

Estimativa de Recalque em Estacas Utilizando Redes Neurais Artificiais

Carla Beatriz Costa de Araújo

Universidade Federal do Ceará, Fortaleza, Brasil, carlabeatriz7@gmail.com

Silvrano Adonias Dantas Neto

Universidade Federal do Ceará, Fortaleza, Brasil, silvrano@gmail.com

Gérson Jacques Miranda dos Anjos

Universidade Federal do Pará, Belém, Brasil, mirandadosanjos@gmail.com

RESUMO: As redes neurais artificiais (RNA) vem sendo empregadas com eficiência na estimativa de recalques em fundações profundas. Nos trabalhos de Amâncio (2013), Silveira (2014) e Dantas Neto et. al (2014) os modelos desenvolvidos com a utilização das RNA apresentaram melhora na previsão de recalques em estacas hélice contínua, cravadas metálicas e estacas escavadas. Este trabalho tem por objetivo o desenvolvimento de modelo de previsão de recalques em estacas desenvolvido a partir da utilização das RNA que consiste num aprimoramento dos modelos apresentados pelos autores citados anteriormente. As variáveis de entrada consideradas para o modelo neuronal de estimativa de recalques foram: o tipo de estaca (T), comprimento (L) e diâmetro (D) da estaca; o somatório do N_{SPT} ao longo do fuste da estaca (NF); o valor do N_{SPT} na base da estaca (NP); a profundidade (d) da camada de solo abaixo da base da estaca que sofre influência do carregamento aplicado, e os três fatores representativos da estratigrafia do solo ao longo do fuste da estaca, definidos como fator representativo das camadas de solo argiloso (Arg), o fator representativo das camadas de solo siltoso (Sil), o fator representativo das camadas de solo arenoso (Ar); e por fim, a carga aplicada (P). O modelo apresentado neste trabalho possui uma arquitetura A:10-12-8-6-4-1. A modelagem com redes neurais foi feita com auxílio do programa QNET2000. O modelo de previsão descrito apresenta os coeficientes de correlação (R) entre os recalques reais e os recalques estimados de 0,99 na fase de treinamento, e 0,96 na fase de validação.

PALAVRAS-CHAVE: Recalque, Estacas, Redes Neurais Artificiais.

1 INTRODUÇÃO

A estimativa dos recalques em fundações profundas é um problema complexo e multivariado, pois muitas são as incertezas associadas aos fatores que afetam este fenômeno. Segundo Nejad et. al (2009), esses fatores incluem a distribuição da carga em profundidade (diagrama de transferência), o histórico de tensão-deformação. Ainda é difícil e trabalhosa a obtenção de parâmetros de resistência e de deformabilidade do solo.

Segundo Velloso & Lopes (2011), a previsão do recalque é um dos exercícios mais difíceis da Geotecnia e os resultados dos cálculos, por mais

sofisticados que sejam, devem ser encarados como uma estimativa.

O fenômeno do recalque em estacas caracteriza-se como um problema complexo, não-linear, envolvendo diversas variáveis. As redes neurais artificiais são comprovadamente ferramentas poderosas para resolução deste tipo de problema. Após a realização do treinamento e da validação, a aplicação de um modelo utilizando redes neurais é simples e rápida. Dada sua capacidade de generalização e fácil aplicação, as RNA vem sendo utilizadas na resolução de problemas complexos na área da Engenharia, inclusive a Geotecnia.

Considerando a importância e a dificuldade

da previsão de recalques em fundações profundas, as redes neurais artificiais (RNA) surgem como uma alternativa para o desenvolvimento de modelos que possam prever com grau de precisão adequado a magnitude dos deslocamentos gerados pela aplicação de uma carga no sistema estaca-solo.

2 REVISÃO BIBLIOGRÁFICA

2.1 Redes Neurais Artificiais

As redes neurais artificiais, segundo Haykin (2001), 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 o uso. Frente aos procedimentos estatísticos usuais, as redes neurais artificiais não apresentam um conjunto de coeficientes, ou parâmetros, apesar de estes serem incluídos no modelo (Dantas Neto, 2004).

O desenvolvimento das redes neurais artificiais foi motivado pela grande capacidade do cérebro humano aprender e realizar tarefas extremamente complexas após passar por algum processo de aprendizagem. O cérebro humano, principal unidade do sistema nervoso central, é um sistema de processamento de informações altamente complexo, não-linear e paralelo formado por um conjunto de unidades fundamentais, os neurônios, organizadas de tal forma a realizar certos processamentos muito mais rápidos que qualquer computador digital atualmente conhecido. O neurônio biológico é formado basicamente por três partes distintas, conforme ilustrado na Figura 1, o corpo celular (soma), o axônio, e os dendritos (HAYKIN, 2001).

O corpo celular ou soma é o responsável pelo processamento das informações que chegam ao neurônio na forma de pulsos elétricos e pela produção da resposta a estes estímulos externos, também como um pulso elétrico. Os dendritos são as estruturas do neurônio responsáveis pelo recebimento dos pulsos elétricos e o axônio é o responsável pela emissão do pulso elétrico produzido pelo neurônio às demais células nervosas com as quais este encontra-se

conectado (HAYKIN, 2001).




Figura 1. Neurônio Biológico, Araújo (2013)

O funcionamento do neurônio artificial se dá de forma análoga ao neurônio biológico. Segundo Haykin (2001) um neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma rede neural. A Figura 2 consiste na representação do neurônio artificial com a apresentação de todos os seus elementos. No modelo neuronal podem ser identificados os seguintes elementos básicos (HAYKIN, 2001):




Figura 2. Neurônio Artificial, Araújo (2013)

- Conjunto de sinapses ou elos de conexão (w_{kj}) – funcionam analogamente às sinapses do neurônio artificial, responsáveis pela armazenagem da informação e modificadas de acordo com o processo de aprendizagem da rede;
- Bias ou limiar (b_k) – o bias é análogo ao limiar no neurônio biológico e tem a função de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo;
- Combinador linear – representa a contribuição de todos os sinais de entrada ponderados pelos respectivos pesos sinápticos;
- Função de ativação – representa o sinal de saída, ou a resposta do neurônio, sendo aplicada ao combinador linear com a função de restringir a amplitude de saída do neurônio.

As funções de ativação podem ser quaisquer funções matemáticas. De uma forma

geral são normalmente utilizadas as seguintes funções de ativação: linear, linear por partes, sigmoide, tangente hiperbólica

Em termos matemáticos, o neurônio k pode ser representado pelas seguintes equações:

$$u_k = \sum w_{ki} x_i = \{w\}^T \{x\} \quad (1)$$

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

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

Onde:

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;

$\{x\} = [x_1, x_2, x_3, \dots, x_m]$ = sinais de entrada;

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

2.2 Fundações do Tipo Estacas

Segundo a NBR 6122/2010, as fundações profundas são aquelas que transmitem a carga ao terreno, ou pela base (resistência de ponta), ou por sua superfície lateral (resistência de fuste), ou por uma combinação das duas. Sua ponta ou base está implantada a uma profundidade superior ao dobro da sua menor dimensão em planta, e no mínimo a 3m.

As estacas são elementos de fundação profunda executadas inteiramente por equipamentos ou ferramentas, sem que, em qualquer fase de sua execução, haja descida de operário (NBR 6122/2010).

Para o projeto de uma fundação profunda em estacas é necessário fazer a previsão tanto da capacidade de carga última (ou carga limite), quanto dos recalques (Benegas, 1993; Velloso & Lopes, 2010). Anjos (2006) comenta que a maioria dos projetos de fundações profundas é feita avaliando apenas a capacidade de suporte das fundações por métodos empíricos ou semi-empíricos, ou seja, ainda persiste a total indiferença quanto ao cálculo de recalques e a transferência de carga.

2.3 Aplicações das “RNAs” na Estimativa de Recalques

Existem muitos métodos na literatura geotécnica, teórica e experimental, para prever recalques em fundações profundas. Devido à dificuldade de obtenção de amostras indeformadas para determinação de parâmetros, como Módulo de Elasticidade (E) e coeficiente de Poisson (ν), muitos métodos de previsão se concentraram em correlações com ensaios *in situ*, como a sondagem à percussão do tipo SPT (NEJAD et. al, 2009).

As RNAs não são uma ferramenta substitutiva das ferramentas computacionais tradicionais, elas podem ser consideradas como ferramenta complementar a estas. Muitos pesquisadores estão utilizando sistemas híbridos que integram RNA com sistemas especialistas ou códigos de elementos finitos, de tal forma a potencializar as vantagens de cada um dos métodos (MARTÍNEZ-CARVAJAL, 2006).

Nejad et. al (2009), Amâncio (2013) e Silveira (2014), Dantas Neto et. al (2014) utilizaram as RNA para previsão do comportamento de estacas quando sujeitas a carregamentos, de forma a realizar a previsão da curva carga x recalque.

Nejad et. al (2009) empregaram as redes neurais para estimar o recalque em estacas, a partir de dados do ensaio de sondagem à percussão (SPT). O banco de dados era composto por 1.013 registros de casos de medições de campo, referentes a 76 estacas isoladas executadas em diversos países (Irã, Suécia, Estados Unidos, etc.). Neste trabalho foi obtida uma correlação entre os valores reais e os valores modelados na validação de 0,972.

Amâncio (2013) e Silveira (2014), Dantas Neto et. al (2014) utilizaram o mesmo conjunto de dados composto por registros de casos de medição de campo referentes a 199 estacas isoladas. Para modelagem foram coletadas informações dos ensaios de sondagem à percussão (SPT) e provas de cargas estáticas. As correlações entre os valores reais e os valores modelados na validação para os diferentes modelos variaram 0,89 e 0,94.

3 METODOLOGIA

3.1 Obtenção dos dados

Para desenvolvimento do modelo foram utilizados os dados referentes aos resultados de sondagens à percussão e provas de carga estáticas de 141 estacas retiradas do banco de dados utilizadas por Amâncio (2013), Silveira (2014) e Dantas Neto et. al (2014).

Segundo Amâncio (2013), algumas das provas de carga estáticas foram executadas com finalidades exclusivamente acadêmicas, e outros ensaios foram realizados para acompanhar o desempenho da fundação projetada. Nestas provas de carga não havia como saber a sua forma de execução (lenta, rápida ou mista). O conjunto de dados que possui 1.320 exemplos do tipo entrada-saída (cada entrada corresponde a um incremento de carga e seu respectivo valor de recalque obtido).

3.2 Definição das variáveis de entrada

Tomando por base o trabalho de Silveira (2014), foram utilizadas as seguintes variáveis de entrada do modelo:

- T = tipo de estaca;
- L = comprimento da estaca (m);
- D = diâmetro da estaca (m);
- NF = somatório de N_{SPT} ao longo do fuste da estaca (golpes/30cm);
- NP = N_{SPT} próximo à base da estaca (golpes/30cm);
- d = profundidade da camada de influência da carga em relação a ponta da estaca (m);
- Arg = fator representativo das camadas de solo argiloso ao longo do comprimento da estaca (m/m); conforme Figura 4.
- Sil = fator representativo das camadas de solo siltoso ao longo do comprimento da estaca (m/m); conforme Figura 4.
- Ar = fator representativo das camadas de solo arenoso ao longo do comprimento da estaca (m/m); conforme Figura 4.
- P = carga aplicada na estaca (kN).

Conforme indicado na Tabela 1, para o desenvolvimento dos modelos, as variáveis de entrada T, L, D e P foram obtidas nas provas de

carga estáticas, e as variáveis NF, NP, d, Arg, Sil e Ar foram obtidas através de sondagens à percussão SPT, e a variável de saída ρ (recalque) nas provas de carga estáticas avaliadas neste estudo.

Tabela 1. Variáveis do modelo.

Variável	Tipo	Aquisição
T	Entrada	Prova de Carga Estática
L		Prova de Carga Estática
D		Prova de Carga Estática
NF		Sondagem à Percussão
NP		Sondagem à Percussão
d		Sondagem à Percussão
Arg		Sondagem à Percussão
Sil		Sondagem à Percussão
Ar		Sondagem à Percussão
P		Prova de Carga Estática
ρ	Saída	Prova de Carga Estática

Para a variável T foram determinados os valores apresentados na Tabela 2, que variam conforme o tipo da estaca.

Tabela 2. Variável T

Tipo de estaca (T)	Valor
Hélice Contínua	1
Cravada Metálica	2
Escavada	3

Para as estacas cravadas metálicas que não possuíam seção circular, foi calculado o diâmetro equivalente segundo a Equação 4.

$$D = \sqrt{\frac{4A \cdot B}{\pi}} \quad (4)$$

Onde:

D= diâmetro equivalente;

A e B = dimensões da seção do perfil (Figura 3)




Figura 3. Seção transversal para estacas cravadas metálicas. Araújo (2015)

O índice de resistência penetração (N_{SPT}) obtido através da sondagem a percussão é

utilizado para definir NF e NP, e leva em consideração a compactidade/consistência do solo, que influenciam diretamente os recalques sofridos pelo solo quando submetido a uma carga. A variável NF é determinada segundo a Equação 5 (que é o somatório dos valores de N_{spt} ao longo do fuste e desconsiderando os valores próximos à base da estaca)

$$NF = \sum N_{SPT} - NP \quad (5)$$

Onde:

N_{SPT} = índice de resistência à penetração ao longo fuste, em golpes/30 cm;

NP = valor de N_{SPT} na base estaca.

A variável de entrada d, definida como sendo a profundidade do bulbo de tensões devido ao carregamento aplicado na base da estaca, adotado como igual a 2 vezes o diâmetro da estaca, ou a distância entre a base da estaca e a camada incompressível, no caso de o bulbo de tensões ultrapassar o limite da camada incompressível. Neste trabalho foi utilizado o critério de Niyama et al. (1998) para definição da profundidade do bulbo de tensões como sendo igual a 2 vezes o valor do diâmetro da estaca.

Os valores das variáveis Arg, Sil e Ar foram determinados analisando os relatórios de sondagem à percussão e verificando a estratigrafia do solo ao longo do fuste da estaca (Figura 4), utilizando as Equações 6, 7 e 8.




Figura 4. Estratigrafia do solo. Araújo (2015)

$$Arg = \frac{\sum L_{argila}}{L} \quad (6)$$

$$Sil = \frac{\sum L_{silte}}{L} \quad (7)$$

$$Ar = \frac{\sum L_{areia}}{L} \quad (8)$$

3.3 Normalização das Variáveis do Modelo

Para o desenvolvimento dos modelos com as RNA foi necessária a normalização dos dados utilizados. Esta normalização é essencial, uma vez que as diferentes funções de ativação que calculam os neurônios fornecem valores dentro de um intervalo.

Os valores dos dados de entrada e saída apresentados na Tabela 3 foram normalizados entre (0,15 e 0,85), considerando-se uma relação linear entre os valores de máximos e mínimos de cada uma das variáveis envolvidas utilizando a Equação 9.

Tabela 3. Valores máximos e mínimos

	Variáveis de entrada										Saída
	T	L	D	NF	NP	d	Arg	Sil	Ar	P	ρ
Máximo	3	33	1,2	455	40	2,4	1	1	1	9.250	189,4
Mínimo	1	3	0,1	12	3	0	0	0	0	0	0

$$\frac{X' - 0,15}{0,85 - 0,15} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

Onde:

X' = variável resultante da normalização;

X = variável a ser normalizada;

$X_{\min}$ = valor mínimo da variável a ser normalizada;

$X_{\max}$ = valor máximo da variável a ser normalizada.

3.4 Modelagem com as RNA

Para o desenvolvimento do modelo de previsão de recalques empregando-se como ferramenta as RNA, foi utilizado o software QNET 2000. Independente do software adotado, algumas decisões são muito importantes na modelagem com as RNA: a escolha do algoritmo, a função de ativação, a arquitetura e ainda, os parâmetros de treinamento da rede.

A escolha da função é feita por tentativa e erro, desta forma, a que fornecer melhores resultados será a utilizada (DANTAS NETO, 2004). A função sigmóide é uma das funções de ativação mais comuns, sendo adotada para desenvolver o modelo de previsão deste trabalho. Esta função é definida como:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

Para a fase de treinamento é necessária a escolha de dois parâmetros: η (taxa de aprendizagem) e o fator α ("momentum"). Estes parâmetros controlam o algoritmo de retropropagação no ajuste dos pesos sinápticos (w_{kj}). Neste trabalho foram adotados os valores de 0,8 para o fator α e taxa de aprendizagem η variando entre 0,001 e 0,15.

3.4 Etapas da Modelagem e Definição do Modelo

O conjunto final utilizado nas fases de treinamento e validação totalizou 1.320 exemplos do tipo entrada-saída. Para fazer uso dos dados obtidos, foi necessária a preparação destes para a utilização no treinamento e validação. Foram separados aleatoriamente 80% dos dados para fase de treinamento e 20% para a fase de validação.

A definição da arquitetura que melhor representou o modelo, foi feita a partir dos resultados obtidos, escolhendo-se a rede que apresentou maior R (coeficiente de correlação). O coeficiente de correlação é calculado a partir da Equação 11 (BUSSAB & MORETTIN, 1987):

$$R = \left(\frac{Cov(X,Y)}{DP(X)DP(Y)} \right) \quad (11)$$

Onde:

$Cov(X,Y)$ = covariância entre duas variáveis aleatórias X e Y;

$DP(X)$ = desvio padrão de X;

$DP(Y)$ = desvio padrão de Y.

4 RESULTADOS

O modelo elaborado pode ser obtido na forma simplificada, representado como (Equação 12)

onde o recalque é função dos distintos dados de entrada conforme abaixo:

$$\rho = f(T, L, D, NF, NP, d, Arg, Sil, Ar, P) \quad (12)$$

Foram testadas diversas arquiteturas, dentre as que apresentaram melhores resultados está a arquitetura A:10-12-8-6-4-1 (Figura 5), com dez nós na camada de entrada, doze neurônios na primeira camada oculta, oito neurônios na segunda camada oculta, seis neurônios na terceira camada oculta, quatro neurônios na quarta camada oculta e um neurônio na camada de saída, sendo o modelo apresentado neste trabalho.

O maior valor para o coeficiente de correlação obtido para o modelo final foi de 0,99 para o treinamento e 0,96 para a validação, resultado para $2,5 \cdot 10^6$ iterações.

Na Figura 6 é apresentada a comparação entre os recalques obtidos através do modelo final e os recalques reais das provas de carga para as etapas de treinamento e validação. Observa-se que o modelo, além de conseguir estimar com precisão os menores deslocamentos, também apresentou resultados consistentes nas situações com maiores valores de recalques.




Figura 5. Arquitetura do modelo




Figura 6. Comparação dos recalques do modelo e os recalques reais para as fases de treinamento e validação

Através do programa QNET 2000 pode-se obter os percentuais de contribuição de cada uma das variáveis de entrada na resposta gerada pelo modelo. A Figura 7 apresenta esses percentuais isoladamente, desta forma, a variável que mais contribui é o comprimento da estaca (L) com 19,5%. Porém, separando pelas três partes que compõe o sistema de mecanismo de transferência de carga: solo, elemento estrutural e carga aplicada, observa-se que as entradas referentes ao solo (consistência/compacidade, camada incompressível e estratigrafia) são as que mais contribuem com 42,7%, seguida pelo elemento estrutural (tipo de estaca, comprimento e diâmetro) com 41,9%, e por último a carga aplicada com 15,4%.




Figura 7. Percentuais de contribuição

Dentre as vantagens da utilização das RNA, está a possibilidade de implementação do modelo em simples planilhas de cálculo, fazendo uso dos pesos sinápticos (w_{kj}) e bias (b_k) obtidos na finalização do treinamento (Tabela 4, 5, 6, 7 e 8) que foram gerados através do programa QNET 2000 e utilizando as Equações 1, 2 e 3. Para aplicação do modelo apresentado, após a elaboração da planilha são necessários os relatórios de sondagem tipo SPT.

Tabela 4. Pesos sinápticos (w_{kj}) e limiares (b_k) entre a camada de entrada e a primeira camada intermediária.

		1ª Camada Intermediária											
Camada de Entrada		1	2	3	4	5	6	7	8	9	10	11	12
	T	1,51	-3,36	0,73	0,88	-0,24	1,09	-3,59	-2,12	-0,97	0,03	0,55	-6,14
	L	10,2	2,16	-1,76	7,66	-1,62	1,10	4,14	4,15	2,98	5,79	-4,88	1,71
	D	-0,63	-3,32	-2,80	1,43	-1,86	-1,73	2,14	-0,97	0,45	-3,44	-2,55	-1,06
	NF	8,92	-1,08	3,91	1,29	-2,16	-1,35	2,33	2,56	-4,16	-6,81	2,32	2,37
	NP	-2,08	0,59	0,45	4,05	-1,34	-0,34	1,10	4,28	-3,02	-0,67	0,25	0,74
	d	4,30	-1,65	-3,94	1,53	4,22	-2,31	-5,83	1,05	-4,44	3,24	-2,81	-1,93
	%Arg	-5,28	0,97	-6,28	0,34	2,21	-1,31	3,00	1,17	2,12	0,91	2,67	-0,47
	%Sil	2,35	0,29	0,01	-2,88	-0,20	-0,93	-0,05	-1,68	1,29	2,07	0,04	-1,54
	%Ar	2,43	0,98	3,89	-3,29	-1,09	-1,43	-1,93	1,20	1,41	0,79	-1,36	1,69
	P	-3,27	-2,71	-3,19	-0,89	0,20	5,19	7,36	-2,04	-13,5	-1,95	-1,33	-3,34
	b _k	-0,15	2,12	-0,20	-3,22	0,94	0,76	-0,56	-1,97	2,87	-0,64	2,15	0,48

Tabela 5. Pesos sinápticos (w_{kj}) e limiares (b_k) entre a segunda camada e a terceira camada intermediária.

		2ª Camada Intermediária							
1ª Camada Intermediária		1	2	3	4	5	6	7	8
	1	7,56	-2,90	2,46	-3,62	0,31	-2,15	-3,57	0,81
	2	-2,33	0,75	1,52	-6,40	0,21	-1,18	-1,08	-0,10
	3	-5,13	0,46	-2,40	0,23	-3,16	3,99	3,67	-0,65
	4	3,20	1,07	0,71	-1,52	-1,07	-1,26	-6,74	2,68
	5	-3,40	-0,24	0,27	-0,13	-0,61	3,63	0,66	0,65
	6	-3,48	-0,06	1,52	2,87	3,15	0,82	3,35	-1,10
	7	-3,31	0,25	-1,06	4,95	0,28	2,77	2,99	-0,49
	8	1,07	-1,15	1,02	2,54	0,14	0,49	-5,68	-1,85
	9	10,8	-1,74	3,19	-2,79	-0,40	-7,43	-8,37	0,50
	10	-5,83	3,08	-3,92	3,65	0,47	2,86	1,16	-3,68
	11	-2,11	-0,93	-1,88	3,27	-0,69	1,34	3,05	1,36
	12	-3,95	-0,79	-2,07	3,27	0,05	-1,18	-1,09	-3,03
	b _k	-0,61	1,29	-0,80	-3,84	-1,06	-1,28	4,53	1,03

Tabela 6. Pesos sinápticos (w_{kj}) e limiares (b_k) entre a terceira camada e a quarta camada intermediária.

		3ª Camada Intermediária					
2ª Camada Intermediária		1	2	3	4	5	6
	1	-3,41	-10,5	-10,9	-7,17	-1,99	-1,15
	2	-1,19	3,55	3,11	-0,28	-1,58	1,36
	3	0,46	-5,81	-0,32	-4,52	-1,02	0,48
	4	0,78	1,54	-2,30	8,93	1,15	1,39
	5	3,93	-0,11	0,80	-1,68	-0,01	-2,07
	6	1,46	3,57	4,45	8,23	1,02	-0,57
	7	2,41	13,1	5,14	2,00	1,30	0,39
	8	-2,21	-2,92	0,74	-4,30	0,11	-0,27
	b _k	0,75	-1,84	-0,82	1,03	-0,29	1,22

Tabela 7. Pesos sinápticos (w_{kj}) e limiares (b_k) entre a quarta camada intermediária e camada de saída.

		4ª Camada Intermediária			
3ª Camada Intermediária		1	2	3	4
	1	-2,25	-0,46	-3,37	-1,05
	2	-8,50	-0,52	-6,77	-1,30
	3	5,99	1,62	5,43	1,35
	4	-6,66	1,86	-4,46	0,27
	5	-1,51	-0,75	-1,13	-0,39
	6	1,56	1,83	2,61	1,23
	b _k	4,98	-1,42	3,66	-1,29

Tabela 8. Pesos sinápticos (w_{kj}) e limiares (b_k) entre a terceira camada e a quarta camada intermediária.

		Camada de saída
4ª Camada Intermediária		p
	1	-6,03
	2	-1,11
	3	-4,78
	4	0,58
	b _k	9,25

Na Figura 8 apresenta-se os resultados da

prova de carga e dos valores modelados através do modelo utilizando as RNA. A estaca é do tipo hélice contínua e foi executada em um solo predominantemente arenoso.




Figura 8. Valores modelados e a prova de carga real.

5 CONCLUSÕES

Este trabalho apresentou um modelo para previsão de recalques induzidos por um carregamento axial em estacas hélices contínuas, estacas cravadas metálicas e estacas escavadas utilizando as redes neurais artificiais. O modelo apresentado conseguiu melhor desempenho comparativamente aos de Amâncio (2013), Silveira (2014) e Dantas Neto et. al (2014), pois em nenhum dos modelos destes autores, o coeficiente de correlação na validação ultrapassou 0,94.

O modelo deste trabalho apresenta-se como uma ferramenta que pode ser utilizada na prática da engenharia de fundações para a previsão de recalques de estacas isoladas para qualquer valor de carga axial. Assim sendo, permite tanto a definição dos recalques para a carga de trabalho, como da curva carga x recalque das estacas isoladas respeitando os dados da Tabela 3.

REFERÊNCIAS

- Amâncio, L. B. *Previsão de recalques em fundações profundas utilizando redes neurais artificiais do tipo perceptron*. Dissertação (Mestrado em Engenharia Civil) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013, 90p.
- Anjos, G. J. M. *Estudo experimental do comportamento de fundações escavadas em solos tropicais*. Tese (Doutorado em Geotecnia) – Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2006, 341p.
- Araújo, C. B. C. (2013) *Previsão de Vazão Para o Açude Orós/CE a Partir de Dados Hidrometeorológicos Utilizando Perceptrons*, Monografia de Graduação em Engenharia Civil, Centro de Tecnologia, Universidade Federal do Ceará, 76p.
- Araújo, C. B. C. (2015) *Aplicação das redes neurais artificiais do tipo perceptron na estimativa de recalques em estacas*, Dissertação de Mestrado, Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, 227p.
- Associação Brasileira de Normas Técnicas. NBR 6122:2010: *Projeto e execução de fundações*, Rio de Janeiro.
- Benegas, E. Q. *Previsões para a curva carga-recalque de estacas a partir do SPT*. Tese de Doutorado, COOPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1993, 84p.
- Bussab, W. O.; Morettin, P. A. (1987) *Estatística básica*, 4. ed., São Paulo, Atual.
- Dantas Neto, S. A. *Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificadas com Borracha Granulada de Pneus Usados*. Tese de Doutorado, publicação G.TD – 024/04, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2004, 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.
- Haykin, S. *Redes Neurais Artificiais: Princípios e práticas*. 2ª edição, Editora Bookman, Porto Alegre, 2001.
- Martínez-Carvajal, H. E. *Modelagem construtiva de areias usando redes neurais artificiais*. Tese (Doutorado em Geotecnia), Departamento de Engenharia Civil, Universidade de Brasília, Brasília, 2006, 250p.
- Nejad, F. P.; Jaksa, M. B.; McCabe, B. A. Prediction of pile settlement using artificial neural networks based on standard penetration test data. *Elsevier Sci.: Computers and Geotechnics*, [S.l.], p. 1125-1133. set. 2009.
- Niyama, S.; Aoki, N.; Chamecki, P. R. Verificação de desempenho. In: HACHICH et al. (eds.). *Fundações: teoria e prática*. 2. Ed. São Paulo: PINI, 1998. cap. 20.
- Silveira, M.V. *Modelo neuronal para previsão de recalques em estacas hélice contínua, metálica e escavada*. Dissertação (Mestrado em Engenharia Civil) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2014, 106p.
- Velloso, D. A.; Lopes, F. R. *Fundações*, volume 1: critérios de projetos, investigação do subsolo, fundações superficiais. 2 ed. São Paulo: Oficina de Textos, 2011.
- Velloso, D. A.; Lopes, F. R. *Fundações*, volume 2: fundações profundas. Nova ed. São Paulo: Oficina de Textos, 2010.