

DOI: 10.47094/COBRAMSEG2024/305

Estimativa de Carga de Ruptura em Estacas Hélice a partir de Ensaios de Prova de Carga Estática Utilizando *Machine Learning*

Vinícius Novaes Almeida

Estudante, UniCEUB, Brasília, Brasil, vinicius.novaes@sempreceub.com

Yuri Miguel de Oliveira

Engenheiro Civil, UniCEUB, Brasília, Brasil, yurimiguel.engenharia@gmail.com

Gabriela de Athayde Duboc Bahia

Engenheira Civil, UniCEUB, Brasília, Brasil, gabriela.bahia@ceub.edu.br

RESUMO: A realização de investigações geotécnicas para a elaboração de projetos de fundação é de extrema importância para assegurar o seu bom comportamento. Uma das formas correntes de investigação do maciço é o emprego de SPT (*Standard Penetration Test*). Dessa forma, este artigo apresentou como objetivo criar um algoritmo que fosse capaz de prever a carga de ruptura de estacas hélices contínua apenas com resultados de ensaios de SPT. O algoritmo foi elaborado a partir de técnicas de *machine learning* fundamentadas no aprendizado supervisionado. Para isso, foram utilizados como dados de treino os resultados de prova de carga estáticas associados aos ensaios de SPT e como dados de teste apenas os resultados dos ensaios SPT. Para a elaboração do algoritmo foi utilizado um banco de dados com 39 (trinta e nove) provas de carga estáticas realizadas em estacas hélice contínua com suas respectivas sondagens, obtidas de obras no Distrito Federal. O algoritmo foi desenvolvido em linguagem python e o método utilizado foi o *Random Forest*. Após a compilação dos dados foi possível obter uma acurácia do modelo de 78,12%. Dessa forma, os resultados mostraram que o modelo proposto funciona, porém com ressalvas na acurácia, sendo necessária a proposição de modelos mais avançados como redes neurais e outras técnicas de *deep learning* para que seja possível obter resultados mais precisos.

PALAVRAS-CHAVE: Previsão de carga, Machine learning, Hélice Contínua

ABSTRACT: Carrying out geotechnical investigations for the preparation of foundation projects is extremely important to ensure their good performance. One of the current ways of investigating the mass is the use of SPT (*Standard Penetration Test*). Therefore, this article aimed to create an algorithm that was capable of predicting the failure load of continuous helix piles only with SPT test results. The algorithm was created using machine learning techniques based on supervised learning. For this, the results of static load tests associated with the SPT tests were used as training data and only the results of the SPT tests were used as test data. To develop the algorithm, a database was used with 39 (thirty-nine) static load tests carried out on continuous helix piles with their respective surveys, obtained from works in the Federal District. The algorithm was developed in python language and the method used was Random Forest. After compiling the data, it was possible to obtain a model accuracy of 78.12%. Thus, the results showed that the proposed model works, but with caveats in accuracy, making it necessary to propose more advanced models such as neural networks and other deep learning techniques so that it is possible to obtain more accurate results.

KEYWORDS: Load forecasting, machine learning, continuous flight auger

1 INTRODUÇÃO

A realização de prospecções no solo para o conhecimento das propriedades do maciço se faz indispensável para o dimensionamento de fundações. Em sua maioria, a prospecção se resume à realização do ensaio de sondagem à percussão (SPT) e, em alguns casos, para obras de médio e grande porte, à utilização de provas de carga.

Esse ensaio visa simular o carregamento aplicado em um elemento de fundação instalado no maciço da obra, de forma a verificar o real comportamento das fundações, considerando a interação solo-fundação. Como resultado do ensaio é possível obter a curva carga x recalque, parâmetro relevante para o dimensionamento das fundações.

Apesar de ideal, a prova de carga não é utilizada de forma corrente, devido ao seu custo e à obrigatoriedade da norma em se utilizar apenas para as situações citadas acima.

Sendo assim, esse estudo tem como intuito estimar a carga de ruptura geotécnica de estacas carregadas axialmente, por meio de *machine learning*, a partir de ensaios de provas de carga estáticas e sondagens à percussão existentes em obras no Distrito Federal. Para que seja possível fazer essa estimativa de forma mais assertiva em obras que apresentem como prospecção apenas os ensaios de SPT.

2 FUNDAMENTAÇÃO TEÓRICA

Para a elaboração de projetos de fundação é comum considerar apenas os resultados de ensaios SPT para a definição da capacidade de carga das fundações. Isso se deve, ao ensaio de SPT ser o mais difundido no Brasil e a cultura brasileira se basear, em grande parte, apenas na realização deste ensaio para a realização de obras convencionais.

Apesar de existirem diversas correlações e métodos para o dimensionamento das fundações baseado nos ensaios SPT, ele nem sempre consegue simular o real comportamento das fundações. Dessa forma, para a elaboração de projetos mais seguros e que consigam se aproximar ao real desempenho das fundações, é importante a realização de ensaios complementares, como por exemplo a realização de provas de carga.

2.1 Provas de Carga Estática

Segundo a NBR 16903 (ABNT, 2020), a prova de carga estática pode ser aplicada para todos os tipos de estacas, verticais ou inclinadas, independentemente do processo de execução e de instalação no terreno.

A prova de carga é um método de análise direta da capacidade de suporte de carga, podendo ser realizada em diversos tipos de estruturas. Ela consiste em solicitar o elemento da fundação através de macacos hidráulicos, simulando o carregamento da edificação sobre o conjunto de fundações e maciço de solo. O tipo de ensaio mais comum envolve a aplicação e carregamento de compressão à estaca, em estágios crescentes da ordem de 20% da carga de trabalho, registrando os deslocamentos correspondentes.

Segundo Cintra e Aoki (2011), ao se aplicar a carga prevista no estágio, os recalques começam a ocorrer, provocando um alívio de carga, o que exige a sua reposição sistemática. Assim, são programados tempos de leitura de deslocamento da estaca a fim de se controlar a estabilização do recalque em cada incremento de carga.

O ensaio tem a vantagem de simular, em verdadeira grandeza, os carregamentos reais de uma construção tornando possível observar a resposta da fundação a essas cargas.

Além disso, a prova de carga previamente executada, permite ao projetista determinar qual a melhor configuração do comprimento das estacas e prever qual o valor do recalque admissível e carga de trabalho do estaqueamento.

A carga máxima do ensaio é estipulada a partir da carga de trabalho do elemento de fundação, sendo calculada como duas vezes a carga de trabalho da estaca. Quando uma prova de carga não é levada até a ruptura ou não se observa a ruptura nítida, pode-se realizar métodos de extrapolação da curva carga-recalque, com o objetivo de estimar a carga de ruptura da estaca, tais como o método da NBR e o método de Van der Veen.

2.2 Método da NBR 6122

No método da NBR 6122 (2019), a carga de ruptura pode ser convencionada como aquela que corresponde, na curva de carga × deslocamento como exemplificada na Figura 1, enquanto o recalque é obtido através da Equação 1.

$$\Delta_r = \left(\frac{P_r \times L}{A \times E} \right) + \left(\frac{D}{30} \right) \quad (1)$$

Onde,

Δ_r é o recalque de ruptura convencional;

P_r é a carga de ruptura convencional;

L é o comprimento da estaca;

A é a área da seção transversal da estaca;

E é o módulo de elasticidade do material da estaca;

D é o diâmetro do círculo circunscrito à seção transversal da estaca ou, no caso de barrete o diâmetro do círculo de área equivalente ao da seção transversal da estaca.

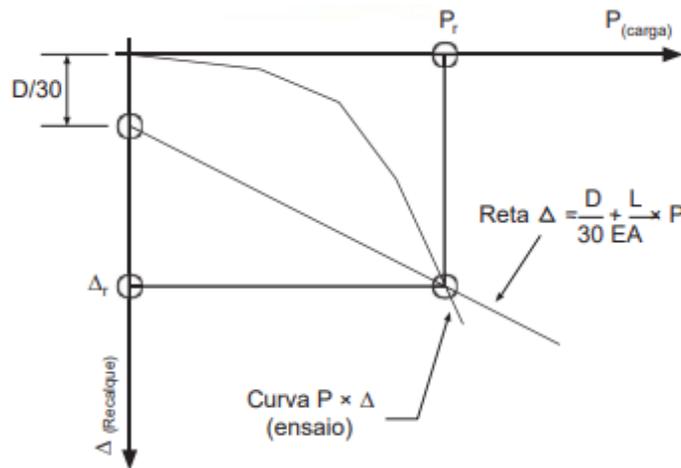


Figura 1. Carga de ruptura convencional.
 Fonte: ABNT NBR 6122 (pp27, 2019)

2.3 Método de Van der Veen

Segundo Jesus (2019), o método de Van der Veen é muito utilizado no Brasil para extrapolar as curvas obtidas em provas de carga que não foram levadas à ruptura. Neste método, a carga de ruptura é determinada por tentativas através de uma equação matemática ajustada (função exponencial) em função do trecho que se dispõe da curva carga-recalque. A Equação (2) define a carga de ruptura definida por Van der Veen (1953).

$$P = P_r (1 - e^{-ar}) \quad (2)$$

Onde:

P é a carga nos diversos pontos da curva carga-recalque;

r é o recalque nos diversos pontos da curva-recalque;

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

P_r é o valor de carga a ser determinado.

Tendo como base a Equação (2) e aplicando a propriedade dos logaritmos, é obtido, após algumas transformações, a Equação (3).

$$ar = -\ln \left(1 - \frac{P}{P_r} \right) \quad (3)$$

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

- Ensaios que atingiram pelo menos 2/3 da carga de ruptura;
- Estacas de deslocamento, pois os resultados da carga de ruptura em estacas escavadas são subestimados, porém como o método subestima o valor, será adotado o valor a favor da segurança;
- Carregamento monotônico (carregamento crescente e aplicado uma única vez).

2.4 Machine learning

No aprendizado de máquinas, *machine learning*, utilizam-se máquinas que possam desenvolver a capacidade de aprender de acordo com as respostas recebidas por meio de associações de diferentes dados. “*Machine learning* é um ramo de algoritmos computacionais em evolução, que é desenvolvido com o objetivo de emular a inteligência humana que aprende do ambiente que a cerca.” (Issam, Murphy. 2015, p.3).

A aprendizagem supervisionada implica na previsão de saídas para dados não vistos a partir do mapeamento de um conjunto de variáveis de entrada e variáveis de saída (Thipathi, 2017).

2.5 Random Forest

Segundo Oliveira (2018), o modelo de aprendizado de máquina *Random Forest Regressor*, é uma técnica baseada na construção de várias árvores de decisão (*Decision Tree*), formando assim uma floresta aleatória. Em geral, este tipo de modelo costuma apresentar excelentes resultados e possui fácil implementação. Nesse método, a técnica de separação dos dados é feita por *bagging*, que é um sistema de escolha por votação.

É importante levar em consideração que para um conjunto de dados muito grande é necessário realizar a compatibilização dos parâmetros deste modelo a fim de evitar problemas na predição dos valores.

3 METODOLOGIA

3.1 Banco de Dados

Para a realização deste artigo foi utilizado como base o trabalho desenvolvido por Oliveira (2018), seguindo o mesmo padrão de estruturação do banco de dados (Tabela 1). Porém, como o objetivo deste artigo é prever a carga de ruptura, apenas para as estacas do tipo escavada, todos os dados referentes a outros tipos de estacas foram desconsiderados, bem como o parâmetro de coeficiente de mola, utilizado no trabalho de Oliveira.

Tabela 1. Variáveis do banco de dados.

Id	Tipo	Origem
Local	Cidade	Projeto
L	Comprimento da estaca (m)	PCE
D	Diâmetro da estaca (m)	PCE
Q_{trab}	Carga de trabalho da estaca (tf)	Projeto
NF	N _{SPT} representativo do fuste	SPT
NP	N _{SPT} representativo da ponta	SPT
d	Dist. Entre a ponta da estaca e o impenetrável (m)	SPT
Arg	Fator representativo da quant. de argila (m/m)	SPT
Sil	Fator representativo da quant. de silte (m/m)	SPT
Ar	Fator representativo da quant. de areia (m/m)	SPT
P	Carga aplicada na estaca (kN)	PCE
ρ	Recalque (mm)	PCE
Qrup	Carga de ruptura da estaca	PCE

Destaca-se que algumas provas de carga não apresentaram ruptura nítida e foram calculadas pelo método de Van der Veen. O recalque analisado nas estacas foram os recalques residuais, ou seja, aqueles obtidos após a ruptura da estaca e após o descarregamento.

Foram analisadas 39 (trinta e nove) provas de carga estáticas em estacas escavadas para a obtenção e organização do banco de dados.

3.2 Algoritmo Python

Para a criação do código, foi necessário fazer o tratamento dos dados levantados, a partir do *Data Cleaning* (Limpeza de Dados), a fim de torná-los aplicáveis para as análises da IA. Após a organização dos dados, deu-se início ao *Data Analysis* (Análise de Dados), processo onde são aplicadas as técnicas de análise de dados buscando encontrar as características do *dataset*.

Em seguida, foi elaborado o algoritmo de *machine learning* de forma a conseguir verificar as correlações existentes entre os resultados de N_{SPT} (Índice de Resistência à Penetração do Solo) com os resultados de prova de carga. A correlação entre os resultados foi obtida a partir da análise do coeficiente de Pearson, que analisa a medida da variância associada a duas variáveis. E o algoritmo foi desenvolvido considerando a carga e o recalque do ensaio de prova de carga, e para a sondagem utilizou-se o somatório do N_{SPT} ao longo de todo o comprimento da estaca, a média do N_{SPT} ao longo de todo o comprimento da estaca, o N_{SPT} da ponta da estaca, a soma e a média ponderadas do N_{SPT} ao longo de todo o comprimento da estaca.

Dessa forma, o modelo de predição do valor da carga de ruptura foi criado, usando como base nos dados de treinamento e na biblioteca *Scikit-learn*.

Para a validação do modelo o banco de dados, os dados foram organizados em dados de treino e dados de teste, tornando possível calcular ao final a acurácia do modelo e avaliar sua precisão. Para determinar quantos dados foram utilizados para treino, foi utilizado o parâmetro `test_size= 0.3` que é responsável por determinar que 70% dos dados serão para treino, e os 30% restantes serão utilizados para a validação dos mesmos.

A acurácia do modelo foi calculada pelo erro médio absoluto.

4 RESULTADOS E ANÁLISES DOS DADOS

4.1 Caracterização dos Dados

A Figura 2 apresenta a caracterização inicial do *dataset*, representado pelas regiões administrativas em que foram obtidos os dados de prova de carga e sondagens SPT utilizados neste trabalho.

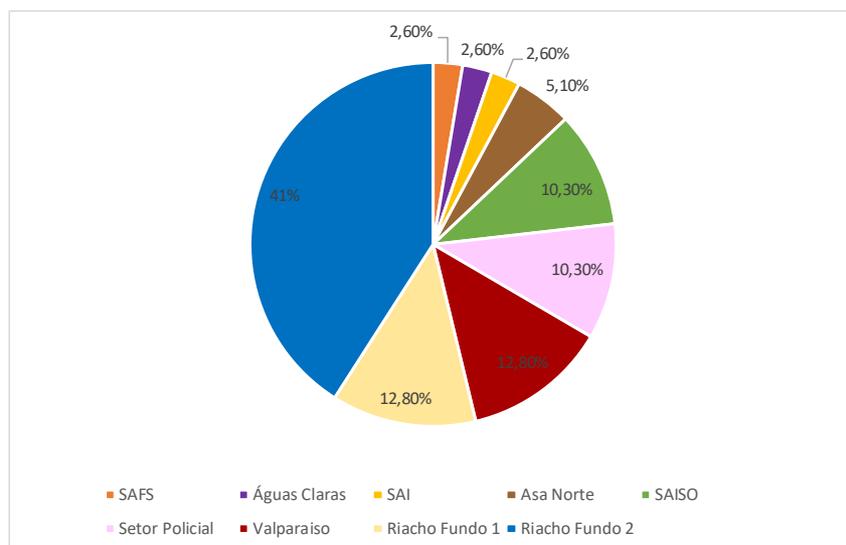


Figura 2. Gráfico representativo das regiões.

Observa-se que a região com maior representatividade é o Riacho Fundo 2, seguido do Riacho Fundo 2 e Valparaíso/Riacho Fundo 1.

A Figura 3 apresenta a variação do diâmetro e da profundidade das estacas por região.

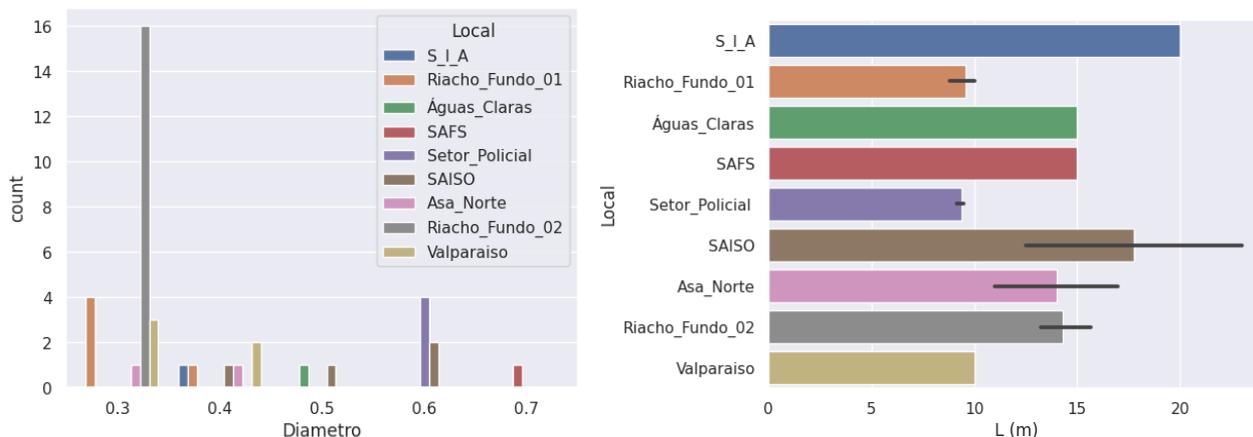


Figura 3. Variação dos diâmetros e da profundidade das estacas por região.

Observa-se que os diâmetros mais utilizados nas análises foram os de 0,3m (constituído por vinte estacas) e 0,6m (constituído por seis estacas). Os comprimentos das estacas analisadas variaram de 8m a 24m, sendo o local com maior variação de comprimento de estaca é o SAISO.

4.2 Avaliação de Desempenho do Modelo

Como o banco de dados foi dividido em dados de treino e dados de teste, foi possível comparar os valores previstos pela IA (*DataTrain*) com os valores reais fornecidos pelo banco de dados (*DataTest*), Figura 4.

Destaca-se que apenas 12 (doze) dados dos 39 (trinta e nove) estudados foram apresentados na figura 4, por apresentarem maiores discrepâncias.

Valor Real de Capacidade de Carga (tf)	Valor Previsto de Capacidade de Carga (tf)
240	386,47
500	531,9
2100	2400
750	799,25
450	386,96
500	482,75
3650	757,95
450	485,45
450	312,66
1200	1115,1
1600	1169,9
1000	791,75

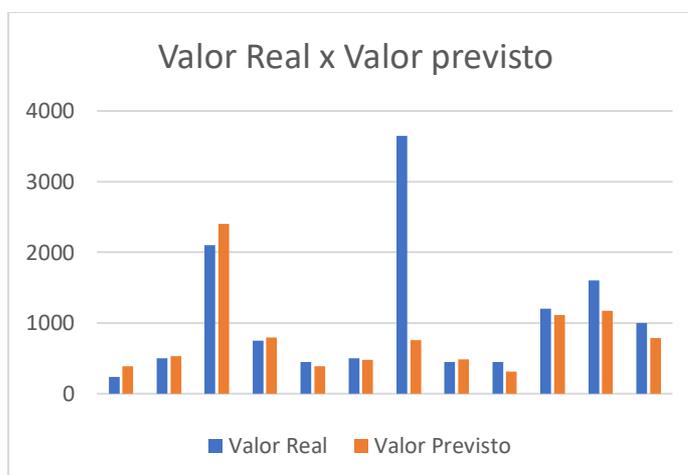


Figura 4. Comparativo entre uma parte dos valores reais e dos previstos pelo modelo.

Tem como base os dados apresentados pela Figura 4, pode-se perceber que o valor real de capacidade de carga de 3650 tf (obtido por meio da prova de carga) foi o que demonstrou a maior discrepância de valor com a IA, em relação ao valor previsto de capacidade de carga (obtido com o algoritmo que estima a capacidade de carga a partir dos dados de N_{SPT}), correspondente a 757,95tf. Isso representa um valor 79%

abaixo do real, seguido pelo valor de 1600tf de capacidade de carga real contra 1169,9tf prevista pela IA, representando cerca de 27% do valor previsto abaixo do real. Dessa forma, a variabilidade dos dados em relação à média foi considerada representativa, de forma geral, pela maioria dos dados se apresentarem próximos à média.

A figura 5 apresenta a implementação de cálculo para obtenção da acurácia do modelo.

```
# Aqui calculamos o percentual do erro médio absoluto
mape = 100 * (errors / y_test)
accuracy = 100 - np.mean(mape)
print ("Acurácia:", round(accuracy, 2), "%")
```

Acurácia: 76.82 %.

Figura 5. Cálculo da acurácia do algoritmo

Através do erro médio absoluto foi obtida uma precisão de 76,82%, o que representa uma precisão mediana em comparação com a quantidade total de dados analisados.

4.3 Importância das Variáveis

A Figura 6 apresenta o gráfico de calor que permite visualizar a correlação entre os dados, por meio do coeficiente de correlação de Pearson.

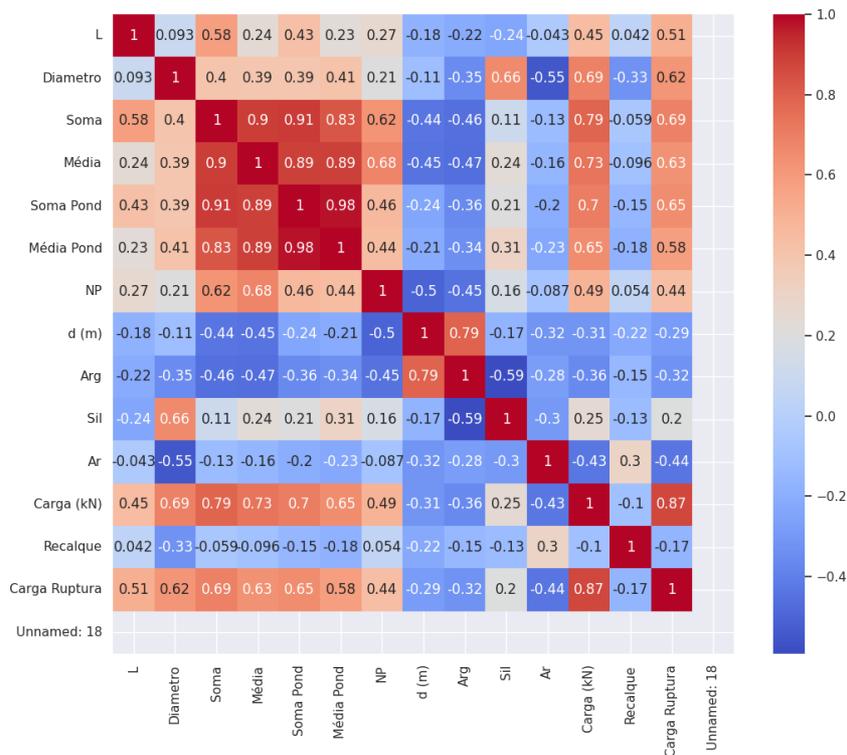


Figura 6. Gráfico de calor

É possível observar que existe pouca correlação linear (abaixo de 0,7) entre os dados. Porém, as variáveis de carga, soma ponderada e média ponderada do N_{SPT} apresentam correlação mediana, o que implica uma maior relação destas variáveis com a carga de ruptura.

5 CONSIDERAÇÕES FINAIS

Os resultados mostraram que o modelo proposto para a previsão da capacidade de carga de ruptura das estacas apresentaram acurácia de 76,82% podendo ser utilizado para o dimensionamento, porém com precaução. Existem ressalvas com relação à precisão do modelo, sendo necessário melhorá-lo, aumentando a quantidade de dados a serem implementados. Destaca-se que houve uma dificuldade de conseguir dados de provas de carga associados a dados de sondagem para a alimentação do banco de dados, dessa forma, a quantidade de dados utilizados para a pesquisa foi pequena, fato que pode ter corroborado para o aumento da dispersão dos resultados e diminuição da acurácia do modelo.

Vale destacar, que a grande variabilidade geotécnica, neste caso representado apenas pelo ensaio de N_{SPT} , dificilmente conseguirá retratar precisamente as condições do solo local analisado, por ser um ensaio pontual e descontínuo. Dessa forma, recomenda-se a utilização de modelos tridimensionais que associem os dados de ensaios como geofísica de eletroresistividade junto ao SPT para calibrar melhor o algoritmo.

Destaca-se ainda que existem limitações intrínsecas ao resultado final, como a utilização do modelo de aprendizado supervisionado utilizado, *random forest*. Neste modelo, quanto maior a dispersão dos dados, menor é a capacidade do modelo em se adaptar, sendo recomendada a utilização de modelos mais avançados como redes neurais e outras técnicas de *deep learning* (aprendizado profundo), para a previsão de resultados com maior precisão.

REFERÊNCIAS BIBLIOGRÁFICAS

- Associação Brasileira de Normas Técnicas (2019). NBR 6122. *Projetos e execuções de fundações*. Rio de Janeiro.
- Associação Brasileira de Normas Técnicas (2020). NBR 16903. *Solo - Prova de carga estática em fundação profunda*. Rio de Janeiro.
- Cintra, J. C. A., Aoki, N. (2011). *Fundações por estacas: projeto geotécnico*, 1a ed., Oficina de textos, São Paulo, SP, 93p.
- Décourt, L. e Niyama, S. (1994). *Predicted and measured behavior of displacement piles in residual soils*, Proc., 13th ICSMFE., New Delhi, India, p. 477–486.
- Issam, E. N., Murphy, M. J. (2015). *What is machine learning?* In: *Machine Learning in Radiation Oncology*, Berlim, p. 3-11.
- Jesus B. V. (2019). *Experimentos de Previsão da Carga de Ruptura em Estacas Carregadas Axialmente à Compressão Utilizando Redes Neurais Artificiais (RNA)*, Dissertação de Mestrado, Universidade do Rio de Janeiro, Centro de Tecnologia e Ciências Faculdade de Engenharia, Rio de Janeiro, 188p.
- Oliveira Y. M. (2018). *Machine Learning Aplicado na Estimativa do Coeficiente de Mola de Estacas com Validação por Meio de Provas de Carga Estáticas*. Monografia de conclusão de curso, Centro Universitário de Brasília, Faculdade de Tecnologia e Ciências Sociais Aplicadas, Brasília, p. 49.
- Van Der Veen, C. (1953). *The bearing capacity of pile*. In: Proc. 3rd ICSMFE, p.84-90.
- Tripathi, A. (2017). *Practical Machine Learning: Resolving and offering solutions to your machine learning problems with R*, 1. ed., Birmingham: Packt Publishing Ltd., p. 543.