



SPOLM 2007

ISSN 2175-6295

Rio de Janeiro- Brasil, 08 e 09 novembro de 2007.

## **REDES NEURAIIS ARTIFICIAIS NA OBTENÇÃO DO TRAÇO E NA DEFINIÇÃO DA RESISTÊNCIA À COMPRESSÃO DE CONCRETOS DE ALTA RESISTÊNCIA**

### **Helen Medina de Oliveira**

Universidade do Estado do Rio de Janeiro  
Rua São Francisco Xavier 524 - Maracanã  
Rio de Janeiro –RJ- CEP 20530-013  
hel\_medina@oi.com.br

### **Luiz Biondi Neto**

Universidade do Estado do Rio de Janeiro  
Rua São Francisco Xavier 524 –Sala 5019 BL-B- Maracanã  
Rio de Janeiro –RJ- CEP 20530-013  
luizbiondi@terra.com.br

### **Maria Elizabeth da Nóbrega Tavares**

Universidade do Estado do Rio de Janeiro  
Rua são Francisco Xavier 524 –Sala 5033 BL-E- Maracanã  
Rio de Janeiro –RJ- CEP 20530-013  
etavares@uerj.br

### **Resumo**

Este trabalho emprega a técnica de inteligência computacional conhecida como Redes Neurais Artificiais (RNA) para determinação do traço de concretos de alta resistência a partir da resistência à compressão requerida para o mesmo e do uso ou não de alguns materiais na mistura, como, por exemplo, plastificante, superplastificante e sílica ativa.

Além disto, foi criada uma segunda Rede Neural Artificial com o objetivo de se determinar a resistência à compressão a partir de seu traço já conhecido.

Desta forma, tem-se a disposição uma ferramenta para a dosagem de concretos de alta resistência a partir das propriedades requeridas para o mesmo e uma segunda, para a obtenção da resistência à compressão com traços conhecidos.

**Palavras-Chave:** Redes Neurais; Traços de concreto; Resistência à compressão.

### **Abstract**

This work uses the computational intelligence technique known as Artificial Neural Network (ANN) to aim at predict the high strength concretes mix proportions based on expected compressive strength of this concretes and the use or not of some materials in the mixture, as, for example, plastificizer, superplastificizer and silica fume.

Moreover, it was created a second Artificial Neural Network that aims at value compressive strength of concretes, which mix proportions are already known.

In this way, we have an available tool for the high strength concrete dosage based on the compressive strength required for or for the attainment of the compressive strength by known traces.

**Keywords:** Artificial Neural Network; Mix proportions of concrete; Compressive strength.

## 1. Introdução

Metodologias de definição do traço de um concreto, isto é, a forma de se determinar a proporção de cada um dos materiais que compõem a mistura, é, até hoje, alvo de estudos em vários centros de pesquisa em todo o mundo. Estes métodos, denominados de Métodos de Dosagem Experimental, se baseiam em princípios científicos e, principalmente, em estudos empíricos, e não apresentam simplesmente uma equação que consiga relacionar as propriedades requeridas para o concreto, como a resistência à compressão, com os materiais disponíveis para seu preparo.

Existem diversos métodos em todo o mundo que oferecem metodologias para a definição do traço de um concreto; entre eles pode-se citar o proposto pelo Instituto Nacional de Tecnologia (INT), o da Associação Brasileira de Cimento Portland (ABCP) e o preconizado pelo American Concrete Institute (ACI) <sup>[1]</sup>.

Contudo, apesar da existência de tantos métodos propostos por diversos institutos de competência técnica inquestionável, nenhum deles consegue fornecer traços que não necessitem de um ajuste experimental.

Portanto, após a obtenção de um traço de concreto definido por um método de dosagem qualquer, é necessário que se prepare uma mistura experimental e que se ensaie a mesma para se verificar se as propriedades desejadas para o concreto foram realmente atingidas. Normalmente, são necessárias pequenas correções na proporção da mistura para que se atinja os valores das propriedades desejados.

As Redes Neurais Artificiais (RNAs), devido a sua característica de generalização a partir da apresentação de um número adequado de pares de treinamento, constituiu-se como uma ferramenta computacional bastante promissora para a determinação de traços de concretos a partir de um conjunto de dados de entrada, como a resistência à compressão característica aos 28 dias ( $f_{ck}$ ), o valor do abatimento do tronco de cone (“slump test”) e algumas características dos materiais constituintes da mistura.

Um aspecto bastante vantajoso do emprego da RNA para a definição do traço de concretos é a possibilidade de se treinar a Rede com valores reais das propriedades associadas a seus respectivos traços, obtidos em ensaios experimentais realizados em laboratório. Com isto, espera-se que a necessidade de ajustes experimentais da mistura, uma vez definido o traço pela RNA, seja reduzida, pois a Rede, em sua fase de execução, generalizará tendo como base dados reais de traços e suas respectivas propriedades. Isto pôde ser observado em dois trabalhos anteriores onde, no primeiro, a RNA foi empregada para determinação de traços de concretos usuais <sup>[2]</sup> e no outro trabalho foi feita a validação experimental dos traços encontrados através da RNA <sup>[3]</sup>.

As Redes Neurais também podem ser aplicadas no caminho inverso ao apresentado anteriormente, ou seja, dado um traço de concreto conhecido, pode-se empregar esta técnica na obtenção de propriedades mecânicas, reológicas e de durabilidade dos concretos.

Desta forma, pode-se reduzir a necessidade da realização de ensaios de laboratório para as determinações experimentais de propriedades, que sempre são dispendiosos tanto em termos de custo quanto em termos de tempo. Por exemplo, em um ensaio de resistência à compressão normalmente se requer que o corpo de prova de concreto seja ensaiado após 28 dias de sua moldagem, sendo que este prazo pode chegar a 90 dias em alguns casos específicos.

## 2. Concreto de alta resistência

A definição de concreto de alta resistência tem variado ao longo dos anos e de lugar para lugar. Nos anos 50, concreto de agregados usuais que tivesse resistência à compressão maior que 30MPa era classificado como de alta resistência. Nos Estados Unidos, hoje em dia, são considerados concretos de alta resistência os com resistência à compressão maior que 40MPa, enquanto na Europa são os com essa resistência maior que 50MPa. Neste trabalho, consideramos a definição americana <sup>[4]</sup>.

Houve um aumento substancial do número de pesquisas e de aplicações do concreto de alta resistência nos últimos vinte anos. Em vários países, há casos de sua aplicação em estruturas em ambiente agressivo, pilares de edifícios altos, pontes e viadutos, estruturas *offshore*, elementos pré-moldados, pisos industriais, silos, etc.

A execução das plataformas do Mar do Norte, nos anos 80 e 90, foi responsável por grande parte do desenvolvimento do concreto de alta resistência, devido às ações que as estruturas das plataformas estavam expostas e ao ambiente agressivo no qual as mesmas se encontravam.

No Brasil, já há vários exemplos de utilização do concreto de alta resistência, particularmente em pilares de edifícios altos. Em geral, tem-se adotado resistência à compressão característica de até 80 MPa, entretanto há casos em que esta resistência atinge valores maiores.

A utilização de concreto de alta resistência apresenta algumas vantagens em relação ao concreto convencional, possibilitando redução das dimensões das peças estruturais (especialmente peças sujeitas à compressão, como pilares), aumento do espaço útil nos pavimentos inferiores, diminuição da carga nas fundações, maior velocidade de execução, ganhos de durabilidade (com redução da porosidade e permeabilidade no concreto), aumento dos vãos livres em pontes, elevada resistência ao desgaste ou abrasão, diminuição das deformações por retração, deformação imediata ou por fluência, além de benefícios ecológicos, energéticos e econômicos, por exemplo, através da utilização de resíduos industriais como sílica ativa <sup>[5,6]</sup>.

Apesar do custo do metro cúbico do CAR ser maior que o concreto convencional, em geral sua utilização é economicamente vantajosa <sup>[7]</sup>, uma vez que permite redução das seções das peças a serem concretadas e, conseqüentemente, do volume de concreto, aço e formas. Para verificar a viabilidade econômica de CAR em edifícios altos, Dal Molin e Wolf <sup>[8]</sup> realizaram um estudo econômico comparativo entre a execução de um edifício de 15 andares com concreto convencional, com resistência à compressão de 21MPa e com CAR, com resistência de 60 MPa, sendo o cálculo correspondente ao terceiro pavimento. Através da análise dos custos com material e execução, obtiveram uma economia de aproximadamente 12% na estrutura de CAR em relação à estrutura de concreto convencional <sup>[5]</sup>.

Contudo o proporcionamento dos materiais para CAR requer especial atenção quanto ao controle e seleção dos componentes, escolha do tipo de cimento, qualidade e tamanho máximo dos agregados, utilização de aditivo e adições, bem como no procedimento de execução da mistura <sup>[6]</sup>.

Como estes concretos têm certas particularidades, alguns dos procedimentos de dimensionamento e verificação tradicionalmente adotados têm se mostrado inadequados para estruturas feitas com esses concretos.

### **3. Traços de concreto**

O concreto propriamente dito é constituído basicamente por uma mistura de aglomerante, normalmente o cimento Portland, agregado miúdo, usualmente a areia, agregado graúdo, geralmente a brita, e água. Podem ser empregados outros componentes como aditivos e adições minerais, com o intuito de se melhorar algumas propriedades do concreto, tanto no estado fresco como no estado endurecido <sup>[9]</sup>.

O traço de um concreto é a proporção com que cada um dos materiais constituintes do mesmo entra na mistura, tendo a quantidade de cimento como a unidade de referência. Ele é apresentado como uma seqüência de números que indicam estas proporções.

Portanto, se ao se determinar os consumos por metro cúbico de concreto obtivéssemos, por exemplo, 450 kg/m<sup>3</sup> de cimento, 675 kg/m<sup>3</sup> de agregado miúdo, 1066 kg/m<sup>3</sup> de agregado graúdo e 180 l/m<sup>3</sup> de água, o traço deste concreto seria apresentado como:

$$\frac{450}{450} : \frac{675}{450} : \frac{1066}{450} : \frac{180}{450} \xrightarrow{\text{traço}} 1 : 1,50 : 2,37 : 0,40$$

#### 4. Resistência à compressão

Em se tratando de um concreto no estado endurecido, esta é geralmente sua principal propriedade e é a que normalmente é utilizada para se caracterizar o concreto. Desta forma, na engenharia estrutural, geralmente um concreto é especificado em termos de sua resistência característica à compressão ( $f_{ck}$ ) aos 28 dias, que é definida como aquela que possui uma probabilidade de 95% de ser ultrapassada no sentido favorável quando se ensaiam um determinado número de corpos de prova, definido por norma, em um laboratório, 28 dias após o preparo do concreto. Então, dado um conjunto de corpos de prova, confeccionados com um mesmo concreto, suas resistências à compressão apresentam uma distribuição de frequências próxima da normal <sup>[10]</sup>, e então, pode-se calcular a resistência característica à compressão ( $f_{ck}$ ) empregando-se a equação:

$$f_{ck} = f_{cj} - 1,65 s$$

sendo

$$f_{cj} = \frac{1}{n} \sum_{i=1}^n f_c$$

$f_c$  = resistência à compressão de cada exemplar

$n$  = número de exemplares

$$s = \sqrt{\frac{\sum (f_c - f_{cj})^2}{n - 1}} \text{ (desvio padrão)}$$

Então, graficamente o  $f_{ck}$  de um concreto pode ser representado conforme mostrado na figura 1.

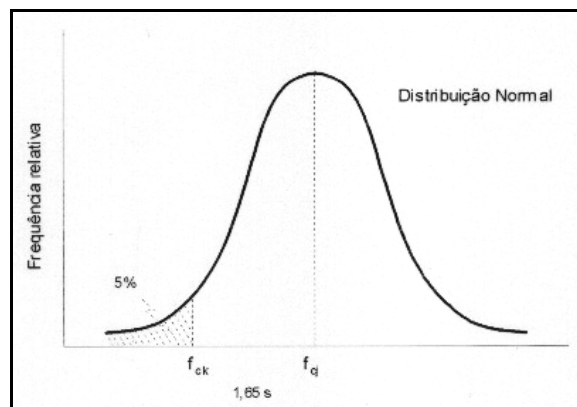


Figura 1 – Representação gráfica do  $f_{ck}$  de um concreto

A medição da resistência à compressão de um concreto é realizada através do ensaio de resistência à compressão estabelecido pela norma brasileira NBR 5739/94 <sup>[11]</sup>.

A importância desta propriedade reside no fato de que todo o cálculo ou projeto das estruturas de concreto armado e protendido é realizado levando-se em conta o valor da resistência característica à compressão aos 28 dias do concreto. Vale acrescentar que normalmente despreza-se a resistência à tração do concreto, pois esta é muito menor que sua resistência à compressão, sendo em torno de 1/10 desta. Este é o motivo pelo qual se empregam barras e/ou cordoalhas de aço nas áreas tracionadas das peças de concreto <sup>[10]</sup>.

## 5. Técnicas de inteligência computacional

Neste trabalho, foi utilizada a seguinte técnica de inteligência computacional: as Redes Neurais Artificiais (RNAs).

As Redes Neurais Artificiais (RNAs) foram inspiradas na estrutura do cérebro com o objetivo de apresentar características humanas necessárias ao tratamento de problemas de difícil modelagem por técnicas computacionais tradicionais. Na engenharia estrutural já existem várias referências de trabalhos que utilizam Redes Neurais. Este crescente uso das RNAs é devido às suas propriedades de: **aprendizado** por experiência; **generalização** de novos exemplos a partir dos já apresentados; **abstração** ou extração de características essenciais de dados ruidosos; e **associação** entre padrões diferentes.

As RNAs são programas computacionais cujo objetivo é aprender um conhecimento específico. Desta forma, diferentemente dos programas tradicionais que têm execução direta, as RNAs têm duas fases distintas de processamento.

A primeira fase de processamento, chamada de treinamento, é caracterizada pela apresentação de padrões visando mapear certo conhecimento que a rede deve aprender. Nesta fase, os padrões são apresentados separadamente ou em lotes à RNA e o erro entre a saída obtida pelo processo iterativo do treinamento e o alvo, ou valor conhecido que se deseja atingir, é medido.

Quando o erro atinge um valor considerado satisfatório para a aplicação investigada, o processo de treinamento é finalizado e o conhecimento obtido é armazenado em um arquivo sob forma numérica, que tenta reproduzir a informação retida nas sinapses neurais biológicas durante o processo natural de aprendizado (rede neural biológica).

Depois de treinada, a rede está pronta para a segunda fase, que é a fase de execução. Nesta etapa serão apresentados à RNA padrões de testes, também sob forma numérica, dos casos de imagens às quais se deseja fazer o diagnóstico e que, normalmente, não fizeram parte do treinamento.

O Perceptron, creditado a Rosenblatt, foi a primeira máquina de aprendizado com possibilidade de treinamento supervisionado. Assim, conforme a Figura 2, a saída atual da rede  $O_j$ , é comparada, a cada nova iteração, com um valor desejado  $T_j$  associado aos padrões de treinamento, gerando um sinal de erro  $e_j$ . Este sinal sofre um processo adaptativo de aprendizado no sentido de atualizar os pesos a cada iteração  $k$  <sup>[12]</sup>.

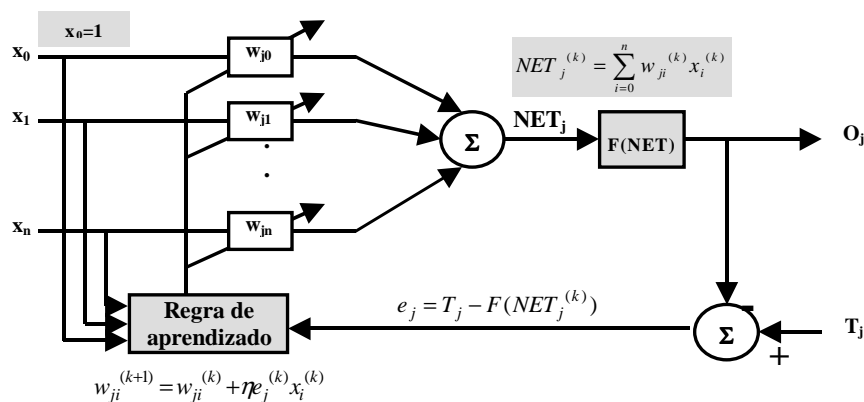


Figura 2 – Arquitetura do Perceptron.

O Perceptron é uma rede que pode ser apresentada apenas com uma camada de neurônios ou com múltiplas camadas (*Multi-Layer Perceptron* – MLP). Quando em funcionamento, o sinal de entrada  $X_i$  (padrão de entrada) é multiplicado por um conjunto de

pesos  $W_{ji}$ , ajustáveis por uma regra de aprendizado a fim de gerar um potencial interno denominado  $NET_j$ , que representa a soma ponderada das entradas pelos respectivos pesos <sup>[12]</sup>.

O sinal  $NET_j$  é então processado por um limitador, denominado de função de ativação  $F$ , que pode ser um degrau, uma rampa, uma sigmóide, uma tangente hiperbólica etc., resultando num sinal de saída  $O_j \in \{0,1\}$  ou  $O_j \in \{-1,1\}$  ou, até mesmo, ilimitado.

O sinal de saída  $O_j$  é comparado com o alvo ou valor desejado  $T_j$ , produzindo o sinal de erro  $e_j$ , usado no ajuste iterativo dos pesos, através de uma regra de aprendizado dada por  $w_{ji}^{(k+1)} = w_{ji}^{(k)} + \eta e_j^{(k)} x_i^{(k)}$ , onde o parâmetro  $\eta$  é um valor positivo denominado de taxa de aprendizado. A taxa de aprendizado  $\eta$  está relacionada com a velocidade e a estabilidade do processo de convergência da RNA. O processo iterativo de apresentação de padrões provoca o decréscimo do erro e quando este atinge um valor preestabelecido, diz-se que a RNA absorveu o conhecimento desejado e que o processo convergiu <sup>[13]</sup>.

Rosenblatt, em 1962, desenvolveu um algoritmo que ajusta os pesos pela minimização do erro médio quadrático, usando o método do gradiente decrescente. Assim, o erro  $e_j = T_j - O_j$  é obtido pela diferença entre esses valores, tomando-se  $O_j$  depois da função de ativação. Devido às derivadas impostas pelo método, a função de ativação deve ser derivável em todo o domínio como acontece, por exemplo, com a sigmóide ou a tangente hiperbólica <sup>[14]</sup>.

Desta forma,  $O_j = F(NET_j) = \tanh(\gamma NET_j)$ , onde  $\gamma$  é um escalar positivo que representa a inclinação da função <sup>[15]</sup>.

O erro quadrático médio é dado por  $E = \frac{1}{2}(e_j^{(k)})^2 = \frac{1}{2}(T_j^{(k)} - O_j^{(k)})^2$ , onde  $O_j^{(k)} = F(NET_j^{(k)})$  e  $NET_j^{(k)} = \sum_{i=0}^n w_{ji}^{(k)} x_i^{(k)}$ ;  $i$  representa a quantidade de entradas do neurônio;  $j$  representa o  $j$ -ésimo neurônio.

O gradiente instantâneo é dado pelo diferencial em relação aos pesos, ou seja:

$$\nabla_w E = \frac{\partial E}{\partial w_{ji}^{(k)}}.$$

$$\text{Aplicando-se a regra da cadeia, tem-se } \frac{\partial E}{\partial w_{ji}^{(k)}} = \frac{\partial E}{\partial e_j^{(k)}} \frac{\partial e_j^{(k)}}{\partial w_{ji}^{(k)}} = \frac{\partial E}{\partial e_j^{(k)}} \left( \frac{\partial e_j^{(k)}}{\partial NET_j^{(k)}} \frac{\partial NET_j^{(k)}}{\partial w_{ji}^{(k)}} \right).$$

$$\text{Como } e_j^{(k)} = T_j^{(k)} - O_j^{(k)}, \text{ então } \frac{\partial e_j^{(k)}}{\partial NET_j^{(k)}} = \frac{\partial (T_j^{(k)} - O_j^{(k)})}{\partial NET_j^{(k)}} = -\frac{\partial O_j^{(k)}}{\partial NET_j^{(k)}}.$$

$$\text{Se } O_j^{(k)} = \tanh(\gamma NET_j^{(k)}) = \frac{1 - \varepsilon^{-2\gamma NET_j^{(k)}}}{1 + \varepsilon^{-2\gamma NET_j^{(k)}}}, \text{ então}$$

$$\frac{\partial O_j^{(k)}}{\partial NET_j^{(k)}} = \frac{(1 + \varepsilon^{-2\gamma NET_j^{(k)}})(2\gamma \varepsilon^{-2\gamma NET_j^{(k)}}) - (1 - \varepsilon^{-2\gamma NET_j^{(k)}})(-2\gamma \varepsilon^{-2\gamma NET_j^{(k)}})}{(1 + \varepsilon^{-2\gamma NET_j^{(k)}})^2}$$

$$\frac{\partial O_j^{(k)}}{\partial NET_j^{(k)}} = \frac{4\gamma \varepsilon^{-2\gamma NET_j^{(k)}}}{(1 + \varepsilon^{-2\gamma NET_j^{(k)}})^2}$$

$$\text{Como } O_j^{(k)} = \frac{1 - \varepsilon^{-2\gamma NET_j^{(k)}}}{1 + \varepsilon^{-2\gamma NET_j^{(k)}}}, \text{ então } 1 - (O_j^{(k)})^2 = \frac{4\varepsilon^{-2\gamma NET_j^{(k)}}}{(1 + \varepsilon^{-2\gamma NET_j^{(k)}})^2}. \quad \text{Logo,}$$

$$\frac{\partial O_j^{(k)}}{\partial NET_j^{(k)}} = \gamma [1 - (O_j^{(k)})^2].$$

$$\text{Finalmente, } \frac{\partial e_j^{(k)}}{\partial NET_j^{(k)}} = -\frac{\partial O_j^{(k)}}{\partial NET_j^{(k)}} = -\gamma [1 - (O_j^{(k)})^2].$$

$$\text{Sabendo-se que } E = \frac{1}{2}(e_j^{(k)})^2, \text{ então } \frac{\partial E}{\partial e_j^{(k)}} = e_j^{(k)}.$$

$$\text{Ainda, } NET_j = \sum_{i=0}^n w_{ji}^{(k)} x_i^{(k)}, \text{ assim } \frac{\partial NET_j}{\partial w_{ji}^{(k)}} = x_i^{(k)}.$$

$$\text{Logo, } \nabla_w E = \frac{\partial E}{\partial w_{ji}^{(k)}}, \frac{\partial E}{\partial w_{ji}^{(k)}} = \frac{\partial E}{\partial e_j^{(k)}} \frac{\partial e_j^{(k)}}{\partial w_{ji}^{(k)}} = \frac{\partial E}{\partial e_j^{(k)}} \frac{\partial e_j^{(k)}}{\partial NET_j^{(k)}} \frac{\partial NET_j^{(k)}}{\partial w_{ji}^{(k)}}.$$

$$\text{Ou seja, } \frac{\partial E}{\partial w_{ji}^{(k)}} = -e_j^{(k)} \lambda [1 - (O_j^{(k)})^2] x_i^{(k)}.$$

O processo de minimização do erro exige que a variação dos pesos ocorra na direção do negativo do Gradiente. Desta forma,  $w_{ji}^{(k+1)} = w_{ji}^{(k)} - \eta \frac{\partial E}{\partial w_{ji}^{(k)}}$ , ou ainda,

$$w_{ji}^{(k+1)} = w_{ji}^{(k)} + \eta \lambda e_j^{(k)} [1 - (O_j^{(k)})^2] x_i^{(k)}.$$

A Figura 3 mostra o método de treinamento proposto por Rosenblatt em 1962 [12].

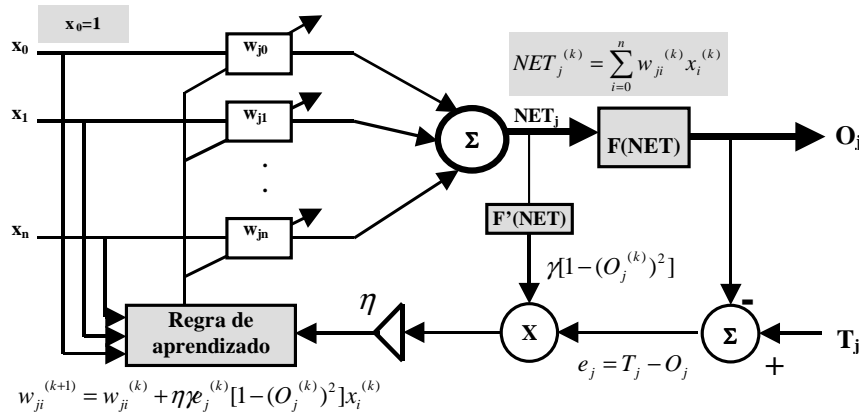


Figura 3 – Aprimoramento do treinamento do Perceptron.

Segundo Skapura [16], o Perceptron pode apresentar múltiplas camadas. Neste caso, emprega-se no treinamento o algoritmo *Back-propagation*, semelhante ao desenvolvido neste artigo. A diferença entre os algoritmos reside no cálculo do sinal de erro nas camadas intermediárias dos neurônios. Este sinal deve permitir a propagação do erro para as camadas anteriores (retropropagação) até chegar à primeira [13]. Neste artigo foi usado Perceptron de Múltiplas Camadas (MLP), com algoritmo de retropropagação do erro. Atualmente esse algoritmo pode ser visto sob várias formas, segundo o método numérico usado na minimização do erro quadrático pelo gradiente decrescente [17, 18].

## 6. Procedimento experimental

Os dados utilizados para o treinamento da rede neural proposta foram retirados de monografias, dissertações de mestrado e teses de doutorado e possuíam traços que tinham resistência à compressão variando entre 40 MPa e 120 MPa.

Numa primeira análise, estávamos entrando com os dados do traço constituinte do concreto e queríamos que a rede desse como resposta a resistência à compressão aos 7 dias e aos 28 dias referente a cada traço.

Contudo, em nossa primeira tentativa com uma RNA para concretos de alta resistência, os dados eram muito reduzidos e ao treinarmos a rede, não conseguimos atingir nossa meta.

Começou então um intenso trabalho de coleta de novos dados, ou seja, de novos traços de concretos de resistências acima de 40 MPa e como fonte de consulta, como antes, foram utilizadas teses de mestrado, doutorado, projetos de graduação entre outras. Foram obtidos 65 traços de concreto diferentes com formulações que poderiam conter além dos elementos comuns a todos eles: cimento, agregados miúdo e graúdo e água, sílica ativa, plastificante, superplastificante, argila expandida, rheobuild e ar incorporado.

Tabela 1 – Um dos traços de concreto empregados.

Materiais	Quantidade
-----------	------------

Agregado graúdo (kg)	804,00
Agregado miúdo (kg)	0
Cimento (kg)	450,00
Água (l)	313,00
Plastificante (l)	0
Superplastificante (l)	0
Sílica (kg)	30,30
Areia artificial (kg)	612,00
Argila expandida D <sub>máx</sub> = 4,8mm(kg)	0
Argila expandida D <sub>máx</sub> = 9,5mm(kg)	0
Rheobuild (kg)	8,04
Ar incorporado (%)	2,00
Resistência aos 7 dias	37,8
Resistência aos 28 dias	44,0

Para a determinação da resistência à compressão aos 7 dias e aos 28 dias, foi apresentado à rede o seguinte padrão de entrada:

- Quantidade de agregado graúdo;
- Quantidade de agregado miúdo;
- Quantidade de cimento;
- Quantidade de água;
- Quantidade de aditivo plastificante;
- Quantidade de aditivo superplastificante;
- Quantidade de sílica;
- Quantidade de areia artificial;
- Quantidade de Metacaulin;
- Quantidade de Rheobuild;
- Quantidade de ar incorporado.

Neste caso, o alvo da RNA é o valor da resistência à compressão aos 7 dias e aos 28 dias correspondente ao traço utilizado na entrada da rede. Então, o alvo é constituído por um vetor de dois elementos, sendo este:

- Resistência à compressão aos 7 dias;
- Resistência à compressão aos 28 dias.

Para modelagem, treinamento e posterior execução das Redes Neurais, foi empregado o toolbox de Redes Neurais do software MATLAB<sup>®</sup> versão 7, desenvolvido pela MATHWORKS<sup>®</sup>.

Foram testadas diversas RNA, tanto para determinação do traço quanto para a obtenção da resistência à compressão e consistência, variando-se os seguintes parâmetros:

- N<sup>o</sup> de Camadas Escondidas – Este parâmetro foi variado desde uma camada até três camadas escondidas.
- N<sup>o</sup> de Elementos Processadores por Camada – O número de neurônios artificiais por camada foi outro parâmetro de análise, o qual foi variado mantendo-se constante o número de camadas escondidas.

Na primeira etapa, foram criadas redes com apenas uma camada oculta com o número de neurônios nesta variando entre 5 e 18 unidades. Na segunda etapa, aumentou-se o número de camadas ocultas para até um total de 2, variando-se também o número de neurônios em cada camada. Nesta etapa, adotou-se quantidades maiores de neurônios por camada, fazendo com que as camadas mais internas possuísem de 7 a 20 unidades. E, por fim, aumentou-se o número de camadas ocultas para 3, variou-se o número de neurônios em suas camadas de 5 a 25 unidades e cada padrão de entrada foi apresentado a RNA mais de uma vez em sua fase de treinamento, sendo cada um deles apresentado duas vezes.

Na figura abaixo, está representado o treinamento de uma destas etapas, onde foi utilizado o algoritmo de treinamento Levenberg-Marquardt backpropagation (default). Pode-



se perceber, através da mesma que o erro final desejado para este processo foi de  $10^{-6}$ , e a rede convergiu para o mesmo com um número de epochs igual a 269.




Figura 4 – Figura gerada pelo treinamento

Deve-se ressaltar que todos estes procedimentos foram realizados tanto para a RNA cuja saída é o traço de um concreto quanto para a RNA cuja saída é a resistência à compressão.

## 7. Resultados obtidos

### 7.1. Rede Neural para determinação da resistência à compressão (fck)

Os resultados obtidos na primeira etapa se mostraram insatisfatórios, a RNA não conseguiu convergir em todos os casos e os valores retornados pela mesma na fase de execução, após o treinamento, apresentaram erros de até 80% em relação ao valor esperado.

Os resultados apresentados na segunda etapa ainda não foram considerados satisfatórios, pois, apesar de apresentarem erros máximos menores que os da primeira etapa e convergirem em todos os casos, ainda apresentaram erros muito elevados. Estes erros ficaram na ordem de 20%. Apesar da grande redução, estes erros ainda são muito elevados para os padrões da tecnologia do concreto.

Os resultados obtidos através de RNAs treinadas com pequena quantidade de padrões apresentaram resultados inferiores aos registrados na literatura corrente.

Quando foram introduzidos no treinamento mais dados referentes a traços de concretos de resistências acima de 40 MPa, obtiveram-se resultados bastante satisfatórios, com erros máximos inferiores a 1%. Na tabela 2, são apresentadas as resistências calculadas pela rede para um traço, o qual tinha suas resistências previamente conhecidas, pois foi separado do banco de dados original para que não fizesse parte do treinamento a fim de que pudesse servir como teste para a RNA. A arquitetura utilizada contém três camadas escondidas, tendo a primeira 20, a segunda 12 e a terceira 7 neurônios. Nesta rede, os padrões de entrada foram apresentados duas vezes.

Tabela 2 – Resultados obtidos pela RNA para a determinação do fck na etapa final

<b>Materiais</b>	<b>Quantidades da RNA</b>	<b>Quantidades esperadas</b>	<b>Erro (%)</b>
Aos sete dias	0,3831	0,3833	0,05

Aos vinte oito dias	0,3626	0,3628	0,05
---------------------	--------	--------	------

## 7.2. Rede Neural para determinação do traço de concreto de alta resistência

Os resultados obtidos para este treinamento apresentaram um comportamento muito semelhante ao descrito acima para a RNA para a determinação da resistência à compressão.

Na etapa final, também obtivemos resultados satisfatórios com erros máximos inferiores a 1%. Na tabela 3, são apresentadas as quantidades calculadas pela rede para uma determinada resistência. Os valores também foram obtidos através de uma RNA com três camadas escondidas, tendo a primeira 20, a segunda 12 e a terceira 7 neurônios e apresentando os padrões de entrada duas vezes.

Tabela 3 – Resultados obtidos pela RNA para a determinação do traço na etapa final

Resistência à compressão	Resistências da RNA	Resistências esperadas	Erro (%)
Agregado graúdo (kg)	0,5622	0,5597	0,44
Agregado miúdo (kg)	0,6964	0,6968	0,06
Cimento (kg)	0,8619	0,8633	0,16
Água (l)	0,5754	0,5751	0,05
Plastificante (l)	0,9754	0,9667	0,9
Superplastificante (l)	-0,0023	0	0
Sílica (kg)	0,0002	0	0
Areia artificial (kg)	-0,0008	0	0
Argila expandida D <sub>máx</sub> = 4,8mm(kg)	0,0000	0	0
Argila expandida D <sub>máx</sub> = 9,5mm(kg)	0,0000	0	0
Rheobuild (kg)	-0,0004	0	0
Ar incorporado (%)	0,0000	0	0

## 8. Conclusão

Analisando os resultados alcançados, percebemos que as RNAs se mostram promissoras para esta aplicação da engenharia civil, mais precisamente da tecnologia do concreto.

Esta técnica se mostra bastante vantajosa devido ao fato de apresentar simultaneamente três características: agilidade, flexibilidade e confiabilidade.

Agilidade porque depois que a RNA foi treinada, os traços ou propriedades dos concretos podem ser obtidos com bastante rapidez.

Flexibilidade, pois as RNAs podem ser treinadas para diferentes tipos de materiais, de acordo com as características regionais dos mesmos, diferente das técnicas usuais de dosagem que são, normalmente, desenvolvidas para os materiais presentes em uma determinada região. Portanto, não há preocupação da não-adaptação de uma metodologia estrangeira, devido à diferença dos materiais encontrados em cada região.

Confiabilidade porque conforme apresentado neste trabalho, as RNAs podem determinar traços ou obter valores de propriedades com margens de erro, bastante pequenas, muitas vezes menores que 0,10%.

O grupo de pesquisas responsável por este estudo se encontra atualmente atuando no sentido de aplicar a técnica de RNAs na obtenção de outras propriedades importantes dos concretos como consistência, resistência à abrasão, resistência à tração, tensão de aderência, módulo de elasticidade, coeficiente de Poisson e permeabilidade.

## 9. Bibliografia

[1] RODRIGUES, P. P. F.. **Parâmetros de dosagem do concreto**. Associação Brasileira de Cimento Portland, 3.ed. São Paulo, 1998.

- [2] ALMEIDA, R.S. de; NETO, L.B.; TAVARES, M.E.N.. **Emprego de Redes Neurais Artificiais na Definição do Traço e na Obtenção de Resistência e Consistência de Concretos Usuais**. In: I Congresso de Estatística e Investigação Operacional da Galiza e Norte de Portugal e VI Congresso Galego de Estatística e Investigación de operaci3ns. Guimarães. CEIO 2005. Azar3m : Universidade do Minho, 2005.
- [3] TAVARES, M.E.N. ; OLIVEIRA, H. M. ; ALMEIDA, R.S. de ; NETO, L.B.. **Valida33o Experimental de Traços de Concreto obtidos por Redes Neurais Artificiais**. In: VI Simp3sio EPUSP Estruturas de Concreto. S3o Paulo, 2006. p. 2029-2042.
- [4] PAULA, A. L. de. **Avalia33o da resist3ncia de pilares de concreto de alta resist3ncia**. Rio de Janeiro, 2007. Disserta33o de mestrado - Universidade Federal do Rio de Janeiro, COPPE.
- [5] DAL MOLIN, D. C. C. **Contribui33o ao estudo das propriedades mec3nicas dos concretos de alta resist3ncia com e sem adi33es de microssilica**. S3o Paulo, 1995. Tese de Doutorado em Engenharia. Escola Polit3cnica, Universidade de S3o Paulo.
- [6] NAWY, E.G. **Fundamentals of High Strength High Performance Concrete**. London: Longman Group Limited, 1996. 340p.
- [7] RADOMSKI, W. **Development of research and application of high-performance concrete in bridge engineering in Poland**. In: INTERNATIONAL CONFERENCE ON HIGH- PERFORMANCE CONCRETE, AND PERFORMANCE AND QUALITY OF CONCRETE STRUCTURES, 2.,1999, Gramado. Proceedings... Michigan: CANMET/ACI, 1999. p. 537-554.
- [8] DAL MOLIN, D.C.C.; WOLF, J. **Viabilidade t3cnico-econ3mica da utiliza33o de concreto de alta resist3ncia em edif3cios altos**. In: ENCONTRO NACIONAL DA CONSTRU333O, 10., Gramado, 1990. Anais... Porto Alegre: SERGS, 1990. p.853-863.
- [9] FILHO, M.C.; LINS, L.N.. **Apostila de Materiais de Constru33o Civil I**. Curso de materiais de constru33o I, UERJ, Rio de janeiro, 2003.
- [10] TAVARES, M.E.N.. **Apostila de concreto armado**. Curso de concreto armado, UERJ, Rio de Janeiro, 2002.
- [11] ASSOCIA333O BRASILEIRA DE NORMAS T3CNICAS. **NBR 5739 - Concreto – Ensaio de compress3o de corpos-de-prova cil3ndricos**, Rio de Janeiro, Julho 1994.
- [12] ROSENBLATT, F.. **Principles of Neurodynamics**. Spartan Editions – New York, 1962.
- [3] HAYKIN, S.. **Neural Networks: A Comprehensive Foundation**. 2nd Edition, Prentice Hall, 1998.
- [14] GOMES, E. G., BIONDI, L.N. LINS, M.P.E., SOARES DE MELLO, J.C.C.B.. **Redes Neurais Artificiais na determina33o do custo de projectos imobili3rios**. In: *Anais do IO2002 – 10<sup>o</sup> Congresso da APDIO* – Guimarães – Portugal, 2002.
- [15] CICHOCKI, A., BARGIELA, A.. **Neural Networks for Solving Linear Inequality Systems**. Journal of Parallel Computing (<http://www.bip.riken.go.jp/abs/>),1996.
- [16] SKAPURA, D.M. **Building Neural Networks**. Addison-Wesley Publishing Company – New York, 1996.

[17] RUMELHART, D., JAMES, E., CLELLAND, L. **The PDP Research Group**. Parallel Distributed Processing – Vol. I – The MIT Press, 1986.

[18] RICHARD, A.J.. **Applied Multivariate Statistical Analysis**. Prentice-Hall – EUA, 1998.

[19] CREMONINI, R.A.; DAL MOLIN, D.C.C.; CECCATTO, D.M.; MANCIO, M.; GOULART, J.. **Desenvolvimento de um Método de Dosagem de Concretos de Alta Resistência com baixo Consumo de Cimento**. In: *43º Congresso Brasileiro do Concreto*.