

Machine Learning* aplicado na estimativa do coeficiente de mola de estacas com validação por meio de provas de carga estáticas**Machine Learning* applied to estimate pile coefficient with validation by static load tests**

DOI:10.34117/bjdv6n1-126

Recebimento dos originais: 30/11/2019

Aceitação para publicação: 14/01/2020

Yuri Miguel de Oliveira

Engenheiro Civil pelo Centro Universitário de Brasília - UniCEUB

Instituição: Centro Universitário de Brasília - UniCEUB

Endereço: SEPN 707/907 Campus Universitário – Asa Norte, Brasília – DF, Brasil

E-mail: miguel.tecedf@gmail.com

Gabriela de Athayde Duboc Bahia

Mestre em Geotecnia pela Universidade de Brasília - UnB

Instituição: Centro Universitário de Brasília - UniCEUB

Endereço: SEPN 707/907 Campus Universitário – Asa Norte, Brasília – DF, Brasil

E-mail: gabriela.bahia@ceub.edu.br

Fernando Rodrigo de Aquino

Mestre em Geotecnia pela Universidade de Brasília - UnB

Instituição: Centro Universitário e Faculdade Projeção - UniProjeção

Endereço: Quadra 4, Área reservada 1, Conjunto A2 – Sobradinho – DF, Brasil

E-mail: fernando.sccap@gmail.com

Marcos Vinicius Amorim Ferreira Guimarães

Mestre em Ciências da Informação pela Universidade de Brasília - UnB

Instituição: Centro Universitário de Brasília - UniCEUB

Endereço: SEPN 707/907 Campus Universitário – Asa Norte, Brasília – DF, Brasil

E-mail: marcos.guimaraes@ceub.edu.br

Ana Laura Ulhôa Gonçalves

Engenheira Civil pelo Centro Universitário de Brasília - UniCEUB

Instituição: Centro Universitário de Brasília - UniCEUB

Endereço: SEPN 707/907 Campus Universitário – Asa Norte, Brasília – DF, Brasil

E-mail: analauraulhoa@gmail.com

Patrícia Sousa de Oliveira

Estudante de Engenharia Civil pelo Centro Universitário de Brasília - UniCEUB

Instituição: Centro Universitário de Brasília - UniCEUB

Endereço: SEPN 707/907 Campus Universitário – Asa Norte, Brasília – DF, Brasil

E-mail: oliveirapatte@gmail.com

RESUMO

O presente trabalho tem o intuito de realizar uma estimativa do coeficiente de mola para fundações do tipo estaca escavada e hélice contínua, executadas em solos da região do Distrito Federal. Com o auxílio de um banco de dados gerado com parâmetros de sondagens e provas de carga foi elaborado um algoritmo capaz de estimar o valor do coeficiente de mola utilizando técnicas fundamentadas no aprendizado supervisionado. Como resultado, obteve-se 87% de precisão para um campo amostral de

104 provas de cargas. Os resultados mostraram que o modelo proposto funciona de forma satisfatória, porém com ressalvas na acurácia.

Palavras-chave: coeficiente de mola, prova de carga, sondagem, *Machine Learning*.

ABSTRACT

The present work intends to estimate the spring coefficient for excavated pile and continuous helix foundations, performed in soils of the Federal District. With the help of a database generated with probing parameters and load tests, an algorithm was developed to estimate the value of the spring coefficient using techniques based on supervised learning. As a result, 87% accuracy was obtained for a sample field of 104 load tests. The results showed that the proposed model works satisfactorily, but with caveats in the accuracy.

Key words: spring coefficient, load test, sounding, *Machine Learning*.

1 INTRODUÇÃO

Na prática da engenharia, buscam-se melhorar continuamente os processos construtivos, a fim de garantir qualidade e durabilidade às edificações. Uma confirmação disso é a atualização da NBR 6122 (ABNT, 2010), que tornou obrigatório o monitoramento de recalques para quatro situações fundamentais: estruturas acima de 60 m de altura do térreo até a laje de cobertura; relação altura/largura superior a quatro; estruturas nas quais a carga variável é expressiva comparada à carga total e fundações ou estruturas não convencionais.

Ainda em sua atualização, a referida norma contemplou os efeitos da deformação do solo: “Em estruturas nas quais a deformabilidade das fundações pode influenciar na distribuição de esforços, deve-se estudar a interação solo-estrutura.” (NBR 6122, 2010, pp.13).

Como alternativa para a consideração da interação solo-estrutura (ISE), os *softwares* aparecem como uma ferramenta de grande valia. A sua utilização permite implementar a flexibilização dos pilares por meio do coeficiente de mola.

Entretanto, a determinação desse parâmetro, realizada, muitas vezes, por tabelas empíricas, nem sempre reflete de forma satisfatória a realidade geotécnica, além de ser complexa a sua correlação direta com a rigidez do solo.

Nesse contexto, o uso da Inteligência Artificial (IA) é uma técnica essencial, pois permite a previsão de valores de difícil determinação para tomadas de decisões mais assertivas.

2 REVISÃO BIBLIOGRÁFICA

Para a concepção de um projeto estrutural é comum desconsiderar o deslocamento dos apoios devido ao recalque das fundações. Apesar de ser uma análise simplificada e usual, este tipo de modelo não retrata o real comportamento da edificação (BAHIA, 2015).

Dessa forma, para a obtenção de análises mais realistas é necessária a consideração da ISE nos modelos estruturais. Sendo necessário estipular um modelo capaz de descrever o comportamento do solo em relação à dissipação das cargas provenientes da superestrutura.

O coeficiente de mola, para a consideração da flexibilização dos apoios, se torna elemento fundamental. Porém, sua determinação deve ser realizada de forma cuidadosa para garantir a confiabilidade do projeto.

Uma das formas de obtenção do referido coeficiente, utilizada neste trabalho, se dá por meio de provas de carga do tipo estática, através da divisão entre a carga e o deslocamento obtidos no referido ensaio para o trecho linear da curva carga *versus* recalque.

2.1 PROVA DE CARGA

O método para execução da prova de carga consiste em se realizar aplicações de cargas em intervalos de tempo pré-determinados. O objetivo final do ensaio é obter uma curva carga x recalque que possibilite realizar as análises do comportamento da fundação.

A carga máxima é estipulada de acordo com a carga de trabalho do elemento estrutural. A carga final do ensaio é calculada como duas vezes a carga de trabalho da estaca ou até a sua ruptura. O critério de estabilização do recalque é estabelecido pela NBR 12131 (ABNT, 2006) como sendo a diferença de deslocamento medida entre duas leituras consecutivas, menor ou igual a 5% do deslocamento do estágio de carregamento analisado.

2.2 FATOR DE SEGURANÇA

O fator de segurança é relativo às diferenças entre os valores teóricos e os valores reais do comportamento da estaca e está diretamente relacionado com a probabilidade de ruína.

Os motivos que levam a essas discrepâncias vêm, muitas vezes, de variação geotécnica do maciço ou de aproximações feitas pelos métodos de cálculo de capacidade de carga.

Em concordância com a NBR 6122 (ABNT, 2010), o fator de segurança global pode ser reduzido de 2,0 para 1,6 vezes, quando realizadas provas de carga para análises acerca do desempenho das fundações.

Vale destacar, que os elementos ensaiados devem ser representativos do conjunto de fundações, bem como, as características do solo que envolve estes elementos.

2.3 CARACTERIZAÇÃO DO SOLO POR MEIO DE SONDAGENS À PERCUSSÃO (SPT)

Para Cintra et. al (2011), o ensaio de SPT consiste na realização de três etapas: perfuração, amostragem e ensaio penetrométrico.

A perfuração consiste em se realizar furos por meio de um trado de sondagem. Caso o NA seja atingido, a perfuração prossegue por um conjunto de hastes rosqueadas introduzidas por dentro do revestimento.

O ensaio penetrométrico, acontece por meio da contagem do número de golpes necessários para se cravar o amostrador no solo. A cravação ocorre até a penetração dos 45 cm da haste onde é efetuada a contagem parcial para cada 15 cm.

De acordo com a NBR 6484 (ABNT, 2001), o objetivo deste ensaio além da amostragem do solo é a determinação do valor do N_{SPT} .

2.4 COEFICIENTE DE MOLA

O cálculo do coeficiente de mola geralmente compreende o trecho elástico da estaca (comportamento no qual a estaca trabalha sem a sua completa mobilização, o que normalmente ocorre na prática), ou seja, onde o comportamento do elemento estrutural se assemelha ao modelo de Winkler.

Silva e Carvalho (2010) definem o coeficiente de reação vertical (K_v) como a razão entre a pressão (q) e o recalque produzido (w) pela aplicação de carga na fundação (equação 1).

$$K_v = \frac{q}{w} \quad (1)$$

Alonso (2018) aponta que o coeficiente de mola (k) pode ser obtido por meio da equação 2.

$$k = \frac{K_v}{area} \quad (2)$$

Em que o K_v representa o coeficiente de reação vertical e a área, representa a área da fundação. Dessa forma, o coeficiente de mola pode ser expresso pela divisão entre a carga e o recalque correspondente na fundação.

Para o cálculo é preciso estabelecer na prova de carga qual é o trecho correspondente ao comportamento elástico da estaca (figura 1).

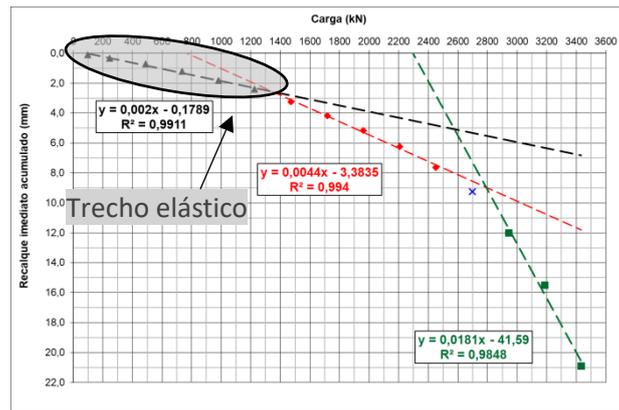


Figura 1. Comportamento elástico da estaca.

A figura 1 apresenta a metodologia de Carvalho et. al (2008), em que o primeiro trecho da curva é utilizado para determinar o cálculo do coeficiente de mola.

2.5 APRENDIZADO DE MÁQUINAS (*MACHINE LEARNING*)

No aprendizado de máquinas, utilizam-se as máquinas como meios para encontrar padrões e solucionar problemas por meio de algoritmos de análise de dados.

“A aprendizagem supervisionada implica aprender um mapeamento entre um conjunto de variáveis de entrada (tipicamente um vetor) e uma variável de saída (também chamada de sinal de supervisão) e aplicando o mapeamento para prever as saídas para dados não vistos.” (TRIPATHI, 2017, pp. 10, tradução nossa).

2.6 *RANDOM FOREST REGRESSOR*

O modelo de aprendizado de máquina *Random Forest Regressor*, se baseia na construção de várias árvores de decisão. Em geral, este tipo de modelo costuma apresentar excelentes resultados e possui fácil implementação.

Nesse método a técnica de separação é feita por *bagging*, sistema de escolha por votação. A figura 2 apresenta uma demonstração do funcionamento e implementação deste método.

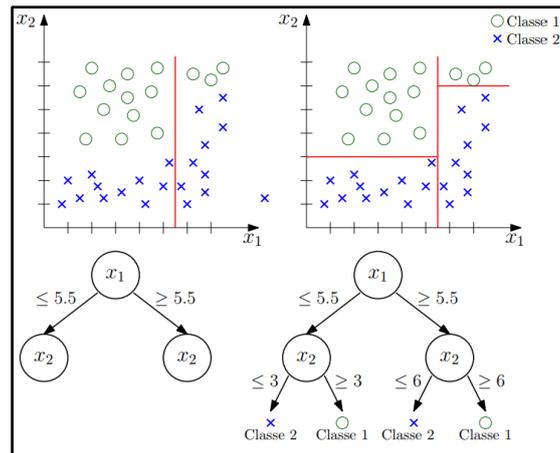


Figura 2. Árvore de decisão com dois parâmetros.
Fonte: Martins et. al (2016, p.24)

É importante observar que para um conjunto de dados grande é necessário realizar a compatibilização dos parâmetros a fim de evitar problemas na predição dos valores.

2.7 DEFINIÇÃO DAS VARIÁVEIS DE ENTRADA

Segundo Araújo (2015), vários são os fatores que influenciam o comportamento de uma estaca, algumas das principais características são: a geometria do elemento estrutural, suas características de resistência e a deformabilidade do solo.

Amancio (2013) apresentou uma metodologia fundamentada em redes neurais para previsão do recalque de fundações profundas, onde as variáveis de entrada no modelo foram: tipo de estaca T; comprimento da estaca L (metro); diâmetro da estaca D (metro); somatório do N_{SPT} ao longo do fuste da estaca NF; N_{SPT} na base da estaca NP; estratigrafia por meio da consideração do solo ao longo do fuste da estaca FS; carga aplicada na estaca P.

Posteriormente, Silveira (2014) complementou essa análise com as mudanças dos parâmetros representativos da estratigrafia do solo ao longo do fuste, por meio das seguintes variáveis: NF = número representativo dos valores de N_{SPT} ao longo do fuste da estaca (golpes/30cm); NP = N_{SPT} na ponta da estaca (golpes/30cm); d = profundidade da camada de influência da carga em relação à ponta da estaca (m); Arg = fator representativo de solo argiloso ao longo do comprimento da estaca (m/m); Sil = fator representativo de solo siltoso ao longo do comprimento da estaca (m/m); Ar = fator representativo de solo arenoso ao longo do comprimento da estaca (m/m).

2.8 CORRELAÇÃO ENTRE AS VARIÁVEIS

Filho Figueiredo e Júnior Silva (2009) definem a correlação de Pearson como a medida da variância associada a duas variáveis. O melhor padrão de relacionamento entre duas variáveis ocorre por meio de uma linha reta nas análises gráficas. Este parâmetro varia entre -1 e +1, sendo que o sinal

indica a direção positiva ou negativa do relacionamento e o valor sugere a força da relação entre as variáveis.

Dessa forma, quanto mais próximo de 1 for o valor, maior é a correlação positiva entre os dados, ou seja, quando um dado aumenta o outro também aumenta; quanto mais próximo de -1 for o valor, maior a correlação negativa, ou seja, quando um dado aumenta o outro diminui; e quando for igual a 0 as variáveis não apresentam uma relação linear entre elas.

3 METODOLOGIA

3.1 BANCO DE DADOS

Para a realização deste estudo foi elaborado um banco de dados com informações de ensaios SPT e provas de carga para cada estaca analisada, conforme apresentado na tabela 1 e na tabela 2.

Tabela 1. Variáveis do banco de dados.

Id	Tipo	Origem
Local	Cidade	PCE
T	Tipo de fundação	PCE
L	Comprimento da estaca (m)	PCE
D	Diâmetro da estaca (m)	PCE
Q_{trab}	Carga de trabalho da estaca (tf)	Projeto
N_F	N _{SPT} representativo do fuste	SPT
N_P	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
k	Coefficiente de mola (kN/mm)	Calculado pela PCE

Destaca-se que para cada estaca, foi calculado um número de coeficientes de mola correspondente ao número de carregamentos realizados dentro do trecho elástico da curva (tabela 2 e figura 3).

Dessa forma, observa-se na tabela 2 que para a estaca E29A obtiveram-se cinco coeficientes

de mola diferentes (1782, 1912, 468, 296 e 236), cada um destes correspondentes a um carregamento respectivo do trecho elástico (785 kN, 196 kN, 392 kN, 588 kN e 785 kN).

Tabela 2. Estruturação dos dados.

da	N	SP1_E29A
	Local	Aguas Claras
	T	HC*
	L	23
	D	0,6
Dados Estaca	Q_{trab}	392
	NF- Σ	299
	NF-Med	13
	NF- Σ Pond	89
	NF-Med Pond	8
Sondagem	NP	63
	d	0
	Arg	1
	Sil	0
	Ar	0
	P₁	49
	ρ_1	0,0275
	k₁	1782
	P₂	196
Prova de carga	ρ_2	0,1025
	k₂	1912
	P₃	392
	ρ_3	0,8375
	k₃	468
	P₄	588
	ρ_4	1,9850
	k₄	296
	P₅	785
	ρ_5	3,325
k₅	236	

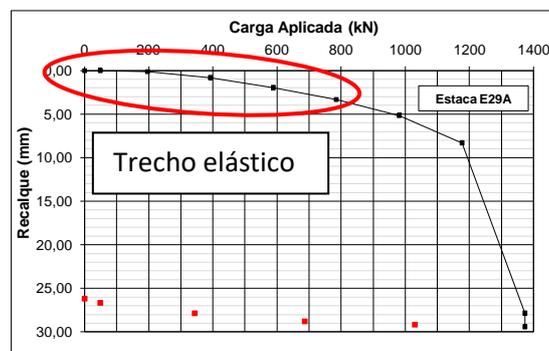


Figura 3. Prova de Carga E29A.

O banco de dados foi elaborado com base nos trabalhos de Amâncio (2013), Silveira (2014)

e Araújo (2015), somando as variáveis: k (coef. de mola) por estágio de carregamento, Q_{trab} (carga de trabalho da estaca) e local.

Os tipos de estacas (T) não foram descritos como valores numéricos, e sim como rótulos. Sendo necessário um tratamento dos dados no momento de criação do modelo de predição.

Foram analisadas 104 (cento e quatro) provas de carga e 104 (cento e quatro) ensaios de sondagem SPT. Sendo 232 (duzentos e trinta e duas) estacas escavadas e 458 (quatrocentos e cinquenta e oito) estacas hélices contínua.

O valor médio de profundidade para as estacas hélice contínua foi de aproximadamente 18 m, já para as estacas escavadas foi de 13 m.

3.2 ALGORITMO PYTHON

O algoritmo utilizado para gerar o modelo de predição do coeficiente de mola foi implementado por meio da linguagem *Python*. O código foi escrito na aplicação *Jupyter Notebook*, plataforma *web* de desenvolvimento de código *open-source*.

Para a criação do código foi realizada a limpeza de dados, com o objetivo de torná-los aplicáveis para as análises. Posteriormente, foi realizada a análise de dados, buscando encontrar as características do *dataset*, sendo possível assim estabelecer a representatividade desse estudo e os atributos mais relevantes para a análise.

Por fim, foi criado o modelo de predição do coeficiente de mola utilizando técnicas de *machine learning* com validação da eficiência do modelo por meio de métricas estabelecidas pela bibliografia técnica.

Para validação do modelo, o banco de dados foi separado em dados de treino e dados de teste, sendo assim possível calcular ao final a acurácia do modelo e avaliar sua precisão em relação aos dados reais do conjunto de teste, e os dados previstos pelo modelo através do aprendizado do conjunto de treino. O método *train_test_split* faz a separação desses dados de forma aleatória.

A acurácia do modelo foi calculada pelo erro médio absoluto.

4 ANÁLISE DOS RESULTADOS

4.1 CARACTERIZAÇÃO DOS DADOS

A localização de estudo das provas de carga analisadas, se encontra representada na figura 3.

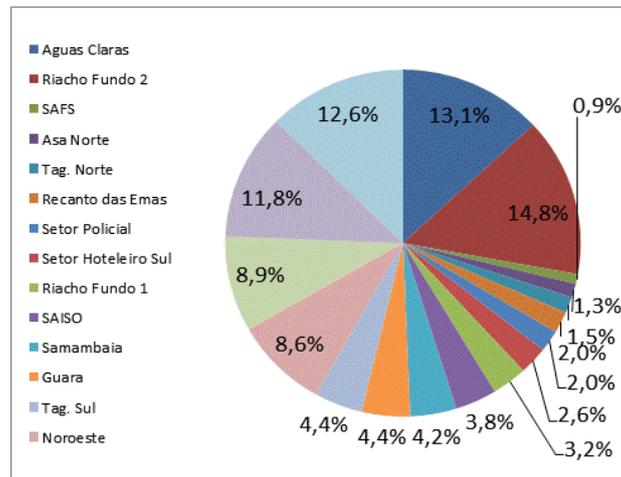


Figura3. Gráfico representativo das regiões.

Observa-se que a região com maior representatividade é o Riacho Fundo 2, seguido de Águas Claras.

A Figura 4 apresenta a variação do diâmetro em relação à profundidade das estacas.

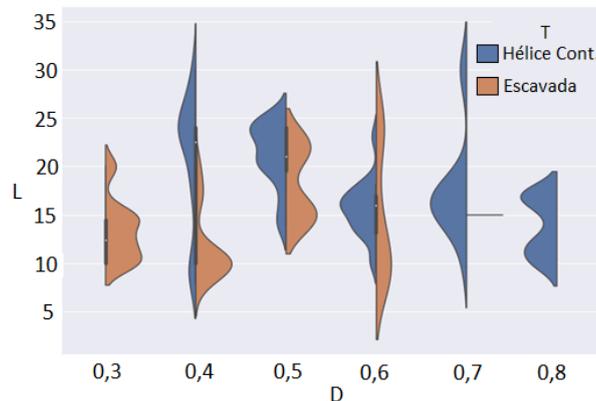


Figura 4. Variação dos diâmetros em relação à profundidade.

Observa-se que os diâmetros com maior variação na profundidade foram de 0,4 metros para hélices contínuas e de 0,6 metros para estacas escavadas.

No geral, as estacas hélice contínua têm os maiores diâmetros e as maiores profundidades, porém é possível observar que existe uma grande quantidade de estacas escavadas com diâmetro de 0,6 m variando sua profundidade entre 5 a 30 metros.

A figura 5 apresenta a dispersão dos dados de coeficiente de mola em relação à média.

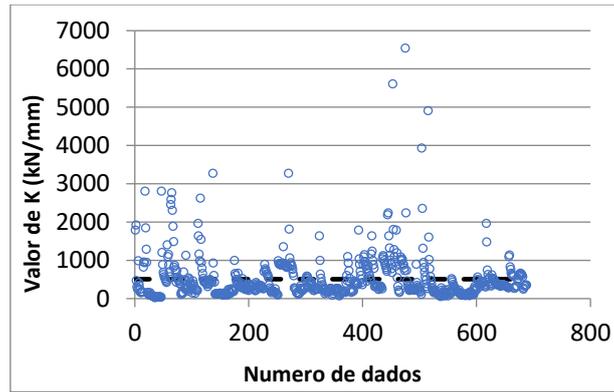


Figura 5. Coeficiente de mola em relação à média.

O valor médio do coeficiente de mola foi de 507 kN/mm, ou seja, esse valor resume de forma geral o universo de dados analisados.

Observa-se que a variabilidade dos dados em relação à média (linha tracejada) foi considerada representativa, pela maioria dos dados terem se apresentado próximos à média.

Foram encontrados os valores de 592 kN/mm como desvio padrão, 22kN/mm como valor mínimo, 6538 kN/mm como valor máximo e 202 kN/mm, 327 kN/mm e 605 kN/mm como quartis estatísticos correspondentes a 25%, 50% e 75%, respectivamente.

A figura 6 apresenta o histograma do coeficiente de mola.

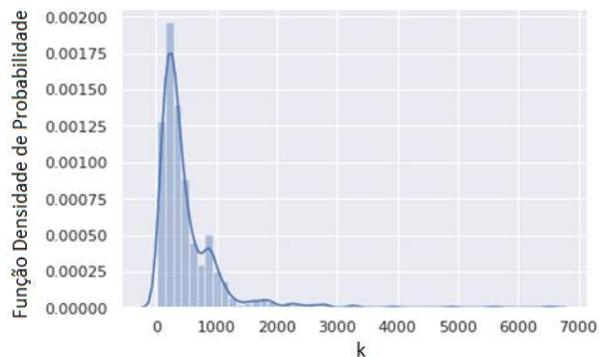


Figura 6. Histograma do coeficiente de mola.

Observa-se que a cerca de 90% dos dados se encontra entre o intervalo de 0 a 1000 kN/mm.

4.2 AVALIAÇÃO DE DESEMPENHO DO MODELO

A tabela 3 apresenta uma comparação entre os três valores com maior dispersão previstos pelo modelo com os valores reais do banco de dados.

Tabela 3. Valores previstos e reais do k .

Valor Real (Data Train)	Valor Previsto (Data Test)
232	238
211	223
388	355

Observa-se na tabela 3, que os valores reais e os valores previstos foram bem próximos, apresentando variação máxima de 9,3%.

A figura 7 apresenta a implementação de cálculo para obtenção da acurácia do modelo.

```
In [29]: # Calculando o erro médio absoluto por outro meio
errors = abs(y_pred - y_test)

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

Acurácia: 87.02 %.
```

Figura 7. Implementação do cálculo de acurácia.

Através do erro médio absoluto foi obtida uma precisão de 87,02%, o que representa uma precisão alta em comparação com a quantidade total de dados analisados.

4.3 IMPORTÂNCIA DA VARIÁVEIS

A figura 8 apresenta um gráfico de calor (*heatmap*) que permite visualizar a correlação entre os dados, por meio do coeficiente de correlação de Pearson.

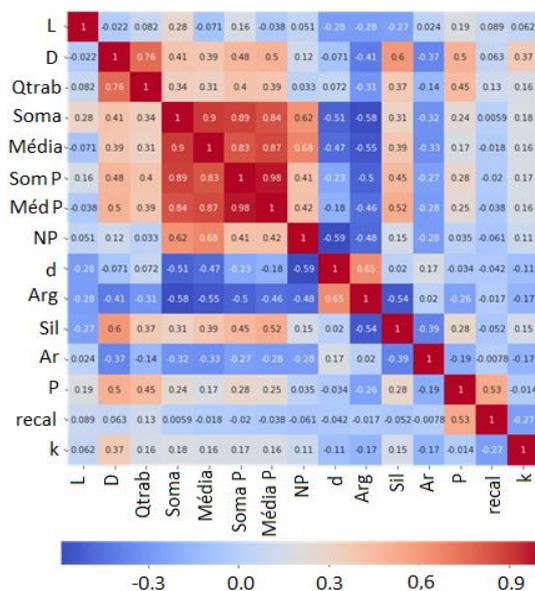


Figura 8. Gráfico de calor.

É possível observar que existe pouca relação linear entre os dados, pois os valores estão próximos de zero. A variável D (diâmetro) apresentou escore médio, indicando uma maior relação deste parâmetro com o valor do coeficiente de mola.

A figura 9 apresenta um gráfico demonstrativo da importância de cada variável para o modelo (obtida por meio da função *feature importance*, contida na biblioteca do *Python*).

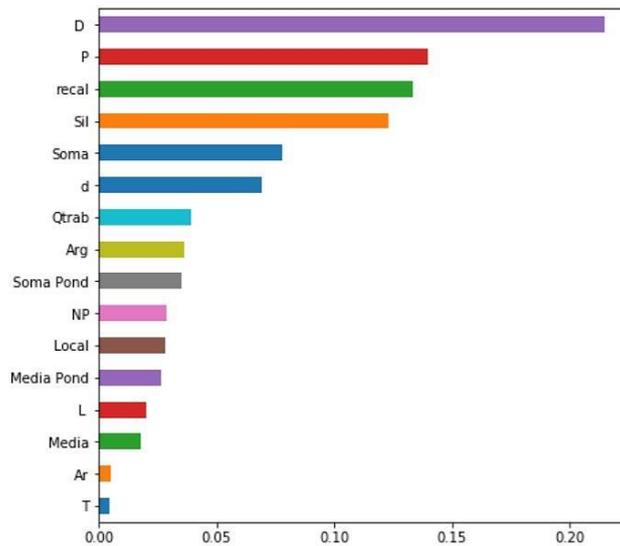


Figura 9. Gráfico representativo para a importância das variáveis no modelo.

Por meio da figura 9 é possível observar que o recalque e a carga aplicada são uns dos parâmetros que apresentam maior influência para a previsão do coeficiente de mola, o que já era esperado uma vez o 'k' é calculado diretamente através destes valores. Porém, o diâmetro da estaca foi a variável com maior valor de importância para previsão no modelo gerado. Isso pode ser explicado, pois o diâmetro da estaca influencia diretamente o cálculo do recalque das estacas e a distribuição dos carregamentos para o solo de fundação.

Com relação aos parâmetros provenientes da sondagem SPT, o valor representativo da quantidade de silte e a soma do N_{SPT} ao longo do fuste da estaca, foram as variáveis que apresentaram maior representatividade. Isso ocorreu, pois, a maior parte das estacas analisadas apresentou-se assente em camadas de silte, enquanto a soma do N_{SPT} está relacionada com a resistência do solo.

5 CONSIDERAÇÕES FINAIS

Os resultados mostram que o modelo proposto para previsão do coeficiente de mola funciona de forma satisfatória, entretanto, existem ressalvas com relação à precisão do modelo, sendo possível, ainda, melhorá-la aumentando a quantidade de dados a serem implementados.

É importante ressaltar a grande variabilidade geotécnica e heterogeneidade dos solos tropicais residuais, sendo assim, por mais que se realize um grande número de sondagens, dificilmente as condições do solo local analisado será precisamente caracterizado. Outra consideração é a pouca representatividade da sondagem SPT como parâmetro de rigidez do solo.

Destaca-se que existem limitações intrínsecas ao resultado final com a utilização do modelo de aprendizado supervisionado utilizado (*random forest*). Um exemplo claro disso é que quanto maior a dispersão dos dados, menor é a capacidade deste modelo em se adaptar. É possível que modelos mais avançados como redes neurais e outras técnicas de *deep learning* (aprendizado profundo), consigam obter resultados mais precisos.

REFERÊNCIAS

- Alonso, U. R. (2018). *Projeto e Execução de Fundações Rasas* – Notas de aula do curso Engeduca, Abril/Maio de 2018, p. 31.
- Associação Brasileira de Normas Técnicas (2006). *NBR 12131: Estacas – Prova de Carga Estática – Método de Ensaio*, Rio de Janeiro, p. 8.
- Associação Brasileira de Normas Técnicas (2010). *NBR 6122: Projetos e Execução de Fundações*, Rio de Janeiro, p. 8.
- Associação Brasileira de Normas Técnicas (2001). *NBR 6484: Solo – Sondagens de simples reconhecimento com SPT – Método de ensaio*, Rio de Janeiro, p. 17.
- Amâncio, L. B. (2013). *Previsão de Recalques em Fundações Profundas Utilizando Redes Neurais Artificiais do tipo Perceptron*, Dissertação de Mestrado, Departamento de Engenharia Civil, Universidade Federal do Ceará, 94 p.
- Araújo, C. B. C. (2015). *Aplicação de Redes Neurais Artificiais do tipo Perceptron na Estimativa de Recalques em Estacas*, Dissertação de Mestrado, Departamento de Engenharia Civil, Universidade Federal do Ceará, 82 p.
- Bahia, G. A. D. (2015). *Avaliação do Desempenho de Fundações em Edificação no DF com a Utilização de Técnicas de Interação Solo-Estrutura*, Dissertação de Mestrado, Programa de Pós-Graduação em Geotecnia, Departamento de Engenharia Civil, Universidade de Brasília, 266 p.
- Carvalho, J. C.; Silva, C. M.; Paolucci, H. V. N.; Gonzalez, Y. V. e Valencia, L. A. L. (2008). *Considerações sobre a Análise dos Resultados de Prova de Carga Estáticas*, SEFE IV – Seminário de Engenharia de Fundações Especiais e Geotecnia, São Paulo, V. 1, pp. 355-369.
- Cintra, J. C. A.; Aoki, N. e Albiero, J. H. (2011). *Fundações Diretas: Projeto Geotécnico*, Oficina de

Textos, 1a ed., São Paulo, 136 p.

- Filho Figueiredo, D. B. e Junior Silva, J. A. (2009). *Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r)*, Revista Política Hoje, V. 18, n. 1, Pernambuco, pp. 115-146.
- Martins, D. H. D. S. S., Prego, T. D. M., Lima, A. A. (2016). *Classificação de Severidade de Falhas em Máquinas Rotativas usando Random Forest e Redes Neurais Artificiais*. Encontro Nacional de Inteligência Artificial e Computacional, 13-24.
- Silva, C. M.; Carvalho, J. C. (2010). *Monitoramento e Controle de Qualidade dos Estaqueamentos Tipo Hélice Contínua Durante a Execução da Obra*, XV Congresso Brasileiro de Mecânica dos Solos, V. 1, Gramado, pp. 1-12.
- Silveira, M. V. (2014). *Modelo Neuronal para previsão de Recalques em Estacas Hélice Contínua, Metálica e Escavada*, Dissertação de Mestrado, Centro de Tecnologia, Universidade Federal do Ceará, pp. 62-70.
- Tripathi, A. (2017). *Practical Machine Learning: Resolving and Offering Solutions to your Machine Learning Problems with R*, Birmingham: Packt Publishing Ltd, 1a ed., 543 p.
- Ingold, T.S. e Miller, K.S. (1983). Drained Axisymmetric Loading of Reinforced Clay, *Journal of Geotechnical Engineering*, ASCE, Vol. 109, p. 883-898.
- Leshchinsky, D. e Perry, E.B. (1987) A Design Procedure for Geotextile Reinforced Walls, *Geosynthetics'87*, IFAI, New Orleans, LA, USA, Vol. 1, p. 95-107.
- Silva, A.R.L. (1995) *Análise de Estabilidade de Aterros Reforçados Sobre Solos Moles*, Dissertação de Mestrado, Programa de Pós-Graduação em Geotecnia, Departamento de Engenharia Civil, Universidade de Brasília, 183 p.
- Terzaghi, K. e Peck, R.B. (1987) *Soil Mechanics in Engineering Practice*, 2nd ed., McGraw Hill, New York, NY, USA, 685 p.