

Artificial neural networks application to predict bond steel-concrete in pull-out tests

Aplicação de redes neurais artificiais na predição da aderência aço-concreto em ensaios do tipo pull-out

A. LORENZI ^a
alexandre.lorenzi@ufrgs.br

B. V. SILVA ^a
dovalesilva@hotmail.com

M. P. BARBOSA ^b
mbarbosa@dec.feis.unesp.br

L. C. P. SILVA FILHO ^c
lcarlos66@gmail.com

Abstract

This study aims the possibility of using the pull-out test results – bond tests steel-concrete, that has been successfully carried out by the research group APULOT since 2008 [1]. This research demonstrates that the correlation between bond stress and concrete compressive strength allows estimate concrete compressive strength. However to obtain adequate answers testing of bond steel-concrete is necessary to control the settings test. This paper aims to correlate the results of bond tests of type pull-out with its variables by using Artificial Neural Networks (ANN). Though an ANN is possible to correlate the known input data (age rupture, anchorage length, covering and compressive strength of concrete) with control parameters (bond stress steel-concrete). To generate the model it is necessary to train the neural network using a database with known input and output parameters. This allows estimating the correlation between the neurons in each layer. This paper shows the modeling of an ANN capable of performing a nonlinear approach to estimate the concrete compressive strength using the results of steel-concrete bond tests.

Keywords: bond steel-concrete, artificial neural networks, pull-out test, concrete strength, APULOT test.

Resumo

O estudo visa avaliar a possibilidade de se usar os resultados do ensaio de arrancamento “pull-out test” – ensaio de aderência aço-concreto para estimativa da resistência à compressão do concreto, este método vem sendo utilizado com sucesso pelo grupo de pesquisa APULOT, desde 2008 [1]. A pesquisa ora realizada evidencia a existência da correlação entre essas duas variáveis, aderência e resistência à compressão do concreto, o que permite determinar estimativas apropriadas da resistência à compressão do concreto, melhorando deste modo a capacidade do controle tecnológico “in situ” do concreto. Entretanto para se obter respostas adequadas dos ensaios de aderência aço-concreto é necessário controlar as configurações de ensaio, dado que existem diversos formatos de corpos de prova para estes tipos de ensaios na literatura. Deste modo, este trabalho tem por objetivo correlacionar os resultados obtidos em ensaios de aderência do tipo pull-out a suas variáveis por meio da utilização de Redes Neurais Artificiais (RNA). Com a utilização de uma RNA, pode-se correlacionar, de forma não linear, dados de entrada conhecidos (idade de ruptura, comprimento de ancoragem, cobrimento e resistência à compressão) com parâmetros de controle (tensão de aderência aço-concreto). Para gerar o modelo neural é necessário treinar a rede, expondo-a a uma série de dados com parâmetros de entrada e de saída conhecidos. Isto permite estimar os coeficientes de correlação entre os neurônios de cada camada. O presente trabalho apresenta a modelagem de uma RNA capaz de realizar uma aproximação não linear, visando estimar a resistência à compressão do concreto a partir dos resultados de ensaios de aderência aço-concreto.

Palavras-chave: aderência aço-concreto, redes neurais artificiais, ensaio pull-out, resistência à compressão do concreto, ensaio APULOT.

^a Federal University of Rio Grande do Sul (UFRGS), Post-Graduation Program of Civil Engineering (PPGEC), Structural Models and Testing Laboratory (LEME), Porto Alegre – RS, Brazil;

^b Federal University of São Paulo (UNESP), Department of Civil Engineering, Ilha Solteira/SP, Brazil;

^c Federal University of Rio Grande do Sul (UFRGS), Post-Graduation Program of Civil Engineering (PPGEC), Structural Models and Testing Laboratory (LEME), Porto Alegre/RS, Brazil.

1. Introdução

A utilização de ferramentas de Inteligência Artificial (IA), que possibilitam o desenvolvimento de modelos capazes de auxiliar no diagnóstico e na tomada de decisão. Existem diversas técnicas de modelagem de dados e produção de informações que buscam simular a inteligência humana, estratégia fundamental para habilitá-las a resolver problemas complexos, tais como: Testes de Hipóteses, Lógica Nebulosa, Sistemas Especialistas, Redes Neurais Artificiais, entre outras. Uma das técnicas de IA mais promissora é a que utiliza as Redes Neurais Artificiais (RNAs), método proposto para solucionar problemas complexos, baseado na construção de um modelo computacional composto de circuitos que simulam o funcionamento do cérebro humano. Este é o caso da interpretação de resultados do ensaio de arrancamento pull-out – ensaio de aderência aço-concreto, que demanda conhecimento especializado e pode ser simulado utilizando estas ferramentas.

Através da utilização das RNAs é possível correlacionar, de forma não linear, parâmetros de entrada conhecidos, como idade de ruptura, comprimento de ancoragem, cobrimento e resistência à compressão com parâmetros de controle desejados, como a tensão de aderência aço-concreto, como uma resposta de saída do modelo neural. As RNAs podem ser geradas utilizando-se como base perceptrons de múltiplas camadas (MLP) e treinadas com um algoritmo de retropropagação de erro, por exemplo, que as submetem a uma grande série de dados de entrada e saída conhecidos, permitindo que a mesma faça uma adequada estimativa dos coeficientes de correlação em cada camada.

O Grupo de Pesquisa LEME (Laboratório de Ensaio e Modelos Estruturais) tem buscado, nos últimos anos, implementar recursos para melhorar a análise de estruturas de concreto armado. O trabalho desenvolvido por LORENZI (2009)[2] mostrou que as RNAs podem ser utilizadas para gerar métodos numéricos possivelmente aplicáveis para estimativa da resistência à compressão a partir de ensaios de velocidade de propagação do pulso ultrassônico (VPU). O grupo de pesquisa APULOT vem trabalhando com afinco estudo que visa avaliar a possibilidade de usar os resultados de ensaios de aderência aço-concreto para estimar a resistência à compressão do concreto. Os autores Silva (2010)[3]; Lorrain et al. (2011)[4] evidenciaram que a correlação entre essas variáveis é válida e que é possível fazer estimativas apropriadas da resistência à compressão. Entretanto para se obter respostas adequadas dos ensaios de aderência aço-concreto é necessário controlar as configurações dos mesmos tendo em vista, entre outros parâmetros, a existência de diversos formatos de corpos de prova para estes tipos de ensaios.

Deste modo, processar inúmeros dados pode ser uma tarefa complexa e demandar muito tempo. Entre os métodos numéricos existentes de processamento de dados, tem-se as RNAs, que se apresenta como um método numérico proposto para solucionar problemas, entre eles, de engenharia e, nesse caso, para determinar a correlação entre a resistência à compressão do concreto e a tensão de aderência aço-concreto em determinados ensaios. Neste trabalho apresenta-se o resultado de alguns estudos desenvolvidos pelo Grupo de Pesquisa LEME/APULOT. Os mesmos são voltados para a modelagem de uma RNA que se mostre eficiente




Figura 1
Modelo não linear de um neurônio [6]

para representar a relação não linear existente entre um conjunto de dados de resistência à compressão e de tensão de aderência aço-concreto.

Desta forma, o objetivo deste trabalho é avaliar o potencial das RNAs para interpretação de dados com vistas a apresentar a modelagem de uma RNA capaz de realizar uma aproximação não linear, visando estimar a resistência à compressão do concreto a partir dos resultados de ensaios de aderência aço-concreto, e demonstrar a precisão da estimativa das RNAs frente a modelos estatísticos de regressão múltiplas tradicionais.

2. Redes neurais artificiais

Como explica SRIRAM (1997)[5], as RNAs são técnicas computacionais que geram modelos inspirados na estrutura neural de organismos inteligentes, e que adquirem conhecimento através da análise de experiências prévias. Em sua forma mais geral, uma RNA é uma estrutura projetada para funcionar de maneira similar à forma como o cérebro realiza uma determinada tarefa de interesse. Objetivando atingir um bom desempenho, as RNAs adotam uma estratégia de interligação maciça de células computacionais simples, denominadas neurônios ou unidades de processamento (HAYKIN, 2001)[6].

As RNAs constituem um paradigma computacional diferente do convencional, que tem por base um elemento processador cen-

tral controlando o sistema. No paradigma neural o processamento é feito de forma distribuída, através dos neurônios artificiais. Os elementos processadores das RNAs operam de maneira paralela, interagindo-se entre si. A rede aprende a resolver uma tarefa que lhe é atribuída através de um algoritmo de treinamento. O funcionamento do modelo depende da dinâmica dos neurônios e da forma como eles são conectados, o que irá determinar o tipo de tarefa que será realizado pela rede. Como as redes são baseadas numa analogia do funcionamento do cérebro, no próximo item aborda-se, sumariamente, alguns aspectos relacionados à forma de operação do mesmo (CORRÊA, 2004[7]).

O funcionamento das RNAs se baseia no estabelecimento de relações entre estímulos de entrada e de saída de um sistema, e apresentam a vantagem de que, para este fim, não é necessário estabelecer um modelo matemático prévio que defina a forma destas relações. As redes aprendem estas relações dos próprios dados, a partir de um processo de treinamento, de forma semelhante ao aprendizado do cérebro humano.

A arquitetura das redes se assemelha à do cérebro em dois aspectos: O conhecimento é adquirido pela rede a partir de registros das condições de entrada e saída de um processo qualquer, por meio de um processo de aprendizagem, que pode ser dirigido ou autônomo. Pesos sinápticos, que representam as forças de conexão entre os neurônios que formam a rede, são utilizadas para armazenar o conhecimento adquirido.




Figura 2
Representação de um RNA com duas camadas ocultas [6]

Uma rede típica é constituída por uma camada de entrada (input layer), composta de tantos neurônios quanto seja necessário para codificar as informações conhecidas; de uma ou mais camadas intermediárias (hidden layers), que permitem a transformação da informação de acordo com uma estrutura de pesos que foi estabelecida quando a rede foi treinada; e de uma camada de saída (output layer), que registra o resultado do processamento realizado. Cada unidade da rede, ou neurônio, guarda apenas um valor de estado, que se modifica dependendo dos estímulos recebidos de todos os neurônios que o antecedem e estão ligados ao mesmo. A Figura 1 ilustra o funcionamento básico de um neurônio. Como representado na figura, o neurônio recebe uma série de sinais de entrada, ou estímulos, cada qual ativado com um determinado peso. Os estímulos são combinados através de uma função aditiva, que pode ser influenciada por uma tendência (ou bias) introduzida no sistema. O resultado é filtrado por uma função de ativação. Esta gera um sinal de saída, com uma certa intensidade, que servirá de estímulo para o próximo neurônio.

As ligações entre os neurônios são denominadas conexões e se caracterizam por terem intensidades diferentes. Estas intensidades são representadas pelos pesos sinápticos, que são coeficientes de correlação existentes entre os neurônios. Em essência, uma RNA funciona através da disseminação de estímulos entre suas camadas, sendo que a matriz de pesos sinápticos vai modificando estes estímulos, gerando respostas diferentes para estímulos diferentes.

Para implementar uma RNA utilizam-se redes de neurônios, estruturas capazes de representar superfícies de decisão mais complexas. O uso de um conjunto de neurônios bem articulado permite à rede “raciocinar”, estabelecendo relações não-lineares entre estí-

mulos e resultado. Esta arquitetura resulta nos denominados perceptrons de múltiplas camadas, ou MLPs (multilayer perceptrons). A Figura 2 mostra um modelo esquemático de um perceptron de 4 camadas, que contém duas camadas intermediárias ocultas.

Conforme Haykin (2001)[6], o treinamento é normalmente realizado de forma supervisionada, com o emprego do algoritmo denominado como Retropropagação de Erro (Error Back Propagation – EBP). Este algoritmo se baseia na realização de iterações durante as quais vão sendo modificados os pesos sinápticos, de trás para frente, buscando reduzir o erro no final de seu treinamento. O mesmo envolve dois passos: a propagação e a retro-propagação. Na propagação, um vetor de entrada é aplicado aos nós sensoriais da rede e seu efeito é propagado através da rede, de forma a produzir um conjunto de estímulos de saída, que caracterizam a resposta da rede.

Comparando a resposta gerada com a esperada verifica-se se é necessário fazer ajustes nos pesos sinápticos. Isto ocorre durante a retro-propagação, na qual os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. O ajuste dos pesos sinápticos faz com que a resposta real da rede se mova para mais perto da resposta desejada, em um sentido estatístico.

Uma das propriedades mais importantes das RNAs é a habilidade de simular o aprendizado, isto é, utilizar novos dados para ajustar o modelo e melhorar o desempenho. A aprendizagem é um processo pelo qual os parâmetros livres de uma RNA são adaptados, através de um processo de estimulação, ao ambiente na qual a rede está inserida. Em função da maneira pela qual a modificação dos parâmetros ocorre se determina qual a estratégia de aprendizagem (HAYKIN, 2001)[6].

3. Estimativa da aderência aço-concreto a partir de ensaios pull-out

A aderência entre o aço e o concreto é um fator determinante para o bom comportamento estrutural do concreto armado. O FIB (2000) [8] enfatiza que o conhecimento do comportamento da aderência é imprescindível para a correta compreensão das regras de cálculo do comprimento de ancoragem e emendas por traspasse das barras de armaduras, para o cálculo dos deslocamentos, considerando o efeito de enrijecimento por tração, o controle de fissuração e a quantidade mínima de armadura. Existem diversos fatores que influenciam na aderência aço-concreto, o ACI 408R/2003[9] enfatiza os seguintes: tipo de configuração das nervuras da barra, o diâmetro da barra, o estado em que se encontra a superfície da barra (deterioração), a disposição da barra na hora do lançamento do concreto (horizontal ou vertical), a relação água cimento (a/c), as resistências mecânicas do concreto, as adições minerais, bem como os materiais pozolânicos, as características físico-químicas dos materiais empregados no concreto, o adensamento e a idade de ruptura, dentre outros.

Existem diversos métodos de ensaios, descritos na literatura (FIB, 2000)[8], para mensurar a aderência aço-concreto. O mais utilizado é o ensaio de arrancamento simples (pull-out test) proposto pela recomendação técnica da RILEM CEB/FIP/83[10]. Com a realização do ensaio, cujo esquema está ilustrado na Figura 3, é possível obter as intensidades das forças em quilonewtons em função do deslocamento. Com este valor de força dividido pela área de




Figura 3
Esquema do ensaio pull-out mostrando as variáveis de controle da RNA

ancoragem da barra, calcula-se a tensão de aderência (τ_b), como mostra a Equação 1. Nesta equação “F” é a força de arrancamento, “ \varnothing ” é o diâmetro da barra de aço, “le” é o comprimento de ancoragem do ensaio e “c” é o cobrimento de concreto. Vale ressaltar que a tensão máxima de aderência ($\tau_{b,m\acute{a}x}$) é calculada com base na força máxima de arrancamento obtida no ensaio.

$$\tau_b = \frac{F}{\pi \varnothing l e} \tag{1}$$

Um grande número de variáveis, como descrito anteriormente afeta os resultados de tensão máxima de aderência. Para melhorar a eficiência do método é necessário desenvolver modelos mais sofisticados, tema que é objeto de interesse da pesquisa em andamento. Dada a sinergia de efeitos e falta de conhecimento sobre

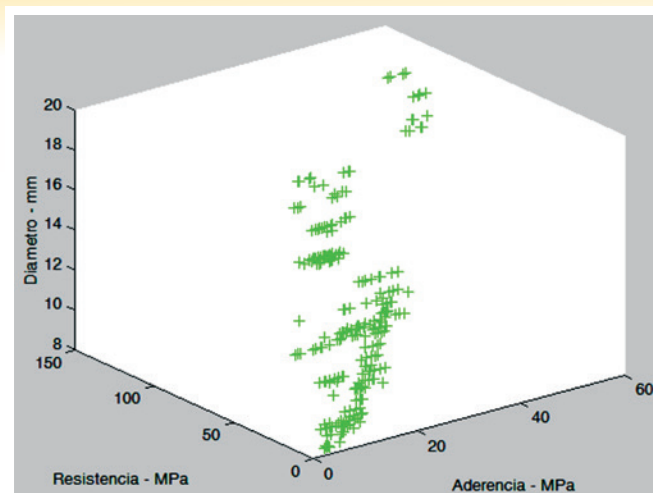


Figura 4
Distribuição dos dados de ensaios de aderência tipo pull-out, utilizados para compor a RNA

Table 1
Experimental data

References	\varnothing (mm)	le (mm)	c (mm)	Age (days)	Concrete compressive strength f_c (MPa)
Castro (2000) [16]	16	80	52 / 92	15 / 18	83,04 / 86,14
Fernandes (2000) [17]	10 / 20	50 / 100	45 / 90	28	27,47 / 27,99
Barbosa (2002) [18]	16 / 20	80 / 100	52 / 90	90	33,63/54,77/63,31 /
França (2004) [19]	16	80	92	28 / 90	32,97 / 35,21
Almeida Filho (2006) [20]	10 / 16	50 / 80	45 / 72	7 / 14	30 / 60
Graeff (2007) [21]	8/12,5	40/62,5	36/56,2	21	25
Caetano (2008) [15]	12,5	62,5	61,8	63	25 / 45 / 65
Simplício (2008)[22]	6,3/8/10/ 12,5/16	18,9/24/30/ 37,5/48	96,9/96/95/ 93,8/92	90	40/35,9/41,4/34/37,4/39,4 /40/39,6/28/29,1/29,3
Reis (2009)[23]	10/16	50/80	45/72	28	23,6/ 37,2
Silva (2010) [3]; Silva et al. (2013) [24]	8/10 /12,5	40/50/62,5	96/95/93,7	3/7/28	16,7/21,1/28/33,1/40,5/49,9
Lorrain et al. (2010) [25]	12,5	62,5	56,2	28	20
Lorrain et al. (2011) [4]	8	80/135	36	3/7/14	6,8/8,1/15,07/23,54/26,75/ 27,12
Ferreira et al. (2011)[26]	6,3/8/10	31,5/40/50	46	7	38,2/45,3
Tojal (2011)[27]	10/16	50/ 80	45/ 72	28	34,5
Silva Filho et al. (2012) [28]	12,5	62,5	56,2	28	27,4
França (2012)[29]	6,3/8/10	31,5/40/50	96,9/96/95	21	25/40
Baiochi et al. (2013) [30] Jacintho et al. (2013)[31]	10	63	46	7/28	49,56/59,63
Godoy et al. 2012)[32] Jacintho et al. (2014)[33]	8	110	46	14/ 28	23,54/38,27/43,27
Lovera e Frutos (2013)[34] Gavilan et al. (2014)[35]	8	91/80/70/63	46	3/5/7/28	20/25/30/35
Silva (2010) [3]; Silva et al. (2014)[36]	8/10/12,5	80/100/125/ 48/60/45	46/45/43,75	3/7/28	16,7/21,1/28/33,1/40,5/49,9
Martins et al. (2014)[37]	8	95/47/39,6	45	7	23,15/45,40/50,61

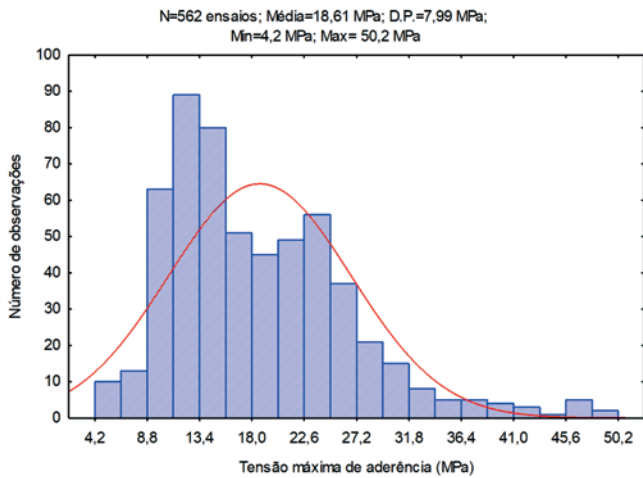


Figura 5
Distribuição dos resultados de tensão máxima de aderência utilizados na RNA

cada um deles, pode-se dizer que este é um problema que exige uma modelagem não-linear de um conhecimento pouco estruturado, o que justifica o emprego da técnica de modelagem via RNAs.

4. Formulação do modelo

De forma a atingir o objetivo proposto por este trabalho, utilizou-se uma RNA com 4 camadas, implementada com a utilização do programa computacional MATLAB 6.0, apropriada para interpretação dos dados de ensaios de aderência AÇO-CONCRETO, com vias a produzir estimativas de resistência.

Fixou-se o número de camadas em 4 em função do número inicial de amostras desta base de dados. Para a base de dados utilizada (562 amostras) considera-se que esta quantidade de correlações permite que se forneça uma boa flexibilidade e capacidade de in-

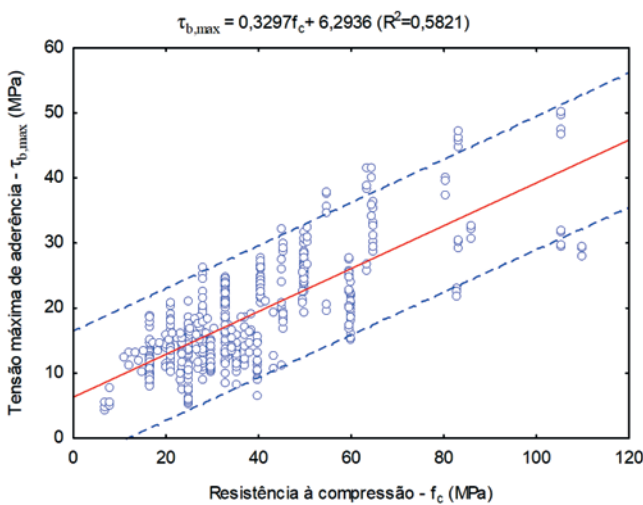


Figura 6
Relação entre a resistência à compressão e a tensão máxima de aderência dos ensaios tipo pull-out utilizados para compor a RNA

terpretação à rede, conforme estudos preliminares realizados pelo Grupo de Pesquisa LEME [11], [12], [13] e [14]. Nestes estudos chegou-se a conclusão de que esta tipologia de rede será capaz de produzir uma simulação adequada e coerente com o objetivo da pesquisa. Os dados de entrada foram normalizados utilizando-se para esta finalidade a função *premnmx*, que pré-processa o treinamento da rede através da normalização das entradas e metas dentro do intervalo [-1,1].

Para analisar como a estrutura da rede afetava a sua precisão de desempenho, foram então modificadas as características da rede padrão, sendo variados o número de neurônios e os parâmetros de controle, com o intuito de averiguar como estas mudanças afetavam o resultado.

Os dados de origem utilizados no presente estudo para treinar e testar as RNAs englobavam resultados de ensaios de aderência aço-concreto tipo pull-out de três diferentes pesquisas. A tabela 1 mostra quais foram os dados retirados e os respectivos autores.

Os dados de origem utilizados no presente estudo para treinar e testar as RNAs englobavam resultados de ensaios aderência do tipo pull-out, sendo que a tensão máxima de aderência dos mesmos variava entre valores de 4,0 a 50,2 MPa. A Figura 4 mostra a distribuição dos dados utilizados (Diâmetro da barra de aço “Ø”

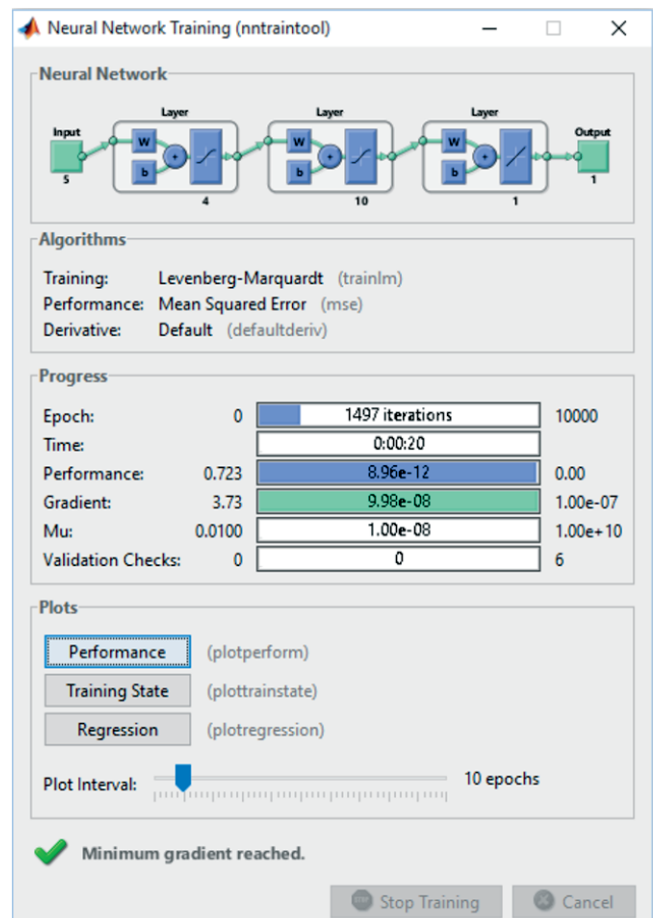




Figura 7
Matlab Neural Network Training Toolbox

**Figura 8**

Evolução do treinamento da Rede Neural Artificial – RNA 20x40x40x1

**Figura 9**

Evolução do treinamento da Rede Neural Artificial – RNA 10x30x30x1

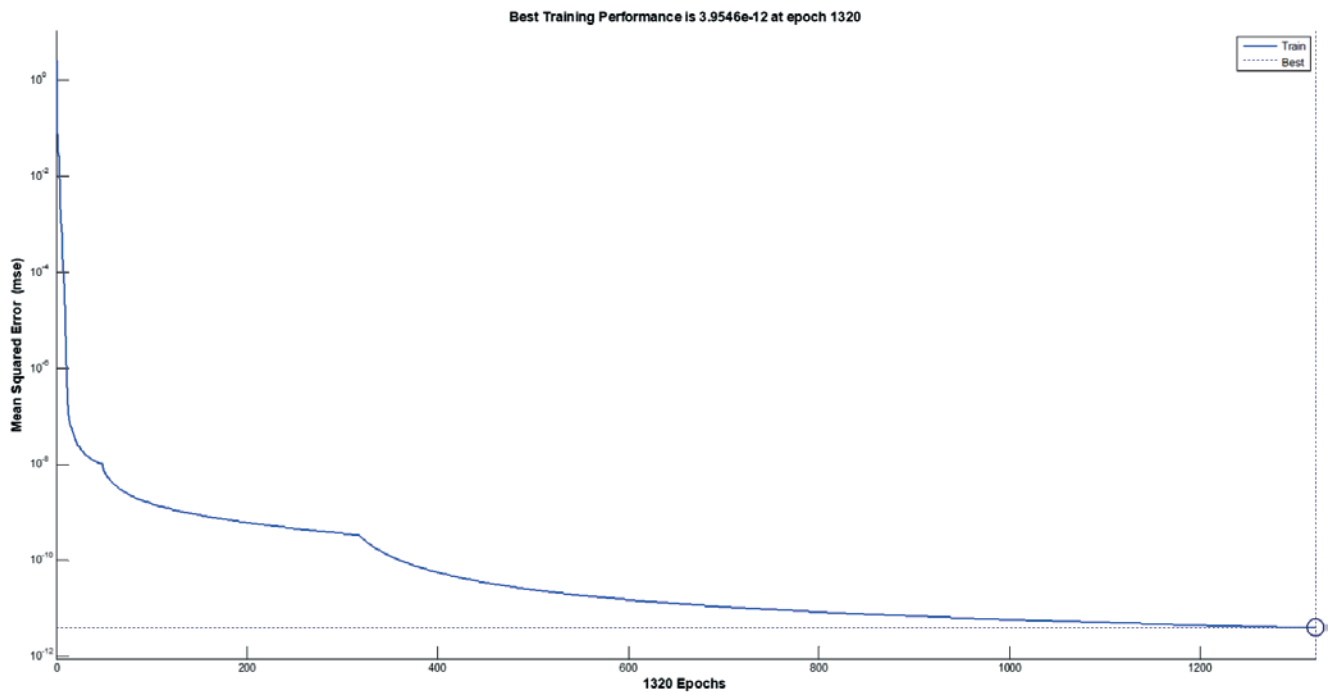


Figura 10
Evolução do treinamento da Rede Neural Artificial – RNA 10x40x80x1




Figura 11
Modelagem da Rede Neural Artificial – RNA 20x40x40x1

x Resistência à compressão "fc" x Resistência de aderência "tb"). A Figura 5 mostra o número de observações em cada faixa de tensão máxima de aderência para os resultados utilizados para compor a RNA. Já a Figura 6 mostra a relação direta entre a resistência à compressão e a tensão máxima de aderência, evidenciando um R² igual a 0,5821.

As relações entre os dados foram estimadas utilizando várias configurações de uma RNA, treinada com um algoritmo de retropropagação de erro, sendo controlados o erro da estimativa e o número de épocas de treinamento (etapas de iteração), e registrado o tempo computacional gasto para proceder com este treinamento. Para realizar a aproximação adotou-se o formato proposto por Caetano (2008)[15], indicado na equação 2:

$$\tau_{b,m\acute{a}x} = 10,34 \times \frac{1}{En^{0,5}} \times Ner^{0,25} \times f_{c_c}^{0,5} \times \frac{1}{Te_c^{f_{c_c}^{0,5}}} \times \frac{1}{\varnothing_c^{f_{c_c}^{0,5}}} \times \left(\frac{0,3 + GC_c}{0,3 + GC_c^{1,4}} \right) \quad (2)$$

Onde:

$\tau_{b,m\acute{a}x}$ = Resistência máxima de aderência, em MPa. En = Tipo de ensaio (0,5 para arrancamento simples; 1,5 para arrancamento excêntrico). Ner = Tipo de nervura (0,5 para tipo "N"; 1,5 para tipo "n"). fcc = resistência à compressão do concreto codificada, em

MPa; $f_{c_c} = \frac{f_c}{30}$. Tec = Temperatura de exposição codificada, em °C; $Te_c = 1$, para $Te \leq 350^{\circ}C$. \varnothing_c = Diâmetro da barra de aço

codificada, em mm. $\varnothing_c = \frac{\varnothing}{16}$; GCc = Grau de corrosão codificado, em porcentagem; $GC_c = \frac{GC}{2}$.




Figura 12
Modelagem da Rede Neural Artificial – RNA 10x30x30x1

5. Resultados e discussões

Em todos os dados retirados da literatura foram com En = 0,5; Ner = 0,5, temperatura ambiente, ou seja, sem altas temperaturas e sem grau de corrosão.

A figura 7 ilustra o Matlab Neural Network Training Toolbox que foi utilizado para realização das simulações através do programa computacional Matlab R2012.

As figuras 8, 9 e 10 ilustram o treinamento de três das simulações utilizadas para a modelagem dos resultados obtidos experimentalmente, visando estimar a resistência à compressão do concreto a partir dos resultados de ensaios de aderência aço-concreto através da utilização das RNAs. A linha em azul representa o erro calculado em cada passo da rede. Em virtude de se buscar o máximo treinamento possível, o valor do erro médio admissível estabelecido para a rede foi de zero.

As figuras 11, 12 e 13 ilustram os resultados de três das RNAs que foram testadas no presente trabalho. Ambas simulações geraram resultados muito parecidos. Como pode ser observado nas figuras, os resultados obtidos indicam que o poder de estimação das RNAs é eficaz. Nas figuras estão representados os dados originais dos 200 casos (losango vermelho), uma estimativa baseada em processos estatísticos tradicionais (cruz azul) e os resultados da RNA (círculo verde).

A figura 11 mostra o resultado obtido com o melhor perceptron estudado, que tinha 20 neurônios na segunda camada, 40 na terceira camada, 40 na quarta camada e 1 na camada de saída. Nas primeiras a função de transferência utilizada foi a tangente sigmóide hiperbólica, enquanto na camada de saída a função adotada foi a linear. A figura 12 demonstra o resultado obtido com um perceptron estudado, que tinha 10 neurônios na segunda camada, 30 na terceira




Figura 13
Modelagem da Rede Neural Artificial – RNA 10x40x80x1

camada, 30 na quarta camada e 1 na camada de saída. Nas primeiras a função de transferência utilizada foi a tangente sigmóide hiperbólica, enquanto na camada de saída a função adotada foi a linear.

Já a figura 13 demonstra o resultado obtido com um perceptron estudado, que tinha 10 neurônios na segunda camada, 80 na terceira camada, 80 na quarta camada e 1 na camada de saída. Nas primeiras a função de transferência utilizada foi a tangente sigmóide hiperbólica, enquanto na camada de saída a função adotada foi a linear.

Apesar do banco de dados deste estudo ainda ser pequeno, pode-se observar que, através da utilização das RNAs, pode-se ajustar melhor os dados obtidos nos experimentos em relação aos modelos estatísticos tradicionais.

Com base nestes primeiros experimentos, a continuidade desta pesquisa irá focar-se em aumentar a base de dados utilizada na simulação e utilizar outros algoritmos de treinamento para realizar esta simulação.

6. Conclusões

Este trabalho buscou, em particular, avaliar a possibilidade de se utilizar o ensaio de aderência aço/concreto para a estimativa da resistência do concreto (f_c), uma iniciativa complicada dado o fato de o concreto ser um material bastante heterogêneo e que se modifica no tempo.

Os resultados demonstram que é possível realizar um mapeamento não linear da relação resistência do concreto x aderência aço/concreto, levando em consideração parâmetros como o comprimento de ancoragem, o diâmetro da bar-

ra, a idade de ruptura e o cobrimento de concreto ao redor da barra de aço (confinamento). A novidade consistiu no emprego dos modelos neurais. Dada a sinergia de efeitos e falta de conhecimento sobre cada um dos parâmetros que afetam a estimativa da f_c , pode-se concluir que o problema exige uma modelagem não-linear de um conhecimento pouco estruturado.

A técnica de modelagem utilizando RNAs, apresentou-se como uma ferramenta eficaz para o tratamento dos dados propostos, dada capacidade de aprendizagem e de generalização do conhecimento adquirido da RNA. Todavia é preciso utilizar uma base de dados que contenha uma quantidade significativa de resultados prévios, com uma boa variação dos parâmetros considerados importantes para a avaliação do comportamento da estrutura.

A partir da análise dos resultados obtidos, pode-se inferir que a utilização das RNAs tem potencial para produzir métodos numéricos robustos e flexíveis para interpretação de ensaios de tensão de aderência aço/concreto (Retirar esse trecho). Os testes realizados reforçam a idéia de que a utilização do ensaio pode ser útil para a análise de estruturas, confirmando a idéia de que este ensaio tem grande potencial de utilização nos casos de inspeção de estruturas. Os modelos gerados podem ser considerados como dinâmicos, visto que as redes podem ir sendo aperfeiçoadas na medida em que se coletam novos dados. Os resultados obtidos indicam que as RNAs tem potencial para serem utilizadas para obtenção de estimativas da resistência à compressão a partir de dados do ensaio de aderência aço/concreto, para inspeção de estruturas.

7. Referências bibliográficas

- [1] LORRAIN, M. S.; BARBOSA P. M. Controle de qualidade dos concretos estruturais: ensaio de aderência aço-concreto. In: Revista Concreto & Construções, São Paulo, Nº51, 3º trimestre, p. 52-57, 2008.
- [2] LORENZI, A. Aplicação de redes neurais artificiais para estimativa da resistência à compressão do concreto a partir da velocidade de propagação do pulso ultra-sônico. Tese (Doutorado em Engenharia Civil) - Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.
- [3] SILVA, B. V. Investigação do potencial dos ensaios APULOT e pull-out para estimativa da resistência a compressão do concreto. Dissertação (Mestrado em Engenharia) - Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, UNESP, 2010.
- [4] LORRAIN, M. S. ; BARBOSA, M. P.; SILVA FILHO, L. C. P. Estimation of compressive strength based on Pull-Out bond test results for on-site concrete quality control. IBRACON Structures and Materials Journal, v. 4, p. 4, 2011.
- [5] SRIRAM, R. D.. Intelligent Systems for Engineering – A Knowledge-based Approach. Londres, Springer-Verlag, 1997.
- [6] HAYKIN, S. Redes Neurais: Princípios e prática. Porto Alegre, Bookman, 2001. Tradução de Paulo Martins Engel.
- [7] CORRÊA, L. G., Memória Associativa em Redes Neurais Realimentadas. 2004. 119p. Dissertação (Mestrado) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo. São Paulo, 2004.
- [8] FÉDÉRATION INTERNATIONALE DE BÉTON. FIB: Bond of reinforcement concrete, State-of-art report. Bulletin Nº 10. Lausanne, Switzerland: FIB, 2000. 427p.
- [9] AMERICAN CONCRETE INSTITUTE. ACI 408R: Bond and development of straight reinforcing bars in tension. Farmington Hills: ACI, 2003. 49 p.
- [10] COMITÉ EURO-INTERNATIONAL DU BÉTON. RILEM/CEB/FIP RC6: Bond test for reinforcing steel - 1 - pull-out test. Paris: CEB, 1983. 3p.
- [11] LORENZI, A.; SILVA FILHO, L. C. P. . Análise de Ensaios Ultra-sônicos no Concreto através de Redes Neurais Artificiais. Learning and Nonlinear Models, v. 9, p. 216-233, 2011.
- [12] LORENZI, A.; SILVA FILHO, L. C. P. ;CAMPAGNOLO, J. L.. Application of Artificial Neural Network for Interpreting Ultrasonic Readings of Concrete. International Journal of Materials & Product Technology, Switzerland, v. 26, n.1/2, p. 57-70, 2006.
- [13] LORENZI, A.; SILVA FILHO, L. C. P. ;CAMPAGNOLO, J. L.. Desenvolvimento de Redes Neurais Artificiais para Interpretação de Ensaios de Velocidade de Propagação de Pulso Ultrassônico no Concreto. Revista IBRACON de Estruturas e Materiais, v. 4, p. 800-830, 2011.
- [14] LORENZI, A.2008LORENZI, A. ; SILVA FILHO, L.C.P. ; TISBIEREK, F. T.. Modelagem de Dados de Ensaios Ultra-sônicos em Concreto através de Redes Neurais Artificiais (RNAs). Revista Abende, v. 25, p. 42-46, 2008.
- [15] CAETANO, L. F. Estudo do comportamento da aderência de elementos de concreto armado em condições extremas. Dissertação (Mestrado em Engenharia Civil) - Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.
- [16] CASTRO, C. M. Concreto de alto desempenho: estudo da aderência com a armadura sob ações repetidas. Dissertação (Mestrado em Engenharia de Estruturas) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000.
- [17] FERNANDES, R. M. A influência das ações repetidas na aderência aço-concreto. Dissertação (Mestrado em Engenharia de Estruturas) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000.
- [18] BARBOSA, M. T. G. Avaliação do comportamento da aderência em concretos com diferentes classes de resistência. Tese (Doutorado em Engenharia Civil) – Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2002.
- [19] FRANÇA, V. H.Aderência Aço-Concreto – Uma análise do comportamento do concreto fabricado com resíduos de borracha. Dissertação (Mestrado em Engenharia) - Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, UNESP, 2004.
- [20] ALMEIDA FILHO, F. M. Contribuição ao estudo da aderência entre barras de aço e concreto auto-adensável. Tese (Doutorado em Engenharia de Estruturas) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2006.
- [21] GRAEFF, A. G., Avaliação experimental e modelagem dos efeitos estruturais da propagação da corrosão em elementos de concreto armado. 2007. 184 f. Dissertação (Mestrado em Engenharia) - Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2007.
- [22] SIMPLÍCIO, M. A. S., Estudo sobre a aderência entre barras de aço e concreto reforçado com fibras. 2008. 261 f. Tese (Doutorado) Programa de Pós-Graduação em Engenharia Civil - Universidade Federal de Pernambuco (UFPE). Recife, 2008.
- [23] REIS, C. N. S., Influência da utilização de agregado miúdo de RCD na aderência aço-concreto reciclado. 2009. 171 f. Dissertação (Mestrado em Engenharia) - Pós-Graduação em Engenharia Civil e Ambiental - PPGCEA - Universidade Estadual de Feira de Santana - UEFS. Bahia, 2009.
- [24] SILVA,B.V.;BARBOSA, M.P.; SILVA FILHO, L. C. P.; LORRAIN, M.S.. Experimental investigation on the use of steel-concrete bond tests for estimating axial compressive strength of concrete: part 1. IBRACON Structures and Materials Journal, v. 6 (5), p. 715-736, 2013.
- [25] LORRAIN, M. S. ; CAETANO, L. F. ; SILVA, B.V. ; GOMES, L. E. S. ; BARBOSA, M.P. ; SILVA FILHO, L. C. P. Bond strength and rib geometry: a comparative study of the influence of deformation patterns on anchorage bond strength. In: PCI Annual Convention & 3rd International FIB Congress FIB, Washington D. C., 2010.
- [26] FERREIRA, E. G.; GONÇALVES, R. S.; CARVALHO, E.; CUNHA, J. C.; BARBOSA, M. P.; LORRAIN M. S. Controle

- da Qualidade do Concreto Pelo Ensaio de Aderência "Pull out Test". In: 53º Congresso Brasileiro do Concreto, 2011, Florianópolis/SC. Anais do 53ºCBC. São Paulo/SP: IBRACON, 2011.
- [27] TOJAL, T. L., Contribuição ao estudo da aderência de barras de aço em concreto autoadensável reforçado com fibras metálicas. 2011. 116 f. Dissertação (Mestrado em Engenharia Civil : Estruturas) – Universidade Federal de Alagoas. Centro de Tecnologia. Maceió, 2011.
- [28] SILVA FILHO, L. C .P.; SILVA, B.V. ; DAL BOSCO, V. I. ; GOMES, L. E. S.; BARBOSA, M.P. ; LORRAIN, M. S. Analysis of the influence of rebar geometry variations on bonding strength in the pull-out test. In: Bond in Concrete 2012 - Bond, Anchorage, Detailing. Fourth International Symposium BIC/ FIB/ Heriot-Watt University, Brescia, Italy, 2012.
- [29] FRANÇA, M. B. B.; CARVALHO, E. P.; CUNHA, J. C.; RODRIGUES, C. S.; MAIA, N. S. Estudo experimental da aderência aço-concreto para barras finas de aço CA-50. In: 54º Congresso Brasileiro do Concreto, 2012, Maceió/AL. Anais do 54º CBC. São Paulo/SP: IBRACON, 2012.
- [30] BAIOSCHI, A. G., PIMENTEL, L. L., JACINTO, A. E.P.G.A., BARBOSA, M. P., FONTANINI, P; S.P., LORRAIN, M. Análise da aderência entre o concreto desenvolvido com resíduo de construção civil e o aço pelo método APULOT. In: 55º Congresso Brasileiro do Concreto, 2013, Gramado/RS. Anais do 55º CBC. São Paulo/SP: IBRACON, 2013.
- [31] JACINTHO, A.E.P.G.A.; PIMENTA, M.T.M.; PIMENTEL, L. L.; FONTANINI, P.S.P.; BARBOSA, M. P. Estudo da aderência aço e concreto com RCD cinza em substituição aos agregados graúdos usuais. In: 55º Congresso Brasileiro do Concreto, 2013, Gramado/RS. Anais do 55º CBC. São Paulo/SP: IBRACON, 2013.
- [32] GODOY, J. L.; JACINTHO, A. E. P. G. A.; PIMENTEL, L. L.; LORRAIN, M.; BARBOSA, M. P. Substituição de uma parcela do agregado natural por borracha de pneus: influência na aderência aço e concreto. In: 54º Congresso Brasileiro do Concreto, 2012, Maceió/AL. Anais do 54º CBC. São Paulo/SP: IBRACON, 2012.
- [33] JACINTHO, A. E. P. G. A.; PIMENTEL L. L.; BARBOSA M. P.; FONTANINI P. S. P. Steel and concrete bond stress: a contribution to the study of APULOT tests using concrete with rubber addition. Revista IBRACON de Estruturas e Materiais, v. 7, p. 817-844, 2014.
- [34] LOVERA, H.; FRUTOS, A. 2013. 136 f. Evaluación de la Tensión de Adherencia entre el Hormigón y el Acero ante la Variación de la Resistencia a Compresión mediante el Ensayo APULOT. Tesis de Ingeniería Civil, Universidad Nacional de Asunción. Asunción, Paraguay, 2013.
- [35] GAVILAN, S.; SILVA, B. V.; SILVA FILHO, L. C. P.; BARBOSA, M.P. Ensayo de arrancamiento, relación recubrimiento-diámetro de barras para evitar el efecto splitting. In: XXXVI Jornadas Sul Americanas de Engenharia Estrutural, 2014, Montevideo/Uruguay. Memórias XXXVI Jornadas Sul Americanas de Engenharia Estrutural. Porto Alegre/RS: ASAAE - Associação Sul Americana de Engenharia Estrutural, 2014.
- [36] SILVA, B. V.; BARBOSA, M. P.; SILVA FILHO L. C. P.; LORRAIN M. S. Experimental investigation on the use of steel-concrete bond tests for estimating axial compressive strength of concrete. Part 2: APULOT. IBRACON Structures and Materials Journal, v. 7 (5), p. 856-878, 2014.
- [37] MARTINS, J. V. R.; JACINTHO, A.E.P.G.A.; PIMENTEL, L. L.; BARBOSA, M. P.; FONTANINI, P. S. P.; LORRAIN, M. Estudo da aderência entre concreto e aço pelo ensaio APULOT utilizando concreto de alta resistência. In: 56º Congresso Brasileiro do Concreto, 2014, Natal/RN. Anais do 56º CBC. São Paulo/SP: IBRACON, 2014.