en el área de los materiales se encuentra la conocida como *redes neuronales artificiales*. Su pertinencia académica, investigativa e industrial se puede demostrar mediante la gran cantidad de trabajos publicados dentro de los últimos diez años. Durante este tiempo las redes neuronales artificiales han sido aplicadas en la modelación de un número importante de problemas de ingeniería civil con un grado aceptable de éxito. Las aplicaciones más

importantes se han realizado en los campos de la detección de daño estructural, identificación de sistemas estructurales, modelamiento del comportamiento de materiales, optimización estructural, control estructural, monitoreo de aguas subterráneas, predicción de asentamientos en fundaciones y proporcionamiento de mezclas de concreto (Graham et al., 2005).

Redes neuronales artificiales (RNA)

Una neurona dentro de un ser vivo tiene la función de controlar algunas de las funciones biológicas básicas, además del estado y comportamiento del organismo con respecto a su entorno. La operación básica de las redes neuronales biológicas es una operación análoga de transformación de sus señales de entrada. Por lo general, corresponden a sistemas de elementos simples muy interconectados. La posibilidad de las neuronas de desarrollar procesos complejos es el resultado de abundantes lazos de retroalimentación junto con no linealidades de los elementos de proceso.

Una neurona consta de un cuerpo celular más o menos esférico del que sale una rama principal conocida como el axón, y varias ramas más cortas llamadas dendritas. Las neuronas se diferencian de las demás células vivas por su capacidad de comunicarse, reciben señales de entrada que son combinadas, analizadas e integradas por el cuerpo celular, desde donde se emiten señales de salida que son llevadas a otras neuronas a manera de información.

Una red neuronal artificial es un modelo computacional que por su arquitectura intenta imitar las relaciones del comportamiento del cerebro. Consiste en un número limitado de elementos interconectados entre sí (neuronas) y distribuidos en una capa de entrada, una o más capas ocultas y una capa de salida. Las capas y las neuronas están interconectadas, como se muestra en la Figura 3.

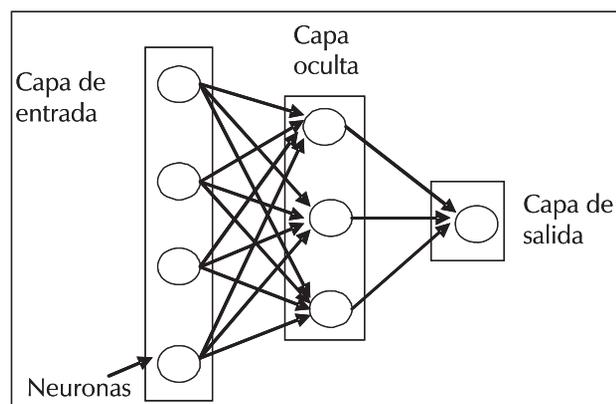


Figura 3. Topología modelo de redes neuronales

La capa de entrada tiene la función de recibir la información desde el exterior, mientras que las neuronas de la capa de salida son las encargadas de entregar los resultados de las predicciones realizadas por la red neuronal. Las capas ocultas generan las relaciones de encadenamiento entre las de entrada y salida, extraen y refinan las relaciones y

características de las variables de entrada para predecir las de salida que son de interés para el problema.

Comúnmente una red neuronal se entrena de manera tal que los pesos valores se ajustan de acuerdo a las variables de entrada y a las salidas esperadas. Esta situación se muestra en la Figura 4 (Demuth et al., 2006). La red se entrena ajustando los pesos mediante la comparación entre las salidas (valores que se predicen en el modelo) y los valores objetivo.

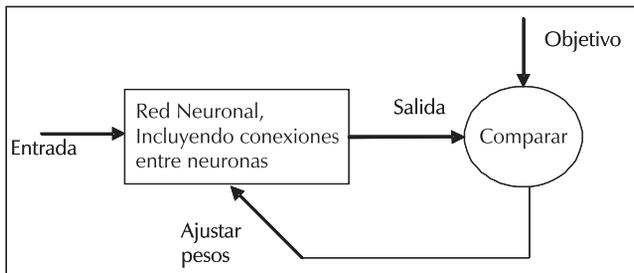


Figura 4. Entrenamiento de una neurona artificial (Demuth et al., 2006).

Neuronas artificiales

Normalmente, dentro de una red, la entrada a una neurona corresponde a un valor numérico definido como un escalar "p", que a su vez es multiplicado por un peso "w" para generar un producto wp, también escalar. Para generar una salida escalar "a" de una neurona es necesario evaluar una relación conocida como función de transferencia, "f", que en ocasiones puede estar influenciada por un sesgo definido por un escalar "b", denominado bias. Dependiendo de si la neurona tiene o no un escalar como sesgo, se define "n" como el argumento de la función de transferencia. Cada neurona recibe una entrada ponderada wp de otras y comunica sus salidas a otras más mediante una función de activación o de transferencia (Figura 5) (Demuth et al., 2006).

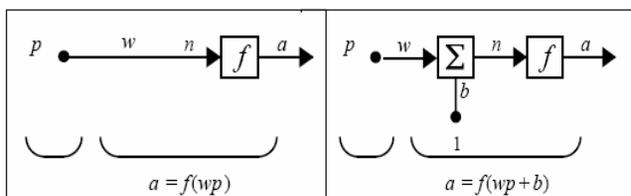


Figura 5. Elementos de una neurona (Demuth et al., 2006)

La función de transferencia "f" normalmente corresponde a una función escalonada, lineal o sinusoidal, que utiliza "n" como argumento y genera como salida al escalar "a". Los escalares "w" y "b", pueden ser ajustados dentro de la neurona de tal manera que la red presente algún comportamiento deseado, es decir, es posible entrenar la red para obtener una salida deseada. Cuando la neurona 1 contiene R entradas, el valor del argumento n de la función de transferencia se define como:

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b$$

donde R corresponde al número de elementos en el vector de entrada.

Generalmente una red neuronal es creada en dos fases, comúnmente referenciadas como fase de entrenamiento y fase de validación del modelo. Normalmente los pesos de la red son inicializados como valores aleatorios.

- Durante la fase de entrenamiento o aprendizaje la muestra que contiene tanto los datos de entrada como los de salida deseados, es procesada para optimizar la red en orden de minimizar el error entre los valores objetivos y las salidas del modelo.

Uno de los algoritmos de aprendizaje más utilizados en aplicaciones de ingeniería es el algoritmo conocido como *back-propagation*. Como su nombre lo indica y tal como lo definen Hilera y Martínez (1997), este tipo de red neuronal utiliza un procedimiento de retropropagación, esto es, un método de aprendizaje de un conjunto predefinido de entradas y salidas, empleando un ciclo de propagación.

- La fase de validación tiene por objeto verificar que la arquitectura de la red propuesta sea capaz de modelar adecuadamente el fenómeno que se está simulando.

Una de las características más importantes de una red neuronal *back-propagation* es que permite aproximar una función con un número importante de discontinuidades.

Desarrollo experimental

Con el fin de encontrar los modelos de redes neuronales artificiales óptimos para predecir la resistencia y la resistividad del concreto se desarrolló un amplio programa experimental consistente en la elaboración de 41 mezclas de concreto diferentes, en las que se varió la dosificación de cada una de ellas. Se fabricaron entre 5 y 7 cilindros por cada mezcla.

Para las mezclas realizadas se variaron los materiales constituyentes de la siguiente forma:

- Se trabajó para todas las mezclas con un mismo tipo de cemento.
- Se utilizó para todas las mezclas arena de la misma fuente.
- Se trabajó para todas las mezclas con agregado grueso de la misma fuente.
- Se varió el contenido de cemento en tres cuantías: 250, 300 y 350 kg/m³ de concreto.
- Se trabajó con tres relaciones agua-cemento: 0,45, 0,55 y 0,67.
- La arena se trabajó con dos granulometrías: una con un módulo de finura alto (3,3) y la otra con un módulo de finura bajo (2,2).
- El agregado grueso se utilizó con tres tamaños máximos diferentes 1", 3/4" y 1/2".
- En las mezclas secas y con poca manejabilidad se utilizó un aditivo plastificante en dosis muy bajas.

Todos los materiales constituyentes de la mezcla se caracterizaron de acuerdo a las recomendaciones de las Normas Técnicas Colombianas.

El cemento con el que se fundieron las probetas ensayadas corresponde a uno Río Claro Tipo III. La arena utilizada en la elaboración de las mezclas provino del municipio de Tabio, Cundinamarca, y corresponde a una de color gris, que originalmente presentó un porcentaje de finos igual al 13%, razón por la cual fue necesario lavarla para ajustarla a un porcentaje inferior al 5% de acuerdo con la Norma NTC 174: *Agregados para concreto*.

Ensayos realizados

Para cada una de las 41 mezclas efectuadas se fabricaron y ensayaron entre cinco y siete cilindros testigo para ser ensayados. Sobre cada uno de los cilindros obtenidos se realizaron ensayos de resistencia a la compresión, velocidad de pulso, peso unitario y resistividad eléctrica.

Como es bien sabido, el contenido de humedad de las muestras afecta los resultados de los ensayos propuestos, por lo que se estableció un tratamiento similar para todas las probetas. Este consistió en un curado sumergido durante los primeros 21 días, a esa edad se sacaron los cilindros de la piscina de curado y se dejaron secar al aire durante siete días. La edad de los cilindros en el momento del ensayo fue de 28 días.

Vectores para predecir la resistencia a la compresión

Para desarrollar el modelo de redes neuronales propuesto para predecir la resistencia a la compresión se utilizaron como variables de entrada la velocidad de pulso y el peso unitario, y como variable de salida la resistencia a la compresión. Se trabajó con una muestra de 187 conjuntos de datos.

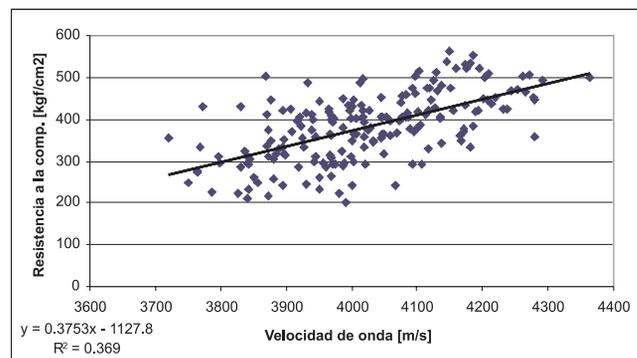


Figura 6. Correlación velocidad de onda – resistencia a la compresión

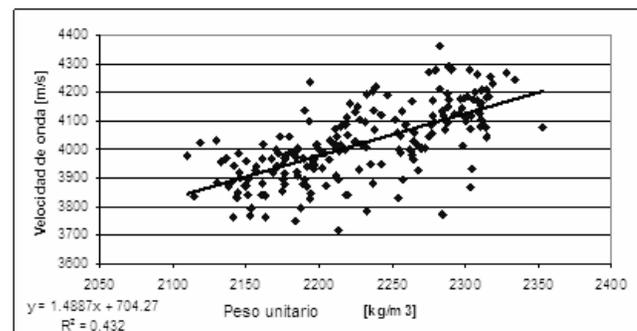


Figura 7. Correlación peso unitario – velocidad de onda

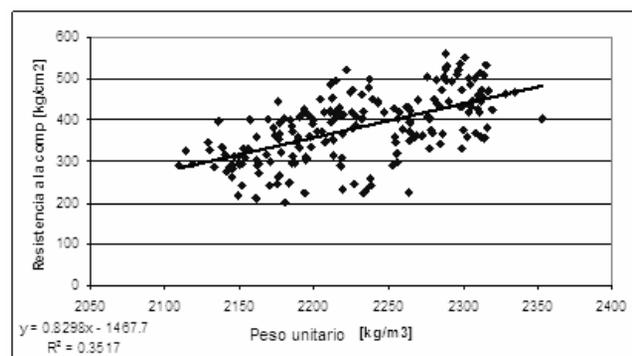


Figura 8. Correlación peso unitario – resistencia a la compresión

Para determinar la relación que existe entre las diferentes variables a ser usadas en el modelo de redes neuronales se aplicó una correlación lineal de mínimos cuadrados y se determinó el coeficiente de determinación entre ellas.

Vectores para predecir la resistividad eléctrica

El ensayo de resistividad es una prueba que no se encuentra normalizada y en la que si bien existen instrumentos comerciales para su valoración aún no existe un consenso general en la comunidad científica sobre la realización e interpretación del ensayo.

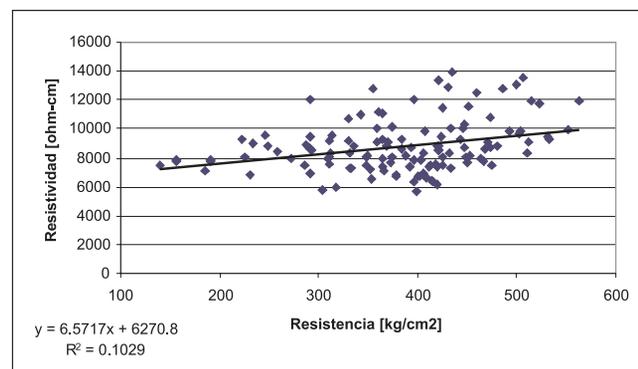


Figura 9. Correlación resistencia a la compresión – resistividad eléctrica

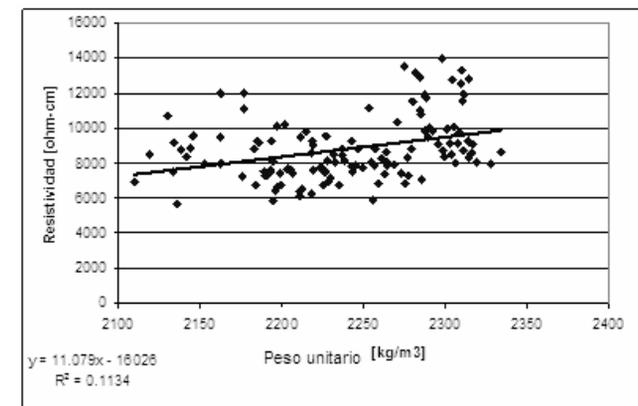


Figura 10. Correlación peso unitario – resistividad eléctrica

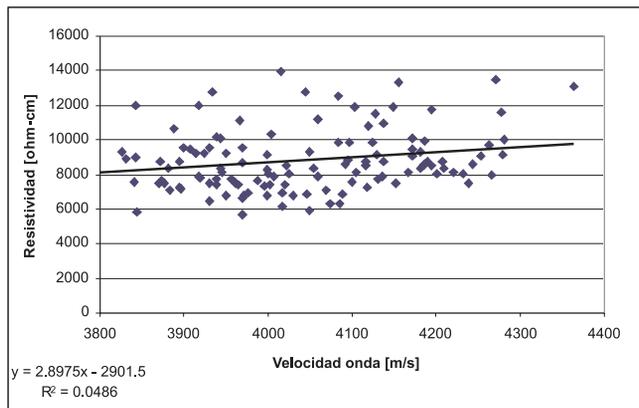


Figura 11. Correlación velocidad de onda – resistividad eléctrica.

Para desarrollar el modelo de redes neuronales propuesto para predecir la resistividad eléctrica se utilizaron como variables de entrada la resistencia a la compresión, la velocidad de pulso y el peso unitario, y como variable de salida la resistividad eléctrica.

Para determinar la relación que existe entre las diferentes variables a ser usadas en el modelo de redes neuronales se aplicó una correlación lineal de mínimos cuadrados y se determinó el coeficiente de correlación entre ellas.

De las figuras 6 a 11 y de acuerdo a los coeficientes de correlación determinados para las diferentes variables analizadas, se puede concluir que no existe una relación lineal definida entre ellas, razón que justifica el uso de un modeloredes neuronales para encontrarla.

Modelos de redes neuronales

La obtención de las arquitecturas de las redes neuronales para predecir la resistencia a la compresión y la resistividad eléctrica se obtuvieron mediante la aplicación comercial *Neural Network Toolbox* de MATLAB® (Demuth et al., 2006).

Para evitar las diferencias de escala entre las variables físicas que intervienen en la red se realizó un proceso de normalización, en el que cada variable se transformó a un sistema natural entre 0 y 1.

Los vectores usados en los modelos se dividieron en dos grupos, con el 77% de los datos se entrenó la red neuronal y con el 23% restante se validó. Se decidió partir cada vector en los anteriores porcentajes pues fue la configuración que se encontró ofreció mejores resultados.

Modelo de redes neuronales para predecir la resistencia a la compresión

En el modelo para predecir la resistencia a la compresión la arquitectura de la red neuronal que mejores resultados ofreció fue la siguiente:

Esta red está conformada por dos neuronas en la capa de entrada (velocidad de pulso y peso unitario), dos capas ocul-

tas de 15 y 10 neuronas cada una, respectivamente, y una capa de salida (resistencia a la compresión). A esta estructura se llegó después de probar diferentes configuraciones de número de neuronas y capas ocultas.

Una vez encontrados los pesos y los valores de bias a partir del entrenamiento de la red neuronal, se hace necesario verificar la confiabilidad del modelo. Es importante anotar que su validación se hace con el grupo de datos seleccionados para tal fin, datos que no tuvieron ninguna participación durante el entrenamiento, por lo que son un buen indicativo de la confiabilidad de la red neuronal.

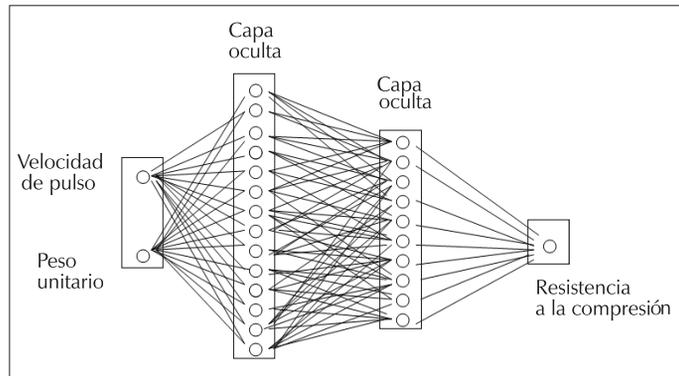


Figura 12. Arquitectura de la red neuronal propuesta.

En la Figura 13 se muestran los datos de validación (medidos experimentalmente) y los predichos mediante el modelo de redes neuronales propuesto.

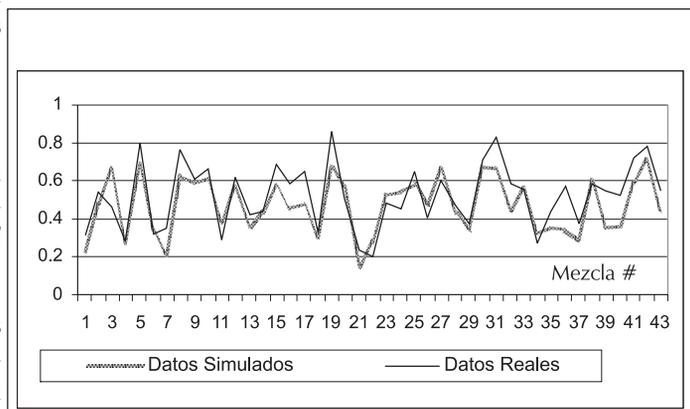


Figura 13. Valores reales y simulados de resistencia a la compresión

De la misma forma, se graficó la relación de los datos reales y simulados; para ellos se encontró un coeficiente de determinación R^2 de 0.7027.

El error encontrado para cada dato simulado se estableció mediante la siguiente Ecuación:

$$Error[\%] = \left| \frac{R_{real} - R_{simul}}{R_{real}} \right| * 100 \quad (5)$$

siendo R_{real} y R_{simul} los valores de resistencia medida y simulada, respectivamente. A continuación se muestra el error relativo para los datos simulados.

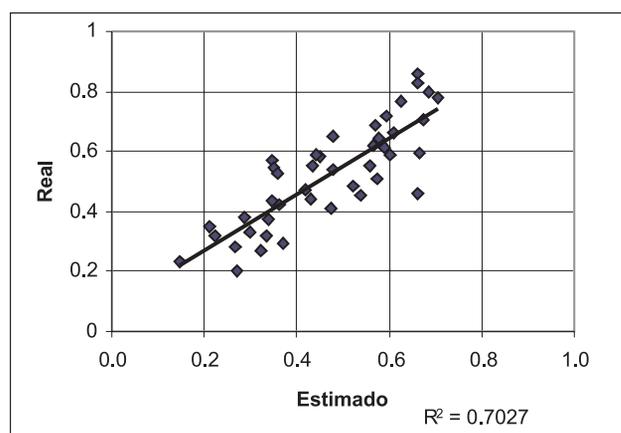


Figura 14. Valores reales y simulados de resistencia a la compresión

Tabla 1. Para los datos simulados el error promedio fue del 9,3%; el error máximo fue de 22,1% y el mínimo de 0,4%.

Real	Simulado	Error	Real	Simulado	Error	Real	Simulado	Error
Resistencia [kg/cm ²]	Resistencia [kg/cm ²]	[%]	Resistencia [kg/cm ²]	Resistencia [kg/cm ²]	[%]	Resistencia [kg/cm ²]	Resistencia [kg/cm ²]	[%]
310	272	12.0	419	365	13.0	520	451	13.2
401	376	6.3	447	376	15.8	420	361	14.1
370	451	22.0	316	303	4.3	407	408	0.4
295	290	1.8	533	451	15.4	291	313	7.6
506	461	9.0	388	415	7.1	359	323	10.1
312	318	1.9	275	241	12.5	413	322	22.1
324	267	17.7	262	291	11.1	335	297	11.3
493	436	11.5	379	395	4.3	421	427	1.3
431	422	2.2	365	401	9.9	405	323	20.1
453	430	5.1	445	417	6.4	396	326	17.6
300	332	10.8	348	375	7.6	475	423	10.9
434	413	4.9	425	453	6.5	500	469	6.3
354	328	7.3	374	352	5.9	406	359	11.6
361	357	1.0	333	320	4.0			
461	414	10.3	470	455	3.1			

Modelo de redes neuronales para predecir la resistividad eléctrica sobre el concreto

Respecto del modelo para predecir la resistividad eléctrica en el concreto, la arquitectura de la red neuronal que mejores resultados ofreció fue la mostrada en la Figura 15. Al igual que en el modelo de resistencia a la compresión, esta configuración se obtuvo realizando diferentes pruebas en el número de capas ocultas y en el de neuronas por capa.

Esta red está conformada por tres neuronas en la capa de entrada (resistencia a la compresión, velocidad de pulso y peso unitario), dos capas ocultas de ocho y doce neuronas cada una, respectivamente, y una capa de salida (resistividad eléctrica).

En la Figura 16 se muestran los datos de validación (medidos experimentalmente) y los predichos, mediante el modelo de redes neuronales propuesto.

La gráfica datos reales vs. simulados produjo una dispersión tal que el coeficiente de determinación R^2 corresponde a 0.4281.

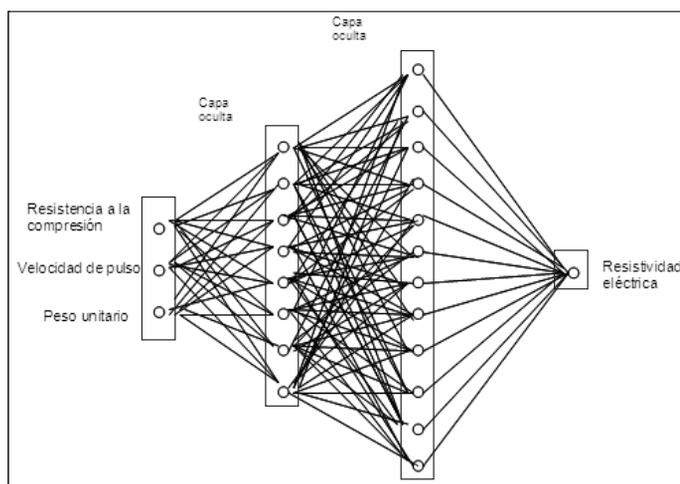


Figura 15. Arquitectura de la red neuronal propuesta.

El error relativo entre los datos reales y los simulados de resistividad eléctrica se muestra a continuación Tabla 2.

Conclusiones

A partir del trabajo experimental y analítico realizado se presentan las principales conclusiones y recomendaciones de la presente investigación.

Tal como se menciona en la literatura, la medición de cualquier parámetro físico en tecnología del concreto y en general de materiales, es un proceso en el que intervienen variables asociadas a los materiales y al ensayo. Se debe reconocer que esas variables tienen un comportamiento estocástico y no determinista, como a veces se suele pensar.

De todas las variables experimentalmente medidas acá sobre el concreto, la resistencia a la compresión y la resistividad eléctrica mostraron una dispersión alta (coeficiente de variación $> 20\%$), mientras que el peso unitario y la velocidad de pulso ultrasónico mostraron dispersiones bajas (coeficiente de variación $< 4\%$).

Los materiales usados en la elaboración de las mezclas son representativos de los utilizados normalmente en la elaboración de mezclas de concreto en la ciudad de Bogotá, por lo que los modelos desarrollados pueden ser aplicables a mezclas de concreto fundidas con materiales de naturaleza similar.

Aunque en la literatura se menciona una estrecha relación entre la resistencia, la compresión y la velocidad de pulso ultrasónico para el concreto, y algunos investigadores muestran gráficas y Figuras con muy buenas correlaciones, los datos experimentales medidos mostraron que el coeficiente de determinación para una regresión lineal de mínimos cuadrados para estas dos variables solo tiene un valor de $R^2 = 0.37$.

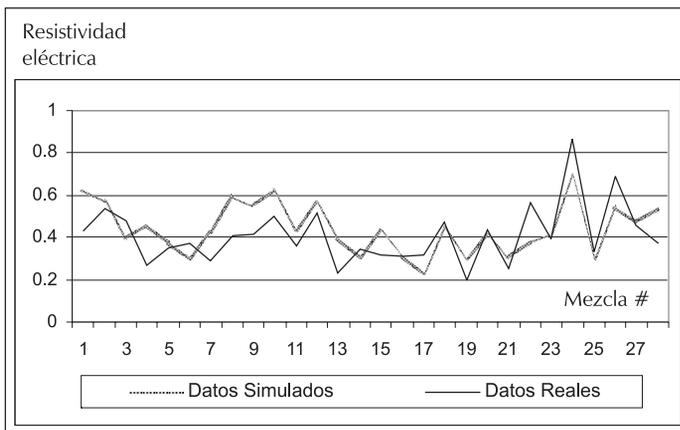


Figura 16. Valores reales y simulados resistividad eléctrica.

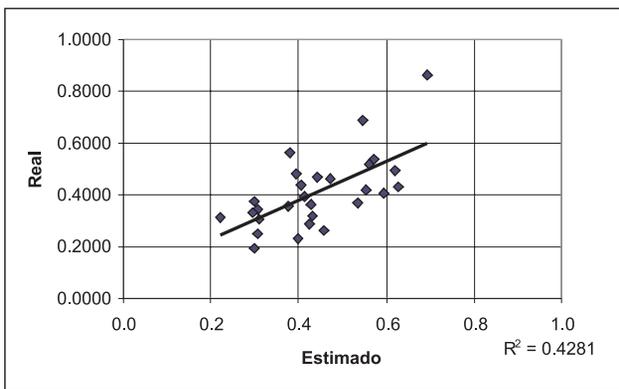


Figura 17. Valores reales y simulados resistividad eléctrica.

Tabla 2. Para los datos simulados el error promedio fue del 12,5%, el error máximo fue de 30,7% y el mínimo de 0,5%.

	<i>Real</i>	<i>Simulado</i>			<i>Real</i>	<i>Simulado</i>	
#	Resistividad ohm-cm	Resistividad ohm-cm	Error %	#	Resistividad ohm-cm	Resistividad ohm-cm	Error %
1	8739	10919	24.9	15	7521	8739	16.2
2	9917	10307	3.9	16	7372	7406	0.5
3	9264	8353	9.8	17	7470	6449	13.7
4	6908	9028	30.7	18	9177	8857	3.5
5	7900	8132	2.9	19	6143	7279	18.5
6	8131	7273	10.6	20	8814	8483	3.8
7	7177	8653	20.6	21	6759	7360	8.9
8	8475	10531	24.3	22	10173	8194	19.5
9	8591	10069	17.2	23	8330	8556	2.7
10	9465	10835	14.5	24	13499	11624	13.9
11	7970	8691	9.1	25	7661	7247	5.4
12	9693	10169	4.9	26	11556	9994	13.5
13	6552	8367	27.7	27	9067	9203	1.5
14	7760	7355	5.2	28	8071	9881	22.4

El modelo de redes neuronales propuesto para predecir la resistencia a la compresión del concreto presentó mejores resultados que los modelos de regresión de mínimos cuadrados. La resistencia a la compresión puede ser determinada de manera no destructiva usando este modelo.

Los errores relativos entre los datos de resistencia medidos y los simulados estuvieron entre 20% y 0,4%, siendo el máximo del mismo orden del coeficiente de variación. El error promedio fue del 9,3%.

El modelo de redes neuronales desarrollado para predecir la resistividad eléctrica del concreto, tuvo mejores resultados que los de regresión de mínimos cuadrados.

El uso de mínimos cuadrados para conocer la correlación entre la resistividad y la resistencia, velocidad de pulso y peso unitario, mostraron que aparentemente no existe relación alguna entre ellas (coeficientes de determinación $R^2 < 0.13$); sin embargo, a partir del modelo de redes neuronales desarrollado se pudo aumentar la correlación a valores cercanos a $R^2 = 0.42$.

Los errores relativos entre los datos de resistencia medidos y los simulados estuvieron entre 30% y 0,4%, siendo el máximo del mismo orden del coeficiente de variación. El error promedio fue del 12,5%.

En el entrenamiento de la red neuronal se obtuvieron mejores resultados utilizando los datos normalizados entre 0 y 1 respecto de los datos sin normalizar, esto debido a la influencia de la escala de las variables cuando se usan sin ningún tipo de normalización. De la misma forma, la red produjo mejores logros cuando los datos se introdujeron de manera aleatoria.

Se dispone para usos prácticos de una metodología que permite predecir la resistencia a la compresión de cilindros de concreto de manera no destructiva a partir de la obtención de la velocidad de pulso y del peso unitario del concreto.

Bibliografía

ASTM C 597., Standard Test Method for Pulse Velocity Through Concrete., Annual Book of ASTM Standards, American Society for Testing and Materials, West Conshohocken, PA, Vol. 4.02.

Demuth, H., Beale, M. and Hagan, M., Neural Network Toolbox., For Use with MATLAB®, 2006.

Graham, L. D. Forbes, D. R. and Smith, S., Modeling the ready mixed concrete delivery system with neural networks., Automation in Construction, Vol. 15, No. 5, 2006, pp. 656-663.

Hilera, J. R, y Martínez, V. J., Redes neuronales Artificiales: Fundamentos, Modelos y Aplicaciones., Castilla Editores, 1997.

Mindess, F. Y. and Darwin, C., Second Edition, Prentice Hall, 2003.

Obert, L., Measurement of pressures on rock pillars in underground mines., R.I. 3521, U.S., Bureau of Mines, 1940.

Portland Cement Association., Electrical Resistivity of Concrete – A Literature Review., PCA R&D, Serial No 2457, 2003.

Ramachandran, V. S. and Beaudoin, J. J., Handbook of analytical techniques in concrete science and technology - principles, techniques, and applications., Edited by Institute for Research in Construction National Research Council, Ottawa, Canada, 1999.