

MODELO DE PREVISÃO DE RECALQUES EM ESTACAS HÉLICE CONTÍNUA, METÁLICAS E ESCAVADAS ATRAVÉS DE REDES NEURAIIS ARTIFICIAIS

Settlement prediction model for continuous flight auger, steel and bored piles using artificial neural networks

Silvrano Adonias Dantas Neto*

Mariana Vela Silveira**

Gerson Jacques Miranda dos Anjos***

Alfran Sampaio Moura****

RESUMO – Este trabalho apresenta um método para previsão de recalques em estacas desenvolvido com o uso de redes neurais artificiais do tipo perceptron. Foram utilizados resultados de 199 ensaios SPT e provas de carga estáticas realizadas em estacas hélice contínua, escavadas e metálicas. São variáveis de entrada para o modelo: tipo e geometria da estaca (diâmetro e comprimento), as características do solo definidas a partir de resultados dos ensaios SPT e a carga aplicada. A arquitetura da rede neural que apresentou o melhor desempenho foi A:10:14:8:4:2:1, com um coeficiente de correlação igual a 0,94. Os resultados foram comparados àqueles obtidos em trabalhos anteriores e por outros autores que também desenvolveram modelos de previsão de recalques com redes neurais artificiais. Esta comparação mostrou que o modelo proposto neste trabalho foi capaz de prever os recalques com maior precisão.

SYNOPSIS – This work presents a method for pile settlement prediction using an artificial neural network (ANN) known as perceptron. Results from 199 SPT and static load tests carried out on continuous flight auger, steel and bored piles were used in the model development. The ANN model allows the prediction of settlements as a function of the pile type and geometry (diameter and length), the stratigraphy and characteristics of soils defined by SPT test results, and the applied load. The architecture that presented the best performance was A10:14:8:4:2:1, with a correlation coefficient of 0.94. The results were compared to those obtained in previous works and by other authors that also developed settlement prediction models using ANNs. This comparison has shown that the proposed model is able to predict settlements more accurately.

PALAVRAS CHAVE – Estacas, redes neurais artificiais, recalques.

* Professor Associado, Eng. Civil, D.Sc., Programa de Pós-Graduação em Engenharia Civil, Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza-CE, Brasil. E-mail: silvrano@ufc.br

** Doutoranda, Eng. Civil, M.Sc, Programa de Pós-Graduação em Engenharia Civil, Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro-RJ, Brasil. E-mail: vela.silveira@gmail.com

*** Professor Adjunto, Eng. Civil, D.Sc, Faculdade de Engenharia Civil, Universidade Federal do Pará, Belém-PA, Brasil. Email: mirandadosanjos@gmail.com

**** Professor Adjunto, Eng. Civil, D.Sc., Programa de Pós-Graduação em Engenharia Civil, Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza-CE, Brasil. E-mail: alfransampaio@ufc.br

1 – INTRODUÇÃO

Os elementos de fundação devem ser projetados de forma que, além de atender aos critérios de capacidade de carga, os recalques sofridos sejam compatíveis com a utilização da estrutura (recalques admissíveis). Portanto, apesar de ser muitas vezes negligenciada, a previsão de recalques é uma etapa importante a ser levada em consideração, especialmente no que se refere às fundações profundas, para as quais os projetos são baseados frequentemente apenas na estimativa da capacidade de carga a partir do emprego de metodologias empíricas baseadas nos resultados de ensaios SPT (*Standard Penetration Test*) ou CPT (*Cone Penetration Test*) (Anjos, 2006).

A Figura 1 mostra o efeito de uma carga vertical P atuando sobre uma estaca isolada de comprimento L , cuja base encontra-se a uma distância d em relação à camada incompressível. De acordo com Cintra e Aoki (2010), com a aplicação da carga (P), a estaca inicialmente experimenta um encurtamento elástico de seu elemento estrutural (ρ_e), como se a sua ponta estivesse sobre uma camada rígida e incompressível. Em seguida, os recalques sofridos (ρ_s) ocorrem devido aos mecanismos de transferência de carga entre o solo e a estaca.

De uma forma geral, pode considerar que a previsão dos recalques em fundações profundas é um problema um tanto complexo, devido às incertezas existentes no que se refere às condições de contorno do problema e à obtenção dos parâmetros geotécnicos que possam representar os mecanismos de transferência de carga nos elementos de fundação sob carga. De acordo com este modelo, o recalque total no topo da estaca pode ser calculado como:

$$\rho = \rho_e + \rho_s \quad (1)$$

ρ – recalque total sofrido pela estaca isolada;

ρ_e – parcela do recalque atribuída ao deslocamento elástico do elemento estrutural da estaca;

ρ_s – parcela do recalque atribuída ao mecanismo de transferência de carga entre a estaca e o solo.




Fig. 1 – Recalque em uma estaca isolada (modificado de Cintra e Aoki, 2010).

O desenvolvimento dos recalques em fundações profundas, especificamente no caso das estacas, pode ser considerado um problema complexo associado a muitas incertezas. Em geral, é observado que os recalques em estacas são influenciados por muitos fatores, dentre os quais podem ser citados: as características de deformabilidade e resistência dos materiais (solo e estaca), a estratigrafia do subsolo, a geometria dos elementos de fundação, os mecanismos de transferência de carga entre o solo e os elementos de fundação, dentre outros.

A previsão dos recalques em estacas pode ser realizada por meio da aplicação de diferentes metodologias. Dentre elas podem ser citadas aquelas desenvolvidas a partir da aplicação dos conceitos da Teoria da Elasticidade, que são talvez as mais comuns no âmbito da Engenharia de Fundações, como por exemplo, os métodos teóricos de Poulos e Davis (1980) e Randolph e Wroth (1978). Também podem ser citados na previsão de recalques em estacas os métodos numéricos, os quais podem considerar diferentes modelos constitutivos para os materiais envolvidos (elástico-linear, elástico não-linear, elastoplástico, etc.) e diferentes condições de contorno.

As principais dificuldades para o emprego das metodologias baseadas na Teoria da Elasticidade, ou via métodos numéricos, para a estimativa de recalques em estacas referem-se à obtenção de parâmetros geotécnicos, que representem o comportamento dos materiais e as condições de contorno do sistema solo-fundação.

Analisando todas as metodologias citadas previamente, pode ser observado que o desenvolvimento dos recalques em estacas é um processo complexo, multivariado, e normalmente não-linear. Assim, a necessidade do desenvolvimento de novos modelos que permitam a previsão dos recalques em fundações do tipo estaca a partir de ferramentas simples e variáveis de entrada que possam representar o fenômeno é crucial no âmbito na Engenharia de Fundações. Por esta razão, as redes neurais artificiais (RNA) surgem como uma poderosa ferramenta a ser utilizada no desenvolvimento de modelos de previsão de recalques em estaca, podendo fornecer resultados mais próximos aos valores reais que aqueles previstos pelos métodos citados anteriormente.

Amâncio (2013) desenvolveu um modelo neuronal o qual permite a previsão dos recalques em estacas hélice contínua, escavadas e metálicas com o uso das RNA, a partir do conhecimento das informações do subsolo definidas com base nos resultados de ensaios SPT e da geometria da estaca. Este modelo é alimentado com informações referentes à geometria da estaca (diâmetro e comprimento) e com dados referentes à condição do subsolo no qual se encontra a estaca, por meio da consideração da soma dos valores de N_{SPT} ao longo do fuste da estaca, e do valor de N_{SPT} na ponta da estaca. O coeficiente de correlação entre os valores reais conhecidos para as estacas utilizadas na modelagem e os valores calculados pelo modelo foi de 0,89, na etapa de validação do modelo, o qual mostra a eficiência da ferramenta na previsão de recalques em estacas.

Dantas Neto *et al.* (2014) também aplicaram um modelo neuronal para a previsão de recalques em estacas a partir do mesmo conjunto de dados utilizado por Amâncio (2013). A principal diferença entre estes dois trabalhos foi que Dantas Neto *et al.* (2014) incorporaram ao conjunto de treinamento e validação exemplos cujos valores dos recalques eram iguais a zero, os quais não haviam sido considerados durante o desenvolvimento do modelo por Amâncio (2013). Este procedimento levou a um aumento do coeficiente de correlação do modelo de 0,89 para 0,94 na etapa de validação.

Assim sendo, levando-se em consideração a necessidade do desenvolvimento de um modelo simples que possa ser alimentado por informações facilmente disponíveis quando da elaboração de um projeto de fundações em estacas, este trabalho tem por objetivo apresentar um modelo de previsão de recalque em estacas, que considere além das variáveis de entrada adotadas por Amâncio (2013) e Dantas Neto *et al.* (2014), variáveis que levem em consideração a estratigrafia do subsolo no qual a estaca encontra-se instalada, e a deformabilidade do solo abaixo da ponta da estaca até à camada rígida incompressível. Os resultados obtidos mostraram que a introdução destas variáveis de entrada no modelo levou a uma melhoria na previsão de recalques, quando comparados com os modelos dos trabalhos de Amâncio (2013) e Dantas Neto *et al.* (2014).

2 – AS REDES NEURAIS ARTIFICIAIS: CONCEITOS E FORMULAÇÃO

As redes neurais artificiais (RNA) são processadores maciçamente paralelos distribuídos e constituídos de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para algum uso (Haykin, 2001). Matematicamente uma rede neural artificial pode ser entendida como um conjunto de nós, que representam os neurônios, organizados em camadas sucessivas, de forma análoga à rede neural mais poderosa conhecida, o cérebro humano.

Segundo Haykin (2001), numa RNA, o neurônio é a unidade fundamental utilizada para o processamento das informações necessárias e tarefas desejadas. A Figura 2 mostra a representação de um neurônio artificial na forma de grafo de fluxo de sinal, como uma analogia ao neurônio biológico, com a apresentação de todos os seus elementos.




Fig. 2 – Neurônio artificial.

Na Figura 2, o valor y_k representa a resposta do neurônio artificial quando submetido aos estímulos externos, sendo calculado de acordo com as expressões seguintes:

$$u_k = \sum w_{ki} x_i = \{\mathbf{w}\}^T \{\mathbf{x}\} \quad (2)$$

$$v_k = u_k + b_k = \sum w_{ki} x_i + b_k = \{\mathbf{w}\}^T \{\mathbf{x}\} + b_k \quad (3)$$

$$y_k = f(v_k) = f(\sum w_{ki} x_i + b_k) = f(\{\mathbf{w}\}^T \{\mathbf{x}\} + b_k) \quad (4)$$

u_k – saída do combinador linear;

v_k – campo local induzido;

y_k – sinal de saída ou resposta do neurônio;

b_k – *bias* ou limiar;

$f(.)$ – função de ativação do neurônio;

$\{\mathbf{x}\} = [x_1, x_2, x_3, \dots, x_m]^T$ – vetor dos sinais de entrada;

$\{\mathbf{w}\} = [w_{k1}, w_{k2}, w_{k3}, \dots, w_{km}]^T$ – vetor dos pesos sinápticos – ligam o neurônio k ao vetor de entrada $\{\mathbf{x}\}$.

Dentre os diferentes tipos de redes neurais utilizados para a modelagem de fenômenos em engenharia, destacam-se os perceptrons multicamadas. O perceptron multicamada é uma rede neural multicamada alimentada adiante, constituída por três tipos de camadas: a camada de entrada,

constituída por nós cuja função é a de receber os estímulos externos definidos pelo vetor $\{x\}$ descrito anteriormente; uma ou mais camadas ocultas de neurônios, responsáveis pelo aumento da capacidade da rede neural artificial em extrair o comportamento mais complexo do ambiente no qual a rede está inserida; e a camada de saída, composta por neurônios cujos sinais representam as respostas para os estímulos apresentados à rede neural.

Nas redes multicamadas, os neurônios de cada camada são calculados utilizando-se a formulação apresentada nas Equações 2 a 4, considerando-se como dados de entrada os valores dos neurônios, ou nós, da camada anterior. Desta forma, o sinal se propaga desde a camada de entrada até à saída, razão pela qual é dito que os perceptrons são redes alimentadas adiante.

Uma das mais importantes propriedades de uma rede neural é a sua habilidade de aprender a partir do ambiente na qual está inserida, e melhorar seu desempenho através de um processo contínuo de treinamento. O treinamento de uma rede neural artificial consiste na alteração de todos os pesos sinápticos (w_{kj}) e limiares existentes (b_k), a partir da experiência conhecida sobre o fenômeno estudado, normalmente disponível em um conjunto de dados do tipo entrada-saída conhecida, designado como conjunto de treinamento.

O desempenho de uma rede neural pode ser avaliado por meio da comparação entre os valores obtidos para os neurônios da camada de saída (y_k), e os valores existentes no i -ésimo exemplo do conjunto de treinamento para os correspondentes valores das variáveis de entrada. Esta comparação é feita por meio da definição de um sinal de erro, representado pela Equação 5, a partir do qual é feita a alteração dos pesos sinápticos de forma iterativa, conforme mostrado esquematicamente na Figura 3.

$$e_k(i,n) = d_k(i) - y_k(i,n) \quad (5)$$

$e_k(i,n)$ – sinal de erro do neurônio $y_k(i,n)$ na iteração n ;

$y_k(i,n)$ – resposta calculada para o neurônio y_k na iteração n e variáveis de entrada existentes no i -ésimo exemplo do conjunto de treinamento;

$d_k(i)$ – saída desejada para as variáveis de entrada existentes no i -ésimo exemplo do conjunto de treinamento utilizadas no cálculo de y_k na iteração n .




Fig. 3 – Alteração dos pesos sinápticos pelo sinal de erro produzido no neurônio y_k .

A partir do cálculo dos sinais de erro em cada neurônio da camada de saída da rede, e considerando todos os exemplos existentes no conjunto de treinamento pode-se definir a seguinte função de custo média para avaliação e controle do processo de alteração dos pesos sinápticos em uma rede neural artificial:

$$E_{med}(n) = \frac{1}{2L} \sum_{i=1}^L \sum_{k \in C} e_k^2(i, n) = \frac{1}{2L} \sum_{i=1}^L \sum_{k \in C} [d_k(i) - y_k(i, n)]^2 \quad (6)$$

L – número de exemplos existentes no conjunto de treinamento;

i – índice que representa cada exemplo existente no conjunto de treinamento com variáveis de entrada e saída conhecidas;

C – conjunto de todos os neurônios da camada de saída no exemplo i do conjunto de treinamento;

n – passo de tempo discreto (época), correspondente a cada alteração do conjunto de pesos sinápticos no conjunto de treinamento.

O processo de treinamento de uma rede neural consiste nos ajustes sucessivos dos seus pesos sinápticos de forma a minimizar o valor da função de custo média em todo o conjunto de treinamento. Para um neurônio pertencente à camada de saída $y_k(i, n)$, o ajuste do vetor dos pesos sinápticos que o liga aos neurônios, ou nós, da camada anterior $\{y_j(i, n)\}$, é dado pela minimização da função de custo média de forma iterativa percorrendo-se todo o conjunto de treinamento (época). A Equação 7 apresenta a regra de alteração dos pesos sinápticos dos neurônios da camada de saída, também conhecida como Regra Delta.

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} - \eta \nabla E_{med}(n) = \{w_{kj}(n)\} + \frac{\eta}{L} \sum_{i=1}^L \delta_k(i, n) \{y_j(i, n)\} \quad (7)$$

$\{w_{kj}(n+1)\}$ – vetor de pesos sinápticos entre os neurônios k e j na iteração (época) n + 1;

$\{w_{kj}(n)\}$ – vetor de pesos sinápticos entre os neurônios k e j na iteração (época) n;

∇E_{med} – gradiente da função de custo média;

η – taxa de aprendizagem;

$\{y_j(i, n)\}$ – vetor de entrada do neurônio $y_k(i, n)$ no i-ésimo exemplo do conjunto de treinamento na iteração n;

$\delta_k(i, n)$ – gradiente local do neurônio $y_k(i, n)$, definido como:

$$\delta_k(i, n) = e_k(i, n) f'(v_k(i, n)) \quad (8)$$

$v_k(i, n)$ – campo local induzido do neurônio $y_k(i, n)$ no i-ésimo exemplo treinado na iteração n.

No caso de o neurônio pertencer a alguma camada oculta, o cálculo direto do gradiente local de acordo com a Equação 8 não é possível, uma vez que a resposta do neurônio não pode ser comparada a um valor conhecido, e, portanto, não pode gerar nenhum sinal de erro. Neste caso, o gradiente local do neurônio da camada oculta é determinado por meio da retropropagação do sinal de erro produzido nos neurônios da camada de saída $y_k(i, n)$. Tal procedimento é conhecido como

Algoritmo de Retropropagação do Erro (*Error Back-propagation*), e foi desenvolvido por Rumelhart *et al.* (1986). Utilizando o algoritmo de retropropagação do erro, o gradiente local de um neurônio pertencente a uma camada oculta imediatamente anterior à camada de saída é definido pela Equação 9.

$$\delta_j(i,n) = -\frac{1}{L} f'(v_j(i,n)) \sum_i \sum_{k \in C} \delta_k(i,n) \{w_{kj}(n)\} \quad (9)$$

Tendo-se em vista a grande dependência da convergência do algoritmo de retropropagação do erro ao valor da taxa de aprendizagem utilizada, Rumelhart *et al.* (1986) propuseram a introdução de um parâmetro α , conhecido como constante de momento, na Equação 7 com o objetivo de aumentar a estabilidade da convergência do algoritmo. Assim, a alteração dos pesos sinápticos pode ser feita a partir da aplicação da Equação 10, conhecida como Regra Delta Generalizada.

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} + \frac{\eta}{L} \sum_{i=1}^L \delta_k(i,n) \{y_k(i,n)\} + \alpha \{\Delta w_{kj}(n-1)\} \quad (10)$$

3 – DESENVOLVIMENTO DO MODELO NEURONAL

A seguir são apresentadas todas as etapas do desenvolvimento do modelo de previsão de recalques em fundações profundas utilizando redes neurais do tipo perceptron, as quais consistiram em: levantamento e coleta dos dados; definição das variáveis do modelo neuronal, tratamento dos dados levantados, e treinamento e validação do modelo.

3.1 – Levantamento de dados

De forma a se levar em conta o comportamento das estacas e os mecanismos de transferência de cargas entre a estaca e o solo circundante, no modelo neuronal foi inferido que o recalque total sofrido pela estaca sofre influência das características de resistência e deformabilidade dos materiais constituintes do subsolo e da estaca, e das características geométricas do elemento estrutural das estacas, como também da carga atuante no conjunto solo-estaca.

Para o desenvolvimento deste trabalho, foram levantados os resultados de provas de carga estáticas e ensaios SPT realizados em 199 estacas, sendo 103 do tipo hélice contínua, 67 metálicas e 29 escavadas. O conjunto de dados obtidos foi o mesmo utilizado nos trabalhos de Amâncio (2013), Dantas Neto *et al.* (2014) e Silveira (2014).

Todas as estacas utilizadas neste trabalho foram executadas em território brasileiro, sendo sua localização por região distribuída de acordo com a Figura 4. Convém salientar que algumas estacas (19,60%) não apresentavam informação quanto a sua localização. A grande distribuição espacial no território brasileiro das estacas utilizadas para o desenvolvimento do modelo neuronal proposto para a previsão de recalques indica a boa representatividade do modelo, uma vez que os dados utilizados contemplam condições geológico-geotécnicas variadas, como aquelas observadas nas diferentes regiões constituintes do território brasileiro.

As informações obtidas a partir das provas de carga estáticas realizadas foram: diâmetro e comprimento das estacas, e as curvas carga *vs.* recalque. Os ensaios SPT realizados nas estacas utilizadas neste estudo permitiram a obtenção da estratigrafia do subsolo e dos valores de N_{SPT} ao longo do fuste e na ponta das estacas.

A Figura 5 mostra a distribuição dos valores de todos os recalques medidos nas 199 estacas utilizadas para o desenvolvimento deste trabalho. Pode-se observar a partir das análises destes




Fig. 4 – Distribuição das estacas utilizadas pelas regiões do Brasil.

resultados que os valores dos recalques utilizados para a alimentação do modelo variam desde poucos milímetros, situações típicas nas quais os recalques ocorrem devido ao encurtamento elástico do elemento estrutural da estaca, até valores elevados, os quais correspondem a situações onde as provas de carga foram levadas até a completa ruptura do sistema solo-fundação.




Fig. 5 – Distribuição dos valores (em mm) dos recalques medidos para o conjunto de estacas utilizado.

3.2 – Definição das variáveis de entrada do modelo neuronal

Levando-se em consideração as variáveis que influenciam os recalques nas fundações profundas do tipo estaca e as informações levantadas nas provas de carga estáticas e ensaios SPT, o modelo neuronal de previsão de recalques em estacas pode ser representado, de uma forma geral, pela seguinte expressão:

$$\rho = f(T, L, D, NF, NP, d, Arg, Sil, Are, P) \quad (11)$$

ρ – recalque total, em milímetros;

T – tipo de estaca (Quadro 1);

L – comprimento da estaca, em metros;

D – diâmetro da estaca, em metros;

NF – soma dos valores de N_{SPT} ao longo do fuste;

NP – valor do N_{SPT} na profundidade de assentamento da ponta da estaca;

Arg, Sil, Are – fatores que levam em conta o tipo de solo no qual a estaca está executada;

P – carga vertical aplicada, em kN.

A variável T foi introduzida para levar em consideração a influência do processo de execução e as características particulares de cada tipo de estaca considerado no mecanismo de transferência de carga, e conseqüentemente, no valor do recalque gerado pelo modelo. O Quadro 1 apresenta os valores para a variável T utilizados durante o desenvolvimento do modelo neuronal de previsão de recalques em estacas.

Quadro 1 – Valores adotados para a variável T (tipo de estaca).

Tipo de estaca	T
Hélice contínua	1
Cravada metálica	2
Escavada	3

As variáveis L e D representam para o modelo neuronal a inércia do elemento estrutural da estaca. No caso das estacas metálicas cravadas com seção não circular (Figura 6), o diâmetro da estaca (D) foi obtido a partir da recomendação de Fleming *et al.* (2008), como sendo o valor equivalente à maior dimensão em planta do perfil metálico ($D = x_b$, se $x_b > y_w$, ou $D = y_w$, se $y_w > x_b$).




Fig. 6 – Seção transversal para as estacas metálicas com seção não-circular.

As variáveis NF e NP foram introduzidas para levar em consideração a influência da consistência (solos argilosos), ou compactidade (solos arenosos), dos solos nos recalques sofridos pela estaca quando submetida a uma carga vertical P. As variáveis NF e NP foram calculadas a partir dos resultados dos ensaios SPT de acordo com as expressões apresentadas nas Equações 12 e 13. Convém salientar que em todo o banco de dados levantados para o desenvolvimento do trabalho, foi adotado o valor máximo de 40 golpes/30 cm para o N_{SPT} .

$$NF = \sum N_{SPT, FUSTE} \quad (12)$$

$$NP = \sum N_{SPT, PONTA} \quad (13)$$

$N_{SPT, FUSTE}$ – valores de N_{SPT} ao longo do fuste da estaca;

$N_{SPT, PONTA}$ – valor de N_{SPT} na profundidade na qual a estaca encontra-se assentada.

A variável d foi definida como a distância entre a ponta da estaca e o topo da camada considerada rígida neste trabalho ($N_{SPT} = 40$ golpes/30 cm). Nos casos em que o ensaio SPT não foi realizado até se atingir o valor máximo para o N_{SPT} de 40 golpes/30 cm, o valor da variável d foi definido como sendo igual a duas vezes o valor do diâmetro da estaca, medido a partir da ponta da estaca. Este critério foi definido com base no conceito de bulbo de tensões apresentado pela Teoria da Elasticidade considerando um carregamento distribuído ao longo de uma área circular.

A influência da constituição das camadas do subsolo no qual a estaca encontra-se executada foi considerada no modelo neuronal a partir da consideração das variáveis Arg (solo argiloso), Sil (solo siltoso) e Are (solo arenoso). Aqui foi considerada a classificação táctil-visual apresentada nas sondagens a percussão, e não qualquer outra classificação, obtida a partir da realização de ensaios laboratoriais mais detalhados, como por exemplo, os ensaios de granulometria. Isto foi adotado porque reflete mais realisticamente o dia-a-dia da prática envolvida nos projetos de fundação no Brasil.

As Equações 14, 15 e 16, assim como o esquema mostrado na Figura 7, apresentam a forma de cálculo das variáveis Arg, Sil e Are a partir de um perfil de sondagem determinado em um ensaio SPT.

$$\text{Arg} = \frac{L_{\text{arg}}}{L} \quad (14)$$

$$\text{Sil} = \frac{L_{\text{silte}}}{L} \quad (15)$$

$$\text{Are} = \frac{L_{\text{areia}}}{L} \quad (16)$$

L_{arg} – comprimento do trecho do fuste da estaca no qual o solo circundante é classificado como solo argiloso no ensaio SPT;

L_{silte} – comprimento do trecho do fuste da estaca no qual o solo circundante é classificado como solo siltoso no ensaio SPT;

L_{areia} – comprimento do trecho do fuste da estaca no qual o solo circundante é classificado como solo arenoso no ensaio SPT.




Fig. 7 – Condição de contorno para definição das variáveis Arg, Sil e Are que representam a estratigrafia do solo.

3.3 – Tratamento dos dados levantados

Uma vez levantadas as informações necessárias para o desenvolvimento do modelo neuronal para previsão dos recalques em estacas, e definidas as variáveis de entrada do modelo, é necessário a escolha do algoritmo de treinamento, o qual permite utilizar os dados disponíveis a respeito do fenômeno estudado na alteração dos pesos sinápticos da RNA.

Neste trabalho foi utilizado o algoritmo de retropropagação do erro desenvolvido por Rumelhart *et al.* (1986) para a alteração dos pesos sinápticos dos perceptrons multicamadas utilizados para o desenvolvimento do modelo de previsão dos recalques em estacas. Para a função de ativação dos neurônios de todas as camadas foi adotada a função sigmóide definida pela Equação 17 e apresentada na Figura 8.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (17)$$




Fig. 8 – Função sigmóide.

Dentre todas as funções possíveis de se utilizar para a ativação dos neurônios, a função sigmóide tem demonstrado bom desempenho, e apresenta como principais vantagens ter como domínio o conjunto dos números reais, e ser contínua e diferenciável em todo o seu domínio, permitindo assim a aplicação da Regra Delta Generalizada para a alteração dos pesos sinápticos. Entretanto, o seu uso requer que os valores das variáveis de saída sejam normalizados em um intervalo que se situe dentro dos limites do conjunto imagem da função, no caso, o intervalo (0,1).

Neste trabalho, optou-se pela normalização tanto da variável de saída (recalque), como das variáveis de entrada apresentadas anteriormente. A normalização das variáveis de entrada e de saída foi feita entre 0,15 e 0,85 considerando uma relação linear entre os valores máximos (x_{\max}), mínimos (x_{\min}) e a variável normalizada (x_{nor}), utilizando-se a Equação 18. O Quadro 2 mostra os valores máximos e mínimos utilizados para a normalização das variáveis consideradas no estudo definidas a partir das informações existentes.

$$\frac{x_{\text{nor}} - 0,5}{0,85 - 0,15} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (18)$$

Quadro 2 – Valores máximos e mínimos utilizados na normalização das variáveis do modelo neuronal.

Valor	Variáveis de Entrada										Saída
	T	L (m)	D (m)	NF	NP	d (m)	Arg	Sil	Are	P (kN)	ρ (mm)
Máximo	3	60,00	1,70	990	40	4,00	1,00	1,00	1,00	16 653	189,4
Mínimo	1	3,00	0,08	6	2	0,00	0,00	0,00	0,00	0	0,00

3.4 – Treinamento e validação do modelo neuronal

A modelagem com redes neurais artificiais é feita em duas etapas, denominadas de etapa de treinamento e etapa de validação. Uma rede neural bem treinada é aquela capaz de generalizar o conhecimento adquirido durante o treinamento, ou seja, capaz de apresentar respostas satisfatórias para estímulos aos quais nunca foi submetida.

Na etapa de treinamento, os pesos sinápticos foram alterados utilizando-se a Regra Delta Generalizada e o Algoritmo de Retropropagação do Erro (Equação 9), sendo utilizados 80% dos exemplos entrada-saída escolhidos de forma aleatória dentro do conjunto de dados disponível. Os parâmetros de treinamento adotados foram $\alpha = 0,8$ (*momentum*) e $0,01 \leq \eta \leq 0,30$ (taxa de aprendizagem). Conforme citado anteriormente, α e η são parâmetros importantes na convergência do Algoritmo de Retropropagação do Erro. Os valores adotados neste trabalho foram os mesmos que os utilizados em trabalhos como Dantas Neto (2004), Amâncio (2013), Dantas Neto *et al.* (2014), comprovando assim que são suficientes para garantir uma convergência satisfatória do algoritmo de treinamento utilizado.

Na validação, os cálculos dos neurônios de saída foram feitos com os pesos sinápticos obtidos na fase de treinamento após um certo número de iterações, porém utilizando informações desconhecidas pela rede neural artificial durante o treinamento. Isto permite avaliar a capacidade de generalização da rede neural testada.

O treinamento e validação dos modelos analisados para as várias arquiteturas testadas foram feitos utilizando-se o programa QNET2000 (Dantas Neto, 2004). A avaliação da eficiência dos modelos nas fases de treinamento e validação foi feita por meio da determinação do coeficiente de correlação entre os resultados fornecidos pelo modelo e os dados de saída existentes nos conjuntos de treinamento e validação, definido de acordo com Bussab e Morettin (1987) como:

$$C(\rho_{cal}, \rho_m) = \frac{Cov(\rho_{cal}, \rho_m)}{\sigma(\rho_{cal}) \cdot \sigma(\rho_m)} \quad (19)$$

$Cov(\rho_{cal}, \rho_m)$ – covariância entre o recalque calculado e o recalque medido;

$\sigma(\rho_m)$ – desvio padrão dos recalques medidos;

$\sigma(\rho_{cal})$ – desvio padrão dos recalques calculados.

4 – APRESENTAÇÃO DOS RESULTADOS

4.1 – Modelo neuronal para previsão de recalques em estacas

O desenvolvimento do modelo neuronal para a previsão de recalques em estacas isoladas dos tipos hélice contínua, escavada e metálica consistiu na definição da arquitetura para a qual a rede neural artificial apresentasse o melhor desempenho, dado pelo coeficiente de correlação entre os recalques medidos existentes no conjunto de validação e os recalques calculados pelo modelo para as variáveis de entrada correspondentes. A Figura 9 ilustra a arquitetura do modelo neuronal que, dentre todos os testados, apresentou o melhor desempenho na fase de validação. De acordo com esta figura, o modelo neuronal é composto por 10 nós na camada de entrada; três camadas ocultas com 14, 8, 4 e 2 neurônios; e 1 neurônio na camada de saída que representa o valor normalizado para o recalque.

A Figura 10 mostra a curva de variação do coeficiente de treinamento (curva de treinamento) a partir da qual é possível se visualizar a convergência do Algoritmo de Retropropagação do Erro na fase de treinamento a partir de 3 000 000 iterações. Para o modelo neuronal desenvolvido para previsão de recalques em estacas, o coeficiente de correlação obtido nas fases de treinamento e validação foi de 0,94. A similaridade entre as curvas mostradas na Fig.10 indica que o subconjunto de dados utilizados para validar o modelo (fase de validação) apresentou a mesma variabilidade que aquela existente nos dados utilizados para o ajuste dos pesos sinápticos (fase de treinamento), indicando que o modelo apresenta uma representatividade satisfatória e boa capacidade de generalização do conhecimento adquirido durante o processo de aprendizagem/treinamento.

Analizando os resultados obtidos com o modelo neuronal utilizando os dados disponíveis no conjunto usado para a validação, observou-se que a Equação 11 deveria ser alterada com a inclusão de um fator de correção $\Delta\rho_0$, resultando na expressão representada pela Equação 20.

$$\rho = f(T, L, D, NF, NP, d, Arg, Sil, Are, P) + \Delta\rho_0 \quad (20)$$




Fig. 9 – Arquitetura do perceptron multicamadas desenvolvido para a previsão de recalques em estacas (A10:14:8:4:2:1).

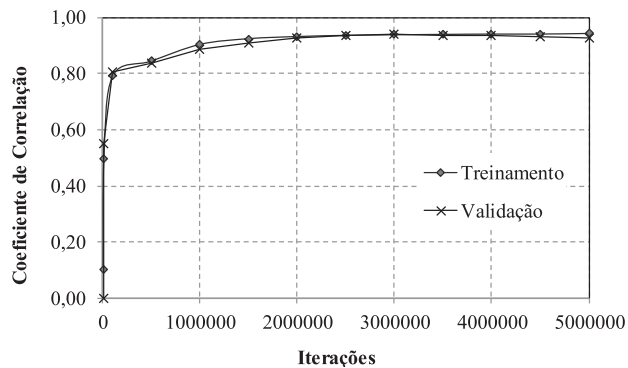


Fig. 10 – Evolução dos valores do coeficiente de correlação com o número de iterações (A10:14:8:4:2:1).

O fator de correção $\Delta\rho_0$ foi introduzido no modelo para levar em conta o fato que alguns valores de recalques obtidos com o modelo neuronal eram diferentes de zero nas situações em que as estacas não encontravam-se carregadas ($P = 0$). Convém salientar que uma das premissas do modelo é que há deformação da estaca com a atuação da carga, assim, foi necessário a introdução deste fator de correção, que corresponde ao recalque estimado pelo modelo quando o valor da variável P é igual a zero.

Os Quadros 3 a 7 mostram os valores dos pesos sinápticos e *bias* para os neurônios do modelo mostrado na Figura 9. De forma similar ao sistema nervoso central humano, os pesos sinápticos e *bias* são os parâmetros que contêm todo o aprendizado sobre um determinado fenômeno, ou tarefa. No caso específico, estes valores armazenam todo o conhecimento adquirido pelo modelo neuronal a partir das informações existentes no conjunto de treinamento, e uma mudança nos valores dos pesos sinápticos só ocorrerá obrigatoriamente se houver uma mudança no comportamento do parâmetro modelado em relação às suas variáveis de entrada. Esta é uma das vantagens importantes dos modelos neuronais desenvolvidos em engenharia, pois, uma vez que os valores dos pesos sinápticos e *bias* são definidos, o conhecimento sobre o fenômeno modelado encontra-se disponível ao uso, podendo ser modelado com o uso de simples planilhas de cálculo.

Os valores dos pesos sinápticos e *bias* apresentados nos Quadros 3 a 7 devem ser assim interpretados: o peso sináptico que conecta o Neurônio 1 da Camada Oculta 2 ao Neurônio 2 da Camada Oculta 1, denominado de w_{21} , é obtido no Quadro 4 e vale -4,082. O *bias* do Neurônio 1 da Camada Oculta 1, denominado de b_1 , é também obtido no Quadro 4 e vale -1,943.

Quadro 3 – Pesos sinápticos (w_{ki}) entre a Camada Oculta 1 e a Camada de Entrada e valores dos *bias* dos neurônios da Camada Oculta 1.

		Camada Oculta 1													
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
Camada de Entrada	T	4,641	-1,860	0,486	-0,868	-2,720	3,348	-2,184	4,579	2,120	1,024	0,796	-1,179	1,288	-1,635
	L	5,628	-1,305	-1,619	-4,186	3,992	-0,440	-10,234	3,173	1,193	7,162	6,390	1,995	-1,037	-1,803
	D	0,339	-2,168	-0,703	-2,959	1,958	-2,950	0,108	-2,699	1,994	-0,016	2,687	3,760	-1,354	0,591
	NF	2,896	1,764	-1,237	0,469	-4,031	-1,167	-2,036	2,483	1,523	14,340	-0,352	-0,901	-0,195	2,882
	NP	0,363	0,343	0,005	0,708	3,284	5,388	-3,207	-2,411	2,812	-3,566	0,294	2,266	0,572	-4,549
	d	-3,023	3,710	-1,683	0,571	1,319	3,481	-4,091	2,091	-1,667	2,332	0,676	3,662	-2,230	1,075
	Arg	-0,665	-1,826	1,320	3,567	-1,721	-4,595	1,081	-2,983	0,030	-7,131	-1,593	0,135	1,029	2,732
	Sil	2,393	0,866	0,012	-4,009	1,416	-1,012	1,455	1,466	-1,447	-2,839	-1,035	-2,491	-2,588	-0,962
	Are	3,376	-2,932	1,316	-1,008	4,581	1,070	0,961	4,936	0,360	2,377	0,210	-3,406	3,443	0,381
	P	-2,675	6,348	0,999	2,837	1,815	-0,560	5,268	-7,704	-0,188	-2,847	14,972	1,175	-1,157	-1,169
	b_k	-0,690	1,074	0,841	1,158	-0,560	-2,582	2,373	1,448	-0,935	2,228	-3,710	-2,235	1,031	0,517

Quadro 4 – Pesos sinápticos (w_{ki}) entre a Camada Oculta 2 e a Camada Oculta 1 e valores dos *bias* dos neurônios da Camada Oculta 2.

		Camada Oculta 2							
		1	2	3	4	5	6	7	8
Camada de Entrada 1	1	-2,944	-4,885	1,943	4,021	1,046	-2,086	1,482	3,292
	2	-4,082	5,097	-0,308	-2,358	-0,824	-2,047	-1,621	-2,108
	3	0,019	1,876	-0,115	1,600	0,109	-1,113	0,311	1,199
	4	1,394	2,310	0,231	-1,716	-0,564	-2,475	0,509	-2,700
	5	2,319	-0,389	-2,825	1,892	0,452	3,068	0,656	2,086
	6	1,674	-1,372	3,812	2,108	1,130	-3,179	-0,582	1,140
	7	6,294	2,180	-5,399	0,290	-0,767	5,664	-1,381	-1,386
	8	4,994	0,411	-3,812	0,078	-0,585	6,974	-2,808	-2,852
	9	0,619	-1,500	1,044	-1,312	0,353	3,597	-0,816	-1,831
	10	-9,145	-2,764	3,450	-1,677	0,302	-12,315	-1,048	-3,091
	11	5,628	10,981	-3,976	-0,425	0,681	6,635	1,705	4,889
	12	-4,441	-6,004	3,933	-3,216	-0,010	-0,049	1,359	0,470
	13	1,896	1,810	0,639	1,262	-0,092	0,787	1,035	-2,123
	14	-2,293	-2,755	0,620	2,374	-0,124	-5,043	0,613	0,373
b_k	-1,943	-1,931	0,335	-0,215	0,060	-0,449	-0,148	0,078	

Quadro 5 – Pesos sinápticos (w_{ki}) entre a Camada Oculta 3 e a Camada Oculta 2 e valores dos *bias* dos neurônios da Camada Oculta 3.

		Camada Oculta 3			
		1	2	3	4
Camada de Entrada 2	1	0,820	11,597	1,974	5,455
	2	12,113	2,012	-3,317	1,886
	3	-2,224	-7,522	-0,856	-8,531
	4	-7,851	-1,166	0,556	0,259
	5	-2,272	-1,964	0,178	-1,980
	6	9,665	6,099	1,298	7,603
	7	-3,818	-3,384	-0,212	-0,054
	8	-7,769	-2,707	0,072	0,639
	b_k	-0,680	-3,740	2,172	-2,944

Quadro 6 – Pesos sinápticos (w_{ki}) entre a Camada Oculta 4 e a Camada Oculta 3 e valores dos *bias* dos neurônios da Camada Oculta 4.

		Camada Oculta 4	
		1	2
Camada de Entrada 3	1	0,257	-12,396
	2	-12,526	4,364
	3	0,567	4,324
	4	-6,900	7,329
	b_k	10,474	2,723

Quadro 7 – Pesos sinápticos (w_{ki}) entre a Camada de Saída e a Camada Oculta 4 e valor do *bias* do neurônios da Camada de Saída.

		Camada de Saída
		ρ
Camada Oculta 4	1	-3,657
	2	-6,352
	b_k	8,276

De acordo com a formulação apresentada anteriormente, e conhecendo-se os valores dos pesos sinápticos e *bias*, a implementação do modelo neuronal para previsão de recalques em estacas hélice contínua, escavada e metálica pode ser feita a partir dos seguintes passos:

- a) Obtenção dos resultados do ensaio SPT realizado no subsolo onde será executada a estaca para as definições dos valores de NF (Eq. 12), NP (Eq. 13), Arg (Eq 14), Sil (Eq. 15), Are (Eq. 16) e d;
- b) Definição da geometria da estaca e tipo (D, L e T);
- c) Adotar $P = 0$ para a definição do valor do fator de correção $\Delta\rho_0$;
- d) Normalização dos valores das variáveis de entrada (T, L, NF, NP, d, Arg, Sil, Are e P) utilizando a Equação 18 e os valores apresentados no Quadro 2;
- e) Cálculo dos sinais dos neurônios do modelo desde a primeira camada intermediária até a camada de saída, utilizando os valores dos pesos sinápticos apresentados nos Quadros 3, 4, 5, 6 e 7;
- f) Transformação do valor calculado para o recalque na escala de normalização utilizada para a sua escala real, utilizando a Equação 18 e os valores máximos e mínimos para o recalque apresentados no Quadro 2;
- g) O valor obtido para o recalque considerando a carga P igual a zero, deve ser adotado como o fator de correção $\Delta\rho_0$;
- h) Repetir os passos entre os itens “a” e “f” para o cálculo do valor do recalque para qualquer valor da carga P diferente de zero, aplicando-se, posteriormente, o fator de correção obtido no item “g”.

4.2 – Aplicação do modelo neuronal para previsão de recalques

O procedimento descrito anteriormente para a aplicação do modelo neuronal de previsão de recalques pode ser usado para a definição de todos os pontos da curva carga vs. recalque de qualquer um dos tipos de estaca considerados neste trabalho (estaca hélice contínua, estaca escavada e estaca metálica).

Para a exemplificação de aplicação do modelo representado na Figura 9 foi considerada uma estaca hélice contínua, com diâmetro igual a 600 mm, comprimento igual a 15,36 m, instalada em um solo cuja estratigrafia e resultados do ensaio SPT são mostrados na Figura 11. Convém salientar que a estaca considerada para a exemplificação da aplicação do modelo neuronal não fazia parte dos dados utilizados no treinamento e validação citados anteriormente.

Considerando as condições de contorno apresentadas na Figura 11 e as definições apresentadas anteriormente, os valores das variáveis de entrada para o modelo neuronal são: $T = 1$, $L = 15,36$ m, $D = 0,6$ m, $NF = 210$, $NP = 40$, $d = 0$ m, $Arg = 0$, $Sil = 0$, $Are = 1,0$, e $P = a$ definir. A Equação 21 ilustra o processo de normalização para a variável de entrada T (tipo de estaca) de acordo com a Equação 18 e informações apresentadas no Quadro 2. O Quadro 8 mostra todas as variáveis de entrada normalizadas de forma semelhante ao que foi feito para a variável T.

$$T_{nor} = (0,85 - 0,15) \frac{1 - 1}{3 - 1} + 0,15 = 0,15 \quad (21)$$

Quadro 8 – Variáveis de entrada normalizadas.

T_{nor}	L_{nor}	D_{nor}	NF_{nor}	NP_{nor}	d_{nor}	Arg_{nor}	Sil_{nor}	Are_{nor}	P_{nor}
0,150	0,302	0,375	0,295	0,850	0,150	0,150	0,150	0,850	0,150




Fig. 11 – Condições de contorno para aplicação do modelo neuronal de previsão de recalques em uma estaca hélice contínua.

Um exemplo de cálculo do valor do neurônio da saída para $P = 0$ pode ser feito seguindo-se o passo-a-passo descrito anteriormente. O primeiro neurônio da primeira camada oculta é calculado utilizando-se as Equações 22, 23 e 24 com os valores dos pesos sinápticos e *bias* apresentados na primeira coluna do Quadro 3, e das variáveis de entrada normalizadas apresentados no Quadro 8, considerando $P_{nor} = 0,15$.

$$u_1 = 4,641 \times 0,15 + 5,628 \times 0,302 + 0,339 \times 0,375 + 2,896 \times 0,295 + 0,363 \times 0,85 - 3,023 \times 0,15 - 0,665 \times 0,15 + 2,393 \times 0,15 + 3,376 \times 0,85 - 2,675 \times 0,15 = 5,96 \quad (22)$$

$$v_1 = u_1 + b_1 = 5,96 - 0,69 = 5,27 \quad (23)$$

$$y_1 = f(v_1) = \frac{1}{1 + e^{-5,27}} = 0,995 \quad (24)$$

No Quadro 9 são apresentados os valores de todos os neurônios obtidos de forma semelhante ao que foi exemplificado nas Equações 22, 23 e 24 para o valor da carga $P = 0$. O valor na escala real do neurônio que representa o recalque (ρ) na estaca, o qual deve ser tomado como o fator de correção $\Delta\rho_0$, é calculado em função do valor da variável de saída normalizada ($\rho_{nor} = 0,1515$) utilizando-se a Equação 25.

$$\rho = \frac{0,1515 - 0,15}{0,85 - 0,15} (189,4 - 0) + 0,00 = 0,41 \text{ mm} \quad (25)$$

Quadro 9 – Valores dos neurônios obtidos para a carga $P = 0$.

Camadas	Ocultas				Saída
	1ª	2ª	3ª	4ª	
y_1	0,995	0,468	0,019	1,000	0,1515
y_2	0,326	0,740	0,006	0,998	-
y_3	0,734	0,739	0,793	-	-
y_4	0,266	0,992	0,061	-	-
y_5	0,999	0,932	-	-	-
y_6	0,806	0,501	-	-	-
y_7	0,049	0,367	-	-	-
y_8	0,980	0,579	-	-	-
y_9	0,959	-	-	-	-
y_{10}	0,998	-	-	-	-
y_{11}	0,835	-	-	-	-
y_{12}	0,220	-	-	-	-
y_{13}	0,953	-	-	-	-
y_{14}	0,076	-	-	-	-

A Figura 12 mostra as curvas carga vertical vs. recalque obtidas a partir da previsão dos recalques para a estaca apresentada na Figura 11 por três modelos desenvolvidos a partir do emprego das redes neurais artificiais: o modelo proposto, e os modelos propostos por Dantas Neto *et al.* (2014) e Amâncio (2013). Esta comparação mostra que apesar de apresentar valores semelhantes para as correlações entre os recalques calculados e os recalques reais para o exemplos do conjunto de treinamento, o modelo proposto neste trabalho representou melhor o comportamento da estaca considerada do que os modelos propostos por Dantas Neto *et al.* (2014) e Amâncio (2013).

Convém salientar que as principais diferenças entre o modelo proposto neste trabalho e os modelos de Dantas Neto *et al.* (2014) e Amâncio (2013) são a consideração da estratigrafia do solo, representada pelas variáveis Arg, Sil e Are, e a adoção da variável d , que representa a espessura da camada deformável abaixo da ponta da estaca. A esta inclusão é que deve ser atribuída a melhoria do comportamento do modelo neuronal apresentado neste trabalho em relação àqueles citados anteriormente.

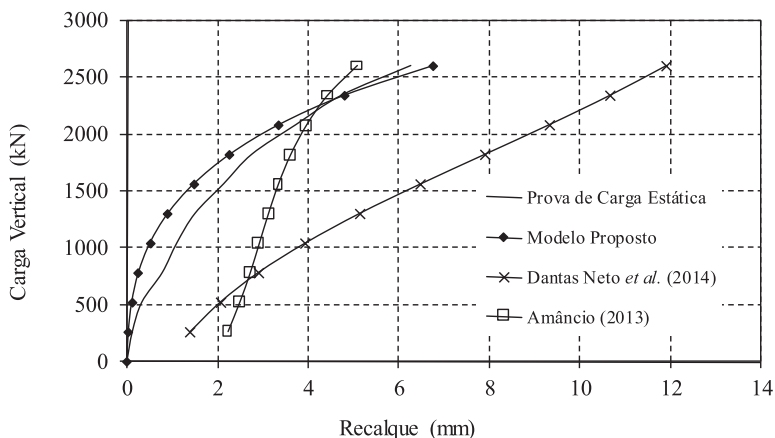


Fig. 12 – Comparação da curva carga vs. recalque real com aquelas obtidas a partir da modelagem com RNA.

5 – CONCLUSÕES

Os resultados obtidos permitem confirmar que as redes neurais artificiais do tipo perceptron apresentam um grande potencial quando utilizadas para a previsão de fenômenos complexos, multivariados, e não-lineares, especificamente, no caso deste trabalho, que trata da previsão de recalques em fundações do tipo estaca.

O modelo proposto deve ser apenas aplicado à previsão de recalques em estacas do tipo hélice contínua, escavada, e metálica. A arquitetura para a qual o modelo teve o melhor desempenho foi aquela formada por 10 nós na camada de entrada, 14 neurônios na primeira camada oculta, 8 neurônios na segunda camada oculta, 4 neurônios na terceira camada oculta, 2 neurônios na quarta camada oculta, e o neurônio na camada de saída que representa o recalque estimado. O coeficiente de correlação entre os valores dos recalques reais e dos recalques estimados pelo modelo para os dados existentes no conjunto de validação foi de 0,94, valor este que pode ser considerado muito satisfatório.

A definição do número de camadas ocultas é um processo de tentativa e erro, sendo definido levando-se em consideração que quanto maior a complexidade do fenômeno estudado mais complexa torna-se a estrutura da rede, portanto, maior tem que ser o número de camadas ocultas. Entretanto, o aumento indiscriminado do número de camadas, além do número de neurônios nestas camadas, além de prejudicar o processo de convergência do algoritmo de treinamento, aumentar o tempo computacional, pode ainda prejudicar a capacidade de generalização do conhecimento pela rede, razão pela qual deve sempre ser feito o processo de validação para cada arquitetura estudada, e para cada determinado número de iterações.

Da forma como foi apresentado, o modelo neuronal de previsão de recalques apresenta grande aplicabilidade na Engenharia de Fundações, pois pode ser utilizado para a estimativa dos recalques para diferentes cargas atuantes, permitindo assim a definição completa da curva carga recalque para os tipos de estacas considerados. Do ponto de vista teórico, pode-se considerar que o modelo neuronal proposto para a previsão dos recalques apresenta como variáveis de entrada muitos dos fatores que influenciam os recalques nos elementos de fundação profunda, tais como, a inércia do elemento estrutural da estaca, a compactidade ou consistência dos solos expressas pelos valores obtidos do N_{SPT} ao longo do fuste e na ponta da estaca, a estratigrafia do solo no qual a estaca está inserida, etc..

Dentre as principais vantagens para o desenvolvimento do modelo de previsão de recalques com a utilização das redes neurais artificiais podem ser citadas: o modelo usa como variáveis de entrada informações facilmente disponíveis na prática da Engenharia de Fundações; uma vez obtidos os pesos sinápticos e *bias*, o modelo pode ser facilmente implementado em simples planilhas de cálculo.

De uma forma geral, pode-se considerar que o modelo desenvolvido com o uso das redes neurais artificiais do tipo perceptron para previsão de recalques em estacas do tipo hélice contínua, escavadas e metálicas apresenta uma ótima performance, e pode, portanto, ser utilizado na prática da Engenharia de Fundações. Da forma como o modelo opera, pode-se inclusive obter capacidade de carga da estaca, a partir do conhecimento completo da curva carga *vs.* recalque do sistema solo-estaca.

6 – REFERÊNCIAS BIBLIOGRÁFICAS

- Anjos, G.J.M. (2006). *Estudo do Comportamento de Fundações Escavadas em Solos Tropicais*. Tese de Doutorado. Publicação G.TD/033/06, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 341p.
- Amâncio, L.B. (2013). *Previsão de recalques em fundações profundas utilizando redes neurais artificiais do tipo perceptron*. Dissertação de Mestrado em Engenharia Civil, Universidade Federal do Ceará, Fortaleza, Brasil. 90p.
- Bussab, W.O.; Morettin, P.A. (1987). *Estatística Básica*. Atual, 4ª ed. São Paulo, Brasil, 150p.
- Cintra, J.C.A.; Aoki, N. (2010). *Fundações por estacas: projeto geotécnico*. Ed. Oficina de Textos. São Paulo, SP, Brasil.
- Dantas Neto, S.A. (2004). *Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificados com Borracha Granulada de Pneus Usados*. Tese (Doutorado em Geotecnia), Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 265p.
- Dantas Neto, S.A.; Silveira, M.V.; Amâncio, L.B.; Anjos, G.M. (2014). *Pile Settlement Modeling with Multilayer Perceptrons*. Electronic Journal of Geotechnical Engineering, v. 19, pp. 4517-4528. <http://www.ejge.com/2014/Ppr2014.426ma.pdf>
- Fleming, W.G.K.; Weltman, A.J.; Randolph, M.F.; Elson, W.K. (2008). *Piling Engineering*. Third Edition. Taylor & Francis e-Library, 408p.
- Haykin S. (2001). *Redes Neurais: princípios e prática*. 2ª. ed. Porto Alegre: Bookman, 900p.
- Poulos, G.H.; Davis, E.H. (1980). *Pile Foundation Analysis and Design*, Wiley and Sons, New York, USA, 397p.
- Randolph, M.F.; Wroth, C. (1978). *Analysis of Deformation of Vertically Loaded Piles*, JGED, ASCE, 104 (GT12), pp. 1465-1488.
- Rumelhart, D.E.; Hinton, G.E.; Williams, R.J. (1986). *Learning Internal Representations of Back-Propagation Error*. Nature, v. 323, pp. 533-536.
- Silveira, M.V. (2014). *Modelo Neuronal para Previsão de Recalques em Estacas Hélice Contínua, Metálica, e Escavada*. Dissertação de Mestrado. Programa de Pós-graduação em Engenharia Civil. Departamento de Engenharia Hidráulica e Ambiental. Universidade Federal do Ceará. Fortaleza, Brasil. 107p.