



Centro Universitário de Brasília – UniCEUB  
Faculdade de Tecnologia e Ciências Sociais Aplicadas – FATECS  
Curso de Engenharia Civil

YURI MIGUEL DE OLIVEIRA

**MACHINE LEARNING APLICADO NA ESTIMATIVA DO  
COEFICIENTE DE MOLA DE ESTACAS COM VALIDAÇÃO POR  
MEIO DE PROVAS DE CARGA ESTÁTICAS**

Brasília-DF

2018

YURI MIGUEL DE OLIVEIRA

**MACHINE LEARNING APLICADO NA ESTIMATIVA DO  
COEFICIENTE DE MOLA DE ESTACAS COM VALIDAÇÃO POR  
MEIO DE PROVAS DE CARGA ESTÁTICAS**

Trabalho de conclusão de curso  
apresentado ao Centro Universitário  
de Brasília (UniCEUB), como  
exigência final para obtenção do  
título de graduação em Engenharia  
Civil

Orientadora: Prof. (a) Msc. Gabriela  
de Athayde Duboc Bahia

Brasília  
2018

YURI MIGUEL DE OLIVEIRA

**MACHINE LEARNING APLICADO NA ESTIMATIVA DO  
COEFICIENTE DE MOLA DE FUNDAÇÕES PROFUNDAS COM  
VALIDAÇÃO POR MEIO DE PROVAS DE CARGA ESTÁTICAS**

Monografia apresentada ao Centro  
Universitário de Brasília (UniCEUB),  
como exigência final para obtenção  
do título de graduação em  
Engenharia Civil

Orientadora: Prof. (a) Msc. Gabriela  
de Athayde Duboc Bahia

Brasília, \_\_\_\_ de \_\_\_\_\_ de 2018

**Banca Examinadora**

---

Prof. (a):  
Orientador(a)

---

Prof.(a):  
Examinador (a)

---

Prof. (a):  
Examinador (a)

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, que me deu amparo e sabedoria para conquistar mais este objetivo de vida.

Aos meus pais, Reginaldo Soares e Ruth Miguel, e a todos os meus familiares que foram meu alicerce durante essa longa caminhada, sempre acreditando no meu potencial e oferecendo-me todo incentivo, apoio e cuidado.

A todos os meus colegas e professores do curso técnico em edificações do Instituto Federal de Brasília, em especial a Professora Larissa Andrade, por estar sempre ao meu lado ajudando-me a perseverar e nunca desistir.

A todos os meus amigos e companheiros de faculdade, em especial, Gustavo Sobral, Issac Ramon e Diego Soares, por todo companheirismo durante o curso.

Aos professores, Fernando Rodrigo e Marcos Vinicius, que me guiaram neste processo e foram fonte de inspiração e cuidado em minha vida acadêmica.

À minha orientadora Gabriela Duboc, que foi a primeira a acreditar no potencial deste trabalho e por toda disposição, cuidado e carinho que tornou possível a conclusão desta monografia.

E por fim, agradeço a todo o corpo docente do Centro Universitário de Brasília – Uniceub, por me proporcionar uma experiência única durante estes 5 anos de caminhada.

*"Ninguém baterá  
tão forte quanto a vida. Porém, não se  
trata de quão forte você consegue  
bater, se trata de quanto você  
consegue apanhar e continuar  
seguindo em frente, o quanto você  
consegue ser atingido e continuar  
lutando. É assim que a vitória é  
conquistada."*

Rocky Balboa

## RESUMO

Na concepção dos projetos estruturais é comum a utilização do coeficiente de mola na tentativa de melhorar a representatividade global das deformações impostas a uma edificação durante a sua vida útil. Isso implica em construções mais duráveis e possibilidade de diminuição dos valores de coeficiente de segurança propostos aos projetos. Porém, a determinação deste parâmetro, ainda hoje, é feita de forma empírica, e são poucos os estudos voltados a entender melhor sua correlação com a rigidez do solo. Neste presente trabalho, estudou-se um modelo de predição do coeficiente de mola de forma a correlacionar dados de provas de carga e sondagens SPT para estacas do tipo escavada e hélice continua executadas em solos da região do Distrito Federal. Primeiramente, criou-se um banco de dados por meio de provas de carga e sondagens. Posteriormente, a criação de um algoritmo capaz de prever o valor do coeficiente de mola, utilizando técnicas de *machine learning* fundamentadas no aprendizado supervisionado. Finalmente foi avaliada a capacidade de aprendizado deste modelo em relação aos dados analisados. Essa proposição demonstrou ser promissora para o avanço destes estudos, sendo obtido um valor de 87% de precisão para um campo amostral de 688 (seiscentos e oitenta e oito). Dessa forma, este estudo colabora para a elaboração de uma nova metodologia de controle de qualidade de estruturas e fundações.

**PALAVRAS-CHAVE:** Coeficiente de Mola. Provas de Carga. Sondagens SPT. *Machine Learning*. Aprendizado. Supervisionado.

## SUMÁRIO

1. INTRODUÇÃO .....	11
1.1. OBJETIVO .....	12
1.1.1. Objetivo Geral .....	12
1.1.2. Objetivo Específico .....	12
2. REVISÃO BIBLIOGRÁFICA.....	13
2.1. Generalidades.....	13
2.2. Prova de carga.....	14
2.2.1. Execução da prova de carga.....	14
2.2.2. Quantidade de ensaios .....	15
2.2.3. Curva carga x recalque.....	16
2.2.4. Critérios de ruptura .....	18
2.2.5. Fator de segurança.....	19
2.3. Caracterização do solo por meio de sondagens à percussão (SPT) .....	19
2.4. Mecanismo de transferência de carga.....	21
2.4.1. Metodologia Carvalho <i>et al.</i> .....	21
2.4.2. Modelo de transferência de carga TQS .....	24
2.5. Modelo de Winkler (1867) – Coeficiente de mola .....	25
2.5.1. Coeficiente de reação vertical (CRV).....	25
2.6. Aprendizado de máquinas ( <i>machine learning</i> ) .....	27
2.6.1. Tipos de aprendizado de máquinas .....	28
2.6.2. Clusterização de dados ( <i>clustering</i> ) .....	28
2.6.3. Árvore de regressão .....	29
2.6.4. <i>Random Forest</i> .....	29
2.6.5. Definição das variáveis de entrada .....	30
2.6.6. Correlação entre as variáveis (Método de Pearson).....	32
3. METODOLOGIA .....	34
3.1. Banco de dados .....	34
3.2. Algoritmo Python.....	35
3.3. Erro médio Absoluto .....	37
4. RESULTADOS E ANÁLISES.....	38
4.1. Caracterização dos dados.....	38
4.2. Avaliação de Desempenho do Modelo .....	44

4.3. Importâncias das Variáveis .....	44
5. CONSIDERAÇÕES FINAIS .....	46
5.1 Sugestões Para Pesquisas Futuras.....	47
REFERÊNCIAS BIBLIOGRÁFICAS.....	48



## LISTA DE FIGURAS

Figura 1: Curva carga x recalque com trechos.....	17
Figura 2: Curva carga versus teórica.....	17
Figura 3: Extrapolação da curva carga x recalque com os critérios de ruptura.....	19
Figura 4: Gráfico Deslocamento x Tempo.....	22
Figura 5: Gráfico carga x recalque imediato.....	23
Figura 6: Gráfico carga x recalque secundário.....	23
Figura 7: Diagrama de atrito lateral (Manual teórico TQS, p.97).....	24
Figura 8: Representação do sistema de molas em estacas.....	26
Figura 9: Trecho correspondente ao comportamento elástico da estaca.....	27
Figura 10: Diagrama representando o processo de clusterização.....	29
Figura 11: Exemplo de árvore de decisão com dois parâmetros.....	30
Figura 12: Determinação da variável NP e cálculo da variável NF.....	32
Figura 13: Relação linear entre dados.....	33
Figura 14: Implementação do modelo Random Forest.....	36
Figura 15: Fluxograma representativo para o modelo preditivo.....	37
Figura 16: Coeficiente de recalque em relação à média.....	39
Figura 17: Histograma do coeficiente de reação vertical.....	39
Figura 18: Gráfico representativo das regiões.....	40
Figura 19: Média das profundidades para cada tipo de estaca.....	41
Figura 20: Gráfico de calor com a correlação entre os dados.....	41
Figura 21: <i>Boxplot</i> da variação dos diâmetros em relação a profundidade para cada tipo de estaca.....	42
Figura 22: Quantidade de estacas para cada diâmetro.....	43
Figura 23: Variação dos diâmetros em relação a profundidade.....	43
Figura 24: Implementação do cálculo de acurácia do modelo.....	44
Figura 25: Gráfico representativo para a importância das variáveis no modelo.....	45

## LISTA DE TABELAS

Tabela 1: Quantidade de provas de carga.....	15
Tabela 2: Estruturação dos dados .....	34
Tabela 3: Descrição dos dados do <i>dataset</i> . .....	38
Tabela 4: Descritivo do quantitativo de estacas.....	40
Tabela 5: Comparação entre os valores previstos e reais do Kv. ....	44

## LISTA DE QUADROS

Quadro 1: Variáveis do banco de dados .....	35
Quadro 2: Bibliotecas utilizadas dentro do algoritmo .....	35

## 1. INTRODUÇÃO

Na engenharia, buscam-se melhorar continuamente os processos construtivos, a fim de garantir qualidade estrutural 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 (menor dimensão) superior a quatro; estruturas nas quais a carga variável é expressiva comparada à carga total (silos e reservatórios) e fundações ou estruturas não convencionais.

Ainda em sua atualização, com o intuito de melhorar as análises estruturais, a NBR 6122 (ABNT, 2010) contemplou a abordagem dos 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 ou fundação-estrutural.” (NBR 6122, 2010, pp.13).

Como uma alternativa para a consideração da interação solo-estrutura (ISE) nos modelos estruturais, os *softwares* aparecem como uma ferramenta de grande valia. A sua utilização permite implementar em seus modelos a análise elástica da superestrutura junto às fundações, ou seja, não mais se considera o engastamento do pilar em sua base, utilizam-se, agora, os recalques provenientes das fundações por meio do coeficiente de mola, permitindo a transmissão de momento para o pilar. Entretanto, o conhecimento desse parâmetro ainda é pouco difundido no mercado, além de ser difícil a sua correlação direta com a rigidez do solo. Para a definição do valor do coeficiente de mola, muitos projetistas utilizam tabelas empíricas, onde nem sempre a relação dos dados reflete de forma satisfatória a realidade geotécnica encontrada em seus projetos. Isso implica em aumentar o nível de incerteza nas considerações de projeto, sendo necessária aplicação de fatores de segurança mais rígidos. Porém, vale ressaltar que os resultados não são necessariamente satisfatórios a todos os casos, além de agregar custos maiores para o dimensionamento da estrutura.

Nesse contexto, o uso da Inteligência Artificial (IA) em análises de bancos de dados passa a ser para a engenharia, uma técnica de grande valia, pois sua utilização permite a obtenção de parâmetros competentes.

Perasso (2016), entende a 4<sup>o</sup> revolução industrial como a união de tecnologias digitais, físicas e biológicas. Sendo, portanto, a nova fase da industrialização uma convergência para uma gama de possibilidades relacionadas aos processos construtivos.

## **1.1. OBJETIVO**

### **1.1.1. Objetivo Geral**

Este trabalho tem por objetivo fazer a estimativa do coeficiente de mola vertical para fundações profundas do tipo estacas por meio da inteligência artificial, e realizar a validação dos dados com a utilização de provas de carga e relatórios de sondagem para obras executadas dentro do Distrito Federal.

### **1.1.2. Objetivo Específico**

Os objetivos específicos deste trabalho são:

- Gerar um banco de dados para provas de carga e sondagens SPT executadas em obras do Distrito Federal;
- Calcular o coeficiente de mola vertical utilizando inteligência artificial;
- Propor um modelo por meio de métodos de análise de dados para correlação e estimativa do coeficiente de mola vertical em fundações do tipo estaca dentro do contexto dos solos do Distrito Federal;
- Analisar os dados obtidos com o objetivo de verificar a sua validação e justificar a sua utilização para criação do modelo.

## 2. REVISÃO BIBLIOGRÁFICA

### 2.1. Generalidades

Para a concepção de um projeto estrutural é comum desconsiderar o deslocamento dos apoios devido ao recalque das fundações. Porém, isso implica na utilização de fatores de segurança maiores, a fim de se evitar perda de qualidade nos projetos por incertezas geotécnicas. Cintra e Aoki (2011) definem que a estrutura é composta por um sistema único dividido em dois subsistemas: estrutural e geotécnico. Esse sistema está sujeito a ações permanentes, variáveis e excepcionais. As atuações dessas forças externas geram solicitações internas na estrutura chamadas de esforços solicitantes.

Na engenharia de fundações o recalque é um dos responsáveis pela ocorrência das manifestações patológicas existentes em edificações. Esse é um desafio que tem guiado a engenharia geotécnica a entender o comportamento da interação-solo estrutura (ISE) e sua aplicação na análise estrutural. A consideração desse tipo de análise pode aumentar a confiabilidade do projeto, aproximando-a ao comportamento real da edificação. Dessa forma, demonstra-se a importância de analisar a concepção do projeto estrutural como um todo, não apenas focando na superestrutura.

Para engenheiros de fundações, têm particular interesse as solicitações que se desenvolvem nas seções de transição da superestrutura para a infraestrutura, as seções correspondentes ao topo das fundações, bem como os deslocamentos verticais para baixo dessas seções (os recalques das fundações). (CINTRA e AOKI, 2011, pp.10)

O uso do coeficiente de mola auxilia nessa união da superestrutura com a fundação, pois a consideração da conexão entre esses dois elementos deixa de ser uma ligação engastada passando a ser considerada como uma ligação flexibilizada, ou seja, consideram-se os deslocamentos da fundação provados pelo solo. Um dos principais trabalhos para o cálculo do coeficiente de mola é realizado por meio do modelo de Winkler (1867).

Com o intuito de realizar esta análise, é necessário o conhecimento do mecanismo de transferência de carga entre a fundação e o solo, além de estipular um modelo capaz de descrever o comportamento do solo em relação à dissipação das cargas provenientes da superestrutura.

Sendo assim, este trabalho abordará o cálculo do coeficiente de mola por meio de ensaios de prova de carga em fundações profundas do tipo estacas.

## **2.2. Prova de carga**

A prova de carga é um método de análise direta da capacidade de suporte de carga, podendo ser realizada em diversos tipos de estruturas. Este trabalho aborda provas de carga do tipo estáticas em fundações profundas.

### **2.2.1. Execução da 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.

“O primeiro modo de se estabelecer a capacidade de carga contra a ruptura de uma estaca é realizar uma prova de carga sobre a mesma” (ALONSO, 2011, pp. 59).

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 ruptura do elemento estrutural, sendo este carregamento aplicado em estágios de incremento de carga, sendo esta aplicada em estágios de incremento de carga de 20% da carga admissível de projeto para o ensaio do tipo lento. Cintra e Aoki (2011) definem que ao aplicar-se a carga prevista no estágio, os recalques começam a ocorrer, provocando um alívio de carga, o que exige a sua reposição sistemática.

Desse modo, são programados tempos de leitura de deslocamento da estaca a fim de se controlar a estabilização do recalque em cada incremento de carga. Vale ressaltar, que em cada estágio de carregamento, a carga deve ser mantida por um tempo mínimo de 30 minutos até a estabilização dos recalques. Sendo o período de aferição dos recalques estabelecidos em  $t = 2\text{min}, 4\text{min}, 8\text{min}, 15\text{min}, 30\text{min}$  e  $60\text{min}$ , após esse período a leitura é realizada de hora em hora. 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.

Ao total são aplicados 10 (dez) estágios de incremento de carga ou até que se atinja 1,6 a carga de trabalho, em caso de avaliação de desempenho. No final desse processo, caso não haja a ruptura do elemento de fundação, é necessário manter a estaca sobre pressão do último estágio por um período de 12 horas.

### 2.2.2. Quantidade de ensaios

A quantidade de ensaios é determinada pela NBR 6122 (ABNT, 2010) sendo apresentado na Tabela 1 o número de ensaios mínimo obrigatório para cada tipo de estaca. Vale destacar que para estaqueamentos com quantidade superior a 500 estacas é possível trabalhar com uma porcentagem menor. Além disso, é permitido fazer uma compatibilização entre ensaios estáticos e dinâmicos na proporção de um ensaio estático para cinco dinâmicos.

Tabela 1: Quantidade de provas de carga

Tipo de estaca	A	B
	Tensão (admissível) máxima abaixo da qual não serão obrigatórias provas de carga, desde que o número de estacas da obra seja inferior à coluna (B), em MPa <sup>bcd</sup>	Número total de estacas da obra a partir do qual serão obrigatórias provas de carga <sup>bcd</sup>
Pré-moldada <sup>a</sup>	7,0	100
Madeira	-	100
Aço	0,5 $f_{yk}$	100
Hélice e hélice de deslocamento (monitoradas)	5,0	100
Estacas escavadas com ou sem fluido $\phi \geq 70$ cm	5,0	75
Raiz <sup>e</sup>	15,5	75
Microestaca <sup>e</sup>	15,5	75
Trado segmentado	5,0	50
Franki	7,0	100
Escavadas sem fluido $\phi < 70$ cm	4,0	100
Strauss	4,0	100

Notas:

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

<sup>b</sup> Os critérios acima são válidos para as seguintes condições (não necessariamente simultâneas):

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



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

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

<sup>e</sup> Diâmetros nominais.

---

Fonte: (NBR 6122 ABNT, 2010, pp.36)


Quando a prova de carga for previamente executada, os resultados permitem ao projetista determinar qual a melhor configuração do comprimento das estacas, qual seria o valor do recalque admissível e qual seria a carga de trabalho do estaqueamento. Segundo Alonso (2011) o conceito de recalque admissível, pelo menos para os prédios, está intimamente ligado à tradição da comunidade. Sendo assim, a prova de carga é um procedimento primordial para o aprimoramento da experiência.

“A realização de provas de carga em uma quantidade estatisticamente representativa, possibilita a determinação do valor médio de resistência, necessário para o cálculo (não determinístico) do fator de segurança global real, e da curva de resistência, que permite a análise de confiabilidade da fundação, com a estimativa da probabilidade de ruína. ” (CINTRA E AOKI, 2011, pp.70)

### 2.2.3. Curva carga x recalque

Segundo Cintra *et al* (2013) o principal produto do ensaio é a curva carga x recalque,  $P \times \rho$ , em que  $P$  é a carga aplicada no topo da estaca, representada no eixo das abscissas, e  $\rho$  é o recalque do topo da estaca, representado no eixo das ordenadas. Os autores afirmam ainda que os pontos da curva são referentes ao final de cada estágio de carregamento. A Figura 1 mostra a conformação da curva, onde os seguimentos horizontais representam a trajetória de carga durante o período de aplicação do estágio, enquanto os seguimentos verticais indicam o recalque durante o período de carga mantido. É possível observar esse efeito na curva carga recalque tanto para o segmento de carregamento quanto para o descarregamento do sistema.


Figura 1: Curva carga x recalque com trechos.



Fonte: CINTRA *et al* (2013, pp.71)

Massad (1992) define o desenvolvimento de uma curva carga *versus* recalque teórica da estaca por meio dos intervalos (0-3, 3-4, 4-5 e 5-6) apresentados na Figura 2.

Figura 2: Curva carga versus teórica.



Fonte: MASSAD (1992, apud, MENEZES, CARVALHO, ALBUQUERQUE, 2005, pp.5)

– Trecho 0-3: definido como um trecho retilíneo, ocorrendo devido à fase pseudo-elástica de mobilização do atrito lateral, ao longo da reta inicial da primeira lei ou relação de Cambefort. O ponto 3 acusa o momento em que o atrito lateral atinge o seu máximo valor no topo da estaca.;

- Trecho 3-4: representa ao avanço da “plena mobilização” do atrito lateral ao longo do fuste. Nesse intervalo observa-se um esboço de formato em curva ou ainda de uma parábola;
- Trecho 4-5: a relação carga versus recalque no topo da estaca volta a ser de forma linear. Nesse intervalo, surge a mobilização da resistência de ponta, correspondente ao trecho pseudo-elástico da segunda relação de Cambefort.
- Trecho 5-6: nesse trecho, chega-se ao valor de carga máxima total da estaca em que a reação de ponta atinge seu valor máximo;
- Trecho 6-7: corresponde, no descarregamento, ao primeiro trecho do estágio de carregamento da estaca (0-3), isto é, trata-se da fase pseudo-elástica da volta na relação de Cambefort;
- Trecho 7-8: analogamente, corresponde ao trecho 3-4, que representa um trecho curvilíneo, no sentido reverso da curva (para o descarregamento); (MENEZES, CARVALHO, ALBUQUERQUE, 2005, pp.5)

#### 2.2.4. Critérios de ruptura

Em geral os critérios de ruptura usualmente adotados pela engenharia de fundações são o de Vesic (1977) que considera o deslocamento médio, medido no topo, igual a 10% de seu diâmetro, e o critério de ruptura estipulado pela NBR 6122 (ABNT, 2010) que define a ruptura da estaca como a reta formada pela

Equação (1) quando intercepta a curva carga x recalque do ensaio.

$$\Delta r = \frac{P * L}{E * A} + \frac{D}{30} \quad \text{Equação (1)}$$

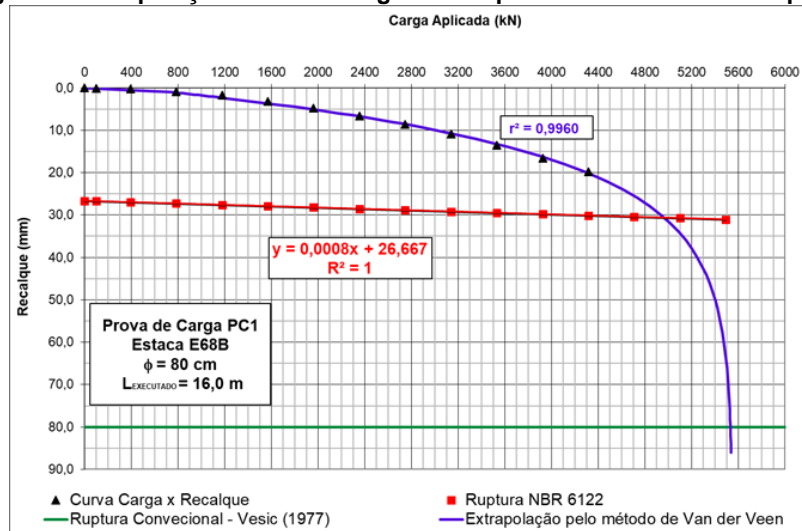
Sendo:

- $\Delta r$  = Recalque de ruptura convencional
- P = Carga de ruptura convencional;
- L = comprimento da estaca;
- E = módulo de elasticidade do material da estaca;
- D = Diâmetro do círculo circunscrito à estaca ou, no caso de barretes, o diâmetro do círculo de área equivalente ao da seção transversal desta.

Notas: As unidades devem ser compatíveis com as unidades do módulo de elasticidade.

A Figura 3 mostra a comparação entre os dois métodos de ruptura aqui apresentados.

Figura 3: Extrapolação da curva carga x recalque com os critérios de ruptura.



### 2.2.5. Fator de segurança

O fator de segurança está relacionado as 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, da variação geotécnica do maciço ou das aproximações feitas pelos métodos de cálculo de capacidade de carga. Em concordância com a NBR 6122 (ABNT, 2010) é comum multiplicar o valor da carga de trabalho da estaca por 1,6 a fim de se limitar a maior carga que será usada no ensaio, além disso, a norma estabelece que o limite de carga é de até 2 vezes o valor da carga de trabalho.

### 2.3. Caracterização do solo por meio de sondagens à percussão (SPT)

Para Cintra *et al* (2013), o ensaio SPT (*Standard Penetration Test*), consiste em três etapas: I) perfuração, II) amostragem e III) ensaio penetrométrico. Sendo as etapas II e III simultâneas enquanto a I ocorre de forma alternada entre as etapas anteriores.

A perfuração consiste em furos verticais por meio de um trado de sondagem. Para Cintra *et al* (2013) esse processo denomina-se operação de tradagem a seco. Com o avanço é possível observar se a umidade do solo aumenta, indicando neste ponto um provável indício da profundidade do nível

d'água (NA). Caso o NA seja atingido, a perfuração prossegue por um conjunto de hastes rosqueadas introduzidas por dentro do revestimento, o qual possui em sua ponta uma peça cortante chamado trépano, cuja função é desagregar o solo.

A amostragem é feita por meio da coleta de amostras do solo em diferentes pontos de profundidade, sua coleta é possível com a utilização de um cilindro vazado chamado amostrador que é colocado junto à ponta da haste no lugar do trépano.

O ensaio penetrométrico, acontece por meio da contagem do número de golpes necessários para se cravar o amostrador com um peso padronizado (65Kg) caindo em queda livre a uma altura também padronizada (75cm) (Cintra, *et al*, 2013). A cravação ocorre até a penetração dos 45 cm da haste onde é efetuada a contagem parcial para cada 15 cm.

O objetivo deste ensaio além da amostragem do solo é a determinação do valor do  $N_{SPT}$  do solo. “A resistência à penetração é também referida como o número N do SPT ou, simplesmente, como SPT do solo, sendo SPT as iniciais de *Standard Penetration Test*” (PINTO, 2006, p.47). Este valor representa a quantidade de golpes necessários para cravação do amostrador nos últimos 30 cm. Para casos onde não ocorra a penetração de todo o amostrador, Pinto (2006) define que deve-se registrar o SPT em forma de fração (por exemplo, 30/14, indicando que para 30 golpes houve penetração de 14 cm).

Os critérios de parada são definidos pela NBR 6484 (ABNT, 2001), norma brasileira para sondagem de simples reconhecimento com SPT. Os parâmetros de paralização do ensaio são:

- a) quando, em 3 m sucessivos, se obtiver 30 golpes para penetração dos 15 cm iniciais do amostrador-padrão;
- b) quando, em 4 m sucessivos, se obtiver 50 golpes para penetração dos 30 cm iniciais do amostrador-padrão;
- c) quando, em 5 m sucessivos, se obtiver 50 golpes para a penetração dos 45 cm do amostrador-padrão;

Tanto os valores do  $N_{SPT}$ , como a caracterização do solo por meio da amostragem obtida pelo ensaio, são parâmetros usados pelos projetistas na escolha do tipo de fundação.

“A resistência à penetração é um índice intensamente empregado em projetos de fundação. A escolha do tipo de fundação para prédios comuns, de 3 a 30 pavimentos, e as definições de projeto, como tipo e comprimento de estacas etc., são costumeiramente baseadas apenas nos resultados de sondagens (identificação visual e SPT), analisadas de acordo com a experiência regional e o conhecimento geológico do local”. (PINTO, 2006, p.50)

## 2.4. Mecanismo de transferência de carga


Estabelecer um mecanismo de transferência de carga é importante para definir quais são os trechos de comportamento da estaca perante a aplicação do esforço solicitante. O cálculo do coeficiente de mola deverá compreender o trecho elástico da estaca, ou seja, onde o comportamento do elemento estrutural se assemelha ao de uma mola descrita pelo modelo de Winkler (1867).

Segundo Aoki (1997), o estudo da ISE parte de uma visão integrada dos elementos que compõe os sistemas estruturais e geotécnicos. A compreensão do mecanismo de transferência de carga para o solo de uma estaca vertical isolada, atravessando as diferentes camadas de solos que compõe o maciço é o primeiro passo para o estudo de caso geral.

### 2.4.1. Metodologia Carvalho *et al*

O modelo apresenta inicialmente uma análise feita por meio da plotagem de um gráfico de **deslocamento** (mm - milímetro) em escala linear x **tempo** (min - minuto) em escala logarítmica, para cada uma das cargas aplicadas ao ensaio, sendo extraído do trecho final linear das curvas o coeficiente angular chamado pelos autores de coeficiente de recalque ( $\alpha$ ) (Figura 4).


Figura 4: Gráfico Deslocamento x Tempo.



Fonte: Oliveira (2018)

A segunda análise pode ser obtida através da plotagem do mesmo gráfico recalque x tempo, agora, porém com a representação do recalque imediato definido pelos autores como aquele ocorrido em até 4 min após a aplicação da carga para cada um dos estágios de carregamento. A partir dos dados obtidos gera-se uma curva entre as **cargas aplicadas** (kN - kilonewton) x **recalque imediato acumulado** (mm - milímetro), seguindo o procedimento de delimitação dos trechos de comportamento (Figura 5).


Figura 5: Gráfico carga x recalque imediato



Fonte: Oliveira (2018)

O terceiro e último método consiste na análise por meio dos recalques secundários, ou seja, aquele que ocorre após o tempo de 4 min de aplicação da carga (Figura 6).

Figura 6: Gráfico carga x recalque secundário.



Fonte: Oliveira (2018)

Para Carvalho *et al.* (2008 e 2010), o primeiro ponto de inflexão corresponde ao início das deformações elásticas oriundas da interação fuste-solo, ou seja, todo o atrito disposto no sistema é mobilizado apenas pelo fuste, encontrando-se no regime pseudoelástico. Porém, vale ressaltar que existe a



possibilidade de ocorrer algumas transferências de carga para a base da estaca, neste regime, dependendo das condições do maciço e da rigidez do elemento estrutural. O segundo ponto de inflexão, corresponde ao início das deformações plásticas do sistema fuste-solo, neste trecho a contribuição da base é mais abrangente e passa a receber a carga à medida que se dissipa o atrito lateral. O terceiro e último ponto seria o ponto de plastificação, onde os recalques passam a ser mais relevantes e acabam influenciando no comportamento global da fundação.


#### 2.4.2. Modelo de transferência de carga TQS

O *software* TQS em seu sistema de cálculo de fundações (Sises – Sistema de Interação Solo – Estrutura) tem por entendimento para o mecanismo de transferência de carga em estacas, o modelo apresentado por AOKI (1979).

A

Figura 7, apresenta os diagramas representativos para a distribuição do atrito lateral para cada um dos modelos apresentados.

Figura 7: Diagrama de atrito lateral (Manual teórico TQS, p.97)



Fonte: (Manual teórico TQS, p.97)

Neste caso tem-se duas condições em que a distribuição parcial da carga vai vencendo a resistência lateral máxima ao longo do fuste (Modelo A), e admite-se que a distribuição se manifeste ao longo do fuste da estaca, redistribuindo as cargas, ou seja, os atritos laterais específicos fuste-solo são

distribuídos proporcionalmente de acordo com o nível de carregamento (Modelo B).

## **2.5. Modelo de Winkler (1867) – Coeficiente de mola**

O modelo apresentado por Winkler em 1867 é um método de modelagem do solo por meio de um sistema de molas com reação linear independente entre si. Sendo essa análise feita sempre na região da fundação, desconsiderando o efeito de grupo ou outras interferências nas regiões próximas a aplicação da carga. Segundo Antoniazzi (2011) este modelo é um dos mais utilizados pela sua simplicidade, porém seu principal problema ocorre em torno da determinação da rigidez das molas elásticas usadas para substituir o solo, além de não considerar uma continuidade da dissipação das cargas ao longo da profundidade. Para Porto (2010) deve-se tomar muito cuidado na determinação numérica deste sistema, pois ele nem sempre apresenta uma correta correlação com a rigidez do solo.


### **2.5.1. Coeficiente de reação vertical (CRV)**

O manual teórico do TQS para o sistema SISEs (Sistema de Interação Solo – Estrutura) define o CRV (coeficiente reação vertical) como a rigidez do contato estaca-solo. O SISEs entende por meio do seu processo de cálculo que a estaca é resistida por meio de um conjunto de molas que se distribuem ao longo do fuste e na base da estaca, representando assim a distribuição da rigidez no elemento estrutural.

Com base nos modelos de transferência de carga já apresentados (

Figura 7), o Modelo A admitiria que o carregamento seria distribuído começando do topo até a base, sendo que cada mola será carregada e no momento da sua plastificação a carga é transferida para a mola subsequente. Já no Modelo B a transferência ocorreria de forma proporcional ao longo do fuste, acionando o sistema de molas do fuste ao mesmo tempo. Nos dois casos a base da estaca só seria solicitada a partir do momento em que o fuste-solo atingisse a plastificação (deslizamento), conforme apresentado pela Figura 8.

Figura 8: Representação do sistema de molas em estacas.



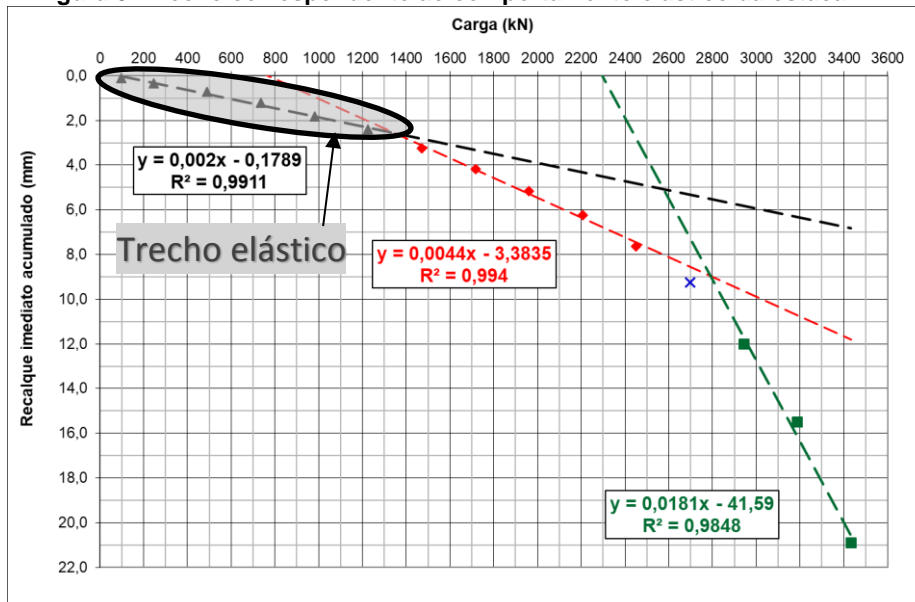
Fonte: (Manual teórico TQS, p.97)

Silva (2006) define o módulo de reação vertical ( $K_s$ ), como a razão entre a pressão em qualquer ponto da superfície de contato ( $q$ ) e o recalque produzido ( $w$ ) pela aplicação de carga na fundação (Equação 02). Sendo ainda este valor dependente das propriedades elásticas do solo e das dimensões da área sob a ação de reação do *subgrade*.

$$K_s = \frac{q}{w} \quad \text{Equação (2)}$$

Para o cálculo do  $K_s$  é preciso estabelecer na prova de carga qual é o trecho correspondente ao comportamento elástico da estaca. Para isso pode ser utilizada a metodologia de Carvalho *et al.* (2008 e 2010), em que o primeiro trecho de linearização da curva é onde encontram-se as cargas e deslocamento utilizados para cálculo do coeficiente de mola vertical (Figura 9).

Figura 9: Trecho correspondente ao comportamento elástico da estaca.



Fonte: Oliveira (2018)

A predição do valor do coeficiente de mola por meio de um método computacional baseado em provas de carga é, portanto, de grande auxílio uma vez que atualmente os projetistas ao utilizarem os *softwares* como o TQS e o Eberick precisam determinar de forma empírica o valor do  $K_s$ .

## 2.6. Aprendizado de máquinas (*machine learning*)

São muitas as definições para o termo aprendizado de máquinas, porém a primeira vez que esse termo foi utilizado foi com o engenheiro Arthur Samuels em 1959. “*Machine Learning*: Campo de estudo que dá aos computadores a capacidade de aprender sem serem programados explicitamente.” (PUGET, 2006, p.6).

Segundo Mitchell (1997, apud CARVALHO, 2011, pp.3) “A capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência.”

No AM (Aprendizado de Máquinas), utilizam-se as máquinas como meios para encontrar padrões e solucionar problemas por meio de algoritmos de análise de dados. “Diferentes algoritmos de AM, diferentes formas de utilizar os algoritmos existentes e adaptações de algoritmos são continuamente propostos.” (CARVALHO, 2011, p.4).

### 2.6.1. Tipos de aprendizado de máquinas

São três as classificações dadas aos tipos de aprendizado de máquina, sendo elas: aprendizado supervisionado (*supervised learning*), aprendizado não supervisionado (*unsupervised learning*) e aprendizado por reforço (*reinforcement learning*). O aprendizado por reforço não será abordado neste trabalho por ter uma aplicabilidade voltada para a robótica.

“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)<sup>1</sup>

“A aprendizagem não supervisionada estuda como os sistemas podem aprender a representar padrões de entrada específicos de uma maneira que reflita a estrutura estatística da coleção geral de padrões de entrada.” (Tripathi, 2017, pp. 12, tradução nossa)<sup>2</sup>

### 2.6.2. Clusterização de dados (*clustering*)

O processo de clusterização consiste em reunir grupos de dados que apresentam similaridades em suas características (Figura 10), “Cada grupo (*cluster*) consiste de objetos que são semelhantes entre si e dissimilares a objetos de outros grupos. O objetivo do agrupamento é determinar o encontro intrínseco em um conjunto de dados não rotulados”. (Tripathi, 2017, pp. 10, tradução nossa).<sup>3</sup>


---

<sup>1</sup> “*Supervised learning entails learning a mapping between a set of input variables (typically a vector) and an output variable (also called the supervisory signal) and applying this mapping to predict the outputs for unseen data.*”

<sup>2</sup> “*Unsupervised learning studies how systems can learn to represent particular input patterns in a way that reflects the statistical structure of the overall collection of input patterns.*”

<sup>3</sup> “*Each object (cluster) consists of objects that are similar between themselves and dissimilar to objects of other groups. The goal of clustering is to determine the intrinsic grouping in a set of unlabeled data.*”

Figura 10: Diagrama representando o processo de clusterização.



Fonte: TRIPATHI (2017, pp.10)

### 2.6.3. Árvore de regressão

O modelo de árvore de regressão segue a estrutura de tomada de decisão baseado em parâmetros pré-estabelecidos. Existem dois tipos de algoritmo nesse contexto, árvores de decisão (classificação de dados em grupos) e árvores de regressão (estimativa de algum valor).


Para Gersting, “uma árvore de decisão é uma árvore na qual os nós internos representam ações, os arcos representam os resultados de uma ação e as folhas representam os resultados finais.” (GERSTING, 2001).

### 2.6.4. *Random Forest*

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. A Figura 11 apresenta uma demonstração do funcionamento da implementação deste método. É importante observar 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.

Figura 11: Exemplo de árvore de decisão com dois parâmetros.



Fonte: MARINS (2016, p.25)

### 2.6.5. 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:

- a) Tipo de estaca T;
- b) Comprimento da estaca L (metro);
- c) Diâmetro da estaca D (metro);
- d) Somatório do  $N_{SPT}$  ao longo do fuste da estaca NF;
- e)  $N_{SPT}$  na base da estaca NP;
- f) Estratigrafia por meio da consideração do solo ao longo do fuste da estaca FS;
- g) 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:

- a)  $NF$  = número representativo dos valores de  $N_{SPT}$  ao longo do fuste da estaca (golpes/30cm);
- b)  $NP$  =  $N_{SPT}$  na ponta da estaca (golpes/30cm);
- c)  $d$  = profundidade da camada de influência da carga em relação à ponta da estaca (m);
- d)  $Arg$  = fator representativo das camadas de solo argiloso ao longo do comprimento da estaca (m/m);
- e)  $Sil$  = fator representativo das camadas de solo siltoso ao longo do comprimento da estaca (m/m);
- f)  $Ar$  = fator representativo das camadas de solo arenoso ao longo do comprimento da estaca (m/m);

A variável  $NF$  foi representada como a soma, a média, a soma ponderada e a média ponderada dos valores do  $N_{SPT}$  ao longo do fuste da estaca. Seguindo as seguintes formulações:

- Somatório do  $N_{SPT}$  ao longo do fuste: método abordado por Silveira (2014), Equação (3).

$$NF = \sum N_{SPT} - NP \quad \text{Equação (3)}$$

- Média aritmética simples no  $N_{SPT}$  ao longo do fuste: Equação (4).

$$NF = \frac{\sum N_{SPT} - NP}{n-1} \quad \text{Equação (4)}$$


- Soma / Média ponderada do  $N_{SPT}$  ao longo do fuste: Este parâmetro considera pesos para os  $N_{SPT}$  ao longo do fuste, conforme mostrado pela
- Figura 12, para a primeira metade do comprimento da estaca recebem pesos de 0.6, para os 25% consecutivos ao anterior os pesos são de 0.3, e os  $N_{SPT}$  consecutivos ao anterior e desconsiderando o  $NP$  apresentam pesos de 0.1. Equações (5) e (6).



$$NF_{soma} = S1.0,6 + S2.0,3 + S3.0,1 \quad \text{Equação (5)}$$

$$NF_{média} = \frac{S1.0,6+S2.0,3+S3.0,1}{S=n1.0,6+n2.0,3+n3.0,1} \quad \text{Equação (6)}$$

Figura 12: Determinação da variável NP e cálculo da variável NF.




Fonte: ARÁUJO (2015, p.78)

### 2.6.6. Correlação entre as variáveis (Método de Pearson)

Filho e Júnior (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. A Figura 13 mostra os tipos de relação linear existente.

Figura 13: Relação linear entre dados



Fonte: <http://nbcgib.uesc.br/lec/2-nao-categorizado/150-cor-pearson>

Segundo Cohen (1988), valores entre 0,10 e 0,29 podem ser considerados pequenos; escores entre 0,30 e 0,49 podem ser considerados como médios; e valores entre 0,50 e 1,00 podem ser interpretados como grandes (*apud* Filho e Júnior, 2009, p.119).

### 3. METODOLOGIA

#### 3.1. Banco de dados

O primeiro passo para realização deste trabalho foi estabelecer uma pesquisa bibliográfica reunindo as possíveis variantes para obtenção do coeficiente de mola. Vale ressaltar que estas variantes deveriam compreender o contexto dos ensaios que são comuns as rotinas das obras. Nesse caso, a prova de carga estática junto da sondagem SPT são parâmetros que devem ser considerados conforme demonstrado por Araújo (2015). As provas de carga e as sondagens SPT utilizadas neste trabalho foram disponibilizadas por empresas do ramo de engenharia da cidade de Brasília.

O segundo passo foi estabelecer um banco de dados conforme demonstrado na Tabela 2, tendo como base os trabalhos de Amâncio (2013), Silveira (2014) e Araújo (2015), dessa forma, seguiu-se o mesmo padrão de estruturação. Porém, como o objetivo deste trabalho é calcular o coeficiente de mola para as fundações foram acrescentadas as variáveis:  $K_v$  (Coeficiente de Mola Vertical) e  $Q_{\text{trab}}$  (Carga de Trabalho da Estaca). Outra mudança realizada foi informar a região de execução conforme informado pelos relatórios das provas de carga e sondagens. Sendo assim, foi possível definir quais eram as regiões com maior abrangência de dados e, portanto, com maior confiabilidade para previsão do coeficiente de mola.

Tabela 2: Estruturação dos dados

Dados da Estaca						Sondagem									Prova de Carga		
N.	Local	T	L	D	$Q_{\text{trab}}$	NF				NP	d	Arg	Sil	Ar	P	$\rho$	$K_v$
						$\Sigma$	Med	$\Sigma$ Pond	Med Pond								
SP1_ E29A	Águas_ Claras	HC*	23	1	0	299	13	89	8	63	0	1	0	0	49	0	1783
SP1_ E29A	Águas_ Claras	HC*	23	1	0	299	13	89	8	63	0	1	0	0	196	0	1913
SP1_ E29A	Águas_ Claras	HC*	23	1	0	299	13	89	8	63	0	1	0	0	392	1	468
SP1_ E29A	Águas_ Claras	HC*	23	1	0	299	13	89	8	63	0	1	0	0	588	2	296
SP1_ E29A	Águas_ Claras	HC*	23	1	0	299	13	89	8	63	0	1	0	0	785	3	236

\*HC: Hélice Contínua

Obs.: As unidades de medida dos parâmetros se encontram apresentados na Tabela 3.

Fonte: Próprio autor (2018)

Destaca-se que as informações utilizadas para a estruturação dos dados (Tabela 2) foram provenientes do relatório de prova de carga, do relatório de sondagem ou do projeto de fundações, conforme pode ser observado na Quadro 1, a seguir.

Quadro 1: Variáveis do banco de dados

Id	Tipo	Origem
Local	Cidade	Prova de carga
T	Tipo de fundação	Prova de carga
L	Comprimento da estaca (m)	Prova de carga
D	Diâmetro da estaca (m)	Prova de carga
Q <sub>trab</sub>	Carga de Trabalho da estaca (tf)	Projeto
N <sub>F</sub>	N <sub>SPT</sub> representativo do fuste da estaca	Sondagem SPT
N <sub>P</sub>	N <sub>SPT</sub> representativo da ponta da estaca	Sondagem SPT
d	Distância entre a ponta da estaca e o impenetrável	Sondagem SPT
Arg	Fator representativo da quantidade de Argila (m/m)	Sondagem SPT
Sil	Fator representativo da quantidade de Silte (m/m)	Sondagem SPT
Ar	Fator representativo da quantidade de Areia (m/m)	Sondagem SPT
P	Carga aplicada na estaca (kN)	Prova de carga
ρ	Recalque (mm)	Prova de carga
Kv	Coeficiente de mola (kN/mm)	Calculado

Fonte: Próprio autor (2018)

Vale destacar que os tipos de estacas (T), diferentemente de Araújo (2015), não foram descritos no banco de dados como valores numéricos, e sim como rótulos dos tipos de estacas. Sendo assim necessário um tratamento dos dados no momento de criação do modelo de predição.

### 3.2. Algoritmo Python

O algoritmo utilizado para gerar o modelo de predição do coeficiente de mola, foi implementado por meio da linguagem Python 3.6. A escolha desta linguagem foi realizada com base na quantidade de bibliotecas existentes para criação de modelos de *machine learning*, conforme apresentado na Quadro 2. O código foi escrito na aplicação *Jupyter Notebook*, que é uma plataforma web de desenvolvimento de código *open-source*. A referida plataforma também permite criar uma documentação junto ao código, sendo possível qualquer leitor acompanhar de forma clara e interativa todo o funcionamento das linhas do algoritmo.

Quadro 2: Bibliotecas utilizadas dentro do algoritmo

Biblioteca	Função
Pandas	Manipulação e Análise de dados
Numpy	Funções Matemáticas
Matplotlib	Visualização de Gráficos
Seaborn	Visualização de Gráficos
Scikit-learn	Aprendizado de Máquina

Fonte: Próprio autor (2018)

O primeiro passo para a criação do código foi denominado de *Data Cleaning* (Limpeza de Dados), onde os dados gerados passam por uma limpeza com o objetivo de torna-los aplicáveis para as análises. Posteriormente, foi realizado o *Data Analysis* (Análise de Dados), onde foram aplicadas técnicas de análise de dados buscando encontrar as características do *dataset*, sendo possível assim estabelecer qual seria a representatividade desse estudo e quais atributos foram mais relevantes para a análise. Por fim, com base nos dados, foi criado o modelo de predição do coeficiente de mola utilizando técnicas de *machine learning* com validação da eficiência deste modelo por meio de métricas estabelecidas pela bibliografia técnica.

O modelo de predição para o valor do coeficiente de mola foi criado baseado na biblioteca *Scikit Learning* (Figura 14), usando como base os dados de treinamento. O parâmetro `max_features='auto'`, foi definido para que o método selecionasse o melhor ponto de corte para definição das árvores. O `n_estimators= 1000` define o número máximo de árvores que podem ser criadas a fim de otimizar o tempo de processamento dos dados, assim como o parâmetro `random_state=42`, que torna os resultados do modelo replicáveis quando definidos os mesmos parâmetros com os mesmos dados de treinamento. O Hiperparâmetro `n_jobs=-1`, informa quantos processadores o algoritmo pode utilizar. O valor -1 significa que não há limite para a quantidade de processadores a ser utilizada.

**Figura 14: Implementação do modelo Random Forest.**

```
In [26]:
from sklearn.ensemble import RandomForestRegressor

# Primeiramente vamos instanciar a classe 'RandomForestRegressor' e chamar o método 'fit'
rf = RandomForestRegressor(max_features='auto', n_estimators=1000, random_state=42, n_jobs=-1
, bootstrap = False)

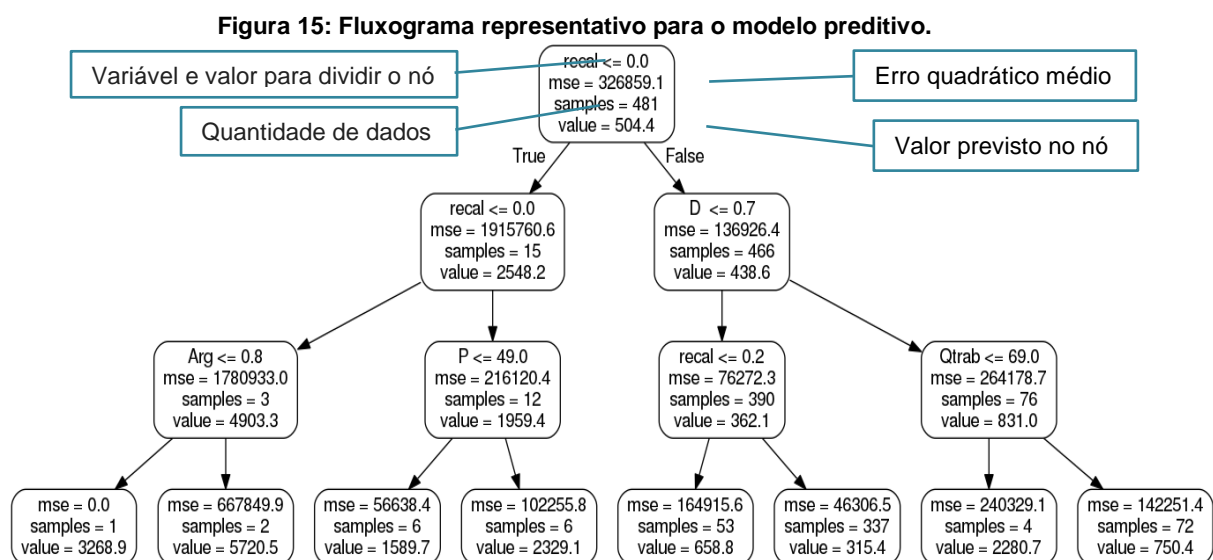
rf.fit(X_train, y_train)

Out[26]:
RandomForestRegressor(bootstrap=False, criterion='mse', max_depth=None,
max_features='auto', max_leaf_nodes=None,
min_impurity_decrease=0.0, min_impurity_split=None,
min_samples_leaf=1, min_samples_split=2,
min_weight_fraction_leaf=0.0, n_estimators=1000, n_jobs=-1,
oob_score=False, random_state=42, verbose=0, warm_start=False)
```

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 parâmetro *test\_size*= 0.3 determina que 70% do conjunto de dados serão para treino, e os 30% restantes serão utilizados para validação no conjunto de teste. O método *train\_test\_split* faz a separação desses dados de forma aleatória.

A Figura 15 apresenta um fluxograma de perguntas e respostas que levam a uma decisão tomada pelo modelo, ou seja, é uma representação do funcionamento simplificado das árvores.



É possível observar que no primeiro nó (conhecido como raiz da árvore), os dados possuem 481 exemplos, diferentemente da quantidade de dados total que era de 688 exemplos, essa diferença é proveniente do corte que foi realizado para a separação dos dados de treinamento e os dados de teste.

### 3.3. Erro médio Absoluto

A acurácia do modelo é calculada pelo erro médio absoluto, conforme demonstrado pela Equação (7).

$$\mathbf{errors} = \left| \frac{y_{pred} - y_{test}}{y_{test}} \right| * \mathbf{100} \quad \mathbf{Equação (7)}$$

## 4. RESULTADOS E ANÁLISES

### 4.1. Caracterização dos dados

A análise dos resultados começa pela definição da descrição geral dos dados que foram encontrados no *dataset*, posteriormente definindo os tipos de estacas que foram estudadas, os diâmetros mais comuns e a localização de maior ocorrência de dados.

A Tabela 3, apresenta uma descrição dos dados em cada uma das colunas, contendo a quantidade de linhas (*count*), a média dos valores (*mean*), o desvio padrão (*std*), o valor mínimo encontrado (*min*), os quartis estatísticos, e o valor máximo encontrado (*max*).

Tabela 3: Descrição dos dados do *dataset*.

	L	D	Q <sub>trab</sub>	Σ	Med	Σ Pond	Med Pond	NP	d	Arg	Sil	Ar	P	ρ	K <sub>v</sub>
<b>count</b>	688	688	688	688	688	688	688	688	688	688	688	688	688	688	688
<b>mean</b>	17	0.5	85	162	11	70	7	21	8	1	0	0	516	2	507
<b>std</b>	6	0.1	63	124	9	48	5	18	6	1	0	0	501	2	592
<b>min</b>	8	0.3	0	18	2	16	2	2	0	0	0	0	20	0	22
<b>25%</b>	12	0.4	12	72	4	39	4	7	4	1	0	0	118	0	202
<b>50%</b>	16	0.5	80	139	7	56	6	14	7	1	0	0	343	1	327
<b>75%</b>	22	0.6	143	215	14	84	8	26	11	1	1	0	785	2	605
<b>max</b>	30	0.8	258	512	44	243	25	63	27	3	2	1	$\frac{274}{7}$	9	6538

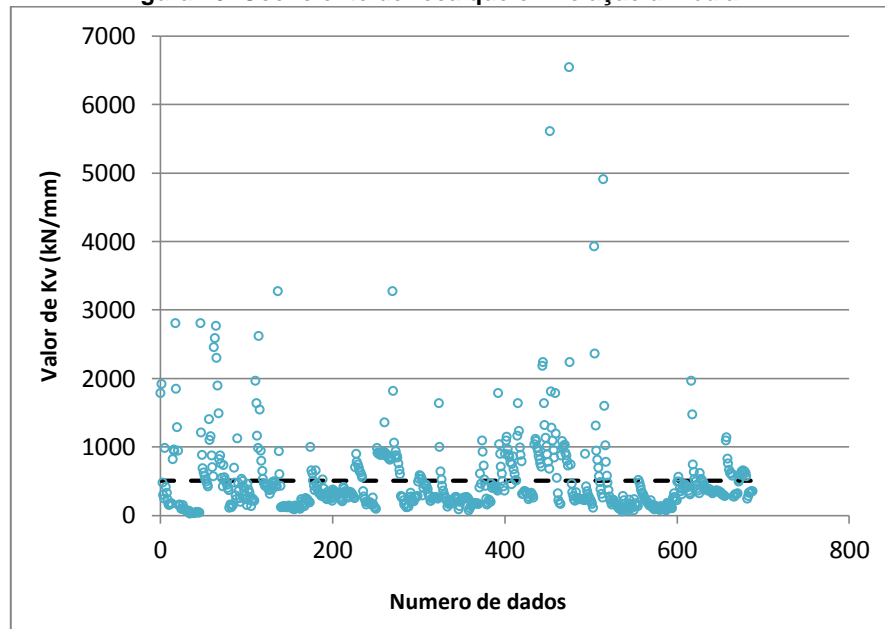
Fonte: Próprio autor (2018)

Conforme observado na tabela acima, o banco de dados foi composto por seiscentos e oitenta e oito linhas para todas as colunas, isso representa o número de provas de carga e dados correlatos obtidos para análise.

É importante observar que o valor médio do coeficiente de mola (K<sub>v</sub>) para o banco de dados foi de 507 kN/mm, ou seja, esse valor resume de forma geral o universo de dados analisados.

A Figura 16 apresenta, para melhor visualização dos resultados, a dispersão dos dados de coeficiente de recalque em relação à média.


**Figura 16: Coeficiente de recalque em relação à média.**



Observa-se na Figura acima que a variabilidade dos dados em relação a média (linha tracejada) não é grande, sendo esta considerada representativa.

A Figura 17 apresenta o histograma do coeficiente de reação vertical.

**Figura 17: Histograma do coeficiente de reação vertical**




Conforme observado na Figura 17 a maior parte dos dados de coeficiente de reação vertical se encontram entre o intervalo de 0 a 1000 kN/mm.



Como o modelo gerado deve ser representativo para o solo do Distrito Federal, foi realizado um levantamento da quantidade de dados obtidos para cada região de Brasília, conforme apresentado na Figura 18.

**Figura 18: Gráfico representativo das regiões**



Destaca-se que para a criação deste banco de dados foram analisadas as estacas do tipo escavadas e as estacas do tipo hélice contínua. Dessa forma, foi avaliada a representatividade do modelo para o tipo de estaca analisada, conforme pode ser observado na Tabela 4.


**Tabela 4: Descritivo do quantitativo de estacas.**

<b>Tipo</b>	<b>Quantidade</b>
Hélice Contínua	458
Escavada	232

De acordo com a Tabela 4, é possível observar que o modelo tem melhor representatividade para estacas do tipo hélice contínua.

A Figura 19 mostra um gráfico de barras contendo a profundidade média para as estacas escavadas e hélices contínuas analisadas.


**Figura 19: Média das profundidades para cada tipo de estaca.**



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

A Figura 20 apresenta um gráfico de calor (*heatmap*) que permite visualizar a correlação entre os dados. Vale ressaltar, que essa metodologia apresenta o coeficiente de correlação de Pearson.


**Figura 20: Gráfico de calor com a correlação entre os dados.**



Segundo a classificação proposta por Cohen (1988), é possível observar que para os valores de Kv existe pouca relação linear entre os dados, pois os valores são muito próximos de zero. Porém, a variável D (diâmetro) segundo a classificação possui escore médio, indicando uma maior relação deste parâmetro com o valor do coeficiente de mola.

A Figura 21 mostra um *boxplot* com a variação do diâmetro em relação à profundidade das estacas.


**Figura 21: *Boxplot* da variação dos diâmetros em relação a profundidade para cada tipo de estaca**



Observar-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.


A Figura 22 apresenta um gráfico com a quantidade de estacas para cada diâmetro.

Figura 22: Quantidade de estacas para cada diâmetro.



A Figura 23 apresenta um gráfico da frequência dos diâmetros (D), pela profundidade (L) para cada tipo de estaca.

Figura 23: Variação dos diâmetros em relação a profundidade.



No geral, as estacas hélice continua têm os maiores diâmetros e também tem as maiores profundidades, porém é possível observar que existe uma grande quantidade de estacas escavadas com diâmetro de 0.6 variando sua profundidade entre 5 a 30 metros.

## 4.2. Avaliação de Desempenho do Modelo

A Figura 24 apresenta o erro médio absoluto obtido no modelo.

Figura 24: Implementação do cálculo de 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 %.
```

Para o modelo gerado a precisão foi de 87.02%, o que representa uma precisão alta em comparação com a quantidade total de dados analisados.

A Tabela 5, mostra uma comparação entre os valores previstos pelo modelo (*Data Train*) com valores reais do banco de dados (*Data Test*). Como o banco de dados foi dividido em dados de treino e dados de teste, é possível fazer essa comparação.


Tabela 5: Comparação entre os valores previstos e reais do Kv.

Valor Real ( <i>Data Train</i> )	Valor Previsto ( <i>Data Test</i> )
211	223
388	355
232	238

## 4.3. Importâncias das Variáveis

A Figura 25, apresenta um gráfico demonstrativo da importância de cada variável para o modelo.

**Figura 25: Gráfico representativo para a importância das variáveis no modelo.**



Por meio deste é possível observar que o recalque e a carga aplicada são grandes influenciadores para a previsão do coeficiente de mola, o que já era esperado uma vez o  $K_v$  é calculado diretamente através destes valores. Porém, o diâmetro da estaca foi a variável com maior valor de importância para previsão no modelo gerado, confirmando assim a tendência já observada no mapa de calor da Figura 20. Isso pode ter ocorrido, pois o diâmetro da estaca influencia diretamente no cálculo do recalque das estacas e na 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, são as variáveis com maior representatividade. Isso ocorreu, pois a maior parte das estacas analisadas apresentou-se assente em camadas de silte, enquanto a soma do  $N_{SPT}$  já era de ser esperado uma boa correlação pois está relacionado com a resistência do solo.

## 5. CONSIDERAÇÕES FINAIS

Os resultados mostram que o modelo proposto para previsão do coeficiente de mola baseado em provas de carga e sondagens SPT funciona de forma satisfatória, porém existem ressalvas com relação à acurácia do modelo.

Conforme apresentado no capítulo 4 a acurácia do modelo foi de 87,02% para os 688 (seiscentos e oitenta e oito) dados do campo amostral estudado. Isso representa uma precisão satisfatória, sendo possível, ainda, melhorá-la aumentando a quantidade de dados a serem implementados no modelo. Destaca-se que, como as relações lineares obtidas por meio da correlação entre o coeficiente de mola e os demais parâmetros apresentados foram consideradas médias, seria de grande valia a realização desse estudo com a utilização de parâmetros obtidos por meio de ensaios.

É importante ressaltar que é grande a variabilidade geotécnica e a 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 exatamente caracterizado. Dessa forma, uma análise de previsão do coeficiente de mola que se baseia apenas em dados de sondagem e provas de carga pode não retratar de forma fiel as condições do local. Outra consideração é a pouca representatividade da sondagem SPT como parâmetro de rigidez do solo, mesmo assim este ensaio ainda é o mais utilizado para estudo dos solos nas obras brasileiras.

Destaca-se que existem limitações intrínsecas ao resultado final com a utilização do modelo de aprendizado supervisionado utilizado neste trabalho (*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. Porém para utilização destas técnicas, novamente ressalta-se a necessidade em aumentar a amostragem dos dados, possibilitando assim melhorar a capacidade de aprendizado.

## 5.1 Sugestões Para Pesquisas Futuras

Em uma futura pesquisa, sugere-se:

- A utilização de ensaios (triaxial e cisalhamento direto, por exemplo) que possam representar melhor a rigidez do solo, de modo a verificar se existe melhoria nas correlações entre o coeficiente de mola e os parâmetros obtidos por estes ensaios.
- Utilização de outros modelos estatísticos mais avançados como redes neurais e outras técnicas de *deep learning* (aprendizado profundo).



## REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 12131: Estacas – Prova de carga estática – Método de ensaio**. Rio de Janeiro, p.8. 2006

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6122: Projetos execução de fundações**. Rio de Janeiro, p.91. 2010

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6484: Solo – Sondagens de simples reconhecimento com SPT – Método de ensaio**. Rio de Janeiro, p.17. 2001

AMANCIO, Luciana Barbosa. **PREVISÃO DE RECALQUES EM FUNDAÇÕES PROFUNDAS UTILIZANDO REDES NEURAIS ARTIFICIAIS DO TIPO PERCEPTRON**. 2013. 44 -48 p. Dissertação (Mestrado em Engenharia Civil)- Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/7980>>. Acesso em: 29 set. 2018.

ANTONIAZZI, Juliana Pippi et al. **Interação solo-estrutura de edifícios com fundações superficiais**. 2011.

AOKI, N. Modelo simples de transferência de carga de estaca vertical sujeita a carga axial de compressão. **CICLO DE PALESTRAS SOBRE ENGENHARIA DE FUNDAÇÕES–ABMS–Núcleo Regional do Nordeste**, 1987.

AOKI, Nelson. Aspectos geotécnicos da interação estrutura-maço de solos. **Jornadas Sul-Americanas de Engenharia Estrutural**, v. 28, p. 7-20, 1997.

ARAÚJO MARINS, Matheus. **CLASSIFICAÇÃO DE FALHAS EM MÁQUINAS ROTATIVAS UTILIZANDO MÉTODOS DE SIMILARIDADE E RANDOM FOREST**. 2016. 52 f. Monografia (ENGENHARIA ELETRÔNICA E DE COMPUTAÇÃO) - ESCOLA POLITÉCNICA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO C, RIO DE JANEIRO, 2016. Disponível em: <<http://monografias.poli.ufrj.br/monografias/monopoli10018526.pdf>>. Acesso em: 08 nov. 2018.

ARAÚJO, Carla Beatriz Costa de. **APLICAÇÃO DAS REDES NEURAIS ARTIFICIAIS DO TIPO PERCEPTRON NA ESTIMATIVA DE RECALQUES EM ESTACAS**. 2015. 75 - 82 p. Dissertação (Mestrado em Engenharia Civil) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2015. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/12932>>. Acesso em: 29 set. 2018.

CARVALHO, J. C. et al. **Considerações sobre a Análise dos Resultados de Prova de Carga Estáticas**. SEFE IV – Seminário de Engenharia de Fundações Especiais e Geotecnia. São Paulo - SP: [s.n.]. 2008.

Cintra, J. C. A., Aoki, N. & Albiero, J.H. (2011). **“Fundações Diretas: Projeto Geotécnico”**. São Paulo/SP: OFICINA DE TEXTOS.

COVAS, Nelson. **Coeficiente de mola - Uma estaca**. 2009. Disponível em: <<http://www.tqs.com.br/suporte-e-servicos/biblioteca-digital-tqs/89-artigos/6-coeficiente-de-mola-uma-estaca>>. Acesso em: 28 set. 2018

FILHO, Dalson Britto Figueiredo; JÚNIOR, José Alexandre da Silva. **Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r)**. Revista Política Hoje, Pernambuco, v. 18, n. 1, p. 115-146, jan. 2009. Disponível em: <[http://bibliotecadigital.tse.jus.br/xmlui/bitstream/handle/bdtse/2766/desvendando\\_mist%C3%A9rios\\_coeficiente\\_figueiredo%20filho.pdf?sequence=1](http://bibliotecadigital.tse.jus.br/xmlui/bitstream/handle/bdtse/2766/desvendando_mist%C3%A9rios_coeficiente_figueiredo%20filho.pdf?sequence=1)>. Acesso em: 08 nov. 2018.

PERASSO, Valeria. **O que é a 4ª revolução industrial - e como ela deve afetar nossas vidas**. 2016. Disponível em: <<https://www.bbc.com/portuguese/geral-37658309>>. Acesso em: 28 set. 2018.  
PINTO, C. S. **Curso de Mecânica dos Solos em 16 Aulas**. 2006.

PORTO, Thiago Bomjardim. **Estudo da interação de paredes de alvenaria estrutural com a estrutura de fundação**. Belo Horizonte, 2010.

PUGET, JEAN FRANCOIS. **What Is Machine Learning?**, 2016, Disponível em: <[https://www.ibm.com/developerworks/community/blogs/jfp/entry/What\\_Is\\_Machine\\_Learning?lang=en](https://www.ibm.com/developerworks/community/blogs/jfp/entry/What_Is_Machine_Learning?lang=en)>. Acesso em: 22 set. 2018.

SILVA, C. M.; CAMAPUM DE CARVALHO, J. **Monitoramento e Controle de Qualidade dos Estaqueamentos Tipo Hélice Contínua Durante a Execução da Obra**. XV Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica. Gramado: ABMS - Associação Brasileira de Mecânica dos Solos. 2010. p. 1-12.

SILVEIRA, Mariana Vela. **Modelo neuronal para previsão de recalques em estacas hélice contínua, metálica e escavada**. 2014. 62 - 70 p. Dissertação (Mestrado em Engenharia Civil)- Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2014. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/11393>>. Acesso em: 29 set. 2018.

SISES - **Manual Teórico**. [S.l.: s.n.], 2015. Disponível em: <<https://referenciabibliografica.net/index.php>>. Acesso em: 30 set. 2018.

TRIPATHI, Atul. **Practical Machine Learning: Resolving and offering solutions to your machine learning problems with R**. 1. ed. Birmingham: Packt Publishing Ltd., 2017. 543 p.