



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
CAMPUS UFRJ - MACAÉ - PROF. ALOÍSIO TEIXEIRA
CURSO DE ENGENHARIA CIVIL



HUGO SANTOS DE ASSIS

**PREVISÃO DO COMPORTAMENTO DE ESTACAS HÉLICE CONTÍNUA A
PARTIR DE INTELIGÊNCIA ARTIFICIAL**

Macaé
2023

CIP - Catalogação na Publicação

A848

Assis, Hugo Santos de

Previsão do comportamento de estacas hélice contínua a partir de inteligência artificial / Hugo Santos de Assis - Macaé, 2023.

58 f.

Orientador(a): Gustavo Vaz de Mello Guimarães.

Coorientador(a): Lucas Marques Pires da Silva.

Trabalho de conclusão de curso (graduação) - Universidade Federal do Rio de Janeiro, Instituto Politécnico, Bacharel em Engenharia Civil, 2023.

1. Estaca hélice contínua. 2. Inteligência artificial. 3. Engenharia Civil.

I. Guimarães, Gustavo Vaz de Mello, orient. II. Silva, Lucas marques Pires da, coorient. III. Título.

CDD 624

Ficha catalográfica elaborada pela Biblioteca com os
dados fornecidos pelo(a) autor(a)
Biblioteca Central do Centro Multidisciplinar UFRJ-Macaé
Bibliotecário: Anderson dos Santos Guarino CRB7 – 5280

HUGO SANTOS DE ASSIS

**PREVISÃO DO COMPORTAMENTO DE ESTACAS HÉLICE CONTÍNUA A
PARTIR DE INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso de graduação submetida à Universidade Federal do Rio de Janeiro – Instituto Politécnico – UFRJ/Macaé como parte dos requisitos necessários à obtenção do grau de bacharel em Engenharia Civil.

Orientadores:

Prof. Gustavo Vaz de Mello Guimarães

Eng. Lucas Marques Pires da Silva

Macaé

2023

HUGO SANTOS DE ASSIS

**PREVISÃO DO COMPORTAMENTO DE ESTACAS HÉLICE CONTÍNUA A
PARTIR DE INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso de graduação submetida à Universidade Federal do Rio de Janeiro – Instituto Politécnico – UFRJ/Macaé como parte dos requisitos necessários à obtenção do grau de bacharel em Engenharia Civil.

Macaé, 19 de julho de 2023

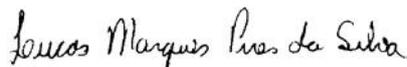
BANCA EXAMINADORA



Prof. Gustavo Vaz de Mello Guimarães, D.Sc.

(Instituto Politécnico - UFRJ/Macaé)

<http://lattes.cnpq.br/3614907040658759>



Engº Lucas Marques Pires da Silva,

(Benthic Engenharia)

<http://lattes.cnpq.br/5569347731590077>



Prof. Mauricio do Espirito Santo Andrade, D.Sc.

(Instituto Politécnico - UFRJ/Macaé)

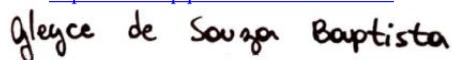
<http://lattes.cnpq.br/8604635938341817>



Profª. Gisele Silva Barbosa, D.Sc.

(Instituto Politécnico - UFRJ/Macaé)

<http://lattes.cnpq.br/0863369004606184>



Engª Gleyce de Souza Baptista,

(Benthic Engenharia)

<http://lattes.cnpq.br/9284309506959502>

Aos meus pais e às minhas irmãs, que sempre me ofereceram amor e o apoio necessário para seguir em frente.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus por me abençoar em ter pessoas tão especiais do meu lado.

Gostaria de agradecer aos meus queridos pais, Jacy e Fátima, não há palavras suficientes para expressar minha gratidão por tudo o que fizeram por mim. Vocês sempre estiveram ao meu lado, nos melhores e piores momentos, oferecendo amor, carinho, compreensão e incentivo constante. A dedicação e sacrifício de vocês para me proporcionar uma educação de qualidade são imensuráveis. Sou verdadeiramente abençoado por ter pais tão sensacionais como vocês.

Às minhas incríveis irmãs, Nathália e Maria Clara, vocês são as pessoas mais especiais da minha vida. Agradeço por sempre estarem me apoiando e me enchendo de carinho.

Aos meus colegas de curso, vocês foram essenciais na minha jornada acadêmica. Agradeço a cada um de vocês por estudarmos juntos, compartilharmos conhecimentos e enfrentarmos os desafios das aulas. Vocês tornaram as aulas mais divertidas e enriquecedoras. Em especial, gostaria de agradecer a um grande amigo que fiz dentro do curso, Gustavo Alexandre, por trazer alegria aos meus dias e por ser um parceiro de estudo tão bom e empático. Foi um prazer ter a presença de vocês comigo nas aulas, sem vocês tenho certeza de que os dias teriam sido mais monótonos e as matérias ainda mais difíceis.

Aos amigos de fora do meu curso que por alguma razão cruzaram meu caminho. Vocês trouxeram alegria para minha vida e nunca me deixaram desistir, mesmo nos momentos mais difíceis. Em especial, gostaria de expressar minha gratidão ao amigo Mateus Guimarães, que esteve ao meu lado nos últimos anos de faculdade, estando comigo em diversos momentos bons e ruins, sempre me apoiando. A amizade de todos vocês é algo inestimável.

Por fim, mas não menos importante, agradeço imensamente a todos os professores do curso de Engenharia Civil da Universidade Federal do Rio de Janeiro, em especial aos meus orientadores Lucas Marques e Gustavo Vaz de Mello. Suas orientações, conhecimentos e atenção foram essenciais para a realização deste trabalho e para o meu crescimento acadêmico em geral. Sempre pude contar com a atenção e sabedoria de vocês em todas as disciplinas, e sou grato por toda a assistência e incentivo que me proporcionaram.

*“Acredite em si mesmo. Você é mais corajoso
do que pensa, mais talentoso do que imagina
e mais capaz do que acredita.”*

(Roy T. Bennett)

RESUMO

O conceito de aprendizado de máquina vem sendo empregado largamente em diversas áreas da indústria, mas na geotecnia esse conceito ainda não é tão explorado. Essas técnicas, que inclusive são creditadas de prever o comportamento humano, também tem o potencial de prever o comportamento do solo. Porém, cabe ressaltar que para o aprendizado de máquina funcionar bem, ele deve ser “ensinado” a partir de um banco de dados confiável. Neste contexto, a partir da análise de nove provas de carga estáticas, realizadas em estacas hélice contínua em território brasileiro, empregou-se um método desenvolvido através de uma rede neural artificial (RNA) para prever as curvas “carga versus recalque” das respectivas estacas. A comparação entre o desempenho das provas de carga e os resultados da previsão pela RNA foi considerado promissor para oito das nove provas de carga.

Palavras-chave: Inteligência Artificial. Comportamento do Solo. Estaca Hélice Contínua. Curva Carga vs Recalque.

ABSTRACT

Machine learning has been widely used in several areas of industry, but in geotechnics this concept is not yet explored. These techniques, which are even credited with predicting human behavior, also have the potential to predict soil behavior. However, it should be noted that for machine learning to work well, it must be “taught” from a reliable database. In this context, from the analysis of nine static load tests, carried out on continuous auger piles in Brazilian territory, a method developed through an artificial neural network (ANN) was used to predict the “load versus settlement” curves of the respective piles. The comparison between the performance of the load tests and the prediction results by the ANN was considered promising for eight of the nine load tests.

Keywords: Artificial Intelligence. Soil Behavior. Continuous Auger Piles. Load vs Settlement Behavior.

SUMÁRIO

1. INTRODUÇÃO	1
1.1 JUSTIFICATIVA.....	1
1.2 MOTIVAÇÃO.....	1
1.3 OBJETIVOS DO TRABALHO.....	2
1.4 METODOLOGIA.....	2
1.5 ESTRUTURA.....	2
2. INTRODUÇÃO DE REDES NEURAS APLICADAS A ENGENHARIA DE FUNDAÇÕES	4
2.1 GENERALIDADES E CONCEITOS.....	4
2.2 REDES NEURAS ARTIFICIAIS.....	5
2.3 MÉTODO DA UFC (2016).....	7
2.3.1 Generalidades.....	7
2.3.2 Obtenção de dados (<i>Data mining</i>).....	7
2.3.3 Variáveis de entrada e arquitetura.....	8
2.3.4 Tratamento dos dados levantados.....	10
2.3.5 Treinamento e Validação.....	11
2.3.6 Apresentação dos resultados do modelo de UFC (2016).....	11
2.3.6.1 Modelo neural para previsão de recalques em estacas.....	11
2.3.7 Conclusão dos resultados do modelo UFC (2016).....	13
3. ESTUDO DE CASOS: APRESENTAÇÃO DO BANCO DE DADOS	15
3.1 GENERALIDADES.....	15
3.2 ALLEDI ET AL. (2006) – EH1 E EH2.....	16
3.3 MANTUANO (2014) – SA25.....	20
3.4 NETO (2002) – EHC2, EHC4 E EHC6.....	22
3.5 CORRÊA ET. AL. (2015) – ET-1 E ET-2.....	26
3.6 DUTRA (2022).....	29
4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS	32
4.1 APRESENTAÇÃO DOS RESULTADOS.....	32
4.1.1 Alledi et al. (2006) – EH1 e EH2.....	32
4.1.2 Mantuano (2014) – SA25.....	34
4.1.3 Neto (2002) – EHC2, EHC4 E EHC6.....	35
4.1.4 Corrêa et al. (2015) – ET-1 E ET-2.....	38

4.1.5 Dutra (2022) – PC002.....	40
5. CONSIDERAÇÕES FINAIS E CONCLUSÕES	42
REFERÊNCIAS BIBLIOGRÁFICAS	44

1. INTRODUÇÃO

As estacas são amplamente utilizadas como fundações profundas em obras de engenharia de grande porte. Assim, é muito importante estudar e aprimorar as rotinas que são utilizadas para projeto geotécnico destas fundações. A inteligência artificial é uma alternativa inovadora e pode ser confiável quando empregada a partir de um banco de dados bem balanceado. Destaca-se que na geotecnia, o conceito de aprendizado de máquina ainda não é tão explorado. Assim, acredita-se que seu uso, através de rede neurais artificiais, pode ser muito útil para prever o comportamento carga versus deslocamento de fundações, sendo uma alternativa promissora com potencial de corroborar aos métodos convencionais (semiempíricos) de previsão de capacidade de carga de ruptura geotécnica de estacas quando submetidas a cargas verticais de compressão.

1.1 JUSTIFICATIVA

Araújo et. al. (2015) menciona que a aplicação de redes neurais artificiais na estimativa de recalques em estacas pode ser uma alternativa aos métodos empíricos ou semiempíricos utilizados na maioria dos projetos de fundações profundas. Essa técnica pode ser utilizada para prever recalques em fundações profundas, o que pode ser útil para avaliar a capacidade de carga das fundações. Além disso, a utilização de redes neurais artificiais pode ser uma alternativa para a previsão de recalques em situações em que é difícil obter amostras indeformadas para determinação de parâmetros geotécnicos.

Portanto, este trabalho busca contribuir com essa técnica que demonstra potencial como uma ferramenta eficaz no dimensionamento e projeto de fundações, fornecendo conhecimentos valiosos para melhores tomadas de decisão na engenharia geotécnica.

1.2 MOTIVAÇÃO

A motivação para escolher esse tema foi despertada após a conclusão de duas disciplinas eletivas no curso de engenharia civil da UFRJ/Macaé, ministradas pelos professores Gustavo Vaz de Mello Guimarães e Lucas Marques Pires da Silva (Tópicos Especiais Ensaio de Laboratório e Tópicos Especiais de Fundações). Essas disciplinas proporcionaram uma conexão interessante entre inteligência artificial e a geotecnia/engenharia civil, resultando até mesmo na elaboração e publicação de um artigo nesta área de concentração.

1.3 OBJETIVOS DO TRABALHO

O objetivo principal deste trabalho foi aplicar uma metodologia (UFC, 2016) baseada em RNA para prever o comportamento carga vs recalque de estacas hélice contínua.

Como objetivos secundários deste trabalho de conclusão de curso, pode-se listar, primeiramente, introduzir conceitos gerais de inteligência artificial, aprendizado de máquina e rede neural artificial. E, secundamente, reunir um banco de dados de provas de carga estáticas em estacas hélice contínua.

1.4 METODOLOGIA

A partir de uma breve revisão bibliográfica sobre rede neural artificial apresentou-se um método para se obter a curva carga vs recalque de fundações profundas (UFC, 2016). Para se utilizar este método, foram utilizados os resultados do comportamento carga vs recalque de 9 provas de carga, provenientes de diferentes estados brasileiros. Por fim, uma comparação entre o desempenho das provas de carga e a previsão da RNA foi realizada.

1.5 ESTRUTURA

Este trabalho de conclusão de curso está dividido em cinco capítulos, distribuídos da seguinte forma: Introdução, Introdução de Redes Neurais Aplicadas à Engenharia de Fundações, Estudo de Casos: Apresentação do Banco de Dados, Apresentação e Discussão dos Resultados e Considerações Finais e Conclusões.

O primeiro capítulo abrange uma visão geral do tema, como a importância e motivação do estudo de estacas como fundações profundas, destacando o uso da inteligência artificial com redes neurais artificiais como alternativa para auxiliar em projetos geotécnicos. Também são apresentados a metodologia utilizada e os objetivos do trabalho.

O segundo capítulo apresenta uma revisão bibliográfica de conceitos para utilização de inteligência artificial, sendo realizada uma introdução a utilização de redes neurais artificiais aplicadas a engenharia de fundações. Por fim, um método desenvolvido através de RNA para previsão da curva carga vs recalque de estacas é destacado como base para essa pesquisa.

O terceiro capítulo apresenta o banco de dados composto por 9 provas de carga estáticas em estacas hélice contínua. Neste caso, forneceram-se as sondagens a percussão com medida de N_{SPT} e as curvas carga vs recalque obtidas naquelas provas de carga.

No quarto capítulo, os resultados encontrados pela inteligência artificial são apresentados e discutidos com base no desempenho das estacas quando submetidas as provas de carga.

O quinto capítulo conclui o trabalho, apresentando as considerações finais e as sugestões para futuras pesquisas.

Por fim, são listadas as referências bibliográficas utilizadas ao longo deste trabalho de conclusão de curso.

2. INTRODUÇÃO DE REDES NEURAI APLICADAS A ENGENHARIA DE FUNDAÇÕES

2.1 GENERALIDADES E CONCEITOS

Desde RIEMANN (1851), problemas com mais de três variáveis vêm se tornando comuns. Devido a limitação do entendimento humano à três dimensões, problemas multidimensionais são de difíceis soluções. Com efeito, correlacionar um valor com duas ou mais variáveis é um trabalho árduo para o ser humano.

Para solucionar tal problema, ROSENBLATT (1957) desenvolveu uma metodologia de ajuste de funções lineares de multivariáveis capaz de resolver casos binários. Essa metodologia ficou conhecida como “perceptron”.

De acordo com Dantas Neto et al. (2016), o perceptron é uma rede neural constituída por três tipos de camadas: camada de entrada, camadas intermediárias (também chamada de ocultas) e camada de saída. Uma característica desta metodologia é que a ordem de entrada dos dados no algoritmo - a fim de ajustar a função - leva a funções diferentes. Cada dado entra no ajuste da função de forma cíclica à medida que os dados vão sendo considerados (“loop”), extraíndo progressivamente as características mais significativas dos padrões de entrada.

Essa natureza do método pode ser interpretada como um aprendizado. Como esses cálculos são feitos geralmente em computadores, dá-se o nome de aprendizado de máquina (“*machine learning*”). Lembrando que o aprendizado de máquinas é uma evolução de um subcampo da inteligência artificial (IA).

O aprendizado de máquina, a inteligência artificial e as redes neurais (RN) podem ser implementadas em diversas linguagens de programação, como o “*Python*”, ou em ferramentas específicas, como o “*Microsoft Excel*” com suporte a macros e VBA (“*Visual Basic for Applications*”).

De acordo com ANGRA E AHUJA (2017), o aprendizado de máquina oferece uma alternativa mais eficiente para capturar o conhecimento em dados para melhorar gradualmente o desempenho de modelos preditivos e tomar decisões baseadas em dados.

Independentemente da plataforma escolhida, cabe esclarecer quatro conceitos básicos para a utilização do aprendizado de máquina supervisionado: (i) banco de dados; (ii) treino; (iii) teste e (iv) validação:

(i) Um banco de dados é uma coleção organizada de informações - ou dados - estruturadas, normalmente armazenadas eletronicamente em um sistema de computador. É importante observar que, sempre que possível, deve-se preferir um banco de dados bem balanceado, contendo uma ampla variedade de características em proporções significantes e semelhantes, pois dessa forma as análises provenientes terão melhor desempenho;

(ii) O treino é o procedimento que vai ensinar a plataforma que está sendo utilizada a se acostumar com padrões das classes pré-determinadas anteriormente;

(iii) O teste vai verificar se um dado pertence a uma classe ou a outra;

(iv) A validação refere-se à avaliação do desempenho de um modelo de aprendizado de máquina em um conjunto de dados diferente daquele usado para o treinamento e teste, verificando sua confiabilidade.

Silva e Guimarães (2022) e Guimarães et al. (2022) lembram que os dados que são utilizados para teste não podem ter participado da fase de treino. Naturalmente, esse procedimento visa não gerar um viés na hora de analisar os dados gerados pelo aprendizado de máquina, inteligência artificial ou rede neural.

2.2 REDES NEURAIS ARTIFICIAIS

Rede neural artificial (RNA) são processadores maciçamente paralelos distribuídos e constituídos de unidades de processamento simples, que têm a capacidade natural para armazenar conhecimento experimental e torná-lo disponível para o uso (Adaptado de Dantas Neto, 2004).

Segundo Araújo et al. (2015), o desenvolvimento das redes neurais artificiais foi motivado pela grande capacidade do cérebro humano aprender e realizar tarefas extremamente complexas após passar por algum processo de aprendizagem.

Nesse contexto, pode-se dizer que uma RNA é um modelo computacional inspirado pelo funcionamento do cérebro humano, sendo composta por um conjunto interconectado de unidades de processamento chamadas de neurônios artificiais ou nodos.

O funcionamento de uma rede neural é baseado no conceito de aprendizado por meio do ajuste dos pesos sinápticos entre os neurônios. Cada neurônio artificial recebe um ou mais sinais de entrada, realiza o processamento desses sinais e produz uma saída. Esses sinais de entrada são multiplicados por pesos sinápticos correspondentes, que representam a força ou a importância da conexão entre os neurônios.

A rede neural é organizada em camadas, sendo a camada de entrada a primeira e a camada de saída a última. Entre essas camadas, podem existir camadas intermediárias,

chamadas de camadas ocultas, que realizam o processamento e a transformação dos sinais de entrada antes de serem enviados para a próxima camada. Nesse complexo sistema, cada neurônio em uma camada é conectado a todos os neurônios da camada seguinte por meio de conexões sinápticas (associadas aos pesos sinápticos).

Alguns tipos de inteligência artificial devem ser previamente treinados. Assim, durante a fase de treinamento da rede neural, os pesos sinápticos são ajustados de forma a minimizar o erro entre as saídas produzidas pela RNA e as saídas desejadas, com base em um conjunto do banco de dados reservado para a fase de treinamento. Ou seja, na fase de treino, os pesos sinápticos são ajustados de modo a minimizar uma função de custo, que mede a discrepância entre as saídas da RNA e as saídas desejadas, ou em outras palavras, a divergência entre o resultado obtido pela rede neural e o resultado ideal que ela deveria produzir.

Vale destacar que o ajuste dos pesos sinápticos é realizado por meio de algoritmos de aprendizado, como por exemplo, “*backpropagation*”, que utiliza técnicas de otimização para atualizar os pesos de forma iterativa.

Uma vez treinada, a rede neural é capaz de realizar tarefas de reconhecimento de padrões, classificação, regressão, entre outras. Durante a fase de teste, os dados de entrada são apresentados à rede, que produz saídas correspondentes com base nos padrões aprendidos durante o treinamento.

É importante ressaltar que o desempenho de uma rede neural depende de vários fatores, como a arquitetura da rede, o número de camadas e neurônios, a função de ativação utilizada pelos neurônios, o algoritmo de aprendizado empregado e o conjunto de dados de treinamento.

Um neurônio artificial funciona de forma semelhante ao neurônio biológico. De acordo com Haykin (2001), um neurônio é uma unidade fundamental de processamento de informações em uma rede neural.

A Figura 2.1 ilustra a representação a ilustração de um neurônio biológico e um neurônio artificial, segundo Araújo (2013).

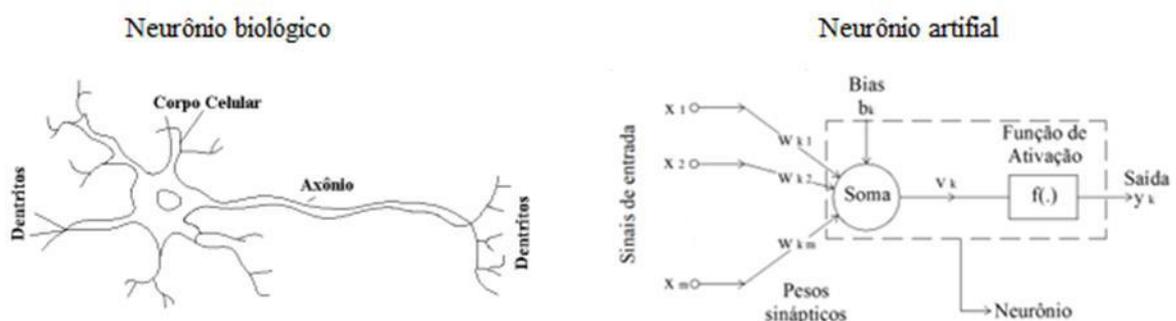


Figura 2.1- Esquema de um neurônio biológico e um neurônio artificial, adaptado de Araújo (2013)

2.3 MÉTODO DA UFC (2016)

2.3.1 Generalidades

O método da UFC (2016) é um modelo de previsão de recalques em estacas utilizando rede neural artificial do tipo perceptron. Naturalmente, a partir da relação entre carga e recalque, é possível obter a capacidade de carga a ruptura geotécnica dessas estacas.

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

As principais etapas do desenvolvimento desse modelo da UFC (2016) foram: (i) levantamento e coleta dos dados; (ii) definição das variáveis do modelo neural; (iii) tratamento dos dados levantados; e (iv) treinamento e validação do modelo.

Recentemente, as pesquisas que utilizam redes neurais artificiais vêm buscando cada vez aumentar o foco em um procedimento chamado alinhamento. Destaca-se que na ocasião do desenvolvimento do método da UFC (2016) este procedimento ainda não era corriqueiro quando da utilização de redes neurais artificiais.

2.3.2 Obtenção de dados (*Data mining*)

Para desenvolver o modelo da UFC (2016), foram utilizados dados provenientes de sondagens à percussão com medida de N_{SPT} e provas de carga estáticas de um conjunto de 199 estacas. Foram obtidos de 3 bancos de dados: Amâncio (2013), Silveira (2014) e Dantas Neto et al. (2014).

De acordo com Amâncio (2013), algumas das provas de carga estáticas foram realizadas com propósitos exclusivamente acadêmicos, enquanto outros ensaios foram conduzidos para acompanhar o comportamento das fundações projetadas. Em relação a essas provas de carga, não havia informações disponíveis sobre a forma de execução específica (lenta, rápida ou mista). O conjunto de dados utilizado para o modelo consiste em 1.320 exemplos do tipo entrada-saída, onde cada entrada corresponde a um incremento de carga e seu respectivo valor de recalque obtido. Vale destacar que não é gerado a mesma quantidade de entrada e saída de dados para todas as estacas, naturalmente, isso varia para cada caso.

Todos as provas de carga utilizadas para a elaboração do método da UFC (2016) foram executadas em território brasileiro. A Figura 2.2 mostra a distribuição por região das localizações das estacas.

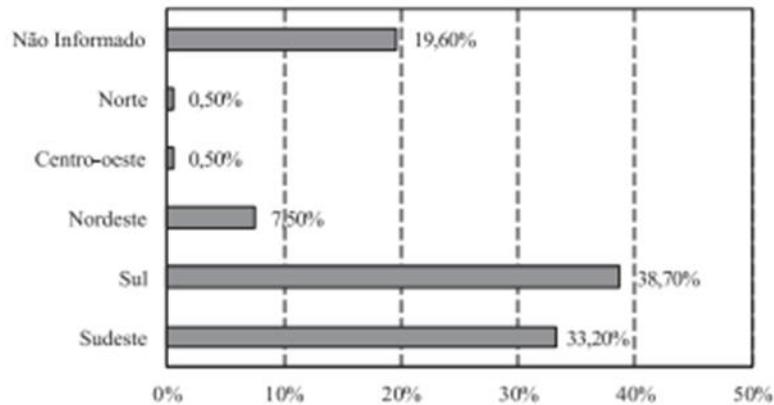


Figura 2.2 – Distribuição regional das provas de cargas - Dantas et al (2016)

De acordo com Dantas Neto et al. (2016), a grande distribuição espacial no território brasileiro das estacas utilizadas para o desenvolvimento do método da UFC (2016) indica a boa representatividade do modelo, pois os dados utilizados contemplam condições geológico-geotécnicas variadas, como aquelas observadas nas diferentes regiões constituintes do território brasileiro.

2.3.3 Variáveis de entrada e arquitetura

Considerando as variáveis que influenciam os recalques nas fundações profundas, tipo de estaca, informações levantadas nas provas de carga estáticas e ensaios de sondagem a percussão com medida de N_{SPT} , o método da UFC (2016) para previsão de recalques em estacas pode ser representado, de uma forma geral, pela seguinte expressão da Equação 2.1:

$$\rho = f(T, L, D, NF, NP, d, Arg, Sil, Are, P) \quad (2.1)$$

Onde:

ρ – recalque total, em milímetros ($\rho_e + \rho_s$);

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

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

T – tipo de estaca (hélice contínua, cravada metálica e escavada);

L – comprimento da estaca, em metros;

D – diâmetro da estaca, em metros;

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

NP^1 – valor do N_{SPT} na profundidade de assentamento da ponta da estaca;

d – distância da ponta da estaca até o impenetrável;

Arg, Sil, Are – fatores que levam em conta o tipo de solo no qual a estaca está executada (argila, silte e areia);

P – carga vertical aplicada, em kN;

A Tabela 2.1 apresenta os valores de entrada para a variável T do modelo neural de previsão de recalques em estacas de UFC (2016).

Tabela 2.1 – Valores adotados para variável T do modelo de UFC (2016)

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

A Figura 2.3 apresenta um esquema de uma estaca (tipo T) enterrada com uma determinada profundidade (L) em solo estratificado (siltoso, arenoso e argiloso) e distando (d) da camada considerada impenetrável a percussão. Além disso é possível identificar a parcela do recalque atribuída ao deslocamento elástico do elemento estrutural da estaca (ρ_e) e a parcela do recalque atribuída ao mecanismo de transferência de carga entre a estaca e o solo (ρ_s).

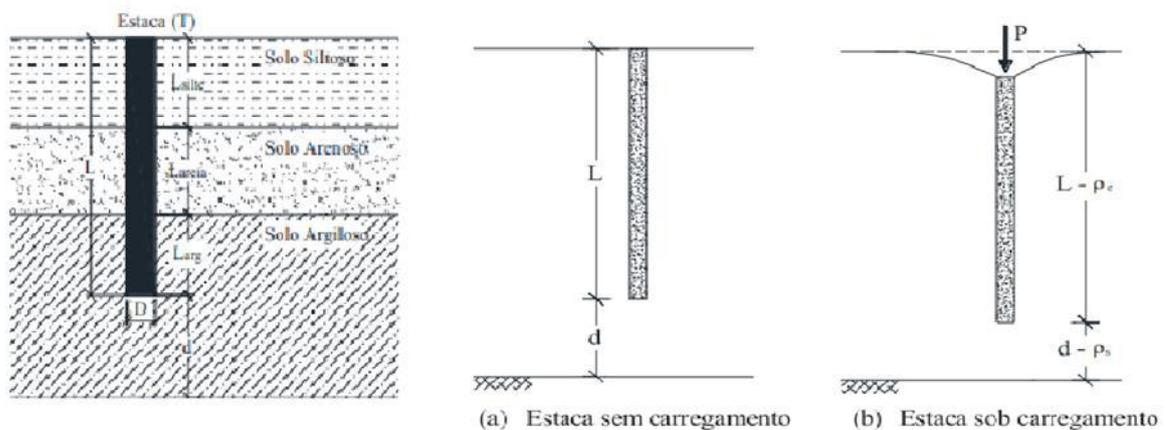


Figura 2.3 - Condições de contorno (Dantas Neto et al, 2016) e adaptado de Cintra e Aoki (2010)

¹ Salienta-se que o valor máximo adotado para N_{SPT} deve ser de 40 golpes/30cm, ou seja, caso a sondagem apresente valores superiores, deverá ser utilizado N_{SPT} igual a 40 golpes.

A Tabela 2.2 fornece um resumo dos valores máximos e mínimos utilizados para a elaboração do método da UFC (2016).

Tabela 2.2 – Valores máximos e mínimos utilizados na RNA, adaptado de Dantas Neto et al (2016)

Variável	Tipo	Aquisição	Mínimo	Máximo
Tipo da estaca – T	Entrada	Prova de carga estática	1	3
Comprimento – L (m)			3	60
Diâmetro – D (m)			0,08	1,7
Soma do N _{SPT} ao longo do fuste – NF			6	990
N _{SPT} na ponta da estaca até o impenetrável		2	40	
Distância da ponta da estaca até o impenetrável – d (m)		Sondagem à percussão	0	4
Percentual de argila do perfil – Arg (m/m)			0%	100%
Percentual de silte do perfil – Sil (m/m)			0%	100%
Percentual de areia do perfil – Ar (m/m)			0%	100%
Carga – P (kN)				0
Recalque – ρ (mm)	Saída	Prova de carga estática	0	189,4

2.3.4 Tratamento dos dados levantados

A partir das informações necessárias para o desenvolvimento do modelo neural para previsão dos recalques em estacas, e definidas as variáveis de entrada do modelo, foi necessário a escolha do algoritmo de treinamento, o qual permitiu utilizar os dados disponíveis a respeito do fenômeno estudado na alteração dos pesos sinápticos da RNA.

No método da UFC (2016) foi utilizado o algoritmo de retropropagação do erro desenvolvido por Rumelhart et al. (1986) para a alteração dos pesos sinápticos dos perceptrons multicamadas utilizadas para o desenvolvimento do modelo de previsão dos recalques em estacas.

Na elaboração do método optou-se pela normalização tanto da variável de saída (recalque), como das variáveis de entrada (T, L, D, NF, NP, d, Arg, Sil, Are, P). A normalização das variáveis de entrada e de saída foi realizada considerando uma relação linear entre os valores máximos ($x_{máx}$), mínimos ($x_{mín}$) e a variável normalizada (x_{nor}), a partir da Equação 2.2 a seguir:

$$\frac{x_{nor} - 0,5}{0,85 - 0,15} = \frac{x - x_{mín}}{x_{máx} - x_{mín}} \quad (2.2)$$

2.3.5 Treinamento e Validação

A modelagem com redes neurais artificiais ocorre em duas etapas: treinamento e validação. A rede neural bem treinada é capaz de generalizar o conhecimento adquirido durante o treinamento e fornecer respostas satisfatórias para estímulos não vistos antes.

No treinamento, os pesos sinápticos foram ajustados utilizando a Regra Delta Generalizada e o Algoritmo de Retropropagação do Erro, utilizando 80% dos exemplos de entrada e saída escolhidos aleatoriamente do conjunto de dados disponível. Os valores adotados no método da UFC (2016) foram os mesmos que os utilizados em trabalhos como Dantas Neto (2004), Amâncio (2013) e Dantas Neto et al. (2014) que garantem uma convergência satisfatória do algoritmo de treinamento utilizado.

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

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

$$C(\rho_{cal}, \rho_m) = \frac{Cov(\rho_{cal}, \rho_m)}{\sigma(\rho_{cal}) \cdot \sigma(\rho_m)} \quad (2.3)$$

Onde:

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

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

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

2.3.6 Apresentação dos resultados do modelo de UFC (2016)

2.3.6.1 Modelo neural para previsão de recalques em estacas

O desenvolvimento do modelo consistiu na definição da arquitetura para a qual a rede neural artificial apresentasse o melhor desempenho, dado pelo coeficiente de correlação entre

os recalques medidos existentes no conjunto de validação e os recalques calculados pelo modelo para as variáveis de entrada correspondentes.

A arquitetura do modelo neural que, dentre todos os testados, forneceu o melhor desempenho na fase de validação está apresentada na Figura 2.4.

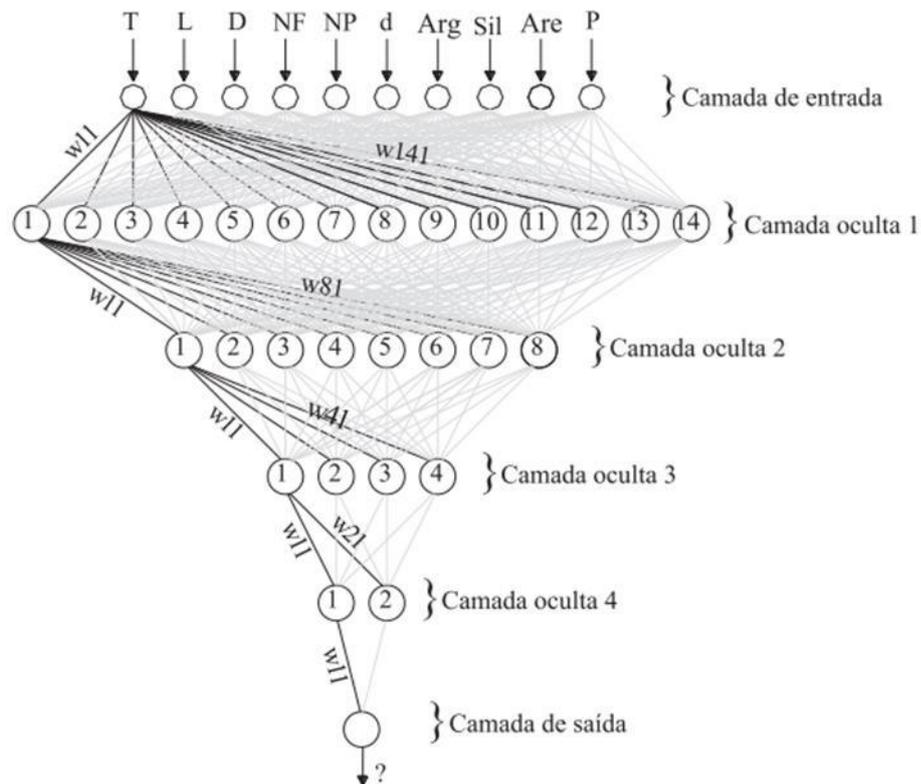


Figura 2.4 - Arquitetura escolhida após 3×10^6 iterações, de acordo com Dantas Neto et al (2016)

Assim, o modelo neural foi composto por 10 nós na camada de entrada; quatro camadas ocultas com 14, 8, 4 e 2 neurônios; e 1 neurônio na camada de saída que representa o valor normalizado para o recalque.

Para o modelo neural desenvolvido para previsão de recalques em estacas, o coeficiente de correlação (R^2) obtido nas fases de treinamento e validação foi de 0,94. Essa concordância entre as curvas de treinamento e validação indica que o subconjunto de dados utilizados para validar o modelo (fase de validação) apresentou a mesma variabilidade que aquela existente nos dados utilizados para o ajuste dos pesos sinápticos (fase de treinamento), indicando que o modelo apresenta uma representatividade satisfatória e boa capacidade de generalização do conhecimento adquirido durante o processo de aprendizagem/treinamento.

Na ocasião, analisando os resultados obtidos com o modelo neural utilizando os dados disponíveis no conjunto usado para validação, notou-se a necessidade de alterar a Equação 2.1,

incluindo um fator de correção $\Delta\rho_0$, resultando na nova expressão representada pela Equação 2.4.

$$\rho = f(T, L, D, NF, NP, d, Arg, Sil, Are, P) + \Delta\rho_0 \quad (2.4)$$

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

A implementação do modelo neural para previsão de recalques em estacas hélice contínua, escavada e metálica pode ser feita a partir do procedimento a seguir e ser usado para a definição de todos os pontos da curva carga vs recalque.

- a) Obtenção dos resultados da sondagem com medida de N_{SPT} realizado no subsolo onde será executada à estaca (definições dos valores de NF , NP , Arg , Sil , Are e d);
- b) Definição da geometria da estaca e tipo (D , L e T);
- c) Adotar $P = 0$ para a definição do valor do fator de correção $\Delta\rho_0$;
- d) Normalização dos valores das variáveis de entrada (T , L , NF , NP , d , Arg , Sil , Are e P) utilizando a Equação 2.2 e os valores apresentados na Tabela 2.2;
- e) Cálculo dos pesos sinápticos dos neurônios do modelo desde a primeira camada intermediária até a camada de saída;
- f) Transformação do valor calculado para o recalque na escala de normalização utilizada para a sua escala real, utilizando a Equação 2.2 e os valores máximos e mínimos para o recalque apresentados na Tabela 2.2;
- g) O valor obtido para o recalque considerando a carga P igual a zero, deve ser adotado como o fator de correção $\Delta\rho_0$;
- h) Repetir os passos entre os itens “a” e “f” para o cálculo do valor do recalque para qualquer valor da carga P diferente de zero, aplicando-se, posteriormente, o fator de correção obtido no item “g”.

2.3.7 Conclusão dos resultados do modelo UFC (2016)

De uma forma geral, pode-se considerar que o modelo desenvolvido com o uso das redes neurais artificiais do tipo perceptron para previsão de recalques em estacas do tipo hélice

contínua, escavadas e metálicas apresenta uma ótima performance, e pode, portanto, ser utilizado na prática da Engenharia de Fundações. Da forma como o modelo opera, pode-se inclusive obter capacidade de carga da estaca, a partir do conhecimento completo da curva carga vs recalque do sistema solo-estaca.

3. ESTUDO DE CASOS: APRESENTAÇÃO DO BANCO DE DADOS

3.1 GENERALIDADES

O estudo de caso foi realizado com base em banco de dados de nove provas de cargas estáticas realizadas em território brasileiro. Todas as estacas eram do tipo hélice contínua. Destaca-se que todas essas provas de cargas nestas estacas foram analisadas por métodos semiempíricos por Beraldo (2022). A Figura 3.1 mostra a distribuição por estados/cidades das localizações das estacas ensaiadas que foram analisadas neste trabalho.

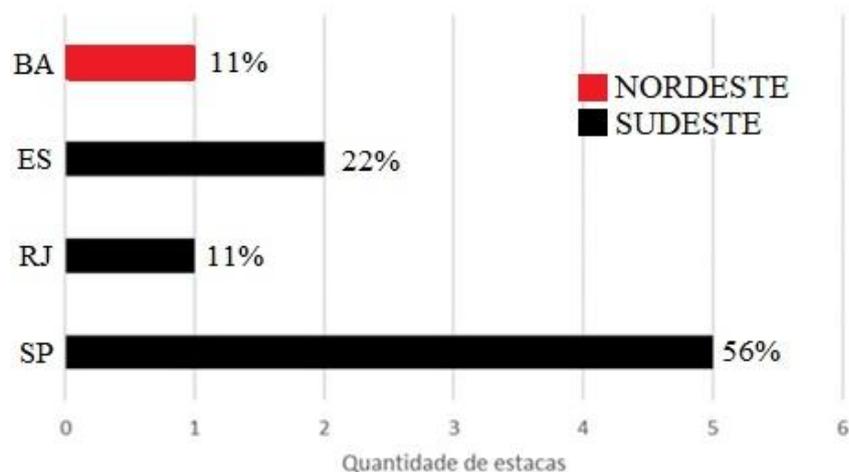


Figura 3.1 – Locais de realização das provas de cargas analisadas neste trabalho

Em princípio, é importante destacar que aparentemente a quantidade de informações do banco de dados utilizado para treinar o modelo da UFC (2016) - 199 estacas - parece ser relativamente pequena para utilização de uma inteligência artificial. Apesar de não existir um número exato, é possível estimar a quantidade de dados para um modelo generalizar de modo eficiente, através de métricas conhecidas, como por exemplo, precisão, recall e F1-Score. Através destes indicadores, o modelo vai sendo executado à medida que se acrescentam dados. Assim, novos resultados são gerados, até obter uma boa convergência, sendo este valor adotado como ideal.

Vale destacar que resultados de provas de carga estáticas em estacas reais (verdadeira grandeza) não se encontram tão facilmente. Este fato decorre, na prática da engenharia de fundações, do alto custo para realização de uma prova de carga estática. Muitas provas de carga são realizadas para fins de pesquisa e pouquíssimas provas de carga estáticas são executadas

em estacas de obras reais. Por outro lado, destaca-se que as tradicionais metodologias semiempíricas para estimativa de capacidade de carga geotécnica de fundações profundas muitas vezes foram desenvolvidas com um banco de dados semelhante, ou até menor que este banco de dados apresentado neste trabalho, como por exemplo o método de Aoki e Veloso (1975), que utilizou um banco de dados composto por 63 provas de carga.

3.2 ALLEDI ET AL. (2006) – EH1 E EH2

Alledi et al. (2006) apresenta duas provas de carga em estacas hélice contínua instrumentadas (EH1 e EH2). A área experimental fica na faixa costeira de Vitória, no Espírito Santo, e possui um perfil geotécnico composto por solos sedimentares do período quaternário.

A Figura 3.2 apresenta o perfil geotécnico realizado através de uma vertical de sondagem com medida de N_{SPT} na região em que a estaca hélice contínua EH1 foi instalada. Destaca-se que a EH1 tinha as seguintes características: 40 centímetros de diâmetro e 8,0 metros de comprimento.

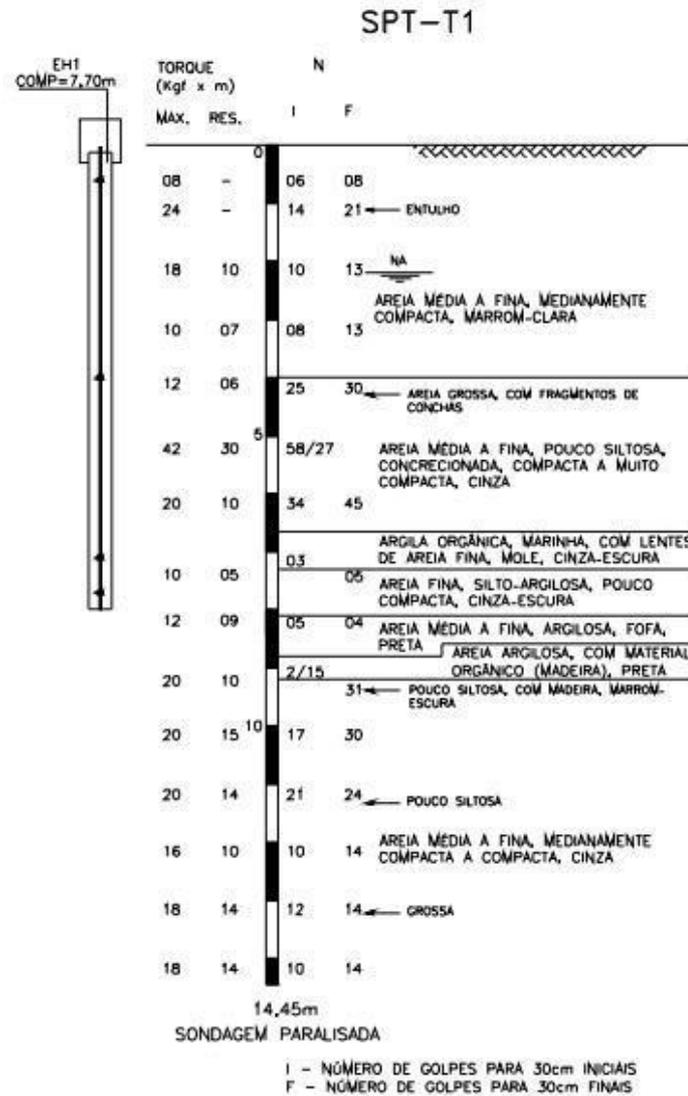


Figura 3.2 - Perfil geotécnico da sondagem SPT - EH1

A Figura 3.3 mostra a curva carga vs recalque da prova de carga realizada na estaca EH1. A estaca foi submetida a uma prova de carga lenta e uma prova de carga rápida. O valor máximo da carga atingida na prova de carga foi da ordem de 700 kN.

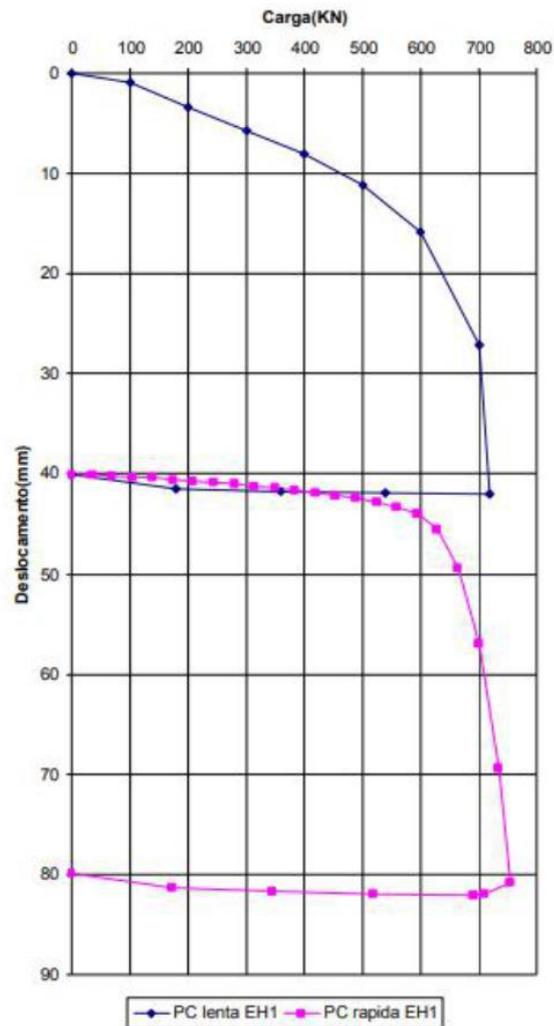


Figura 3.3 - Curva Carga x Deslocamento - EH1

A Figura 3.4 apresenta o perfil geotécnico realizado através de outra vertical de sondagem, também com medida de N_{SPT} , na região em que a estaca hélice contínua EH2 foi instalada. A estaca, EH2, tinha 0,40 metros de diâmetro e 12,0 metros de comprimento.

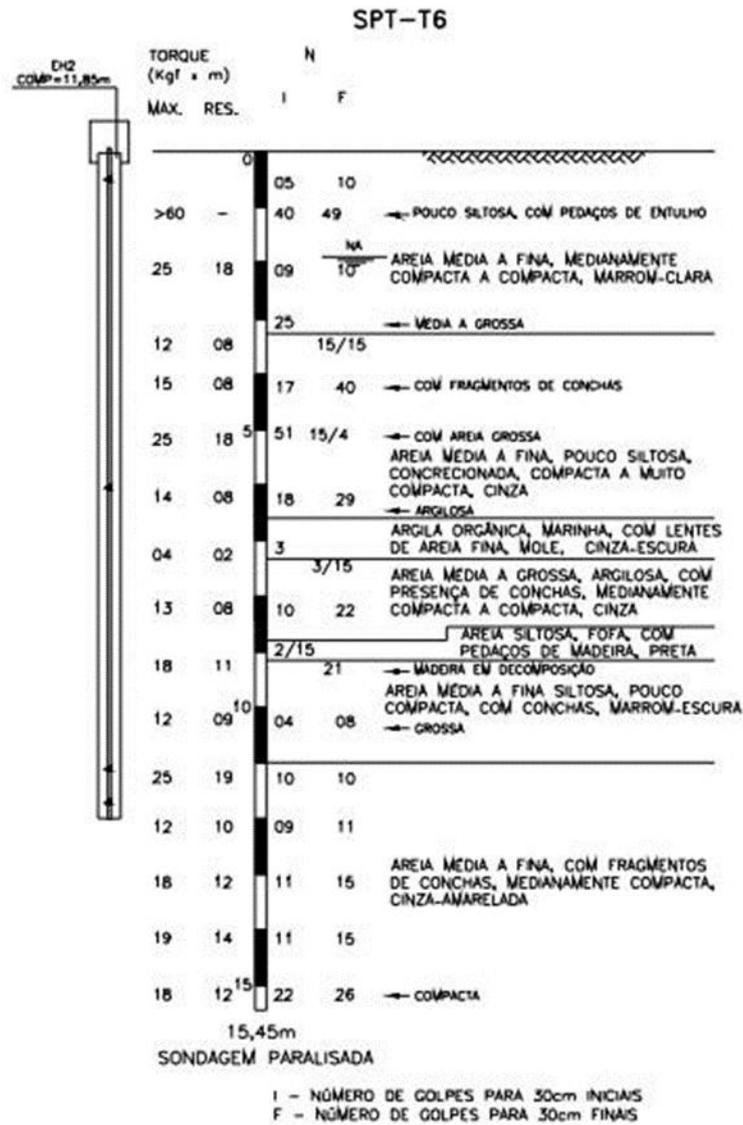


Figura 3.4 -. Perfil geotécnico da sondagem SPT – EH2

A Figura 3.5 apresenta a curva carga vs recalque da prova de carga realizada na estaca EH2. A estaca também foi submetida a uma prova de carga lenta (nesse caso com um descarregamento) e uma prova de carga rápida. O valor máximo da carga alcançada na prova de carga foi da ordem de 1100 kN.

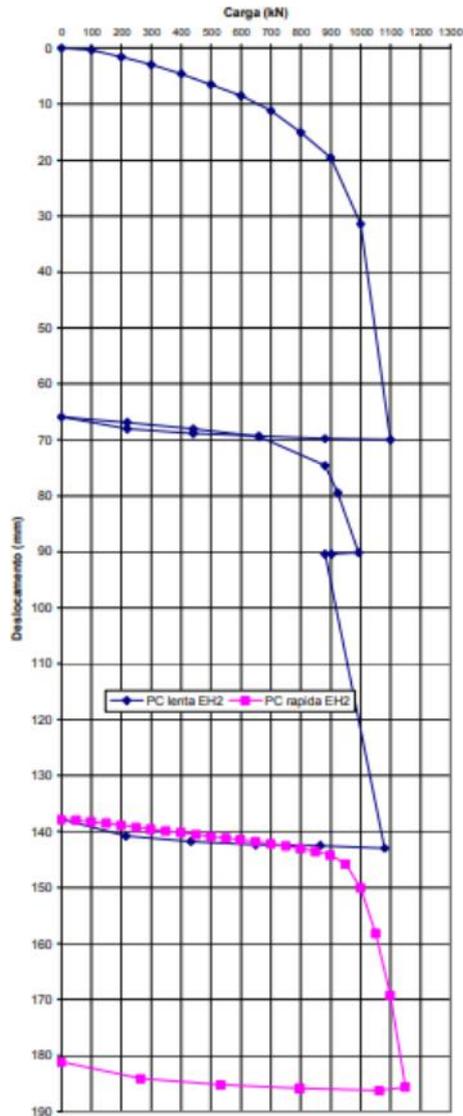


Figura 3.5 - Curva Carga x Deslocamento - EH2

3.3 MANTUANO (2014) – SA25

O trabalho de Mantuano (2014) apresenta uma estaca hélice contínua com as seguintes características: diâmetro de 0,5 metros e comprimento de 22 metros.

A Figura 3.6 apresenta a vertical de sondagem com medida de N_{SPT} próximo ao local de instalação da estaca.

SA25
 COMP=22,0m

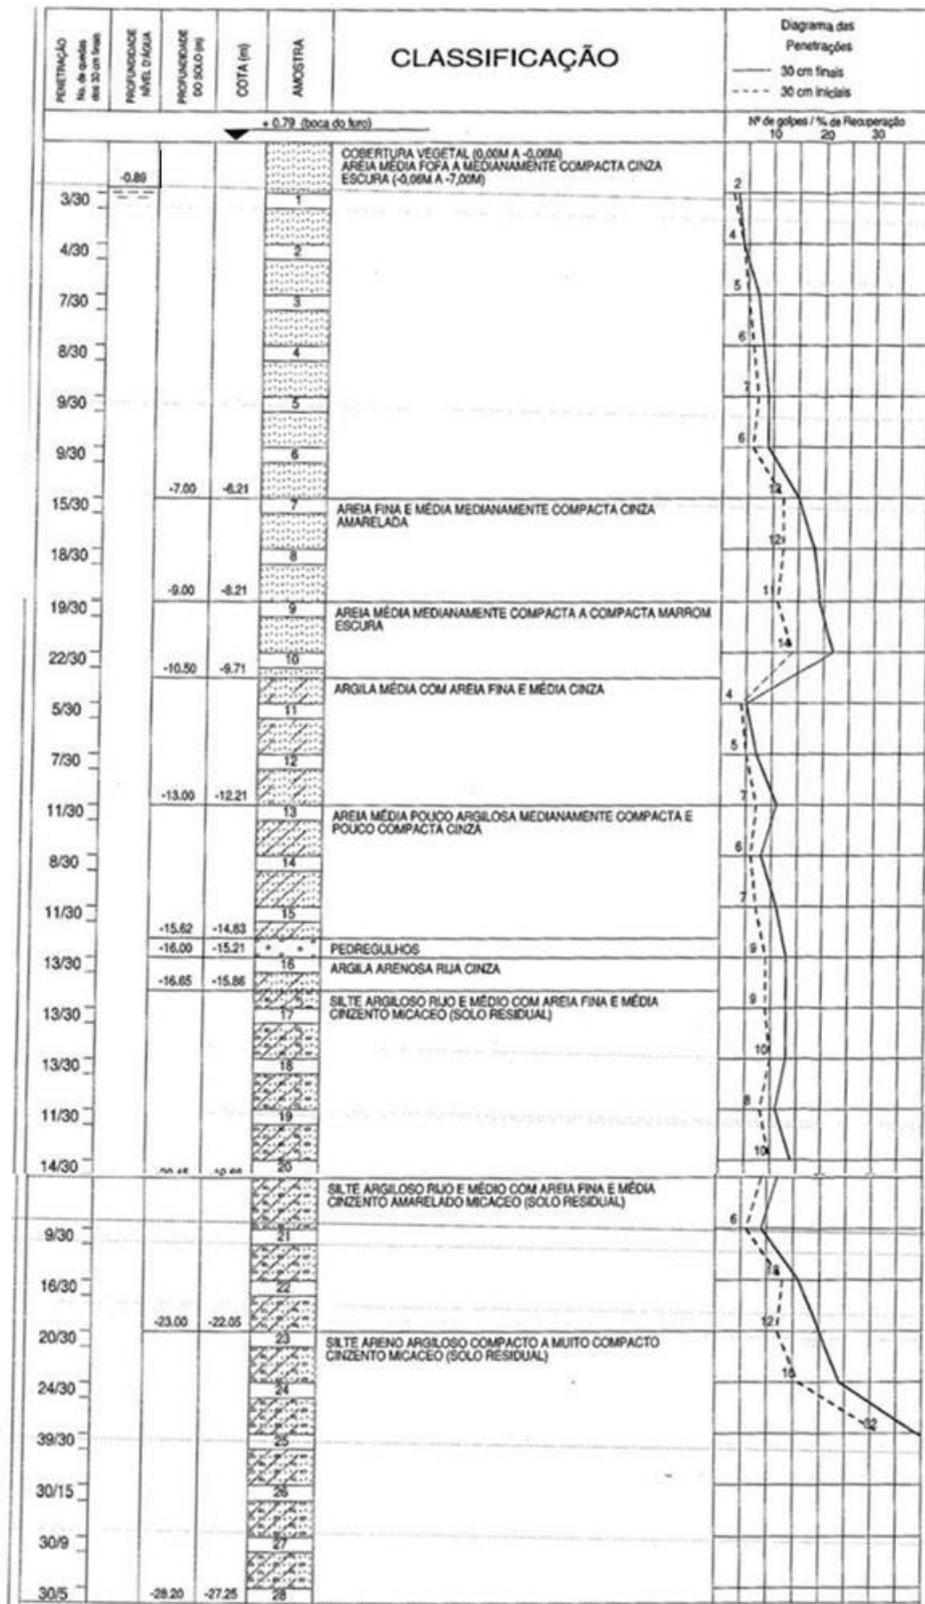


Figura 3.6 - Perfil geotécnico da sondagem SPT - SA25

A curva carga vs recalque desta prova de carga está apresentada na Figura 3.7. O valor atingido de carga máxima foi da ordem de 2900 kN.

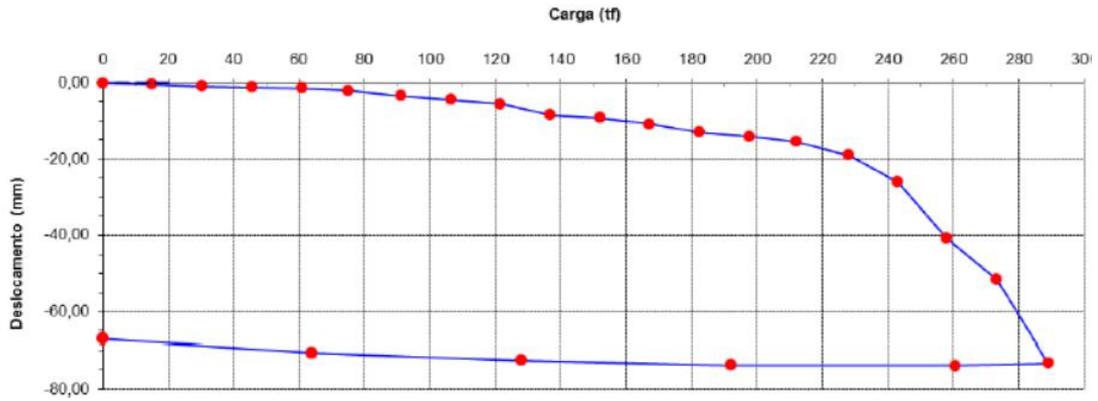


Figura 3.7 - Curva Carga x Deslocamento - SA25

3.4 NETO (2002) – EHC2, EHC4 E EHC6

No estudo realizado por Neto (2002), foram realizadas três provas de carga em estacas do tipo hélice contínua no centro de São Paulo.

Na Figura 3.8 é apresentado o perfil geotécnico (sondagem a percussão com medida de NSPT) em local próximo onde a estaca EHC2 foi instalada. A estaca EHC2, possuía diâmetro de 0,40 metros e comprimento de 10,8 metros.

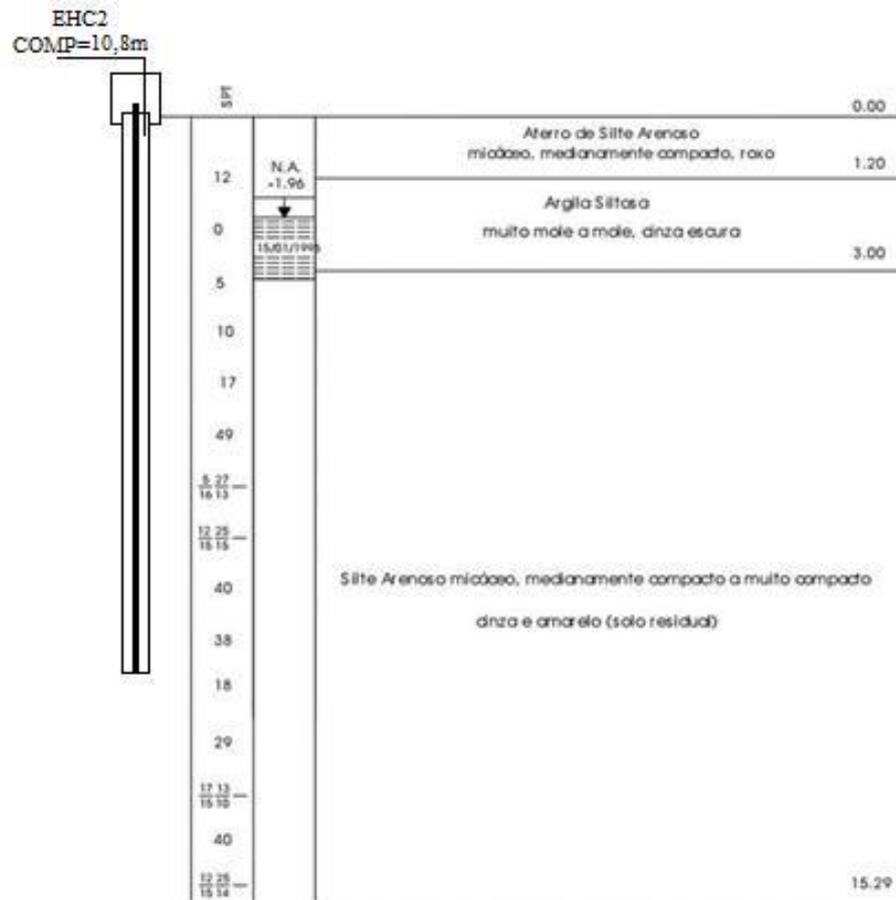


Figura 3.8 - Perfil geotécnico da sondagem SPT - EHC2

A Figura 3.9 exibe a curva carga vs recalque da prova de carga realizada na estaca EHC2.

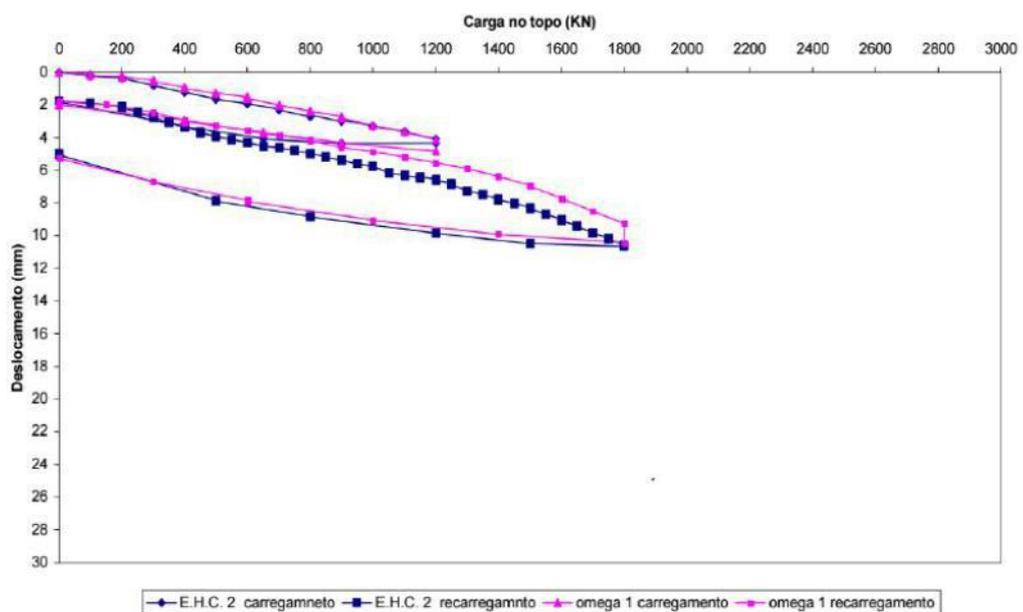


Figura 3.9 - Curva Carga x Deslocamento - EHC2

A Figura 3.10 exibe o perfil geotécnico realizado através de uma vertical de sondagem com medida de N_{SPT} na área em que a estaca EHC4 foi executada. A estaca EHC4 possuía diâmetro de 0,40 metros e comprimento de 17,5 metros.

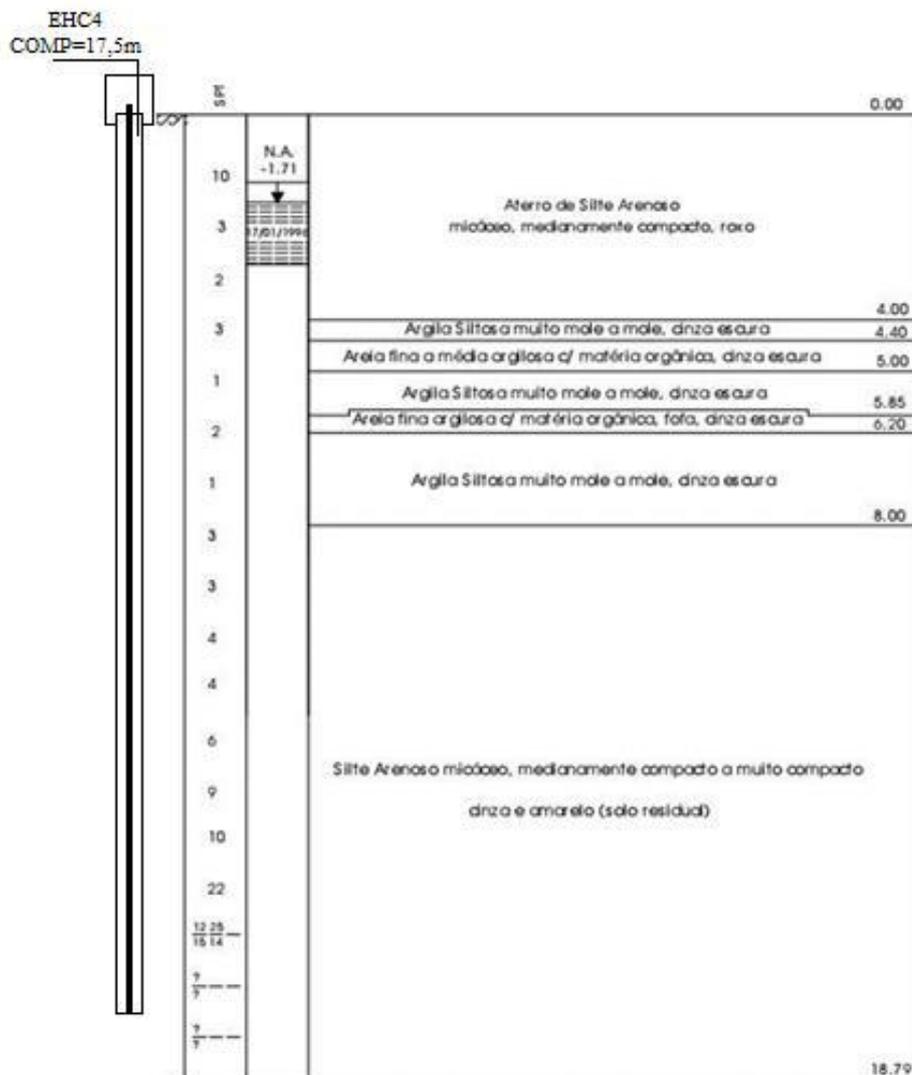


Figura 3.10 - Perfil geotécnico da sondagem SPT - EHC4

Na Figura 3.11 mostra a curva carga vs deslocamento da prova de carga realizada na estaca EHC4.

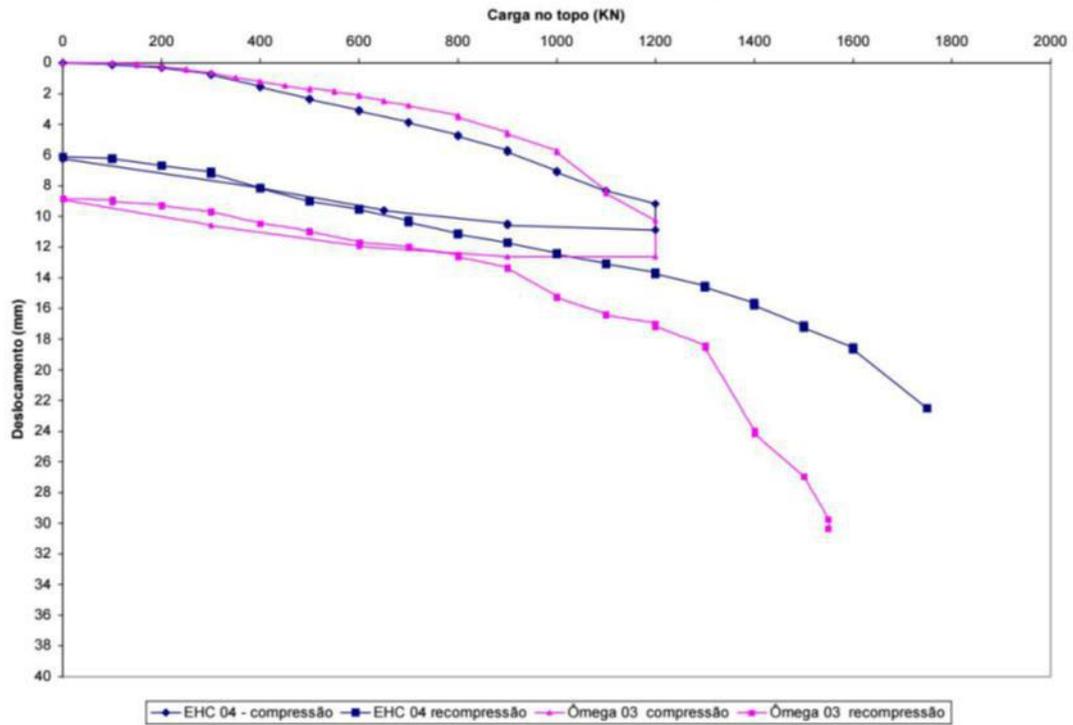


Figura 3.11 -. Curva Carga x Deslocamento - EHC4

A próxima Figura 3.12 mostra o perfil geotécnico onde a estaca EHC6 foi executada. Destaca-se que a estaca EHC6, tinha um diâmetro de 0,40 metros e comprimento de 12 metros.

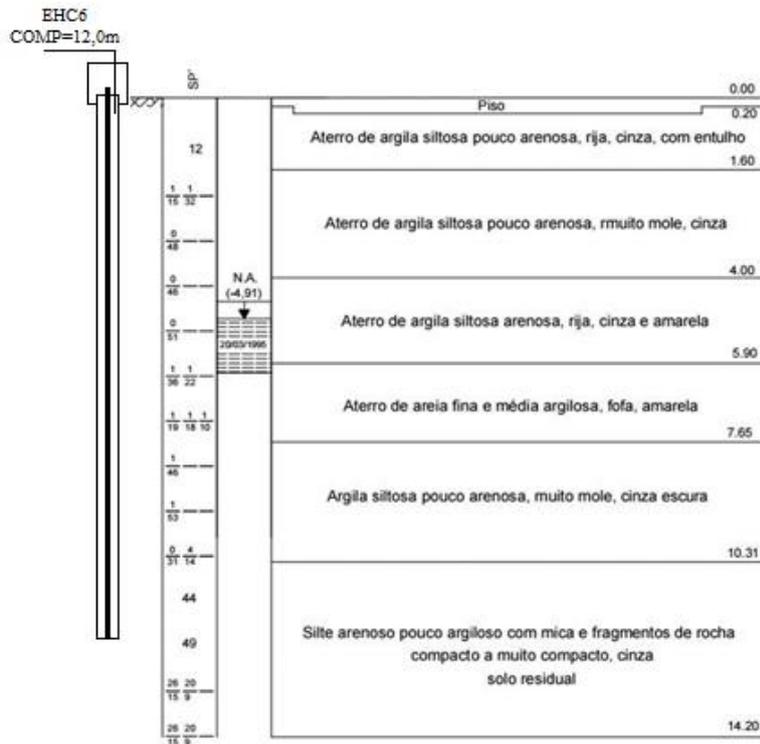


Figura 3.12 - Perfil geotécnico da sondagem SPT - EHC6

A Figura 3.13 exibe a curva carga vs recalque da prova de carga realizada na estaca EHC6. A carga máxima atingida na prova de carga foi da ordem de 1750 kN.

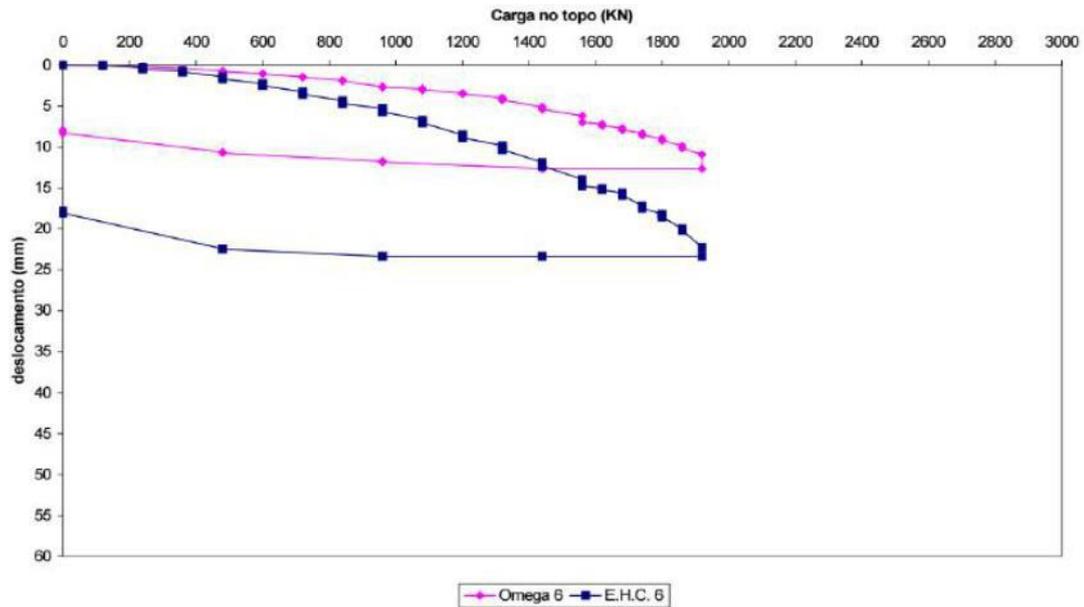


Figura 3.13 - Curva Carga x Deslocamento - EHC6

3.5 CORRÊA ET. AL. (2015) – ET-1 E ET-2

No estudo conduzido por Corrêa et. al. (2015), foram realizadas a instalação de estacas hélice contínuas monitoradas na cidade de Jundiá, no interior de São Paulo.

A Figura 3.14 mostra o perfil geotécnico onde a estaca ET-1 foi instalada. A estaca ET- 1 tinha um diâmetro de 0,7 metros e comprimento de 17,00 metros.

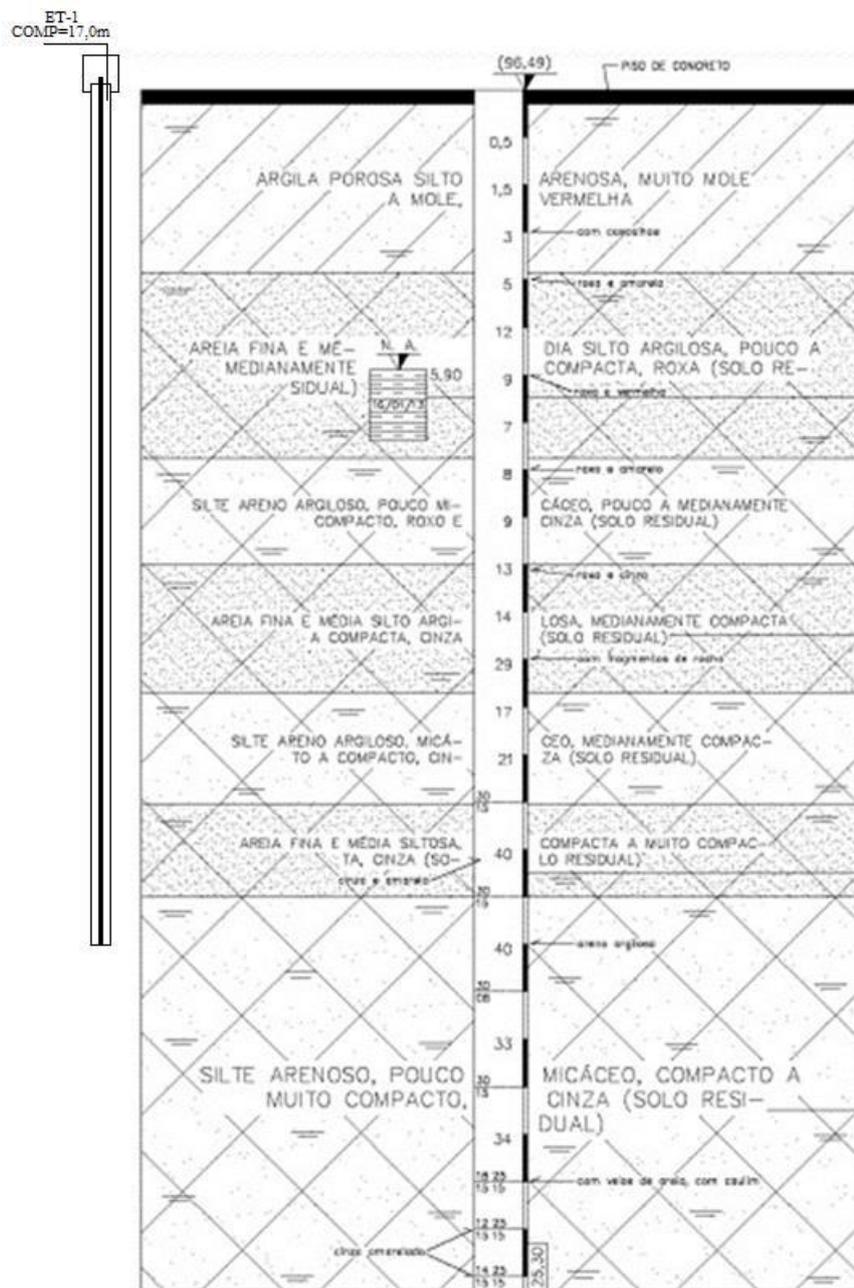


Figura 3.14 - Perfil geotécnico da sondagem SPT - ET-1

Na Figura 3.15, é exibido o resultado da prova de carga realizada na estaca ET-1, de acordo com o estudo conduzido por (Corrêa et al., 2015). É importante ressaltar que a carga máxima atingida foi de 3750 kN.

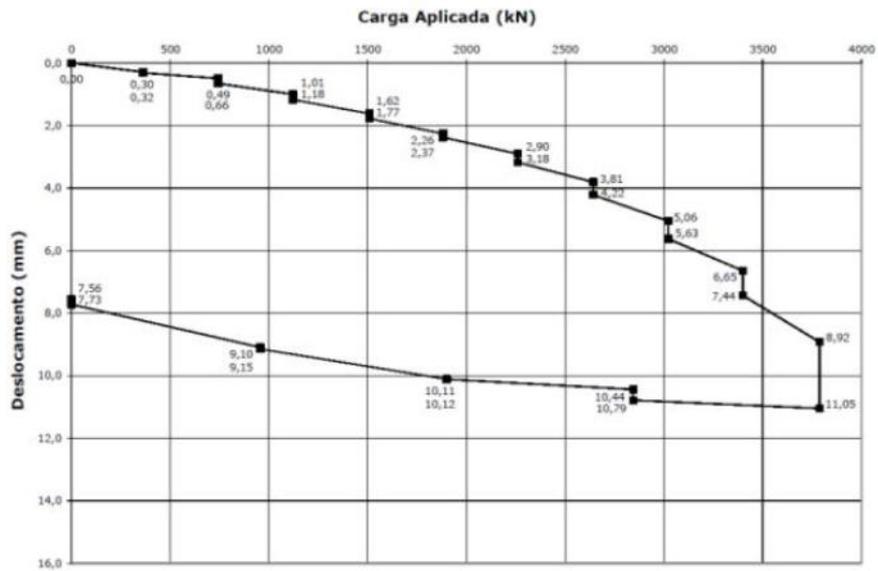


Figura 3.15 - Curva Carga x Deslocamento - ET-1

A Figura 3.16 mostra o perfil geotécnico onde a estaca ET-2 foi executada. A estaca ET- 2 tinha um diâmetro de 0,7 metros e comprimento de 16,00 metros.

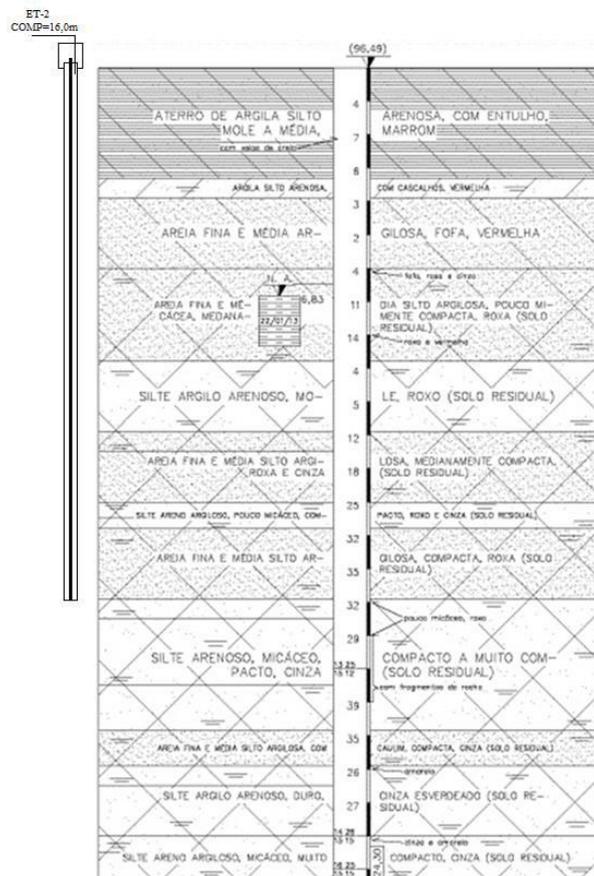


Figura 3.16 - Perfil geotécnico da sondagem SPT - ET-2

Na Figura 3.17, é exibido o resultado da prova de carga realizada na estaca ET-2. Neste caso, o valor da carga máxima foi de 4000 kN.

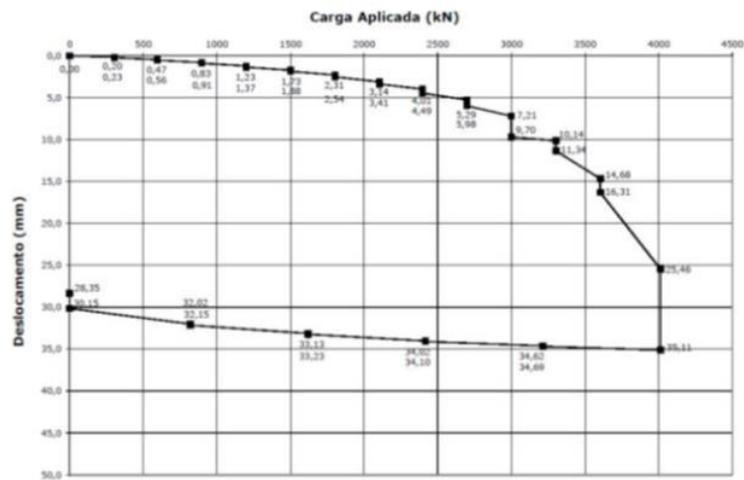


Figura 3.17 - Curva Carga x Deslocamento - ET-2

3.6 DUTRA (2022)

Dutra (2022) apresenta uma estaca de hélice contínua monitorada, identificada como PC002, de um projeto de construção de um condomínio em Salvador, Bahia. A estaca em análise possuía dimensões de 0,5 metros de diâmetro e 18 metros de comprimento.

A Figura 3.18 retrata o perfil geotécnico obtido através de uma vertical de sondagem a percussão com medida de N_{SPT} em local próximo a instalação da estaca.

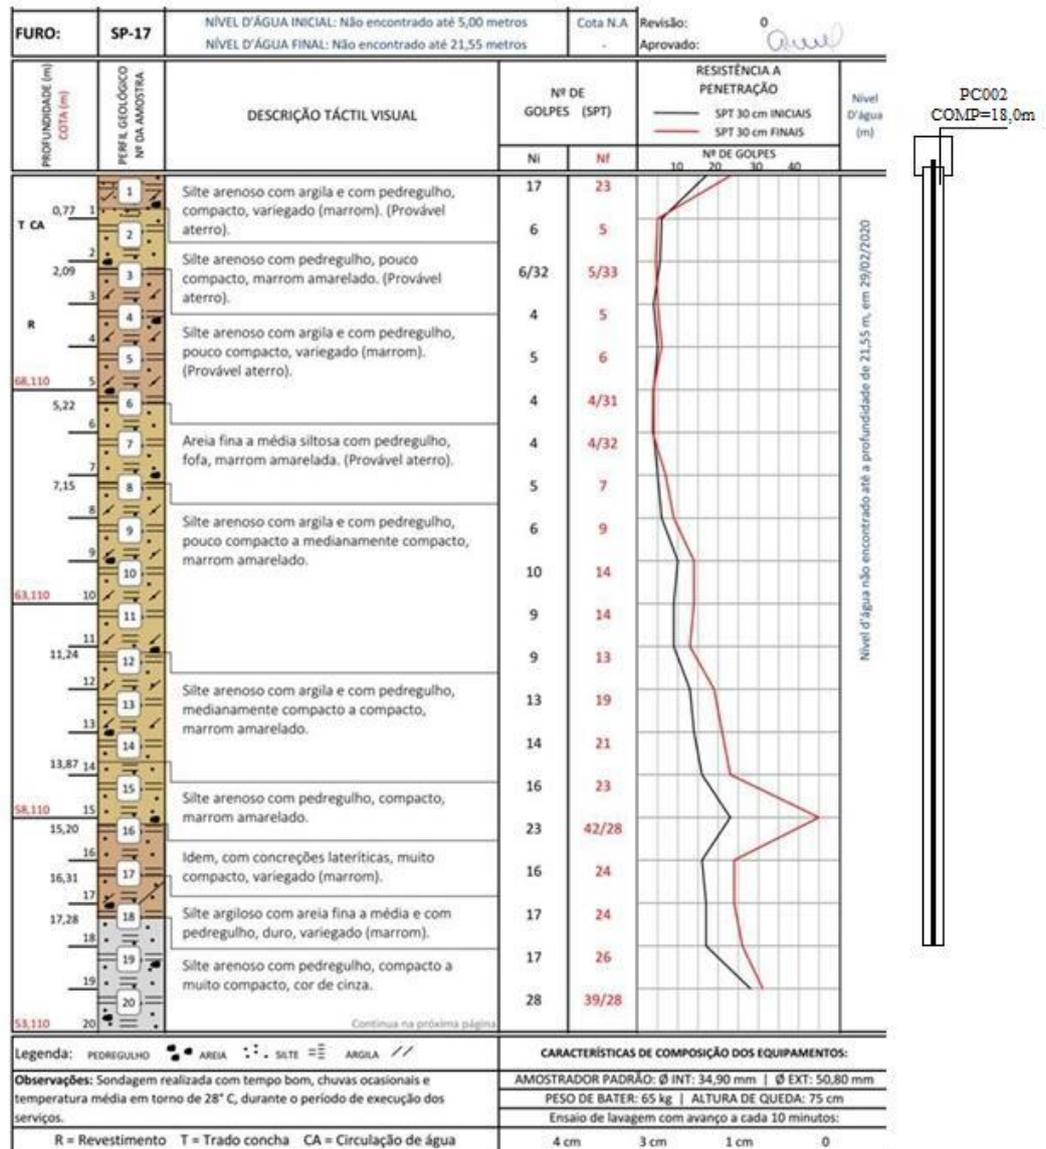


Figura 3.18 - Perfil geotécnico da sondagem SPT - PC002

A Figura 3.19 apresenta a curva carga vs deslocamento da prova de carga realizada na estaca PC002. O valor atingido de carga máxima foi de 1330 kN.

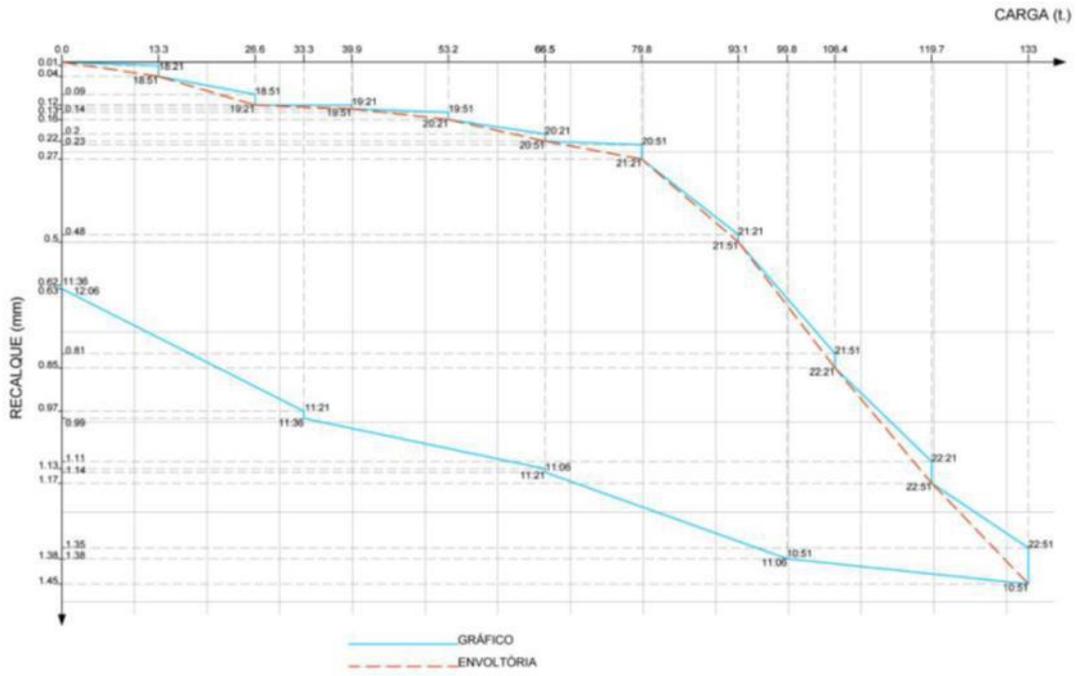


Figura 3.19 - Curva Carga x Deslocamento - PC002

4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

O procedimento realizado consistiu na aplicação da metodologia da UFC (2016) para estimar o recalque de estacas utilizando uma Rede Neural Artificial (RNA). Com base nessa abordagem, foi possível obter uma curva que relaciona a carga aplicada às estacas com o recalque resultante, além de realizar a estimativa da carga de ruptura (em alguns casos).

Para o desenvolvimento dessa metodologia, optou-se pelo software Excel, aproveitando o banco de dados fornecido por Beraldo (2022). As tabelas referentes a cada caso específico foram inseridas como dados de entrada no próprio Excel, permitindo a geração/criação/formação das respectivas curvas carga vs recalque. É relevante destacar que os gráficos são plotados com base em múltiplos pontos calculados pela própria rede neural, garantindo uma abordagem mais abrangente.

4.1 APRESENTAÇÃO DOS RESULTADOS

4.1.1 Alledi et al. (2006) – EH1 e EH2

A Tabela 4.1 mostra os valores de entrada na rede neural para EH1 e a Figura 4.1 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.1 – Valores de entrada na rede neural para EH1

Tipo de estaca	Hélice contínua
Comprimento	7,7
Diâmetro	0,4
Soma dos NSPT no fuste	162
NSPT na ponta	4
Distância do impenetrável	0,8
Percentual de espessura de argila	6%
Percentual de espessura de silte	0%
Percentual de espessura de areia	94%

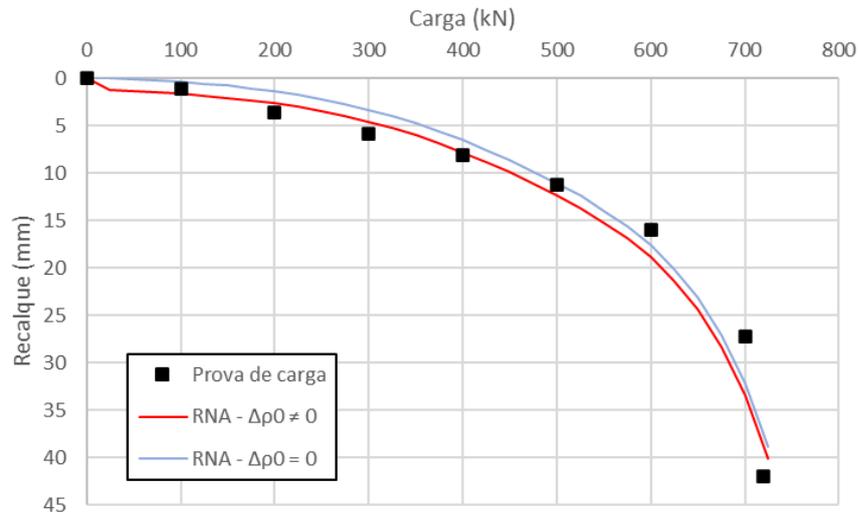


Figura 4.1 - Previsão da curva carga-recalque de EH1 em comparação à prova de carga real

A Figura 4.1 mostra que houve uma concordância da previsão da RNA em relação ao desempenho da EH1 ao longo de toda a curva carga vs recalque. Porém destaca-se que a previsão considerando o $\Delta\rho_0$ se ajustou melhor no início da curva, ou seja, para cargas menores. Já a previsão desconsiderando $\Delta\rho_0$ se ajustou melhor no final da curva, mais próximo a carga de ruptura. Vale destacar que, na ruptura, as duas previsões e o desempenho se ajustaram muito bem.

A Tabela 4.2 mostra os valores de entrada na rede neural para EH2 e a Figura 4.2 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.2 - Valores de entrada na rede neural para EH2

Tipo de estaca	Hélice contínua
Comprimento	11,85
Diâmetro	0,4
Soma dos NSPT no fuste	263
NSPT na ponta	11
Distância do impenetrável	0,8
Percentual de espessura de argila	6%
Percentual de espessura de silte	0%
Percentual de espessura de areia	94%

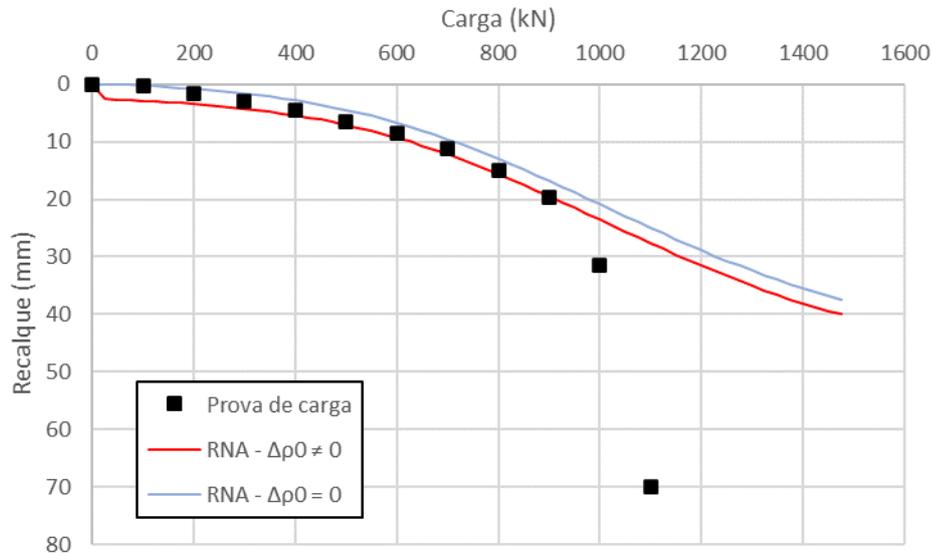


Figura 4.2 - Previsão da curva carga-recalque de EH2 em comparação à prova de carga real

A Figura 4.2 mostra uma concordância da curva carga recalque para as duas considerações de $\Delta\rho_0$ no trecho pseudolinear (até cerca de 900 kN). A partir desse ponto a curva real apresenta uma inflexão tendendo a ruptura, comportamento esse que não foi acompanhado pela previsão da RNA.

4.1.2 Mantuano (2014) – SA25

A Tabela 4.3 mostra os valores de entrada na rede neural para SA25 e a Figura 4.3 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.3 - Valores de entrada na rede neural para SA25

Tipo de estaca	Hélice contínua
Comprimento	22
Diâmetro	0,5
Soma dos NSPT no fuste	229
NSPT na ponta	16
Distância do impenetrável	1
Percentual de espessura de argila	14%
Percentual de espessura de silte	24%
Percentual de espessura de areia	61%

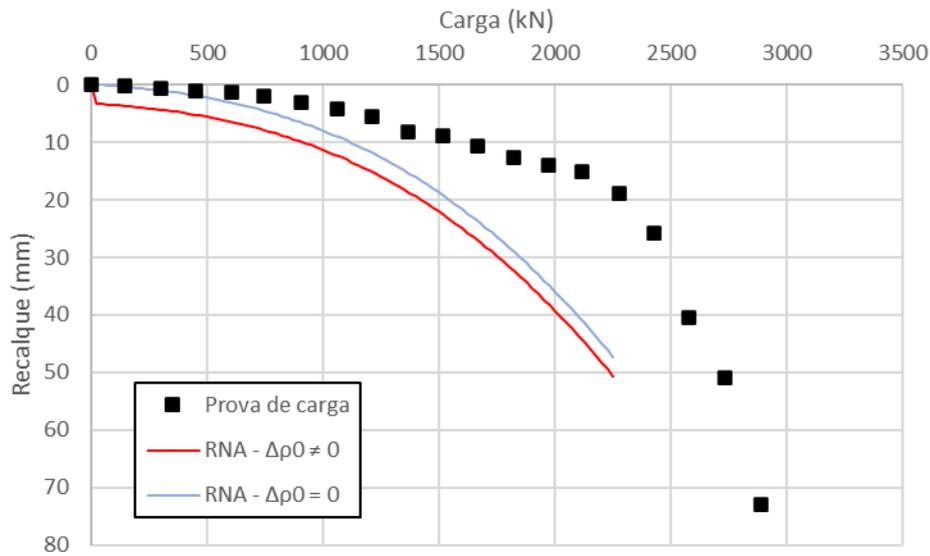


Figura 4.3 - Previsão da curva carga-recalque de SA25 em comparação à prova de carga real

A Figura 4.3 mostra que independente da consideração de $\Delta\rho_0$ as previsões da RNA em relação a SA25 apresentaram recalque maiores que os medidos, exceto para pequenas cargas com $\Delta\rho_0 = 0$. Cabe ressaltar que a tendência de ruptura prevista pela RNA concorda com a medida.

4.1.3 Neto (2002) – EHC2, EHC4 E EHC6

A Tabela 4.4 mostra os valores de entrada na rede neural para EHC2 e a Figura 4.4 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.4 - Valores de entrada na rede neural para EHC2

Tipo de estaca	Hélice contínua
Comprimento	10,8
Diâmetro	0,4
Soma dos NSPT no fuste	242
NSPT na ponta	18
Distância do impenetrável	0,8
Percentual de espessura de argila	17%
Percentual de espessura de silte	83%
Percentual de espessura de areia	0%

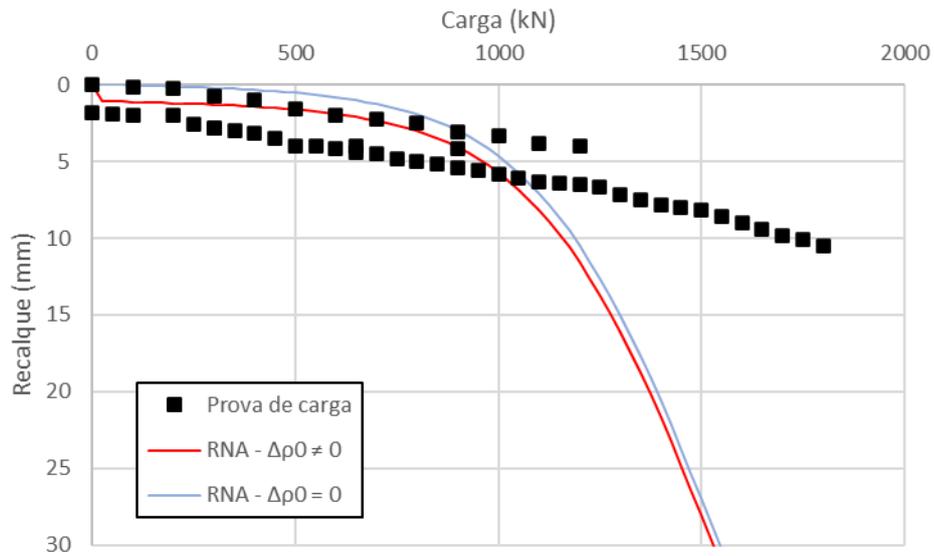


Figura 4.4 - Previsão da curva carga-recalque de EHC2 em comparação à prova de carga real

A Figura 4.4 mostra que independente de $\Delta\rho_0$ até 900 kN existe uma concordância de valores medido com os valores previstos pela RNA em relação a EHC2. A partir desse valor a RNA prevê uma ruptura enquanto os dados medidos não mostram esse comportamento.

A Tabela 4.5 mostra os valores de entrada na rede neural para EHC4 e a Figura 4.5 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.5 - Valores de entrada na rede neural para EHC4

Tipo de estaca	Hélice contínua
Comprimento	17,5
Diâmetro	0,4
Soma dos NSPT no fuste	163
NSPT na ponta	40
Distância do impenetrável	0,8
Percentual de espessura de argila	17%
Percentual de espessura de silte	77%
Percentual de espessura de areia	5%

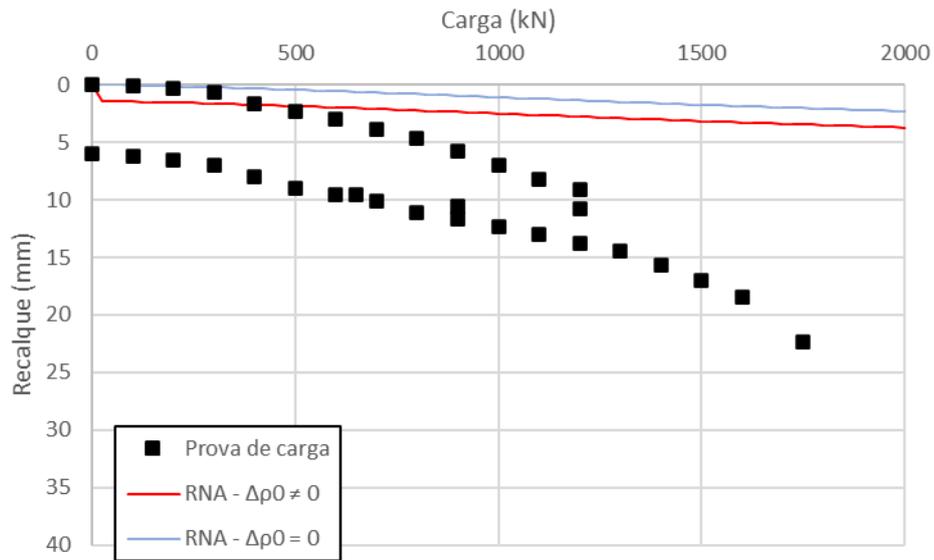


Figura 4.5 - Previsão da curva carga-recalque de EHC4 em comparação à prova de carga real

A Figura 4.5 mostra que a previsão da RNA em relação a EHC4 diverge completamente dos dados medidos. Cabe ressaltar que para $\Delta\rho_0 = 0$ e para pequenas cargas há uma mínima concordância com os dados medidos.

Tabela 4.6 - Valores de entrada na rede neural para EHC6

Tipo de estaca	Hélice contínua
Comprimento	12
Diâmetro	0,4
Soma dos NSPT no fuste	58
NSPT na ponta	49
Distância do impenetrável	0,8
Percentual de espessura de argila	71%
Percentual de espessura de silte	14%
Percentual de espessura de areia	15%

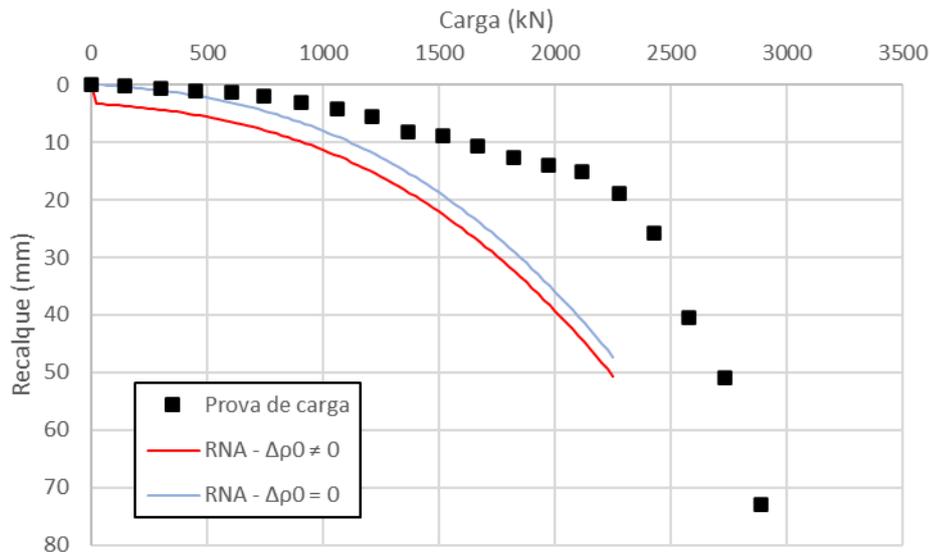


Figura 4.6 - Previsão da curva carga-recalque de EHC6 em comparação à prova de carga real

A Figura 4.6 mostra que independente da consideração de $\Delta\rho_0$ as previsões da RNA em relação a EHC6 apresentaram recalque maiores que os medidos, exceto para pequenas cargas com $\Delta\rho_0 = 0$. Cabe ressaltar que a tendência de ruptura prevista pela RNA concorda com a medida.

4.1.4 Corrêa et al. (2015) – ET-1 E ET-2

A Tabela 4.7 mostra os valores de entrada na rede neural para ET-1 e a Figura 4.7 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.7 - Valores de entrada na rede neural para ET-1

Tipo de estaca	Hélice contínua
Comprimento	17
Diâmetro	0,7
Soma dos NSPT no fuste	229
NSPT na ponta	40
Distância do impenetrável	1,4
Percentual de espessura de argila	24%
Percentual de espessura de silte	26%
Percentual de espessura de areia	50%

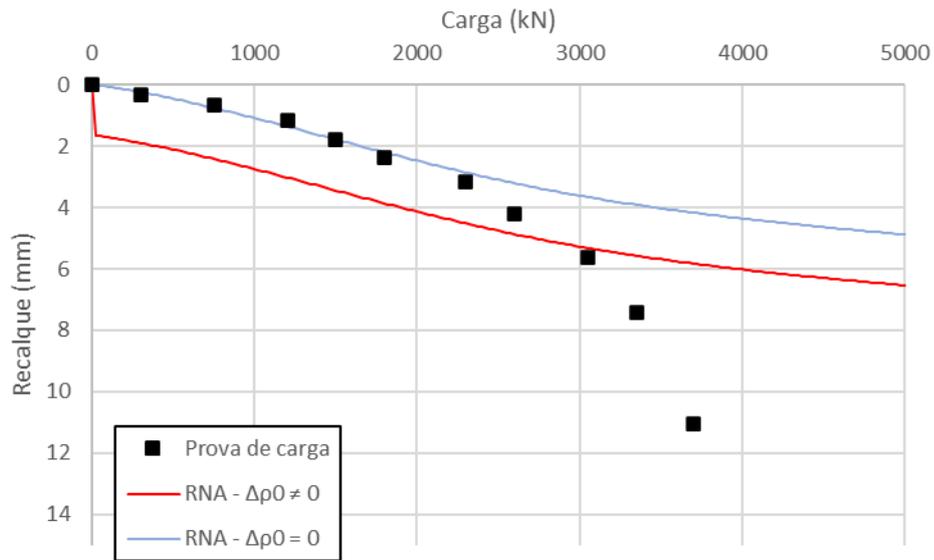


Figura 4.7 - Previsão da curva carga-recalque de ET-1 em comparação à prova de carga real

A Figura 4.7 mostra que a previsão da RNA em relação a ET-1 diverge completamente dos dados medidos. Cabe ressaltar que para $\Delta\rho_0 = 0$ e para cargas menores que 2000 kN há uma concordância com os dados medidos.

A Tabela 4.8 mostra os valores de entrada na rede neural para ET-2 e a Figura 4.8 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.8 - Valores de entrada na rede neural para ET-2

Tipo de estaca	Hélice contínua
Comprimento	16
Diâmetro	0,7
Soma dos NSPT no fuste	184
NSPT na ponta	32
Distância do impenetrável	1,4
Percentual de espessura de argila	25%
Percentual de espessura de silte	12%
Percentual de espessura de areia	63%

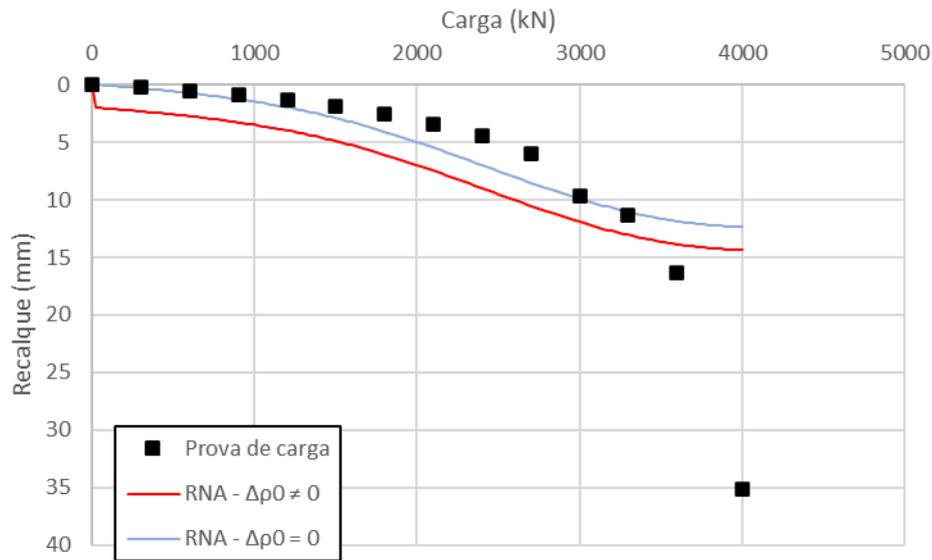


Figura 4.8 - Previsão da curva carga-recalque de ET-2 em comparação à prova de carga real

A Figura 4.8 mostra que no trecho de cargas até 3000 kN houve uma certa concordância das previsões da ET-2 da RNA com os dados medidos. Porém é observável que os recalques foram ligeiramente maiores que os medidos, com os recalques do modelo de $\Delta\rho_0 \neq 0$ maiores que comparado com o modelo de $\Delta\rho_0 = 0$. Para cargas maiores que 3000 kN as previsões divergiram uma vez que a curva real apresentou um ponto de inflexão e as previsões não apresentarem tal comportamento.

4.1.5 Dutra (2022) – PC002

A Tabela 4.9 mostra os valores de entrada na rede neural para a estaca estudada e a Figura 4.9 mostra a previsão da rede neural no intervalo de carga da prova de carga sob duas hipóteses antagônicas em relação a consideração da nulidade de $\Delta\rho_0$.

Tabela 4.9 - Valores de entrada na rede neural para PC002

Tipo de estaca	Hélice contínua
Comprimento	18
Diâmetro	0,5
Soma dos N_{SPT} no fuste	260
N_{SPT} na ponta	26
Distância do impenetrável	1
Percentual de espessura de argila	0%
Percentual de espessura de silte	11%
Percentual de espessura de areia	89%

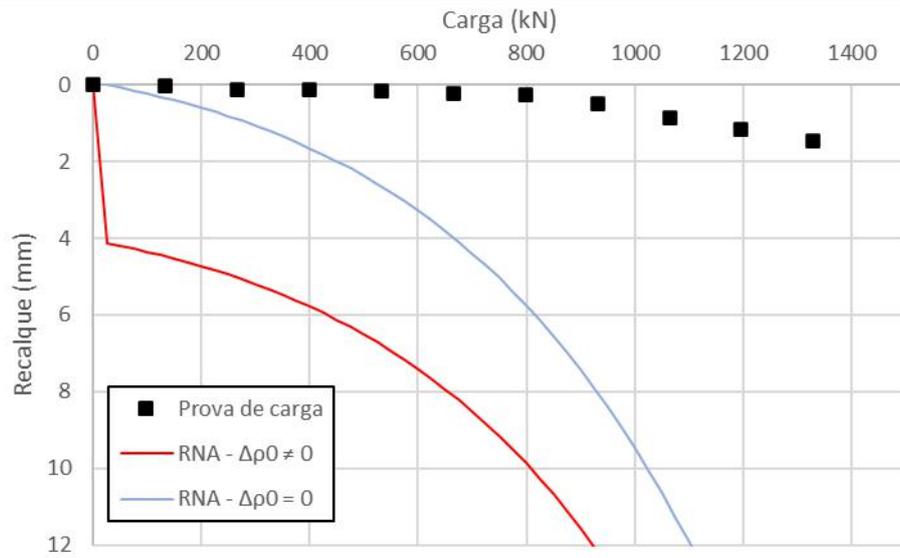


Figura 4.9 - Previsão da curva carga-recalque de PC002 em comparação à prova de carga real

A Figura 4.9 mostra que independente de $\Delta\rho_0$ a previsão da RNA divergiu completamente dos dados medidos na prova de carga da PC002.

5. CONSIDERAÇÕES FINAIS E CONCLUSÕES

Devido a limitação do entendimento humano à três dimensões, problemas multidimensionais são de difíceis soluções. Com efeito, correlacionar um valor com duas ou mais variáveis é um trabalho árduo para o ser humano. A metodologia conhecida como perceptron, que é um neurônio artificial computacional, veio auxiliar a soluções de problemas desta magnitude, pois é um ajuste de funções lineares de multivariáveis que consegue resolver casos binários.

O comportamento de uma estaca hélice contínua quando submetida a um carregamento envolve várias questões, desde sua integridade estrutural, passando pela transferência de carga da superestrutura para o solo e por fim os recalques sofridos quando carregadas. São muitas variáveis, tais como: características geométricas da fundação; tipo do material da estaca; processo de instalação das estacas; parâmetros de deformação e resistência ao cisalhamento do solo; N_{SPT} ; estratigrafia do perfil geotécnico em questão; tipo de carregamento, etc. No entanto, é importante destacar que, para que o aprendizado de máquina funcione adequadamente, ele deve ser treinado com base em um banco de dados confiável.

Neste estudo, foram utilizadas nove provas de carga estáticas realizadas em estacas hélice contínua no Brasil. O método da UFC (2016) baseado em uma RNA foi empregado para obter as curvas "carga vs recalque" para cada estaca ensaiada.

Vale lembrar que o método da UFC (2016) impõe algumas restrições que limitam a validade de aplicação do método. Estas restrições estão associadas aquelas variáveis mencionadas anteriormente (tipos de estacas, N_{SPT} , estratigrafia do solo, tipo de carregamento etc.).

Destaca-se que dentre as 9 estacas do tipo hélice contínua analisadas, 5 delas (EH1, EH2, SA25, EHC6, PC002) respeitam os limites de aplicação do método. Ou seja, seria esperado um bom ajuste entre desempenho da prova de carga e previsão da RNA.

Assim, observou-se que 4 estacas analisadas (EH1, EH2, SA25 e EHC6) realmente apresentaram um bom ajuste entre desempenho e previsão. Apenas uma estaca (PC002) o ajuste entre desempenho da prova de carga e previsão da RNA mostrou um comportamento inadequado. Uma das justificativas para que isso tenha ocorrido, é que talvez o banco de dados utilizado pelo modelo da UFC (2016) para treinar a rede neural não tenha sido o suficiente para conseguir detectar o comportamento específico do solo do Nordeste onde a estaca PC002 foi executada e ensaiada.

Em 4 estacas (EHC2, EHC4, ET-1 e ET-2) o limite de aplicação do método não foi respeitado, mesmo assim observou-se algum grau de concordância entre desempenho e previsão. As estacas EHC2 e EHC4 foram submetidas a um ciclo de carga e descarga. Este fato pode ter alterado o desempenho da prova de carga e a previsão da RNA não contempla este tipo

de carregamento. Já as estacas ET1 e ET2 foram executadas com a ponta em solo muito resistente. Esta condição de contorno seria similar a um engastamento, sendo esta condição não contemplada pelo método.

Com efeito, conclui-se que, no geral, a comparação entre o desempenho das provas de carga e as previsões pela RNA pode ser considerada promissora.

Devido à natureza recente da utilização de redes neurais artificial a engenharia de fundações, diversas sugestões para futuras pesquisas podem ser destacadas, tais como:

- Ampliar o banco de dados, aplicando a RNA do método da UFC (2016) em outras estacas;
- Aplicar outros modelos de RNA neste banco de dados;
- Desenvolver uma nova RNA com a inclusão de novos parâmetros, tais como: diferentes ensaios de investigação geotécnica (ensaios de campo – piezocone, dilatômetro, penetrômetro de bolso; ensaios de laboratório – adensamento, cisalhamento direto, triaxial); novos tipos de estaca (concreto, raiz, trado, etc).
- Utilizar ensaios de carregamento dinâmico em estacas como base para desenvolver uma nova RNA;
- Utilizar a nega e o repique elástico para fomentar uma nova RNA a fim de obter curvas carga vs recalque de estacas;
- Prever através de IA outros comportamentos de estacas submetidas a esforços de tração, esforço horizontal ou ainda uma combinação entre eles.

REFERÊNCIAS BIBLIOGRÁFICAS

ALLEDI, C. T. D. B.; POLIDO, U.; ALBUQUERQUE, P.J.R. *Provas de Carga em Estacas Hélice Contínua Monitoradas em Solos Sedimentares*. In: Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica, 13, 2006, Curitiba. Anais... Curitiba: ABMS, 2006.

ALLEDI, C. T. D. B. *Transferência de carga de estacas hélice contínua instrumentadas em profundidade*. Tese (Doutorado em Engenharia Civil) - Viçosa, MG, 2013.

AOKI, N.; VELLOSO, D. A. . An Approximate Method to Estimate the Bearing Capacity of Piles. In: Congresso Panamericano de Mecánica de Suelos e Ingeniería de Fundaciones. Vol. 1. p.367-376. 1975

ANGRA, S.; AHUJA, S. *Machine learning and its applications: a review*. In Big Data Analytics and Computational Intelligence (ICBDAC), International Conference on. IEEE, pp. 57-60. 2017.

AMÂNCIO, L. B. *Previsão de Recalques em Fundações Profundas Utilizando Redes Neurais Artificiais do Tipo Perceptron*. Dissertação (Mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Fortaleza, 2013.

ARAÚJO, C. B. C. *Previsão de Vazão Para o Açude Orós/CE a Partir de Dados Hidrometeorológicos Utilizando Perceptrons*, Monografia de Graduação em Engenharia Civil, Centro de Tecnologia, Universidade Federal do Ceará, 76p. 2013.

ARAÚJO, C. B. C.; ANJOS, G.; DANTAS, S. *Estimativa de Recalque em Estacas Utilizando Redes Neurais Artificiais*. In: Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica, 18, Belo Horizonte, ABMS, 2015.

BERALDO, K. W. *Estacas Hélice Contínuas: Avaliação de Desempenho de Métodos Semiempíricos Para Previsão da Capacidade de Carga de Ruptura Geotécnica*. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Campus Macaé, 2022.

CINTRA, J.C.A.; AOKI, N. *Fundações por estacas: projeto geotécnico*. Ed. Oficina de Textos. São Paulo, SP, Brasil. 2010.

CORRÊA, C. N.; FALCONI, F.; ROCHA, L. M. B.; MASET, V. L. *Prova de Carga Estática Prévia em Estaca Hélice Contínua Monitorada no Interior do Estado de São Paulo*. Dissertação de Mestrado In Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica, 18, Belo Horizonte, ABMS, 2015.

DANTAS NETO, S.A. *Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificados com Borracha Granulada de Pneus Usados*. Tese (Doutorado em Geotecnia), Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 265p. 2004.

DANTAS NETO, S.A.; SILVEIRA, M.V.; AMÂNCIO, L.B.; ANJOS, G.M. *Pile Settlement Modeling with Multilayer Perceptrons*. *Electronic Journal of Geotechnical Engineering*, v. 19, pp. 4517-4528. 2014.

DANTAS NETO, S. A.; SILVEIRA, M. V.; ANJOS, G. J. M.; MOURA, A. S. *Modelo de Previsão de Recalques em Estacas Hélice Contínua, Metálicas e Escavadas Através de Redes Neurais Artificiais*, *Revista Geotecnia*, Lisboa, v. 136, p. 27-47, mar. 2016.

DUTRA, C. S. *Estaca Hélice Contínua: Comparação da Capacidade de Carga à Ruptura Geotécnica entre Metodologias Semiempíricas Nacionais e Internacional*. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Campus Macaé, 2022.

GUIMARÃES, G. V. M.; SILVA, L. M. P.; CARDOSO, L. M.; THOMAZ, I. C. A.; ASSIS, H. S.; GONÇALVES, G. G.; PINHEIRO, F. B. *Utilizando a Inteligência Artificial em Amostras de Solo para Definição de Ensaio Geotécnicos*. In: *Revista Engenharia 4.0: a era da produção inteligente*. Pascal, 2022.

GUIMARÃES, G. V. M.; SILVA, L. M. P. *Aplicação de Aprendizado de Máquina para o Comportamento de Areias Puras*. In: *ANAIS DO XX COBRAMSEG, 2022*, Campinas. Anais eletrônicos. Campinas, Galoá, 2022. Disponível em: Acesso em: 02 set. 2022.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Prentice-Hall Inc., New York, 842p. 2001.

MANTUANO, R. M. *Comparação entre os Métodos de Dimensionamento e Influência do Processo Executivo no Comportamento de Estacas Hélice*. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Escola Politécnica, 2013.

NETO, J. A. A. *Análise do Desempenho de Estacas Hélice Contínua e Ômega – Aspectos Executivos*. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2002.

RASCHKA S. E MIRJALILI V. *Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow, 2nd ed.*, Packt, Mumbai, India, 622. 2017.

RIEMANN, G. F. B. *Grundlagen für eine allgemeine Theorie der Funktionen einer veränderlichen complexen Größe*. Tese (Doutorado) – Universidade de Göttingen, Göttingen, 1851.

ROSENBLATT, F. *The Perceptron, a Perceiving and Recognizing Automaton Project Para*. Cornell Aeronautical Laboratory, 1957.

RUMELHART, D.E.; Hinton, G.E.; Williams, R.J. Learning Internal Representations of Back-Propagation Error. *Nature*, v. 323, pp. 533-536. 1986.

SCICAST #540: Alinhamento IA. Locução: Tarik Fernandes, Marcelo de Matos, Lennon Ruhnke, Livia Nádia da Costa Leite, Natalia Nakamura, Roberto Spinelli. [S.l.] Portal Deviante, 09/06/2023. Podcast. Disponível em: <<https://www.deviante.com.br/podcasts/scicast-540>>

SILVEIRA, M.V. *Modelo Neuronal para Previsão de Recalques em Estacas Hélice Contínua, Metálica e Escavada*. Dissertação de Mestrado. Programa de Pós-graduação em Engenharia Civil. Departamento de Engenharia Hidráulica e Ambiental. Universidade Federal do Ceará. Fortaleza, Brasil. 107p. 2014.

TAVARES et al. *Identificação de problemas nos sensores de estacas hélice a partir de uma inteligência artificial*. In: ANAIS DO XX COBRAMSEG, 2022, Campinas. Anais eletrônicos. Campinas, Galoá, 2022. Disponível em: Acesso em: 02 set. 2022.