

# Aplicación de una red neuronal artificial a la dosificación de hormigones premezclados

## *Application of an artificial neural network to ready-mixed concretes mix design*

J. SETIÉN, I. A. CARRASCAL, J. F. FIGUEROA, J. A. POLANCO

División de Ciencia e Ingeniería de los Materiales. Escuela Técnica Superior de Ingenieros de Caminos, Canales y Puertos.  
Universidad de Cantabria

Fecha de recepción: 18-X-02

Fecha de aceptación: 26-XI-02

ESPAÑA

### RESUMEN

En este trabajo se presenta la aplicación práctica de una red neuronal artificial (ANN) al problema de la dosificación de hormigones en planta. Tras una breve introducción a la compleja problemática de la dosificación de hormigones y un repaso a los fundamentos de la neurocomputación, se diseña un modelo de red neuronal óptimo para abordar el problema. Para entrenar dicha red, se realizan varias amasadas de prueba, registrándose para cada una de ellas la trabajabilidad, mediante la medida del asiento del cono de Abrams, y la resistencia característica a los 28 días. Una vez entrenada la red, se pone a prueba su carácter predictivo comparando los resultados que proporciona con los de cuatro amasadas de referencia, demostrándose que esta aproximación puede ser utilizada como método multicriterial para la obtención de mezclas óptimas de hormigón.

**PALABRAS CLAVE:** neurocomputación, redes neuronales, procesamiento de datos, dosificación de hormigones, trabajabilidad

### 1. INTRODUCCIÓN

Tradicionalmente, el hormigón se fabrica a partir de unos pocos componentes bien definidos: cemento, agua, áridos finos y áridos gruesos. El objetivo final es conseguir una mezcla que proporcione una determinada resistencia a compresión característica, evaluada normalmente a la edad de 28 días.

### SUMMARY

This paper presents the practical application of an artificial neural network (ANN) to the problem of concrete mix in a factory. After a brief introduction to the complex problem of concrete mixes design and a quick review of the fundamental basis of neurocomputation, an optimal neural network model has been developed to cope with such a problem. For training the net, several control mixes have been fabricated recording in all cases both the characteristic 28 days compressive strength and the workability measured in terms of the slump of the Abrams' cone. After the training process of the net, the power of its predictive ability is checked by comparison of the results obtained with those corresponding to four reference mixes; in this way, it is shown that the considered approach can be used in multicriterial search for optimal concrete mixes.

**KEYWORDS:** neurocomputation, neural networks, data processing, concrete mix, workability

### 1. INTRODUCTION

Traditionally, concrete is fabricated from a few well-defined components: cement, water, fine aggregates and coarse aggregates. The main goal is to get a mixture with a specific characteristic compressive strength, normally evaluated at the age of 28 days.

Aunque, en apariencia, parece un problema sencillo en el que únicamente intervienen cuatro parámetros, que pueden elegirse como los contenidos relativos de cada uno de los componentes principales en la mezcla, nunca ha sido resuelto analíticamente de forma convincente. La mayoría de los métodos actuales de dosificación están basados en la generalización de experiencias previas, disponibles en forma de tablas o fórmulas empíricas.

La dificultad radica en el hecho de que aunque los componentes se describen utilizando un término simple para cada uno de ellos, en realidad se pueden presentar bajo una gran variedad de formas. Así por ejemplo, el cemento puede ser de distintas resistencias, finuras y composiciones químicas y los áridos finos pueden tener diferente tamaño máximo y naturaleza. Lo mismo ocurre con los áridos gruesos, que pueden ser rodados, de machaqueo, etc. Además, en las últimas décadas se han desarrollado nuevos componentes y tecnologías que han multiplicado el número de parámetros que intervienen en los métodos de dosificación; así, se utilizan aditivos químicos como plastificantes, aireantes o modificadores del tiempo de fraguado, y adiciones a los cementos como escorias siderúrgicas, cenizas volantes, humo de sílice, filler calizo, etc. Como consecuencia, el problema de la dosificación de hormigones se plantea en la actualidad en un espacio de decisión de 10, 20 o incluso más dimensiones.

A parte de los tipos de componentes empleados, las propiedades del hormigón se ven influenciadas no sólo por las proporciones de mezcla, sino también por la técnica de preparación de la misma. Además, la investigación en este campo se ve dificultada por el hecho de que los ensayos característicos típicos de control de la resistencia a compresión, como índice principal para evaluar la aptitud del hormigón, se deben realizar transcurridos 28 días (90 en algunos casos) a partir del momento en que se realiza la mezcla.

En este marco parece adecuada la introducción de técnicas basadas en el uso de redes neuronales artificiales (ANN), que abren nuevas posibilidades en la clasificación y generalización de variables y datos experimentales. Si el problema puede aproximarse de forma efectiva en un sistema neuronal, a pesar de la complejidad e incertidumbre de los datos, podría ser útil al ingeniero a la hora de dosificar hormigones como una nueva herramienta que apoya el proceso de selección y decisión, mejorando notablemente su eficiencia.

En este sentido, se han realizado varios intentos para el análisis y representación de datos (1), así como en la predicción tanto de resistencias (2, 3) como de asientos (4), pero hasta el momento no se tienen noticias de la

*On the surface, this seems to be a simple problem with only four decision parameters involved, which can be chosen as the relative proportions of each component in the concrete mixture, but this problem has never really been analytically solved in a convincing way. Most of the current design methods are based on a generalization of previous experience, available as tables or empirical formulas.*

*The difficulty lies in the fact that although the components could be described using only a single term for each one, they can actually appear under a great variety of forms. In this way, there are cements of various strengths, finenesses and chemical compositions, and the fine aggregates may be of different maximum grain size or origin. The same is true for the coarse aggregates, which can be rounded, crushed, etc. Moreover, in recent years both new components and technologies have emerged, notably increasing the number of parameters of the design procedure; in this manner, chemical admixtures as plasticizers, air-entraining agents or setting and hardening modifiers are now widely used, as well as additives for cements as blast furnace slags, fly ashes, silica fume or fillers. Consequently, the problem of concrete mix design might be posed as a search in a 10, 20 or even more dimensional decision space.*

*Apart from the component types used, the final properties of concrete are also influenced not only by the mix proportions but by the mix preparation technique. Besides, research in this field is hindered by the fact that a typical testing cycle for determining the compressive strength as an index of concrete fitness, takes about 28 days (or even 90 in some cases) after the fabrication of the mix.*

*In this context, the introduction of artificial neural networks techniques (ANN) which open up new possibilities in classifying and generalizing the available experimental results would seem appropriate. If such a problem can be effectively modelled in a neural system, in spite of data complexity and uncertainty, it might be useful for a concrete mix designer as a new tool that supports the decision process and improves its efficiency.*

*To this end, several attempts have been made to analyse and represent data (1) and to predict resistances (2, 3) as well as slumps (4), but to our knowledge no work in the opposite sense, which is the*

predicción en sentido inverso, que es el objetivo fundamental del presente trabajo. Así, los datos de partida en este estudio serán, precisamente, el asiento del cono y la resistencia característica del hormigón que se desea obtener, mientras que los “outputs” a la salida de la red neuronal se pretende que sean las cantidades de los distintos componentes que han de intervenir en la mezcla.

La metodología propuesta puede resultar de gran interés, sobre todo en aquellas instalaciones en las que usualmente se dosifica hormigón bajo condiciones de alta repetitividad y reproductibilidad, y además disponen de gran cantidad de datos experimentales para el correcto entrenamiento del sistema neuronal, como pueden ser las plantas de hormigonado.

## 2. CRITERIOS DE DOSIFICACIÓN

Como es bien sabido, el hormigón se obtiene por mezcla de cemento, áridos (gruesos y finos) y agua. Usualmente, la calidad del hormigón se especifica, entre otras, por medio de las dos propiedades siguientes:

(1) Resistencia: se mide en términos de la resistencia a compresión de probetas cilíndricas normalizadas de 150 mm de diámetro y 300 mm de altura, moldeadas y curadas bajo condiciones de saturación de humedad a temperatura constante, y ensayadas a una edad especificada (usualmente 28 días, aunque 7 y 90 días también son edades corrientemente contempladas).

(2) Docilidad: describe la capacidad de compactación del hormigón y se mide en términos del asiento (caída en milímetros) que experimenta un cono normalizado de hormigón fresco de 300 mm de altura, 200 mm de diámetro en su base y 100 mm de diámetro en la cima.

También es bien sabido que diferentes proporciones de mezcla dan lugar a hormigones con diferentes resistencias y trabajabilidades, pero incluso con la misma mezcla, estas propiedades pueden verse afectadas por la acción de factores externos como la humedad relativa o la temperatura ambiente, así como por propiedades intrínsecas de los constituyentes tales como el tamaño de las partículas de cemento, la textura superficial y la angulosidad de los áridos gruesos o la granulometría de los áridos finos. Esto sin considerar las posibles modificaciones inducidas por la acción de aditivos específicos como retardadores y aceleradores de fraguado, plastificantes, aireantes y pigmentos.

*main goal of this study, has been recorded. Thus, the input data in this work will be the slump and the compressive strength of the desired concrete, while the outputs of the neural network are intended to be the contents of the different components that must take part in the mix.*

*The proposed methodology may be of great interest, particularly in plants where the concrete is mixed under high-repeatability conditions and which also have at their disposal a huge amount of experimental data for the correct training of the neural system, as in the concrete factories.*

## 2. MIX CRITERIA

*As previously stated, concrete is fabricated by mixing cement, aggregates (coarse and fine) and water. Usually, the fitness for service of concrete is specified, among others, using the two following properties:*

*(1) Resistance: is measured in terms of the compressive resistance of standard cylindrical samples 150 mm diameter and 300 mm long, moulded and cured under saturated wet conditions at constant temperature and tested at specific age (very often 28 days, although 7 and 90 days are also ages usually considered).*

*(2) Workability: this refers to the ease with which concrete can be placed and compacted; it is measured in terms of the difference in height (slump in mm) of fresh concrete in the shape of a standard truncated cone (200 mm diameter at the base, 100 mm diameter at the top and a height of 300 mm) before and after the mould has been removed.*

*It is also well-known that different concrete mix proportions produce concretes of different strength and workability. Even with the same mix, these properties vary subject to some external factors such as relative humidity and ambient temperature, as well as inherent properties of the constituents such as the grain size of the cement particles, surface texture and angularity of the coarse aggregates or grading of fine aggregates. Besides, it is necessary to take into account the possible modifications due to the action of specific admixtures such as retarders or accelerators of setting time, plasticizers, air-entraining agents or pigments.*

En definitiva, tratar de encontrar la dosificación óptima bajo cualquier criterio que se asuma, implica la resolución de un problema no trivial de optimización en un espacio de 20 o 30 dimensiones, como ya se ha comentado con anterioridad, en el que no se conoce la forma analítica de la función objetivo. Y esto, sin mencionar otros importantes parámetros tecnológicos que también influyen en el proceso, como el volumen de la mezcladora empleada, el orden de introducción de los distintos componentes en la mezcladora o si el hormigón va a ser vertido o bombeado.

Solamente si el hormigón va a ser producido siempre en el mismo lugar, utilizando las mismas máquinas, tecnología y componentes, es posible obtener una versión notablemente simplificada del problema. El número de parámetros puede entonces reducirse a unos pocos que, básicamente, representarán las cantidades de componentes que han de intervenir en la mezcla. Parece, por tanto, obvio que los resultados más satisfactorios de la aplicación de técnicas de redes neuronales artificiales a la dosificación de hormigones se obtendrán en plantas de hormigonado que utilizan siempre el mismo tipo de cemento, los mismos acopios de áridos con sus granulometrías específicas, las mismas adiciones y aditivos suministrados siempre por el mismo fabricante.

En el caso particular implicado en este trabajo, se considera una planta de hormigonado que sistemáticamente emplea un cemento tipo I 42.5 R con una sustitución parcial de cenizas volantes de central térmica en proporciones variables; asimismo, se recurre a áridos de cantera propia clasificados en dos tamaños distintos: un árido grueso 12/20 y un árido fino 0/5. Por último, se incluye también la acción de un aditivo superplastificante en la dosificación de las amasadas.

### 3. ALGORITMO DE LA RED NEURONAL EMPLEADA

La teoría de las ANNs se introdujo por vez primera en la década de los años 40 del pasado siglo con el fin de simular el funcionamiento del cerebro humano (5). En la práctica, en inteligencia artificial, una ANN consta de unidades computacionales, llamadas neuronas, que imitan la acción de las células nerviosas humanas.

La neurona recibe uno o más datos de entrada, que convierte, por medio de una función disponible conocida como función de activación o función de transferencia, en un conjunto de datos de salida. Cuando se unen dos o más neuronas conjuntamente, se crea una red neuronal.

*Therefore, the search for an optimal mix under the assumption of any criterion involves the resolution of a non trivial problem of optimisation in a 20- or 30-dimensional space, while an analytical form of the objective function is unknown as was previously stated. Further relevant technological parameters which affect the process are the volume of the applied concrete mixing device, the mixing sequences, whether the material is to be cast or gunnited, etc.*

*Only when concrete is going to be produced at the same place, using the same machines, technology and components, is it possible to get a more simplified version of the problem. In this case, the number of parameters can be reduced to the few that represent the current quantities of the components in the mix. It seems obvious that the most satisfactory results of artificial neural network techniques applied to the concrete mix design will be achieved in concrete factories which always use the same type of cement, the same supplies of aggregates with specific gradings, and additives and admixtures always provided by the same purveyor.*

*In this particular work, a concrete factory using a cement I 42.5 R with partial substitution of thermal power plant fly ashes in different proportions has been considered; this factory also uses aggregates from its own quarry graded in two different sizes: coarse aggregate 12/20 and fine aggregate 0/5. Finally, the addition of a superplasticizer agent to the mixtures has also been taken into account.*

### 3. ALGORITHM OF THE NEURAL NETWORK USED

*The ANN theory was first proposed in the 1940s to simulate the working of the human brain (5). In practice, in artificial intelligence, an ANN consists of computing units, called neurons, that imitate the action of human nerve cells.*

*The neuron receives one or more input data which it converts, by means of a suitable function known as an activation or transfer function, into a single output datum. When more than one neuron are working together, the so-called neural network is created.*

Inicialmente, la idea de crear redes neuronales no gozó de mucho éxito y, por esta razón, fue abandonada durante muchos años. El espaldarazo definitivo llegó de la mano del bien conocido Teorema de Hecht-Nielsen (6) que establece que cualquier función vectorial  $y = f(x)$  puede calcularse utilizando una red neuronal disponible en la que todos sus niveles estén totalmente conectados entre sí, demostrándose así que una red neuronal puede resolver problemas de absoluta generalidad.

A diferencia de los algoritmos clásicos, en los que el problema se basa en una función  $y = f(x)$  donde  $x$  e  $y$  son, en general, vectores y  $x$  son los datos, en una red neuronal tanto  $x$  como  $y$  son datos y la función  $f$  es desconocida. Por tanto, en una red neuronal,  $f$  consiste en los modos en que los datos se transmiten de una neurona a otra y el conjunto de reglas sobre las cuales se apoya la transformación de datos dentro de cada neurona.

En base a estas premisas, todas las ciencias y tecnologías han hecho uso de las ANNs en mayor o menor medida, obteniendo en algunos casos resultados sorprendentes. No ha sido ajena a este progreso la Tecnología de los Materiales de Construcción (7), que se ha aprovechado de la potencia y flexibilidad que ofrecen en un amplio conjunto de problemas.

Como ya se ha comentado, las ANNs se basan en la organización de muchos elementos de proceso de forma semejante a la anatomía del cerebro humano. Además de estas semejanzas estructurales muestran unas propiedades funcionales muy interesantes, como son la capacidad de autoaprendizaje de la experiencia y la capacidad de generalización a partir de determinados ejemplos o casos, permitiendo incluso discernir entre ciertas características aun cuando existan datos equívocos o irrelevantes (8).

Su principal ventaja radica en solucionar problemas que son demasiado complejos para las técnicas convencionales: problemas que no tienen un algoritmo específico para su solución o, en caso de tenerlo, es demasiado complejo para ser encontrado. En cambio, existen tareas para las que las ANNs no son adecuadas, como pueden ser las tareas de cálculo y, en general, tareas repetitivas. Otro punto desfavorable es que las ANNs son incapaces de explicar el razonamiento que ha conducido a la resolución de un determinado problema, es decir, la red se comporta como una caja negra.

Los puntos clave de las ANNs se encuentran en sus componentes estructurales así como en sus propiedades funcionales. El conjunto de modelo de estructura y funcionamiento de una ANN se denomina paradigma. El paradigma consiste en la especificación de:

*At first, the idea of neural networks did not meet with a great deal of success and for this reason was abandoned for many years. The definitive support came from the well-known Hecht-Nielsen theorem (6) which states that any vector function  $y = f(x)$  may be calculated using a suitable neural network with all its levels totally connected between them and, as a consequence, the neural network can solve problems of absolute generality.*

*As opposed to a classical algorithm, in which the problem at hand is a function  $y = f(x)$  where  $y$  and  $x$  are, in general, vectors and  $x$  are the data and  $f$  is the form, in a neural network  $x$  and  $y$  are the data and the function  $f$  is unknown. In a neural network  $f$  consists of the modes in which data are transmitted from one neuron to another and of the set of rules upon which the transformation of data within each neuron is based.*

*In this framework, all the sciences and technologies applied the neural network approach to different problems, obtaining in some cases very surprising results. Technology of materials for construction is no exception (7) taking advantage of its power and flexibility in an extensive set of problems.*

*As previously stated, ANNs are based on the arrangement of many process elements which are intended to imitate the human brain anatomy. Beyond this structural similarity they exhibit some very interesting working properties, such as self-learning capacity from experience and generalisation ability from specific examples or cases, allowing to distinguish between some characteristics even if ambiguous or irrelevant data exist (8).*

*The main advantage lies in solving problems which are too complex for conventional techniques of calculus: problems with no specific algorithm to get the solution or with algorithms that are too complex to be readily found. However, ANNs are not appropriate for some tasks like repetitive calculus works. Another drawback is that ANNs are not capable of providing information about the reasoning followed to get the solution of a specific problem, i.e., a neural network works like a "black box".*

*Key points of ANNs are found in their structural components as well as in their operational properties. The structural model and working process of an ANN is called a paradigm. The paradigm consists in the specification of:*

- Los elementos de proceso: neuronas, función de activación, tipo de normalización, etc.
- La arquitectura de la red: número de niveles o capas, forma de las conexiones, número de neuronas por capa, etc.
- El método de aprendizaje.

El desarrollo de las ANNs consistirá básicamente en seleccionar el paradigma o paradigmas a utilizar, ajustar los parámetros de la red y conseguir efectuar un entrenamiento con el conjunto de datos adecuado.

El elemento básico que forma la ANN es, como ya se ha dicho, la neurona, cuyo esquema se ha representado en la Figura 1. La neurona está formada por una entrada,  $p$ , que puede ser múltiple, dos parámetros ajustables como son el peso,  $w$ , y el error,  $b$ , la función de activación,  $F$ , y la salida,  $a$ . En este trabajo, como se verá más adelante, las entradas serán dos y las salidas seis.

De forma más precisa, una vez la neurona  $i$  ha recibido los  $n$  datos de entrada  $p_j$ , que pueden proceder de otra neurona de una capa previa, y los ha multiplicado por los correspondientes factores de peso  $w$ , calcula su suma

$$S_i = \sum_j w_{ij} p_j \quad [1]$$

Esta suma se convierte en el argumento de la función de activación,  $F$ , proporcionando así el dato de salida,  $a$ , de la correspondiente unidad neuronal, dato que puede ser el output definitivo o bien servir de dato de entrada a las neuronas de otras capas posteriores:

$$T(S_i) = a_i \quad [2]$$

La función de activación puede tomar diferentes formas: lineal, escalón, rampa, tangente o sigmoidea; esta última ha sido la considerada en este trabajo y su ecuación viene dada por la expresión:

$$F(x) = \frac{1}{1 + e^{-\lambda x}} \quad [3]$$

Estas funciones no lineales, como ha demostrado Grossberg (9), son capaces de manejar con solvencia números tanto grandes como pequeños y son las más adecuadas para extender la potencia de las capacidades de la red.

Por otra parte, la arquitectura se refiere a la configuración de las neuronas, es decir, a la distribución de las mismas, así como a la forma de realizar la interconexión entre ellas. Las neuronas se distribuyen en capas (en serie) y dentro de cada capa las neuronas van colocadas en paralelo. Cada capa está totalmente conectada con la siguiente pero no existe conexión alguna entre neuronas de una misma capa.

- The process elements: neurons, transfer function, type of normalization, etc.
- The architecture of the network: number of layers, arrangement of connections, number of neurons per layer, etc.
- The learning methodology.

*The design of ANNs begins with the selection of a paradigm or paradigms to be used and the adjustment of network parameters; the final process involves the training of the neural system with a proper set of data.*

*As stated above, the basic element of ANN is the neuron that has been schematically represented in Figure 1. The neuron consists of an input,  $p$ , which can be multiple, two adjustable parameters such as the weight function,  $w$ , and error,  $b$ , the transfer function,  $F$ , and the output,  $a$ . In this work, as will be seen below, the number of inputs is two and the number of outputs is six.*

*More precisely, once the neuron  $i$  has received the  $n$  input data  $p_j$ , which can come from another neuron in a previous layer, and are multiplied by the weights  $w$ , it calculates their sum:*

*This sum thus becomes the subject of a certain transfer function,  $F$ , giving in this way the output datum,  $a$ , of the corresponding neural unit; this datum may be the definitive output or may act as an input datum for neurons in subsequent layers:*

*The transfer function may be of different types: linear, step, ramp, tangent or sigmoid; this latter type of function has been selected for this work, its mathematical form being:*

*These non-linear functions, as shown by Grossberg (9), are able to handle both small and large numbers and are also the most adequate to expand the power of the network's capability.*

*On the other hand, architecture deals with the arrangement of neurons, that is, their distribution and the way in which they are interconnected. Neurons are arranged in layers (in series) and inside each layer neurons are placed in parallel. Each layer is totally connected with the next one but no connections exist between neurons on the same layer.*

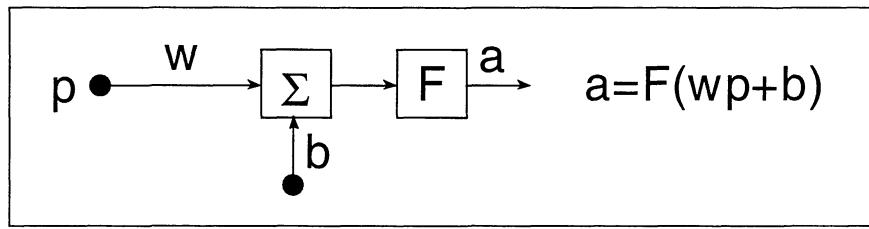


Figura 1.- Esquema de una neurona.

*Figure 1.- Schematic representation of a neuron.*

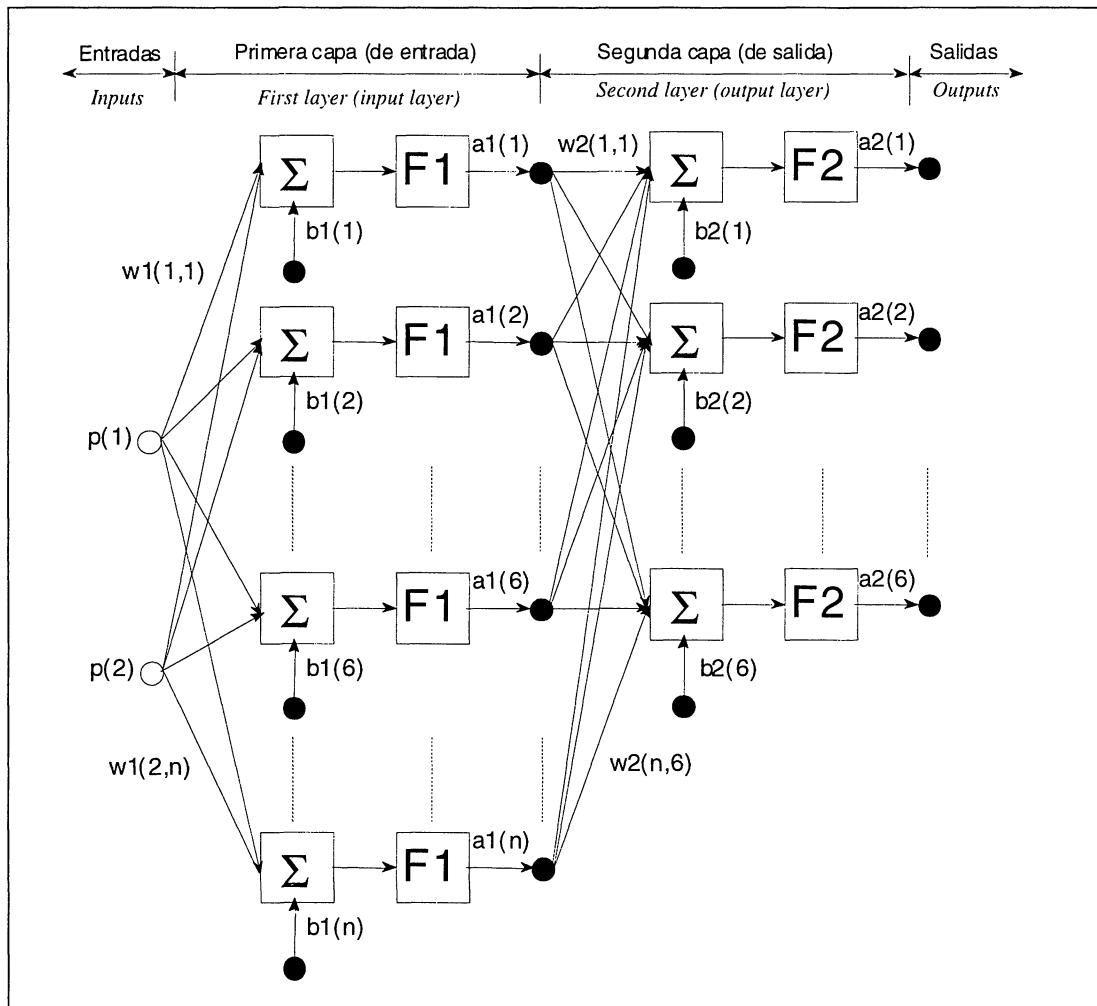


Figura 2.- Arquitectura de la red neuronal estructurada en dos capas.

*Figure 2.- Architecture of a two layer neural network.*

En este trabajo, en primera instancia, se ha empleado una red de dos capas con un número variable de neuronas en la capa de entrada y 6 en la de salida, según se indica en la Figura 2. Para la elección del número de neuronas en la capa de entrada se ha seguido el método de prueba y error, comprobándose que, para los datos experimentales disponibles, el error acumulado presenta una meseta estable para valores

*In this work, in a first approach, a network of two layers with a variable number of neurons in the input layer and 6 neurons in the output layer has been used, as shown in Figure 2. For the choice of the neuron's number in the input layer a trial and error method has been applied showing, for the available set of*

comprendidos entre 6 y 25 neuronas, como se muestra en la Figura 3; para números superiores de neuronas, pueden obtenerse puntualmente errores inferiores, pero la red se vuelve inestable. En base a esta figura, se han tanteado tres redes con 6, 15 y 25 neuronas, respectivamente en la capa de entrada. El número de neuronas en la capa de salida viene fijado por el número de datos de salida que se pretende conseguir.

Haciendo uso de los datos disponibles, una ANN “aprende” las relaciones esenciales entre entradas y salidas dadas por el almacenamiento de la información en una distribución de pesos de conexión. Un algoritmo de aprendizaje proporciona las reglas o ecuaciones dinámicas que cambian la distribución de los pesos. Una vez aprendida la relación fundamental entre entradas y salidas, la red neuronal debe entonces ser capaz de generar salidas razonables para entradas desconocidas. Este proceso se denomina generalización.

El algoritmo de *backpropagation* (10, 11), es el más importante, aunque no el único, que pueden emplear las ANNs para la calibración de los factores de peso,  $w(i,j)$ . La base del aprendizaje que emplea este algoritmo es bastante simple: puesto que en cada presentación de un conjunto de datos experimentales de entrenamiento se conoce la diferencia entre la salida deseada y la realmente conseguida, se puede calcular el valor del error cuadrático cometido. En

*experimental data, that accumulated error exhibits a stable plateau for values in the range of 6 to 25 neurons, as shown in Figure 3; higher numbers of neurons can occasionally lead to lower errors but the network becomes unstable. According to this figure, three different networks with 6, 15 and 25 neurons in the input layer have been checked. The number of neurons in the output layer is predetermined by the number of output data under consideration.*

*Making use of the available data, an ANN “learns” the essential relationships between inputs and outputs provided by the storage of information in a distribution of weights of connection. A learning algorithm gives the rules or dynamical equations for changing such a distribution of weights. Once the fundamental relationship between inputs and outputs has been established, the neural network should be capable of generating reasonable outputs from unknown inputs. This process is called generalization.*

*The backpropagation algorithm (10, 11) is the most important, but not the only one, that can be used by ANNs for the calibration of weights,  $w(i,j)$ . The basis of learning in this algorithm is quite simple: the knowledge of the difference between the true output and the output actually obtained for any training experimental set of data allows the estimation of the corresponding squared error sum to be made. The normal process is to start from a vector with input  $X$*

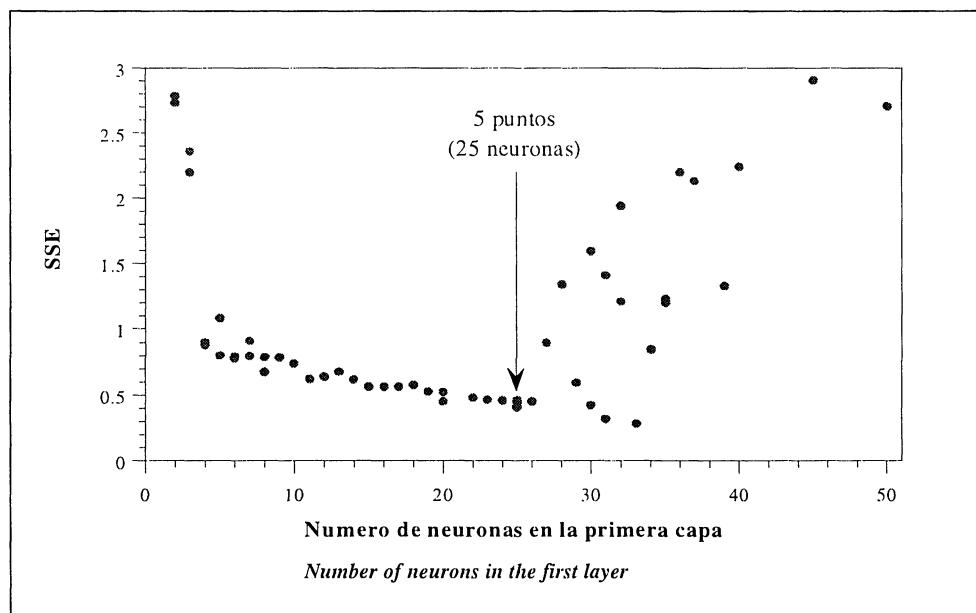


Figura 3.- Variación del error acumulado en función del número de neuronas en la primera capa para 5.000 épocas.

Figure 3.- Variation of accumulated error as a function of the number of neurons in the first layer for 5.000 epochs.

efecto, conocido un vector de entrada,  $X$ , y su correspondiente salida,  $O$ , ambos datos experimentales, para el vector  $X$  la red calculará una cierta salida,  $Y$ , que en general diferirá de la salida exacta,  $O$ , de forma que el error cometido por la red puede definirse como:

$$SSE = \frac{1}{2} \sum_j (O_j - Y_j)^2 \quad [4]$$

El objetivo fundamental es minimizar este error. Para ello se han de modificar los pesos de cada uno de los elementos que integran la capa en el sentido de disminución de éste, lo cual se consigue modificándolos en la dirección de su derivada (gradiente).

El problema que existe para las capas intermedias que no son de salida, donde no se conoce la salida deseada de los elementos de dicha capa, se resuelve estimando el valor que hubiera tenido la salida deseada en función de los errores cometidos en la capa posterior, es decir, el ajuste de los pesos de una capa se realiza en función de la variación del error de la capa posterior (propagación del gradiente del error). Esto se realiza de forma iterativa para cada una de las capas empezando por el final y retrocediendo hacia atrás hasta reducir al máximo posible el error de la red, lo que justifica la utilización del término *backpropagation* (12). Cada una de estas iteraciones realizada por el algoritmo para todos los datos experimentales disponibles se denomina época; al final de cada época los parámetros  $w(i,j)$  y  $b(i)$  variarán, por tanto, en función de la suma del error cuadrático acumulado (SSE) a lo largo de la totalidad de las iteraciones.

Una vez establecida así la red neuronal, se considera que los factores de peso,  $w(i,j)$ , son los idóneos para un conjunto dado de datos experimentales,  $X_j$ , puesto que cuando se alimenta la red con todos estos vectores en la capa de entrada, la respuesta a la salida,  $Y_j$ , es tal que el error implicado, SSE, es mínimo. Cuando se carga un nuevo vector,  $X_n$ , la red neuronal proporcionará una respuesta,  $Y_n$ , que se denomina la predicción o estimación de la red neuronal.

Esta capacidad predictiva de la red neuronal es la que se aprovecha en este trabajo para la determinación de dosificaciones óptimas de hormigones premezclados bajo las condiciones anteriormente expuestas.

#### **4. PROCESO DE ENTRENAMIENTO DE LA RED**

Una vez la red ha sido completamente definida, pero antes de que pueda ser implementada, ha de procederse a la etapa de entrenamiento o aprendizaje, esencial para la calibración de los factores de peso y la minimización

and the corresponding output  $O$ ,  $X$  and  $O$  being experimental data. Once the vector  $X$  is loaded, the network calculates a certain output  $Y$ , which in general will be different from the true output  $O$ . The error committed by the network may thus be defined as:

The main goal is to keep this error as a minimum. In this way, weights of elements on each layer should be modified in order to minimize it, which can be achieved by doing this in its derivative direction (gradient).

A problem remains for the intermediate hidden layers which are not output layers and for which the real output of their elements is unknown; the solution is to estimate the value of the true output as a function of errors committed in the next layer, that is, the choice of weights in a layer takes into account the change of error in the next layer (propagation of the gradient of error). This procedure is repeated for each layer beginning with the final layer and propagating backwards until the network error is conveniently reduced and the term backpropagation is then justified. Each of these iterations made by the algorithm for all the available experimental data is called an epoch; at the end of each epoch, parameters  $w(i,j)$  and  $b(i)$  will vary as a function of the sum of accumulated squared error (SSE) throughout all the iterations.

Once the neural network has been established, its weights  $w(i,j)$ , are the best possible ones for the given experimental data,  $X_j$ , because when all these vectors are loaded onto the input layer of the neural network, the response,  $Y_j$ , is such that the error, SSE, is a minimum. When a new vector is loaded,  $X_n$ , the neural network will provide a response,  $Y_n$ , which is called the prediction or estimation of the neural network.

This predictive capability of the neural network is used in the present work for the design of optimal concrete mixes under the considerations stated above.

#### **4. TRAINING PROCESS OF THE NETWORK**

Once the network is completely defined but before its implementation, the training or learning stage, essential for calibration of weights and minimization of error, must occur. To do this, significant series of

del error. Para ello es necesario disponer de series significativas de datos experimentales y resultados para alimentar la red.

En este trabajo, se han llevado a cabo 30 amasadas de prueba, con los materiales seleccionados, utilizando una hormigonera de eje vertical. Las amasadas estaban dosificadas para obtener 40 litros de hormigón y la incorporación de los distintos componentes ha seguido siempre el siguiente orden:

- 20% del agua
- 100% del árido 0/5
- 100% del árido 12/20
- 100% del cemento I 42.5 R
- 100% de la ceniza volante
- 80% restante del agua con el aditivo superplastificante

En todos los casos considerados, el tiempo de amasado ha sido de 3 minutos a partir de la incorporación del último componente a la hormigonera.

Las dosificaciones propuestas iban encaminadas a la consecución de 5 tipos distintos de hormigón, con resistencias características a 28 días de 15, 17,5, 20, 25 y 30 MPa, respectivamente, y dos consistencias, plástica y blanda, para cada uno de ellos.

Dicha consistencia ha sido determinada experimentalmente por medio del asiento del cono de Abrams, según las especificaciones recogidas en la Norma UNE 83-313:90, tomándose dicha medida a los 4 minutos contados a partir del momento de la fabricación del hormigón para todas las dosificaciones ensayadas.

Por su parte, la resistencia mecánica a compresión del hormigón se ha calculado siguiendo las directrices impuestas en la Norma UNE 83-304:84. El proceso de compactación utilizado en todas las amasadas es del tipo vibración externa, el curado de las probetas se realizó en cámara húmeda y la rotura de las mismas, tras refrentado con mortero de azufre, en una máquina hidráulica de 150 t de capacidad.

Con estos datos y resultados, se ha procedido al entrenamiento de la ANN, utilizando como parámetros de entrada el asiento del cono y la resistencia característica, y obteniendo como parámetros de salida las cantidades de cemento, ceniza volante, árido 0/5, árido 12/20, aditivo superplastificante y agua que se deben mezclar para obtener un metro cúbico de hormigón que cumpla las especificaciones de docilidad y resistencia previamente consignadas.

*experimental data and results are needed for the network training.*

*In this work, 30 batches of control have been carried out with the selected materials using a drum mixer. The mixtures were designed in order to get 40 litres of concrete in a single-stage mixing with the following sequence batching of all the ingredients:*

- 20% of water
- 100% of aggregate 0/5
- 100% of aggregate 12/20
- 100% of cement I 42.5 R
- 100% of fly ash
- 80% of remaining water with the superplasticizer admixture.

*In all cases, the mixing time has been 3 minutes from the incorporation of the last ingredient to the mixer.*

*The proposed mixes were designed to achieve 5 different types of concrete, with 28 days strengths of 15, 17.5, 20, 25 and 30 MPa, and two different consistencies for each one of them.*

*Such a consistency has been experimentally estimated by means of the slump of Abrams' cone according to the regulations of the standard UNE 83-313:90, taking the measurement 4 minutes after the concrete fabrication for all the considered mixes.*

*On the other hand, compressive mechanical strength of concrete has been evaluated following the regulations in the standard UNE 83-304:84. The compaction process for all mixes was external vibration, the samples were cured in a humidity controlled chamber and the tests after sulphur mortar capping were carried out in a hydraulic machine having 150 t of loading capacity.*

*With these data and results, the ANN training has been successfully completed, using as input parameters the slump and the compressive strength and obtaining as output parameters the proportions of cement, fly ashes, fine and coarse aggregates, superplasticizer admixture and water which should be mixed in order to reach a cubic meter of concrete with both the resistance and workability previously stated.*

## 5. RESULTADOS OBTENIDOS

Con el fin de contrastar el potencial predictivo de la red neuronal diseñada se han considerado cuatro amasadas de referencia con distintos valores de consistencias y resistencias características que, lógicamente, no han sido incorporadas a la red durante el proceso de aprendizaje.

El procedimiento operativo a seguir es alimentar la red con los datos de entrada, asiento del cono y resistencia característica, de cada una de estas cuatro amasadas de referencia. La red neuronal, a la salida, nos proporcionará las cantidades de los seis componentes básicos cuya mezcla daría como resultado un hormigón con las propiedades deseadas. Estos valores de salida ( $S_{exp}$ ), serán comparados con los reales de las amasadas de referencia ( $S_{real}$ ), evaluando en cada caso un error relativo,  $e(\%)$ , calculado a partir de la siguiente expresión:

$$e(\%) = \frac{S_{exp} - S_{real}}{S_{exp}} \times 100 \quad [5]$$

Como índice de la calidad de la predicción se evalúa, para cada amasada de referencia, un promedio de los errores obtenidos en la determinación de cada uno de los seis componentes básicos.

En la Figura 4, se muestran los resultados obtenidos con 5000 épocas, para las cuatro amasadas de referencia, utilizando una red neuronal de dos capas con 6 (6/6),

## 5. RESULTS

*In order to check the predictive capability power of the designed neural network, four mixes of reference with different values of resistances and slumps have been considered; obviously, these four mixes have not been loaded in the network during training process.*

*The procedure consists in loading the network with input data, that is, slump and compressive resistance, for each one of the four reference mixes. The neural network will provide as response the proportions of the six basic components whose mixture leads to a concrete with the desired properties. These output parameters ( $S_{exp}$ ) will be compared with true values from reference mixes ( $S_{real}$ ) evaluating the relative error through the formula:*

*As an index of fitness of predictions for each reference mixture an average of errors in the estimation of each individual basic component is considered.*

*Figure 4 shows the results obtained for the reference mixtures in 5.000 epochs using a two layer neural network with 6 (6/6), 15 (15/6) and 25 (25/6) neurons,*

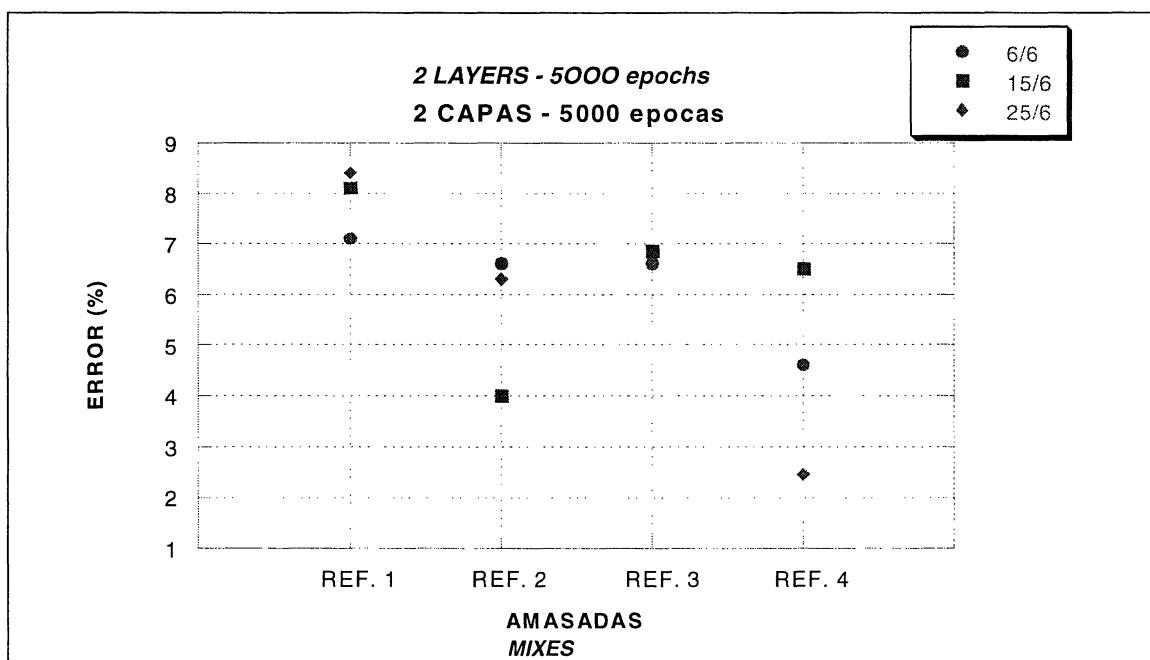


Figura 4.- Errores obtenidos para las cuatro amasadas de referencia con una red neuronal estructurada en dos capas.

Figure 4.- Average errors obtained from a two layer neural network for the four reference mixtures.

15 (15/6) y 25 (25/6) neuronas, respectivamente, en la capa de entrada y 6 neuronas en la capa de salida. En dicha figura se observa que, en todos los casos contemplados, el error promedio de las predicciones se mantiene por debajo del 10%. La mejor predicción corresponde a la amasada de referencia número 4 (asiento del cono igual a 3 cm y resistencia característica de 39 MPa), para la que dos diferentes arquitecturas de la red neuronal proporcionan errores inferiores al 5%.

Con el fin de intentar mejorar los resultados obtenidos, se modifica la arquitectura de la red neuronal empleada, ampliándola a un diseño en tres capas en la que se intercala una capa oculta entre las de entrada y salida. El número de neuronas en esta capa intermedia lo fija el operador de forma arbitraria: aunque no hay reglas generales precisas al respecto, existen algunos criterios empíricos para estimar este número, como el que establece que el número de neuronas en la capa intermedia debe ser el doble que el de neuronas en la capa de entrada, que ha sido el criterio adoptado en el presente trabajo.

De esta forma, se han probado las siguientes configuraciones, todas ellas con 5.000 épocas: (6/12/6), (10/20/6), (15/30/6) y (25/50/6). En la Figura 5 se muestran los resultados obtenidos para las cuatro amasadas de referencia. Puede verse en esta figura que los resultados empeoran para la amasada de referencia número 1 (asiento del cono igual a 7 cm y resistencia característica de 24 MPa), con errores promedio superiores en algunos casos al 10%, pero se observa que se obtienen buenos resultados para las tres amasadas restantes, en especial con la configuración (15/30/6), que proporciona para ellas errores inferiores al 5%, manteniéndose por debajo del 10% para la primera. Como ejemplo ilustrativo, en la Tabla 1 se muestran los resultados de las predicciones obtenidas con esta configuración para la amasada de referencia número 3 (asiento del cono igual a 6 cm y resistencia característica de 34 MPa), observándose el grado de acuerdo conseguido con un error promedio del 2,5%.

En base a estos resultados, se ha efectuado una última comprobación tratando de reducir, en la medida de lo posible, los errores obtenidos hasta el momento. Seleccionando la configuración que mejores resultados globales ha proporcionado, es decir (15/30/6), se han realizado 5 ajustes distintos con esta red, todos ellos de 5.000 épocas, y se han calculado los valores medios de las predicciones de los seis parámetros considerados y sus correspondientes errores. Paralelamente, utilizando esa misma configuración, se han realizado otros dos ajustes aumentando sensiblemente el número de épocas hasta 172.000 y 200.000, respectivamente. En la Figura 6 se muestran, comparativamente, los resultados obtenidos en estos dos planteamientos.

respectively, in the input layer and 6 neurons in the output layer. As can be seen in the figure, the average error of predictions is kept below 10% in all cases. The best prediction corresponds to reference mixture number 4 (slump 3 cm and resistance 39 MPa): two different network architectures give rise to less than 5% of error.

In order to improve the obtained results, the architecture of the network is modified to get a three layer design with a hidden layer between the input and output layer. The number of neurons in the middle layer is arbitrary fixed by the operator: though general rules do not exist for estimating this number, there are some empirical criteria suggesting that the number of hidden neurons must be twice the number of neurons in the first level; this criteria has been adopted in this work.

To this end, the following arrangements have been tested for 5.000 epochs: (6/12/6), (10/20/6) and (25/50/6). Figure 5 shows the results obtained for the reference mixtures. As can be easily seen, a worsening of results for reference mixture number 1 (slump 7 cm and resistance 24 MPa) is reported, with average errors higher than 10% in some cases; however, good results were obtained for the three remaining mixtures, particularly with (15/30/6) configuration which gave for them errors less than 5% and even below 10% for the reference mixture number 1. As an illustrative example, Table 1 shows the predictive results obtained from such configuration for reference mixture number 3 (slump 6 cm and resistance 34 MPa); a high level of matching has been reported in this case with an average error of 2.5%.

According to these results and in order to reduce the errors, a new test has been carried out. Selecting the best configuration at that moment, i.e. (15/30/6), five different fittings of 5.000 epochs have been carried out with this network and both the mean values of predictions for the six output parameters and corresponding errors have been calculated. In the same way, using the same configuration, two more estimations have been carried out with a remarkable increase in the number of applied epochs up to 172.000 and 200.000, respectively. Figure 6 shows comparatively the results obtained from these two different approaches.

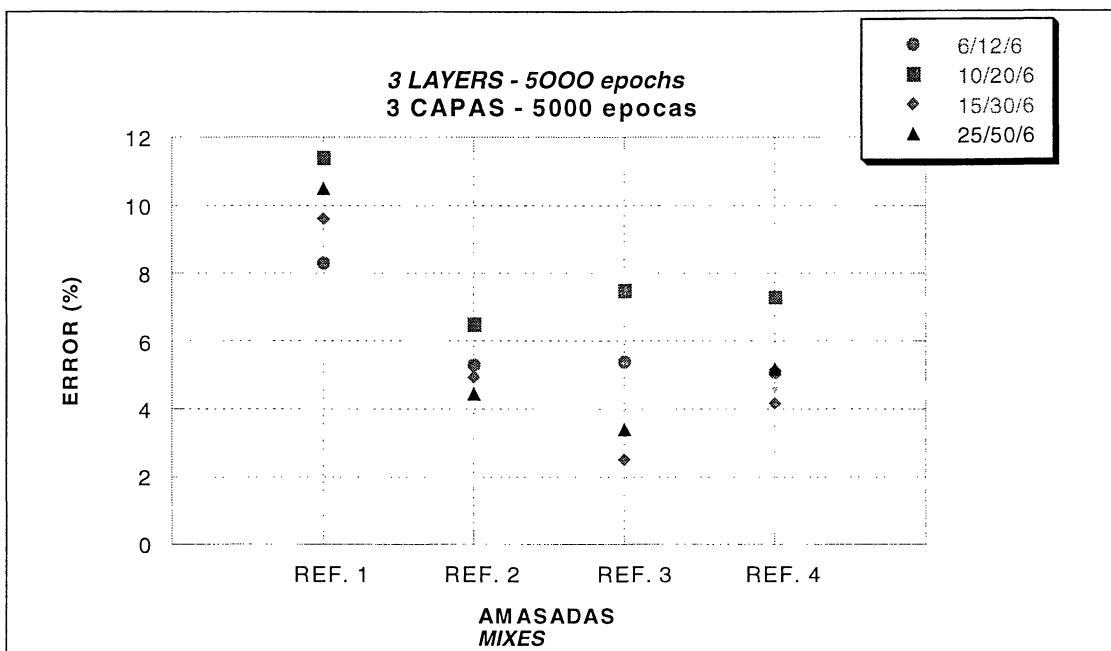


Figura 5.- Errores obtenidos para las cuatro amasadas de referencia con una red neuronal estructurada en tres capas.

Figure 5.- Average errors obtained from a three layer neural network for the four reference mixtures.

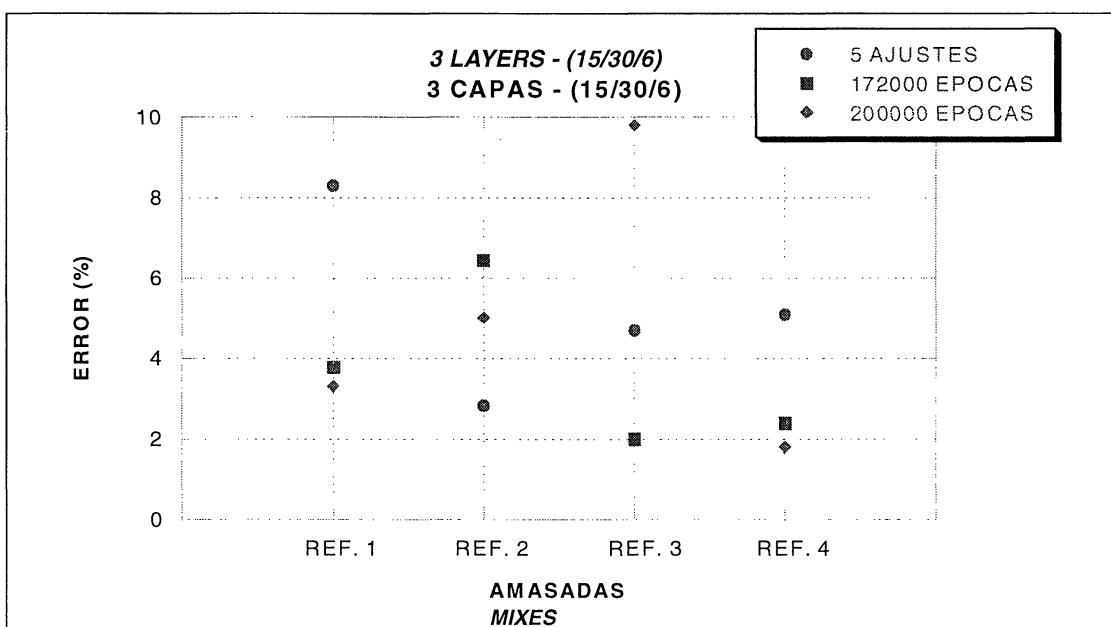


Figura 6.- Errores obtenidos para las cuatro amasadas de referencia con una red neuronal estructurada en tres capas, modificando el número de ajustes y de épocas en cada caso.

Figure 6.- Average errors obtained from a three layer neural network for the four reference mixtures, modifying the number of fittings or epochs respectively.

#### TABLA 1/TABLE I

Predicciones obtenidas con la configuración (15/30/6) para la amasada de referencia número 3

Obtained predictions from (15/30/6) configuration for reference batch number 3

Amasada Batch	Cemento Cement (kg/m <sup>3</sup> )	Cenizas Fly ashes (kg/m <sup>3</sup> )	Árido 12/20 Aggregates 12/20 (kg/m <sup>3</sup> )	Árido 0/5 Aggregates 0/5 (kg/m <sup>3</sup> )	Aditivo Additive (l/m <sup>3</sup> )	Agua Water (l/m <sup>3</sup> )
Ref. N° 3	200	108	975	975	2.46	154
15/30/6	210	115	969	958	2.45	156

En dicha figura se observa que los resultados obtenidos son dispares, y no permiten extraer conclusiones definitivas, pero en todos los casos analizados los errores con relación a tres de las amasadas de referencia se mantienen por debajo del 5%. Esto indica que los resultados obtenidos son similares utilizando un único ajuste con un número muy elevado de épocas, que utilizando la media de los resultados de varios ajustes con un número de épocas mucho más bajo.

## 6. CONCLUSIONES

En este trabajo, se ha propuesto la utilización de una red neuronal artificial para predecir las dosificaciones que han de aplicarse en la fabricación de hormigones de los que se conoce a priori la resistencia característica y la consistencia. Las características propias de las redes neuronales hacen que esta aproximación sea completamente novedosa frente a los métodos clásicos.

Globalmente, se obtiene una sensible mejoría en los resultados obtenidos cuando se utiliza una red neuronal estructurada en tres capas frente a una más simple de dos capas, obteniéndose los errores más bajos con la configuración de 15 neuronas en la capa de entrada, 30 en la capa oculta y 6 en la de salida. En este caso, los errores en las predicciones se sitúan por debajo del 5% para tres de las cuatro amasadas de referencia, estando el error de la cuarta amasada ligeramente por encima de esta valor.

Por otra parte, el hecho de utilizar ajustes únicos con números muy elevados de épocas no mejora sensiblemente los resultados con relación a la posibilidad de hacer la media de los resultados de varios ajustes con un número relativamente bajo de épocas, por lo que es recomendable elegir la opción que implique un menor consumo de tiempo de cálculo.

Debe hacerse notar que, aunque la red neuronal es capaz de aprender a partir de los datos de entrenamiento, su funcionamiento es generalmente considerado como el de una caja negra: ni es posible extraer conocimiento relacional de una red neuronal entrenada, ni se puede integrar información especial en torno al problema en dicha red con el fin de simplificar el procedimiento de aprendizaje.

En consecuencia, la aproximación más racional a las técnicas de aprendizaje y predicción en base a redes neuronales consiste en la utilización de datos de una única fuente, como pueden ser los registros de una planta de hormigonado; la propuesta en este trabajo, puede ser útil en la optimización de dosificaciones de hormigones con propiedades preestablecidas, por lo que resulta muy prometedora en el control de las líneas de

*This figure shows the unlikeness of the results obtained and no conclusive remarks can be derived although in all cases the average errors for three of the reference mixtures are kept below 5%. As a consequence, it seems clear that the results obtained are similar if a unique fit with a high number of epochs is used instead of the mean value of results from different fittings with a lower number of epochs.*

## 6. CONCLUSIONS

*In this work, the use of an artificial neural network for predicting the mix proportions to be applied in the production of ready-mixed concretes of known compressive strength and consistency is proposed. The specific characteristics of neural networks made this approach brand-new in comparison with classical methods.*

*In general, a slight improvement in the results is obtained from a three layer neural network in comparison with a more simple network of two layers; lowest errors were obtained with a configuration of 15 neurons in the input layer, 30 in the hidden layer and 6 in the output. In this case, average errors of predictions are kept below 5% for three of the reference mixes and for the fourth mix errors are slightly above this value.*

*On the other hand, the fact of using only one fit with a higher number of epochs does not significantly improve results in comparison with the possibility of estimating the mean value of results of various low numbers of epochs fittings; the less-consuming calculus time option is thus recommended.*

*It should be noted that, although a neural network is able to learn from training data, its working is usually considered as a black box: it is neither possible to extract relational knowledge from a trained neural network, nor can special information on the problem at hand be inferred in order to simplify the learning procedure.*

*As a consequence, the most rational approach to learning methods and prediction techniques from neural networks is based on the use of data from a sole source, such as records in a concrete factory; in this way, the proposal of this work could be useful in the optimisation of concrete mixes with preestablished properties and may be very useful for controlling of*

producción de plantas que fabrican productos de hormigón utilizando siempre los mismos componentes.

Finalmente, debe tenerse en cuenta la variabilidad experimental asociada siempre a los ensayos de este tipo de materiales: los resultados son difícilmente reproducibles, los errores experimentales son apreciables y la unicidad está claramente descartada, pues obviamente las dosificaciones que conducen a unos ciertos valores de resistencias y consistencias, no son, ni mucho menos, únicas. Esto implica que, aunque se disponga de grandes conjuntos de datos para el entrenamiento de la red, los resultados obtenidos siempre estarán dotados de un cierto grado de incertidumbre que hace que las predicciones derivadas deban contemplarse como meramente orientativas.

*production lines in concrete plants which always use the same components.*

*Finally, the experimental variability always associated with tests on these materials must be taken into account: results are hardly reproducible, experimental errors are not negligible and uniqueness is clearly discarded due to the fact that mixes leading to certain values of strengths and consistencies are obviously not unique. As a consequence, even if huge sets of experimental data for network training are available, the results obtained will always be endowed with some degree of uncertainty and the derived predictions should be considered as merely indicative.*

## BIBLIOGRAFÍA

- (1) J. N. K. Liu: *Neural network model for the analysis and representation of data in concrete manufacturing*. Proceedings of the 2<sup>nd</sup> Australian and New Zealand Conference on Intelligent Information Systems (1994), pp. 86-90.
- (2) S. Lai, M. Serra: *Concrete strength prediction by means of neural network*. Construction and Building Materials, Vol. 11, nº 2 (1997), pp. 93-98.
- (3) J. Kasperkiewicz, J. Racz, A. Dubrawski: *HPC strength prediction using artificial neural network*. Journal of Computing in Civil Engineering, Vol. 9, nº 4 (1995), pp. 279 – 284.
- (4) M. Strefezza, Y. Dotc, S. Sano, K. Hatakeyama, K. Uemura, T. Ueda: *Slump value estimation for fresh concrete using self-generating radial base network*. Proceedings of the 1993 Artificial Neural Networks in Engineering (1993), pp. 885-890.
- (5) S. Murray. Neural networks for statistical modelling. Van Nostrand Reinhold Ed., 1993.
- (6) R. Hecht-Nielsen: *Theory of back propagation neural networks*. International Joint Conference on Neural Networks (1989).
- (7) J. Tuya. Redes neuronales artificiales. E. T. S. Ingenieros Industriales de Gijón. 1990.
- (8) H. Denuth, M. Beale. Neural network toolbox user's guide for use with Matlab. The Math Works Inc., Marde, 1996.
- (9) S. Grossberg: *Contour enhancement, short-term memory, and consistencies in reverberating neural network*. Stud. Appl. Math., 52 (1973), pp. 217-257.
- (10) J. J. Hopfield: *Neural network and physical systems with emergent collective computational abilities*. Proceeding of the National Academy of Science, 79 (1982), pp. 2.554-2.558.
- (11) D. E. Rumelhart, G. E. M. Hinton, R. J. J. Williams. Learning internal representations by error propagation, parallel distributed processing, Vol. 1. MIT Press, Cambridge, MA (1986), pp. 318-362.
- (12) G. Pajares, V. Moreno, J. M. De la Cruz: *Clasificación de texturas mediante redes neuronales*. Ingeniería Civil, 123 (2001), pp. 61-69.

\* \* \*

# MATERIALES DE CONSTRUCCIÓN

Monográfico dedicado a

## LOS MATERIALES COMPUESTOS EN LA CONSTRUCCIÓN

La revista MATERIALES DE CONSTRUCCIÓN, editada en el Instituto de Ciencias de la Construcción EDUARDO TORROJA, dedica un número doble (Nº 247/248) a: *Los Materiales Compuestos en la Construcción*.

*Los Materiales Compuestos en la Construcción* es una temática muy actual ya que incide en el desarrollo y aplicación de Nuevos Materiales ("Composites"), que son el futuro en el campo de la Construcción. Uno de los sectores productivos que más influyen en el PIB es el de la construcción, con lo cual resulta necesario involucrar al sistema de I+D en el desarrollo de nuevos materiales compuestos basados en el cemento. En estos términos se presentaba en la última convocatoria de proyectos de investigación de la CICYT y dentro del Programa Nacional de Materiales, lo referente a las investigaciones en el Área de Materiales Compuestos (B.O.E. 7 de noviembre de 1997). *Los Materiales Compuestos en la Construcción* constituyen un tema estratégico, tanto para los ingenieros de caminos, canales y puertos como para los ingenieros de materiales.

Este número monográfico se compone de dos partes. La parte I se dedica a los materiales compuestos de matriz de hormigón. Son tratados temas claves como la dosificación, la interfase en sistema acero-hormigón y la implantación de nuevas fibras como son las acrílicas. La parte II se concentra en los denominados materiales compuestos de matriz orgánica, analizándose en profundidad las nuevas tecnologías tipo sandwich, textiles o de parrilla.

En este número especial se recogen trabajos de investigación originales e inéditos, en los que también se presentan las amplias posibilidades de aplicación de estos materiales. Los autores de estos trabajos, tanto los nacionales como los internacionales, son especialistas reconocidos en su respectivos campos científicos.

Los artículos que componen este número especial son:

- **Materiales Compuestos en la Construcción: Introducción (Composite Materials in Building: Introduction)**  
A. Miravete
- **Dosificación de hormigón reforzado con fibras de acero (Mix design of steel fiber reinforced concrete)**  
E. Moreno y M. Fernández Cánovas
- **Estudio de la interfase en los hormigones reforzados con fibras (Interface study of fiber reinforced concrete)**  
A. Pacios y M. Fernández Cánovas
- **Hormigones reforzados con fibras acrílicas (Concretes reinforced with acrylic fibres)**  
T. Amet
- **Fabricación y diseño de estructuras parrilla (Manufacture and design of composite grids)**  
Stephen W. Tsai, Kevin K.S. Liu y Philippe M. Manne
- **Características de los elementos resistentes tipo sandwich construidos en materiales compuestos avanzados a partir de tejidos tridimensionales (Characteristics of sandwich-type structural elements built of advanced composite materials from three dimensional fabrics)**  
L. Castejón, M.A. Jiménez y A. Miravete
- **Materiales compuestos realizados a partir de nuevas tecnologías textiles (Composite materials from new textile technologies)**  
M.A. Jiménez, L. Castejón y A. Miravete
- **Los composites y la construcción: su ayer, hoy y mañana (Composites and construction: yesterday, today and tomorrow)**  
J. Manso
- **Conclusiones finales (Final conclusions)**  
A. Miravete