

Redes neurais artificiais para previsão de capacidade de carga em estacas do tipo hélice contínua

Artificial neural networks for load capacity prediction in continuous flight auger piles

DOI:10.34117/bjdv7n12-171

Recebimento dos originais: 12/11/2021

Aceitação para publicação: 07/12/2021

Iago Irteson Pegado Moreira

Graduando em Engenharia Cartográfica e de Agrimensura (ECA)
Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: pegadoiago@gmail.com

Emerson Cordeiro Moraes

Doutor em Engenharia de Sistemas e Computação - Universidade Federal do Rio de Janeiro
Universidade Federal Rural da Amazônia
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: emerson.morais@ufra.edu.br

Raykleison Igor dos Reis Moraes

Doutor em Engenharia Mecânica - Universidade Estadual de Campinas (UNICAMP)
Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: raykleison.moraes@ufra.edu.br

Alex de Jesus Zissou

Doutorando em Agronomia - Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: alexzissou@gmail.com

Pedro Silvestre da Silva Campos

Doutor em Ciências Agrárias - Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: pedro.campos@ufra.edu.br

Glauber Tadaiesky Marques

Doutor em Física Teórica - Universidade Federal do Espírito Santo (UFES)
Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: glauber.tadaiesky@ufra.edu.br

Otavio Andre Chase

Doutor em Engenharia Elétrica e Sistemas de Energia - Universidade Federal do Pará (UFPA)
Membro Sênior do Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE)
Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: otavio.chase@ufra.edu.br

José Felipe Souza de Almeida

Doutor em Engenharia Elétrica - Universidade Federal do Pará (UFPA)
Universidade Federal Rural da Amazônia (UFRA)
Avenida Presidente Tancredo Neves, 2501 – Terra Firme - Belém – PA - Brasil
E-mail: felipe.almeida@ufra.edu.br

RESUMO

As Redes Neurais Artificiais (RNAs) são usadas atualmente para uma gama de problemas lineares e não-lineares, pois é utilizada como uma ferramenta alternativa para prever determinados fenômenos no ramo da Engenharia Geotécnica. Especificamente neste trabalho, aplica-se a ferramenta RNA Perceptron de Múltiplas Camadas para previsão de capacidade de carga de estacas escavadas do tipo hélice contínua. Para a construção da base de dados foram utilizados dados de literatura de prova de carga estática e de ensaio de sondagem de simples reconhecimento (SPT) de diferentes estados do Brasil, com diferentes tipos de solo. Foram realizados 60 tipos de configurações para a arquitetura da rede neural, objetivando a predição da capacidade de carga da estaca, gerando gráficos de treinamento da rede, de teste e erro quadrático médio. Os resultados mostram que as RNAs têm um grande potencial para resolver problemas deste tipo e para auxiliar em tomada de decisões.

Palavras-chave: Redes Neurais Artificiais, Engenharia Geotécnica, Capacidade de Carga.

ABSTRACT

Artificial Neural Networks (ANNs) are currently used for a range of linear and non-linear problems, as it is used as an alternative tool to predict certain phenomena in the Geotechnical Engineering subject. Specifically in this work, the Multilayer Perceptron ANN tool is applied to predict the load capacity of continuous helix type excavated piles. For the database construction, data from the literature of static load test and standard penetration test (SPT) from different Brazilian states, with different types of soils, were used. Sixty configurations were performed for the neural network architecture, aiming to predict the pile load capacity, generating network training, test and mean square error graphs. The results show that ANNs have a great potential to solve problems of this type and to assist in decision making.

Keywords: Artificial Neural Networks, Geotechnical Engineering, Load Capacity.

1 INTRODUÇÃO

Um dos principais problemas da Engenharia Geotécnica é a previsão de capacidade de carga em estacas, visto que o solo é heterogêneo e não linear, ou seja, o solo é imprevisível e

variável. Por esse motivo se faz necessário alguns ensaios de laboratório e de campo. Segundo Cintra e Aoki (2010), capacidade de carga é o valor de força correspondente à máxima resistência que o sistema pode oferecer ou o valor representativo da condição de ruptura do sistema, em termos geotécnicos. Pelo entendimento físico deste sistema há duas formas de resistência e são elas: as tensões resistentes ao longo do fuste (carga lateral, R_L) e as tensões resistentes na ponta da estaca (R_P).

No Brasil, a sondagem de simples reconhecimento se tornou a mais usual para trabalhos deste tipo, visto que este tipo de ensaio fornece uma gama de informações para a previsão de capacidade de carga. Alguns métodos empíricos e semiempíricos são utilizados para validar tais experimentos, dentre os métodos semiempíricos é importante destacar os métodos: Aoki-Velloso (1975) e Décourt-Quaresma (1978) (CINTRA et al., 2013).

As redes neurais artificiais vêm sendo utilizadas cada vez mais, nos mais variados tipos de problemas complexos, segundo Haykin (2005). Para Morais (2010), as RNAs são sistemas paralelos que são compostos por uma unidade de processamento simples (nodos ou neurônios) que calculam algumas funções matemáticas que geralmente são não-lineares. Essas unidades são classificadas em uma ou mais camadas e são interligadas por um grande número de conexões, no qual geralmente são unidirecionais e, que na maioria dos modelos, estas conexões estão concatenadas a pesos, os quais os mesmos armazenam conhecimento representado pelo modelo e também serve pra ponderar a entrada recebida por cada neurônio da rede.

2 REVISÃO DE LITERATURA

2.1 INVESTIGAÇÃO GEOTÉCNICA

Segundo Delazzeri (2018) para realizar projetos geotécnicos com segurança e economia, é fundamental fazer o reconhecimento das características do subsolo, estes que são regularmente efetuados com base em ensaios em laboratório e/ou campo. Com isso, as observações permitem uma melhor estimativa das propriedades geotécnicas dos materiais envolvidos, além da definição da estratigrafia do subsolo.

Também é importante realizar a classificação de camadas que compõem o substrato, analisando: tipo do solo, profundidades, consistência, compacidade, características de resistência e deformabilidade, localização do nível d'água, profundidade de superfície do impenetrável, entre outros. Para determinar essas características, se faz necessário a aplicação

de instrumentação de campo, no qual viabiliza observar o comportamento do solo “in situ” montando um elo entre os mecanismos de comportamento da obra e as hipóteses dos projetos.

2.2 ENSAIO SPT

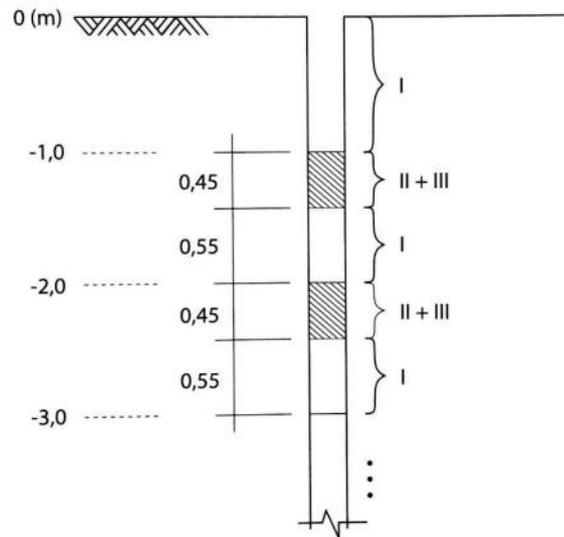
Os ensaios ou sondagens de simples reconhecimento (SPT, do inglês: Standard Penetration Test) é o tipo mais comum utilizado no Brasil. Segundo Cintra et al. (2013), o ensaio SPT consiste na cravação do amostrador padrão, sendo necessário aplicar golpes na haste por meio de algum peso que se lança em queda livre.

O método mais utilizado atualmente, no Brasil, para a determinação dos tipos de solo, perfil geológico, consistência dos solos, além da capacidade de carga das camadas do subsolo é a sondagem à percussão, que é conhecida como sondagem de simples reconhecimento com SPT (Standart Penetration Test), cujo mesmo é identificado pela normalização da ABNT na NBR 6484 (CASTRO et al., 2016).

A NBR 6484 (ABNT, 2020) que é a norma de sondagem de simples reconhecimento determina a execução de: sistema de sondagem manual e sistema de sondagem mecanizado; tipos de solos e suas respectivas profundidades de ocorrência; indicação da posição do nível de água (se houver) durante a execução de cada sondagem; índice de resistência à penetração N a cada metro. Onde N é o índice de resistência à penetração que é determinado pelo número de golpes que corresponde à cravação de 30 cm do amostrador padrão, logo após a cravação inicial de 15 cm, utilizando um martelo de 65 kg de massa.

Segundo Delazzeri (2018), o ensaio SPT consiste em três etapas: perfuração (I), amostragem (II) e ensaio penetrométrico (III). Inicialmente, perfura-se o primeiro metro com trado manual, pois o amostrador é introduzido somente no início do segundo metro. Depois, para cada metro, toma-se 0,45 m para amostragem e ensaio penetrométrico, seguindo de 0,55 m de perfuração conforme apresenta a Figura 1.

Figura 1 – Sequência de etapas do ensaio SPT.



Fonte: Adaptado Cintra *et al.* (2013)

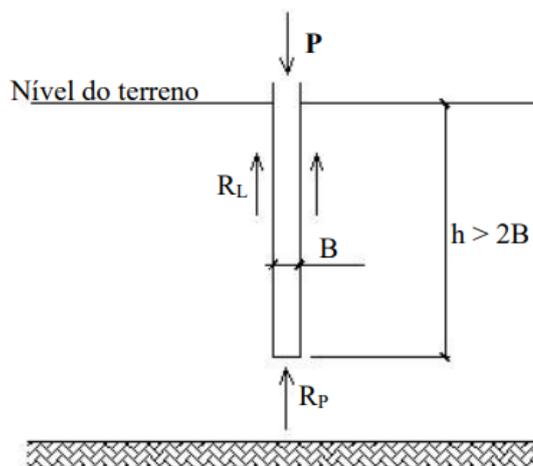
No qual em cada metro de sondagem, com exceção do primeiro, se obtém três valores de golpes no ensaio penetrométrico (N_1 , N_2 e N_3), por ser afetado pela etapa de perfuração pode desconsiderar N_1 e assim, define-se o índice de resistência à penetração (N_{SPT}) como a soma do número de golpes dos últimos 30 cm de penetração do amostrador, conforme apresenta a Equação (1) (Cintra *et al.*, 2013).

$$N_{SPT} = N_2 + N_3 \left(\frac{\text{golpes}}{30\text{cm}} \right) \quad (1)$$

2.3 TIPOS DE FUNDAÇÕES PROFUNDAS

Segundo NBR 6122 (ABNT, 2019) a definição de fundação profunda se dá pelo elemento estrutural que transmite a carga por uma das três maneiras: pela base, sua superfície lateral ou a combinação das duas, e acrescenta que sua base deve estar assentada a uma profundidade h superior ao dobro de sua menor dimensão B em planta, e no mínimo igual a 3 metros conforme a Figura 2 (AMANCIO, 2013).

Figura 1 – Mecanismo de funcionamento de uma fundação profunda



Fonte: Amancio (2013) apud Amancio (2009)

Através dessa afirmação a carga vertical P aplicada ao topo da estaca pode ser calculada através da Equação (2):

$$P = R_L + R_p \quad (2)$$

Sendo:

- R_L representa a resistência do fuste em kN,
- R_p representa a resistência da base em kN.

Fundações profundas estão divididas em duas grandes categorias através da NBR 6122/2019, são dos tipos estacas ou tubulões.

A estaca pode ser definida como o elemento executado com o auxílio de ferramentas e equipamentos, sem que tenha a necessidade de algum operário descer durante todo o processo, elas podem ser constituídas de madeira, aço ou concreto, ou então pela combinação desses três materiais (AMANCIO, 2013).

Tubulões podem ser definidos como elementos de forma cilíndrica, no qual pelo menos em sua fase final ocorre a descida do operário, podendo ser executado a céu aberto ou a ar comprimido, podendo ter ou não base alargada (AMANCIO, 2013)

Décourt e Cintra (1998) descrevem que as estacas podem ser classificadas em duas categorias: Estacas de Deslocamento ou Estacas Escavadas.

Estacas de deslocamento podem ser definidas como aquelas que são introduzidas no terreno através de um método que não ocorra a retirada do solo. No Brasil, comumente é utilizado esse tipo de estaca que são as pré-moldadas de concreto armado, também se

enquadram nessa categoria as estacas metálicas, de madeira, apiloadas de concreto, de concreto fundido no terreno dentro de um tubo de revestimento de aço cravado com ponta fechada.

Já as estacas escavadas podem ser descritas como aquelas executadas “in situ” através da perfuração do terreno por qualquer processo, com a remoção do material podendo ter ou não revestimento e com ou sem a utilização de fluidos estabilizantes, as estacas que se enquadram nesse quesito são do tipo broca, executadas manualmente ou mecanicamente, os tipos “strauss”, os barretes, as de hélice contínua e etc.

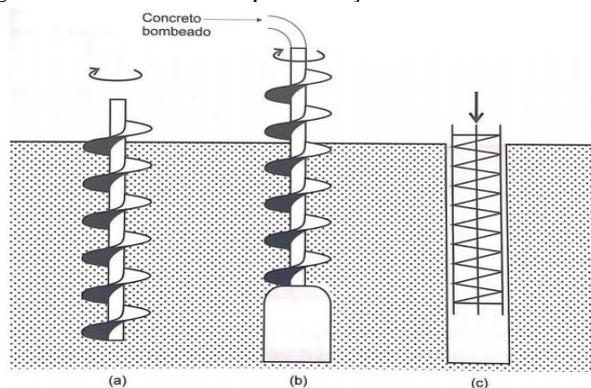
Delazzeri (2018) discorre sobre o histórico da estaca do tipo hélice contínua, que teve seu início nos Estados Unidos, na década de 50. Já na Europa, esta técnica só foi chegar na década de 70, na Alemanha e, posteriormente, ficou popular por toda a Europa.

Já no Brasil, conforme Magalhães (2005), essa estaca foi introduzida em 1987, porém, na época não tinha equipamentos propícios para a sua execução, que eram montados sob guindastes e esteiras, sendo sua capacidade de fundação de até 15 metros.

A estaca hélice contínua é uma estaca de concreto moldada “in loco”, que consiste na perfuração do solo através de uma haste formada por um trado contínuo (hélice contínua) e consequente injeção de concreto. O trado é introduzido no solo até a profundidade definida no projeto, sendo então retirado simultaneamente com a aplicação de concreto, sob pressão controlada, através da parte central do trado. (MAGALHÃES, 2005).

A Figura 3 detalha o processo executivo de uma estaca escavada do tipo hélice: onde é mostrada a escavação do fuste da estaca (a), em seguida o lançamento do concreto durante a retirada da hélice contínua (b), e posteriormente, a instalação da armação (c).

Figura 3 – Processo de implementação de estaca hélice contínua



Fonte: Delazzeri (2018) *apud* Velloso e Lopes (2010)

2.4 ENSAIO DE PROVAS DE CARGAS

Para Delazzeri (2018), além dos métodos semiempíricos, o ensaio de prova de carga é uma ferramenta mais precisa ainda, uma vez que esse ensaio de campo é capaz de fazer observações acerca do comportamento que ocorre com o sistema solo-estaca.

Segundo a NBR 6122 (ABNT, 2010), a determinação da carga admissível pode ser teórica, quando o cálculo é feito de acordo com a teoria desenvolvida dentro da mecânica dos solos, ou semiempíricos, quando são usadas correlações com ensaios in situ. A carga de ruptura pode ser determinada através de provas de carga estática, executadas de acordo com a NBR 12131 (ABNT, 2006), ou pelo ensaio de carregamento dinâmico, visando à avaliação de cargas mobilizadas na interface solo-estaca, fundamentada na Teoria da Equação de Onda Unidimensional, conforme a NBR 13208 (ABNT, 2007) (DELAZZERI, 2018).

Segundo Delazzeri (2018) para o ensaio de prova de carga estática, o seu principal objetivo é fornecer informações para avaliar o comportamento da carga da tensão versus deformação, além de estimar suas características de capacidade de carga.

Para Melo (2009), a capacidade de carga de um elemento isolado (P_u) é o principal objetivo da prova de carga, ela é composta por duas parcelas de resistência, pela resistência da ponta (R_p) e pelo atrito lateral (R_l) de acordo com as Equações (3) e (4).

$$P_u = R_l + R_p \quad (3)$$

$$P_u = F_{s\text{ méd}} * A_l + \sigma_p * A_p \quad (4)$$

Sendo:

- $F_{s\text{ méd}}$ o atrito unitário médio ou a adesão média do solo ao longo da estaca;
- A_l a área da estaca;
- σ_p a capacidade de carga da camada de solo que serve de apoio à estaca;
- A_p a área de secção transversal da ponta da estaca.

2.5 ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL PERCEPTRON DE MÚLTIPLAS CAMADAS

As Redes Neurais Artificiais (RNAs) podem ser descritas como sistemas paralelos que são constituídos por unidades de processamento simples, no qual são capazes de calcular determinadas funções matemáticas. Estas unidades estão organizadas em uma ou mais camadas

que são interligadas por conexões, que na maioria das vezes são unidirecionais. Na maioria dos modelos, estas conexões são associadas a pesos sinápticos, no qual os mesmos armazenam o conhecimento que é representado no modelo e, ponderando a entrada recebida por cada neurônio da rede.

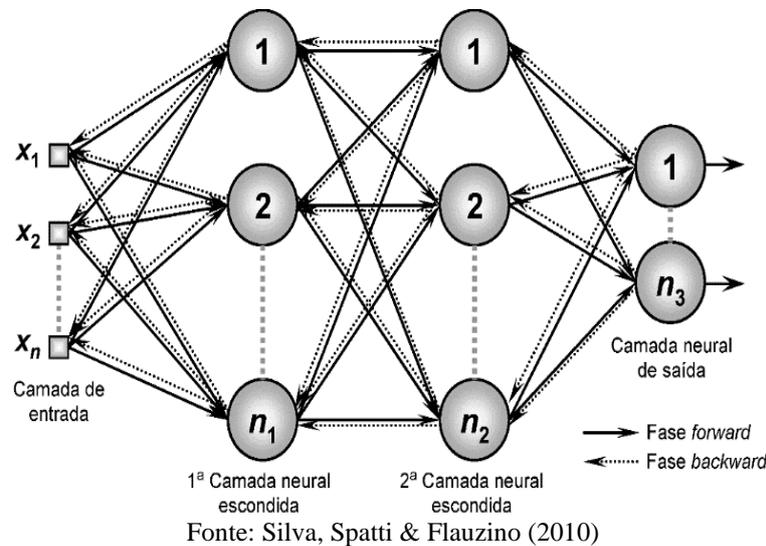
Tipicamente, a rede consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada. Estas redes neurais são normalmente chamadas de perceptrons de múltiplas camadas (MLP, multilayer perceptron) (HAYKIN, 2005).

Em conformidade com Haykin (2005), o mesmo cita que o algoritmo Perceptrons de múltiplas camadas é um grupo de unidades sensoriais que forma a camada de entrada da rede, em seguida vem a camada oculta, que pode conter uma ou mais camadas ocultas de nós computacionais e por fim, a camada de saída da rede. Por ser uma arquitetura mais versátil, sua aplicação pode ser usada em diversos tipos de problemas, tais como:

- Previsão de séries temporais;
- Aproximação universal de funções;
- Otimização de sistemas;
- Reconhecimento de Padrões.

Morais (2010) e Farias (2018) descrevem que o algoritmo backpropagation (Figura 4) se baseia na regra de aprendizagem por correção de erros, que consiste em duas fases: a fase forward que é a fase de propagação adiante e a fase backward que é a fase de propagação reversa. Na primeira fase, o forward começa através da camada de entrada da rede, são então propagados através da rede, camada por camada até a produção de suas respectivas saídas (resposta da rede). Os valores atuais de pesos sinápticos e limiares considerados nesta etapa são todos fixos e permanecem inalterados durante a execução desta fase. Ao final dessa fase. As respostas produzidas pelas saídas da rede são comparadas com as respectivas respostas desejadas e um sinal de erro é produzido.

Figura 4 – Fluxo do processamento do algoritmo backpropagation



Já a fase backward começa da fase de saída da máquina, passando pela camada oculta e calculando seus erros e assim atualizando seus pesos para a diminuição de erros e os levando para a camada de entrada, ou seja, esta fase é a forma inversa da fase forward (MORAIS, 2010).

Segundo Barca e Magini (2005) O algoritmo backpropagation conta com o uso do aprendizado supervisionado, no qual o método de treinamento tem embasamento a tentativa de erros, por essa razão, se a atualização da taxa dos pesos for baixa, a rede pode consumir um longo tempo para o treinamento, porém se a taxa for alta a rede consegue processar em um curto espaço de tempo.

3 METODOLOGIA

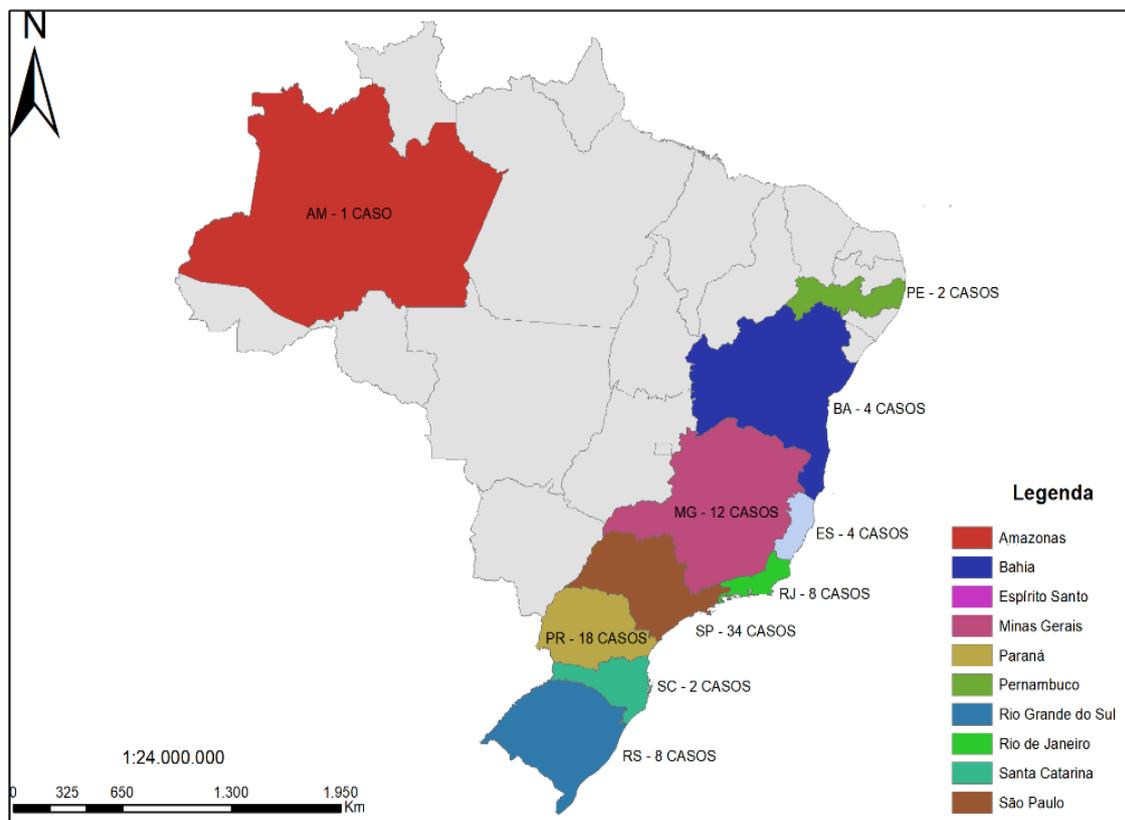
3.1 COLETA E APRESENTAÇÃO DA BASE DE DADOS

Para a realização deste trabalho, foram obtidos os dados de 95 estacas do tipo hélice contínua através da dissertação intitulada “Estimativa da Capacidade de Carga de Fundações Profundas Utilizando Rede Neural Artificial” de Marcus Lessandro Costa Delazzeri, desenvolvida no programa de pós-graduação em Engenharia Civil e Ambiental da Universidade Estadual de Feira de Santana e defendida em 2018.

A Figura 5 apresenta a localização das estacas que foram utilizadas para a formação do banco de dados.

Figura 5 – Localização das provas de carga

LOCALIZAÇÃO DAS PROVAS DE CARGA QUE FORMAM O BANCO DE DADOS



Fonte: Autor, 2021

3.2 LIMPEZA E PROCESSAMENTO DA BASE DE DADOS

Ao todo foram utilizadas 95 provas de carga estática do tipo hélice contínua, geralmente o conjunto total de amostras é dividido em dois subconjuntos, que são denominados de subconjunto de treinamento e subconjunto de teste, sendo o subconjunto de treinamento variando entre 60% a 90% e o subconjunto de teste varia entre 10% a 40%.

Para o treinamento da rede do problema em questão 71 dados de prova de carga foram designados para o treinamento da rede e 24 dados de prova de carga foram designados para o teste da rede, ou seja, para treinamento foram utilizados 74,73% e para o teste foram utilizados 25,26%.

O código foi construído no ambiente NetBeans IDE 8.2 e utilizada a linguagem de programação Java. Foram feitas adaptações no código original para resolver o problema em questão.

3.3 DEFINIÇÃO DAS VARIÁVEIS DE ENTRADA E SAÍDA DA REDE

Para as variáveis de entrada dos modelos foram utilizadas as características geométricas das estacas e os resultados de ensaios de sondagem de simples percussão (SPT) conforme a Tabela 1:

Tabela 1 – Variáveis de entrada e saída da rede neural artificial

Variáveis de Entrada
Diâmetro
Comprimento
Perímetro
Área da Secção Transversal
NPAreia
NPArgila
NPSilte
NLAreia
NLArgila
NLSilte
Variáveis de Saída
Carga de Ponta
Carga de Atrito Lateral

Fonte: Autor, 2021

3.4 DEFINIÇÃO DAS ARQUITETURAS DA REDE NEURAL ARTIFICIAL

Para a realização deste trabalho foram executadas 60 configurações de redes neurais, sendo todas com uma camada oculta, variando somente o a função de ativação, número de neurônios na camada oculta e taxa de aprendizado. Foram realizados 12 experimentos com 3, 5, 7, 9 e 11 neurônios na camada oculta, conforme Tabela 2.

Tabela 2 – Configuração dos experimentos de 1 a 12

Experimentos	Número de Neurônios na Camada Oculta	Taxa de Aprendizado	Função de Ativação
1	3, 5, 7, 9, 11	0.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG
2			Camada Oculta: SIGLOG Camada de Saída: SIGLOG
3			Camada Oculta: SIGLOG Camada de Saída: LINEAR

4		0.5	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG
5			Camada Oculta: SIGLOG Camada de Saída: SIGLOG
6			Camada Oculta: SIGLOG Camada de Saída: LINEAR
7		0.9	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG
8			Camada Oculta: SIGLOG Camada de Saída: SIGLOG
9			Camada Oculta: SIGLOG Camada de Saída: LINEAR
10		1.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG
11			Camada Oculta: SIGLOG Camada de Saída: SIGLOG
12			Camada Oculta: SIGLOG Camada de Saída: LINEAR

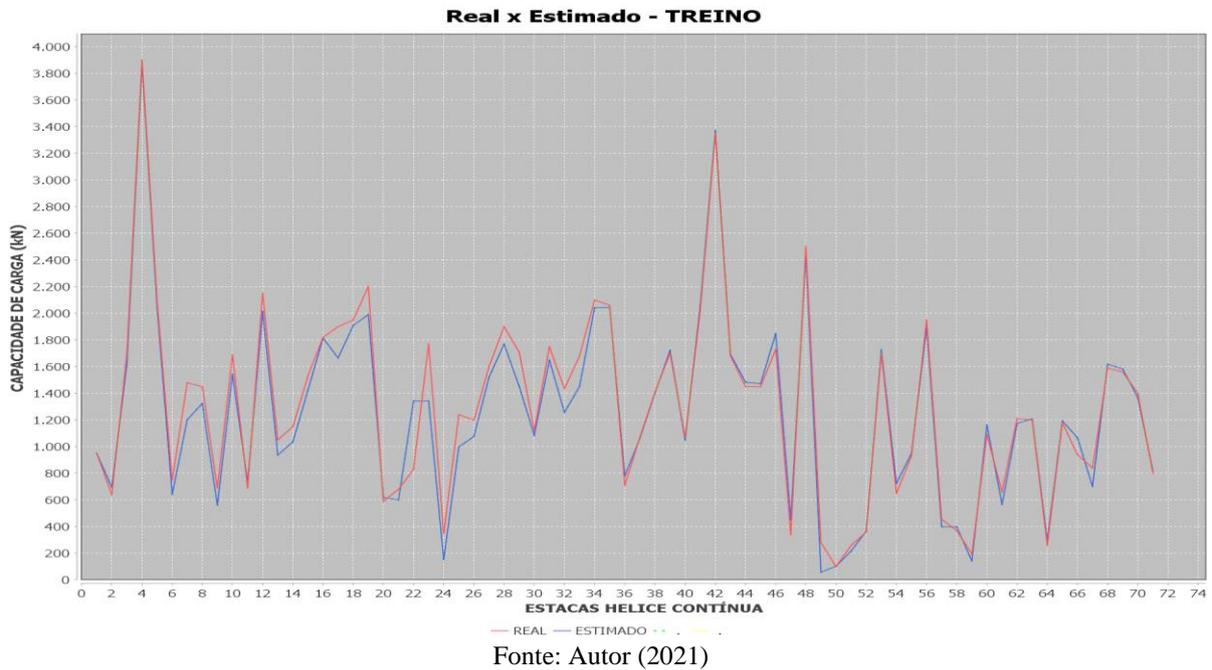
Fonte: Autor (2021)

4 RESULTADOS E DISCUSSÕES

Os resultados obtidos serão apresentados de três formas para as 60 configurações propostas. Primeiramente, será apresentado o gráfico de treinamento da melhor configuração de acordo com o erro quadrático médio. Depois, será apresentado o gráfico de teste da melhor configuração de acordo com o erro quadrático médio. E a última forma é o gráfico de evolução de erro para vinte mil épocas executadas nos experimentos.

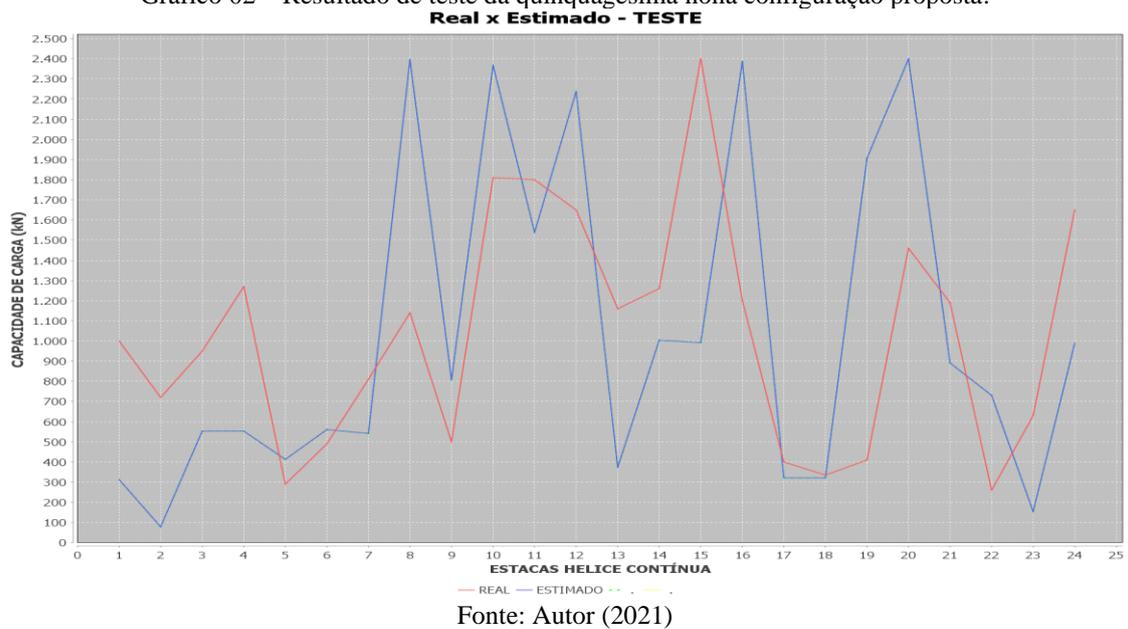
No Gráfico 01, da fase de treinamento, a linha em vermelho mostra o valor real da capacidade de carga das estacas e a linha em azul representa a capacidade de carga estimada pela RNA, onde no eixo das ordenadas está representada a capacidade de carga das estacas de treinamento e o eixo das abcissas retrata o número utilizado de estacas para o treinamento.

Gráfico 01 – Resultado de treinamento da quinquagésima nona configuração proposta



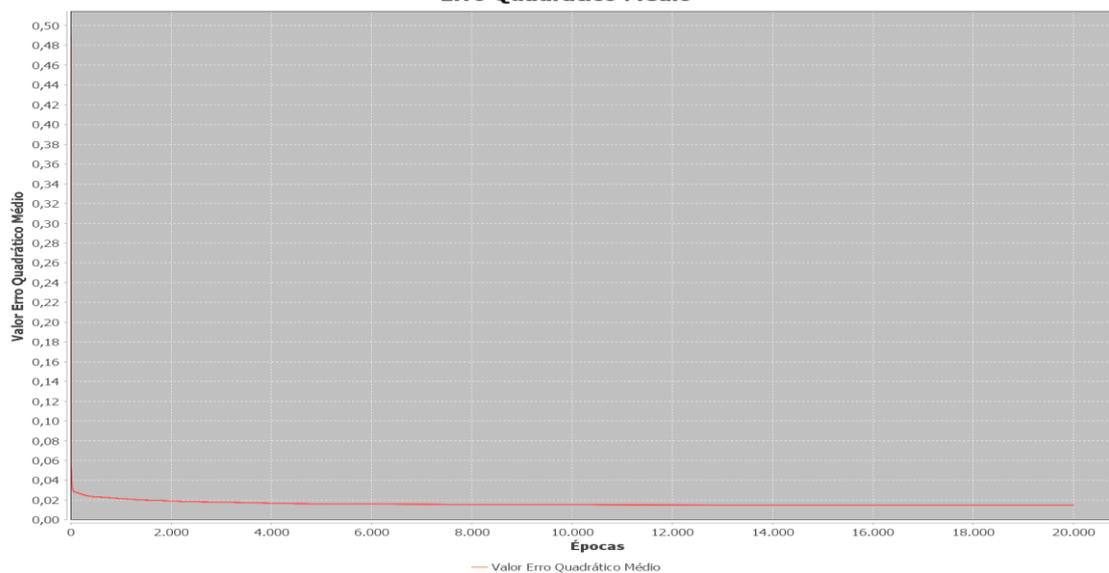
O Gráfico 02 apresenta o melhor resultado de teste da rede neural artificial, onde a linha vermelha é a capacidade de carga real das estacas e a linha em azul é a capacidade predita pela rede neural.

Gráfico 02 – Resultado de teste da quinquagésima nona configuração proposta.



No Gráfico 03, percebe-se que o erro quadrático médio tem uma redução drástica nas primeiras iterações, e após, estabiliza-se, havendo ganho pouco significativo com as iterações seguintes.

Gráfico 03 – Resultado do erro quadrático médio da quinquagésima nona configuração proposta



Fonte: Autor (2021)

Após a geração de 180 resultados com gráficos, sendo 60 de treinamento, 60 de teste e 60 de evolução do erro é possível chegar a algumas conclusões através da análise dos dados obtidos. O experimento que obteve o menor erro quadrático médio foi o de número 59, isto é, um experimento com 11 neurônios na camada oculta. Porém é notório que em alguns resultados de teste deste experimento extrapolaram bastante o seu valor real de capacidade de carga. A Tabela 5 resume os resultados dos 60 experimentos.

Tabela 5 – Resultado do erro quadrático médio dos 60 experimentos

Experimentos	Número de Neurônios na Camada Oculta	Taxa de Aprendizado	Função de Ativação	Erro Quadrático Médio
1	3	0.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02784924752037174 6
2			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02800053869032258
3			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.02860717448032708 6
4		0.5	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02819401582080369

5	5		Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02804256708234087	
6			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.03143718584785693	
7		0.9	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02878132325819308	
8			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02800551014156713 4	
9			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.03785422977742211	
10		1.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02941674200451027 7	
11			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02796688479498943 3	
12			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.04278318000638952 5	
13		5	0.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02741967125636583 8
14				Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02764543490052313
15				Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.02831151769879928 4
16			0.5	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02740024897162571 6
17	Camada Oculta: SIGLOG Camada de Saída: SIGLOG			0.02792362534518653 6	
18	Camada Oculta: SIGLOG Camada de Saída: LINEAR			0.03147715511653819	
19	0.9		Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02821693359959662	
20			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02622987517859585 7	
21			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.03808637008141917	
22	1.1		Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02836414213674415 6	
23			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02694253052541129 7	
24			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.04351588455928579 6	
25	7	0.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02256797943590115 4	
26			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02337388426877097 2	

27	9	0.5	Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.02323444303282112 5
28			Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02266670940841751 2
29		0.5	Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02070186471589663 4
30			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.02569612890741476
31		0.9	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02572237408265966
32			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02092636435681393 5
33			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.05746879019316272
34		1.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.02414258839264630 4
35			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02196194942098089 4
36			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.06325478469246786
37		0.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.0203851194816284
38			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.02089663672837988
39			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.02047450274403595
40		0.5	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01743367198303980 4
41			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01727033722869853 6
42			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.05185730818451554 6
43	0.9	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01988414788862239	
44		Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01722752976427929 4	
45		Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.03823980529792388	
46	1.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01961239961899177 7	
47		Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01790219802922515	
48		Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.06325477440536578	

49	11	0.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01579053893000092
50			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01716998972589796 3
51			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.01647395045207273
52		0.5	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01656918455146672 7
53			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01518946449190521 4
54			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.02917452615584160 6
55		0.9	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01638833188778042 8
56			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01490868646446735
57			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.05746805036035968 6
58		1.1	Camada Oculta: HYPERTAN Camada de Saída: SIGLOG	0.01593258902830695 4
59			Camada Oculta: SIGLOG Camada de Saída: SIGLOG	0.01485007372928332 1
60			Camada Oculta: SIGLOG Camada de Saída: LINEAR	0.06325477440546472

Fonte: Autor (2021)

5 CONSIDERAÇÕES FINAIS

Este trabalho utilizou redes neurais artificiais do modelo perceptron de múltiplas camadas e algoritmo backpropagation para a determinação de capacidade de carga de fundações de estaca do tipo hélice contínua no qual os modelos obtidos foram executados através de dados de prova de carga estática. Os experimentos propostos conseguiram apresentar uma boa eficiência de acordo com o aumento de número de neurônios na camada oculta, e assim se conseguiram boas previsões de capacidade de carga.

Baseando-se nos objetivos foi determinada a rede neural artificial mais eficiente, ou seja, aquela que se comportou de melhor, isto é, aquela com o menor erro quadrático médio. Ou seja, as RNAs têm potencial e podem auxiliar na tomada de decisões no que diz a respeito de capacidade de carga.

Para trabalhos futuros pode-se realizar comparação de resultados da melhor configuração da rede neural com resultados de métodos semiempíricos para capacidade do tipo hélice contínua, tais como: Aoki-Velloso, Decourt-Quaresma e Teixeira.

Pode-se, também, aumentar o número de estacas no banco de dados para deixar a rede com a acurácia ainda maior, além de realizar experimentos com mais camadas ocultas e aplicar redes neurais usando dados de ensaio de carregamento dinâmico.

Esta metodologia também ser aplicada em outras modalidades de estacas, tais como: escavadas do tipo raiz, pré-moldadas de concreto e metálicas.

REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 6122**: Projeto e execução de fundações. Rio de Janeiro: ABNT, 2019.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 6484**: Solo - Sondagem de simples reconhecimento com SPT - Método de ensaio. Rio de Janeiro: ABNT, 2020.
- Amancio, L. B. (2013). **Previsão de Recalques em Fundações Profundas Utilizando Redes Neurais Artificiais do Tipo Perceptron**. Tese apresentada ao programa de pós graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Mestre em Engenharia Civil. Área de Concentração: Geotecnia.
- Barca, M. C. S.; Silveira, T. R. S.; Magini, M. (2005). **Treinamento de Redes Neurais Artificiais: O Algoritmo Backpropagation**. In: Encontro Latino Americano de Iniciação Científica, IX., Jacareí. **Anais [...]**. Universidade do Vale do Paraíba, 2005. p. 46–49.
- Braga, A. D.; Carvalho, A. P.; Ludermir, T. B. (2007). **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LIVROS TÉCNICOS E CIENTÍFICOS EDITORA S.A, 2007.
- Castro, B. C.; Garcia. A. F.; Gondo. G. H. B.; Marques. S. F.; Sousa. M. V.; Queiroz. J. S.; Reinaldo. R. L. **Perfis geotécnicos da cidade de Palmas - TO por meio de sondagens SPT e ensaios geofísicos**. In: Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica, 18., 2016, Belo Horizonte. [...]. Belo Horizonte: ABMS, 2016.
- Cintra, J. C. A.; Aoki, N. **Fundações por estacas: Projeto Geotécnico**. São Paulo: Editora Oficina de Textos, 2010, 96p.
- Cintra, J. C. A.; Aoki, N.; Tsuha, C. H. C.; Giacheti. H. L. **Fundações: ensaios estáticos e dinâmicos**. [S.L]: Editora Oficina de Textos, 2013, 144p.
- Décourt, L.; Albiero, J. H.; Cintra, J. C. A. Análise e Projeto de Fundações Profundas. In: Hachich, W. Falconi, F. F. Saes. J. L. Frota, G. O. Carvalho, C. S. Niyama. S. **Fundações: Teoria e Prática**. 2. Ed. São Paulo: Pini, 1998. 758p.
- Delazzeri, M. L. C. (2018). **Estimativa da Capacidade de Carga de Fundações Profundas Utilizando Rede Neural Artificial**. Tese apresentada ao programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Estadual de Feira de Santana como requisito parcial à obtenção do título de Mestre em Ciências em Engenharia Civil e Ambiental.
- Falcão, H. S.; Lovato, A. V.; Santos, A. F.; Oliveira, L. S.; Maniçoba, R. H. C.; Guimarães, M. A.; Santana, M. S. Classificação de Vagas de Estacionamento com Utilização de Rede Perceptron Multicamadas. **Revista de Sistemas de Informação da FSMA**, Visconde de Araújo, v. 12, 2013, p. 41-48, 2013.
- Farias, E. L. (2018). **Redes Neurais Convulacionais e Máquinas de Aprendizado Extremo Aplicadas ao Mercado Financeiro Brasileiro**. Tese de Doutorado apresentada ao Programa

de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Civil.

Haykin, S. **Redes Neurais: Princípios e Prática**. 2. ed. Hamilton: Bookman, 2007. 898 p.
Magalhães, P. H. L. (2005). **Avaliação dos Métodos de Capacidade de Carga e Recalque de Estacas Hélice Contínua via Provas de Carga**. Tese apresentada ao programa de engenharia civil e ambiental da universidade de Brasília como requisito parcial à obtenção do título de mestre.

Melo, B. D. (2009). **Análise de provas de carga à compressão à luz do conceito de rigidez**. Tese apresentada à Universidade Estadual de Campinas para obtenção do grau de Mestre em Engenharia Civil, na área de concentração de Geotecnia.

Morais, E. C. (2010). **Reconhecimento de Padrões e Redes Neurais Artificiais em Predição de Estruturas Secundárias de Proteínas**. Tese apresentada ao programa de pós-graduação em engenharia civil da Universidade Federal do Rio de Janeiro, como requisito parcial à obtenção do título de doutor em engenharia de sistemas e computação, 2010.

Silva, I. N.; Spatti, D. H.; Flauzino, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber Editora Ltda., 2010. 399p.