



Universidade do Estado do Rio de Janeiro
Centro de Tecnologia e Ciências
Faculdade de Engenharia

Bruno Vieira de Jesus

**Experimentos de previsão da carga de ruptura em estacas
carregadas axialmente à compressão utilizando Redes Neurais
Artificiais (RNA)**

Rio de Janeiro
2019

Bruno Vieira de Jesus

Experimentos de previsão da carga de ruptura em estacas carregadas axialmente à compressão utilizando Redes Neurais Artificiais (RNA)



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Civil, da Universidade do Estado do Rio de Janeiro. Área de concentração: Geotecnia.

Orientadores: Prof^ª. Dr^ª. Ana Cristina Castro Fontenla Sieira
Prof. Dr. Armando Prestes de Menezes Filho

Rio de Janeiro

2019

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

J58 Jesus, Bruno Vieira de.
Experimentos de previsão da carga de ruptura em estacas carregadas axialmente à compressão utilizando redes neurais artificiais (RNA) / Bruno Vieira de Jesus. – 2019.
178f.

Orientadores: Ana Cristina Castro Fontenla Sieira, Armando Prestes de Menezes Filho.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia civil - Teses. 2. Estacaria (Engenharia civil) - Teses. 3. Resistência de materiais - Teses. 4. Materiais - Testes - Teses. 5. Redes neurais (Computação) - Teses. I. Sieira, Ana Cristina Castro Fontenla. II. Menezes Filho, Armando Prestes de. III. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. IV. Título.

CDU 624.154:620.17

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Data

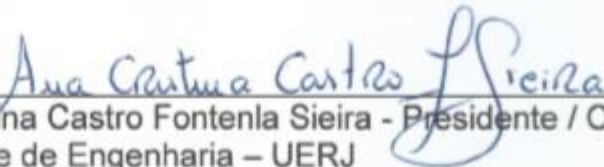
Bruno Vieira de Jesus

Experimentos de previsão da carga de ruptura em estacas carregadas axialmente à compressão utilizando Redes Neurais Artificiais (RNA)


Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Civil, da Universidade do Estado do Rio de Janeiro. Área de concentração: Geotecnia.

Aprovado em: 12 de fevereiro de 2019.

Banca Examinadora:



Ana Cristina Castro Fontenla Sieira - Presidente / Orientadora
Faculdade de Engenharia – UERJ



Armando Prestes de Menezes Filho – Orientador
Faculdade de Engenharia – UERJ



Acácio Magno Ribeiro
Universidade Federal de Juiz de Fora - UFJF



Marcos Antonio da Silva
UNISUAM



Marcus Peigas Pacheco
Faculdade de Engenharia – UERJ

Rio de Janeiro

2019

DEDICATÓRIA

Dedico este trabalho a minha mãezinha querida, Adjanira.

AGRADECIMENTOS

A minha mãe, que sempre me incentivou e apoiou nos estudos.

Aos meus queridos e estimados professores orientadores: Ana Cristina Castro Fontenla Sieira e Armando Prestes de Menezes Filho, os meus mais sinceros agradecimentos. A extraordinária orientação a mim dada, transcendeu a parte técnica e atingiu também a parte humana. As conversas, a disponibilidade, as reuniões, as palavras de incentivo, o carinho, os abraços, a dedicação, a atenção. Sou muito agradecido a vocês.

Aos demais professores do PGECIV: Bernadete R. Danziger, Rogério L. Feijó, Marcus P. Pacheco, Bruno T. Lima e Denise M. S. Gerscovich. Obrigado por fazerem este curso excelente. Quando cheguei na UERJ me senti abraçado por vocês. Obrigado.

As duas amigas maravilhosas, que conheci ao cursar este mestrado: Fernanda Ignacio e Simone Albuquerque. Este mestrado não teria sido tão especial sem vocês.

Aos colegas de curso: Isabela Caetano, Daniel Coelho, Daniel Lopez, Severino Passos, Marina Lopes, Guilherme Pereira, Flávia Santos e Pablo Richard.

Aos Professores Marcos Antonio da Silva (UGB) e Elaine Toscano Fonseca (UERJ) pelo apoio com o MATLAB e com as redes neurais.

Aos membros da banca, por terem aceitado o convite.

A empresa Terratek, em especial ao Alberto Ortigão, pela cessão do banco de dados utilizado neste trabalho.

Ao Carlos Elisio, pelo amor, carinho, atenção e paciência.

A todos do PGECIV.

À CAPES pelo apoio financeiro durante o mestrado.

A todos aqueles, que embora não citados nominalmente, contribuíram direta e indiretamente para a execução deste trabalho

Se você só fizer o que sabe, nunca será nada além do que já é.

Mestre Shifu

RESUMO

JESUS, Bruno Vieira de. *Experimentos de previsão da carga de ruptura em estacas carregadas axialmente à compressão utilizando redes neurais artificiais (RNA)*. 2019. 178f. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

Este trabalho apresenta experimentos de predição de carga de ruptura de estacas carregadas axialmente à compressão utilizando redes neurais artificiais (RNA). O banco de dados utilizado na pesquisa possui 342 elementos, e é composto de resultados de provas de cargas estáticas à compressão, ensaios de carregamentos dinâmicos e sondagens à percussão. O programa adotado é o MATLAB[®], versão R2017a. São utilizados quatro modelos de redes buscando-se a previsão da carga de ruptura a partir de dados do comprimento e área da seção transversal da estaca, e dos valores do N_{SPT} . Em cada modelo realizam-se processos de treinamento e teste. Posteriormente, procede-se à validação de cada arquitetura adotada, apresentando-se as redes com melhor desempenho. Os diferentes modelos buscaram um refinamento da rede, e a capacidade de generalização da mesma. No Modelo 01, a rede com melhor desempenho apresenta $R_{\text{training}} = 0,96$ e $R_{\text{test}} = 0,81$. No Modelo 02, houve um refinamento na rede, chegando-se a $R_{\text{training}} = 0,99$ e $R_{\text{test}} = 0,89$. No Modelo 03, a rede com melhor performance apresenta $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,93$ e no Modelo 04, a rede chegou a $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,96$. Apesar dos bons coeficientes de correlação apresentados, todas as redes apresentam elevados erros percentuais nos resultados do treinamento e teste, bem como na etapa de validação, quando se comparam os dados obtidos (*output*) com os dados esperados (*target*). Os resultados sugerem que as redes não são capazes de generalizar uma solução obtendo um resultado final com respostas satisfatórias. Alguns fatores que podem interferir no desempenho da rede são a qualidade das informações do banco de dados, a diversidade de solos, que pode conduzir a saídas distintas para um mesmo dado de entrada, e às incertezas inerentes ao comportamento dos solos e à qualidade dos ensaios analisados.

Palavras-chave: Redes Neurais Artificiais (RNAs); Carga de Ruptura; Estacas; Prova de Carga Estática; Ensaio de Carregamento Dinâmico.

ABSTRACT

JESUS, Bruno Vieira de. *Experiments of prediction failure load in piles compression axially loaded using artificial neural networks (ANNs)*. 2019. 178f. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

This work presents experiments of prediction failure load in piles compression axially loaded using artificial neural networks (ANNs). The database used in the research has 342 elements, and consists of static compression load test, dynamic load tests and standard penetration tests results. The software used was MATLAB®, version R2017a. Four network models are used to try to predict the failure load from data of the pile's length and cross-sectional area and the N_{SPT} 's values. In each model, training and testing are performed. Subsequently, each architecture is validated, presenting the best performing networks. The different models search a refinement of the network, and the generalization capacity of the same. In Model 01 the best performing network presents $R_{training} = 0.96$ and $R_{test} = 0.81$. In Model 02, there was a refinement in the network, obtains $R_{training} = 0.99$ and $R_{test} = 0.89$. In Model 03, the best network presents $R_{training} = 0.95$ and $R_{test} = 0.93$ and in Model 04 the network obtains $R_{training} = 0.95$ and $R_{test} = 0.96$. Although the good correlation coefficients presented, all the networks present high percentage errors in the training and test results, as well as in the validation results, when the data obtained (output) with the expected data (target) were compared. The results suggest that the networks were not able to generalize a solution obtaining a final result with satisfactory answers. Some factors that may interfere with network performance are the quality of the database information, the diversity of soils, which can lead to different outputs for the same input data, and the uncertainties inherent in soil behavior and the quality of the tests analyzed.

Keywords: Artificial Neural Networks (ANNs); Failure load; Piles Static load test; Dynamic load test.

LISTA DE FIGURAS

Figura 1 – Aparelhagem padrão para execução de sondagens de simples reconhecimento com SPT (Schnaid e Odebrech, 2012)	24
Figura 2 – Amostrador padrão do tipo “Raymond” (Schnaid e Odebrech, 2012)	25
Figura 3 – Sequência das etapas do ensaio SPT (Cintra et al., 2013).....	26
Figura 4 – Definição do índice de resistência a penetração N (adaptado de Cintra et al., 2013)	27
Figura 5 – Parcelas de resistência que constituem a capacidade de carga (Cintra e Aoki, 2010)	31
Figura 6 – Plataforma carregada ou cargueira (Velloso e Lopes, 2010)	44
Figura 7 – Conjunto de Estacas definitivas, ou somente para atender o ensaio (Velloso e Lopes, 2010)	45
Figura 8 – Conjunto de tirantes ancorados (Velloso e Lopes, 2010).....	45
Figura 9 – Curva carga x recalque com a representação dos estágios de carregamento e descarregamento (adaptado de Cintra et al., 2013)	46
Figura 10 – Regiões de um curva carga x recalque (Vargas, 1977 apud Melo 2009)	49
Figura 11 – Curvas carga x recalque (adaptado de Alonso, 2011)	50
Figura 12 – Método da NBR 6122 (NBR 6122, 2010)	52
Figura 13 – Definição da carga de ajuste, Método de Van der Veen (1953).....	55
Figura 14 – Método de Van der Veen (1953), modificado por Aoki (1976)	56
Figura 15 – Representação do ensaio de carregamento dinâmico (Cintra et al., 2013)	57
Figura 16 – Representação da solução da equação da onda (Gonçalves et al. 2000 apud Cintra et al. 2013).....	62
Figura 17 – Esquema básico de instrumentação de campo (modificado de Alonso, 2011)	65
Figura 18 – Sinal típico de saída de um PDA (Alonso, 2011)	65
Figura 19 – Esquema simplificado de cálculo pelo método CAPWAP® (Alonso, 2011)	68
Figura 20 – Sequência de ajuste de um sinal pelo método CAPWAP® (adaptado de Velloso e Lopes, 2010).....	69

Figura 21 – Resultado típico - Análise método CAPWAP® (Cintra et al., 2013).....	70
Figura 22 – Esquema de uma estrutura típica de um neurônio (Silva et al., 2010)...	74
Figura 23 – Impulso nervoso em um neurônio (Macedo et al., 2012)	75
Figura 24 – Modelo do Neurônio Artificial	76
Figura 25 – Função degrau (<i>heavyside</i>) ou função de limiar (adaptado de Silva et al., 2010)	78
Figura 26 – Função degrau bipolar ou função sinal (adaptado de Silva et al., 2010)	78
Figura 27 – Função rampa simétrica (adaptado de Silva et al., 2010)	78
Figura 28 – Função logística (<i>S-shape</i>) (adaptado de Silva et al., 2010).....	79
Figura 29 – Função tangente hiperbólica (adaptado de Silva et al., 2010)	80
Figura 30 – Função linear ou função identidade (adaptado de Silva et al., 2010).....	80
Figura 31 – Rede Direta (<i>feed-forward</i>) de uma camada	82
Figura 32 – Rede Direta (<i>feed-forward</i>) de múltiplas camadas, com duas camadas neurais escondidas	82
Figura 33 – Redes Recorrentes (<i>feed-backward</i>).....	83
Figura 34 – Exemplo de Rede Reticulada, a Rede de Kohonen	84
Figura 35 – Aprendizagem com professor	87
Figura 36 – Comportamento de um <i>Perceptron</i> classificador de padrões cuja função é dividir classes linearmente separáveis	90
Figura 37 – Comportamento de um <i>Perceptron</i> de multiplas camadas classificador de padrões com mais de duas classes linearmente separáveis.....	92
Figura 38 – Domínios de normalização para função de ativação tangente hiperbólica (adaptado de Silva et al., 2010).....	95
Figura 39 – Regra da parada antecipada baseada na validação cruzada (adaptado de Haykin, 2008)	96
Figura 40 – <i>Toolbox nntool</i>	103
Figura 41 – <i>Toolbox nntool</i> , criando a rede neural artificial.....	103
Figura 42 – Gráfico de desempenho da rede A22:6:1 – Modelo 01	112
Figura 43 – Gráficos “ <i>target x output</i> ” da rede A22:6:1 – Modelo 01.....	113
Figura 44 – Gráfico Erro percentual por estaca – Treinamento e teste da rede A22:6:1	114
Figura 45 – Gráfico Erro percentual por estaca – Validação da rede A22:6:1	115
Figura 46 – Desempenho da rede A22:11:1 – Modelo 02.....	117
Figura 47 – Gráficos “ <i>target x output</i> ” da rede A22:11:1 – Modelo 02.....	117

Figura 48 – Erro percentual por estaca – Treinamento e teste da rede A22:11:1 ...	118
Figura 49 – Erro percentual por estaca – Validação da rede A22:11:1	119
Figura 50 – Gráfico de desempenho da rede A12:3:1 – Modelo 03	122
Figura 51 – Gráficos “ <i>target x output</i> ” da rede A12:3:1 – Modelo 03.....	123
Figura 52 – Gráfico Erro percentual por estaca – Treinamento e teste da rede A12:3:1	124
Figura 53 – Erro percentual por estaca – Validação da rede A12:3:1	124
Figura 54 – Gráfico Erro percentual por estaca – Treinamento e teste das redes A12:14:6:1 e A12:24:3:1.....	125
Figura 55 – Gráfico Erro percentual por estaca – Validação das rede A12:14:6:1 e A12:24:6:1	126
Figura 56 – Gráfico de desempenho da rede A7:7:1 – Modelo 04	130
Figura 57 – Gráficos “ <i>target x output</i> ” da rede A7:7:1 – Modelo 04.....	130
Figura 58 – Gráfico Erro percentual por estaca – Treinamento e teste da rede A7:7:1	131
Figura 59 – Gráfico Erro percentual por estaca – Validação da rede A7:7:1	132

LISTA DE TABELAS

Tabela 1 – Tipos de Estacas (adaptado de Velloso e Lopes, 2010)	22
Tabela 2 – Estados de compacidade e de consistência (NBR 6484, 2001).....	28
Tabela 3 – Fatores de correção de $F1$ e $F2$ (Cintra e Aoki, 2010)	34
Tabela 4 – Coeficientes CAV e αAV (Cintra e Aoki, 2010)	34
Tabela 5 – Parâmetros $CDEC$ (Décourt, 1978).....	36
Tabela 6 – Fator αDEC (Décourt, 1996)	36
Tabela 7 – Fator βDEC (Décourt, 1996).....	37
Tabela 8 – Valores aproximados de a, b, a', b' (adaptado de Velloso, 1981)	39
Tabela 9 – Coeficientes de ajuste $\alpha UFRGS$ e $\beta UFRGS$ (Lobo, 2005).....	40
Tabela 10 – Quantidade de provas de carga (NBR6122, 2010)	42
Tabela 11 – Valores de Jc sugeridos por Rausche et al. (1985)	67
Tabela 12 – Variáveis utilizadas na Rede Neural.....	105
Tabela 13 – Máximos e mínimos das variáveis do banco de dados	106
Tabela 14 – Modelos de redes neurais avaliados	108
Tabela 15 - Características dos modelos	109
Tabela 16 – Arquiteturas utilizadas no Modelo 01.....	110
Tabela 17 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 01	111
Tabela 18 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 02	116
Tabela 19 – Arquiteturas utilizadas no Modelo 03.....	120
Tabela 20 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 03	121
Tabela 21 – Arquiteturas utilizadas no Modelo 04.....	127
Tabela 22 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 04	129

LISTA DE ABREVIATURAS E SIGLAS

<i>Adaline</i>	<i>Adaptive Linear Neuron</i>
CAPWAP [®]	<i>Case Pile Wave Analysis Program</i>
CASE [®]	<i>Método simplificado, Case Western Reserve University</i>
CPT	<i>Cone Penetration Test</i>
EQM	Erro Quadrático Médio
ISSMFE	<i>International Society for Soil Mechanics and Foundation</i>
LMS	<i>Least Mean Square</i>
<i>Madaline</i>	<i>Multiple Adaline</i>
MCP	<i>Modelo McCulloch e Pitts</i>
<i>MLP</i>	<i>Multilayer Perceptron</i>
<i>MSE</i>	<i>Mean Squared Error</i>
NBR	Norma Brasileira
PDA	<i>Pile Driving Analyser</i>
PGECIV	Programa de Pós Graduação em Engenharia Civil
PMC	<i>Perceptron de múltiplas camadas</i>
RBF	Redes de Base Radial
RN	Referência de Nível
RNA	Rede Neural Artificial
SPT	<i>Standard Penetration Test</i>
SPT-T	<i>Standard Penetration Test</i> com medida de torque
UERJ	Universidade do Estado do Rio de Janeiro
UFJF	Universidade Federal de Juiz de Fora
UGB/FERP	Centro Universitário Geraldo Di Biase / Fundação Educacional Rosemar Pimentel

LISTA DE SÍMBOLOS

a	parâmetro de correlação entre o SPT e o CPT - Método de Pedro Paulo da Costa Velloso
a'	parâmetro de correlação entre o SPT e o CPT - Método de Pedro Paulo da Costa Velloso
a_l	área lateral total do amostrador SPT
a_p	área de ponta do amostrador SPT
A	área da seção transversal da estaca
A_p	área da seção transversal na ponta da estaca
A_t	valor real no período t
α_{AV}	razão de atrito – Método Aoki e Velloso
α_{DEC}	fator aplicado à parcela de ponta - Método Décourt e Quaresma
α_{ppv}	fator de execução da estaca - Método de Pedro Paulo da Costa Velloso
α_{UFRGS}	coeficiente de ajuste aplicado para resistência lateral - Método da UFRGS
b	parâmetro de correlação entre o SPT e o CPT - Método de Pedro Paulo da Costa Velloso
b'	parâmetro de correlação entre o SPT e o CPT - Método de Pedro Paulo da Costa Velloso
b_k	Bias
β	constante real associada ao nível de inclinação da função logística frente ao seu ponto de inflexão
β_{DEC}	fator aplicado à parcela de atrito lateral - Método Décourt e Quaresma
β_{ppv}	fator de carga de ponta - Método de Pedro Paulo da Costa Velloso
β_{UFRGS}	coeficiente de ajuste aplicado para resistência de ponta - Método da UFRGS
c	velocidade de propagação da onda de choque (ou de tensão)
C_{AV}	coeficiente que depende do tipo de solo - Método Aoki e Velloso
C_{DEC}	coeficiente característico do solo – Método Décourt e Quaresma
d	diâmetro da ponta do cone CPT
D	diâmetro do fuste
Δ_l	espessura da camada de solo

ΔQ	acrécimo de carga
Δr	acrécimo do recalque da ponta da estaca
$\Delta \rho$	penetração do golpe
e_t	erro no período t
E	módulo de elasticidade do material da estaca
$EP(\%)$	erro percentual
$E_{aplicada}$	energia potencial correspondente índice de resistência à penetração obtido no ensaio
E_{60}	60% da energia potencial teórica de queda livre
E^*	energia potencial teórica de queda livre
f_{ck}	resistência característica do concreto
f_u	tensão limite de cisalhamento ao longo do fuste
F_d	variação da energia potencial
F_{t1}	força no tempo t_1
F_{t2}	força no tempo t_2
F_1	Fator de correção 1 em função do tipo de estaca
F_2	Fator de correção 2 em função do tipo de estaca
$F(v_k)$	Função de Ativação
$F \downarrow$	força descendente
$F \uparrow$	força ascendente
g	aceleração da gravidade
γ	peso específico da estaca
η_1	eficiência do golpe
η_2	eficiência das hastes
η_3	eficiência do sistema
J_c	fator de amortecimento
k	neurônio
L	comprimento da estaca
λ	fator de carregamento da estaca - Método de Pedro Paulo da Costa Velloso
M_h	massa da haste
M_m	massa do martelo
n	número de períodos usados

N	índice de resistência à penetração a cada metro
N_{eq}	índice de resistência à penetração a cada metro com medida de torque
N_{ippv}	valor de N_{SPT} correspondente à camada i - Método de Pedro Paulo da Costa Velloso
N_l	índice médio de resistência à penetração na camada de solo de espessura Δ_l
N_p	índice médio de resistência à penetração na cota de apoio da estaca
N_1	valor de número de golpes para penetrar os primeiros 15 cm
N_{1ppv}	valor médio de N_{SPT} , calculado desde a cota da ponta da estaca até dois diâmetros acima da mesma - Método de Pedro Paulo da Costa Velloso
N_2	valor de número de golpes para penetrar os segundos 15 cm
N_{2ppv}	valor médio de N_{SPT} , calculado desde a cota da ponta da estaca até um diâmetro abaixo da mesma - Método de Pedro Paulo da Costa Velloso
N_3	valor de número de golpes para penetrar o último 15 cm
N_{60}	valor de penetração de referência, com base no padrão internacional
P	carga aplicada no topo da estaca teste
P_r	valor de carga a ser determinado
P_t	previsão para o período t
φ_{eq}	diâmetro equivalente
Q	carga aplicada
Q_L	parcela de resistência por atrito lateral ao longo do fuste
Q_P	parcela de resistência de ponta
Q_r	carga de ruptura
Q_T	capacidade de carga da estaca
Q_u	carga correspondente a um valor de rigidez nula
q_u	tensão limite normal no nível da ponta
r	recalque
R	capacidade de carga de um sistema solo-estaca
R_{all}	coeficiente de correlação de todo o conjunto de dados
R_d	parcela dinâmica
R_L	resistência lateral
R_P	resistência de ponta
R_t	Resistência total à penetração da estaca

R_{test}	coeficiente de correlação do teste
R_{training}	coeficiente de correlação do treinamento
R_u	resistência elástica limite
R^2	coeficiente de correlação
ρ	massa específica do material da estaca
t	instante de tempo
t_1	tempo de maior intensidade do golpe
t_2	tempo de maior intensidade do golpe mais tempo para a onda ir até a ponta da estaca e voltar por reflexão até o topo
T	tempo
σ	tensão
u	deslocamento
U	perímetro da seção transversal do fuste
v	velocidade de partícula
v_p	velocidade de partícula na ponta da estaca
v_k	saída do combinador linear (Somador)
v_1	velocidade de partícula no tempo t_1
v_2	velocidade de partícula no tempo t_2
$v \downarrow$	velocidade de partícula descendente
$v \uparrow$	velocidade de partícula ascendente
x	posição da seção transversal da estaca
x_j	vetor de entrada
X	variável a ser normalizada
$X_{\text{mín}}$	valor mínimo da variável a ser normalizada
$X_{\text{máx}}$	valor máximo da variável a ser normalizada
X'	variável resultante da normalização
y_k	saída do neurônio k
W_{kj}	pesos sinápticos do neurônio k
z	comprimento da haste que penetrou no solo
Z	impedância
∞	infinito

SUMÁRIO

INTRODUÇÃO	19
Motivação	19
Objetivos	19
Estrutura da dissertação	20
1 FUNDAMENTAÇÃO TEÓRICA	21
1.1 Fundações Profundas	21
1.2 SPT (<i>Standard Penetration Test</i>)	23
1.3 Métodos de Previsão de Capacidade de Carga em estacas	30
1.3.1 Método de Aoki e Velloso (1975)	32
1.3.2 Método de Décourt e Quaresma (1978) modificado por Décourt (1996)	35
1.3.3 Método de Pedro Paulo da Costa Velloso (1981)	37
1.3.4 Método da UFRGS, Lobo (2005)	39
1.4 Provas de Carga	40
1.4.1 Prova de Carga Estática	43
1.4.2 Ensaio de Carregamento Dinâmico	56
2 REDE NEURAL ARTIFICIAL (RNA)	71
2.1 Introdução	71
2.2 O Cérebro Humano e o neurônio biológico	74
2.3 Modelagem do Neurônio Artificial	75
2.3.1 Tipos de Função de Ativação	77
2.3.2 Arquiteturas de Rede	81
2.3.3 Aprendizagem (ou Treinamento) da Rede	84
2.3.4 Modelos de Redes Neurais Artificiais	90
2.3.5 O Algoritmo de Retropropagação (Backpropagation)	92
2.3.6 Funcionalidade e Otimização das Redes MLP	93
2.3.7 Função de Aprendizagem " <i>trainbr</i> "	96
2.3.8 Função de adaptação de aprendizagem " <i>learnngdm</i> "	97
2.4 Aplicação de RNA em Geotecnia	97
3 METODOLOGIA	102
3.1 MATLAB® - Ferramenta Computacional	102

3.2 Banco de Dados	104
3.3 Variáveis.....	105
3.4 Tratamento dos dados de entrada.....	106
4 APRESENTAÇÃO DOS RESULTADOS	108
4.1 Introdução.....	108
4.2 Modelo 01	109
4.3 Modelo 02.....	115
4.4 Modelo 03.....	120
4.5 Modelo 04.....	126
4.6 Discussão dos Resultados.....	133
5 CONCLUSÕES E SUGESTÕES	138
5.1 Conclusões	138
5.2 Trabalhos Futuros.....	139
REFERÊNCIAS.....	141

INTRODUÇÃO

Motivação

Rede Neurais Artificiais (RNA) são modelos computacionais baseados na forma como o cérebro humano realiza a aprendizagem, e tentam reproduzir a forma como o mesmo resolve problemas, através de neurônios artificiais.

A motivação para a utilização de Redes Neurais Artificiais decorre da grande capacidade que essas estruturas possuem em aprender por meios de um conjunto de dados e a partir disso generalizar uma solução obtendo um resultado final com respostas coerentes para dados que não estavam presentes no conjunto amostral inicial.

Redes Neurais Artificiais possuem um grande potencial para serem empregadas em diversos campos de estudo, tais como: diagnósticos médicos, em controles de processos de produção, no diagnóstico de dados econômicos e financeiros, em robótica, nas engenharias, dentre outras áreas.

Em engenharia geotécnica, a aplicação de redes neurais artificiais é um campo em aberto, com bastante potencial de êxitos. Muitos trabalhos tem sido desenvolvidos em: classificação de solos, estudos sobre acréscimo de tensões no solo, estudos em fundações, em barragens, em mapeamento geotécnico, em geotecnia ambiental, em túneis, estimativa de permeabilidade de solos, entre tantas outras.

Provas de carga são ensaios que melhor representam o comportamento de solo x fundação. Como resultado do ensaio obtém-se a curva carga x recalque e uma das informações obtidas é a carga de ruptura da estaca, que serve como importante instrumento para os projetos de fundações.

A tentativa de prever a carga de ruptura através de Redes Neurais Artificiais é um área de estudo promissora.

Objetivos

A presente dissertação tem como objetivo experimentar modelos para prever a carga de ruptura de estacas submetidas à esforços axiais de compressão através de Redes Neurais Artificiais. Esta investigação visa experimentar modelos de redes

neurais artificiais alimentadas por um banco de dados com resultados de provas de carga estáticas à compressão, ensaios de carregamento dinâmico, sondagens à percussão e dados da geometria das estacas.

Estrutura da dissertação

O presente capítulo apresenta os objetivos e a motivação para o desenvolvimento deste trabalho.

No capítulo 2 é apresentada uma fundamentação teórica através da abordagem geral sobre Fundações Profundas, enfatizando as estacas, o ensaio SPT, os métodos de previsão de capacidade de carga em estacas, a prova de carga estática e o ensaio de carregamento dinâmico (prova de carga dinâmica).

No capítulo 3 serão apresentados os conceitos básicos de redes neurais artificiais. Uma breve abordagem sobre seu histórico, as características dos neurônios humanos e o modelo de neurônio artificial. Será exibida a modelagem de um neurônio artificial com os tipos de funções de ativação, as arquiteturas de redes neurais, os métodos de aprendizagem, os principais modelos de RNAs e suas definições básicas. Também será apresentado o algoritmo de retropropagação, a função de treinamento e a função de adaptação de treinamento utilizadas nas redes deste trabalho. Finalmente, o capítulo apresentará uma breve abordagem da utilização das RNAs em Geotecnia.

No capítulo 4 serão descritas as metodologias utilizadas para a criação da Rede Neural Artificial, contemplando a ferramenta numérica computacional utilizada (MATLAB[®]), as variáveis utilizadas, assim como a apresentação do banco de dados que compõe o presente trabalho.

O capítulo 5 apresenta os resultados dos modelos preditivos de carga de ruptura abordados no capítulo anterior. Serão abordados quatro modelos e apresentados os dados referentes ao treinamento e teste, e validação das redes que apresentaram melhor desempenho utilizando cada um dos modelos. Uma discussão sobre os resultados obtidos é apresentada.

No capítulo 6 serão apresentadas as conclusões obtidas com o desenvolvimento da presente dissertação, além de algumas propostas para trabalhos futuros.

1 FUNDAMENTAÇÃO TEÓRICA

Apresenta-se neste capítulo uma abordagem geral sobre Fundações Profundas, enfatizando as estacas, o ensaio SPT, os métodos de previsão de capacidade de carga em estacas e as provas de carga, tanto a prova de carga estática, quanto o ensaio de carregamento dinâmico (prova de carga dinâmica).

1.1 Fundações Profundas

Segundo Cintra e Aoki (2010), uma fundação é um sistema composto pelo elemento estrutural e pelo maciço de solo que a envolve, e a este sistema é atribuída a capacidade de absorver e transmitir ao maciço as cargas aplicadas e proporcionar as condições mínimas de segurança, funcionalidade e durabilidade.

Existem dois tipos básicos de fundação: a superficial (ou direta, ou rasa) e a profunda, sendo esta última o foco deste trabalho. O que difere os dois tipos, além da profundidade de assentamento, é a maneira como ambas transferem a carga da estrutura para o terreno.

Quando a camada de solo superficial ou imediatamente inferior a supra estrutura não tem capacidade de suportar os carregamentos, podendo provocar recalques excessivos ou ruptura por cisalhamento do solo, o uso das fundações profundas se torna necessário, fazendo com que os carregamentos sejam transmitidos a camadas mais profundas e com capacidade de suporte adequada.

Segundo a NBR 6122 (2010), que trata do projeto e execução de fundações, as fundações profundas são aqueles elementos de fundação que transmitem a carga ao terreno, ou através da sua base (resistência de ponta) ou pela contribuição da sua superfície lateral (resistência de fuste) ou ainda, por uma combinação das duas. Sua base deve estar assentada a uma profundidade superior ao dobro da sua menor dimensão em planta, e no mínimo 3,0 m. Entre os tipos de fundações profundas podemos citar as estacas, os tubulões e os caixões.

As estacas são elementos estruturais esbeltos caracterizadas por sua seção transversal geralmente pequena comparada ao seu comprimento, instaladas no solo por cravação ou perfuração, em posição vertical ou pouco inclinada.

Conforme a NBR 6122 (2010), as estacas são definidas como um elemento de fundação profunda executada inteiramente por equipamentos ou ferramentas,

sem que, em qualquer fase de sua execução, haja descida de operário. Os tipos de estacas empregados no Brasil são: de madeira, de aço cravadas (por percussão, prensagem ou vibração), de concreto pré-moldado, estaca tipo Strauss, tipo Franki, estaca escavada (sem revestimento, com revestimento de aço – provisório ou perdido – e com escavação com estabilização por fluido), estaca Raiz, microestaca injetada e estaca hélice.

De acordo com Velloso e Lopes (2010), as estacas podem ser classificadas segundo diferentes critérios. De acordo com o material, em: de madeira; de concreto; de aço e mistas. De acordo com o processo executivo, em: “de deslocamento”, as estacas cravadas, em geral, que ao serem executadas, deslocam o solo horizontalmente; “de substituição”, as estacas escavadas, em geral, que para serem executadas tomam o local onde o solo ocupava, causando algum tipo de redução das tensões horizontais geostáticas; e “sem deslocamento”, as estacas escavadas, em que não ocorre quase nenhuma remoção de solo e/ou, na realização da concretagem são tomadas medidas para que as tensões geostáticas sejam restituídas (pelo menos parcialmente). A Tabela 1, mostra a junção dessas duas classificações.

Tabela 1 – Tipos de Estacas (adaptado de Velloso e Lopes, 2010)

Tipo de Execução		Estacas
De grande	Deslocamento	Madeira
		Pré-moldadas de concreto
		Tubos de aço de ponta fechada
		Tipo Franki
		Microestacas injetadas
De pequeno	Deslocamento	Perfis de aço
		Tubos de aço de ponta aberta (desde que não haja embuchamento na cravação)
		Estacas hélice especiais (“estacas hélice de deslocamento”)
Sem deslocamento	Deslocamento	Escavadas com revestimento metálico perdido que avança à frente da escavação
		Estaca Raiz
De substituição	Deslocamento	Escavadas sem revestimento ou com uso de lama
		Tipo Strauss

Tipo de Execução	Estacas
	Estacas hélice contínua em geral

1.2 SPT (*Standard Penetration Test*)

O SPT é um ensaio de campo onde se determina o índice de resistência à penetração e é realizado juntamente com a Sondagem de Simples Reconhecimento. Estes ensaios são prescritos pela NBR 6484 (2001), que discorre sobre: Solo – Sondagens de simples reconhecimento com SPT – Método de Ensaio.

A sondagem de simples reconhecimento de solos com SPT, tem como princípio a perfuração e cravação dinâmica a cada metro de um amostrador padrão, afim de se determinar os tipos de solo em suas referentes profundidades de ocorrência, os índices de resistência à penetração a cada metro (N), e a posição do nível d'água.

Segundo Schnaid e Odebrech (2012), o SPT é, reconhecidamente, a ferramenta de investigação geotécnica mais popular, rotineira e econômica em praticamente todo o mundo. Ele serve como indicativo da densidade de solos granulares e é aplicado também na identificação da consistência de solos coesivos, e até mesmo de rochas brandas.

No Brasil, para elaboração de projetos de fundações profundas e superficiais são utilizados, muitas das vezes somente, os resultados das sondagens de simples reconhecimento com SPT. Visto que a NBR 6122 (2010) refere-se a sondagem de simples reconhecimento com SPT como ensaio obrigatório para projetos de fundações, visando a determinação da estratigrafia e classificação dos solos, posição do nível d'água e medida do índice de resistência à penetração. Além do que, o ensaio é um método direto de prospecção do subsolo para fins geotécnicos, uma vez que ao ser executado pode-se observar diretamente o solo ensaiado e obter amostras ao logo da perfuração, podendo assim determinar a estratigrafia do terreno; possui facilidade e simplicidade de execução, pois seu procedimento de ensaio é fácil de ser seguido e seu equipamento é simples e robusto; possui baixo custo de execução; pode ser executado em condições adversas de clima; e possui uma grande experiência acumulada pelo seu uso recorrente.

A aparelhagem padrão para execução de sondagens de simples reconhecimento com SPT pode ser vista na Figura 1 e é composta em linhas gerais

dos seguintes equipamentos: Torre (tripé) com sarilho, cabo e roldana; Tubos de revestimento de aço; Composição de perfuração e de cravação do amostrador padrão; Trado concha (ou cavadeira) e Trado helicoidal; Trépano de lavagem; Amostrador padrão do tipo Raymond (Figura 2); Cabeça de bater da composição de cravação; Martelo padronizado, com massa de 65 kg; Bomba d'água centrífuga para circulação de água; Ferramentas gerais, tais como: balde para esgotar a água do furo, medidor de nível d'água, metro de balcão, recipientes para as amostras, caixa d'água e tambor com divisão interna para decantação.




Figura 1 – Aparelhagem padrão para execução de sondagens de simples reconhecimento com SPT (Schnaid e Odebrech, 2012)




Figura 2 – Amostrador padrão do tipo “*Raymond*” (Schnaid e Odebrech, 2012)

Em regras gerais a execução da sondagem de simples reconhecimento com SPT compreende as seguintes etapas:

I. Processo de Perfuração:

A sondagem é iniciada com o emprego de trado concha ou cavadeira manual até a profundidade de um metro.

Nas operações seguintes do processo de perfuração, intercaladas das etapas II (Amostragem) e III (Ensaio de Penetração Dinâmica), utiliza-se trado helicoidal até atingir o nível do lençol freático. A partir do qual se passa a utilizar o método de perfuração por circulação de água, usando-se o trépano de lavagem como equipamento de escavação, removendo o material escavado por circulação de água por intermédio da bomba d’água motorizada.

II. Amostragem:

Uma parte representativa do solo retirado pelo trado concha até a profundidade de um metro deverá ser coletado para análise posterior.

Em seguida, à partir de um metro de profundidade, a cada metro de perfuração são colhidas amostras cilíndricas dos solos por meio do amostrador-padrão, para classificação do tipo de solo.

III. Ensaio de Penetração Dinâmica (ou Penetrométrico):

O Amostrador-padrão conectado às hastes de cravação deve descer no interior do furo de sondagem e ser apoiado no fundo (na profundidade de um metro). Em seguida, a cabeça de bater deve ser colocada no topo da haste e

o martelo apoiado suavemente sobre a cabeça de bater, sendo anotado o valor da penetração do amostrador no solo em centímetros, quando houver.

Utiliza-se o topo do tubo de revestimento como referência e marca-se com giz na haste de cravação três segmentos de 15 cm, totalizando 45 cm.

Não sendo observado nenhuma penetração do amostrador no solo ao apoiar o martelo sobre a cabeça de bater, segue-se o processo de penetração dinâmica, onde o amostrador padrão é cravado no solo através de quedas sucessivas do martelo sobre a cabeça de bater, sendo erguido até uma altura de 75 cm, até completar 45 cm de penetração do amostrador, anotando-se separadamente o número de golpes necessários para a cravação de cada segmento de 15 cm do amostrador-padrão, utilizando como referência as marcações à giz na haste de cravação.

As etapas II e III são executadas simultaneamente, e a etapa I é alternada com as etapas II e III em cada metro de sondagem, ou seja, ao término da cravação dos 45 cm do amostrador na etapa III realiza-se a amostragem (etapa II), e inicia-se novamente a etapa I (Processo de perfuração) ao se executar mais 55 cm de perfuração, totalizando um metro de ensaio, conforme ilustrado na Figura 3.




Figura 3 – Sequência das etapas do ensaio SPT (Cintra et al., 2013)

Em cada metro de sondagem executado, com exceção do primeiro metro escavado, obtemos na Etapa III três valores de golpes no ensaio de penetração dinâmica ao se atingir 45 cm de penetração do amostrador padrão: N_1 , o valor de número de golpes para penetrar os primeiros 15 cm; N_2 , o valor de número de

golpes para penetrar os segundos 15 cm; e N_3 , o valor de número de golpes para penetrar o último 15 cm. Desconsidera-se o valor de N_1 , por ser um valor que pode ser afetado pela etapa de perfuração e define-se o índice de resistência a penetração N como a soma do número de golpes requeridos para a segunda e terceira etapas de penetração de 15 cm, conforme Equação (1), e esquematizado na Figura 4, para uma profundidade compreendida entre as profundidades z e $(z+1)$.

$$N = N_2 + N_3 \quad (1)$$




Figura 4 – Definição do índice de resistência a penetração N (adaptado de Cintra et al., 2013)

De acordo com a NBR 8036 (1983), que trata da programação de sondagens de simples reconhecimento dos solos para fundação de edifícios, a quantidade de sondagens a serem realizadas e sua localização em planta dependem do tipo de estrutura e suas características e das condições geotécnicas do subsolo. Estas sondagens devem fornecer um perfil da provável variação das camadas do subsolo do local de estudo.

As sondagens de simples reconhecimento com SPT devem ser executadas até uma profundidade em que o solo não seja mais solicitado significativamente pelas cargas estruturais, sendo fixado como critério a profundidade onde o acréscimo da tensão no solo devida às cargas estruturais consistir em menos que 10% da tensão geostática efetiva.

Durante a realização da sondagem é observado o nível d'água, registrando-se sua elevação. O nível d'água final é determinado após o término da sondagem, decorridos no mínimo 12 h.

A classificação das amostras é realizada num processo onde se busca identificar visualmente a sua granulometria, conforme NBR 7181 (1984), que trata sobre: Solo – Análise Granulométrica - Método de Ensaio; sua plasticidade; sua cor; e origem.

As amostras devem ser separadas em função da sua profundidade e examinadas individualmente, devendo-se iniciar a classificação em função da sua granulometria, separando em dois grupos: solos grossos (pedregulhos e areias) e solos finos (siltes e argilas) e realizada em conjunto com seu índice de resistência à penetração, levando a classificações quanto à compacidade e consistência, conforme Tabela 2.

Tabela 2 – Estados de compacidade e de consistência (NBR 6484, 2001)

Solo	Índice de resistência à penetração (N)	Designação¹⁾
Areias e siltes arenosos	≤ 4	Fofa(o)
	5 a 8	Pouco compacta(o)
	9 a 18	Medianamente compacta(o)
	19 a 40	Compacta(o)
	> 40	Muito compacta(o)
Argilas e siltes argilosos	≤ 2	Muito mole
	3 a 5	Mole
	6 a 10	Média(o)
	11 a 19	Rija(o)
	> 19	Dura(o)
¹⁾ As expressões empregadas para classificação da compacidade das areias (fofa, compacta, etc.), referem-se à deformabilidade e resistência destes solos, sob o ponto de vista de fundações, e não devem ser confundidas com as mesmas denominações empregadas para designação da compacidade relativa das areias ou para a situação perante o índice de vazios críticos, definidos na Mecânica dos solos.		

A nomenclatura das amostras devem vir acompanhadas pela indicação de sua cor, através das designações: branco, cinza, preto, marrom, amarelo, vermelho, roxo, azul e verde. Sendo admitidos distinção entre claro e escuro. A utilização do termo variegado se dá quando o solo possuir mais de duas cores em sua composição.

Afim de tornar a classificação do tipo de solo mais completa, deve-se usar a denominação da origem do solo (se solos residuais; transportados: coluvionares, aluvionares, fluviais e marinhos; ou aterros) e se possui presença acentuada de mica. Recomenda-se se o solo for residual a indicação da rocha de origem. Admite-se complementação das descrições quando houver: pedregulhos, cascalhos, detritos, matéria orgânica, conchas, concreções, etc.

Para expressar os resultados das sondagens de simples reconhecimento com SPT são gerados relatórios de campo (boletim de campo) que servem de referência para elaboração de relatórios definitivos (boletim definitivo de sondagem) que devem conter um perfil individual de sondagem (desenho em escala 1:100), onde são apresentados a sequências das camadas do subsolo, constando suas cotas, posição onde foram retiradas as amostras, os níveis d'água, a resistência à penetração (N) de cada camada nas cotas onde foram observadas. Deve constar ainda, um desenho com a localização dos furos de sondagens em relação aos pontos de referência bem definidos no terreno e indicação na Referência de Nível (RN) tomada para o nivelamento.

Apesar da prática brasileira ser regularizada pelas recomendações da NBR 6484 (2001), que estabelecem os critérios para execução do ensaio e adoção de equipamentos, existem diversos fatores que influenciam na transferência de energia do martelo até o amostrador, tais como: perdas por atrito entre o cabo e a roldana; o sistema de elevação, liberação e geometria do martelo; uso ou ausência de coxim e cabeça de bater; o tipo de cabo, se sisal ou aço; dentre outros. Assim foi necessária uma padronização para a energia a ser utilizada como referência no ensaio, estabelecida pela ISSMFE(1989) como 60% da energia potencial teórica como padrão internacional. Portanto ao se realizar o ensaio SPT, uma correção do valor de N para N_{60} (valor de penetração de referência, com base no padrão internacional) deve ser realizada por meio de uma relação linear entre a energia empregada no ensaio e a energia de referência, conforme Equação (2).

$$N_{60} = N * \left(\frac{E_{aplicada}}{E_{60}} \right) \quad (2)$$

sendo:

$E_{aplicada}$ = Energia potencial correspondente a N obtido no ensaio;

E_{60} = 60% da energia potencial teórica de queda livre E^* ;

E^* = 474 J;

N = valor de penetração obtido no ensaio;

N_{60} = valor de penetração de referência, com base no padrão internacional.

No Brasil é muito comum o uso de sistemas manuais de liberação de queda do martelo, cuja energia aplicada varia entre 70% e 80% da energia potencial teórica de queda livre E^* (Décourt, 1989; Belicantra, 1998; Cavalcante et al., 2004).

Segundo Schnaid e Odebrech (2012) nos Estados Unidos da América e na Europa o sistema de liberação de queda do martelo é mecanizada e a energia liberada é de cerca de 60%.

A interpretação de resultados para fins de projetos geotécnicos pode ser obtida por meio de métodos indiretos, onde os resultados do ensaio SPT são utilizados na previsão de parâmetros constitutivos, representando o comportamento do solo; e por métodos diretos, onde os resultados do ensaio SPT são aplicados diretamente na previsão da capacidade de carga (por exemplo os Métodos de Aoki-Velloso, 1975, e Décourt-Quaresma, 1978) ou estimativa do recalque de um elemento de fundação, sem a necessidade de determinar parâmetros intermediários. (Schnaid e Odebrech, 2012)

1.3 Métodos de Previsão de Capacidade de Carga em estacas

A capacidade de carga do sistema solo-estaca é o máximo carregamento que o sistema pode suportar, sem que ocorra a ruptura do solo, recalques excessivos na estrutura ou danos estruturais na estaca. A capacidade de carga de projeto é obtida através da carga de ruptura dividida pelo fator de segurança adotado. Também pode ser adotada como sendo a carga que gera o recalque máximo permitido em uma construção.

De acordo com Velloso e Lopes (2010) uma fundação corretamente dimensionada deve apresentar simultaneamente segurança em relação aos possíveis modos de ruptura (atendimento aos estados limites últimos), bem como deslocamentos aceitáveis sob carga de serviço (atendimento aos estados limite de utilização). Portanto em um projeto de uma fundação deve-se verificar a segurança

com relação a perda da capacidade de carga, pois este é um dos principais modos de colapso.

A estimativa da capacidade de carga de uma estaca isolada pode ser feita por fórmulas estáticas (teóricas ou empíricas e semi-empíricas), fórmulas dinâmicas, ou provas de carga. Existem várias teorias de estimativa de capacidade de carga, devidas a diferentes autores.

A capacidade de carga (R) de um sistema solo-estaca depende do tipo de solo onde a estaca está instalada, do tipo de sua execução, da sua seção transversal e de seu comprimento, e é constituída de duas parcelas de resistência: a resistência lateral (R_L) e a resistência de ponta (R_p), conforme Equação (3) e Figura 5.

$$R = R_L + R_p \quad (3)$$




Figura 5 – Parcelas de resistência que constituem a capacidade de carga (Cintra e Aoki, 2010)

Para a aplicação dos Métodos Teóricos é necessário o conhecimento das propriedades geotécnicas do solo do local tais como coesão, ângulo de atrito, módulo de elasticidade, etc. e para os Métodos Empíricos e Semi-empíricos, dados de ensaios de campo ou dados de cravação da estaca.

De acordo com Danziger (2017), a diferença entre os métodos teóricos e os empíricos e semi-empíricos é que no caso dos teóricos, o atrito lateral unitário e a

resistência de ponta unitária (ambos em unidade de tensão) são obtidos através de princípios de Mecânica dos Solos, mostrando seu comportamento teórico na ruptura ou sob a carga de serviço.

A principal dificuldade de aplicação dos métodos teóricos consiste na estimativa de parâmetros geotécnicos das diversas camadas do terreno atravessadas pelas estacas com base nas investigações geotécnicas usuais, no caso do Brasil, quase sempre apenas as sondagens a percussão, tornando-se necessárias correlações para se obter propriedades geotécnicas do solo do local tais como coesão, ângulo de atrito, módulo de elasticidade, etc.

Os métodos empíricos e semi-empíricos utilizam os valores obtidos diretamente dos ensaios de campo para estimativa do atrito lateral unitário e a resistência de ponta unitária, ou seja, sem passar pelos parâmetros geotécnicos, sendo os mais comuns os ensaios SPT e CPT.

Os principais métodos empíricos e semi-empíricos de estimativa de capacidade de carga de estaca utilizados no Brasil são os fundamentados no SPT, sendo os mais utilizados os seguintes: Método de Aoki e Velloso (1975); Método de Pedro Paulo da Costa Velloso (1981) e Método de Décourt e Quaresma (1978) modificado por Décourt (1996). Estes métodos serão detalhados abaixo, além do Método da UFRGS, desenvolvido por Lobo (2005), pois foram utilizados na presente dissertação o banco de dados de sondagens e de provas de carga empregados para elaboração desse método.

1.3.1 Método de Aoki e Velloso (1975)

O método de Aoki e Velloso (1975) foi primeiramente desenvolvido com valores obtidos do ensaio de penetração de cone in situ (CPT). Posteriormente foi adaptado para ser utilizado com os valores N obtidos do SPT. Como o método é brasileiro e a sondagem de simples reconhecimento de solo (SPT) no Brasil é mais utilizado, o método com a formulação baseada no SPT torna-se mais usual (Cintra e Aoki, 2010).

A capacidade de carga da estaca (Q_T) pode ser calculada pela Equação (4).

$$Q_T = Q_P + Q_L = q_u A_p + U \sum f_u \Delta_l \quad (4)$$

sendo:

Q_P = parcela de resistência de ponta;

Q_L = parcela de resistência por atrito lateral ao longo do fuste;

q_u = Tensão limite normal no nível da ponta;

A_p = área da seção transversal na ponta da estaca;

U = perímetro da seção transversal do fuste;

f_u = Tensão limite de cisalhamento ao longo do fuste;

Δ_l = espessura da camada de solo.

Os valores de q_u e f_u são calculados a partir do valor de N do ensaio SPT, através da Equação (5) e Equação (6), respectivamente.

$$q_u = \frac{C_{AV} N_p}{F_1} \quad (5)$$

$$f_u = \frac{\alpha_{AV} C_{AV} N_l}{F_2} \quad (6)$$

sendo:

F_1 e F_2 = fatores de correção;

C_{AV} = coeficiente que depende do tipo de solo;

α_{AV} = razão de atrito;

N_p = índice médio de resistência à penetração na cota de apoio da estaca;

N_l = índice médio de resistência à penetração na camada de solo de espessura Δ_l ;

Substituindo as Equações (5) e (6) na Equação (4), a capacidade de carga de uma estaca pode ser estimada pela fórmula semi-empírica dada pela Equação (7).

$$Q_T = \frac{C_{AV} N_p}{F_1} A_p + \frac{U}{F_2} \sum \alpha_{AV} C_{AV} N_l \Delta_l \quad (7)$$

Os coeficientes F_1 e F_2 são fatores de correção e determinados em função do tipo de estaca, seus valores são mostrados na Tabela 3.

Tabela 3 – Fatores de correção de F_1 e F_2 (Cintra e Aoki, 2010)

Tipo de Estaca	F_1	F_2
Franki	2,50	$2 \cdot F_1$
Metálica	1,75	$2 \cdot F_1$
Pré-moldada de concreto	$1 + (D/0,8)$	$2 \cdot F_1$
Escavada	3,00	$2 \cdot F_1$
Raiz, Hélice Contínua e Ômega	2,00	$2 \cdot F_1$

C_{AV} e α_{AV} foram propostos com base na experiência e em valores da literatura, são determinados em função do tipo de solo os valores se encontram na Tabela 4.

Tabela 4 – Coeficientes C_{AV} e α_{AV} (Cintra e Aoki, 2010)

Solo	C_{AV} [MPa]	α_{AV} [%]
Areia	1,00	1,40
Areia Siltosa	0,80	2,00
Areia Silto argilosa	0,70	2,40
Areia Argilosa	0,60	3,00
Areia Argilo siltosa	0,50	2,80
Silte	0,40	3,00
Silte Arenoso	0,55	2,20
Silte Areno argiloso	0,45	2,80
Silte Argiloso	0,23	3,40
Silte Argilo arenoso	0,25	3,00
Argila	0,20	6,00
Argila Arenosa	0,35	2,40
Argila Areno siltosa	0,30	2,80

Solo	C_{AV} [MPa]	α_{AV} [%]
Argila Siltosa	0,22	4,00
Argila Silto arenosa	0,33	3,00

1.3.2 Método de Décourt e Quaresma (1978) modificado por Décourt (1996)

Este método fundamenta-se nos valores de N obtidos pelo ensaio de penetração (SPT) ou N_{eq} pelo ensaio de penetração com medida de torque (SPT-T), e foi desenvolvido inicialmente para estacas de deslocamento, mas pode ser utilizado também para outros tipos de estacas (Décourt, 1998).

A carga de ruptura da estaca (Q_T) pode ser calculada pela Equação (8).

$$Q_T = \alpha_{DEC} C_{DEC} N_p A_p + \beta_{DEC} 10 \left(\frac{N_L}{3} + 1 \right) U \Delta_l \quad (8)$$

sendo:

N_p = valor médio do índice de resistência à penetração na ponta ou base da estaca, obtido a partir de três valores: o correspondente ao nível da ponta ou base, o imediatamente anterior e o imediatamente posterior;

C_{DEC} = coeficiente característico do solo ajustado por meio de 41 provas de carga realizadas em estacas pré-moldadas de concreto;

α_{DEC} = fator aplicado à parcela de ponta, de acordo com o tipo de solo e o tipo de estaca;

N_L = índice médio de resistência à penetração ao longo do fuste;

β_{DEC} = fator aplicado à parcela de atrito lateral de acordo com o tipo de solo e o tipo de estaca;

A_p = área da seção transversal na ponta da estaca;

U = perímetro da seção transversal do fuste;

Δ_l = espessura da camada de solo.

Décourt (1996) introduziu os coeficientes α_{DEC} e β_{DEC} na equação original para viabilizar a sua utilização no caso de estacas escavadas e demais tipos de estacas (Cintra e Aoki, 2010).

O valor de N_L é obtido fazendo-se a média dos índices de resistência à penetração do SPT ao longo do fuste da estaca, sem considerar os valores que serão utilizados na resistência de ponta, respeitando o limite de $3 \leq N_L \leq 15$ para estacas Strauss e tubulões a céu aberto e o limite de $3 \leq N_L \leq 50$ para estacas escavadas com bentonita e estacas de deslocamento (Cintra e Aoki, 2010).

Na Tabela 5 são apresentados os valores de C_{DEC} e na Tabela 6 e Tabela 7 os valores de α_{DEC} e β_{DEC} , respectivamente.

Tabela 5 – Parâmetros C_{DEC} (Décourt, 1978)

Tipo de Solo	C_{DEC} [kPa] de acordo com tipo de estaca	
	Deslocamento	Escavada
Argila	120	100
Silte Argiloso	200	120
Silte Arenoso	250	140
Areia	400	200

Tabela 6 – Fator α_{DEC} (Décourt, 1996)

Tipo de Solo	Tipo de estaca - α_{DEC}				
	Escavada em geral	Escavada (bentonita)	Hélice contínua	Raiz	Injetada sob altas pressões
Argila	0,85	0,85	0,3	0,85	1
Solos intermediários	0,60	0,60	0,3	0,60	1
Areias	0,50	0,50	0,3	0,50	1

Tabela 7 – Fator β_{DEC} (Décourt, 1996)

Tipo de Solo	Tipo de estaca - β_{DEC}				
	Escavada em geral	Escavada (bentonita)	Hélice contínua	Raiz	Injetada sob altas pressões
Argila	0,80	0,90	1	1,5	3
Solos intermediários	0,65	0,75	1	1,5	3
Areias	0,50	0,60	1	1,5	3

1.3.3 Método de Pedro Paulo da Costa Velloso (1981)

Inicialmente o método de Pedro Paulo da Costa Velloso (1981) foi desenvolvido com os resultados do CPT na estimativa da capacidade de carga do sistema solo-estaca. Porém, o autor sugere correlações que permitem o uso dos resultados do SPT. A capacidade de carga da estaca (Q_T) pode ser calculada pela Equação (9).

$$Q_T = \alpha_{ppv} \beta_{ppv} q_u A_P + \alpha_{ppv} \lambda U \sum f_u \Delta_{li} \quad (9)$$

sendo:

α_{ppv} = fator de execução da estaca (1,0 para estaca escavada e 0,5 para estaca cravada);

q_u = resistência média de ponta;

λ = fator de carregamento da estaca (1,0 para estaca compressão e 0,7 para tração);

U = perímetro do segmento i do fuste da estaca;

f_u = atrito lateral médio;

Δ_{li} = comprimento do segmento i do fuste da estaca;

β_{ppv} = fator de carga de ponta em função da dimensão da ponta da estaca, que relaciona o modelo do cone ao comportamento da estaca. Para estaca comprimida é dado pela Equação (10).

$$\beta_{ppv} = 1,016 - 0,016 \frac{D}{d} \quad (10)$$

sendo:

d = diâmetro da ponta do cone CPT (3,6 cm no cone padrão);

D = diâmetro do fuste.

Os valores de q_u e f_u são calculados a partir do valor de N do ensaio SPT através das Equações (11) e (12), respectivamente.

$$q_u = \frac{a N_1^b + a N_2^b}{2} \quad (11)$$

$$f_u = a' \Delta N_i^{b'} \quad (12)$$

sendo:

N_1 = valor médio de N_{SPT} , calculado desde a cota da ponta da estaca até dois diâmetros acima da mesma;

N_2 = valor médio de N_{SPT} , calculado desde a cota da ponta da estaca até um diâmetro abaixo da mesma;

N_i = valor de N_{SPT} correspondente à camada i ;

a, b, a', b' = parâmetros de correlação entre o SPT e o CPT, os valores encontram-se na Tabela 8.

Tabela 8 – Valores aproximados de a, b, a', b' (adaptado de Velloso, 1981)

Tipo do Solo	Ponta		Atrito	
	a [kPa]	b	a' [kPa]	b'
Areias sedimentares submersas ⁽¹⁾	600	1	5,0	1
Argilas sedimentares submersas ⁽¹⁾	250	1	6,3	1
Solos residuais de gnaiss arenoso-siltosos submersos ⁽¹⁾	500	1	8,5	1
Solos residuais de gnaiss siltosos-arenosos submersos	400 ⁽¹⁾	1 ⁽¹⁾	8,0 ⁽¹⁾	1 ⁽¹⁾
	470 ⁽²⁾	0,96 ⁽²⁾	12,1 ⁽²⁾	0,74 ⁽²⁾

⁽¹⁾ Dados obtidos na obra na Refinaria de Duque de Caxias – RJ;
⁽²⁾ Dados obtidos na obra de AÇO – MINAS (MG).

1.3.4 Método da UFRGS, Lobo (2005)

O método da UFRGS foi proposto por Lobo (2005), que utilizou conceitos de conservação da energia e estabeleceu uma relação entre a força de reação dinâmica do solo à cravação do amostrador SPT e a capacidade de carga do sistema solo-estaca (Q_T), através da Equação (13).

$$Q_T = \beta_{UFRGS} 0,7 F_d \frac{A_p}{a_p} + \alpha_{UFRGS} \frac{0,2 U}{a_l} \sum F_d \Delta_l \quad (13)$$

sendo:

β_{UFRGS} = coeficiente de ajuste aplicado para resistência de ponta;

A_p = área da ponta ou base da estaca;

a_p = área de ponta do amostrador SPT (20,4 cm²);

α_{UFRGS} = coeficiente de ajuste aplicado para resistência lateral;

a_l = área lateral total do amostrador SPT (externa + interna = 810,5 cm²);

Δ_l = espessura de cada camada de solo considerado;

U = perímetro do segmento do fuste da estaca;

F_d = variação da energia potencial.

Para o cálculo da variação da energia potencial (F_d), deve-se utilizar a Equação (14).

$$F_d = \frac{\eta_3[\eta_1(0,75 + \Delta\rho) M_m g + \eta_2 \Delta\rho M_h g]}{\Delta\rho} \quad (14)$$

sendo:

η_1 = eficiência do golpe = 0,764;

η_2 = eficiência das hastes = 1;

η_3 = eficiência do sistema = $(0,0907 - 0,0066z)$;

z = comprimento da haste que penetrou no solo (m);

M_m = massa do martelo (kg);

M_h = massa da haste (3,23 kg/m);

g = aceleração da gravidade (m/s²);

$\Delta\rho$ = penetração do golpe = $30/N_{SPT}$ (m/golpes)

Os coeficientes de ajuste α_{UFRGS} e β_{UFRGS} (Tabela 9) foram obtidos a partir da análise comparativa e da correlação estatística entre os resultados gerados pelo método da UFRGS, Lobo (2005). Para análise foi utilizado um banco de dados composto de 328 provas de carga à compressão e 43 provas de carga à tração, executadas em diferentes tipos de estaca como: cravadas metálicas, cravadas pré-moldadas, hélice contínua e escavadas.

Tabela 9 – Coeficientes de ajuste α_{UFRGS} e β_{UFRGS} (Lobo, 2005)

Tipo de Estaca	α_{UFRGS}	β_{UFRGS}
Cravada pré-moldada	1,50	1,10
Cravada metálica	1,00	1,00
Hélice contínua	1,00	0,60
Escavada	0,70	0,50

1.4 Provas de Carga

Segundo Albuquerque (2001), as provas de carga utilizadas em geotecnia para se estudar o comportamento estaca-solo, verificam aspectos importantes como

a capacidade de carga e os deslocamentos do elemento de fundação, e, ainda, no caso de estacas instrumentadas a transferência de carga em profundidade.

A execução de provas de carga com fins geotécnicos se justifica como ensaio de controle de qualidade de execução nos casos onde se busca avaliar a integridade estrutural do elemento de fundação e quando se procura a garantia de não ruptura do elemento estrutural, para uma determinada carga de trabalho. Os resultados das provas de carga podem ser usados para avaliar os parâmetros adotados nos projetos, na previsão de recalques ou nos casos onde se busca determinar a carga de ruptura. São usados, também, quando se procura determinar o comportamento carga x deslocamento de um elemento de fundação, e especialmente para a região da carga de trabalho.

As provas de cargas em estacas podem ser classificadas em:

- Prova de carga estática em estacas e tubulões, normatizada através da NBR 12131 (2006), que trata sobre: Estacas – Prova de carga estática – Método de ensaio;
- Ensaio de carregamento dinâmico em estacas, com suas disposições previstas na NBR 13208 (2007), que refere-se sobre: Estacas – Ensaio de carregamento dinâmico.

As provas de carga podem ser feitas com cargas verticais ou inclinadas, à compressão ou tração, cargas horizontais ou qualquer tipo de solicitação, procurando reproduzir as condições de funcionamento da fundação a que se destinam (Albuquerque, 2001).

Segundo Milititsky (1991), as provas de carga constituem técnica insubstituível para o estudo e determinação do comportamento de fundações profundas sob carga, devendo reproduzir, da forma mais próxima, as condições reais da fundação, não somente no que se refere à geometria ou técnica construtiva, mas ao tipo de carregamento real da estrutura.

A NBR 6122 (2010) determina a obrigatoriedade de execução de provas de carga estáticas, conforme NBR 12313 (2006), em obras que tiverem o número de estacas maiores que o valor especificado na coluna (B) da Tabela 10, sempre executadas no início da obra. A quantidade de provas de carga estáticas deverá corresponder a, no mínimo, 1% da quantidade total de estacas, arredondando-se sempre para mais. Torna-se obrigatório, seguindo a mesma norma, se as estacas forem empregadas para valores de tensões médias (em termos de tensões

admissíveis) maiores que a coluna (A) da Tabela 10, independentemente do número de estacas projetadas para a obra.

Tabela 10 – Quantidade de provas de carga (NBR6122, 2010)

Tipo de Estaca	A Tensão (admissível) máxima abaixo da qual não serão obrigatórias provas de carga, desde que o número de estacas da obra seja inferior à coluna (B) em MPa ^{b c d}	B Número total de estacas da obra a partir do qual serão obrigatórias provas de carga ^{b c d}
Pré-moldada ^a	7,0	100
Madeira	-	100
Aço	0,5 f _{yk}	100
Hélice e hélice de deslocamento (monitoradas)	5,0	100
Escavadas com ou sem fluido (φ ≥ 70 cm)	5,0	75
Raiz ^e	15,5	75
Microestaca ^e	15,5	75
Trado Segmentado	5,0	50
Franki	7,0	100
Escavadas sem fluido (φ < 70 cm)	4,0	100
Strauss	4,0	100

^a Para o cálculo da tensão (admissível) máxima consideram-se estacas vazadas como maciças, desde que não exceda 40 % da seção total.

^b Os critérios acima são válidos para as seguintes condições (não necessariamente simultâneas):

- Áreas onde haja experiência prévia com o tipo de estaca empregado.
- Onde não houver particularidades geológico-geotécnicas.
- Quando não houver variação do processo executivo padrão.
- Quando não houver dúvida quanto ao desempenho das estacas.

^c Quando as condições acima não ocorrerem devem ser feitas provas de carga em no mínimo 1 % das estacas, observando-se um mínimo de uma prova de carga (conforme ABNT NBR 12131), qualquer que seja o número de estacas.

^d As provas de carga executadas exclusivamente pra avaliação de desempenho devem ser levadas até que atinja pelo menos 1,6 vez a carga admissível ou até que se observe um deslocamento que caracterize ruptura.

^e Diâmetros nominais.

A Tabela 10 se aplica a obras com até 500 estacas e em uma mesma região representativa do subsolo. Caso este número de estacas seja superior, a quantidade de provas de carga adicionais fica a critério do projetista.

Os ensaios de carregamento dinâmicos podem substituir as provas de carga estáticas na proporção 5:1, ou seja, cinco ensaios dinâmicos para cada prova de carga prevista pela Tabela 10, desde que o número de estacas na obra esteja compreendido entre os valores da coluna (B), da Tabela 10, e duas vezes estes valores. Acima deste número de estacas se torna obrigatório pelo menos uma prova de carga estática.

O resultado da execução das provas de carga é considerado satisfatório quando forem verificadas simultaneamente as duas condições abaixo:

- 1) Fator de Segurança mínimo com relação à ruptura obtida na prova de carga ou por extrapolação igual a 2,0;
- 2) Recalque verificado na carga de trabalho compatível com a estrutura.

Caso o resultado das provas de carga não atendam simultaneamente os itens acima mencionados, ou seja, considerado insatisfatório, deverá ser realizado um novo programa de provas de carga adicionais para um reexame das cargas admissíveis ou resistentes de projeto, com o objetivo final a readequação da fundação e seu eventual reforço ou aceitação dos serviços sob condições especiais previamente definidas.

1.4.1 Prova de Carga Estática

De acordo com a NBR 12131 (2006), o objetivo da prova de carga estática em estacas é fornecer elementos para avaliar o comportamento carga x deslocamento.

O princípio básico da prova de carga estática é a aplicação de sucessivos estágios de carregamentos axiais estáticos, de tração, compressão ou transversal, de forma controlada à estaca e o registro dos deslocamentos correspondentes (recalques). Para aplicar a carga é necessário utilizar um sistema de reação para que se possa efetuar o carregamento da estaca teste.

Segundo Niyama et al. (1998), uma grande vantagem da prova de carga estática é consistir em um ensaio onde se repercute o complexo comportamento do conjunto solo-fundação; influenciado pela modificação provocada no solo pelos

trabalhos de infraestrutura da obra e execução das fundações, e pelas incertezas decorrentes das dificuldades executivas das fundações.

De acordo com Albuquerque (2001), neste tipo de ensaio o estudo estatístico raramente é feito, tendo em vista que não se consegue abranger um número significativo de elementos, pois toda uma estrutura é necessária para a realização de uma prova de carga estática, incluindo o custo e o tempo. Mas, apesar de todas estas dificuldades, este procedimento ainda é a melhor maneira de se comprovar o desempenho (resistência limite) de uma fundação isolada, principalmente se for profunda, do tipo estaca ou tubulão.

Em uma prova de carga estática a aplicação do carregamento se dá através de um ou mais macacos hidráulicos alimentados por bombas elétricas ou manuais, atuando contra um sistema de reação estável.

O sistema de reação para provas de carga estáticas à compressão, pode ser:

- a) Plataforma carregada (ou Cargueira), Figura 6. A plataforma deverá ser sustentada por cavaletes ou “fogueiras”, projetadas no terreno de forma a garantir estabilidade e condições adequadas de segurança ao conjunto. E deverá ser carregada com material cuja massa total supere em pelo menos 20% a carga máxima prevista para o ensaio;




Figura 6 – Plataforma carregada ou cargueira (Velloso e Lopes, 2010)

- b) Conjunto de Estacas definitivas, ou somente para atender o ensaio, dimensionadas com capacidade de carga a tração pelo menos 50% maior que a máxima carga prevista para a prova de carga Figura 7;




Figura 7 – Conjunto de Estacas definitivas, ou somente para atender o ensaio (Velloso e Lopes, 2010)

- c) Conjunto de tirantes ancorados, com Fator de Segurança 1,2, caso os tirantes sejam ensaiados antes da realização da prova de carga e, caso contrário, deverão ser projetados para suportar pelo menos 1,5 vezes a carga máxima prevista para cada tirante Figura 8;




Figura 8 – Conjunto de tirantes ancorados (Velloso e Lopes, 2010)

- d) A própria estrutura, desde que dimensionada também para todas as solicitações impostas pela prova de carga.

A medida da carga pode ser realizada com o auxílio de um manômetro instalado na saída da bomba ou por uma célula de carga, o que garante uma maior precisão das leituras.

As leituras de recalque, em cada estágio, são realizadas empregando-se extensômetros convenientemente instalados nos cantos do bloco de coroamento da estaca. A média aritmética de suas leituras representa o recalque da estaca.

Como resultado do ensaio, obtém-se a curva carga x recalque, conforme Figura 9, na qual pode-se observar que P é a carga aplicada no topo da estaca

teste, representada no eixo das abscissas, e ρ é o recalque do topo da estaca, representado no eixo das ordenadas. A curva passa pelos pontos finais de cada estágio de carregamento (deslocamentos estabilizados).

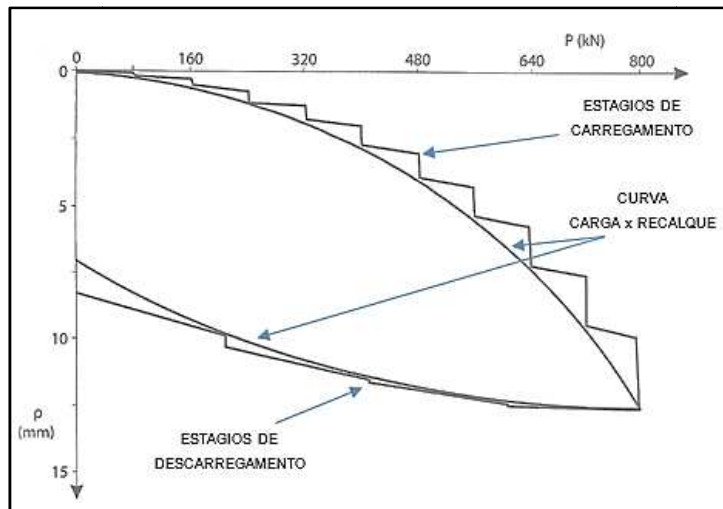


Figura 9 – Curva carga x recalque com a representação dos estágios de carregamento e descarregamento (adaptado de Cintra et al., 2013)

Na execução da prova de carga estática, a estaca teste é carregada até a ruptura ou até duas vezes a carga de trabalho, e pode ser realizada com Carregamento Lento, Rápido, Misto, Cíclico Lento ou Cíclico Rápido. No entanto, a grande maioria das provas de carga estáticas são descarregadas sem atingir a ruptura.

O modo de aplicação do carregamento (Lento, Rápido, Misto, Cíclico Lento ou Cíclico Rápido) está descrito na NBR 12131 (2006). A seguir, serão expostos sucintamente os dois modos mais utilizados no Brasil.

- Carregamento Lento:
 - a) Os carregamentos devem ser feitos em estágios iguais e sucessivos;
 - b) O carregamento aplicado em cada estágio não deve ser superior a 20% da carga de trabalho prevista para a estaca teste;
 - c) Em cada estágio, deve-se manter a carga até a estabilização dos deslocamentos (recalques) no tempo mínimo de 30 minutos;
 - d) Em todos os estágios, depois de cada aplicação de carga, os deslocamentos devem ser lidos nos tempos de 2 min, 4 min, 8 min, 15

min, 30 min, 1 h, 2 h, 3 h, 4 h, etc., contados a partir do início do estágio, até se atingir a estabilização;

- e) A estabilização dos deslocamentos ocorre quando a diferença entre duas leituras consecutivas correspondem a, no máximo, 5% do deslocamento ocorrido no mesmo estágio (deslocamento do estágio anterior e o atual);
 - f) Quando se atinge a carga máxima do ensaio, esta deve ser mantida durante 12 h entre a estabilização dos deslocamentos e o início do descarregamento;
 - g) O descarregamento deve ser efetuado em pelo menos quatro estágios. Cada estágio é mantido até a estabilização dos deslocamentos de acordo com os itens d) e e). O tempo mínimo de cada estágio deve ser de 15 minutos;
 - h) Após o descarregamento total, as leituras dos deslocamentos devem continuar até a sua estabilização.
- Carregamento Rápido:
 - a) Os carregamentos devem ser feitos em estágios iguais e sucessivos;
 - b) O carregamento aplicado em cada estágio não deve ser superior a 10% da carga de trabalho;
 - c) Independentemente da estabilização dos deslocamentos (recalques), cada estágio de carregamento deve ser mantido por 10 min. Em fundações de torres de transmissão de energia este tempo pode ser reduzido para 5 min;
 - d) Obrigatoriamente os deslocamentos deverão ser lidos no início e fim de cada estágio;
 - e) Quando se atinge a carga máxima do ensaio, esta deve ser mantida e efetuadas cinco leituras de deslocamentos nos tempos 10 min, 30 min, 60 min, 90 min e 120 min, para depois proceder o início do descarregamento, em no mínimo cinco estágios. Cada etapa deve ser mantida por 10 min, com a leitura dos respectivos deslocamentos;
 - f) Após o descarregamento total, devem ser realizadas duas leituras adicionais de recalques, aos 40 min e 70min.

A vantagem da prova de carga lenta consiste no acompanhamento detalhado de cada etapa do ensaio, obtendo-se respostas mais delineadas na curva carga x recalque. A desvantagem está no grande tempo utilizado na execução ensaio, sendo necessário um revezamento de turno de equipes para o acompanhamento do mesmo.

A vantagem da prova de carga rápida consiste na grande economia de tempo comparada com a prova de carga lenta e a sua desvantagem é que os pontos da curva carga x recalque não são pontos estabilizados.

Nas provas de carga estáticas, a aplicação do carregamento mobiliza progressivamente a resistência do sistema estaca-solo, composta das parcelas de atrito lateral e resistência de ponta.

As provas de carga estáticas também podem ser classificadas em provas de carga comuns e provas de carga instrumentadas.

Em uma prova de carga estática comum, os dados obtidos no ensaio mostram somente o deslocamento e a carga aplicada no topo da estaca teste, resultando em uma curva carga x recalque, em que se pode observar na realidade uma curva resistência total x recalque, sem que seja possível distinguir a parcela de atrito lateral ao longo do fuste e a resistência de ponta da estaca. Este tipo de prova de carga é a mais utilizada na maior parte das provas de carga estáticas realizadas.

Em provas de carga instrumentadas, o objetivo da instrumentação é obter a informação da distribuição de tensões e deformações ao longo do fuste e na ponta da fundação. Com isso, obtém-se a resistência lateral e a resistência de ponta da estaca em cada estágio de carregamento da estaca teste, podendo-se gerar um diagrama de transferência de carga, e auxiliar na definição de critérios de ruptura para aquelas provas de carga em estacas não instrumentadas.

As provas de carga estáticas instrumentadas mostram análises mais completas que os resultados das provas de carga estáticas e permitem avaliações mais confiáveis e precisas do comportamento da fundação.

Para medir os deslocamentos e as deformações, os instrumentos mais utilizados são os extensômetros elétricos de resistência (“*strain-gages*”) colados na armadura ou em hastes de aço inseridas na estaca. Pode-se utilizar outros instrumentos tais como: medidores de deslocamento em profundidade (“*tell-tales*”) ou extensômetros recuperáveis (ou removíveis).

Albuquerque (2001) ressalta que é necessário haver uma equipe especializada e conhecedora das técnicas de instrumentação e aquisição de dados para se executar uma prova de carga estática instrumentada. O emprego desta técnica está quase que restrito aos centros de pesquisa, sendo de extrema importância parcerias entre a comunidade acadêmica e empresas executoras para que as provas de carga utilizassem os recursos da instrumentação em profundidade.

As provas de carga estáticas em estacas (ou tubulões) são analisadas quase sempre apenas por meio das curvas carga x recalque, que mostram o valor da carga medida na cabeça da estaca, determinando assim o comportamento da fundação.

Segundo Niyama et al. (1998), a curva carga x recalque obtida em uma prova de carga em estacas isoladas pode ser dividida em três regiões, observadas na Figura 10.




Figura 10 – Regiões de um curva carga x recalque (Vargas, 1977 apud Melo 2009)

- I. A primeira região, denominada de região de deformação elástica, apresenta uma proporcionalidade entre as cargas e os recalques;
- II. A segunda é a de deformação visco plástica. Nesta região, a velocidade de carregamento influi muito sobre os recalques;
- III. A terceira corresponde à região de ruptura. É a parte da curva que define a carga de ruptura (Q_r), ou seja, quando o recalque aumenta indefinidamente com pequenos ou nenhum acréscimo de carga.

Na Engenharia Geotécnica, a ruptura física é considerada quando ocorre o colapso do elemento estrutural e/ou do maciço de solo que lhe dá suporte, causando

recalques excessivos para pequenos ou para nenhum incremento de carga (Amann, 2008).

De acordo com Alonso (2011), a curva carga x recalque pode delinear curvas diversas, que podem ser representadas de forma mais genérica através de duas formas, conforme a Figura 11.

- Ao atingir o valor Q_r , o recalque se torna contínuo, demonstrando uma ruptura nítida (Figura 11, curva a);
- A carga de ruptura não é claramente definida, representando uma ruptura convencional (Figura 11, curva b).




Figura 11 – Curvas carga x recalque (adaptado de Alonso, 2011)

De Beer (1988), ao analisar o comportamento de estacas, distingue dois tipos de ruptura, a ruptura física e a ruptura convencional. Define como ruptura física a carga Q_u correspondente ao limite da relação entre o acréscimo do recalque da ponta da estaca (Δr) e o acréscimo de carga (ΔQ), tendendo ao infinito, conforme Equação (15). E determina que a ruptura convencional é a carga correspondente a uma deformação da ponta da estaca de 10% do diâmetro para estacas cravadas, e de 25% a 30% do diâmetro para estacas escavadas.

$$Q_u = \frac{\Delta r}{\Delta Q} = \infty \quad (15)$$

De acordo com Décourt (1996), há grande dificuldade de definir “ruptura”, assim como as deformações necessárias para atingi-la.

Décourt et al. (1996), com base no Conceito de Rigidez, define ruptura física como a carga (Q_u) correspondente a um valor de rigidez nula, sendo a rigidez (RIG) a relação entre a carga aplicada (Q) e o recalque (r) correspondente, conforme Equação (16) e Equação (17).

$$Q_u = \lim_{r \rightarrow \infty} RIG \quad (16)$$

$$RIG = \frac{Q}{r} \rightarrow \infty \quad (17)$$

Segundo Décourt (2008), a rigidez nula corresponde a deformação infinita. Pode-se concluir, com base no conceito de rigidez, que a ruptura física nunca foi atingida, e portanto, se faz necessário definir a ruptura convencional, que, de acordo com Décourt (1996, 1998), no caso de estacas de seção circular, é a carga correspondente a uma deformação de 10% do seu diâmetro (para estacas de deslocamento e estacas escavadas em argila) e 30% do seu diâmetro (para estacas escavadas em solos granulares). E, para estacas com outro tipo de seção, considera-se um diâmetro equivalente (φ_{eq}), conforme Equação (18), sendo A a área da seção transversal da estaca.

$$\varphi_{eq} = \sqrt{\frac{4A}{\pi}} \quad (18)$$

Segundo a NBR 6122 (2010), em provas de carga executadas, as fundações profundas podem não apresentar ruptura nítida nas seguintes situações:

- Quando não se pretende levar as fundações profundas à ruptura;
- Quando a fundação profunda possui capacidade de resistir a uma carga maior que aquela a ser aplicada na prova de carga;

- Quando a fundação profunda é carregada até apresentar um recalque considerável, mas a curva carga x recalque não indica uma carga de ruptura, e sim um crescimento contínuo de recalque com a carga.

Quando a ruptura não é definida, seja pela interrupção da prova de carga por motivos de custo, prazo, sistema de reação insuficiente ou precaução, e para não danificar o elemento estrutural ensaiado, recomenda-se extrapolar a curva carga x recalque através de métodos de estimativa da capacidade de carga (Alonso, 2011).

Os métodos de estimativa da capacidade de carga a partir da curva carga x recalque de provas de carga estáticas mais utilizados no Brasil são os Métodos de Van der Veen (1953), Van der Veen (1953) modificado por Aoki (1976) ou método de Van der Veen generalizado, Décourt (1996) e Método da NBR 6122 (2010). A seguir, será descrito o Método da NBR 6122 (2010) e o Método de Van der Veen (1953) modificado por Aoki (1976), utilizados no banco de dados empregado no presente trabalho.

Método da NBR 6122 (2010)

Segundo o Método da NBR 6122 (2010), a capacidade de carga do sistema solo – estaca (ou tubulão) deve ser considerada definida quando houver a ruptura nítida, caracterizada por deformações contínuas, sem novos acréscimos de carga em uma prova de carga estática executada de acordo com a NBR 12131 (2006) (Figura 12).




Figura 12 – Método da NBR 6122 (NBR 6122, 2010)

Há duas circunstâncias em que a ruptura nítida não é alcançada: quando o sistema solo - estaca (ou tubulão) apresenta capacidade de carga superior à carga máxima aplicada na estaca, ou quando estaca (ou tubulão) for submetido a carregamentos até desenvolver recalques muito elevados, porém não característicos da ruptura nítida.

O Método da NBR 6122 (2010) propõe para os casos anteriores a extrapolação da curva carga x recalque para avaliar a carga de ruptura através do recalque calculado pela Equação (19).

$$\Delta_r = \frac{PL}{EA} + \frac{D}{30} \quad (19)$$

sendo:

Δ_r = recalque de ruptura convencional;

L = comprimento da estaca;

P = carga de ruptura convencional

D = diâmetro do círculo circunscrito à estaca ou no caso de barretes, o diâmetro do círculo de área equivalente ao da seção transversal desta;

A = área da seção transversal do fuste da estaca;

E = módulo de elasticidade do material da estaca.

De acordo com Campos (2005), o módulo de elasticidade (E) para estacas de concreto pode ser calculado utilizando procedimentos da Norma Brasileira que trata do Projeto de estruturas de concreto – Procedimento, NBR 6118 (2014), em função da resistência característica (f_{ck}), ou, na falta de informações, adotam-se valores conservadores de 20000 MPa (para estacas escavadas) e 25000 MPa (para estacas pré-moldadas).

O módulo de elasticidade E da estaca também pode ser obtido ao instalar *strain-gauges* no fuste, com o objetivo de medir deformações das estacas, sendo conhecida a tensão aplicada. Ao dividir a tensão aplicada pelo deslocamento medido, pode-se obter o módulo de elasticidade da estaca.

Com todos os parâmetros definidos em unidades compatíveis, e a partir de um valor arbitrário de carga (P), calcula-se o recalque (Δ) correspondente, obtendo um ponto ($P; \Delta$). Graficamente, por este ponto, plota-se a reta que corta o eixo dos

recalques em $(D/30)$. O ponto de interseção entre essa reta e a curva carga x recalque corresponde à carga de ruptura convencional.

Método de Van der Veen (1953) modificado por Aoki (1976)

Esse método é muito utilizado no Brasil, para extrapolar as curvas obtidas em provas de carga que não foram levadas à ruptura. Neste método, a carga de ruptura é determinada por tentativas através de uma equação matemática ajustada (função exponencial) em função do trecho que se dispõe da curva carga-recalque.

A Equação (20) define a carga de ruptura definida por Van der Veen (1953).

$$P = P_r(1 - e^{-ar}) \quad (20)$$

sendo:

P = carga nos diversos pontos da curva carga-recalque;

r = recalque nos diversos pontos da curva carga-recalque

a = parâmetro determinado por regressão linear que define a forma da curva;

P_r = valor de carga a ser determinado.

Com base na Equação (20), aplicando a propriedade dos logaritmos, e após algumas transformações é obtida a Equação (21).

$$ar = -\ln\left(1 - \frac{P}{P_r}\right) \quad (21)$$

A partir da Equação (21) é possível deduzir uma relação linear entre o valor $\ln\left(1 - \frac{P}{P_r}\right)$ e o recalque r . Partindo-se de um determinado valor qualquer de uma Carga de ajuste P_r adotada, calculam-se os valores correspondentes de $\ln\left(1 - \frac{P}{P_r}\right)$ que são plotados em um gráfico em função do recalque r ; A partir dessa etapa são realizadas novas tentativas com outros valores de P_r até que o gráfico resulte, aproximadamente, em uma linha reta, adotando-se este valor P_r como o valor de carga de ruptura do elemento. A curva que apresente o melhor coeficiente de correlação R^2 , proporcionará a carga de ruptura do ensaio, observado na Figura 13.

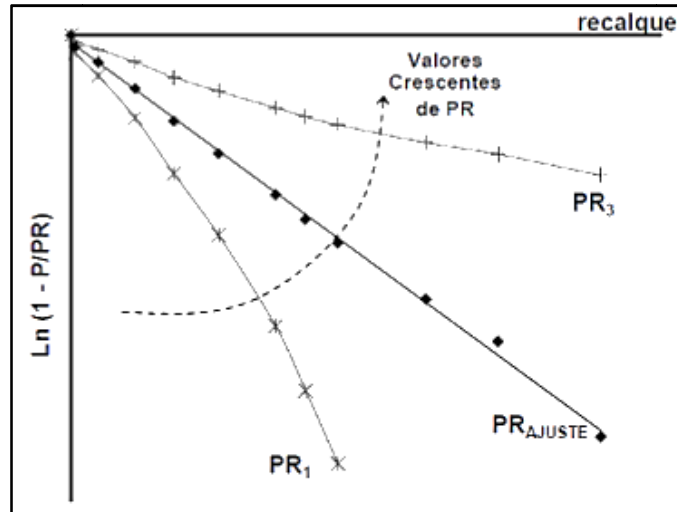


Figura 13 – Definição da carga de ajuste, Método de Van der Veen (1953)

Aoki 1976, apud Cintra e Aoki, 1999, observando que na maioria dos casos, o trecho inicial da curva poderia ser desprezado na determinação da capacidade de carga, sugeriu uma modificação da equação. A equação foi reescrita, Equação (22), dando a origem do método de Van der Veen generalizado ou Van der Veen (1953), modificado por Aoki (1976).

$$P = P_r(1 - e^{-(b+ar)}) \quad (22)$$

A curva ajustada (Figura 14) é obtida arbitrando-se valores para r e calculando os valores correspondentes para P . Ou seja, calcula-se o valor de $P = P_r(1 - e^{-(b+ar)})$, onde P corresponde ao recalque r . A partir da Equação (22), aplicando a propriedade dos logaritmos, e após algumas transformações é obtida a Equação (23).

$$ar + b = -\ln\left(1 - \frac{P}{P_r}\right) \quad (23)$$

A Equação (23) plotada conduz a uma reta, visualizada na Figura 14.




Figura 14 – Método de Van der Veen (1953), modificado por Aoki (1976)

De acordo com Décourt & Niyama (1994), o método de Van der Veen (1953) pode ser aplicado somente nas seguintes condições:

- Ensaios que atingiram pelo menos 2/3 da carga de ruptura;
- Estacas de deslocamento, pois os resultados da carga de ruptura em estacas escavadas são subestimados;
- Carregamento monotônico (carregamento crescente e aplicado uma única vez).

Danziger (2017) destaca que o método de Van Der Veen (1953) não deve ser aplicado quando a curva carga recalque apresenta comportamento tipicamente linear, indicando pouca mobilização da resistência de ponta.

Segundo Velloso e Lopes (2010), as extrapolações pelo método de Van der Veen (1953) são confiáveis apenas em casos que o recalque máximo alcançado na prova de carga for, no mínimo, 1% da largura “B” da estaca.

1.4.2 Ensaio de Carregamento Dinâmico

O Ensaio de Carregamento Dinâmico é um ensaio cujas disposições estão previstas na NBR 13208 (2007), com análise fundamentada na teoria da equação da onda unidimensional, e que tem como objetivo a avaliação das cargas mobilizadas na interface solo-estaca, eficiência do sistema de impacto, tensões de compressão e tração ao longo da estaca, integridade estrutural e características dinâmicas do sistema solo-estaca.

Niyama (1991) definiu a prova de carga dinâmica como um ensaio em que se aplica um carregamento dinâmico axial em uma estaca, a princípio de qualquer espécie, com o objetivo de obter a estimativa da capacidade de carga, através do emprego da equação de onda, durante o processo de cravação e recravação de uma estaca.

Para a execução do ensaio, o sistema de aplicação de impacto (martelo) deve possuir uma massa e energia potencial suficiente para gerar uma força de impacto capaz de provocar deslocamentos permanentes da ponta da estaca e mobilizar resistências das camadas de solo atravessadas pelo fuste da estaca. Uma representação do ensaio de carregamento dinâmico está apresentada na Figura 15.




Figura 15 – Representação do ensaio de carregamento dinâmico (Cintra et al., 2013)

Para o sistema de aquisição das respostas dinâmicas do ensaio, devem ser empregados transdutores e dispositivos que forneçam valores de:

- 1) deformação específica gerada ou de força aplicada;
- 2) aceleração ou velocidade ou deslocamento.

Todos resultados em função do tempo em uma seção transversal específica da estaca.

As medidas de velocidade podem ser obtidas a partir de acelerômetros, que são dispositivos usados para medir a aceleração própria de um sistema. A aceleração própria de um sistema é medida em relação a outro sistema em queda livre. Já as medidas de deformação podem ser convertidas em força, ao se utilizar no nível da instrumentação o valor da área da seção transversal da estaca e o

módulo de elasticidade dinâmico do material da estaca (E), obtido através da Equação (24).

$$E = \rho c^2 \quad (24)$$

sendo:

c = Velocidade de propagação da onda de choque (ou de tensão), característica do material constituinte da estaca;

ρ = Massa específica do material da estaca, calculada através da Equação (25).

$$\rho = \frac{\gamma}{g} \quad (25)$$

sendo:

γ = peso específico da estaca;

g = aceleração da gravidade.

No momento do ensaio, a velocidade de onda utilizada para a determinação do módulo de elasticidade dinâmico (E) deve ser verificada e calibrada em função da proporcionalidade dos sinais de força e velocidade multiplicada pela impedância (Z) e se possível, em função da reflexão da onda de impacto na ponta da estaca no tempo (T), conforme Equações (26) e (27).

$$Z = \frac{EA}{c} = \rho c A = A \sqrt{E\rho} \quad (26)$$

$$T = \frac{2L}{c} \quad (27)$$

sendo:

A = área da seção transversal da estaca no nível da instalação dos transdutores;

L = comprimento da estaca, entre o nível de instalação dos transdutores e a ponta da estaca.

Os ensaios de carregamento dinâmico podem ser realizados na cravação e/ou recravação, no caso de estacas cravadas e após no mínimo sete dias de instalação de estacas moldadas *in loco*. Sendo uma importante forma de avaliar a cicatrização (“*set-up*”) e a relaxação, a recuperação e a perda de resistência que ocorrem em determinados solos com a cravação das estacas, respectivamente.

A utilização dos ensaios de carregamento dinâmico podem ter como objetivo a averiguação da carga mobilizada nas condições mais próximas as que se verificarão durante a vida útil da estaca, desde que realizadas após o processo de instalação da estaca, em tempo suficiente para que ocorram as variações de resistência do solo devido a perturbação do terreno gerada pelo processo executivo, seja para estacas cravadas seja para moldadas no local.

Para a avaliação da capacidade de carga da estaca, o ensaio de carregamento dinâmico pode ser feito de forma que a energia de cravação seja constante ou crescente, ou seja, de forma constante quando a aplicação dos golpes com energia constante (altura de queda igual em todos os golpes) ou ligeiramente maior que a aplicada no final da cravação; e de energia crescente, quando a aplicação dos golpes for com alturas de quedas variáveis de forma crescente a partir de um nível de energia inferior ao final da cravação, com sistema de impacto de queda livre. Quando utilizado o sistema de energia crescente, recomenda-se o traçado da curva carga mobilizada x deslocamento dinâmico máximo de cada golpe do ensaio, devendo-se calibrar as resistências através da análise numérica tipo CAPWAP®.

Independentemente das medições adquiridas por meio da instrumentação dinâmica, devem ser verificadas obrigatoriamente a correspondência entre golpes, alturas de queda e os valores das penetrações permanentes (valores das negas). O traçado do repique elástico para cada golpe aplicado no nível do topo da estaca durante o ensaio também pode ser obtido afim de atender as condições de segurança.

De acordo com a NBR 13208 (2007) o ensaio de carregamento dinâmico pode ser paralisado diante das seguintes situações:

- a) Ruptura do sistema na interface solo-estaca ou rocha-estaca;
- b) Quando se alcançar níveis de tensões dinâmicas de compressão e/ou de tração próximas às resistências características do material constituinte da estaca;

- c) Ao se atingir o Fator de Segurança preconizado pela NBR 6122 (2010) em relação à carga de trabalho especificado em projeto;
- d) Iminente dano estrutural ou comprovação do mesmo;
- e) Condições de segurança insatisfatórias, não admitindo a continuação do ensaio.

Os procedimentos para o registro, interpretação e avaliação dos resultados obtidos através da instrumentação devem ser fundamentados na Teoria de Propagação da onda unidimensional.

Na execução do ensaio de carregamento dinâmico, são fornecidos através do método simplificado CASE[®], a cada golpe à estaca, a carga mobilizada na interface solo-estaca, as tensões dinâmicas máximas de compressão e de tração, e a integridade estrutural da estaca.

Para a avaliação da capacidade de carga da estaca através do ensaio de carregamento dinâmico, pode-se fazer uso de duas metodologias, uma é o método simplificado, do tipo CASE[®], e a outra é a análise rigorosa, do tipo CAPWAP[®].

Teoria da onda unidimensional

A partir da Teoria da onda unidimensional, ou Teoria da Equação da Onda, desenvolvida por Smith (1960), a análise de capacidade de carga de estacas passou a ser feita através do ensaio de carregamento dinâmico.

Para a interpretação do ensaio de carregamento dinâmico, utilizando a Teoria da propagação da onda unidimensional, considera-se que ao aplicar um carregamento dinâmico no sistema estaca-solo, o impacto do martelo gera uma onda de tensão descendente na estaca, e que a resistência por atrito lateral ou mudança de seção transversal da estaca (área, peso específico ou resistência) provoca reflexões ascendentes de ondas de tensão. Estas ondas de tensão podem ser avaliadas durante o ensaio, por meio de medidas de força (através de medidas de deformação convertidas em força) e de velocidade (através de acelerômetros) em seção instrumentada na estaca.

A equação da onda é uma equação diferencial envolvendo derivadas parciais de segunda ordem. No caso particular de se aplicar um golpe de um martelo com peso W caindo de uma altura H à uma estaca sem resistência ao longo do fuste, a equação da onda aplicada é dada pela Equação (28).

$$c^2 \cdot \frac{\partial^2 u}{\partial x^2} - \frac{\partial^2 u}{\partial t^2} = 0 \quad (28)$$

sendo:

x = posição da seção transversal da estaca;

u = deslocamento;

t = instante de tempo;

c = velocidade de propagação da onda de tensão, dada pela Equação (29), advinda da Equação (24);

$$c = \sqrt{\frac{E}{\rho}} \quad (29)$$

E = módulo de elasticidade do material da estaca;

ρ = massa específica do material da estaca.

Pode-se concluir através da Equação (29), que a velocidade de propagação da onda de tensão c , é uma constante que depende unicamente das propriedades do material da estaca.

A solução geral da Equação (28) é dada pela Equação (30).

$$u(x, t) = f(x - ct) + g(x + ct) = u \downarrow + u \uparrow \quad (30)$$

As funções $f(x - ct)$ e $g(x + ct)$ representam as ondas descendente ($u \downarrow$) e ascendente ($u \uparrow$), respectivamente, que se sobrepõem com a mesma velocidade de propagação da onda de tensão c , entretanto em sentidos opostos, conforme Figura 16.




Figura 16 – Representação da solução da equação da onda (Gonçalves et al. 2000 apud Cintra et al. 2013)

De forma simplificada através da Equação (30) é possível se obter as funções de velocidade de partícula $v(x, t)$ e de força $F(x, t)$ na seção instrumentada, através das Equações (31) e (32), respectivamente, expressas em função da sobreposição das ondas descendente e ascendente.

$$v = v \downarrow + v \uparrow \quad (31)$$

$$F = F \downarrow + F \uparrow \quad (32)$$

sendo:

$v \downarrow$ = velocidade de partícula descendente;

$v \uparrow$ = velocidade de partícula ascendente;

$F \downarrow$ = força descendente;

$F \uparrow$ = força ascendente.

A velocidade de partícula v , pode ser definida através da Equação (33), dependendo das características do material da estaca e da tensão imposta no ensaio (σ).

$$v = \frac{\sigma}{E} c \quad (33)$$

Ao reorganizar a Equação (33), obtém-se a Equação (34), em função da tensão imposta ao ensaio.

$$\sigma = \frac{E}{c} v \quad (34)$$

Utilizando o conceito que a Força F é a aplicação de uma tensão σ em uma área A , Equação (35), e substituindo a Equação (34) na Equação (35), pode-se definir que as funções de velocidade de partícula $v(x, t)$ e de força $F(x, t)$ possuem uma proporcionalidade quantificada através de uma constante chamada impedância Z , conforme Equação (36). A impedância Z também já foi definida anteriormente, através da Equação (26).

$$F = \sigma A \quad (35)$$

$$F = \frac{EA}{c} v = Zv \quad (36)$$

Da Equação (36), pode-se definir as Equações (37) e (38).

$$F \downarrow = Zv \downarrow \quad (37)$$

$$F \uparrow = -Zv \uparrow \quad (38)$$

Ao utilizar o conceito das Equações (37) e (38) na Equação (32), obtém-se a Equação (39).

$$F = Z(v \downarrow - v \uparrow) \quad (39)$$

Ao utilizar o conceito das Equações (37) e (38) em função da velocidade de partícula v na Equação (31), obtém-se a Equação (40).

$$v = \frac{1}{Z} (F \downarrow - F \uparrow) \quad (40)$$

Ao empregar o conceito da Equação (32), pode-se definir a força ascendente como na Equação (41).

$$F \uparrow = F - F \downarrow \quad (41)$$

Ao substituir a Equação (41) na Equação (40), obtém-se a Equação (42).

$$v = \frac{1}{Z}(2F \downarrow - F) \quad (42)$$

Os valores de velocidade e força obtidos no nível da instrumentação (topo da estaca) durante a execução do ensaio são valores totais, no entanto, para saber as informações sobre os efeitos externos que causam a reflexão, tais como atrito lateral, resistência de ponta, mudança de impedância (alteração da seção transversal da estaca, variação de módulo de elasticidade da estaca, etc.) são necessárias as informações da onda ascendente.

Reorganizando a Equação (42), obtém-se a Equação (43).

$$F \downarrow = \frac{F + vZ}{2} \quad (43)$$

Realizando a substituição da Equação (43) na Equação (41), obtém-se a Equação (44).

$$F \uparrow = \frac{F - vZ}{2} \quad (44)$$

As Equações (43) e (44) mostram que conhecendo a força F e a velocidade de partícula v na seção instrumentada e através da impedância Z (características do material da estaca) é possível determinar isoladamente as amplitudes das ondas descendente e ascendente.

Método simplificado do tipo CASE®

Através de um PDA (*"Pile Driving Analyser"*) em um sistema básico de instrumentação no campo, como da Figura 17, são processados os sinais da aceleração e deformação específica como dados de entrada, fornecendo como saídas os sinais de velocidade (integração da aceleração medida nos acelerômetros) e de força (aplicação da Lei de Hooke ao sinal medido nos transdutores de deformação específica) em cada golpe dado à estaca e imediatamente após o mesmo. Um sinal típico de saída é mostrado na Figura 18.




Figura 17 – Esquema básico de instrumentação de campo (modificado de Alonso, 2011)




Figura 18 – Sinal típico de saída de um PDA (Alonso, 2011)

Com base nos sinais de saída típicos, conforme Figura 18, os pesquisadores da *Case Western Reserve University*, de Cleveland (Ohio, EUA) desenvolveram o método simplificado, do tipo CASE[®].

O CASE[®] é um método simplificado que possibilita a estimativa imediata da resistência estática para uma estaca submetida a um impacto dinâmico, através da interpretação das medidas de força e velocidade da seção instrumentada (seu topo). O método foi desenvolvido utilizando a solução da equação da onda unidimensional por intermédio de correlações empíricas com resultados de provas de carga estáticas (Cintra et al., 2013).

Neste método são utilizadas três hipóteses simplificadoras: Uma que considera o comportamento plástico ideal do solo, outra que considera a estaca com comportamento ideal elástico e uniforme e por último, que são transmitidas à estaca somente tensões axiais. Também supõe-se que todas as reflexões da onda ocorrem em função da resistência do solo e que o atrito mobilizado seja igual tanto para as ondas descendentes quanto para as ascendentes. Estima-se, então, a Resistência total à penetração da estaca (R_t) somando a resistência de ponta (R_p) e a resistência por atrito lateral (R_l), conforme Equação (45).

$$R_t = R_p + \sum R_l \quad (45)$$

Ao analisar a Figura 18, pode-se observar o sinal de força, representado pela linha cheia, e o sinal de velocidade vezes a impedância, pela linha tracejada. O afastamento entre estas duas linhas demonstra a ocorrência de resistência por atrito lateral (R_l) ao longo do fuste da estaca.

Por intermédio da análise das ondas descendentes e ascendentes, adotada na hipótese de Smith (1960), foi estimada a Resistência total à penetração da estaca (R_t), sendo composta de uma parcela estática (R_s) e uma parcela dinâmica (R_d), Equação (46):

$$R_t = R_s + R_d = \frac{1}{2}(F_{t1} + F_{t2}) + \frac{1}{2}Z(v_1 - v_2) \quad (46)$$

sendo:

F_{t1} = força no tempo t_1 ;

t_1 = tempo de maior intensidade do golpe;

F_{t2} = força no tempo t_2 ;

t_2 = tempo $\left[t_1 + 2 \left(\frac{l}{c} \right) \right]$;

$2 \left(\frac{l}{c} \right)$ = tempo para a onda ir até a ponta da estaca e voltar por reflexão até o

topo;

l = comprimento da estaca;

v_1 = velocidade de partícula no tempo t_1 ;

v_2 = velocidade de partícula no tempo t_2 .

Com base na teoria da Equação da onda unidimensional e por simplificação do método, a parcela dinâmica (R_d) é dada pela Equação (47) como proporcional à velocidade de partícula na ponta da estaca (v_p), a qual é dada pela Equação (48).

$$R_d = J_c Z v_p \quad (47)$$

$$v_p = (2F \downarrow - R_p)/Z \quad (48)$$

sendo:

J_c = fator de amortecimento, que depende do tipo de solo da ponta da estaca. Os valores propostos por Rausche et al. (1985) estão reunidos na Tabela 11.

Tabela 11 – Valores de J_c sugeridos por Rausche et al. (1985)

Tipo de Solo	Varição de J_c	Valor sugerido de J_c
Areia	0,05 – 0,20	0,05
Areia Siltosa ou Silte Arenoso	0,15 – 0,30	0,15
Silte	0,20 – 0,45	0,30
Argila Siltosa ou Silte Argiloso	0,40 – 0,70	0,55
Argila	0,60 – 1,10	1,10

Conhecida a resistência total à penetração da estaca (R_t), basta subtrair da mesma a parcela dinâmica (R_d), calculada através da Equação (47) e obter a parcela estática (R_s), através da Equação (49).

$$R_s = R_t - (J_c Z v_p) \quad (49)$$

Análise rigorosa, do tipo CAPWAP®

A análise rigorosa, do tipo CAPWAP®, é um método mais elaborado para a avaliação do comportamento de estacas durante a cravação obtendo-se a previsão

da carga mobilizada durante o golpe do martelo, bem como sua distribuição ao longo do fuste da estaca.

Foi desenvolvido paralelamente ao Método CASE[®] na *Case Western Reserve University* (EUA), porém permite uma análise mais elaborada dos sinais de cravação obtidos no topo da estaca. O método requer um tempo de processamento e só é realizado posteriormente à cravação da estaca, no escritório.

Através do método computacional CAPWAP[®] (*Case Pile Wave Analysis Program*), após o ensaio de carregamento dinâmico, efetua-se a interpretação dos registros de força e velocidade obtidos na cabeça da estaca. O sistema solo-estaca modelado é comparado com os resultados medidos de força ou velocidade. Esta modelagem do sistema solo-estaca é ajustada variando os parâmetros do solo até que se obtenha um bom ajuste, de modo que coincida com as respostas medidas.

Este método utiliza o modelo proposto por Smith (1960), e modela-se a estaca como uma série de molas e elementos de massa às quais se aplicam forças resistentes, conforme Figura 19. Nesta Figura, pode ser visualizado todo o processo computacional resumido no fluxograma para a realização do sistema iterativo.

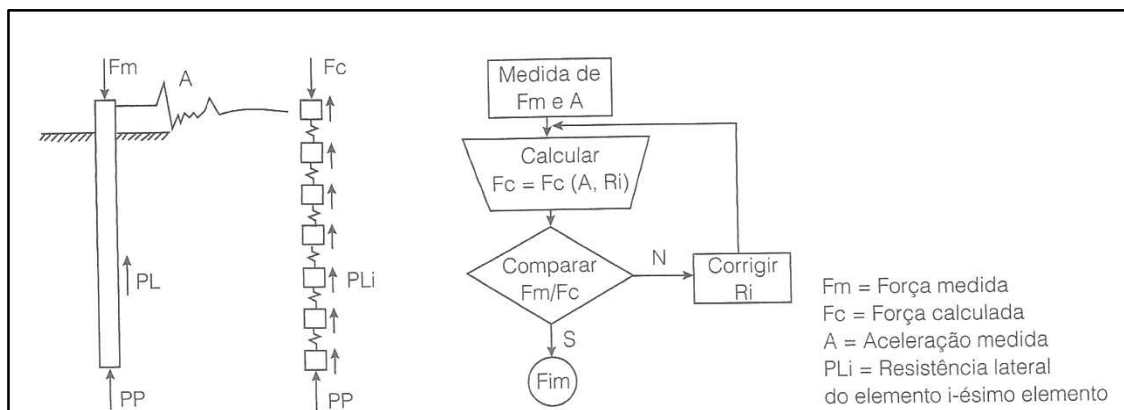


Figura 19 – Esquema simplificado de cálculo pelo método CAPWAP[®] (Alonso, 2011)

Na Figura 20, pode-se observar como se dá a sequência de ajuste de sinal pelo método CAPWAP[®].




Figura 20 – Sequência de ajuste de um sinal pelo método CAPWAP® (adaptado de Velloso e Lopes, 2010)

A análise do método se dá por um processo iterativo, em que são adotados inicialmente parâmetros conhecidos da estaca e parâmetros estimados do solo. O valor da resistência estática será mais preciso quanto melhor for o ajuste entre as curvas do sinal medido (linha cheia) e da linha tracejada obtida através da solução da equação da onda unidimensional.

O método considera que as forças de reação do solo são passivas e expressas em função do movimento da estaca. Precisa-se informar ao programa, para cada camada de solo, a resistência elástica limite (R_u), a deformação elástica máxima (“*quake*”), as constantes de amortecimento (“*damping*”), além de informações das características da estaca, do martelo, capacete, etc. Como resposta do programa, tem-se a capacidade de carga da estaca, a eficiência do golpe, a força de compressão máxima, o deslocamento máximo (nega), etc.

Na Figura 21, é exibido um resultado típico de uma análise pelo método CAPWAP® para um golpe de um ensaio de carregamento dinâmico.

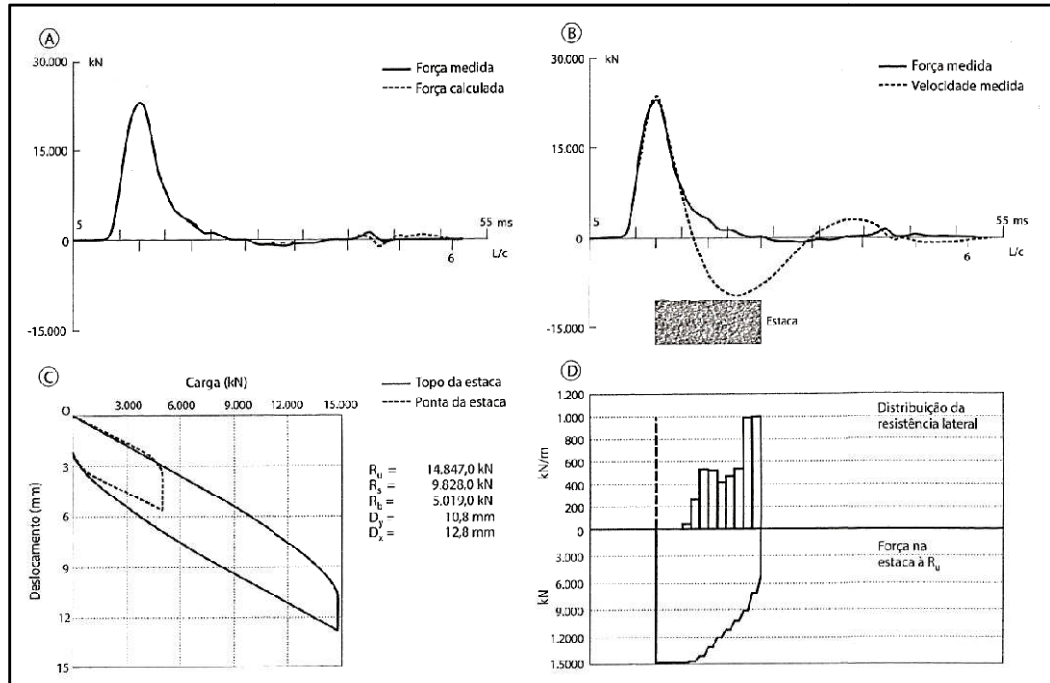


Figura 21 – Resultado típico - Análise método CAPWAP® (Cintra et al., 2013)

A comparação entre a força medida com a calculada na seção instrumentada (topo da estaca) é vista na Figura 21A. Na Figura 21B, são mostradas as curvas de força e velocidade obtidas pelo PDA no campo. Na Figura 21C, são plotadas as curvas carga x recalque no topo e na ponta da estaca. Na Figura 21D, são apresentados o gráfico de barras representando a distribuição de resistência por atrito lateral na estaca e o diagrama de esforços normais ao longo do fuste da estaca.

2 REDE NEURAL ARTIFICIAL (RNA)

Neste capítulo, serão apresentados os conceitos básicos de redes neurais artificiais, bem como a modelagem e o aprendizado. Inicialmente será realizada uma breve abordagem sobre histórico das Redes Neurais Artificiais, as características dos neurônios biológicos (humanos) e em seguida a introdução do modelo de neurônio artificial, que procura de forma análoga reproduzir o seu funcionamento. Na sequência, será mostrada a modelagem de um neurônio artificial com os tipos de funções de ativação, as arquiteturas de redes neurais existentes, os métodos de aprendizagem, os principais modelos de Redes Neurais Artificiais e suas definições básicas. Também será apresentado o algoritmo de treinamento de redes diretamente alimentadas, conhecido como algoritmo de retropropagação, a função de treinamento e a função de adaptação de treinamento utilizadas na rede deste trabalho. Finalmente, o capítulo apresenta uma breve abordagem da utilização das Redes Neurais Artificiais em Geotecnia.

2.1 Introdução

Rede Neurais Artificiais (RNA) são modelos computacionais inspirados nos mecanismos de aprendizagem do cérebro humano, que tentam simular a forma como o mesmo resolve problemas, através de neurônios artificiais, que por sua vez são baseados nos neurônios biológicos.

RNAs são sistemas paralelamente distribuídos, compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não-lineares). Os nodos são dispostos em uma ou mais camadas e interligados por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. Por não ser baseada em regras ou programas (computação não-algorítmica), a computação neural se constitui em uma alternativa à computação algorítmica convencional (Braga et al., 2000).

O grande atrativo de se estudar soluções de problemas através das RNAs está na habilidade da rede de aprender por meio de exemplos e generalizar a solução aprendida. Esta generalização se dá no aprendizado da rede através de um

conjunto de exemplos relativamente pequeno e tem como resultado final respostas coerentes para dados que não estavam presentes no processo de aprendizagem.

A primeira referência aos estudos das RNAs foi o trabalho pioneiro realizado por McCulloch e Pitts (1943), seguido mais tarde por Hebb (1949), Rosenblath (1958), Widrow e Hoff (1960), Widrow (1962) e Minsky e Pappert (1969), que aprofundaram os estudos sobre o tema. Após esses estudos, houve um grande hiato nas pesquisas na década de 1970, e somente foi retomado na década de 1980 por Hopfield (1982) e mais adiante por Rumelhart e McClelland (1986), trabalhos que impulsionaram diversas outras pesquisas e ajudaram a estimular o interesse da comunidade internacional no estudo das RNAs, juntamente com outro importante fator: o avanço da tecnologia, em especial da microeletrônica.

As RNAs possuem um grande potencial para serem empregadas em diversos campos de estudo, como:

- **Classificação de Padrões:**
Ao associar um padrão de entrada (amostra) a uma das classes previamente definidas. Exemplos: reconhecimento de imagens, voz e escrita;
- **Controle de processos:**
Identificando ações de controle que permitam o alcance dos requisitos de qualidade, de eficiência e de segurança de um processo. Exemplos: controles aplicados em robótica, aeronaves, elevadores e eletrodomésticos;
- **Agrupamento de dados (clusterização):**
Na detecção e identificação de particularidades e similaridades entre os diversos padrões de entrada afim de possibilitar seu agrupamento. Exemplos: identificação automática de classes (em problemas de diagnóstico médico), compressão de dados e mineração de dados (*data mining*);
- **Sistemas de Previsão:**
Estimando valores posteriores de um processo levando-se em conta diversas medidas prévias observadas em seu domínio. Exemplos: previsão de séries temporais, mercados financeiros e climáticas;

- Memórias Associativas:
Restaurando padrões corretos mesmo que seus elementos constituintes estejam apresentados de forma incerta, duvidosa ou imprecisa. Exemplos: processamento e transmissão de imagens, identificação de caracteres manuscritos.

Dentre as principais características de uma RNA pode-se citar:

- Capacidade de Aprendizado:
A utilização de um método de treinamento (ou aprendizagem) permite que a rede extraia o relacionamento existente entre variáveis que compõem a aplicação do problema em estudo;
- Habilidade de generalização:
Após o processo de treinamento, a rede é capaz de generalizar o conhecimento adquirido, ou seja, possibilita a estimativa de soluções que não eram conhecidas;
- Adaptação por experiência:
Os parâmetros internos da rede, com seus pesos sinápticos, são ajustados a partir da apresentação sucessiva de exemplos (dados de entrada);
- Organização de dados:
A rede é capaz de realizar sua organização interna para agrupar amostras similares, baseada em características marcantes de um conjunto de dados;
- Armazenamento distribuído:
O conhecimento dentro da rede é feito de forma distribuída entre as sinapses dos neurônios artificiais, o que permite uma certa robustez caso alguns neurônios se tornem inoperantes;
- Tolerância a falhas:
Devido a natureza distribuída da informação na rede e ao elevado número de interconexões entre neurônios artificiais, a rede torna-se um sistema tolerante a falhas quando parte de sua estrutura interna for suavemente corrompida;
- Facilidade de Prototipagem:

A implementação da maioria das arquiteturas neurais pode ser facilmente prototipada em software.

Após o processo de treinamento, os resultados são geralmente obtidos por algumas operações matemáticas elementares;

- Uniformidade de análise e projeto:

A mesma notação é utilizada em todos os domínios de aplicação das redes neurais artificiais.

2.2 O Cérebro Humano e o neurônio biológico

O estudo das RNAs é fundamentado, de uma forma muito simplificada, no estudo biológico do funcionamento do cérebro humano, quando se compara a estrutura artificial com a complexa estrutura biológica.

O cérebro humano possui aproximadamente cem bilhões (10^{11}) de neurônios, sua célula fundamental. Cada neurônio processa e se comunica com cerca de seis mil outros neurônios de forma contínua e paralela, possuindo em torno de 60 trilhões de sinapses (ou conexões entre neurônios, onde ocorre a transmissão de impulsos nervosos de uma célula para outra). Na Figura 22, pode-se visualizar um esquema de uma estrutura típica de um neurônio biológico com seus componentes.




Figura 22 – Esquema de uma estrutura típica de um neurônio (Silva et al., 2010)

O cérebro humano é considerado o mais fascinante e complexo processador de informações de composto orgânico existente. Sendo parte do sistema nervoso humano, é responsável por todas as funções e movimentos do organismo, suas emoções, pensamentos, percepções e cognições, assim como as funções

sensoriomotoras e autônomas. Possui uma rede de nodos com competência de reconhecer padrões e relacioná-los, com capacidade de usar e armazenar conhecimento por experiência e de interpretar observações. Além disso, possui a habilidade de se adaptar aos estímulos externos ao criar novas conexões sinápticas entre neurônios ou modificar as conexões já existentes.

São pelas sinapses que os neurônios (nodos) se unem funcionalmente, formando redes neurais biológicas. As sinapses funcionam como válvulas, e controlam a transmissão de impulsos, ou seja, o fluxo da informação entre os neurônios. Na Figura 23 pode-se observar o neurônio biológico com as terminações sinápticas e a direção e sentido do impulso nervoso.




Figura 23 – Impulso nervoso em um neurônio (Macedo et al., 2012)

2.3 Modelagem do Neurônio Artificial

O modelo básico de um neurônio artificial proposto por McCulloch e Pitts (1943) é mostrado na Figura 24, também chamado de modelo MCP. Este modelo é utilizado até hoje como uma unidade de processamento de informação fundamental para a operação de uma rede neural.

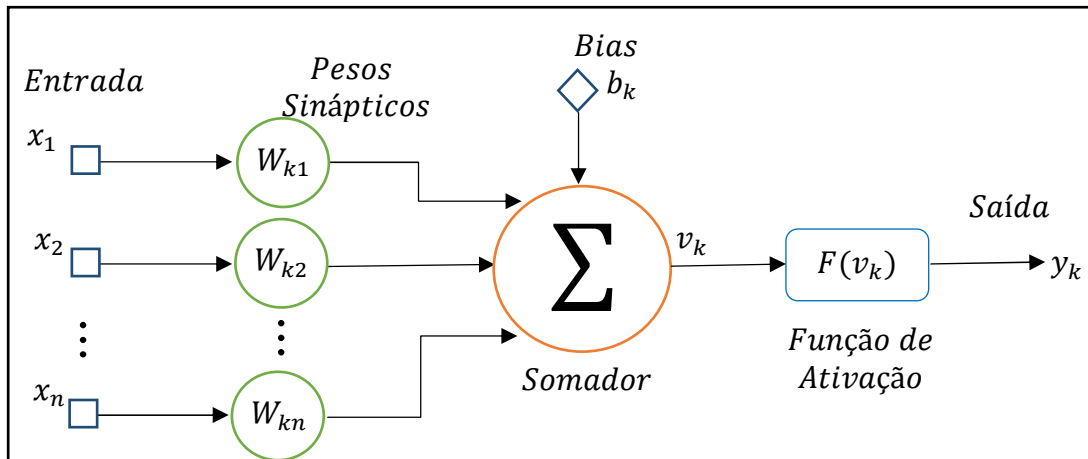


Figura 24 – Modelo do Neurônio Artificial

Conforme a Figura 24, pode-se descrever um modelo com:

- terminais de entrada x_1, x_2, \dots, x_n (que representam os dendritos, no neurônio biológico);
- um terminal de saída y_k (simulando o axônio, no neurônio biológico);
- terminais de entrada do neurônio artificial com pesos acoplados $W_{k1}, W_{k2}, \dots, W_{kn}$ (afim de emular o comportamento das sinapses). Os pesos sinápticos têm a função de determinar a importância dos sinais de determinada região. Uma atenção deve ser dada aos índices do peso sináptico W_{kn} , onde o primeiro índice refere-se ao neurônio em questão e o segundo índice ao terminal de entrada da sinapse ao qual o peso se refere. Portanto, uma sinapse n , que está conectada a um neurônio k , recebe um sinal x_n que por sua vez é multiplicado pelo peso sináptico W_{kn} , tendo o seu efeito dado por $(x_n \cdot W_{kn})$;
- Um Somador Σ , que é um combinador linear, com função de realizar o somatório das entradas do neurônio, ponderadas pela ação dos respectivos pesos sinápticos, tendo como saída v_k ;
- Uma Função de Ativação $F(v_k)$, que condiciona a amplitude do sinal de saída de um neurônio ao restringir a amplitude do sinal de saída a um valor finito. Os intervalos típicos de normalização de saída são $[0,1]$ ou $[-1,1]$;
- o Bias b_k , ou também chamado de Limiar de Ativação, que tem aplicação externa e possui a capacidade de aumentar ou diminuir a entrada da função de ativação, caso ele seja positivo ou negativo.

Alternativamente, pode-se descrever um neurônio artificial de forma matemática, conforme Equação (50) e Equação (51).

$$y_k = F(v_k + b_k) \quad (50)$$

sendo:

$$v_k = \sum_{j=1}^n (x_j \cdot W_{kj}) \quad (51)$$

em que:

x_j = vetor de entrada;

W_{kj} = pesos sinápticos do neurônio k;

v_k = saída do combinador linear (Somador);

b_k = bias;

$F()$ = função de ativação;

y_k = saída do neurônio k.

2.3.1 Tipos de Função de Ativação

A função de ativação $F(v_k)$ define a saída de um neurônio (restringindo a amplitude) em função da saída do combinador linear (v_k). As funções de ativação de um neurônio artificial mais comumente utilizadas são divididas em dois grupos: as Funções de Ativação parcialmente diferenciáveis e as Funções de Ativação totalmente diferenciáveis. Segundo Haykin (2008), a diferenciabilidade de uma função de ativação é uma característica importante da teoria das redes neurais, por exemplo, a presença de redes com funções de ativação totalmente diferenciáveis são importantes, pois caso contrário, a relação de entrada e saída de rede poderia reduzir um *perceptron* de múltiplas camadas em um *perceptron* de uma única camada.

Funções de Ativação parcialmente diferenciáveis são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes, tais como: Função

degrau (*heavyside*) ou função de limiar, descrita pela Figura 25 e Equação (52); Função degrau bipolar ou função sinal, descrita pela Figura 26 e Equação (53) e Função rampa simétrica, descrita pela Figura 27 e Equação (54).




Figura 25 – Função degrau (*heavyside*) ou função de limiar (adaptado de Silva et al., 2010)

$$F(v_k) = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases} \quad (52)$$




Figura 26 – Função degrau bipolar ou função sinal (adaptado de Silva et al., 2010)

$$F(v_k) = \begin{cases} 1, & \text{se } v_k > 0 \\ 0, & \text{se } v_k = 0 \\ -1, & \text{se } v_k < 0 \end{cases} \quad (53)$$




Figura 27 – Função rampa simétrica (adaptado de Silva et al., 2010)

$$F(v_k) = \begin{cases} a, & \text{se } v_k > a \\ v_k, & \text{se } -a \leq v_k \leq a \\ -a, & \text{se } v_k < a \end{cases} \quad (54)$$

Na Função rampa simétrica, os valores retornados de $F(v_k)$ são iguais aos próprios valores da saída do combinador linear v_k (potenciais de ativação) quando estão definidos no intervalo $[-a, a]$, limitando-se aos valores de fronteira em caso contrário.

Funções de Ativação totalmente diferenciáveis, são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todo seu domínio de definição, tais como: Função sigmoide do tipo logística (*S-shape*), descrita pela Figura 28 e Equação (55); Função tangente hiperbólica, descrita pela Figura 29 e Equação (56) e Função linear ou função identidade, descrita pela Figura 30 e Equação (57).

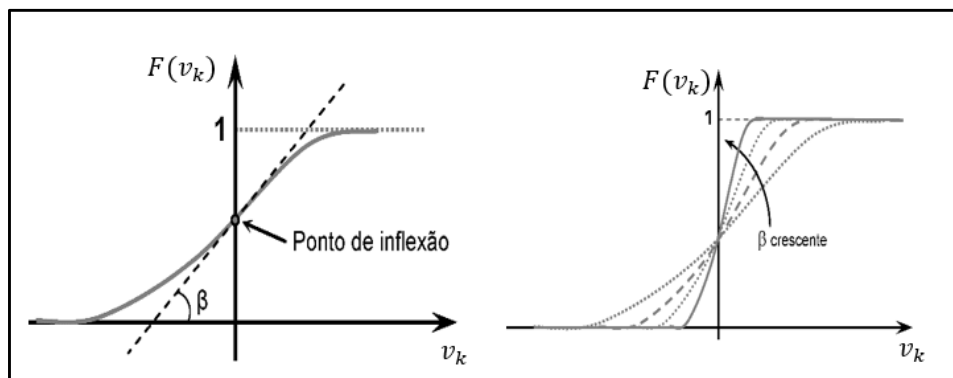


Figura 28 – Função logística (*S-shape*) (adaptado de Silva et al., 2010)

$$F(v_k) = \frac{1}{1 + e^{\left(\frac{-v_k}{\beta}\right)}} \quad (55)$$

em que:

β = constante real associada ao nível de inclinação da função logística frente ao seu ponto de inflexão.

A função logística, ilustrada na Figura 28 e Equação (55), é uma função do tipo sigmoide, semilinear, limitada, monótona, possuindo saídas entre 0 e 1. É definida como uma função estritamente crescente que apresenta um equilíbrio entre

comportamento linear e não-linear. O formato geométrico tende a ser similar ao da função degrau quando β for muito elevado (tender ao infinito).




Figura 29 – Função tangente hiperbólica (adaptado de Silva et al., 2010)

$$F(v_k) = \frac{1 - e^{-\beta \cdot v_k}}{1 + e^{-\beta \cdot v_k}} \quad (56)$$

A função tangente hiperbólica, ilustrada na Figura 29 e na Equação (56), possui comportamento muito similar à função sigmoide, porém com saídas entre -1 e 1. O valor de β também está associado ao seu ponto de inflexão. O formato geométrico tende a ser similar ao da função degrau bipolar quando β for muito elevado (tender ao infinito).




Figura 30 – Função linear ou função identidade (adaptado de Silva et al., 2010)

$$F(v_k) = v_k \quad (57)$$

A função linear ou identidade, descrita na Figura 30 e na Equação (57), produz resultados $F(v_k)$ idênticos aos valores do potencial de ativação v_k .

2.3.2 Arquiteturas de Rede

A arquitetura de uma RNA determina a forma como os seus neurônios são arrumados uns em relação aos outros, fornecendo características e aplicações bastante distintas, conforme o arranjo utilizado.

A arquitetura da rede está profundamente relacionada ao algoritmo de aprendizagem utilizado para o treinamento, e os arranjos são estruturados através do direcionamento do fluxo sináptico. Na definição da arquitetura a ser utilizada são considerados os seguintes parâmetros: número de camadas da rede, número de nós (ou nodos) em cada camada, tipo de conexões entre os nós e a topologia da rede.

De uma forma geral, pode-se identificar quatro tipos básicos de arquiteturas: Redes Diretas (*feed-forward*) de uma Camada; Redes Diretas (*feed-forward*) de Camadas Múltiplas; Redes Recorrentes (*feed-backward*); Redes Reticuladas, abordadas a seguir.

Redes Diretas (*feed-forward*) de Uma Camada

As redes diretas de uma camada são constituídas de uma camada de entrada e única camada de neurônios, que é a própria saída. O Fluxo de informações segue continuamente em uma única direção (unidirecional), fazendo com que a rede seja sempre alimentada adiante (*feed-forward*) e de forma acíclica. Na Figura 31, pode-se verificar como é composta uma Rede Direta (*feed-forward*) de uma camada.

Esse tipo de rede é utilizado em telecomunicações, onde *modems* de alta velocidade de transmissão utilizam equalizadores adaptativos de linha e canceladores adaptativos de eco. Cada um desses sistemas adaptativos utiliza uma rede neural (Widrow et al., 1994). Também são utilizados para classificação de padrões e filtragem linear. Redes Perceptron e Adaline são exemplos de redes neurais diretas de uma camada (*feed-forward*).

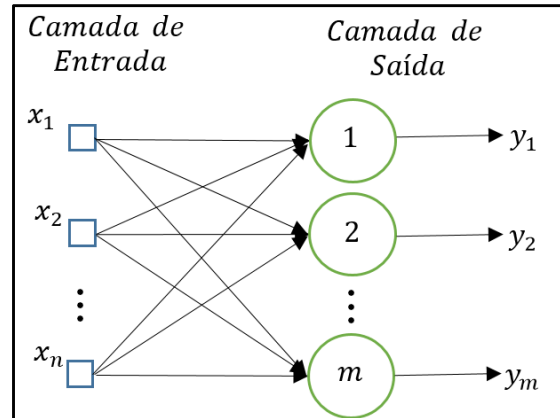


Figura 31 – Rede Direta (*feed-forward*) de uma camada

Redes Diretas (*feed-forward*) de Camadas Múltiplas

Redes Diretas de Camadas Múltiplas são compostas de uma ou mais camadas neurais escondidas. A quantidade de camadas escondidas e de neurônios dependem, principalmente, do tipo e da complexidade do problema. Assim como nas Redes diretas de uma camada, o fluxo de informações é contínuo e unidirecional, fazendo com que a rede seja sempre alimentada adiante (*feed-forward*) e de forma acíclica. A Figura 32 mostra um exemplo de uma rede direta de múltiplas camadas, com duas camadas neurais escondidas.

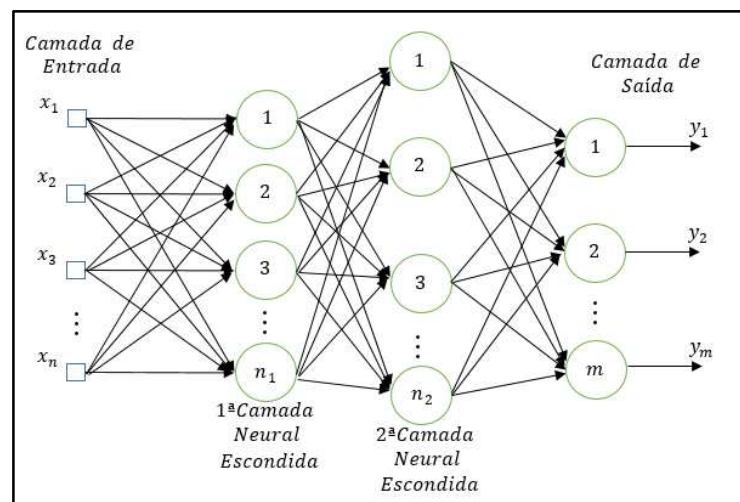


Figura 32 – Rede Direta (*feed-forward*) de múltiplas camadas, com duas camadas neurais escondidas

Aplicações de redes de múltiplas camadas podem ser citadas na área de reconhecimento de caracteres, aproximação de funções, classificação de padrões, controle de processos, otimização, etc. Redes Perceptron Multicamadas (*Multilayer Perceptron, MLP*) e Redes de Base Radial (RBF) são exemplos de redes neurais diretas de múltiplas camadas (*feed-forward*).

Redes Recorrentes (*feed-backward*)

Nas Redes Recorrentes (*feed-backward*) as saídas dos neurônios são realimentadas com o sinais de entrada para outros neurônios, conforme observado na Figura 33.

A realimentação (ou laços de realimentação) faz com que a rede seja capaz de produzir um processamento dinâmico não linear de informações, de forma cíclica, impactando profundamente na capacidade de aprendizagem da rede e no seu desempenho.

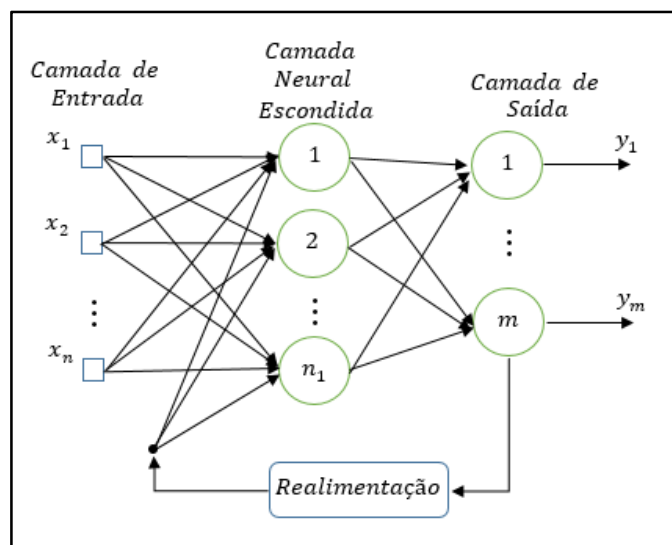


Figura 33 – Redes Recorrentes (*feed-backward*)

Redes Recorrentes (*feed-backward*) podem ser aplicadas nas áreas de sistemas de previsão, reconhecimento de sinais de radar, processamento de imagens, otimização, controle de processos, reconhecimento de imagens, etc. Como exemplo desse tipo de arquitetura tem-se a Rede Perceptron multicamadas com realimentação e Rede de Hopfield.

Redes Reticuladas

Redes Reticuladas levam em consideração a disposição espacial dos neurônios, ou seja, a forma em que está organizada. E tem como finalidade a extração de características.

A Rede de Kohonen, em que neurônios estão dispostos no espaço bidimensional, vista na Figura 34, é um exemplo de Rede Reticulada.

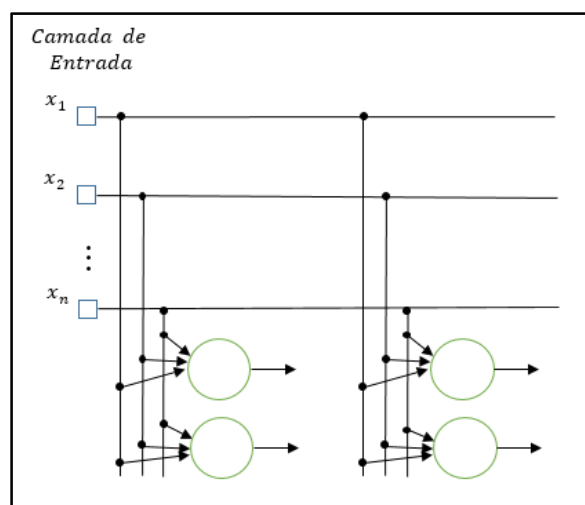


Figura 34 – Exemplo de Rede Reticulada, a Rede de Kohonen

Redes Reticuladas são aplicadas em problemas de agrupamento, classificação de padrões, otimização de sistemas, simulações, etc.

2.3.3 Aprendizagem (ou Treinamento) da Rede

Uma das mais importantes características de uma Rede Neural Artificial é a sua habilidade em aprender quando apresentada a amostras que traduzem o comportamento do sistema e logo após ter aprendido a relacionar as entradas e saídas, a rede possui competência de generalizar soluções, ou seja, produzir uma saída próxima da esperada, a partir de quaisquer dados de entrada inseridos.

Aprendizagem, ou Processo de Treinamento, da Rede consiste em aplicar passos ordenados com a finalidade de sintonizar (ajustar) os pesos sinápticos e limiares dos neurônios, com objetivo final de generalização de soluções (as quais não eram conhecidas). O conjunto desses procedimentos bem definidos (passos

ordenados) para adaptar os parâmetros de uma RNA, que faz com que ela aprenda determinada função, recebe o nome de algoritmo de aprendizagem. Existem inúmeros algoritmos de aprendizagem e o que os difere entre si é a forma como o ajuste dos pesos é realizado.

Em um conjunto total de amostras, representando todo os dados disponíveis sobre o comportamento do processo a ser mapeado, divide-se em dois subconjuntos: o subconjunto de treinamento, que será utilizado para o treinamento em si da rede, empregando entre 60 a 90% do conjunto amostral; e o subconjunto de teste, que será utilizado entre 10 a 40% das amostras restantes que não foram utilizadas no treinamento da rede, com o objetivo de testar (validar) se a generalização das soluções propostas pela rede está em níveis aceitáveis.

Durante a execução da etapa de aprendizagem da rede, cada apresentação completa das amostras pertencentes ao subconjunto de treinamento com objetivo o ajustar os pesos sinápticos e os limiares de seus neurônios, é denominada época de treinamento (ou passo de treinamento, ou idade de treinamento).

Para a realizar o treinamento de RNAs, uma série de decisões devem ser tomadas afim de que o treinamento convirja para o objetivo, seja a minimização do erro médio quadrático ou qualquer que seja a função a minimizar. O Erro Quadrático Médio (EQM, ou *MSE*, do inglês *Mean Squared Error*) é dado pela Equação (58), e é uma das mais importantes medidas de erro de previsão.

$$EQM = \frac{1}{n} \sum_{i=1}^n (e_t)^2 \quad (58)$$

sendo:

n = número de períodos usados;

e_t = erro no período t , dado pela Equação (59).

$$e_t = A_t - P_t \quad (59)$$

em que:

A_t = valor real no período t ;

P_t = previsão para o período t .

Uma das decisões a serem tomadas é sobre a forma de aprendizado, que pode ser:

- Por Batelada (*batch*): quando a atualização dos pesos é dada ao final do processamento de todos os pares entrada-saída. Pode ser lento se o conjunto de treinamento possuir muitos pares;
- Em lotes: quando o conjunto é dividido em lotes para efetuar a atualização dos pesos ao fim do processamento de cada lote;
- Em Regra delta (treinamento *on-line*): quando a atualização dos pesos se dá ao ser processado cada par entrada-saída apresentado.

Outras decisões importantes sobre o processo de treinamento incluem:

- Número de camadas escondidas;
- Número de neurônios nas camadas escondidas;
- Número de neurônios de saída;
- Valor máximo inicial de distribuição dos pesos sinápticos;
- Número de épocas de treinamento.

Cabe ressaltar que não existe uma fórmula definida para se obter estes parâmetros, sendo geralmente definidos por um julgamento empírico realizado a partir de vários testes com a rede, por exemplo: uma RNA com poucos neurônios na camada escondida pode apresentar uma aproximação ruim da série modelada. Outro exemplo é quando no processo de otimização da RNA, dado por um valor inicial aleatório dos pesos, atinja um ponto de mínimo local que apresenta um resultado real impreciso para o prognóstico do problema. Este caso ainda pode ser agravado caso a escolha do número de épocas de treinamento seja estimado de forma insuficiente para alcançar o mínimo global.

Os critérios de parada do processo podem ser definidos a partir da fixação de parâmetros, tais como:

- Número máximo de épocas alcançado;
- Erro mínimo atingido;
- Obtenção do valor de variação mínimo para os erros.

Basicamente existem cinco formas principais de aprendizagem: Aprendizagem com Professor, Aprendizagem sem Professor, Aprendizagem por Reforço, Aprendizagem usando lote de padrões (*Off-line*) e Aprendizagem usando padrão-por-padrão (*On-line*), descritas sucintamente abaixo.

Aprendizagem com Professor

Na Aprendizagem com Professor os sinais de entrada e saída desejadas para a rede são distribuídas por um professor (supervisor) externo. Este professor ensina, indicando claramente um desempenho bom ou ruim para a rede, ou seja, apontando qual seria a resposta correta para cada amostra apresentada.

Este método de aprendizado é o mais comum no treinamento das RNAs segundo Braga et al. (2000).

A Figura 35 esboça o mecanismo de aprendizado com professor. A finalidade é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos, através de um professor.

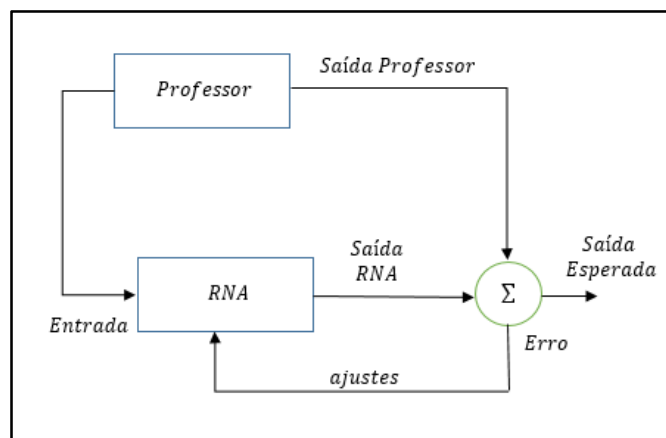


Figura 35 – Aprendizagem com professor

O processo iterativo para uma Aprendizagem com professor, observando a Figura 35, é:

1. Apresente uma amostra de treinamento;
2. Calcule a saída produzida pela rede;
3. Compare com a saída desejada;
4. Se o erro da resposta atual estiver dentro de valores aceitáveis:
 - a. Então, termine o processo de aprendizado;
 - b. Senão, ajuste os pesos sinápticos e limiares dos neurônios para minimizar o erro e volte ao passo 1.

A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento (Braga et al., 2000). De acordo com o mesmo autor, os algoritmos para aprendizado supervisionado mais conhecidos são a Regra Delta proposta por Widrow (1960) e a sua generalização para redes de múltiplas camadas, o algoritmo *Backpropagation*. E o primeiro modelo de RNA que utilizou aprendizado supervisionado foi o *Perceptron*.

Aprendizagem sem Professor

No aprendizado sem professor, como o próprio nome sugere, não existe um professor ou supervisor para acompanhar o processo de aprendizado.

Nesta forma de aprendizagem, a rede deve se auto organizar em relação às peculiaridades entre os elementos do conjunto amostral total, identificando subconjuntos (*clusters*) que contenham semelhanças. A partir do momento que a rede estabelece um ajuste com as regularidades estatísticas da entrada de dados, ela desenvolve uma capacidade de formar representações internas para codificar características da entrada e criar novas classes ou grupos de forma automática.

Os passos básicos para uma Aprendizagem sem professor são:

1. Apresente todas as amostras de treinamento;
2. Obtenha as características que marcam as amostras de treinamento;
3. Agrupe todas as amostras com características em comum;
4. Coloque as amostras comuns em classes.

Aprendizagem por Reforço

De acordo com Silva et al. (2010) os métodos baseados na aprendizagem com reforço tem sido considerados uma variação das técnicas que utilizam aprendizagem com professor, as quais avaliam constantemente a diferença de valor entre a resposta produzida pela rede em relação à respectiva saída desejada, apesar de não utilizar um professor (ou supervisor). Os algoritmos que utilizam a aprendizagem por reforço ajustam os parâmetros internos dos neurônios em função

de quaisquer dados qualitativos ou quantitativos advindos da interação com o sistema que está sendo mapeado, as quais são usadas para medir o desempenho do aprendizado.

A aprendizagem por reforço é tipicamente realizada por tentativa e erro, pois só existem duas respostas possíveis para uma determinada entrada, se ela é satisfatória ou não. Se a resposta é satisfatória, o processo de aprendizagem é encerrado, senão, incrementos nos pesos sinápticos e limiares são gradualmente inseridos afim de reforçar (reparar) esta condição comportamental em que o sistema está compreendido, até que a resposta seja satisfatória.

Aprendizagem usando lote de padrões (*Off-line*)

Na aprendizagem usando lotes de padrões (*off-line*), ou também chamada de aprendizagem por batelada (*batch*), os ajustes nos pesos e limiares dos neurônios são realizados somente quando todo o conjunto de treinamento é apresentado de uma vez (por batelada). Portanto, é condição necessária que todas as amostras utilizadas no aprendizado estejam disponíveis enquanto dure o processo de aprendizado.

Neste tipo de aprendizagem, cada passo de ajuste contempla o total de desvios observados nas amostras de aprendizagem diante dos respectivos valores de saídas esperados.

Aprendizagem usando padrão-por-padrão (*On-line*)

Na aprendizagem usando padrão-por-padrão (*on-line*), os ajustes nos pesos e limiares dos neurônios são executados após a apresentação de cada amostra de aprendizagem.

Esta aprendizagem é geralmente empregada quando o comportamento do sistema a ser mapeado varia de forma bastante rápida, podendo as amostras utilizadas em um determinado instante no processo de aprendizagem não serem mais representativas para o comportamento do sistema em instantes posteriores, podendo inclusive serem descartadas.

2.3.4 Modelos de Redes Neurais Artificiais

Os principais modelos de Redes Neurais Artificiais e suas definições básicas são apresentados a seguir.

Perceptron de uma camada

O *Perceptron* de uma camada foi o primeiro modelo de rede neural concebido, e é a forma mais simples de uma RNA classificadora de padrões. Composto de um neurônio artificial com seus pesos sinápticos ajustáveis, juntamente com o bias, é capaz de classificar padrões em duas classes, ou seja, são capazes de aprender somente sobre problemas linearmente separáveis (que podem ser separados por uma reta em um hiperplano), conforme Figura 36.

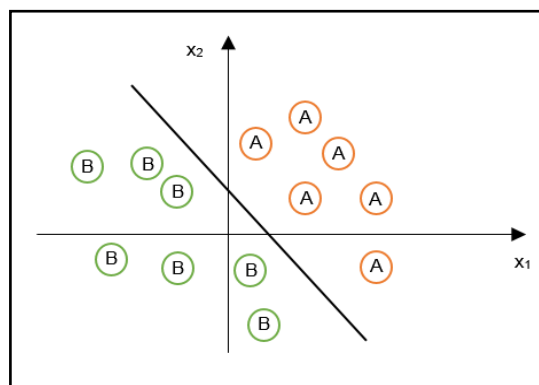


Figura 36 – Comportamento de um *Perceptron* classificador de padrões cuja função é dividir classes linearmente separáveis

Rosenblatt (1958) desenvolveu o primeiro algoritmo destinado ao treinamento do *Perceptron*, por isso o fato de o *Perceptron* de uma camada também ser chamado de *Perceptron* de Rosenblatt.

Adaline

O modelo *Adaline* (**AD**Aptive **L**inear **NE**uron) foi desenvolvido por Widrow e Hoff (1960), e foi criado quase que simultaneamente ao modelo do *Perceptron* de Rosenblatt, sendo, ambos compostos por um neurônio artificial e fundamentados em operações de soma ponderada executadas por elementos de processamento,

seguido de comparação com um valor limiar, e treinados através de aprendizagem supervisionada, porém com abordagens diferentes.

A diferença básica entre o *Perceptron* de Rosenblatt e o modelo *Adaline*, é o algoritmo empregado para a aprendizagem, que no modelo *Adaline* é denominado de Algoritmo do Mínimo Quadrado Médio, conhecido também como Regra Delta ou LMS (*Least Mean Square*), o qual deu origem ao algoritmo de retropropagação (ou *Backpropagation*) para *Perceptrons* de múltiplas camadas. A Regra Delta, baseia-se na proposta de se obter um ponto mínimo através de um processo iterativo local, com um conjunto de treinamento de cada vez.

O modelo *Adaline* também se distingue do *Perceptron* de uma camada pelo cálculo do erro de saída ser realizado em relação à sua saída linear, e a minimização obtida pelo método do gradiente descendente.

Madaline

O modelo *Madaline* (*Multiple Adaline*) é uma rede única, composta de várias *Adalines*. Um modelo *Madaline* pode possuir um conjunto de *Adalines*, porém em pelo menos um deles precisa atuar com parâmetros fixos implementando critérios de decisão.

Este modelo foi um dos primeiros a incluir elementos adaptativos organizados em camadas treináveis.

Perceptron de múltiplas camadas

O modelo *Perceptron* de múltiplas camadas (PMC, ou *MLP*, do inglês *Multilayer Perceptron*) é composto de múltiplas camadas de unidades computacionais, e apresenta na sua forma mais simples pelo menos uma camada intermediária (escondida) de neurônios entre as camadas de entrada e saída, e são na maioria das vezes completamente interconectadas, ou seja, cada neurônio em uma camada tem conexões com todos os neurônios da camada seguinte.

Caso seja adicionado mais camadas de neurônios ao *Perceptron* de uma camada, é possível classificar padrões com mais de duas classes, porém é necessário que as mesmas sejam também linearmente separáveis, gerando assim

mais de uma reta classificadora e o *Perceptron* de múltiplas camadas, conforme Figura 37.

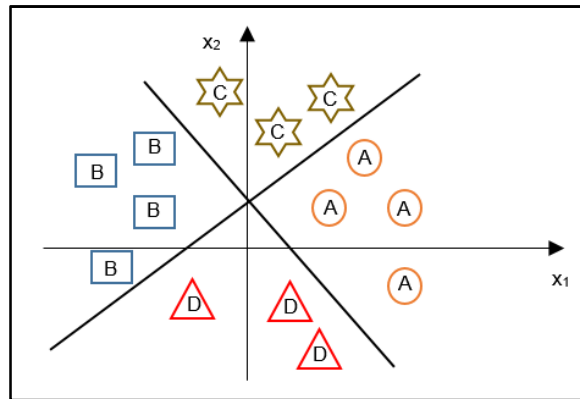


Figura 37 – Comportamento de um *Perceptron* de multiplas camadas classificador de padrões com mais de duas classes linearmente separáveis

Modelos PMC possuem três tipos básicos de camadas: a camada de entrada, (ou nós de fonte), responsável por exibir os padrões de entrada à rede e não realiza nenhum processamento; as camadas intermediárias (ocultas), que funcionam como extratores de características, com a codificação interna dessas particularidades traduzindo-se no ajuste dos pesos sinápticos; e a camada de saída, que tem o papel de estabelecer os padrões de resposta da rede.

Neste modelo, as regras de aprendizagem utilizadas são uma generalização da Regra Delta, empregada no modelo *Adaline*. O algoritmo utilizado para a aprendizagem do modelo PMC é o algoritmo de retropropagação (*Backpropagation*), que se baseia na regra de aprendizagem por correção de erro.

O processamento do fluxo de informações da rede é contínuo e unidirecional, fazendo com que a rede seja sempre alimentada adiante (*feed-forward*) e de forma acíclica. A função de ativação mais aplicada a unidades dessas redes é a função sigmóide.

2.3.5 O Algoritmo de Retropropagação (Backpropagation)

Rumelhart e McClelland (1986) descreveram o algoritmo de treinamento de Retropropagação (*Backpropagation*). O termo *Backpropagation*, também chamado

de Regra Delta generalizada, surgiu do fato que o algoritmo se fundamenta na retropropagação dos erros para realizar os ajustes dos pesos sinápticos das camadas intermediárias.

O algoritmo *Backpropagation* busca minimizar o erro obtido pela rede ajustando pesos e limiares para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. Para isto, ele emprega o Método do Gradiente Descendente. O gradiente de uma função é o vetor que indica a direção e o sentido no qual, por deslocamento a partir do ponto especificado, a função tem taxa de variação máxima. Isto garante que a rede percorra a superfície na direção e sentido que irá reduzir ainda mais o erro obtido.

Pode-se sintetizar a dinâmica do algoritmo de retropropagação em dois procedimentos básicos: A primeira fase, chamada de “propagação adiante” (*forward*), onde os sinais de entrada são inseridos e a “propagação” do efeito desse vetor de entrada através da rede, camada a camada, até a produção de uma saída, considerando-se somente os valores atuais dos pesos sinápticos e dos limiares de seus neurônios, que permanecerão inalterados na execução dessa fase. E a segunda fase, chamada de “retropropagação” ou “propagação reversa”, onde ocorre a propagação do sinal de erro gerado na saída da rede em sentido contrário ao das conexões sinápticas (*backward*). Os ajustes dos pesos sinápticos e limiares de todos os neurônios ocorrem nessa fase, quando o sinal de erro é “retropropagado” através da rede. Em síntese, as sucessivas execuções das fases *forward* e *backward*, ajustam automaticamente em cada iteração os pesos sinápticos e os limiares dos neurônios, fazendo com que ocorra uma redução gradativa da soma dos erros produzidos pelas respostas da rede em função daquela desejadas.

2.3.6 Funcionalidade e Otimização das Redes MLP

É uma tarefa complexa modelar a arquitetura e topologia ideais de uma rede neural de forma em que ela apresente o tamanho ótimo, afim de obter as representações necessárias sem que fique grande demais, e ao mesmo tempo ter um treinamento rápido sem que fique pequena e não consiga simular bem o problema.

De acordo com Haykin (2008), a complexidade de um problema é uma característica que não se pode controlar. A partir dessa proposição, para que possa ocorrer uma boa generalização, ou seja, que a rede seja capaz de gerar respostas corretas a estímulos externos, mesmo que estes não sejam exatamente iguais aos estímulos utilizados inicialmente no seu aprendizado, pode-se manter fixa a arquitetura da rede e investigar o tamanho do conjunto amostral ideal ou estabelecer um conjunto de aprendizado fixo e investigar a melhor arquitetura de rede para esse conjunto.

No caso específico da Rede PMC, utilizado nesse trabalho, recomenda-se alguns cuidados listados a seguir.

Para o cálculo do erro para cada neurônio do PMC, deve-se saber a derivada da função de ativação associada aquele neurônio, ou seja a função de ativação deve ser contínua e diferenciável. Haykin (2008), sugere o uso das funções de ativação não-lineares do tipo sigmoidais, pois através delas os pesos sinápticos são modificados mais intensamente e mais rapidamente (em termos de iterações necessárias para o aprendizado) nos neurônios da rede, contribuindo para uma melhor convergência e estabilidade durante o processo de aprendizagem.

Silva et al. (2010) ressaltam a importância da normalização individualizada que todas as variáveis de entrada e saída da rede precisam sofrer em relação aos seus respectivos valores mínimos e máximos, considerando todos os dados disponíveis, e garantindo que tais valores estejam contidos no conjunto de aprendizagem. Assegurando que os valores estejam compreendidos na faixa de variação dinâmica das funções de ativação das camadas escondidas (tangente hiperbólica, Figura 38), afim de evitar a saturação dos neurônios. Caso não seja realizado esse procedimento, os valores de máximos e mínimos estarão no conjunto de teste, implicando à redução dos domínios referentes às variáveis do conjunto de aprendizagem. Deve-se de forma similar a normalização efetuada nas amostras de entrada e saída no pré processamento, realizar a operação de desnormalização no pós processamento, afim de converter as respostas dos neurônios de saída da rede para os valores que representam o domínio real da aplicação.




Figura 38 – Domínios de normalização para função de ativação tangente hiperbólica (adaptado de Silva et al., 2010)

LeCun (1993) apud Haykin (2008) aponta que no processo de aprendizagem por retropropagação as variáveis de entrada contidas no conjunto devem ser não correlacionadas, afim de evitar redundâncias na rede, otimizar o tempo de processamento e obter melhores respostas da rede.

Os neurônios ocultos exercem um papel decisivo na operação de um PMC com aprendizagem por retropropagação, pois atuam como detectores de características. Não existem regras claras para se definir quantas unidades devem existir nas camadas ocultas, quantas camadas são necessárias, ou como devem ser as conexões entre essas unidades.

Braga et al. (2000) recomendam a utilização de função de adaptação de aprendizagem com a utilização do termo *momentum*, pois é uma técnica utilizada para acelerar o processo de treinamento e evitar mínimos locais na superfície de erro. Sua grande utilização é influenciada por ser ela uma técnica simples e efetiva de ajuste dos pesos, aumentando a velocidade de aprendizado (aceleração) e reduzindo o perigo de instabilidade. O termo *momentum* pode acelerar a aprendizagem em regiões muito planas da superfície de erro. Além disso, suprime a oscilação de pesos em vales e depressões.

A atenção na quantificação de neurônios nas camadas ocultas está associada a existência de um número excessivo de neurônios, tornando a rede tão flexível que se torna especialista no conjunto de aprendizagem, tipificando assim uma condição denominada *overfitting*. Quando ocorre essa condição, diz-se que a rede memorizou padrões de aprendizagem e gravou suas peculiaridades. Por outro lado, caso a rede tenha um número insuficiente de neurônios, esta terá que trabalhar com um número excessivo de restrições na tentativa de modelar o problema, podendo não conseguir extrair e armazenar as características necessárias para implementação das

hipóteses a respeito do comportamento do processo, caracterizando assim uma condição denominada *underfitting*.

Uma ferramenta estatística denominada Regra da parada antecipada baseada na validação cruzada é um poderoso artifício para se evitar *overfitting* (Haykin, 2008). Resumidamente, consiste em: Inicialmente, o conjunto de dados são divididos em dois subconjuntos, de forma aleatória: estimação (aprendizagem) e validação. A aprendizagem, realizada com o subconjunto de estimação, é cessada periodicamente e o erro da rede é calculado em relação ao subconjunto de validação (após um número específico de épocas). A rede é testada com o subconjunto de validação após cada período de aprendizagem. Ao observar que o erro do subconjunto de validação começa a crescer, mesmo com o erro de treinamento decrescendo, interrompe-se a aprendizagem (ponto de parada antecipada). Este processo pode ser verificado na Figura 39.




Figura 39 – Regra da parada antecipada baseada na validação cruzada (adaptado de Haykin, 2008)

2.3.7 Função de Aprendizagem “trainbr”

A função de treinamento de rede utilizada neste trabalho foi a “*trainbr*” que atualiza os valores dos pesos e bias de acordo com a otimização de Levenberg-Marquardt. Em um processo denominado *Bayesian regularization*, que ocorre dentro do algoritmo de Levenberg-Marquardt, é realizada uma combinação ideal dos erros quadráticos e dos pesos, afim de produzir uma rede que generalize bem os resultados, utilizando poucas épocas de treinamento e convergindo mais rapidamente se comparadas com outras funções de treinamento.

A função “*trainbr*” utiliza o artifício da Regra da parada antecipada, pois utiliza poucas épocas de treinamento para obter um rede neural com boa capacidade de generalização, evitando o problema do *overfitting*. Com isso, elimina-se o problema da estimativa da arquitetura (tamanho) ideal da rede, pois mesmo que se utilizasse uma rede com grande número de neurônios nas camadas escondidas, não geraria uma rede especialista no conjunto de dados de treinamento.

O algoritmo *trainbr* geralmente funciona melhor quando as entradas (*inputs*) e alvos ou metas (*targets*) da rede são dimensionadas para que estejam no intervalo [-1,1]. (MATLAB, 2017)

Ao utilizar o algoritmo “*trainbr*”, é importante deixar o *software* processar as iterações até que o número efetivo de parâmetros tenha sido alcançado, isto geralmente ocorre quando o *software* apresenta a mensagem “*Maximum mu reached*” (máximo μ alcançado), sendo um bom indicativo de que o algoritmo processou todas as informações necessárias para o bom funcionamento da rede. (MATLAB, 2017)

O parâmetro “*mu*” utilizado neste algoritmo é denominado Parâmetro de ajuste de Marquardt (“*Marquardt adjustment parameter*”).

2.3.8 Função de adaptação de aprendizagem “*learngdm*”

A função de adaptação de aprendizagem utilizada neste trabalho foi a “*learngdm*”, que é uma função de aprendizado que utiliza o gradiente descendente dos pesos e bias com *momentum*.

Esta função de adaptação de aprendizagem é utilizada quando se quer evitar os pontos de mínimos locais e encontrar o mínimo global na superfície de erro.

A partir da entrada, *learngdm* calcula para um determinado neurônio, a variação dos pesos e do bias, a taxa de aprendizado e a constante de *momentum*, de acordo com o gradiente descendente com *momentum*.

2.4 Aplicação de RNA em Geotecnia

Na Engenharia Geotécnica as RNAs possuem uma gama de aplicações, dentre elas: classificação de solos, acréscimo de tensões no solo, fundações, previsão de recalques, barragens, mapeamento geotécnico, geotecnia ambiental,

túneis, estimativa de permeabilidade de solos, entre tantas outras, mostrando-se uma promissora área de estudo.

Abaixo serão listados alguns trabalhos mostrando as áreas geotécnicas citadas acima no âmbito nacional.

Martinez-Carvajal (2006) utilizou um sistema híbrido constituído de RNA e Elementos Finitos através do *software* ALLFINE para realizar a modelagem constitutiva de areias. Utilizou um banco de dados com ensaios de laboratório contemplando um vasto conjunto de trajetórias de tensões do tipo convencional e do tipo compressão isotrópica, além de trajetórias no plano octaédrico. Mostrou em seu trabalho como utilizar RNAs informando a elas dados experimentais para receber como resposta o comportamento constitutivo das areias e caso seja utilizado um código de elementos finitos, atuar como um operador constitutivo afim de solucionar problemas de contorno. As simulações mostraram-se satisfatórias.

Um estudo apresentado por Ruffier et al. (1998) mostrou uma aplicação de RNA ao estudo de capacidade de carga de fundações solicitadas a esforços de tração, quando assentadas em terrenos inclinados.

Carrasco Gutiérrez (2003) empregou a técnica de redes neurais artificiais e modelos estatísticos para análise, modelagem e previsão dos valores de vazão e de cargas de pressão na barragem Corumbá I, do sistema Furnas Centrais Elétricas, a partir dos dados de instrumentação disponíveis desde 1997. A previsão de valores prováveis pode auxiliar em tomadas de decisão durante a operação da barragem. Os resultados obtidos foram bastante satisfatórios, mostrando-se alternativa atraente para investigações de séries temporais por sua capacidade de análise de problemas de natureza não-linear e não-estacionários.

Biondi Neto et al. (2006) utilizaram dados no treinamento da RNA obtidos de situações reais, com a classificação validada pelo método de determinação do comportamento do solo através do Teste da Penetração do Cone (CPT). Foram usadas duas variáveis de entrada: q_c , que indica a resistência da ponta do cone e R_f , razão de atrito, que representa a relação entre a resistência de atrito lateral f_s e a resistência da ponta do cone, afim de mapear 12 tipos de solos, abrangendo desde solos finos e sensíveis, a areias pedregulhosas. Os resultados obtidos pela RNA, treinada pelo método resiliente de retro propagação de erro, acertou a classificação do solo em aproximadamente 98% dos casos.

O trabalho exposto por Chissolucombe (2009) aplicou RNA para estimar os deslocamentos induzidos pela escavação de um túnel em uma situação real do Metrô-DF. Resultou em respostas extremamente eficientes, comparativamente com métodos empíricos, analíticos e simulações numéricas ao utilizar um conjunto de dados para treinamento da rede que englobou todo o universo do problema.

Cabral et al. (2006) aplicaram Redes Neurais Artificiais na determinação de acréscimos de tensões verticais em solos, decorrentes de carregamentos infinitos trapezoidais. Os resultados fornecidos pela rede neural foram comparados com a solução gráfica de Fadum, e o erro máximo encontrado foi inferior a 3%, que pode ser considerado satisfatório, mostrando que as redes neurais artificiais são uma ferramenta promissora na determinação de acréscimos de tensão em solos.

Silva et al. (2006) empregaram RNA na obtenção de acréscimos de tensão no solo devido a carregamento circular. Utilizaram a Rede Neural para aproximação de funções com suas curvas representadas no ábaco de acréscimos de tensão devido a um carregamento circular, sendo apresentados os resultados de seu uso para a geração de acréscimos de tensão vertical no solo devido a um carregamento uniforme, circular e perfeitamente flexível. Os resultados mostraram agilidade e confiabilidade (devido aos baixos erros obtidos) quando utilizado o processamento em lote (quando se tem um número grande de valores de acréscimos de tensão a serem retirados do ábaco).

Um trabalho propondo aplicação e avaliação de uma rede neural artificial para escolha de áreas para aterro sanitário foi proposto por Nunes et al. (2007). Os autores verificaram o comportamento da RNA para generalização de padrões espaciais para seleção de áreas potenciais para disposição de resíduos sólidos urbanos no município de Presidente Prudente - SP. Como resultado a RNA conseguiu reconhecer os padrões espaciais dos dados de entrada, mostrando-se bastante coerentes com a realidade.

Nola (2015) avaliou dados geológico-geotécnicos prévios para a elaboração de carta de eventos perigosos de movimentos de massa gravitacionais por meio de redes neurais artificiais e probabilidade. Os modelos de RNAs e probabilidade condicional foram elaborados para o uso no *software* MATLAB[®] utilizando um conjunto de mapas e cartas geológico-geotécnicas, concluindo que existe uma necessidade de inserir dados que geralmente não são fornecidos em trabalhos rotineiros, tais como: levantamento da atividade, velocidade, volume e data da

ocorrência, caracterização das feições de movimento de massa gravitacionais, parâmetros de resistência dos materiais, dados de intensidade e distribuição pluviométrica da região, descontinuidades do substrato rochoso.

Uma aplicação das redes neurais artificiais do tipo *perceptron* na estimativa de recalques em estacas foi proposta por Araújo (2015). Para desenvolvimento do trabalho, foram realizadas análises de sondagens à percussão do tipo SPT e provas de carga estáticas em 199 estacas. A modelagem das RNAs foi feita utilizando o programa QNET 2000. O modelo apresentou ótimo desempenho, resultando em um coeficiente de correlação entre os recalques reais e os recalques modelados no treinamento de 0,99 e na validação de 0,98.

Silveira (2014) utilizou uma RNA relacionando o recalque em estacas isoladas com o tipo (hélice contínua, cravada metálica e escavada) e as propriedades geométricas das estacas (diâmetro e comprimento), a estratigrafia e as características de compacidade, ou consistência dos solos por meio dos resultados obtidos nos ensaios SPT, e a carga atuante, obtidas em provas de carga estáticas. A modelagem foi realizada através do *software* QNET 2000. A autora encontrou um coeficiente de correlação entre os recalques estimados e medidos na fase de validação de 0,94, tal valor pode ser considerado satisfatório, se tratando da previsão de um fenômeno complexo.

Uma estimativa de permeabilidade do solo a partir do índice de plasticidade do solo, utilizando RNA foi proposta por Lôbo et al. (2011). Uma campanha de ensaios de permeabilidade e classificação dos solos foi realizada na cidade de Medellín - Colômbia e por meio da RNA se estabeleceu uma correlação entre esses dois parâmetros. A correlação encontrada foi considerada satisfatória, obtendo-se um valor de 81,6%. Com esta correlação e a partir da realização de novos ensaios de classificação dos solos foi possível estimar a permeabilidade do solo para toda a cidade.

Ribeiro et al. (2018) utilizaram geoprocessamento e Redes Neurais Artificiais como técnicas de mapeamento geotécnico aplicado à pavimentação, utilizando variáveis biofísicas e espaciais para explicar o fenômeno modelado. As características pesquisadas (pedologia, geologia, geomorfologia, vegetação, altimetria e posição) se correlacionaram com os valores de CBR dos solos em duas energias de compactação: normal (CBR-N) e intermediária (CBR-I). Os dados foram retirados de projetos e estudos na área da Região Metropolitana de Fortaleza.

Foram gerados dois modelos de melhor ajuste para a geração de estimativas de CBR-N e CBR-I. As características geotécnicas estimadas por esses modelos permitiram a elaboração de dois Mapas Geotécnicos Neurais estratificados para prever valores de CBR-N e CBR-I. Os resultados mostraram que a técnica é promissora, tanto para estimar as propriedades mecânicas dos solos, quanto para prever sua ocorrência e localização na área estudada.

3 METODOLOGIA

Neste capítulo será apresentada a metodologia utilizada para a criação da Rede Neural Artificial, contemplando a ferramenta computacional utilizada (MATLAB[®]), as variáveis utilizadas, assim como a apresentação do banco de dados que compõe o presente trabalho.

3.1 MATLAB[®] - Ferramenta Computacional

A ferramenta computacional utilizada para gerar e analisar a Rede Neural Artificial foi o software MATLAB[®] (**MAT**rix **LAB**oratory), versão R2017a, da empresa *The Mathworks, Inc.*

O MATLAB[®] é um ambiente de programação e computação científica de alto nível, que permite implementar algoritmos, manipular matrizes, plotar funções, analisar dados e, principalmente, resolver problemas numéricos complexos. Os problemas e soluções são expressos somente como eles são escritos matematicamente, ao contrário da programação tradicional.

Seu processamento é composto em suma por equacionamentos matriciais. Combina programação textual e gráfica para projetar seu sistema em um ambiente de simulação, para realizar análise e posterior visualização de dados.

A vantagem de utilizar esta ferramenta computacional se dá pelo fato de se ter disponível diretamente milhares de algoritmos e dezenas de caixas de ferramentas (chamadas de “*ToolBoxes*”), permitindo se tornar especialista em diversas áreas de conhecimento, desde análise de elementos finitos, até o uso de inteligência artificial, como as Redes Neurais Artificiais.

O MATLAB[®] dispõe de *Toolboxes* de Redes Neurais Artificiais que fornecem algoritmos, modelos pré-treinados e aplicativos para criar, ensinar, treinar, visualizar e simular redes neurais artificiais. Com estes artifícios, pode-se executar classificação de padrões, regressões, agrupamentos, previsão de séries temporais, modelagem e controle de sistemas dinâmicos.

A partir da *Toolbox nntool (Neural Network Tool)*, mostrada na Figura 40, foi modelada toda a Rede Neural. Nesta caixa inicial, são definidos os dados de entrada (*input data*), os dados alvo (*target data*) e a Rede neural (*networks*). Após o processamento dos dados são apresentados os dados de saída (*output data*) e os

dados dos erros (*error data*). Para atribuir características à rede, deve-se clicar no botão “New” e aparecerá uma nova caixa de criação da rede, Figura 41, onde são atribuídos o nome (*name*) e as propriedades da rede (*network properties*). Através desta caixa é criada a rede propriamente dita, tipificando, através do tipo de rede (*network type*), e inserindo os dados de entrada (*input data*), os dados de alvo (*target data*). É escolhida a função de treinamento (*training function*), indicando a função de adaptação de aprendizado (*adaptation learning function*) e elegendo a função de desempenho (*performance function*). A arquitetura da rede também é desenvolvida ao quantificar o número de camadas escondidas ou ocultas da rede (*number of layers*), as propriedades de cada camada oculta (*properties for layer*) ao indicar o número de neurônios na camada (*number of neurons*) e a função de transferência ou de ativação (*transfer function*).

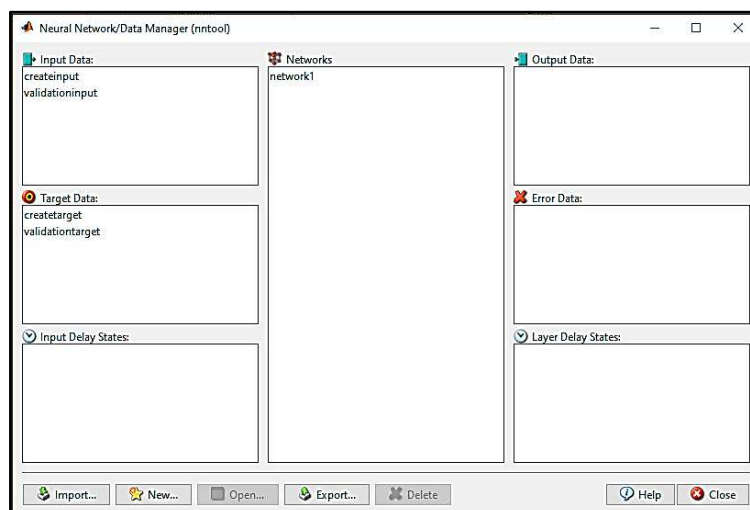


Figura 40 – Toolbox nntool

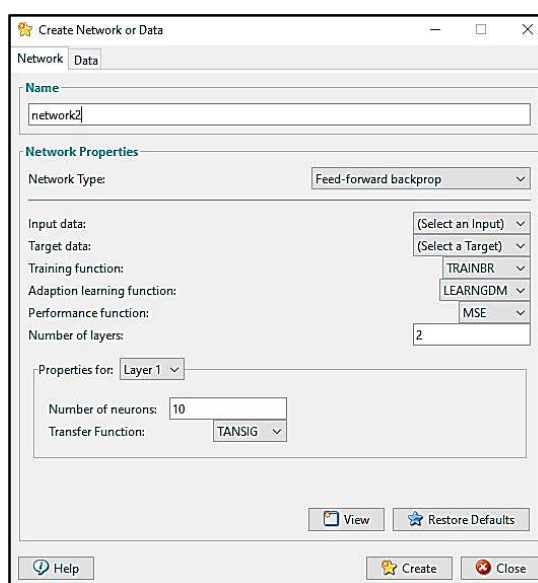


Figura 41 – Toolbox nntool, criando a rede neural artificial

Na presente dissertação, as redes testadas utilizaram a seguinte tipologia:

- tipo de rede (*network type*): *Feed-forward backpropagation*;
- função de treinamento (*training function*): *Bayesian regularization (trainbr)*;
- função de adaptação de aprendizado (*adaptation learning function*): *learnngdm*;
- função de desempenho (*performance function*): *mse (Mean Squared Error)*.

As arquiteturas testadas serão apresentadas mais adiante, mostrando o número de camadas escondidas e a quantidade de neurônios em cada camada escondida, porém em todas, a função de transferência (*transfer function*) utilizada nas camadas escondidas foi a “*tansig*” (tangente hiperbólica) e na camada de saída a “*purelin*” (linear).

3.2 Banco de Dados

Neste trabalho foram utilizados dois bancos de dados, um com dados de provas de carga estática, e outro com ensaios de carregamentos dinâmicos com o objetivo de verificar a viabilidade do uso das RNA na previsão da capacidade de carga. Nestes bancos de dados, sempre existia uma sondagem a percussão associada a cada prova de carga estática ou ensaio de carregamento dinâmico realizados.

O primeiro banco de dados, composto por resultados de provas de carga estáticas à compressão e sondagens à percussão, foi elaborado a partir do banco de dados utilizado por Lobo (2015). O banco de dados é composto por provas de cargas à compressão executadas em diversas regiões do Brasil ao longo das últimas quatro décadas e foram obtidos na literatura técnica e em arquivos de empresas de fundações. De um total de 328 provas de carga estáticas à compressão, 131 casos são de estacas cravadas pré-moldadas de concreto armado, 28 de estacas cravadas metálicas, 99 de estacas hélice contínua e 70 de estacas escavadas.

Para a definição da carga de ruptura da estaca Q_u , foi utilizado o Método preconizado pela NBR 6122 (2010). Em alguns casos onde carga de ruptura da estaca Q_u não ficava bem definida na curva carga x recalque, a mesma foi estimada através do Método de Van der Veen (1953), modificado por Aoki (1976).

O segundo banco de dados é composto de 21 ensaios de carregamento dinâmico executados em estacas raiz e de sondagens à percussão associadas.

Esses dados foram cedidos pela empresa Terratek e os ensaios foram executados nas cidades de Nova Iguaçu – RJ e em Roseira – SP.

No ANEXO A encontram-se as tabelas em função de cada tipo de estaca, com a identificação de cada estaca, comprimento, área da seção transversal, localização e a sondagem à percussão associada.

Os dois conjuntos de dados foram unidos para compor um único banco de dados, com um total de 349 elementos, gerando um conjunto de informações com diversos tipos de estacas, geometrias distintas, diferentes perfis de subsolo, resultando em diferentes cargas de ruptura da estaca.

3.3 Variáveis

Neste trabalho, foram adotadas como variáveis entrada, os dados da geometria da estaca e valores do N_{SPT} ao longo da estaca, e como variável de saída a carga de ruptura da estaca. Na Tabela 12 são mostradas as variáveis adotadas, sua descrição, o tipo de variável e a forma de aquisição.

Tabela 12 – Variáveis utilizadas na Rede Neural

Variáveis	Descrição	Tipo	Aquisição
L	Comprimento da Estaca	Entrada	Projeto
A_t	Área da seção transversal da estaca	Entrada	Projeto
N_{SPT}	N_{SPT} ao longo do comprimento da estaca	Entrada	Sondagem a Percussão
Q_u	Carga de ruptura da estaca	Saída	Provas de carga

A variável N_{SPT} foi subdividida em outras variáveis, com o objetivo de melhor representar a variação do N_{SPT} ao longo do comprimento da estaca. Foi realizada uma divisão da estaca em “n” segmentos e realizada a média do valor do N_{SPT} compreendido nas profundidades do trecho. Denominando as variáveis N_{SPT1} , caracterizando o N_{SPT} correspondente ao trecho 1 da estaca; N_{SPT2} , caracterizando o N_{SPT} correspondente ao trecho 2 da estaca; N_{SPTn} , caracterizando o N_{SPT} correspondente ao trecho “n” da estaca.

A divisão da estaca em “n” segmentos e a realização da média do N_{SPT} compreendido nas profundidades do segmento “n” foram feitas com o objetivo de

melhor representar a variação do comprimento das estacas, que variava de 3,0 m até 60,0 m. Com isso, foi possível homogeneizar os dados do N_{SPT} , fazendo com que cada estaca, independente do seu comprimento, tivesse o mesmo número de dados referente ao N_{SPT} . Além do fato de que é necessário ter o mesmo número de informações (variáveis) nos dados de entrada, para o software, MATLAB[®], realizar e processar a rede neural.

Foram realizados na presente dissertação, testes com três divisões diferentes de trechos para o comprimento de estaca: divisão da estaca em 20 segmentos, em 10 segmentos e 5 segmentos, gerando respectivamente, 20 variáveis ($N_{SPT1}, N_{SPT2}, \dots, N_{SPT20}$), 10 variáveis ($N_{SPT1}, N_{SPT2}, \dots, N_{SPT10}$) e 5 variáveis ($N_{SPT1}, N_{SPT2}, \dots, N_{SPT5}$).

3.4 Tratamento dos dados de entrada

Ao analisar o banco de dados utilizado neste trabalho, verificou-se que os dados de entrada e saída variavam de 0 à 21652, conforme Tabela 13, indicando a necessidade de normalizar esses dados, afim de uniformizar os valores com unidades diferentes e, em uma escala menor, essas informações para aplicar no modelo.

Tabela 13 – Máximos e mínimos das variáveis do banco de dados

Variável	Entrada			Saída
	L [m]	A_t [m ²]	N_{SPT}	Q_u [kN]
Valor mínimo	3,0	0,00473	0	20,5
Valor máximo	60,0	2,26980	45	21652,0

A normalização também se faz necessária devido ao emprego da função de treinamento (*training function*): *trainbr* e da função de transferência (*transfer function*) das camadas escondidas “*tansig*” necessitarem ser dimensionadas para que os dados estejam no intervalo [-1,1].

A normalização do banco de dados utilizada nesta dissertação foi realizada considerando uma relação linear entre os valores máximo, mínimo e a variável normalizada, conforme a Equação (60), no intervalo [-0,85, 0,85]. O objetivo foi evitar a zona de saturação do valores próximos aos extremos -1 e 1, ao aplicar a função de

transferência *tansig* (tangente hiperbólica), e garantir que os valores estejam na faixa de variação dinâmica, mostrada anteriormente na Figura 38.

$$\frac{X' - (-0,85)}{0,85 - (-0,85)} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (60)$$

sendo:

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.

A escolha por normalizar, tanto as variáveis de entrada como de saída, se deve também a alguns testes realizados durante o desenvolvimento do modelo, em que as variáveis não foram normalizadas, e os resultados mostraram-se de má qualidade.

4 APRESENTAÇÃO DOS RESULTADOS

4.1 Introdução

No presente capítulo, serão expostos os resultados dos modelos preditivos de carga de ruptura apresentados no Capítulo 4. Serão abordados quatro modelos e apresentados os dados referentes ao treinamento e teste, e validação das redes utilizando cada um dos modelos.

Conforme apresentado anteriormente, no presente trabalho foi utilizada a seguinte tipologia de rede neural em todos modelos testados no software MATLAB®:

- tipo de rede (*network type*): *Feed-forward backpropagation*;
- função de treinamento (*training function*): *Bayesian regularization (trainbr)*;
- função de adaptação de aprendizado (*adaptation learning function*): *learnsgdm*;
- função de desempenho (*performance function*): *mse (Mean Squared Error)*;
- função de transferência (*transfer function*): nas camadas escondidas, “*tansig*” (tangente hiperbólica) e na camada de saída “*purelin*” (linear).

Foram avaliados quatro modelos de redes neurais, conforme verificado na Tabela 14.

Tabela 14 – Modelos de redes neurais avaliados

Modelos	Variáveis de Entrada			Nº Variáveis de Entrada	Variável de Saída	Nº Variáveis de Saída
Modelo 01	L [m]	A_t [m ²]	$N_{SPT1}, N_{SPT2}, \dots, N_{SPT20}$	22	Q_u [kN]	1
Modelo 02	L [m]	A_t [m ²]	$N_{SPT1}, N_{SPT2}, \dots, N_{SPT20}$	22	Q_u [kN]	1
Modelo 03	L [m]	A_t [m ²]	$N_{SPT1}, N_{SPT2}, \dots, N_{SPT10}$	12	Q_u [kN]	1
Modelo 04	L [m]	A_t [m ²]	$N_{SPT1}, N_{SPT2}, \dots, N_{SPT5}$	7	Q_u [kN]	1

A partir da Tabela 14, pode-se notar que a principal diferença entre os modelos é o número de variáveis de entrada. Esta diferença deve-se ao fato, já explicado no capítulo anterior, das diferentes formas de atribuir o valor do N_{SPT} à estaca, dividindo a estaca em diferentes tamanhos: em 20 segmentos para os modelos 01 e 02, em 10 segmentos para o modelo 03 e em 5 segmentos para o modelo 04. Os modelos 01 e 02 possuem a mesma configuração, porém o que os

distingue, são o número de dados utilizados para formar os dados de entrada. Esta diferença entre os modelos 01 e 02 será detalhada mais adiante na abordagem de cada modelo. A Tabela 15 apresenta as principais características de cada modelo.

Tabela 15 - Características dos modelos

Modelo	Dados de entrada	Dados de treinamento e teste	Dados para validação	Variáveis para discretização da estaca	Variáveis de entrada
01	349	281	68	20	22
02	292	243	49	20	22
03	292	243	49	10	12
04	231	199	32	5	7

4.2 Modelo 01

No primeiro modelo testado, foram utilizadas todas as informações contidas no banco de dados, ou seja, 349 dados. Deste total, foram separados os dados para treinamento (*training*) e teste (*test*), e os dados para futura validação (*validation*) da rede.

Para treinamento e teste da rede, foram empregados 281 dados, aproximadamente 80% do total do banco de dados. E separados para validação, 68 dados, cerca de 20% dos dados iniciais.

Dos dados fornecidos para treinamento e teste da rede, o MATLAB[®] utiliza cerca de 85% para o treinamento, e os 15 % restantes para o teste interno. No entanto, o programa não explicita quais foram os dados utilizados para treinar a rede e quais foram utilizados para o teste. Este teste interno serve para verificar a capacidade de generalização da rede.

Os dados da validação não entram na criação da rede propriamente dita, e servem como um segundo teste para verificar a capacidade de generalização da rede. Neste caso, sabe-se quais os dados são fornecidos.

Das 22 variáveis de entrada utilizadas neste modelo, uma representa o comprimento da estaca; outra, a área da seção transversal da estaca; e 20, os valores de N_{SPT} a cada um dos 20 segmentos da estaca.

No Modelo 01 foram treinadas, testadas e validadas 12 redes com arquiteturas diferentes, sendo 6 redes com 1 camada oculta e outras 6 com duas camadas ocultas, conforme verificado na Tabela 16.

Tabela 16 – Arquiteturas utilizadas no Modelo 01

Arquiteturas		Descrição
1 Camada Oculta	A22:2:1	22 neurônios de entrada: 2 neurônios na camada oculta: 1 neurônio na camada de saída
	A22:4:1	22 neurônios de entrada: 4 neurônios na camada oculta: 1 neurônio na camada de saída
	A22:6:1	22 neurônios de entrada: 6 neurônios na camada oculta: 1 neurônio na camada de saída
	A22:11:1	22 neurônios de entrada: 11 neurônios na camada oculta: 1 neurônio na camada de saída
	A22:22:1	22 neurônios de entrada: 22 neurônios na camada oculta: 1 neurônio na camada de saída
	A22:44:1	22 neurônios de entrada: 44 neurônios na camada oculta: 1 neurônio na camada de saída
2 Camadas Ocultas	A22:2:2:1	22 neurônios de entrada: 2 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A22:3:2:1	22 neurônios de entrada: 3 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A22:4:2:1	22 neurônios de entrada: 4 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A22:6:2:1	22 neurônios de entrada: 6 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A22:11:2:1	22 neurônios de entrada: 11 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A22:22:2:1	22 neurônios de entrada: 22 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída

Ao final da etapa de treinamento e teste da rede, o MATLAB[®] fornece ao usuário um gráfico de *performance*, mostrando em qual época o processo foi finalizado, e mais três gráficos alvo x saída ("*target x output*"), onde exhibe o coeficiente de correlação do treinamento (R_{training}), o coeficiente de correlação do teste (R_{test}) e o coeficiente de correlação de todo o conjunto de dados (R_{all}). As informações de todas as arquiteturas treinadas e testadas do Modelo 01, encontram-se na Tabela 17.

Tabela 17 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 01

Arquiteturas		R_{training}	R_{test}	R_{all}	Critério de Paralisação do Treinamento e Teste	Nº de iterações alcançadas
1 camada oculta	A22:2:1	0,85	0,68	0,84	"Maximum mu reached"	181
	A22:4:1	0,92	0,79	0,89	"Maximum mu reached"	182
	A22:6:1	0,96	0,81	0,90	"Maximum mu reached"	317
	A22:11:1	0,99	-0,44	0,66	"Maximum mu reached"	322
	A22:22:1	0,99	-0,07	0,86	"Maximum mu reached"	567
	A22:44:1	0,99	0,20	0,91	"Maximum mu reached"	618
2 camadas ocultas	A22:2:2:1	0,88	0,71	0,84	"Maximum mu reached"	81
	A22:3:2:1	0,95	0,23	0,71	"Maximum mu reached"	177
	A22:4:2:1	0,96	0,53	0,72	"Maximum mu reached"	231
	A22:6:2:1	0,99	0,04	0,89	"Maximum mu reached"	419
	A22:11:2:1	0,99	0,02	0,76	"Maximum mu reached"	359
	A22:22:2:1	0,99	0,67	0,94	"Maximum epoch reached"	1000

A partir da Tabela 17, nota-se que algumas arquiteturas apresentam um elevado coeficiente de correlação no treinamento, tais como: A22:11:1, A22:22:1, A22:44:1, A22:6:2:1, A22:11:2:1, A22:22:2:1. Todas com $R_{\text{training}} = 0,99$. Porém, as mesmas apresentam baixos coeficientes de correlação no teste, o que mostra que apesar dessas redes serem bem treinadas, não possuem capacidade de generalização, devido aos baixos valores de R_{test} . Isto significa que ao apresentar

dados que não foram utilizados no treinamento, como por exemplo os dados da validação, a rede não possui boa capacidade de previsão de valores.

Ao avaliar uma rede em função dos coeficientes de correlação, deve-se procurar valores elevados de R_{training} e de R_{test} simultaneamente. Portanto, uma rede com boa capacidade de predição de valores deve possuir coeficiente de correlação de teste elevado e com valor próximo ao coeficiente de correlação de treinamento. Utilizando este conceito, a melhor rede encontrada foi A22:6:1, com $R_{\text{training}} = 0,96$ e $R_{\text{test}} = 0,81$. A Figura 42 apresenta o gráfico de desempenho, e a Figura 43 os gráficos “*target x output*”, mostrando os coeficientes de correlação da rede A22:6:1 utilizando o Modelo 01.




Figura 42 – Gráfico de desempenho da rede A22:6:1 – Modelo 01

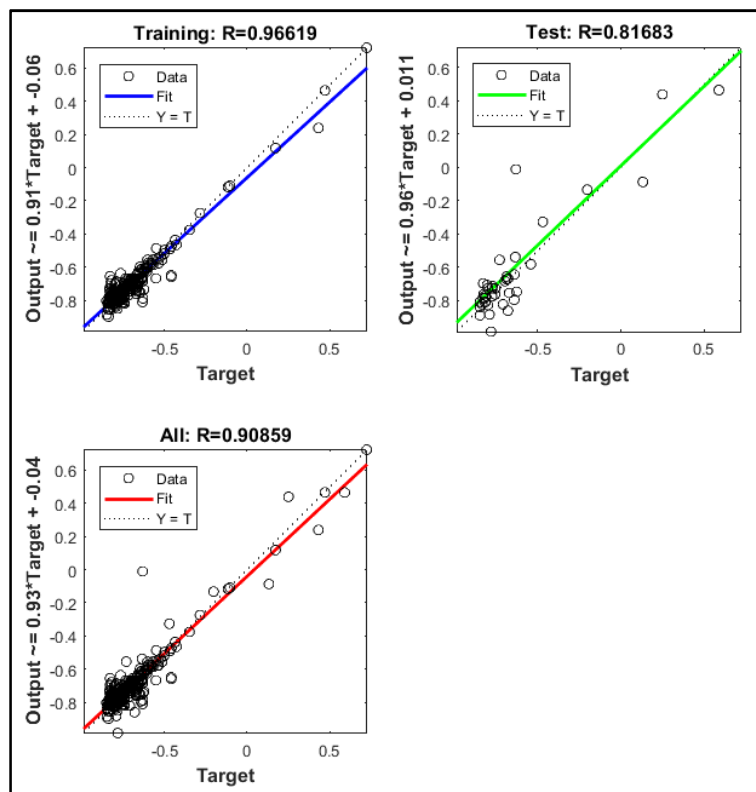


Figura 43 – Gráficos “target x output” da rede A22:6:1 – Modelo 01

Uma avaliação com os dados utilizados no treinamento e teste foi realizada, verificando os dados fornecidos ao programa (*target*), com os valores de saída do programa após treinamento da rede (*output*) e calculado o erro percentual em cada um dos 281 dados fornecidos para treinamento e teste da rede A22:6:1. O erro percentual foi calculado através da Equação (61).

$$EP(\%) = \left(\frac{X_{obtido} - X_{esperado}}{X_{esperado}} \right) \cdot 100(\%) \quad (61)$$

sendo:

$EP(\%)$ = Erro percentual;

X_{obtido} = valor obtido no programa após o treinamento e teste (*output*);

$X_{esperado}$ = valor esperado, dados fornecidos ao programa (*target*);

Uma tabela com os valores dos dados fornecidos ao programa (*target*), com os valores de saída do programa após treinamento da rede (*output*) e com o valor do erro percentual calculado em cada um dos 281 dados fornecidos para treinamento e teste da rede A22:6:1, encontra-se no

ANEXO B. A partir dessa tabela, foi gerado o gráfico da Figura 44.




Figura 44 – Gráfico Erro percentual por estaca – Treinamento e teste da rede A22:6:1

O erro percentual representa o quão distantes os resultados estão dos valores reais. No presente trabalho, considerou-se que a faixa de erro aceitável seria de 0% a 10%. Observa-se na Figura 44, poucos valores com erros aceitáveis (faixa de valores de 0 % até 10 %), e a maioria dos resultados com erros percentuais elevados (dentro de uma faixa de valores variando de 10 % a 50 %). Porém, o que chama a atenção é a presença de casos com erros muito elevados (maiores que 50 %), da ordem de 200 %, 400 %, até mesmo um caso com 2.800 %, o que não é esperado para uma rede com coeficientes de correlação $R_{\text{training}} = 0,96$ e $R_{\text{test}} = 0,81$.

A validação da rede foi realizada com os dados que não foram usados no treinamento e teste. Foram utilizados 68 dados para esse teste de verificação da generalização da rede. A checagem da validação também foi feita em função dos erros percentuais obtidos.

Uma tabela com os valores dos dados de validação fornecidos ao programa (*target*), com os valores de saída do programa após validação da rede (*output*) e com o valor calculado do erro percentual em cada um dos 68 dados fornecidos para

validação da rede A22:6:1 encontra-se no ANEXO C. A partir dessa tabela foi gerado o gráfico da Figura 45.




Figura 45 – Gráfico Erro percentual por estaca – Validação da rede A22:6:1

Observa-se na Figura 45, que os erros percentuais na validação são elevados e muito elevados e com casos extremos de erros percentuais da ordem de 500 %, até mesmo de -900 %. Os resultados sugerem que a rede não foi capaz de generalizar os dados e obter um resultado final com respostas satisfatórias.

Este comportamento dos erros percentuais altos e com casos pontuais de erros muito elevados apresentados no treinamento e teste, e na validação da rede A22:6:1, também foi constatado nas demais arquiteturas de rede do Modelo 01.

4.3 Modelo 02

O Modelo 02 foi desenvolvido com as mesmas arquiteturas do Modelo 01, observadas na Tabela 16. Porém, foi utilizado um número mais reduzido de informações no banco de dados. Isto decorre do fato que foi observado no banco de dados informações redundantes, ou seja, casos em que se atribuía a algumas

estacas o mesmo valor de comprimento, o mesmo valor de seção transversal, o mesmo perfil de subsolo (com os mesmos valores de N_{SPT}), porém com valores de carga de ruptura diferentes. Existia no banco de dados informações com os mesmos valores de “*inputs*”, porém com “*targets*” diferentes.

As informações redundantes do banco de dados foram retiradas, restando um total de 292 elementos, sendo 243 utilizados para treinamento e teste (aproximadamente 83 % do total) e 49 para validação da rede (cerca de 17 % do total).

Todas as 12 arquiteturas de rede foram treinadas e testadas pelo MATLAB[®], fornecendo o gráfico de *performance* e os três gráficos de alvo x saída (“*target x output*”). As informações retiradas desses gráficos encontram-se na Tabela 18.

Tabela 18 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 02

Arquiteturas		R_{training}	R_{test}	R_{all}	Critério de Paralisação do Treinamento e Teste	Nº de iterações alcançadas
1 camada oculta	A22:2:1	0,91	0,55	0,88	"Maximum mu reached"	72
	A22:4:1	0,95	0,42	0,80	"Maximum mu reached"	225
	A22:6:1	0,98	0,39	0,95	"Maximum mu reached"	190
	A22:11:1	0,99	0,89	0,95	"Maximum mu reached"	330
	A22:22:1	0,99	0,40	0,94	"Maximum epoch reached"	1000
	A22:44:1	0,98	0,31	0,96	"Maximum mu reached"	532
2 camadas ocultas	A22:2:2:1	0,93	0,53	0,91	"Maximum mu reached"	215
	A22:3:2:1	0,96	0,36	0,89	"Maximum mu reached"	216
	A22:4:2:1	0,95	0,55	0,90	"Maximum mu reached"	138
	A22:6:2:1	0,97	0,80	0,94	"Maximum mu reached"	226
	A22:11:2:1	0,99	-0,02	0,66	"Maximum epoch reached"	1000
	A22:22:2:1	0,99	0,19	0,87	"Maximum epoch reached"	1000

A avaliação da rede de melhor desempenho levou em consideração o mesmo conceito aplicado no Modelo 01, buscando-se a rede com os maiores R_{training} e de R_{test} simultaneamente. Utilizando este julgamento, a melhor rede encontrada foi

A22:11:1, com $R_{\text{training}} = 0,99$ e $R_{\text{test}} = 0,89$. A Figura 46 e a Figura 47 mostram os gráficos de *performance*, e os gráficos “*target x output*”, indicando os coeficientes de correlação, da rede A22:11:1 utilizando o Modelo 02.




Figura 46 – Desempenho da rede A22:11:1 – Modelo 02

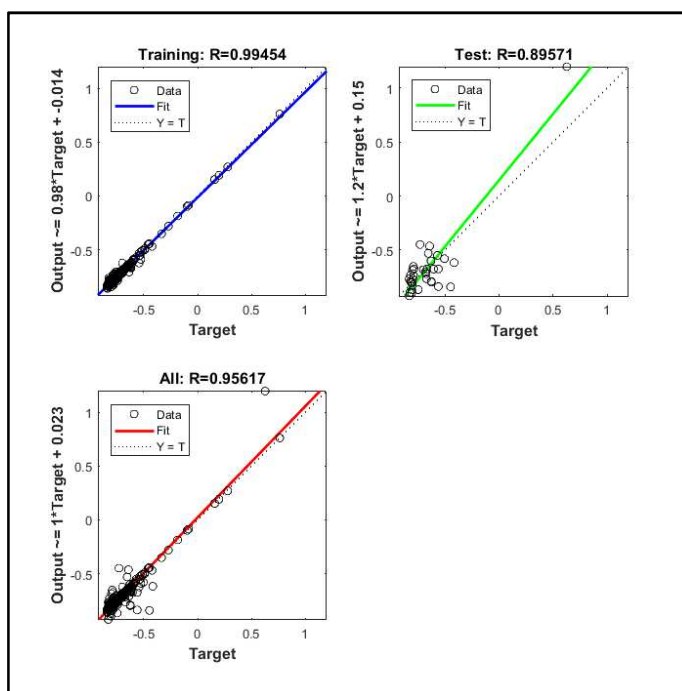


Figura 47 – Gráficos “*target x output*” da rede A22:11:1 – Modelo 02

A checagem com os dados utilizados no treinamento e teste foi realizada, verificando os dados fornecidos ao programa (*target*), com os valores de saída do programa após treinamento da rede (*output*). Foi calculado o erro percentual em

cada um dos 243 dados fornecidos para treinamento e teste da rede A22:11:1. O ANEXO D apresenta os dados que serviram para a criação do gráfico da Figura 48.




Figura 48 – Erro percentual por estaca – Treinamento e teste da rede A22:11:1

Observa-se na Figura 48, muitos valores com erros aceitáveis (de 0 % até 10 %), resultados com erros percentuais elevados (variando de 10 % a 50 %), e alguns casos de erros muito elevados (maiores que 50 %), com picos de 300 % a 400 %.

A validação da rede foi realizada com os 49 dados que não foram usados no treinamento e teste. A checagem da validação também foi feita em função dos erros percentuais obtidos.

Uma tabela com os valores dos dados de validação fornecidos ao programa (*target*), com os valores de saída do programa após validação da rede (*output*) e com o valor calculado do erro percentual em cada uma das 49 dados fornecidos para validação da rede A22:11:1, encontra-se no ANEXO E. A partir dessa tabela foi gerado o gráfico da Figura 49.




Figura 49 – Erro percentual por estaca – Validação da rede A22:11:1

Observa-se na Figura 49, que os erros percentuais na validação possuem poucos casos aceitáveis e são em sua maioria elevados e muito elevados, com casos extremos de erros percentuais de 900 %. Mostrando que a rede não foi capaz de generalizar os dados e apresentar respostas coesas.

Esse comportamento dos erros percentuais elevados e muito elevados apresentados no treinamento e teste, e na validação da rede A22:11:1, também foi constatado nas demais arquiteturas de rede do Modelo 02.

Cabe ressaltar que, apesar de na maioria dos casos, não terem sido encontrados erros dentro de uma faixa considerada aceitável, houve uma melhoria na rede, quando comparada ao Modelo 01, ao eliminar dados que geravam “confusão” na rede.

4.4 Modelo 03

No Modelo 03 foi utilizado um banco de dados com 292 elementos, sendo 243 utilizados para treinamento e teste (aproximadamente 83 % do total) e 49 para validação da rede (cerca de 17 % do total). O mesmo número de elementos do Modelo 02, sem as informações redundantes contidas no Modelo 01.

Este modelo difere dos anteriores pelo número de variáveis de entrada, em um total de 12, enquanto que nos anteriores eram 22 variáveis. Esta redução do número de variáveis, decorre da representação do comprimento da estaca em 10 segmentos e atribuição de uma média dos valores de N_{SPT} . Das 12 variáveis de entrada, uma, representa o comprimento da estaca; outra, a área da seção transversal da estaca; e 10 são atribuídas ao N_{SPT} de cada um dos 10 segmentos.

Foram treinadas, testadas e validadas 16 redes com arquiteturas diferentes, sendo 9 redes com 1 camada oculta e 7 com duas camadas ocultas, conforme verificado na Tabela 19.

Tabela 19 – Arquiteturas utilizadas no Modelo 03

Arquiteturas		Descrição
1 Camada Oculta	A12:2:1	12 neurônios de entrada: 2 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:3:1	12 neurônios de entrada: 3 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:4:1	12 neurônios de entrada: 4 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:5:1	12 neurônios de entrada: 5 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:6:1	12 neurônios de entrada: 6 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:12:1	12 neurônios de entrada: 12 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:24:1	12 neurônios de entrada: 24 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:36:1	12 neurônios de entrada: 36 neurônios na camada oculta: 1 neurônio na camada de saída
	A12:48:1	12 neurônios de entrada: 48 neurônios na camada oculta: 1 neurônio na camada de saída

Arquiteturas		Descrição
2 Camadas Ocultas	A12:3:2:1	12 neurônios de entrada: 3 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A12:4:2:1	12 neurônios de entrada: 4 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A12:6:2:1	12 neurônios de entrada: 6 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A12:6:3:1	12 neurônios de entrada: 6 neurônios na primeira camada oculta: 3 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A12:12:6:1	12 neurônios de entrada: 12 neurônios na primeira camada oculta: 6 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A12:14:6:1	12 neurônios de entrada: 14 neurônios na primeira camada oculta: 6 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A12:24:6:1	12 neurônios de entrada: 24 neurônios na primeira camada oculta: 6 neurônios na segunda camada oculta: 1 neurônio na camada de saída

As informações retiradas do gráfico de *performance* e dos três gráficos de alvo x saída ("*target x output*") de todas arquiteturas apresentadas, encontram-se na Tabela 20.

Tabela 20 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 03

Arquiteturas		R_{training}	R_{test}	R_{all}	Critério de Paralisação do Treinamento e Teste	Nº de iterações alcançadas
1 camada oculta	A12:2:1	0,96	0,73	0,96	"Maximum mu reached"	92
	A12:3:1	0,95	0,93	0,93	"Maximum mu reached"	871
	A12:4:1	0,98	0,68	0,96	"Maximum epoch reached"	1000
	A12:5:1	0,98	0,88	0,97	"Maximum mu reached"	160
	A12:6:1	0,98	0,89	0,97	"Maximum mu reached"	129
	A12:12:1	0,99	0,86	0,98	"Maximum mu reached"	250
	A12:24:1	0,98	0,84	0,97	"Maximum mu reached"	232
	A12:36:1	0,99	0,60	0,96	"Maximum mu reached"	827
	A12:48:1	0,98	0,79	0,96	"Maximum mu reached"	606

Arquiteturas		R_{training}	R_{test}	R_{all}	Critério de Paralisação do Treinamento e Teste	Nº de iterações alcançadas
2 camadas ocultas	A12:3:2:1	0,98	0,51	0,96	"Maximum mu reached"	141
	A12:4:2:1	0,98	0,88	0,97	"Maximum mu reached"	201
	A12:6:2:1	0,99	0,82	0,96	"Maximum mu reached"	543
	A12:6:3:1	0,99	0,66	0,97	"Maximum mu reached"	587
	A12:12:6:1	0,99	0,65	0,97	"Maximum mu reached"	482
	A12:14:6:1	1,00	0,63	0,89	"Maximum epoch reached"	1000
	A12:24:6:1	1,00	0,64	0,89	"Maximum epoch reached"	1000

Com os resultados apresentados na Tabela 20 e adotando-se o mesmo julgamento realizado nos modelos anteriores, a rede considerada de melhor desempenho foi a A12:3:1, com $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,93$. Os gráficos de *performance* e os gráficos “*target x output*” mostrando os coeficientes de correlação da rede A12:3:1 estão apresentados na Figura 50 e na Figura 51, respectivamente.




Figura 50 – Gráfico de desempenho da rede A12:3:1 – Modelo 03

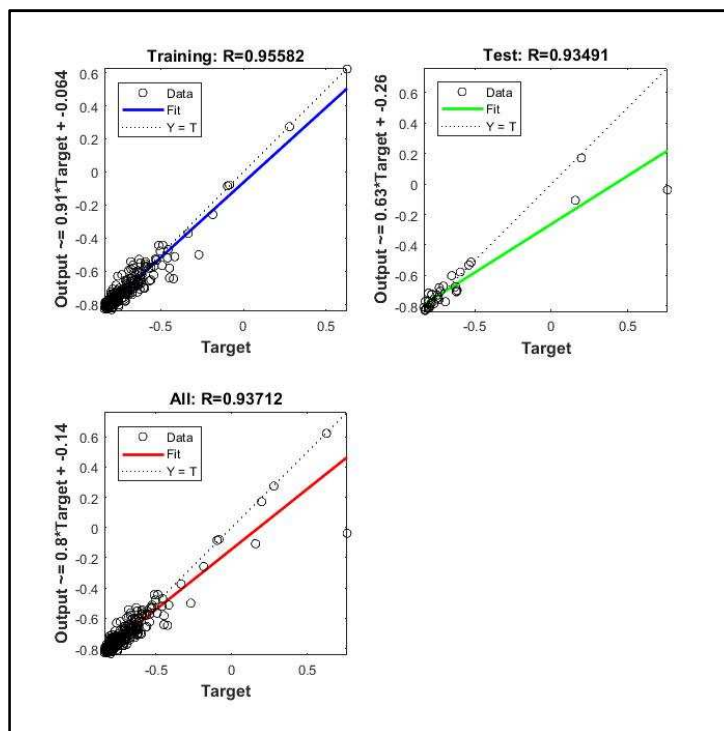


Figura 51 – Gráficos “target x output” da rede A12:3:1 – Modelo 03

O ANEXO F reúne os dados utilizados no treinamento e teste da rede A12:3:1, com os elementos fornecidos ao programa (*target*), os valores de saída após treinamento da rede (*output*) e o erro percentual calculado. A partir desses dados, foi gerado o gráfico apresentado na Figura 52.

A partir desta Figura, observa-se alguns valores com erros aceitáveis (de 0 % até 10 %), a maioria dos casos com erros elevados (variando de 10 % a 50 %), e casos de erros muito elevados (maiores que 50 %), com extremos da ordem de 300 %.

Uma tabela com os valores dos dados de validação fornecidos ao programa (*target*), com os valores de saída do programa após validação da rede (*output*) e com o valor calculado do erro percentual em cada uma dos 49 dados fornecidos para validação da rede A12:3:1, encontra-se no ANEXO G. A partir dessa tabela foi gerado o gráfico de erro percentual apresentado na Figura 53.




Figura 52 – Gráfico Erro percentual por estaca – Treinamento e teste da rede A12:3:1




Figura 53 – Erro percentual por estaca – Validação da rede A12:3:1

Observa-se na Figura 53, que na maioria dos casos, os erros percentuais na validação são elevados, entre 10% a 50 %. A rede forneceu poucos valores aceitáveis (de 0 % até 10 %) e alguns casos de erros percentuais muito elevados (maiores que 50 %). Os resultados mostram uma melhora nos valores dos erros percentuais quando comparados ao Modelos 01 e 02, porém ainda apresentando valores insatisfatórios, mostrando que a rede não foi capaz de generalizar os dados.

Esse comportamento apresentado pela rede A12:3:1, dos erros percentuais apresentados no treinamento e teste, e validação, também foi constatado nas demais arquiteturas de rede do Modelo 03, com exceção das redes A12:14:6:1 e A12:24:6:1. Essas duas redes com comportamento atípico são mostradas na Figura 54 e Figura 55.




Figura 54 – Gráfico Erro percentual por estaca – Treinamento e teste das redes A12:14:6:1 e A12:24:3:1

Observa-se comportamento similar dos erros percentuais no treinamento e teste das duas redes apresentadas na Figura 54. Grande parte dos casos com erros na faixa de valores considerada aceitável (de 0 % até 10 %), e alguns casos com erros percentuais muito elevados (maiores que 50 %), com picos em torno de 700 %.




Figura 55 – Gráfico Erro percentual por estaca – Validação das rede A12:14:6:1 e A12:24:6:1

Apesar das redes A12:14:6:1 e A12:24:6:1 apresentarem no treinamento e teste um desempenho com muitos casos de erros percentuais próximos de zero, quando foi realizada a validação, observa-se na Figura 55, poucos casos com erros aceitáveis e muitos casos com erros elevados e muito elevados, com extremos da ordem de 700 %, mostrando uma melhora se comparado aos Modelos 01 e 02, porém indicando também uma incapacidade de generalização dessas redes.

4.5 Modelo 04

O Modelo 04 foi desenvolvido utilizando como base o banco de dados utilizado nos Modelos 02 e 03, porém restringindo o comprimento das estacas até 20 m. Assim, o banco de dados ficou com 231 elementos, sendo 199 utilizados para treinamento e teste, e 32 para validação da rede.

Este modelo possui 7 variáveis de entrada, decorrente da representação do comprimento da estaca em 5 segmentos e atribuição de uma média dos valores de N_{SPT} com a profundidade em que estes segmentos se encontram no subsolo. Das 7

variáveis de entrada, uma, representa o comprimento da estaca; outra, a área da seção transversal da estaca; 5, são atribuídas aos valores de N_{SPT} a cada um dos 5 segmentos da estaca.

A utilização neste modelo de estacas até 20 m foi concebida para melhor representar a média do N_{SPT} em cada segmento da estaca. Caso fosse utilizado todo o banco de dados, foi observado estacas com até 60 m de comprimento, gerando segmentos com média utilizando até 12 elementos (60 m dividido por 5 segmentos = 12 elementos). Realizar a média de 12 elementos (12 m seguidos de N_{SPT}) não representaria bem o trecho de subsolo. Ao optar por restringir até 20 m de comprimento, são gerados segmentos com média utilizando no máximo 4 elementos (20 m dividido por 5 segmentos = 4 elementos), melhor caracterizando os trechos de subsolo.

Foram treinadas, testadas e validadas 20 redes com arquiteturas diferentes, sendo 11 redes com 1 camada oculta e 9 com duas camadas ocultas, conforme verificado na Tabela 21.

Tabela 21 – Arquiteturas utilizadas no Modelo 04

Arquiteturas		Descrição
1 Camada Oculta	A7:2:1	7 neurônios de entrada: 2 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:3:1	7 neurônios de entrada: 3 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:4:1	7 neurônios de entrada: 4 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:5:1	7 neurônios de entrada: 5 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:6:1	7 neurônios de entrada: 6 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:7:1	7 neurônios de entrada: 7 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:14:1	7 neurônios de entrada: 14 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:21:1	7 neurônios de entrada: 21 neurônios na camada oculta: 1 neurônio na camada de saída

Arquiteturas		Descrição
	A7:28:1	7 neurônios de entrada: 28 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:35:1	7 neurônios de entrada: 35 neurônios na camada oculta: 1 neurônio na camada de saída
	A7:70:1	7 neurônios de entrada: 70 neurônios na camada oculta: 1 neurônio na camada de saída
2 Camadas Ocultas	A7:2:2:1	7 neurônios de entrada: 2 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:3:2:1	7 neurônios de entrada: 3 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:4:2:1	7 neurônios de entrada: 4 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:6:2:1	7 neurônios de entrada: 6 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:7:2:1	7 neurônios de entrada: 7 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:14:2:1	7 neurônios de entrada: 14 neurônios na primeira camada oculta: 2 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:3:3:1	7 neurônios de entrada: 3 neurônios na primeira camada oculta: 3 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:14:3:1	7 neurônios de entrada: 14 neurônios na primeira camada oculta: 3 neurônios na segunda camada oculta: 1 neurônio na camada de saída
	A7:21:3:1	7 neurônios de entrada: 21 neurônios na primeira camada oculta: 3 neurônios na segunda camada oculta: 1 neurônio na camada de saída

As informações retiradas do gráfico de *performance* e dos três gráficos de alvo x saída (“*target x output*”) de todas arquiteturas apresentadas, encontram-se na Tabela 22.

Tabela 22 – Coeficientes de correlação, critérios de paralisação e número de iterações alcançadas no Modelo 04

Arquiteturas		R_{training}	R_{test}	R_{all}	Critério de Paralisação do Treinamento e Teste	Nº de iterações alcançadas
1 camada oculta	A7:2:1	0,93	0,71	0,82	"Maximum mu reached"	114
	A7:3:1	0,91	0,93	0,91	"Maximum mu reached"	90
	A7:4:1	0,93	0,75	0,86	"Maximum mu reached"	129
	A7:5:1	0,94	0,74	0,93	"Maximum mu reached"	136
	A7:6:1	0,96	0,82	0,95	"Maximum mu reached"	239
	A7:7:1	0,95	0,96	0,94	"Maximum mu reached"	262
	A7:14:1	0,99	0,68	0,95	"Maximum mu reached"	454
	A7:21:1	0,99	0,83	0,92	"Maximum mu reached"	523
	A7:28:1	0,98	0,38	0,77	"Maximum mu reached"	840
	A7:35:1	0,99	0,88	0,95	"Maximum epoch reached"	1000
A7:70:1	0,95	0,78	0,94	"Maximum epoch reached"	1000	
2 camadas ocultas	A7:2:2:1	0,91	0,90	0,91	"Maximum mu reached"	107
	A7:3:2:1	0,95	0,84	0,94	"Maximum mu reached"	137
	A7:4:2:1	0,96	0,70	0,94	"Maximum mu reached"	231
	A7:6:2:1	0,97	0,62	0,91	"Maximum mu reached"	297
	A7:7:2:1	0,98	0,82	0,91	"Maximum mu reached"	346
	A7:14:2:1	0,99	0,49	0,84	"Maximum mu reached"	915
	A7:3:3:1	0,96	0,72	0,92	"Maximum mu reached"	243
	A7:14:3:1	0,99	0,48	0,95	"Maximum mu reached"	417
	A7:21:3:1	0,99	0,52	0,85	"Maximum epoch reached"	1000

Ao analisar os resultados da Tabela 22 e utilizar o mesmo critério de julgamento adotado nos modelos anteriores, a rede de melhor desempenho foi a A7:7:1, com $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,96$. Os gráficos de performance e os gráficos “*target x output*” mostrando os coeficientes de correlação da rede A7:7:1 estão apresentados na Figura 56 e Figura 57, respectivamente.




Figura 56 – Gráfico de desempenho da rede A7:7:1 – Modelo 04

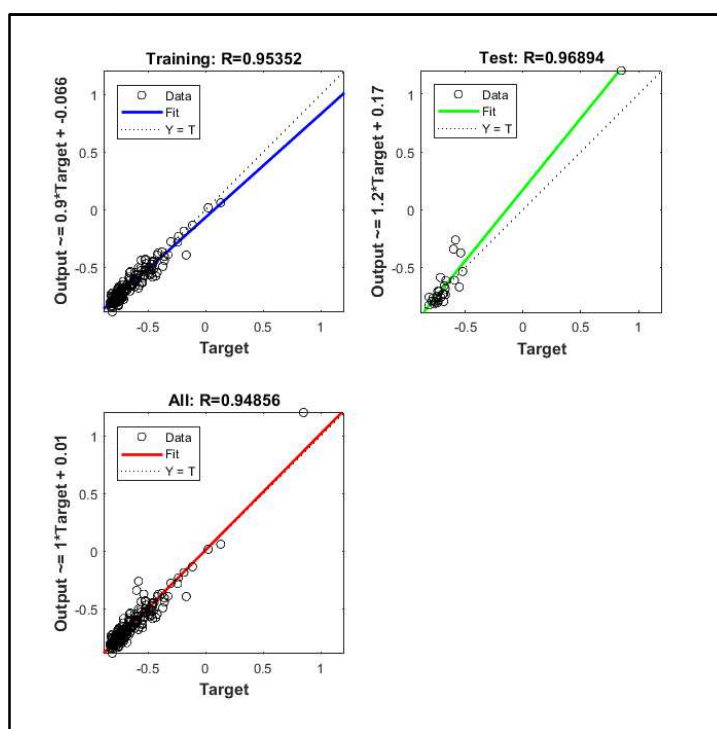


Figura 57 – Gráficos “target x output” da rede A7:7:1 – Modelo 04

Os dados utilizados no treinamento e teste da rede A7:7:1, com os elementos fornecidos ao programa (*target*), os valores de saída após treinamento da rede (*output*) e o erro percentual calculado, encontram-se no ANEXO H. A partir desses dados foi gerado o gráfico apresentado na Figura 58.




Figura 58 – Gráfico Erro percentual por estaca – Treinamento e teste da rede A7:7:1

A análise dos resultados apresentados na Figura 58 permitiu observar alguns valores com erros aceitáveis entre 0 até 10 %, muitos resultados dentro de uma faixa de valores elevado variando de 10 % a 50 %, e alguns casos de erros muito elevados (maiores que 50 %), com extremo de 350 %. Os resultados mostraram-se melhores, quando comparados aos Modelos 01 e 02. Comportamento similar foi observado no Modelo 03.

Uma tabela com os valores dos dados de validação fornecidos ao programa (*target*), com os valores de saída do programa após validação da rede (*output*) e com o valor calculado do erro percentual para cada um dos 32 dados fornecidos para validação da rede A7:7:1, encontra-se no ANEXO I. A Figura 59 apresenta o gráfico gerado a partir dos dados do ANEXO I.




Figura 59 – Gráfico Erro percentual por estaca – Validação da rede A7:7:1

Observa-se na Figura 59, poucos resultados com erros percentuais aceitáveis e que na maioria dos casos, os erros percentuais na validação são elevados, entre 10 % a 50 %, apresentando alguns valores muito elevados, maiores que 50 %, com pico de 70 %. Este modelo apresentou melhora na magnitude dos erros percentuais na validação se comparados aos três modelos anteriores, porém ainda apresentando erros elevados e muito elevados. Mais uma vez, nota-se a incapacidade da rede em generalizar as informações e obter resultados com respostas satisfatórias.

4.6 Discussão dos Resultados

No presente item, serão discutidos os resultados obtidos a partir dos quatro modelos treinados, buscando-se compreender a incapacidade de generalização observada nas redes.

O Modelo 01 utilizou todas as 349 informações contidas no banco de dados, separados em 281 casos para treinar e testar a rede, e 68 casos para validação. Foram treinadas, testadas, e validadas neste modelo 12 arquiteturas diferentes. O modelo foi composto de 22 variáveis de entrada (L , A_T , N_{SPT1} , N_{SPT2}, \dots , N_{SPT20}) e 1 variável de saída (Q_u).

Para o Modelo 01 foi exposta a arquitetura eleita de melhor desempenho, A22:6:1, com $R_{\text{training}} = 0,96$ e $R_{\text{test}} = 0,81$, explicitando seus gráficos de *performance* (Figura 42) e “*output x target*” (Figura 43). Foi realizado um cálculo de erro percentual para o treinamento e teste, onde foram observados alguns casos com erros baixos (faixa de valores de 0 % até 10 %), a maioria dos resultados com erros percentuais elevados (dentro de uma faixa de valores variando de 10 % a 50 %), e alguns casos muito elevados (maiores que 50 %), com a presença de um caso extremo com 2.800 %. Este comportamento parece inesperado para uma rede com os coeficientes de correlação de treinamento e teste obtidos.

O cálculo dos erros percentuais também foi realizado para os dados da validação, encontrando um comportamento de erros elevados e muito elevados e com caso extremo de erro percentual da ordem de 900 %. Os resultados indicaram a incapacidade da rede de generalizar informações, ou seja, quando a rede é apresentada a dados novos, não utilizados no seu treinamento e teste, não possui boa capacidade de prever informações (neste caso, a carga de ruptura). Todas as demais arquiteturas do Modelo 01 apresentaram comportamento similar nos erros percentuais no treinamento e teste, e na validação.

Diante do observado no Modelo 01, foi desenvolvido o Modelo 02, reduzindo as informações contidas no banco de dados. Durante a pesquisa, foram verificadas informações redundantes, ou seja, mesmos dados de entrada (L , A_t , N_{SPT}), porém com diferentes dados de objetivo (Q_u), o que poderia ter influenciado o comportamento atípico de casos com erros elevadíssimos do Modelo 01.

O Modelo 02 utilizou 292 informações contidas no banco de dados, separados em 243 casos para treinamento e teste da rede e 49 casos para validação da rede.

Foram treinadas e testadas, e posteriormente validadas as mesmas arquiteturas e com as mesmas variáveis de entrada e saída do Modelo 01.

A arquitetura A22:11:1 foi considerada a de melhor *performance*, com $R_{\text{training}} = 0,99$ e $R_{\text{test}} = 0,89$. Os gráficos de *performance* e “*output x target*” foram apresentados na Figura 46 e na Figura 47.

A magnitude dos erros percentuais obtidos no treinamento e teste foi menor, se comparada a melhor rede do Modelo 01. Foram obtidos muitos valores com erros aceitáveis (de 0 % até 10 %), resultados com erros percentuais elevados (variando de 10 % a 50 %), e alguns casos de erros muito elevados (maiores que 50 %), com picos de 300 % a 400 %.

Os erros percentuais associados à validação da rede foram em sua maioria elevados e muito elevados, com casos extremos de erros percentuais de 900 %, mostrando que a rede utilizando este modelo 02 também não foi capaz de generalizar os dados. O comportamento apresentado pela rede A22:11:1 no treinamento e teste, e na validação também foi observado nas demais arquiteturas desse modelo.

Observada a incapacidade de generalização das redes utilizando os Modelos 01 e 02, uma nova testagem foi realizada com o Modelo 03, reduzindo o número de variáveis de entrada, visando um melhor comportamento da rede. Neste caso, a estaca foi discretizada em 10 elementos.

O Modelo 03 utilizou 292 informações contidas no banco de dados, separados em 243 casos para treinamento e teste da rede e 49 casos para validação da rede, assim como no Modelo 02. Foram treinadas e testadas, e validadas neste modelo 16 arquiteturas diferentes. O modelo era composto de 12 variáveis de entrada (L , A_T , $N_{\text{SPT}1}$, $N_{\text{SPT}2}, \dots, N_{\text{SPT}10}$) e 1 variável de saída (Q_u).

A arquitetura que apresentou melhor comportamento foi a A12:3:1, com $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,93$, cujos gráficos de *performance* e “*output x target*” foram apresentados na Figura 50 e na Figura 51.

Uma redução da amplitude dos erros no treinamento e teste foi obtida, se comparada aos Modelos 01 e 02, com valores de erros aceitáveis entre 0 até 10 %, muitos resultados dentro de uma faixa de valores variando de 10 % a 50 %, e novamente alguns casos de erros muito elevados (maiores que 50 %), com extremos da ordem de 300 %.

Na validação também foi observada uma melhora na magnitude dos erros, quando comparados aos Modelos 01 e 02, porém ainda com valores elevados, entre 10 % a 50 %, poucos valores aceitáveis (de 0 % até 10 %) e alguns casos de erros percentuais muito elevados, maiores que 50 %. Os resultados sinalizam, mais uma vez, que a rede não foi capaz de generalizar os dados.

As redes A12:14:6:1 e A12:24:6:1 manifestaram no treinamento e teste erros na maioria dos casos, percentuais aceitáveis (e próximos à zero), porém em aproximadamente 15 % dos casos com erros percentuais muito elevados, acima de 50 %. Na validação apresentaram poucos casos aceitáveis, e muitos casos com erros muito elevados, maiores que 50 %.

As redes testadas com o Modelo 03 também se apresentaram incapazes de generalizar valores.

Uma última tentativa foi realizada no objetivo de criar uma rede com capacidade de prever resultados com qualidade. Para o Modelo 04, foi realizada uma nova redução nos parâmetros de entrada. O modelo era composto de 7 variáveis de entrada (L , A_T , N_{SPT1} , $N_{SPT2}, \dots, N_{SPT5}$) e 1 variável de saída (Q_u). Neste caso, a estaca foi discretizada com 5 elementos, e limitada a 20 m de comprimento. Este procedimento foi adotado, de modo a evitar que se utilizasse a média de valores de N_{SPT} em trechos maiores que 4,0 m. Em alguns casos, o subsolo pode apresentar uma estratigrafia muito heterogênea, conduzindo a médias de valores que não representam satisfatoriamente o perfil.

Uma redução no banco de dados também então foi realizada, utilizando estacas até 20 m de comprimento, totalizando 231 informações, separadas em 199 casos para treinamento e teste da rede e 32 casos para validação da rede. Foram treinadas e testadas, e validadas neste modelo 20 arquiteturas diferentes.

A arquitetura que apresentou melhor comportamento foi a A7:7:1, com $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,96$, de acordo com os gráficos de *performance* (Figura 56) e “*output x target*” (Figura 57).

No treinamento e teste foram observados alguns valores com erros aceitáveis entre 0 até 10 %, muitos resultados dentro de uma faixa de valores variando de 10 % à 50 %, e persistindo alguns casos de erros muito elevados, maiores que 50%. Na validação, poucos casos com erros percentuais aceitáveis e a maioria dos casos, com erros percentuais elevados, entre 10% a 50 %, e poucos valores de erros muito

elevados, maiores que 50 %, sendo o maior valor encontrado de 70 %. Mais uma vez, constatou-se a incapacidade de generalização da rede.

No treinamento e teste, o Modelo 04 se comportou de forma similar ao Modelo 03 e melhor do que os Modelos 01 e 02. Na validação, observou-se uma redução no maior valor obtido de erro, porém este ainda é considerado muito elevado.

Apesar de serem observados pequenos avanços no decorrer do trabalho, e nos modelos 01 a 04, é contraditório que a rede melhore com a retirada de elementos do banco de dados. O ideal é trabalhar com um banco de dados o mais extenso e coerente possível, o que não foi observado nos dados analisados na presente pesquisa.

Diante dos resultados expostos pode-se concluir que as tentativas de melhora no comportamento das redes somente conduziram a respostas na redução da magnitude dos erros percentuais, tanto no treinamento e teste, quanto na validação das redes. Porém não suficientes para utilização da rede para previsão da capacidade de carga de solos.

Em todos os modelos, foram encontrados casos com erros percentuais muito elevados (maiores que 50 %), o que não é esperado para redes que apresentam coeficientes de correlação maiores que 0,90.

A primeira suposição para o comportamento apresentado pelas redes é que o banco de dados utilizado era inconsistente.

O banco de dados utilizou informações de provas de carga executadas no Brasil ao longo das últimas quatro décadas. Ao longo desses anos, as normas de prova de carga mudaram e foram atualizadas. Como consequência, distintos procedimentos com relação à carga máxima aplicada no ensaio e a definição da carga de ruptura foram adotados. Com isso, pode-se ter elementos no banco de dados com diferentes definições de carga de ruptura.

Associado a cada prova de carga na estaca estava uma sondagem à percussão, definindo o perfil do subsolo com valores de N_{SPT} a cada metro. Assim como a norma de prova de carga foi atualizada e modificada ao longo das quatro últimas décadas, a norma de execução de sondagem à percussão também foi. Nas atualizações e modificações foram definidos e padronizados a massa, a geometria e a forma de liberação do martelo de bater, a altura de queda, o tipo de cabo utilizado (sisal ou aço), uso ou ausência de coxim e cabeça de bater, dentre outros elementos

que alteram a transferência de energia do martelo até o amostrador, e conseqüentemente mudando o valor do N_{SPT} ao longo das últimas quatro décadas. Isso conduz a um banco de dados com diferentes definições de N_{SPT} .

Outra suposição é que não foram oferecidas à rede variáveis de entrada suficientes para ela discretizar o comportamento da variável de saída (carga de ruptura). Foram apresentados à rede dados de entrada referentes à geometria da estaca (comprimento e área da seção transversal) e do perfil do subsolo (N_{SPT} ao longo do comprimento da estaca). Porém não foi oferecido à rede o tipo de solo ao longo da estaca (se areia, argila ou silte). Dois tipos de solos diferentes, por exemplo, uma areia e uma argila com os mesmos valores de N_{SPT} , possuem características de resistência distintas. O N_{SPT} é um parâmetro de resistência à cravação de um amostrador no solo. Como esta separação pelo tipo de solo não foi realizada, o mesmo valor de N_{SPT} pode levar a resistências de solos diferentes e a cargas de rupturas diferentes e ter contribuído para o comportamento observado nas redes experimentadas.

Incertezas inerentes ao comportamento dos diversos tipos de solos e à qualidade dos ensaios utilizados para compor o banco de dados também podem ter influenciado no desempenho da rede.

5 CONCLUSÕES E SUGESTÕES

5.1 Conclusões

O presente trabalho apresentou experimentos de predição de carga de ruptura de estacas carregadas axialmente à compressão utilizando redes neurais artificiais (RNA). O banco de dados utilizado na pesquisa foi composto de resultados de provas de cargas estáticas à compressão, ensaios de carregamentos dinâmicos e sondagens à percussão. O programa adotado foi o MATLAB[®], versão R2017a. No decorrer da pesquisa, foram utilizados quatro modelos de redes buscando-se a previsão da carga de ruptura a partir de dados do comprimento e área da seção transversal da estaca, e dos valores do N_{SPT} . Em cada modelo realizaram-se processos de treinamento e teste. Posteriormente, procedeu-se à validação de cada arquitetura adotada, apresentando-se as redes com melhor desempenho. Os diferentes modelos buscaram um refinamento da rede, e a capacidade de generalização da mesma. No Modelo 01, foram utilizados 349 dados de entrada, e a rede com melhor desempenho apresentou $R_{\text{training}} = 0,96$ e $R_{\text{test}} = 0,81$. No Modelo 02, houve um refinamento na rede, eliminando-se do banco de dados, informações que poderiam confundir a rede, chegando-se a $R_{\text{training}} = 0,99$ e $R_{\text{test}} = 0,89$. No Modelo 03, optou-se por reduzir o número de dados de entrada, e a rede com melhor performance apresentou $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,93$. Finalmente, no Modelo 04, a rede chegou a $R_{\text{training}} = 0,95$ e $R_{\text{test}} = 0,96$, e neste caso, optou-se por utilizar apenas estacas com comprimentos inferiores a 20 m.

Apesar dos bons coeficientes de correlação apresentados, todas as redes apresentaram elevados erros percentuais nos resultados do treinamento e teste, bem como na etapa de validação, quando se comparam os dados obtidos (*output*) com os dados esperados (*target*).

Os resultados mostraram que as redes não foram capazes de generalizar uma solução obtendo um resultado final com respostas satisfatórias. Alguns fatores podem interferir no desempenho da rede como a qualidade das informações do banco de dados, a diversidade de solos, que pode conduzir a saídas distintas para um mesmo dado de entrada, e às incertezas inerentes ao comportamento dos solos e à qualidade dos ensaios analisados.

O banco de dados utilizou informações de provas de carga executadas no Brasil ao longo das últimas quatro décadas. Ao longo desses anos, as normas de prova de carga foram atualizadas e conseqüentemente distintos procedimentos com relação à carga máxima aplicada no ensaio e a definição da carga de ruptura foram adotados. Com isso, pode-se ter elementos no banco de dados com diferentes definições de carga de ruptura.

Outra suposição é que não foram oferecidas à rede variáveis de entrada suficientes para ela discretizar o comportamento da variável de saída (carga de ruptura). Informações como o tipo de solo (argila, silte, areia) não foram oferecidas, o que pode ter contribuído para a falha na generalização. Dois tipos de solos diferentes podem apresentar os mesmos valores de N_{SPT} e possuírem características de resistência distintas.

5.2 Trabalhos Futuros

O presente trabalho expôs experimentos de previsão de carga de ruptura de estacas carregadas axialmente à compressão a partir de resultados de provas de carga estáticas, ensaios de carregamento dinâmico e sondagens à percussão.

O trabalho buscou melhorar o desempenho da rede a cada modelo experimentado, com diferentes quantidades de informações no banco de dados, distintas arquiteturas e quantidades de variáveis de entradas variadas. Contudo, nenhuma rede obteve capacidade de prever a carga de ruptura da estaca de forma satisfatória.

Seguindo a linha de pesquisa desenvolvida nesta dissertação e tendo em vista os resultados obtidos, sugere-se para pesquisas futuras:

- Utilização de um banco de dados confiável e atualizado, com informações de provas de cargas e sondagens à percussão de acordo com normas atuais;
- Elaboração de redes individualizando o tipo de estaca (cravada pré-moldada de concreto, cravada metálica, hélice contínua, escavada e raiz);
- Avaliação de redes discretizando o tipo de solo (se areia, silte ou argila) ao longo do comprimento da estaca;

- Emprego de uma forma distinta da utilizada neste trabalho de atribuir o N_{SPT} ao comprimento da estaca, por exemplo, somatório e/ ou média ao longo de todo o comprimento da estaca.

REFERÊNCIAS

ALBUQUERQUE, P. J. R. Estacas escavadas, hélice contínua e ômega: Estudo do comportamento à compressão em solo residual de diabásio, através de provas de carga instrumentadas em profundidade. Tese (Doutorado em Engenharia Civil) – Escola Politécnica da Universidade Estadual de São Paulo, São Paulo, 2001, 263p.

ALONSO, U. R. Previsão e controle das fundações: uma introdução ao controle da qualidade em fundações. São Paulo: Editora Edgar Blücher Ltda, 2 ed., 146p, 2011.

AMANN, K. Análise matemática e paramétrica dos métodos de interpretação da curva carga x recalque de estacas. In: CONGRESSO NACIONAL DE GEOTECNIA, 11., 2008, Coimbra. Anais... Coimbra: 2008. CD-ROM.

AOKI, N. Considerações sobre a capacidade de carga de estacas isoladas. Notas de aula. Universidade Gama Filho, 1976.

AOKI, N.; VELLOSO, D. A. *An approximate method to estimate the bearing capacity of piles.* In: *PANAMERICAN CONFERENCE ON SOIL MECHANICS AND FOUNDATION ENGINEERING*, 5., 1975, Buenos Aires. Proceedings... Buenos Aires: Huella Estudio Grafico, 1975. v.1, p. 367-376.

ARAÚJO, C. B. C. Aplicação das redes neurais artificiais do tipo perceptron na estimativa de recalques em estacas. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Fortaleza, 2015.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 6118 - Projeto de estruturas de concreto – Procedimento. Rio de Janeiro, 2014.

_____. NBR 6122: Projeto e execução de fundações. Rio de Janeiro, 2010.

_____. NBR 6484 - Solo - Sondagens de simples reconhecimento com SPT – Método de ensaio. Rio de Janeiro, 2001.

_____. NBR 7181 – Solo – Análise Granulométrica - Método de Ensaio. Rio de Janeiro, 1984.

_____. NBR 8036 – Programação de sondagens de simples reconhecimento dos solos para fundação de edifícios. Rio de Janeiro, 1983.

_____. NBR 12131 - Estacas – Prova de carga estática – Método de ensaio. Rio de Janeiro, 2006.

_____. NBR 13208 - Estacas – Ensaio de carregamento dinâmico. Rio de Janeiro, 2007.

BELICANTRA, A. Avaliação dos fatores intervenientes no índice de resistência à penetração do SPT. Tese (Doutorado) – Universidade de São Paulo, São Carlos, 1998.

BIONDI NETO, L. ; SIEIRA, A. C. C. F. ; DANZIGER, B. R. ; SILVA, J. G. S. . Neuro-CPT: Classificação de Solos usando-se Redes Neurais Artificiais. Engevista (UFF) , v. 08, p. 37-48, 2006.

BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: LTC Editora, 262p, 2000.

CABRAL, E. V.; BIONDI NETO, L. ; SIEIRA, A. C. C. F. Aplicação de Redes Neurais Artificiais na Determinação de Acréscimos de Tensões Verticais em Solos Decorrentes de Carregamentos Infinitos Trapezoidais. In: II GeoJovem, 2006, Nova Friburgo/RJ. II GeoJovem, 2006.

CAMPOS, G. G. G. Análise experimental e numérica do comportamento de estacas apiloadas em solo laterítico de Londrina/PR. 2005. 162p. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2005.

CARRASCO GUTIÉRREZ, J. L. Monitoramento da instrumentação da barragem Corumbá I por redes neurais e modelos de Box & Jenkins. Rio de Janeiro, 2003. 146p. Dissertação de Mestrado – Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, 2003.

CAVALCANTE, E. H.; DANZIGER, F.A.B.; DANZIGER, B.R. *Estimating the SPT penetration resistance from rod penetration based on instrumentation. In: INT. CONF. ON SITE CHARACTERIZATION, 2., Porto, Portugal. Proceedings... Rotterdam: Millpress, 2004. p. 293-298.*

CHISSOLUCOMBE, I. Uso de técnicas de inteligência artificial na estimativa de deslocamentos e danos induzidos por escavações subterrâneas. 2009. 216 f. Tese (Doutorado em Geotecnia) - Universidade de Brasília, Brasília, 2009.

CINTRA, J. C. A.; AOKI, N. Carga Admissível em Fundações Profundas. São Carlos: EESC-USP, 1 ed, v. 1, 61p, 1999.

CINTRA, J. C. A.; AOKI, N. Fundações por estacas: projeto geotécnico. São Paulo: Oficina de Textos, 2010, 96p.

CINTRA, J.C.A.; AOKI, N.; TSUHA, C.H.C.; GIACHETI, H.L. Fundações ensaios estáticos e dinâmicos. 1.ed. São Paulo: Oficina de Textos, 2013.

DANZIGER, B. R. (2017). Fundações Especiais. Notas de Aula. PGECIV UERJ.

DE BEER, E. *Different behavior of bored and driven piles. In: 1ST INTERNATIONAL GEOTECHNICAL SEMINAR ON DEEP FOUNDATIONS ON BORED AND AUGER PILES, Ghent. Proceedings... Ghent. W. F. van Impe, pp. 47-82, 1988.*

DÉCOURT, L. *The standard penetration test. State-of-the-art report. Proceedings of the XII ICSMEF, Rio de Janeiro, v.4, p.2405-2416, 1989.*

_____. A Ruptura de Fundações Avaliada com Base no Conceito de Rigidez. In: SEMINÁRIO DE ENGENHARIA DE FUNDAÇÕES ESPECIAIS E GEOTECNIA III, SEFE, 1996, São Paulo. Anais... São Paulo: ABEF/ABMS, 1996. v. 1, p.215-224.

_____. Ruptura de Fundações e coeficientes de segurança a luz do Conceito de Rigidez. In: CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA, XI COBRAMSEG, 1998, Brasília. Anais... Brasília: ABMS, 1998, v.3, p. 1599-1606.

_____. Provas de carga em estacas podem dizer muito mais do que têm dito. In: SEMINÁRIO DE ENGENHARIA DE FUNDAÇÕES ESPECIAIS E GEOTECNIA, VI SEFE, 2008, São Paulo. Anais... São Paulo: ABMS, 2008, v.1, p. 221-245.

DÉCOURT, L.; ALBIERO, J. H.; CINTRA, J. C. A. Análise e Projeto de Fundações Profundas. In: HACHICH, W.; FALCONI, F. F.; SAES, J. S.; FROTA, R. G. Q.; NIYAMA, S. Fundações Teoria e Prática. São Paulo: Editora Pini, 1996, p. 265-301.

DÉCOURT, L.; NIYAMA, S. *Predicted and measured behavior of displacement piles in residual soils. In: INTERNATIONAL CONFERENCE ON SOIL MECHANICS AND FOUNDATION ENGINEERING*, 13, 1994, New Delhi. Proc... ICSMFE XIII, v. 1 p. 143-146.

DÉCOURT, L.; QUARESMA, A.R. Capacidade de carga de estacas a partir de valores SPT. *Proceedings of the VI Cong. Brasileiro Mec. Solos Eng. Fund.*, Rio de Janeiro, p. 45-53, 1978.

GONÇALVES, C.; ANDREO, C. S.; BERNARDES, G. P.; FORTUNATO, S. G. S. Controle de fundações profunda através de métodos dinâmicos. 1. ed. 2000. 253p.

HEBB, D. O., *The organization of Behavior*, John Wiley & Sons, New York, 1949.

HAYKIN, S. Redes Neurais. Princípios e prática. 2.ed. São Paulo: Bookman Editora, 2008.

HOPFIELD, J. J., *Neural Networks and Physical Systems with Emergent Collective Computational Abilities. Proceedings of National Academy of Sciences*, Vol.79, pp. 2554-2558, April, 1982.

ISSMFE – *Report of the ISSMFE - Technical Committee on Penetration Testing of Soils –TC 16 With Reference Test Procedures – CPT – SPT – DP – WST, International Reference Test Procedure for the Standard Penetration Test (SPT)*, p. 17-19, 1989.

LECUN, Y. *Efficient Learning and Second-order Methods, A Tutorial at NIPS 93*, Denver, 1993.

LOBO, B. O. Método de previsão de capacidade de carga de estacas: aplicação dos conceitos de energia do ensaio SPT. 2005. 121f. Dissertação (Mestrado em Engenharia) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

LÔBO, B. R. H.; ZALUAGA, R. A. G.; MARTÍNEZ-CARVAJAL, H. E. Utilização de redes neurais para estimar a permeabilidade do solo. In: *Simpósio Brasileiro de Aplicações de Informática em Geotecnia, 2011, Brasília. Simpósio Brasileiro de Aplicações de Informática em Geotecnia*, p. 137-145, 2011.

MACEDO, C. E. C. ; SILVA, N. B.; LICHSTON, J. E. *Organização e diferenciação celular*. 2.ed. Natal: EDUFRN, 2012.

MARTÍNEZ-CARVAJAL, H. E. *Modelagem Constitutiva de Areias Usando Redes Neurais Artificiais*. s.l. : Tese de Doutorado, Publicação G.TD-035/06, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 247 p, 2006.

MATLAB. *Version: R2017a. Documentation: improve neural network generalization and avoid overfitting*, Mathworks, 2017.

MCCULLOCH, W., PITTS, W., *A Logical Calculus of the Ideas Immanent in Nervous Activity*. *Bulletin of Mathematical Biophysics*, 5:115-133,1943.

MELO, B. N. Análise de provas de carga à compressão à luz do conceito de rigidez. 2009. 219 f. Dissertação (Mestrado em Engenharia Civil) - Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Universidade Estadual de Campinas, Campinas, 2009.

MILITITSKY, J. Provas de carga estáticas. In: SEMINÁRIO DE ENGENHARIA DE FUNDAÇÕES ESPECIAIS E GEOTECNIA, II SEFE, 1991, São Paulo. Anais... São Paulo: ABEF e ABMS, 1991, v.2, p. 203-228.

MINSKY, M.; PAPPERT, S., *Perceptrons*, MIT Press, Cambridge, 1969.

NIYAMA, S. Prova de Carga Dinâmica em Estacas. In SEMINARIO DE ENGENHARIA DE FUNDACOES ESPECIAIS, II, Sao Paulo. Anais, 1991 v.2, p.229-268.

NIYAMA, S.; AOKI, N.; CHAMECKI, P. R. Verificação de desempenho. In: HACHICH, W. et. al. Fundações: teoria e prática. 2.ed. São Paulo : Editora Pini, 1998. p.723-754.

NOLA, I. T. S. Avaliação de dados geológico-geotécnicos prévios para elaboração de carta de eventos perigosos de movimentos de massa gravitacionais por meio de redes neurais artificiais e probabilidade. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2015.

NUNES, J. O. R.; SAMIZAVA, T. M.; IMAI, N. N.; GALO, M. L. B. T. ; KAIDA, R. H. Aplicação e avaliação de uma rede neural artificial para escolha de áreas para aterro sanitário. In: Revista Formação (Online), Universidade Estadual Paulista (UNESP) - Presidente Prudente - SP , v. 1, p. 113-125, 2007.

RAUSCHE, F.; GOBLE, G., G.; LIKINS, G. E. *Dynamic determination of pile capacity*, JGED, ASCE, v. 111, n. 3, p. 367-383, 1985.

RIBEIRO, A. J. A.; SILVA, C. A. U.; BARROSO, S. H. A. Metodologia de baixo custo para mapeamento geotécnico aplicado à pavimentação. *Revista Transportes (Online)* v. 26, n. 2, p.84-100, 2018.

ROSENBLATT, R., *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*. *Psychol. Rev.*65, 1958.

RUFFIER, A. P. ; MIDÃO, F. S. ; LISBOA, E. F. A. . Aplicação de Redes Neurais ao Estudo do Arrancamento de Fundações. In: XI Congresso Brasileiro de Mecânica dos Solos e Engenharia de Fundações, 1998, Brasília, DF, 1998.

RUMELHART, D. E.; MCCLELLAND, J. L., *Parallel Distributed Processing*. MIT Press, Vol.1, 1986.

SCHNAID, F. e ODEBRECHT, E. Ensaio de campo e suas aplicações à engenharia de fundações. 2.ed. São Paulo: Oficina de Textos, 2012.

SILVA, M. A.; NETTO, L.B. ; GERSCOVICH, D.M. . Utilização de Rede Neural Artificial na Obtenção dos Acréscimos de Tensão no Solo Devido a Carregamento Circular. In: II GeoJovem, 2006, Nova Friburgo/RJ. II GeoJovem, 2006.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas – curso prático. São Paulo: Artliber Editora Ltda, 2010.

SILVEIRA, M. V. Modelo neuronal para previsão de recalques em estacas hélice contínua, metálica e escavada. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Fortaleza, 2014.

SMITH, E. A. L. *Pile Driving Analysis by the Wave Equation* – *Journal of Soil Mechanics and Foundation ASCE* – Tradução n.8 da ABMS (Núcleo Regional de São Paulo), 1960.

VAN DER VEEN, C. *The bearing capacity of pile. In: INTERNATIONAL CONFERENCE OF SOIL MECHANICS AND FOUNDATION ENGINEERING, 3.*, 1953, Zurich. Proceedings... Zurich: ICOSOMEF, 1953, v.2, p.84-90.

VARGAS, M. Uma experiência brasileira em fundações por estacas. Parte 1: Teoria das estacas verticais carregadas axialmente. *Geotecnia*, Lisboa, n. 23, p. 3-33, 1977.

VELLOSO, D. A.; LOPES, F. R. *Fundações*. Oficina de Textos 1ª edição. São Paulo. 2010.

VELLOSO, P.P.C. *Fundações: aspectos geotécnicos*. 3.ed. Rio de Janeiro: PUC – RJ, 1981. v.3. p. 467-469.

WIDROW, B, *Generalization and Information Storage in Networks of Adaline Neurons. Self-Organizing Systems*, 1962.

WIDROW, B.; HOFF, M.E. *Adaptative switching circuits*. Institute of Radio Engineers, Western Electronic Show and Convention, 1960.

WIDROW, B.; RUMELHART, D.E.; LEHR, M.A. *Neural Networks: Applications in Industry, Business and Science*, Communications of ACM, Vol.37, N.3, March, 1994.

ANEXO A – BANCO DE DADOS: TABELAS EM FUNÇÃO DO TIPO DE ESTACA, COM A IDENTIFICAÇÃO, COMPRIMENTO, ÁREA DA SEÇÃO TRANSVERSAL, LOCALIZAÇÃO E A SONDAGEM À PERCUSSÃO ASSOCIADA À CADA PROVA DE CARGA ESTÁTICA À COMPRESSÃO E ENSAIO DE CARREGAMENTO DINÂMICO.

Estacas Cravada Metálica				
Identificação	L [m]	At [m ²]	Qurup [kN]	Localização
1	19.8	0.02310	640	São Paulo, SP
2	22.9	0.04120	1200	São Paulo, SP
3	28.3	0.06300	1500	São Paulo, SP
4	28.3	0.05300	1500	São Paulo, SP
5	26.0	0.09150	1550	São Paulo, SP
6	30.3	0.09954	1100	Santos, SP
7	31.8	0.09954	2040	Santos, SP
8	29.0	0.09954	1260	Santos, SP
9	32.5	0.09954	1500	Santos, SP
10	15.7	0.06452	1630	Rio de Janeiro, RJ
11	15.3	0.06452	1670	Rio de Janeiro, RJ
12	21.4	0.01568	320	Rio de Janeiro, RJ
13	21.3	0.01568	300	Rio de Janeiro, RJ
14	21.6	0.01568	300	Rio de Janeiro, RJ
15	21.4	0.01568	740	Rio de Janeiro, RJ
16	21.2	0.01568	800	Rio de Janeiro, RJ
17	8.0	0.02070	900	Bahia
18	11.0	0.02070	490	Bahia
19	13.3	0.01600	815	Bahia
20	13.3	0.01600	360	Bahia
21	8.6	0.00569	670	Bahia
22	6.6	0.00473	270	Bahia
23	7.7	0.02070	190	Bahia
24	19.9	0.02070	1700	Bahia
25	15.4	0.02070	1400	Bahia
26	16.3	0.02070	2030	Bahia
27	17.2	0.01600	1135	Bahia
28	16.4	0.01600	825	Bahia

Estacas Cravada Pré moldada de concreto					Estacas Cravada Pré moldada de concreto					Estacas Cravada Pré moldada de concreto				
Identificação	L [m]	At [m ²]	Qrup [kN]	Localização	Identificação	L [m]	At [m ²]	Qrup [kN]	Localização	Identificação	L [m]	At [m ²]	Qrup [kN]	Localização
1	18,90	0,05309	1115	Cubatão, SP	45	28,70	0,28274	4900	Duque de Caxias, RJ	89	10,00	0,04909	360	Curitiba, PR
2	21,12	0,05309	1005	Cubatão, SP	46	29,00	0,28274	3170	Santa Cruz, RJ	90	4,40	0,01767	55	Curitiba, PR
3	10,50	0,05309	950	Sumaré, SP	47	35,50	0,28274	3850	Av. dos Automobilistas, SP	91	3,40	0,01767	53	Curitiba, PR
4	11,20	0,05309	850	Sumaré, SP	48	21,25	0,28274	3230	Av. dos Automobilistas, SP	92	12,00	0,03142	284	Curitiba, PR
5	9,25	0,05309	1000	Jaguari, SP	49	30,10	0,38485	4300	Santa Cruz, RJ	93	14,00	0,04909	530	Curitiba, PR
6	3,30	0,05309	1040	Via Anhanguera, SP	50	24,00	0,28274	2740	-	94	7,70	0,07069	770	Curitiba, PR
7	21,10	0,08553	1830	Cubatão, SP	51	9,40	0,02270	575	São Paulo, SP	95	10,30	0,12566	1150	Curitiba, PR
8	39,90	0,08553	1115	Santos, SP	52	9,00	0,03142	770	São Paulo, SP	96	12,00	0,12566	1370	Curitiba, PR
9	9,90	0,08553	900	Via Anhanguera, SP	53	10,30	0,04155	1010	São Paulo, SP	97	14,00	0,07069	835	Curitiba, PR
10	11,50	0,08553	1080	São Bernardo do Campo, SP	54	9,60	0,05309	1200	São Paulo, SP	98	13,55	0,07069	760	Curitiba, PR
11	23,00	0,08553	1250	Santa Cruz, RJ	55	9,60	0,08553	1940	São Paulo, SP	99	14,00	0,04909	535	Curitiba, PR
12	21,35	0,13854	2030	São Sebastião, SP	56	10,00	0,02250	125	Bauria, SP	100	12,40	0,04909	445	Curitiba, PR
13	12,00	0,13854	2200	Volta Redonda, RJ	57	14,00	0,02250	205	Bauria, SP	101	13,00	0,03142	390	Curitiba, PR
14	9,70	0,13854	1880	São Caetano do Sul, SP	58	5,00	0,05309	325	Recife, PE	102	13,55	0,04909	560	Curitiba, PR
15	21,10	0,13854	5300	Duque de Caxias, RJ	59	5,70	0,02545	335	Jornville, SC	103	11,60	0,03142	400	Curitiba, PR
16	14,97	0,13854	1780	Sumaré, SP	60	18,10	0,05309	840	Jornville, SC	104	9,00	0,03142	350	Curitiba, PR
17	23,15	0,13854	1820	Santa Cruz, RJ	61	13,70	0,04000	265	Jornville, SC	105	11,10	0,02545	340	Curitiba, PR
18	23,00	0,19635	3100	Capit, RJ	62	14,00	0,04000	285	Jornville, SC	106	12,10	0,03142	340	Curitiba, PR
19	21,80	0,19635	2700	São José dos Campos, SP	63	23,30	0,07069	2720	Jornville, SC	107	10,60	0,06158	575	Curitiba, PR
20	18,00	0,19635	2430	Angra dos Reis, RJ	64	20,00	0,03240	540	Jornville, SC	108	12,00	0,12566	1240	Curitiba, PR
21	15,40	0,19635	2610	Angra dos Reis, RJ	65	12,30	0,07545	675	Jornville, SC	109	12,00	0,06158	710	Curitiba, PR
22	13,10	0,19635	2790	Angra dos Reis, RJ	66	8,60	0,02540	650	São José, SC	110	12,30	0,12566	960	Curitiba, PR
23	15,80	0,19635	2350	Duque de Caxias, RJ	67	8,20	0,04000	1200	São José, SC	111	12,00	0,08353	990	Curitiba, PR
24	26,50	0,19635	2520	Santos, SP	68	8,40	0,05290	950	São José, SC	112	14,40	0,04909	495	Curitiba, PR
25	34,00	0,19635	2600	Santos, SP	69	8,80	0,03240	590	São José, SC	113	12,90	0,03142	350	Curitiba, PR
26	34,00	0,19635	2620	Santos, SP	70	12,00	0,02545	570	Jornville, SC	114	12,90	0,04909	485	Curitiba, PR
27	14,00	0,19635	2850	Ipiranga, MG	71	12,00	0,02545	490	Jornville, SC	115	7,85	0,07069	780	Guarulhos, SP
28	29,50	0,19635	4030	Santa Cruz, RJ	72	10,00	0,01767	290	Manoré, PR	116	6,65	0,07069	1020	Guarulhos, SP
29	27,40	0,19635	2940	Santa Cruz, RJ	73	12,00	0,04155	407	Manoré, PR	117	7,00	0,07069	1015	Guarulhos, SP
30	38,85	0,19635	8250	Santa Cruz, RJ	74	11,10	0,12566	820	Curitiba, PR	118	8,30	0,07069	1140	Guarulhos, SP
31	28,75	0,19635	5950	Santa Cruz, RJ	75	12,00	0,07069	580	Curitiba, PR	119	6,80	0,07069	705	Guarulhos, SP
32	26,40	0,19635	2760	Barret, SP	76	14,00	0,04909	780	Jornville, SC	120	16,20	0,04909	680	Campo Largo, PR
33	19,90	0,19635	3140	Barret, SP	77	13,50	0,19635	600	Santos, SP	121	16,80	0,04909	815	Campo Largo, PR
34	16,50	0,19635	2900	Barret, SP	78	27,00	0,19635	2280	Santos, SP	122	15,35	0,04909	710	Campo Largo, PR
35	20,20	0,19635	2650	Barret, SP	79	27,00	0,12441	2070	Santos, SP	123	14,00	0,04909	525	Araucária, PR
36	9,40	0,19635	2810	Barret, SP	80	10,00	0,04155	330	Curitiba, PR	124	23,65	0,13854	1800	Duque de Caxias, RJ
37	18,70	0,19635	3600	Barret, SP	81	10,00	0,02545	365	Curitiba, PR	125	14,00	0,07069	600	São Paulo, SP
38	28,40	0,19635	2750	São Caetano do Sul, SP	82	8,75	0,01767	275	São Paulo, SP	126	14,00	0,02750	750	São Bernardo do Campo, SP
39	11,70	0,19635	3050	Barcarena, PA	83	13,50	0,04909	600	Curitiba, PR	127	11,00	0,02250	720	São Bernardo do Campo, SP
40	12,95	0,19635	2320	Barcarena, PA	84	11,50	0,03142	272	Curitiba, PR	128	14,00	0,02250	910	São Bernardo do Campo, SP
41	9,30	0,28274	5000	Beim, MG	85	13,50	0,04909	800	Curitiba, PR	129	8,00	0,07069	1200	São Paulo, SP
42	21,40	0,28274	3850	São José dos Campos, SP	86	11,50	0,03142	650	Curitiba, PR	130	11,30	0,06250	730	São Paulo, SP
43	29,80	0,28274	5000	Duque de Caxias, RJ	87	3,50	0,01767	205	Curitiba, PR	131	8,50	0,07069	780	São Paulo, SP
44	27,10	0,28274	3950	Duque de Caxias, RJ	88	12,00	0,04909	500	Curitiba, PR					

Identificação	Estacas Escavadas					Estacas Escavadas				
	L [m]	At [m²]	Qrup [kN]	Localização	Identificação	L [m]	At [m²]	Qrup [kN]	Localização	
1	7.5	0.38485	990	São Paulo, SP	36	10	0.08042	445	Ilha Solteira, SP	
2	11	0.12566	1100	Triunfo, RS	37	10	0.08042	510	Ilha Solteira, SP	
3	11	0.19635	1970	Triunfo, RS	38	3	0.04909	44	Londrina, PR	
4	11	0.28274	2670	Triunfo, RS	39	3	0.04909	57	Londrina, PR	
5	20	0.12566	1890	Triunfo, RS	40	3	0.04909	57	Londrina, PR	
6	20	0.12566	2200	Triunfo, RS	41	4.03	0.04909	125	Londrina, PR	
7	20	0.12566	2200	Triunfo, RS	42	4.2	0.04909	180	Londrina, PR	
8	20	0.12566	1700	Triunfo, RS	43	6.1	0.04909	224	Londrina, PR	
9	20	0.12566	2200	Triunfo, RS	44	6	0.04909	325	Londrina, PR	
10	20	0.12566	1890	Triunfo, RS	45	8.2	0.04909	380	Londrina, PR	
11	20	0.12566	2200	Triunfo, RS	46	8.4	0.04909	380	Londrina, PR	
12	20	0.12566	1510	Triunfo, RS	47	20.6	0.28274	5000	Pudamonhangaba, SP	
13	20	0.28274	1840	Triunfo, RS	48	16.1	0.50265	7200	Pudamonhangaba, SP	
14	20	0.28274	2410	Triunfo, RS	49	17	0.78540	7400	Pudamonhangaba, SP	
15	20	0.28274	2550	Triunfo, RS	50	7.9	0.07069	280	Distrito Federal	
16	20	0.28274	2300	Triunfo, RS	51	7.9	0.07069	200	Distrito Federal	
17	20	0.28274	2830	Triunfo, RS	52	8.4	0.07069	210	Distrito Federal	
18	20	0.28274	2690	Triunfo, RS	53	26.8	1.13097	9500	Vitória, ES	
19	20	0.28274	3820	Triunfo, RS	54	6	1.13097	6400	Ouro Branco, MG	
20	12	0.38485	2120	Distrito Federal	55	22.6	1.13097	9350	-	
21	6	0.04909	120	-	56	15.8	1.13097	12500	-	
22	10	0.03142	270	Londrina, PR	57	22	1.13097	9300	Vitória, ES	
23	9.95	0.03142	275	Rio Grande, RS	58	9.8	0.07069	180	Passo Fundo, RS	
24	14.3	0.38485	1430	Rio Grande, RS	59	11.3	0.07069	325	Passo Fundo, RS	
25	12	0.04909	445	Rio Grande, RS	60	9	0.19635	1340	Porto Alegre, RS	
26	52	2.13825	21100	Rio Grande, RS	61	11.5	0.07069	650	Porto Alegre, RS	
27	52	2.13825	20000	Rio Grande, RS	62	12	0.44179	2510	Triunfo, RS	
28	60	2.26980	21652	Rio Grande, RS	63	13.6	0.12566	1225	Triunfo, RS	
29	60	2.26980	18315	Rio Grande, RS	64	12.2	0.44179	2090	Triunfo, RS	
30	60	2.26980	16795	Rio Grande, RS	65	10.5	0.50265	2280	Triunfo, RS	
31	60	2.26980	16000	Rio Grande, RS	66	8.25	1.53938	4500	Esteio, RS	
32	31	1.53938	14000	Rio de Janeiro, RJ	67	26.41	1.53938	13000	Porto Alegre, RS	
33	10	0.38485	2940	-	68	7.2	1.53938	16300	Sapucaia do Sul, RS	
34	6	0.38485	2600	-	69	15	0.38485	2240	Porto Alegre, RS	
35	10	0.08042	490	Ilha Solteira, SP	70	8.3	0.12566	745	Porto Alegre, RS	

Prof. (m)		Estracas Escavadas																							
		Identificação																							
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	
NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
1	20	7	7	7	14	14	14	14	14	14	14	14	14	14	14	14	14	14	14	21	6	3	3	13	6
2	30	8	8	8	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	30	2	3	3	14	1
3	24	4	4	4	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	30	4	4	4	9	4
4	30	5	5	5	13	13	13	13	13	13	13	13	13	13	13	13	13	13	13	30	3	5	5	4	5
5	30	6	6	6	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	30	4	5	5	3	4
6	30	15	15	15	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	30	4	6	6	4	4
7	40	11	11	11	13	13	13	13	13	13	13	13	13	13	13	13	13	13	13	30	5	5	4	3	
8		9	9	9	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	30	7	7	4	6	
9		9	9	9	11	11	11	11	11	11	11	11	11	11	11	11	11	11	11	30	6	6	4	5	
10		19	19	19	13	13	13	13	13	13	13	13	13	13	13	13	13	13	13	30	5	5	7	8	
11		35	35	35	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	30	8	8	14	12	
12					8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	40			12	12	
13					17	17	17	17	17	17	17	17	17	17	17	17	17	17	17				8		
14					10	10	10	10	10	10	10	10	10	10	10	10	10	10	10				7		
15					13	13	13	13	13	13	13	13	13	13	13	13	13	13	13						
16					13	13	13	13	13	13	13	13	13	13	13	13	13	13	13						
17					16	16	16	16	16	16	16	16	16	16	16	16	16	16	16						
18					30	30	30	30	30	30	30	30	30	30	30	30	30	30	30						
19					30	30	30	30	30	30	30	30	30	30	30	30	30	30	30						
20					40	40	40	40	40	40	40	40	40	40	40	40	40	40	40						

Prof. (m)	Estacas Escavadas																																																																					
	Identificação																																																																					
	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70																																														
NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT	NSPT																																														
0	1	1	1	0	0	0	5	11	0	18	0	8	0	0	0	0	0	0	0	0	0	0	0	0																																														
1	3,6	3,6	3,6	4	4	4	18	19	28	23	28	5	0	5	12	5	5	5	5	2	2	0	8	2																																														
2	7	7	7	4	4	4	18	22	27	13	27	4	10	12	13	18	18	18	7	9	5	0	5	10																																														
3	19	19	19	2	2	2	15	25	11	16	11	9	9	8	10	16	16	16	20	12	7	6	9	8																																														
4	18	18	18	4	4	4	17	17	12	19	12	13	7	15	12	14	14	14	17	2	4	8	10	13																																														
5	19	19	19	4	4	4	17	22	12	22	12	17	4	13	8	10	10	10	18	2	5	18	13	25																																														
6	18	18	18	7	7	7	18	40	14	23	14	20	9	23	11	11	11	11	10	5	5	30	13	30																																														
7	20	20	20	8	8	8	16		26	22	26	24	13	17	15	10	10	10	7	8	2	40	9	21																																														
8	16	16	16	14	14	14	9		23	25	23	28	16	18	15	11	11	11	9	40	8	9	39																																															
9	10	10	10				11		25	26	25	30	20	10	13	11	11	11	7	6	6	10																																																
10	3,46	3,46	3,46				11		20	29	20	39	26	32	12	22	30	30	6	6	6	6																																																
11	14	14	14				13		23	29	23				12	22	30	30			11	7																																																
12	13	13	13				8		25	30	25				38	30	38				15	13																																																
13	9	9	9				11		27	30	27										15	30																																																
14	12	12	12				10		29	30	29										19	30																																																
15	17	17	17				8		12	30	12										30	40																																																
16	7	7	7				30		12	40	12										28																																																	
17	30		33				30		15		15										22																																																	
18	30						30		15		15										30																																																	
19	30						30		28		28										30																																																	
20	30						30		26		26										30																																																	
21							30		22		22										30																																																	
22							25		23		23										22																																																	
23							9		40												30																																																	
24							12														30																																																	
25							27														30																																																	
26							20														40																																																	

Estacas Raiz				
Identificação	L [m]	At [m²]	Qrup [kN]	Localização
1	17.5	0.07069	1833.9	Roseira, SP
2	18	0.07069	2105.8	Roseira, SP
3	18	0.07069	1754.9	Roseira, SP
4	8	0.13203	833.8	Nova Iguaçu, RJ
5	10.8	0.07548	595.7	Nova Iguaçu, RJ
6	8.6	0.13203	869.2	Nova Iguaçu, RJ
7	10.6	0.04909	709.9	Nova Iguaçu, RJ
8	10.6	0.04909	607.9	Nova Iguaçu, RJ
9	13	0.04909	657	Nova Iguaçu, RJ
10	11.4	0.04909	1128.8	Nova Iguaçu, RJ
11	8.8	0.04909	786.1	Nova Iguaçu, RJ
12	9	0.04909	465.1	Nova Iguaçu, RJ
13	14	0.07548	899.9	Nova Iguaçu, RJ
14	14.4	0.07548	1671.3	Nova Iguaçu, RJ
15	13.35	0.07548	778.2	Nova Iguaçu, RJ
16	6.6	0.13203	897	Nova Iguaçu, RJ
17	13	0.04909	746.6	Nova Iguaçu, RJ
18	11.4	0.04909	1202.9	Nova Iguaçu, RJ
19	13.1	0.07548	710	Nova Iguaçu, RJ
20	7.1	0.13203	1568.3	Nova Iguaçu, RJ
21	8	0.13203	1411.4	Nova Iguaçu, RJ

**ANEXO B – ERRO PERCENTUAL POR ESTACA – A22:6:1 - TREINAMENTO E TESTE –
MODELO 01**

A22:6:1 - TRAINING AND TEST - MODELO 01											
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	893	640	40	51	1463	2900	-50	101	875	835	5
2	1130	1200	-6	52	2100	2810	-25	102	400	760	-47
3	1599	1500	7	53	3344	3600	-7	103	515	445	16
4	3760	1550	143	54	3977	2750	45	104	265	390	-32
5	1769	1100	61	55	3115	3050	2	105	310	560	-45
6	1879	2040	-8	56	1416	2320	-39	106	636	400	59
7	1174	1260	-7	57	2549	5000	-49	107	631	350	80
8	1824	1630	12	58	4631	3850	20	108	1144	340	237
9	1656	1670	-1	59	2424	5000	-52	109	431	575	-25
10	1946	320	508	60	3428	3950	-13	110	462	1240	-63
11	1972	300	557	61	3744	3170	18	111	373	710	-47
12	1520	300	407	62	3821	3850	-1	112	971	960	1
13	2036	800	155	63	3512	3230	9	113	578	990	-42
14	721	900	-20	64	3740	4300	-13	114	674	495	36
15	632	815	-22	65	1022	575	78	115	877	485	81
16	414	360	15	66	1042	770	35	116	-422	780	-154
17	752	670	12	67	1743	1010	73	117	901	1020	-12
18	1387	270	414	68	1731	1940	-11	118	1072	1140	-6
19	-46	190	-124	69	417	125	234	119	403	705	-43
20	1010	1700	-41	70	627	205	206	120	1891	680	178
21	1780	1400	27	71	-68	335	-120	121	1165	815	43
22	1799	1135	58	72	589	840	-30	122	1127	525	115
23	1159	825	40	73	646	265	144	123	1961	1800	9
24	1339	1115	20	74	864	285	203	124	1235	600	106
25	910	950	-4	75	1350	540	150	125	751	750	0
26	1266	850	49	76	1031	675	53	126	779	910	-14
27	814	1040	-22	77	1091	650	68	127	682	1200	-43
28	1770	1830	-3	78	988	1200	-18	128	1141	730	56
29	2712	1115	143	79	1844	590	213	129	956	990	-3
30	1122	900	25	80	1028	570	80	130	710	1100	-35
31	1037	1080	-4	81	793	290	174	131	710	2670	-73
32	1128	1250	-10	82	556	407	37	132	2320	1890	23
33	1500	2200	-32	83	945	820	15	133	2320	2200	5
34	1689	1880	-10	84	2068	780	165	134	2320	1700	36
35	5260	5300	-1	85	676	600	13	135	2320	2200	5
36	1684	1780	-5	86	1364	2280	-40	136	2320	1890	23
37	1349	1820	-26	87	784	320	145	137	2320	2200	5
38	3039	2700	13	88	1235	305	305	138	2320	1510	54
39	1645	2430	-32	89	1573	275	472	139	2320	2410	-4
40	1255	2610	-52	90	389	272	43	140	2320	2550	-9
41	508	2790	-82	91	1161	800	45	141	2320	2300	1
42	1691	2350	-28	92	1563	650	141	142	2320	2830	-18
43	1355	2520	-46	93	608	21	2866	143	2320	2690	-14
44	3199	2600	23	94	1033	360	187	144	2320	3820	-39
45	2805	2850	-2	95	146	55	166	145	2191	2120	3
46	3820	4030	-5	96	560	53	957	146	-41	120	-134
47	2922	2940	-1	97	843	284	197	147	640	275	133
48	9129	8250	11	98	161	770	-79	148	922	1430	-36
49	2265	2760	-18	99	752	1150	-35	149	527	445	18
50	2859	3140	-9	100	479	1370	-65	150	20032	20000	0

A22:6:1 - TRAINING AND TEST - MODELO 01											
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
151	16742	18315	-9	201	4218	4450	-5	251	-128	2190	-106
152	16742	16795	0	202	4002	4200	-5	252	1463	1690	-13
153	16415	14000	17	203	1405	1430	-2	253	1588	660	141
154	2869	2940	-2	204	759	1230	-38	254	1588	1260	26
155	2656	2600	2	205	1032	470	120	255	1145	1230	-7
156	558	490	14	206	1032	690	50	256	1771	1700	4
157	558	510	9	207	1669	1990	-16	257	1073	620	73
158	-473	44	-1176	208	1174	890	32	258	2098	1780	18
159	-473	57	-930	209	1641	2120	-23	259	1487	1940	-23
160	362	125	189	210	10689	2800	282	260	1714	1640	5
161	366	180	103	211	2394	2710	-12	261	2629	2590	1
162	372	224	66	212	364	1820	-80	262	2751	2860	-4
163	643	380	69	213	2602	2350	11	263	15312	2400	538
164	598	380	57	214	1563	1310	19	264	1573	1200	31
165	4774	5000	-5	215	1678	2140	-22	265	1826	1834	0
166	7334	7200	2	216	1549	2250	-31	266	2040	1755	16
167	514	280	84	217	2642	2680	-1	267	650	834	-22
168	514	200	157	218	1321	2850	-54	268	1903	797	139
169	871	210	315	219	1149	1000	15	269	-15	869	-102
170	9433	9500	-1	220	2926	2810	4	270	732	710	3
171	6041	6400	-6	221	2053	1510	36	271	1109	608	82
172	9341	9350	0	222	1957	1820	8	272	1119	1129	-1
173	9720	12500	-22	223	2175	2410	-10	273	742	786	-6
174	-618	180	-443	224	3176	3150	1	274	1334	465	187
175	840	325	158	225	3133	3200	-2	275	616	900	-32
176	1500	1340	12	226	2483	2070	20	276	845	778	9
177	302	650	-54	227	2025	1760	15	277	-1726	897	-292
178	1526	1225	25	228	3471	4020	-14	278	688	747	-8
179	2279	2090	9	229	6672	4850	38	279	1119	1203	-7
180	1139	2280	-50	230	1228	2280	-46	280	1748	1568	11
181	4501	4500	0	231	4573	4900	-7	281	393	1411	-72
182	12326	13000	-5	232	2145	1950	10				
183	13860	16300	-15	233	2010	1950	3				
184	738	745	-1	234	2197	2400	-8				
185	1644	1700	-3	235	2999	2730	10				
186	1242	880	41	236	664	1340	-50				
187	4901	5400	-9	237	3417	3500	-2				
188	3748	3600	4	238	404	400	1				
189	1932	1350	43	239	2485	300	728				
190	2678	2450	9	240	2159	410	427				
191	1251	1440	-13	241	973	510	91				
192	1593	970	64	242	249	710	-65				
193	2772	2440	14	243	2125	2160	-2				
194	1387	1290	8	244	3341	3200	4				
195	1387	1290	8	245	2272	1930	18				
196	1422	1410	1	246	3510	3450	2				
197	879	1380	-36	247	551	630	-13				
198	2207	1900	16	248	551	570	-3				
199	1985	2280	-13	249	843	455	85				
200	772	2820	-73	250	843	450	87				

ANEXO C – ERRO PERCENTUAL POR ESTACA – A22:6:1 - VALIDAÇÃO – MODELO 01

A22:6:1 - VALIDATION - MODELO 01							
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	9755	1500	550	35	417	270	54
2	1933	1500	29	36	31047	21100	47
3	1946	740	163	37	31487	21652	45
4	-260	490	-153	38	31487	16000	97
5	1161	2030	-43	39	558	445	25
6	1761	1005	75	40	-473	57	-930
7	668	1000	-33	41	363	325	12
8	6025	2030	197	42	10281	7400	39
9	1375	3100	-56	43	9336	9300	0
10	5695	2620	117	44	2196	2510	-13
11	2315	5950	-61	45	375	2240	-83
12	1144	2650	-57	46	936	2700	-65
13	1605	4900	-67	47	1419	2080	-32
14	1399	2740	-49	48	1751	1720	2
15	1731	1200	44	49	3381	2750	23
16	-2	325	-101	50	879	1870	-53
17	1562	2720	-43	51	3022	3000	1
18	1916	950	102	52	3948	990	299
19	1028	490	110	53	759	2490	-69
20	1153	560	106	54	-160	2700	-106
21	1364	2070	-34	55	1321	2660	-50
22	118	600	-80	56	2175	2350	-7
23	729	500	46	57	3957	1960	102
24	1678	530	217	58	664	1340	-50
25	1277	535	139	59	249	700	-64
26	531	340	56	60	1697	1950	-13
27	684	350	95	61	-5032	2960	-270
28	1506	1015	48	62	1145	2110	-46
29	658	710	-7	63	2098	1780	18
30	689	720	-4	64	3031	2450	24
31	1001	780	28	65	2040	2106	-3
32	710	1970	-64	66	688	657	5
33	2320	2200	5	67	825	1671	-51
34	2320	1840	26	68	3088	710	335

**ANEXO D – ERRO PERCENTUAL POR ESTACA – A22:11:1 - TREINAMENTO E TESTE
– MODELO 02**

A22:11:1 - TRAINING AND TEST - MODELO 02											
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	2054	640	221	51	120	5000	-98	101	492	710	-31
2	1211	1200	1	52	3982	3850	3	102	761	960	-21
3	4991	1500	233	53	3717	3950	-6	103	706	990	-29
4	1549	1550	0	54	3189	3170	1	104	669	495	35
5	1115	1100	1	55	3677	3850	-4	105	661	485	36
6	1236	1260	-2	56	3241	3230	0	106	749	780	-4
7	1638	1630	0	57	3357	4300	-22	107	1163	1020	14
8	1734	1670	4	58	977	575	70	108	1009	1140	-12
9	1064	320	233	59	738	770	-4	109	135	705	-81
10	850	900	-6	60	969	1010	-4	110	986	680	45
11	1090	815	34	61	1693	1940	-13	111	2190	815	169
12	690	670	3	62	199	125	59	112	513	525	-2
13	260	270	-4	63	395	205	93	113	1711	1800	-5
14	155	190	-18	64	-531	335	-258	114	876	600	46
15	1908	1700	12	65	809	840	-4	115	710	750	-5
16	1396	1400	0	66	1042	265	293	116	1078	1200	-10
17	849	1135	-25	67	480	285	68	117	2462	730	237
18	850	825	3	68	635	540	18	118	972	990	-2
19	1572	1115	41	69	551	675	-18	119	1772	1100	61
20	996	950	5	70	818	650	26	120	1772	2670	-34
21	266	850	-69	71	1118	1200	-7	121	2828	1890	50
22	1579	1830	-14	72	617	590	5	122	2828	3820	-26
23	1279	1115	15	73	-545	570	-196	123	2072	2120	-2
24	1030	900	14	74	405	290	40	124	-13	120	-111
25	1002	1080	-7	75	771	407	89	125	443	275	61
26	1309	1250	5	76	1437	820	75	126	1481	1430	4
27	1642	2200	-25	77	817	780	5	127	937	445	111
28	2111	1880	12	78	612	600	2	128	19982	20000	0
29	4738	5300	-11	79	2148	2280	-6	129	25381	18315	39
30	1784	1780	0	80	577	320	80	130	13883	14000	-1
31	1857	1820	2	81	75	305	-75	131	2931	2940	0
32	2737	2700	1	82	352	275	28	132	4807	2600	85
33	2299	2430	-5	83	-921	272	-439	133	486	510	-5
34	2295	2610	-12	84	1042	800	30	134	-96	180	-153
35	755	2790	-73	85	889	650	37	135	353	224	58
36	2375	2350	1	86	525	360	46	136	594	380	56
37	2414	2520	-4	87	552	284	94	137	5054	5000	1
38	2494	2600	-4	88	815	770	6	138	7070	7200	-2
39	2852	2850	0	89	1032	1150	-10	139	519	280	85
40	4117	4030	2	90	1158	1370	-15	140	428	210	104
41	2700	2940	-8	91	573	835	-31	141	9483	9500	0
42	8238	8250	0	92	1408	760	85	142	6200	6400	-3
43	3100	2760	12	93	858	445	93	143	9351	9350	0
44	3207	3140	2	94	924	390	137	144	12440	12500	0
45	2258	2900	-22	95	-256	560	-146	145	139	180	-23
46	2448	2810	-13	96	356	400	-11	146	817	325	151
47	2181	3600	-39	97	457	350	30	147	1596	1340	19
48	3117	2750	13	98	621	340	83	148	902	650	39
49	2165	3050	-29	99	57	575	-90	149	1249	1225	2
50	2187	2320	-6	100	1343	1240	8	150	2162	2090	3

A22:11:1 - TRAINING AND TEST - MODELO 02							
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
151	2284	2280	0	201	1986	1950	2
152	4497	4500	0	202	1806	1950	-7
153	12926	13000	-1	203	2348	2400	-2
154	685	745	-8	204	2708	2730	-1
155	1616	1700	-5	205	774	1340	-42
156	822	880	-7	206	3737	3500	7
157	2897	5400	-46	207	620	400	55
158	160	3600	-96	208	111	300	-63
159	1834	1350	36	209	1498	410	265
160	2585	2450	6	210	549	510	8
161	1685	1440	17	211	675	710	-5
162	1566	970	61	212	2221	2160	3
163	3975	2440	63	213	3271	3200	2
164	-199	1290	-115	214	1872	1930	-3
165	1317	1410	-7	215	3433	3450	0
166	1239	1380	-10	216	335	630	-47
167	1913	1900	1	217	2151	2190	-2
168	2178	2280	-4	218	1630	1690	-4
169	2291	2820	-19	219	998	660	51
170	4300	4450	-3	220	1376	1230	12
171	4256	4200	1	221	1684	1700	-1
172	1444	1430	1	222	393	620	-37
173	938	1230	-24	223	1747	1780	-2
174	394	470	-16	224	1943	1940	0
175	394	690	-43	225	1773	1640	8
176	1857	1990	-7	226	2595	2590	0
177	1412	890	59	227	2864	2860	0
178	1795	2120	-15	228	2403	2400	0
179	668	2800	-76	229	1488	1200	24
180	2659	2710	-2	230	1974	1834	8
181	1864	1820	2	231	805	834	-3
182	2312	2350	-2	232	1092	797	37
183	1315	1310	0	233	894	869	3
184	2150	2140	0	234	704	710	-1
185	1058	2250	-53	235	499	608	-18
186	2698	2680	1	236	1047	786	33
187	2332	2850	-18	237	414	465	-11
188	1032	1000	3	238	1055	900	17
189	2800	2810	0	239	812	778	4
190	1423	1510	-6	240	1027	897	15
191	1683	1820	-8	241	778	747	4
192	2294	2410	-5	242	1599	1568	2
193	3139	3150	0	243	1086	1411	-23
194	3131	3200	-2				
195	2119	2070	2				
196	1749	1760	-1				
197	3233	4020	-20				
198	4967	4850	2				
199	2134	2280	-6				
200	4977	4900	2				

ANEXO E – ERRO PERCENTUAL POR ESTACA – A22:11:1 - VALIDAÇÃO – MODELO 02

A22:11:1 - VALIDATION - MODELO 02			
Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	14434	1500	862
2	186	1500	-88
3	861	2030	-58
4	1289	1005	28
5	-2883	1000	-388
6	4970	2030	145
7	3467	3100	12
8	3663	5950	-38
9	1893	2650	-29
10	2429	4900	-50
11	553	2740	-80
12	1693	1200	41
13	-638	325	-296
14	1906	2720	-30
15	1280	950	35
16	1401	560	150
17	2148	2070	4
18	2467	600	311
19	846	500	69
20	2130	530	302
21	3341	535	525
22	165	340	-51
23	369	350	5
24	328	1015	-68
25	5723	710	706
26	530	720	-26
27	1306	780	67
28	1772	1970	-10
29	199	270	-26
30	20510	21100	-3
31	486	445	9
32	5514	7400	-25
33	6590	9300	-29
34	2498	2510	0
35	81	2240	-96
36	1496	2700	-45
37	3299	2080	59
38	1315	1720	-24
39	3647	2750	33
40	1801	3000	-40
41	3441	990	248
42	-2202	2700	-182
43	3585	1950	84
44	-2254	2960	-176
45	1376	2110	-35
46	1425	2450	-42
47	4631	2106	120
48	778	657	18
49	2255	710	218

**ANEXO F – ERRO PERCENTUAL POR ESTACA – A12:3:1 - TREINAMENTO E TESTE –
MODELO 03**

A12:3:1 - TRAINING AND TEST - MODELO 03											
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	765	640	20	51	2583	5000	-48	101	599	710	-16
2	821	1200	-32	52	3460	3850	-10	102	1041	960	8
3	1553	1500	4	53	4003	3950	1	103	795	990	-20
4	1825	1550	18	54	3661	3170	15	104	724	495	46
5	1660	1100	51	55	3957	3850	3	105	357	485	-26
6	1481	1260	18	56	3418	3230	6	106	817	780	5
7	993	1630	-39	57	4603	4300	7	107	736	1020	-28
8	873	1670	-48	58	487	575	-15	108	840	1140	-26
9	682	320	113	59	548	770	-29	109	677	705	-4
10	663	900	-26	60	816	1010	-19	110	670	680	-2
11	870	815	7	61	964	1940	-50	111	810	815	-1
12	580	670	-13	62	271	125	116	112	614	525	17
13	280	270	4	63	375	205	83	113	2111	1800	17
14	525	190	176	64	258	335	-23	114	1159	600	93
15	1532	1700	-10	65	683	840	-19	115	339	750	-55
16	1428	1400	2	66	586	265	121	116	564	1200	-53
17	1239	1135	9	67	720	285	153	117	692	730	-5
18	1538	825	86	68	544	540	1	118	2045	990	107
19	971	1115	-13	69	360	675	-47	119	963	1100	-12
20	648	950	-32	70	206	650	-68	120	2228	2670	-17
21	560	850	-34	71	429	1200	-64	121	1823	1890	-4
22	1348	1830	-26	72	492	590	-17	122	2789	3820	-27
23	2720	1115	144	73	1666	570	192	123	3238	2120	53
24	1130	900	26	74	260	290	-10	124	478	120	298
25	1079	1080	0	75	456	407	12	125	445	275	62
26	1259	1250	1	76	1139	820	39	126	2829	1430	98
27	1326	2200	-40	77	1122	780	44	127	434	445	-2
28	1394	1880	-26	78	1517	600	153	128	10079	20000	-50
29	2528	5300	-52	79	2407	2280	6	129	18269	18315	0
30	2278	1780	28	80	272	320	-15	130	13941	14000	0
31	2157	1820	19	81	332	305	9	131	3050	2940	4
32	3028	2700	12	82	329	275	20	132	1521	2600	-42
33	2124	2430	-13	83	481	272	77	133	677	510	33
34	2011	2610	-23	84	731	800	-9	134	376	180	109
35	1736	2790	-38	85	490	650	-25	135	451	224	101
36	2219	2350	-6	86	518	360	44	136	510	380	34
37	2479	2520	-2	87	367	284	29	137	3320	5000	-34
38	3118	2600	20	88	851	770	11	138	4335	7200	-40
39	1780	2850	-38	89	1174	1150	2	139	694	280	148
40	4191	4030	4	90	1346	1370	-2	140	741	210	253
41	2847	2940	-3	91	825	835	-1	141	9574	9500	1
42	7345	8250	-11	92	918	760	21	142	5921	6400	-7
43	2187	2760	-21	93	581	445	31	143	9497	9350	2
44	1813	3140	-42	94	543	390	39	144	9220	12500	-26
45	1891	2900	-35	95	773	560	38	145	762	180	323
46	1815	2810	-35	96	287	400	-28	146	1006	325	210
47	2430	3600	-33	97	549	350	57	147	1480	1340	10
48	2903	2750	6	98	843	340	148	148	545	650	-16
49	1837	3050	-40	99	522	575	-9	149	1474	1225	20
50	1797	2320	-23	100	1188	1240	-4	150	3810	2090	82

A12:3:1 - TRAINING AND TEST - MODELO 03							
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
151	3556	2280	56	201	3155	1950	62
152	5052	4500	12	202	2104	1950	8
153	12665	13000	-3	203	2422	2400	1
154	994	745	33	204	3985	2730	46
155	836	1700	-51	205	1606	1340	20
156	1260	880	43	206	2368	3500	-32
157	4186	5400	-22	207	575	400	44
158	3371	3600	-6	208	823	300	174
159	1258	1350	-7	209	785	410	91
160	3087	2450	26	210	822	510	61
161	2106	1440	46	211	807	710	14
162	1195	970	23	212	2553	2160	18
163	2072	2440	-15	213	3487	3200	9
164	1520	1290	18	214	1614	1930	-16
165	1407	1410	0	215	3327	3450	-4
166	1690	1380	22	216	908	630	44
167	1788	1900	-6	217	1497	2190	-32
168	2014	2280	-12	218	2419	1690	43
169	3712	2820	32	219	1086	660	65
170	3516	4450	-21	220	1808	1230	47
171	5033	4200	20	221	1322	1700	-22
172	1071	1430	-25	222	1391	620	124
173	1209	1230	-2	223	2230	1780	25
174	1025	470	118	224	1942	1940	0
175	1335	690	93	225	1645	1640	0
176	1376	1990	-31	226	2293	2590	-11
177	1203	890	35	227	2162	2860	-24
178	2313	2120	9	228	2448	2400	2
179	2413	2800	-14	229	980	1200	-18
180	2356	2710	-13	230	1908	1834	4
181	2458	1820	35	231	1582	834	90
182	2995	2350	27	232	1010	596	70
183	1543	1310	18	233	1462	869	68
184	1956	2140	-9	234	1367	710	93
185	1762	2250	-22	235	1397	608	130
186	2093	2680	-22	236	788	786	0
187	2517	2850	-12	237	981	465	111
188	1450	1000	45	238	1483	900	65
189	2728	2810	-3	239	1159	778	49
190	1442	1510	-5	240	1037	897	16
191	1590	1820	-13	241	1754	747	135
192	1935	2410	-20	242	1126	1568	-28
193	3389	3150	8	243	1140	1411	-19
194	3799	3200	19				
195	2552	2070	23				
196	1620	1760	-8				
197	3920	4020	-2				
198	4086	4850	-16				
199	3338	2280	46				
200	4710	4900	-4				

ANEXO G – ERRO PERCENTUAL POR ESTACA – A12:3:1 - VALIDAÇÃO – MODELO 03

A12:3:1 - VALIDATION - MODELO 03			
Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	1637	1500	9
2	1869	1500	25
3	1560	2030	-23
4	1090	1005	8
5	991	1000	-1
6	1964	2030	-3
7	2669	3100	-14
8	4021	5950	-32
9	2157	2650	-19
10	5276	4900	8
11	2927	2740	7
12	721	1200	-40
13	494	325	52
14	1031	2720	-62
15	586	950	-38
16	756	560	35
17	1782	2070	-14
18	570	600	-5
19	496	500	-1
20	719	530	36
21	527	535	-1
22	274	340	-19
23	321	350	-8
24	1000	1015	-1
25	1502	710	112
26	314	720	-56
27	730	780	-6
28	1529	1970	-22
29	341	270	26
30	12551	21100	-41
31	445	486	9
32	6332	7400	-14
33	9329	9300	0
34	3821	2510	52
35	3556	2240	59
36	2602	2700	-4
37	2024	2080	-3
38	1809	1720	5
39	2185	2750	-21
40	2380	3000	-21
41	768	990	-22
42	2404	2700	-11
43	2377	1950	22
44	2769	2960	-6
45	2412	2110	14
46	2450	1425	-42
47	1788	2106	-15
48	1754	657	167
49	1007	710	42

**ANEXO H – ERRO PERCENTUAL POR ESTACA – A7:7:1 - TREINAMENTO E TESTE –
MODELO 04**

A7:7:1 - TRAINING AND TEST - MODELO 04															
Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)	Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	818	640	28	51	1344	820	64	101	2949	2940	0	151	1246	1000	25
2	1474	1630	-10	52	1069	780	37	102	2492	2600	-4	152	1341	1510	-11
3	1830	1670	10	53	1057	600	76	103	691	510	35	153	1833	1820	1
4	666	900	-26	54	312	320	-3	104	18	180	-90	154	2308	2410	-4
5	648	815	-20	55	202	305	-34	105	272	224	21	155	3334	3150	6
6	106	670	-84	56	176	275	-36	106	495	380	30	156	3474	3200	9
7	-286	270	-206	57	611	272	125	107	6686	7200	-7	157	2025	2070	-2
8	96	190	-50	58	616	800	-23	108	667	280	138	158	1667	1760	-5
9	1738	1700	2	59	323	650	-50	109	712	210	239	159	4193	4020	4
10	1040	1400	-26	60	521	360	45	110	6363	6400	-1	160	4877	4850	1
11	1211	1135	7	61	310	284	9	111	15106	12500	21	161	3502	2280	54
12	1058	825	28	62	749	770	-3	112	812	180	351	162	4321	1950	122
13	1021	1115	-8	63	1345	1150	17	113	545	325	68	163	2526	1950	30
14	621	950	-35	64	1414	1370	3	114	1821	1340	36	164	3076	2400	28
15	455	850	-46	65	585	835	-30	115	1161	650	79	165	1746	1340	30
16	905	900	1	66	1051	760	38	116	1376	1225	12	166	2616	3500	-25
17	1055	1080	-2	67	573	445	29	117	2508	2090	20	167	601	400	50
18	1572	2200	-29	68	557	390	43	118	2300	2280	1	168	925	300	208
19	1748	1880	-7	69	420	560	-25	119	4542	4500	1	169	420	410	2
20	1871	1780	5	70	251	400	-37	120	939	745	26	170	423	510	-17
21	2792	2430	15	71	303	350	-14	121	1657	1700	-3	171	541	710	-24
22	2566	2610	-2	72	238	340	-30	122	751	880	-15	172	3539	3450	3
23	2141	2790	-23	73	521	575	-9	123	5243	5400	-3	173	720	630	14
24	2374	2350	1	74	1393	1240	12	124	3252	3600	-10	174	1322	2190	-40
25	1917	2850	-33	75	573	710	-19	125	1927	1350	43	175	2224	1690	32
26	2209	3140	-30	76	1263	960	32	126	2354	2450	-4	176	791	660	20
27	2437	2900	-16	77	961	990	-3	127	1660	970	71	177	1307	1700	-23
28	2394	2810	-15	78	757	495	53	128	2324	2440	-5	178	1218	620	96
29	2979	3600	-17	79	265	485	-45	129	1213	1290	-6	179	2103	1780	18
30	2000	3050	-34	80	642	780	-18	130	1720	1410	22	180	2118	1940	9
31	2061	2320	-11	81	658	1020	-35	131	2217	1380	61	181	1689	1640	3
32	3339	5000	-33	82	873	1140	-23	132	2059	1900	8	182	2177	2590	-16
33	572	575	-1	83	483	705	-32	133	2020	2280	-11	183	2767	2860	-3
34	631	770	-18	84	491	680	-28	134	2892	2820	3	184	2551	2400	6
35	516	1010	-49	85	825	815	1	135	4162	4450	-6	185	1086	1200	-10
36	1222	1940	-37	86	636	525	21	136	1346	1430	-6	186	1824	1834	-1
37	233	125	86	87	891	600	49	137	1464	1230	19	187	884	834	6
38	241	205	17	88	423	750	-44	138	823	470	75	188	511	596	-14
39	28	335	-92	89	902	1200	-25	139	1321	690	91	189	1028	869	18
40	338	840	-60	90	393	730	-46	140	1390	1990	-30	190	637	710	-10
41	678	265	156	91	1934	990	95	141	1458	890	64	191	571	608	-6
42	934	285	228	92	1159	1100	5	142	3011	2120	42	192	423	786	-46
43	677	540	25	93	2070	2670	-22	143	2715	2800	-3	193	887	465	91
44	342	675	-49	94	2050	1890	8	144	2546	2710	-6	194	1035	900	15
45	157	650	-76	95	3350	3820	-12	145	3734	1820	105	195	1080	778	39
46	395	1200	-67	96	2347	2120	11	146	3035	2350	29	196	1223	897	36
47	241	590	-59	97	289	120	141	147	830	1310	-37	197	719	747	-4
48	622	570	9	98	413	275	50	148	1578	2140	-26	198	1423	1568	-9
49	225	290	-22	99	2290	1430	60	149	1902	2250	-15	199	1412	1411	0
50	451	407	11	100	420	445	-6	150	2945	2850	3				

ANEXO I – ERRO PERCENTUAL POR ESTACA – A7:7:1 - VALIDAÇÃO – MODELO 04

A7:7:1 - VALIDATION - MODELO 04			
Estaca	valor obtido (output)	valor esperado (target)	EP (%)
1	1071	2030	-47
2	485	1000	-52
3	905	1200	-25
4	237	325	-27
5	402	950	-58
6	827	560	48
7	698	600	16
8	524	500	5
9	724	530	37
10	734	535	37
11	287	340	-16
12	212	350	-39
13	972	1015	-4
14	725	710	2
15	229	720	-68
16	814	780	4
17	1657	1970	-16
18	312	270	16
19	11636	7400	57
20	2428	2510	-3
21	3817	2240	70
22	2762	2700	2
23	1380	2080	-34
24	2773	2750	1
25	1598	990	61
26	3318	2700	23
27	2430	1950	25
28	3564	2960	20
29	2896	2450	18
30	1843	2106	-12
31	719	657	9
32	899	710	27