



CENTRO UNIVERSITÁRIO DE BRASÍLIA - CEUB

PROGRAMA DE INICIAÇÃO CIENTÍFICA

VINÍCIUS NOVAES ALMEIDA

**ESTIMATIVA DA CARGA DE RUPTURA EM ESTACAS A PARTIR DE
ENSAIOS DE PROVA DE CARGA ESTÁTICA UTILIZANDO *MACHINE
LEARNING***

BRASÍLIA

2023

VINÍCIUS NOVAES ALMEIDA

**ESTIMATIVA DA CARGA DE RUPTURA EM ESTACAS A PARTIR DE
ENSAIOS DE PROVA DE CARGA ESTÁTICA UTILIZANDO *MACHINE
LEARNING***

Relatório final de pesquisa de Iniciação Científica apresentado à Assessoria de Pós-Graduação e Pesquisa.

Orientação: Gabriela de Athayde Duboc Bahia

BRASÍLIA

2023

“The Mystery of Life isn’t a problem to solve, but a reality to experience.”

(Frank Herbert)

Sumário

RESUMO.....	9
1. INTRODUÇÃO.....	11
1.1. Justificativa.....	12
1.2. OBJETIVO.....	12
1.2.1 Objetivo Geral	12
1.2.2 Objetivo específico	13
2.REVISÃO BIBLIOGRÁFICA	14
2.1 Conceitos	14
2.1.1 Inteligência artificial	14
2.1.2 Machine learning	14
2.1.3 Redes neurais	14
2.1.3 Diferença entre Inteligência artificial, <i>machine learning</i> e redes neurais.	15
2.2 Técnicas computacionais para classificação de dados	16
2.2.1 Clusterização de dados	17
2.2.2 Árvore de regressão	17
2.2.3 <i>Random forest</i>	18
2.3 Breve Histórico de Inteligência Artificial Aplicada em Fundações	19
2.3.1 <i>State-of-the-art review of some artificial intelligence applications in.....</i>	19
<i>pile foundations</i> Mohamed A. Shahin (2016)	19
2.3.2 <i>Machine Learning</i> Aplicado na Estimativa do Coeficiente de Mola de Estacas com Validação por Meio de Provas de Carga Estáticas, YURI MIGUEL DE OLIVEIRA (2018)	20
2.3.3 Experimento de Previsão de Carga de Ruptura em Estacas Carregadas Axialmente a Compressão Utilizando Redes Neurais (RNA), Bruno Vieira de Jesus (2019).....	21
2.3.4 <i>Estimation of Bearing Capacity of Piles in Cohesionless Soil Using Optimised Machine Learning Approaches</i> , Navid Kardani, Annan Zhou, Majidreza Nazem, Shui-Long Shen (2019)	21
2.3.5 <i>Estimation of Load-set Behavior of Driven Concrete Piles Using Artificial Neural Network and Cone Penetration Test</i> , I V Ofrikhter, and A B Ponomarev (2021).....	22
2.4 Provas de Carga Estática.....	22
2.5 Método Para Previsão de Ruptura de Estaca	25
2.5.1 Método da NBR 6122.....	26
2.5.1 Van der Veen	27

4. METODOLOGIA.....	30
4.1 Banco de dados	30
4.1.2 Análise de dados de provas de carga e sondagem.....	33
4.2 Algoritmo Python	34
4.3 Erro médio absoluto	36
5. RESULTADOS E ANÁLISES	37
5.2 Avaliação da precisão do modelo.....	42
6. CONSIDERAÇÕES FINAIS	45
6.1 Sugestões Para Pesquisas Futuras	46
REFERÊNCIAS BIBLIOGRÁFICAS	47

LISTA DE FIGURAS

Figura 1 Demonstração da organização de uma rede neural em camadas e nós.	15
Figura 2 Diagrama representando o processo de clusterização.....	17
Figura 3 Como uma árvore de decisões funciona.	18
Figura 4 Exemplo de árvore de decisão com dois parâmetros.....	18
Figura 5 Prova de carga estática.....	25
Figura 6: Carga de ruptura convencional	27
Figura 7 Definição da carga de ajuste, Método de Van der Veen (1953)	28
Figura 8 Curva ajustada pelo método de Van der Veen (1953), modificado por Aoki (1976)	29
Figura 9 Representação do parâmetro d	32
Figura 11 Exemplo de curva Carga x Recalque	34
Figura 12 implementação do modelo de Random Forest.....	35
Figura 13 Fluxograma representando uma árvore pequena da floresta de regressão	36
Figura 15 Gráfico Correspondência do Comprimento Médio x Local	38
Figura 19 Correspondência Recalque médio x Diâmetro médio	41

LISTAS DE TABELAS

Tabela 1 Quantidade de provas de carga	24
Tabela 2 Organização do banco de dados	31

LISTAS DE QUADROS

Quadro 1 Comparativo entre Machine learning e Deep learning.....	16
Quadro 2 Nomenclatura utilizada no banco de dados.....	32
Quadro 3 Bibliotecas utilizadas no algoritmo.....	35

RESUMO

A investigação do sistema solo-fundação é de extrema importância para a construção de edificações seguras. Uma das formas de investigação geotécnica bastante utilizada é o ensaio SPT (*Standard Penetration Test*). Este ensaio é utilizado para estimar a resistência a penetração do solo, o tipo de solo, presença de nível d'água e dependendo do equipamento, atrito lateral do solo. Além do ensaio SPT, para a realização de projetos de fundações mais seguros e econômicos, tem-se o ensaio de prova de carga estática, o qual permite verificar o desempenho das fundações. A prova de carga é um método de análise direta da capacidade de suporte de carga, podendo ser realizada em diversos tipos de estruturas. Porém, apesar de ideal a prova de carga não é utilizada com frequência, devido ao seu custo e à obrigatoriedade da norma em se utilizar somente em obras de grande porte. Sendo assim, esse estudo estimou 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 situadas no Distrito Federal.

Para isso, foi desenvolvido um algoritmo em linguagem python que pudesse, a partir dos dados de treino, prever os resultados de carga de ruptura em obras que apresentassem apenas sondagem a percussão simples. Para o desenvolvimento do algoritmo foram utilizados modelos de aprendizado supervisionado (*Random Forest*). Desta forma, foi possível obter resultados com acurácia de 78,12%. Porém, vale ressaltar que existem limitações em relação ao resultado final, que influenciaram no valor da acurácia, tais como: o número limitado da amostragem de dados utilizada (67 provas de carga), a variabilidade geotécnica do perfil estratigráfico associado aos ensaios pontuais de SPT, o que dificulta a representatividade das condições do solo local e o próprio aprendizado supervisionado utilizado (*Random Forest*) que quanto maior a dispersão de dados produz resultados com menor capacidade de previsão.

Palavras chave: Hélice contínua, Carga de ruptura e *Machine Learning*.

ABSTRACT

The investigation of the soil-foundation system is extremely important for the construction of safe buildings. One of the most used forms of geotechnical investigation is the SPT test (Standard Penetration Test). This test is used to estimate the resistance to soil penetration, the type of soil, presence of water level and depending on the equipment, lateral friction of the soil. In addition to the SPT test, to carry out safer and more economical foundation projects, there is the static load test, which allows checking the performance of the foundations. The load test is a method of direct analysis of the load bearing capacity, which can be performed in different types of structures. However, despite being ideal, the load test is not used frequently, due to its cost and the requirement of the standard to use it only in large works. Therefore, this study estimated the geotechnical failure load of axially loaded piles, using machine learning, based on static load test tests and percussion drilling in works located in the Federal District.

For this, an algorithm was developed in Python language that could, from the training data, predict the breaking load results in works that only presented sounding to simple percussion. Supervised learning models (Random Forest) were used to develop the algorithm. In this way, it was possible to obtain results with an accuracy of 78.12%. However, it is worth mentioning that there are limitations in relation to the final result, which influenced the accuracy value, such as: the limited number of data samples used (67 load tests), the geotechnical variability of the stratigraphic profile associated with the punctual tests of SPT , which makes it difficult to represent the conditions of the local soil and the supervised learning used (Random Forest) that the greater the data dispersion produces results with less predictive capacity.

Keywords: Continuous Flight Auger, Breaking Load, Machine Learning.

1. INTRODUÇÃO

A realização de prospecções no solo para o conhecimento das propriedades do maciço se faz indispensável para o dimensionamento de fundações. Porém, ainda que seja importante para a obtenção dos parâmetros necessários ao cálculo, em sua maioria, a prospecção se resume apenas ao ensaio de sondagem à percussão (SPT). Isso dificulta o conhecimento do comportamento de forma global do maciço, a interação entre o elemento de fundação com o solo e o real desempenho das fundações.

Dessa forma, para obras de maior porte como àquelas que apresentam os carregamentos principais da estrutura sendo esforços de tração ou esforços horizontais, obras de arte especiais com vão superior a 30,0 m ou mais de 3 (três) vãos (quatro linhas de apoio), obras com grande número de estacas ou tensões de trabalho de grande magnitude, a NBR 6122 apresenta, como obrigatoriedade, a verificação do desempenho das fundações por meio 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.

Para isso, será utilizado um banco de dados com 67 (sessenta e seis) ensaios de prova de carga associados às suas respectivas sondagens. A partir dessas informações será elaborado um algoritmo capaz de prever a carga de ruptura geotécnica da fundação a partir de técnicas de *machine learning* fundamentadas no aprendizado supervisionado.

Como ferramenta para a construção do algoritmo será utilizada a plataforma Google Colab, que permite a execução de códigos em Python de forma gratuita a partir do navegador.

O banco de dados será organizado de forma a determinar os parâmetros que devem ser considerados para a previsão da capacidade de carga de ruptura geotécnica da fundação a partir das informações dos ensaios (prova de carga e SPT).

Por meio dos resultados desse trabalho estima-se que seja possível dimensionar os elementos de fundação com mais segurança e assertividade.

1.1. Justificativa

A otimização do tempo e a diminuição dos custos mantendo a segurança é um dos grandes desafios na engenharia civil. Sendo assim, este trabalho propõe desenvolver um algoritmo capaz de estimar a carga de ruptura em estacas hélice contínua a partir de uma base de dados. A técnica de *machine learning* é capaz de simplificar modelos matemáticos complexos e apresentar resultados concretos e precisos em um tempo menor, apresentando ainda a capacidade de aprender com o universo de dados estudados e se tornar ainda mais preciso.

1.2. OBJETIVO

1.2.1 Objetivo Geral

Este estudo possui como objetivo organizar uma base de dados, com 67 (sessenta e sete) ensaios de prova de carga associados às suas respectivas sondagens a fim de criar uma inteligência artificial, com base na técnica de *machine learning*, com o intuito de prever a carga de ruptura em estacas que apresentem apenas os ensaios de sondagem SPT.

1.2.2 Objetivo específico

Os objetivos específicos deste trabalho são:

- Gerar um banco de dados com resultados de provas de carga e sondagens SPT;
- Tratar a base de dados, identificando os principais parâmetros que podem influenciar nas análises;
- Desenvolver um algoritmo que utilize IA (inteligência artificial) capaz de analisar a base de dados organizados e gerar conclusões;
- Analisar as conclusões e verificar sua validade e precisão.

2.REVISÃO BIBLIOGRÁFICA

2.1 Conceitos

Neste tópico serão apresentados conceitos abordados durante o estudo, para melhor compreensão do estado da arte.

2.1.1 Inteligência artificial

Pode-se dizer que a inteligência artificial, se trata de sistemas que têm como objetivo imitar a inteligência humana com o intuito de executar tarefas diversas.

“A definição de Inteligência artificial é algo muito discutido na comunidade científica, um mesmo dicionário por exemplo fornece mais de quatro definições. Ao invés de procurar por uma definição geral de inteligência artificial, pode-se restringir-se a definição de sistemas artificialmente inteligentes. Existem muitas definições, mas a maioria pode ser classificada dentre as seguintes categorias: sistemas que pensam como humanos, sistemas que agem como humanos, sistemas que pensam racionalmente e sistemas que agem racionalmente.” (KOK, BOERS, KOSTERS, PUTTEN. 2009, p.9)

2.1.2 Machine learning

Machine Learning ou aprendizagem de máquinas é uma tecnologia onde os computadores possuem a capacidade de aprender de acordo com as respostas recebidas por meio de associações de diferentes dados, que podem ser desde imagens até números. “*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.” (MURPHY. 2015, p.3). No *machine learning*, utilizam-se as máquinas como meio para encontrar padrões e solucionar problemas utilizando-se de algoritmos de análise de dados.

2.1.3 Redes neurais

Segundo a IBM Cloud Education (2020), as redes neurais são um subconjunto de *machine learning* e estão no núcleo dos algoritmos de *deep learning*. Seu nome e estrutura são inspirados no cérebro humano, imitando a maneira como

os neurônios biológicos enviam sinais para os outros. As redes neurais são organizadas em camadas de um nó, contendo uma camada de entrada, podendo conter uma ou várias camadas ocultas e uma camada de saída como exemplificado na Figura 1.

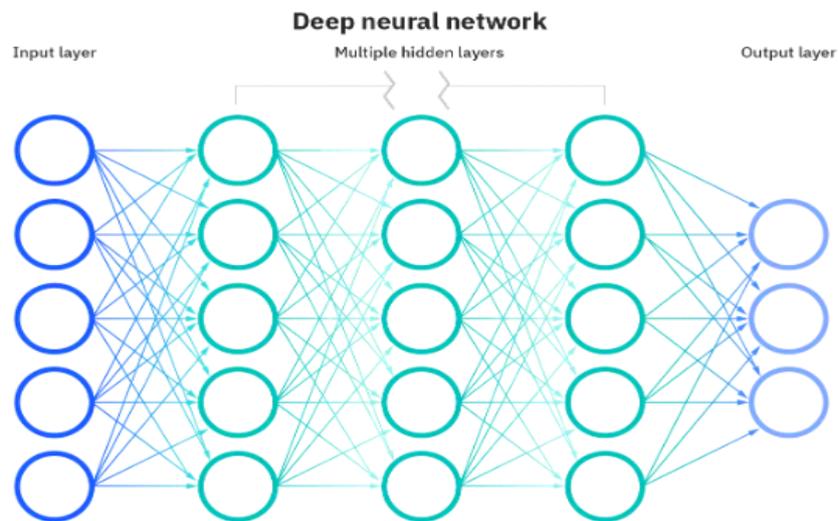


Figura 1 Demonstração da organização de uma rede neural em camadas e nós.

Fonte: IBM Cloud Education 2020.

Ainda segundo IBM Cloud Education (2020), as redes neurais contam ainda com dados de treinamento que tem como objetivo possibilitar um aprendizado ao programa, com o objetivo de melhorar sua precisão ao longo do tempo.

2.1.3 Diferença entre Inteligência artificial, *machine learning* e redes neurais

Segundo a Microsoft (2022), a inteligência artificial (IA) é uma técnica que permite aos computadores imitar a inteligência humana. O *machine learning* é um subconjunto de inteligência artificial que, por sua vez, utiliza técnicas que permitem que os computadores usem a experiência para aprimorar as tarefas. Já as redes neurais, fazem parte do subconjunto de *Deep learning* ou aprendizado profundo, que consiste em um subconjunto do *machine learning*. O processo de aprendizado é profundo porque a estrutura das redes neurais

artificiais consiste em várias camadas: de entrada, saída e oculta. O Quadro 1 demonstra um comparativo entre as técnicas, para melhor entendimento.

Quadro 1 Comparativo entre *Machine learning* e *Deep learning*

Características	<i>Machine learning</i>	<i>Deep learning</i>
Número de pontos de dados	Pode usar pequenas quantidades de dados para fazer previsões.	Precisa usar grandes quantidades de dados de treinamento para fazer previsões.
Dependências do <i>hardware</i>	Pode funcionar em máquinas de <i>low-end</i> . Ele não precisa de uma grande quantidade de poder computacional.	Depende de computadores avançados. Ele faz inerentemente um grande número de operações de multiplicação de matriz. Uma <i>GPU</i> pode otimizar essas operações com eficiência.
Processo de personalização	Requer que os recursos sejam identificados e criados com precisão pelos usuários.	Aprende recursos de alto nível de dados e cria novos recursos por si só.
Abordagem de aprendizagem	Divide o processo de aprendizado em etapas menores. Em seguida, ele combina os resultados de cada etapa em uma saída.	Percorre o processo de aprendizado resolvendo o problema de ponta a ponta.
Tempo de execução	Leva um tempo comparativamente pequeno para ser treinado, variando de alguns segundos a algumas horas.	Geralmente leva muito tempo para treinar porque um algoritmo de aprendizado profundo envolve muitas camadas.
Saída	A saída geralmente é um valor numérico, como uma pontuação ou uma classificação.	A saída pode ter vários formatos, como um texto, uma pontuação ou um som.

Fonte: Microsoft (2022)

2.2 Técnicas computacionais para classificação de dados

A fim de compreender melhor os conceitos abordados neste estudo, serão detalhados os métodos computacionais escolhidos para tratar e classificar os dados coletados para o estudo.

2.2.1 Clusterização de dados

Segundo Oliveira (2018), o processo de clusterização consiste em reunir grupos de dados que apresentam similaridades em suas características (Figura 2), “Cada grupo (*cluster*) consiste em 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).

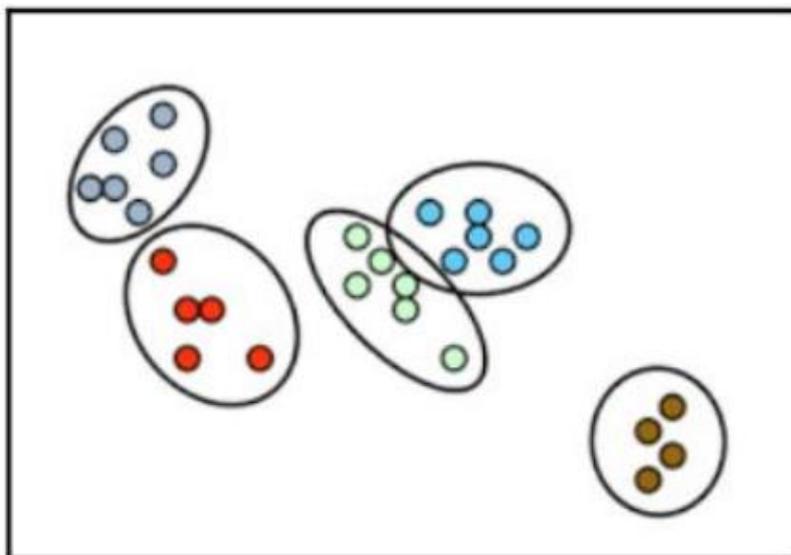


Figura 2 Diagrama representando o processo de clusterização.

Fonte: TRIPATHI (2017, pp.10).

2.2.2 Árvore de regressão

Árvore de regressão é um modelo de tomada de decisões que se baseia em parâmetros pré-estabelecidos. Existem, atualmente, dois tipos de algoritmo nesse contexto, árvores de decisões que consistem em classificar dados agrupados e árvore de regressão, que consiste em estimativa de valores. A Figura 3 ilustra como uma árvore de decisões funciona.

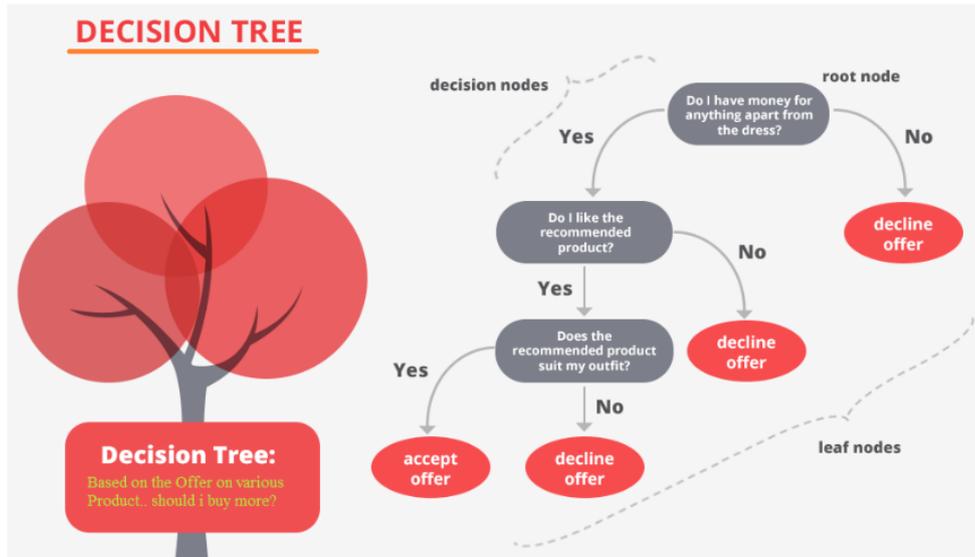


Figura 3 Como uma árvore de decisões funciona.

Fonte: Data Science Foundation.

2.2.3 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. Ainda segundo Oliveira (2018) nesse método a técnica de separação dos dados é feita por *bagging*, que é um sistema de escolha por votação.

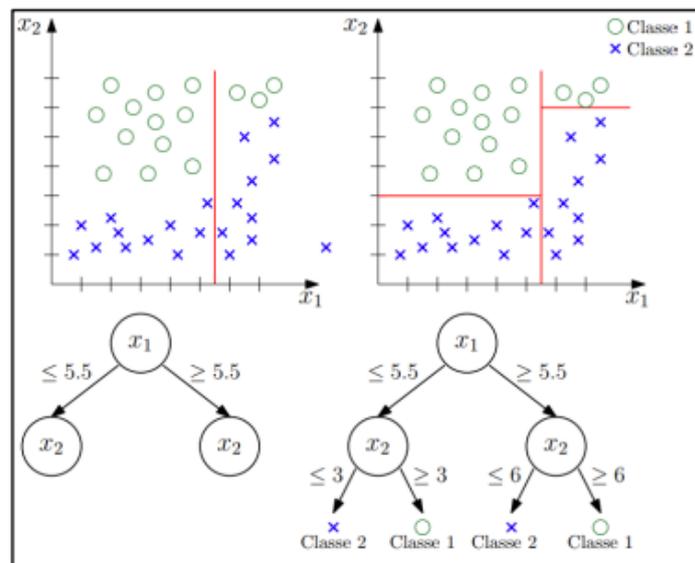


Figura 4 Exemplo de árvore de decisão com dois parâmetros

Fonte: MARINS (2016, p.25)

Observando a Figura 4 é possível compreender o funcionamento da implementação deste método. 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.

2.3 Breve Histórico de Inteligência Artificial Aplicada em Fundações

A fim de compreender melhor o estado da arte, serão apresentados nos itens seguintes um breve histórico de utilização da técnica de aprendizado de máquinas como ferramenta da geotecnia.

2.3.1 *State-of-the-art review of some artificial intelligence applications in pile foundations* Mohamed A. Shahin (2016)

Neste estudo Mohamed A. Shahin analisou a aplicação de algumas técnicas de inteligência artificial com o objetivo de estimar a carga de ruptura, capacidade de carga e atrito lateral de estacas. No desenvolvimento do estudo, Shahin analisou três técnicas de IA (inteligência artificial) sendo elas, *Artificial Neural Networks*, *Genectic programming* e *Evolutionaty Polynominal Regression*. Durante a análise, o autor conclui que existem diversos fatores no uso de inteligências artificiais que precisam ser sistematicamente investigadas quando se desenvolvem modelos de IA para problemas envolvendo engenharia geotécnica, para que a exatidão do modelo seja melhorada. Esses fatores são a determinação de *inputs* adequados para o modelo, a divisão e a caracterização de dados, a validação do modelo, análise de dados e incerteza do modelo.

Em seu estudo, o autor aborda que a complexidade dos problemas envolvendo geotecnia é alta e de difícil compreensão. Por isso, a inteligência artificial oferece vantagens sobre outras técnicas computacionais. Segundo Shahin (2016) como modelos matemáticos possuem uma lacuna de conhecimento físico, os modelos matemáticos assumem parâmetros ou simplificam o problema. Ainda segundo Shahin (2016) conseqüentemente, muitos modelos matemáticos não simulam o comportamento complexo da maioria dos problemas geotécnicos. Devido ao fato de as inteligências artificiais serem movidas a dados, se torna possível analisar

a complexidade do solo com facilidade sem a necessidade de simplificar ou assumir parâmetros. A opinião do autor ao final do estudo é que inteligências artificiais são ferramentas poderosas que devem ser incorporadas no meio geotécnico, para facilitar e otimizar a execução de estacas, e que para ser possível desenvolver inteligências artificiais cada vez mais precisas, é necessário criar bancos de dados.

2.3.2 *Machine Learning* Aplicado na Estimativa do Coeficiente de Mola de Estacas com Validação por Meio de Provas de Carga Estáticas, YURI MIGUEL DE OLIVEIRA (2018)

Neste trabalho Oliveira estudou um modelo de predição do coeficiente de mola, utilizando *machine learning*, com o intuito de correlacionar dados de provas de carga e sondagens SPT para estacas do tipo escavada e hélice contínua.

Para dar início ao desenvolvimento deste estudo, o primeiro passo do autor foi organizar o seu banco de dados, utilizando o *software* Excel, o autor organizou e caracterizou os parâmetros utilizados, sendo eles o comprimento e diâmetro da estaca, o resultado das sondagens, o tipo de solo e os resultados da prova de carga. Para desenvolver a linguagem, Oliveira (2018) utilizou a linguagem Python, e após o *Data Cleaning* e *Data Analysis*, o autor deu início ao modelo de predição utilizando os métodos Árvore de Regressão e *Random Forest*.

Ao final deste trabalho, o autor constatou que o modelo apresentou resultados satisfatórios e com precisão de 87,02%, que pode vir a ser melhorada aumentando a quantidade de dados inseridos no modelo. Porém, existem ressalvas com relação a precisão do modelo, pois como a variabilidade geotécnica é muito grande, por mais que se realize muitas sondagens, dificilmente as condições dos solos analisados serão caracterizadas o que prova que haverá dispersão de dados. E quanto maior for a dispersão de dados, menor será a capacidade do modelo utilizado de se adaptar. O autor ainda propõe que outros modelos mais complexos sejam capazes de aumentar a precisão mesmo com a dispersão.

2.3.3 Experimento de Previsão de Carga de Ruptura em Estacas Carregadas Axialmente a Compressão Utilizando Redes Neurais (RNA), Bruno Vieira de Jesus (2019)

Neste trabalho Jesus conduziu experimentos de previsão de carga de ruptura de estacas carregadas axialmente a compressão. Primeiro foi inserido um banco de dados, com resultados de provas de carga estáticas à compressão, sondagem à percussão, comprimento da estaca, área da seção transversal da estaca e carga de ruptura. Em seguida, utilizaram-se quatro modelos de redes neurais com o objetivo de prever a carga de ruptura.

“Em cada modelo realizam-se processos de treinamento e teste. Posteriormente, procede-se à validação de cada arquitetura adotada, apresentando-se as redes com melhor desempenho. Os diferentes modelos buscaram um refinamento da rede, e a capacidade de generalização da mesma.” (Jesus, 2019, p.8).

Ao final do estudo foi possível constatar que apesar dos bons coeficientes de correlação, todas as redes apresentaram erros percentuais elevados nos resultados de teste e de treinamento, assim como na fase de validação. Os resultados mostraram que as redes não foram capazes de generalizar uma solução obtendo um resultado com respostas satisfatórias. Uma possível suposição para o surgimento do problema que o autor desenvolveu foi a de que não foram oferecidas à rede variáveis de entrada suficientes para ela discretizar o comportamento da variável de saída (carga de ruptura). Informações como o tipo de solo (argila, silte, areia) não foram oferecidas, o que pode ter contribuído para a falha na generalização. Além disso, dois tipos de solos diferentes podem apresentar os mesmos valores de NSPT e possuem características de resistência distintas.

2.3.4 Estimation of Bearing Capacity of Piles in Cohesionless Soil Using Optimised Machine Learning Approaches, Navid Kardani, Annan Zhou, Majidreza Nazem, Shui-Long Shen (2019)

Este estudo teve como objetivo simplificar e otimizar métodos para a estimativa de carga de ruptura de estacas através do uso de *Neural Networks*. Para a realização deste estudo, os autores desenvolveram seis avançados algoritmos de *Machine Learning* com auxílio de técnicas como *Decision Tree*, *K-nearest*

Neighbour e *Random Forest*. Foi utilizada uma base de dados composta por resultados de NSPT e carga de ruptura de 59 estacas em solo arenoso. Também há nesta base de dados a localização geográfica dos elementos de fundação, o tipo de estaca utilizado, o comprimento e diâmetro das estacas.

Ao final do estudo os autores concluíram que o método de *machine learning* se mostrou eficiente para prever a capacidade de carga de estacas apresentando uma precisão de 86,7%. Também foi possível determinar no estudo que o fator mais influente em estacas é a tensão efetiva.

2.3.5 Estimation of Load-set Behavior of Driven Concrete Piles Using Artificial Neural Network and Cone Penetration Test, I V Ofrikhter, and A B Ponomarev (2021)

Neste estudo ao invés de utilizar métodos empíricos para determinar a capacidade de carga de estacas, Ofrikhter e Ponomarev decidiram utilizar *machine learning*. Para desenvolver este trabalho, foi organizada uma base de dados com resultados de NSPT e CPT de 58 estacas pré-moldadas de concreto de deslocamento e tipo de solo. Após a organização dos dados, as redes neurais empregadas foram treinadas utilizando o método de *backpropagation*.

Ao final deste estudo foi possível observar que as redes neurais treinadas pelo método *backpropagation* permitiu que se obtivessem resultados com margem de erro de 43,40%. Os autores concluíram ainda que para obter melhores resultados, seria necessário coletar uma grande quantidade de dados sobre cada tipo de estaca, porém graças a habilidade de aprender com grande facilidade, as redes neurais aparentam ser ferramentas convenientes e de fácil utilização para auxiliar em projetos de fundação.

2.4 Provas de Carga Estática

Segundo a NBR 16903 (ABNT, 2020), a prova de carga estática é aplicada para todos os tipos de estacas, verticais ou inclinadas, independentemente do processo de execução e de instalação no terreno. Essa norma se aplica às provas de carga que utilizam o critério de cargas controladas.

A prova de carga é um método de análise direta da capacidade de suporte de carga, podendo ser realizada em diversos tipos de estruturas. A prova de carga consiste em solicitar o elemento da fundação através de macacos hidráulicos, simulando o carregamento da edificação sobre o conjunto fundações e maciço. 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.

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 de 20% da carga admissível de projeto para o ensaio do tipo lento.

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.

É importante levar em consideração 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 60min , após esse período a leitura é realizada de hora em hora. O critério de estabilização do recalque estabelecido pela NBR 12131 (ABNT, 2006) é a diferença de deslocamento medida entre duas leituras consecutivas ser 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 a carga de trabalho. No final desse processo, caso não haja a ruptura do elemento de fundação, é necessário mantê-lo sob a pressão do último estágio por um período de 12 horas.

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.

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 ^{bcd}	Número total de estacas da obra a partir do qual serão obrigatórias provas de carga ^{bcd}
Pré-moldada ^a	7,0	100
Madeira	-	100
Aço	0,5F _{yk}	100
Hélice e hélice de deslocamento (monitoradas)	5,0	100
Estacas escavadas com ou sem fluido $\varnothing \geq 70\text{cm}$	5,0	75
Raiz ^e	15,5	75
Microestaca ^e	15,5	75
Trado segmentado	5,0	50
Franki	7,0	100
Escavada sem fluido $\varnothing < 70\text{cm}$	4,0	100
Strauss	4,0	100

Notas:

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

^b 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.

^c 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.

^d 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.

^e Diâmetros nominais.

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

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, conforme observado na Figura 5.



Figura 5 Prova de carga estática

Fonte Geoprova Engenharia, Ensaios e Monitoramento

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.

2.5 Método Para Previsão de Ruptura de Estaca

Segundo a NBR 6122 (ABNT, 2019) o comportamento de uma estaca ou tubulão, quando submetido à prova de carga, pode não apresentar ruptura nítida. Isto ocorre em duas circunstâncias:

- a) Quando a carga de ruptura da estaca ou tubulão é superior à carga máxima que se pretende aplicar (por exemplo, por limitação de reação);
- b) Quando a estaca ou tubulão é carregada até apresentar recalques elevados, mas que não configuram uma ruptura nítida como descrito.

Os critérios mais utilizados para a extrapolação da curva da carga de ruptura são: Van Der Veen (1953), Mazurkiewicz (1972), Décourt (1996) e o critério da própria NBR 6122 (ABNT, 2019). Entretanto neste estudo, será utilizado somente o método de Van Der Veen (1953), por ser o mais utilizado.

2.5.1 Método da NBR 6122

Neste método a carga de ruptura pode ser convencionalizada como aquela que corresponde, na curva de carga x deslocamento como exemplificada na Figura 6, 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 modulo 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;

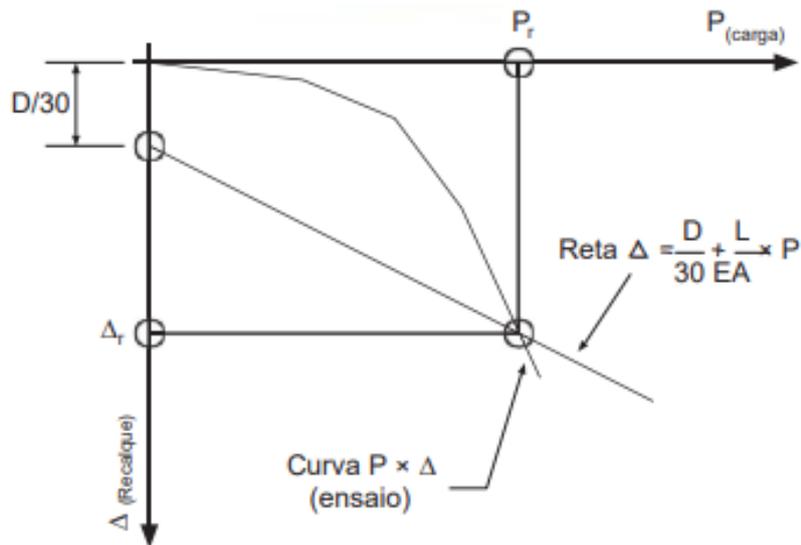


Figura 6: Carga de ruptura convencional

Fonte: ABNT NBR 6122 (pp27, 2019)

2.5.1 Van der Veen

Segundo Jesus (2019) esse método 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).

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

Segundo Jesus (2019), a partir da Equação (3) é possível deduzir uma relação linear entre o valor $\ln \left(1 - \frac{P}{P_r} \right)$ e o recalque r . Partindo-se de um determinado valor qualquer de uma carga de ajuste P_r adotada, calculam-se os valores correspondentes de $\ln \left(1 - \frac{P}{P_r} \right)$ que são então, plotados em um gráfico em função do recalque r . A partir dessa etapa são realizadas novas tentativas com diferentes valores de P_r até que o gráfico resultante das operações se assemelhe com uma linha reta, adotando assim este valor de P_r como o valor de carga de ruptura do elemento. A curva que apresenta o melhor coeficiente de correlação R^2 , proporcionará a carga de ruptura do ensaio, observado na Figura 7.

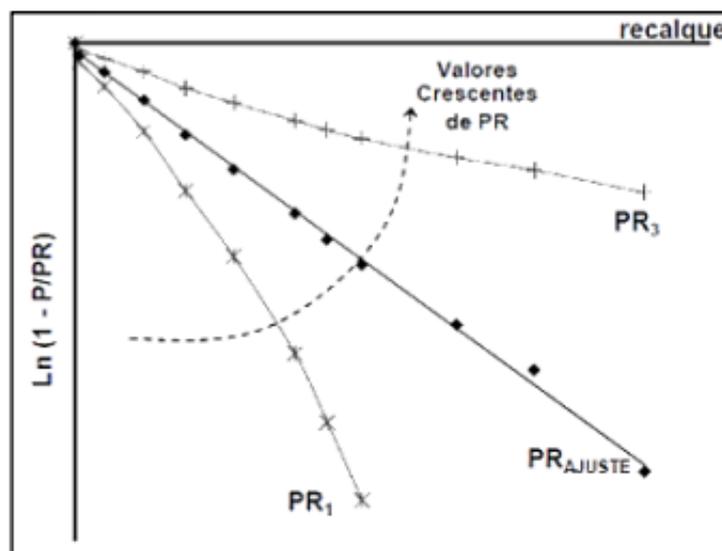


Figura 7 Definição da carga de ajuste, Método de Van der Veen (1953)

Fonte: Experimentos de Previsão da Carga de Ruptura em Estacas Carregadas Axialmente à Compressão Utilizando Redes Neurais Artificiais (RNA). JESUS (2019, Pp 55).

Aoki (1976), apud Cintra e Aoki (1999) observando que em grande parte dos casos, o trecho inicial da curva poderia ser desprezado na determinação da capacidade de carga, sugeriu uma modificação da equação. A equação foi então reescrita, dando origem ao método de Van der Veen generalizado ou também conhecido como Van der Veen modificado por Aoki (1976), Equação (4).

$$P = P_r(1 - e^{-(b+ar)}) \quad (4)$$

Segundo Jesus (2019), a curva ajustada (Figura 7) é obtida arbitrando-se valores para r e calculando os valores correspondentes para P . Ou seja, calcula-se $P = P_r(1 - e^{-(b+ar)})$. Aplicando-se propriedades logarítmicas é encontrada a Equação (5).

$$ar + b = -\ln\left(1 - \frac{P}{P_r}\right) \quad (5)$$

A Equação (5) leva a uma reta, representada na Figura 8.

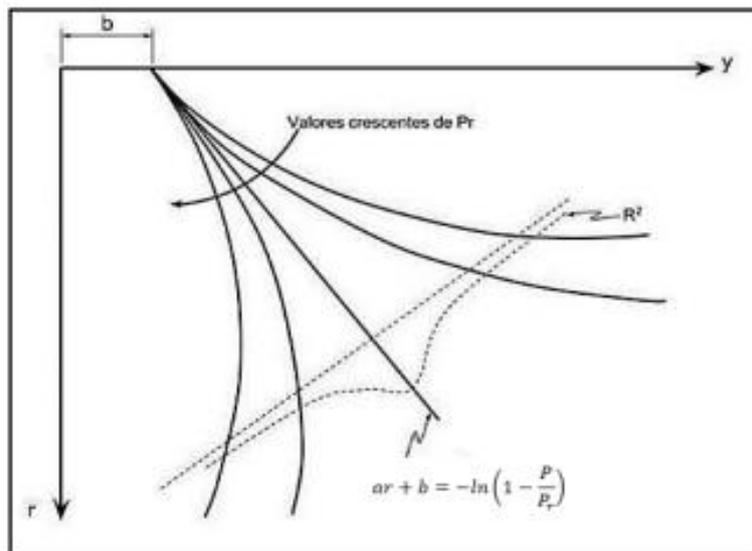


Figura 8 Curva ajustada pelo método de Van der Veen (1953), modificado por Aoki (1976)

Fonte: Experimentos de Previsão da Carga de Ruptura em Estacas Carregadas Axialmente à Compressão Utilizando Redes Neurais Artificiais (RNA). JESUS (2019, pp 56)

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)

4. METODOLOGIA

Para desenvolver este estudo, foi realizada uma pesquisa bibliográfica com intuito de compreender melhor o assunto e escolher técnicas computacionais. Após a pesquisa bibliográfica, deu-se início à fase de organização do banco de dados e elaboração do algoritmo, conforme apresentado abaixo

4.1 Banco de dados

A preparação do banco de dados se deu por meio da separação das informações acerca das fundações e do solo em que essas fundações seriam assentes. Dessa forma, as fundações escolhidas para alimentação do banco de dados foram estacas tipo hélice contínua, apenas com armadura de ligação, e os solos foram àqueles obtidos por meio das sondagens. Sendo assim, foram separados os parâmetros de diâmetro, profundidade das estacas, tipo de solo, valor de NSPT, posição de nível d'água e região administrativa de Brasília em que a fundação se encontrava.

Foi utilizado como base o trabalho de Oliveira (2018), seguindo o mesmo padrão de estruturação, demonstrado pela Tabela 2. Porém, como o objetivo deste trabalho é prever a carga de ruptura apenas para as estacas do tipo hélice contínua, todos os dados referentes a outros tipos de estacas foram desconsiderados, bem como o parâmetro de coeficiente de mola que foi utilizado no trabalho do Oliveira.

Tabela 2 Exemplo da organização do banco de dados

Sondagem					Prova de Carga											
Nome	Região	L (m)	D (m)	Q_{trab} (tf)	NF					d (m)	Arg	Sil	Ar	P (kN)	ρ (mm)	Carga de ruptura (kN)
					Σ	Med	Pond	Média Pond	N_p							
SP1_ E29A	Águas_ Claras	23,12	0,6	0	299	13	89,1	7,68	63	0	0,91	0,09	0	49,03	173,42	1783,027
SP1_ E29A	Águas_ Claras	23,12	0,6	0	299	13	89,1	7,68	63	0	0,91	0,09	0	196,13	693,68	1913,492
SP1_ E29A	Águas_ Claras	23,12	0,6	0	299	13	89,1	7,68	63	0	0,91	0,09	0	392,27	1387,36	468,377
SP1_ E29A	Águas_ Claras	23,12	0,6	0	299	13	89,1	7,68	63	0	0,91	0,09	0	588,4	2081,04	296,422
SP1_ E29A	Águas_ Claras	23,12	0,6	0	299	13	89,1	7,68	63	0	0,91	0,09	0	784,53	2774,71	235,949
SP2_ E1B	Águas_ Claras	23,12	0,5	0	308	16,21	110,5	9,53	60	0	0,87	0,09	0,04	49,03	249,72	980,665
SP2_ E1B	Águas_ Claras	23,12	0,5	0	308	16,21	110,5	9,53	60	0	0,87	0,09	0,04	196,13	998,9	406,493
SP2_ E1B	Águas_ Claras	23,12	0,5	0	308	16,21	110,5	9,53	60	0	0,87	0,09	0,04	392,27	1997,79	327,570
SP2_ E1B	Águas_ Claras	23,12	0,5	0	308	16,21	110,5	9,53	60	0	0,87	0,09	0,04	588,4	2996,69	231,425

Fonte: Próprio autor

As informações utilizadas para a estruturação dos dados conforme demonstrados na Tabela 2, foram retiradas dos relatórios de prova de carga, dos relatórios de sondagem ou dos projetos de fundações, sendo a nomenclatura utilizada apresentada no Quadro 2

Quadro 2 Nomenclatura utilizada no banco de dados

ID	Tipo	Origem
Região	Região administrativa de Brasília	Projeto
L	Comprimento da estaca	Prova de carga
D	Diâmetro da estaca	Prova de carga
Q_{trab}	Carga de trabalho da estaca	Projeto
N_F	N_{SPT} representativo do fuste da estaca	Sondagem SPT
N_P	N_{SPT} 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	Sondagem SPT
Sil	Fator representativo da quantidade de Silte	Sondagem SPT
Ar	Fato representativo da quantidade de Areia	Sondagem SPT
P	Carga aplicada na estaca	Prova de carga
ρ	Recalque	Prova de carga
Carga de ruptura	Carga de ruptura da estaca	Prova de carga

Fonte: Próprio autor

A Figura 9, apresenta como fora determinado o parâmetro d citado no Quadro 2.

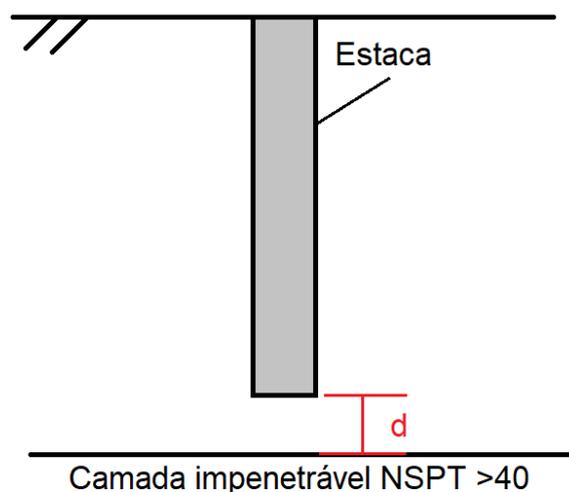


Figura 9 Representação do parâmetro d

Fonte: Próprio autor

4.1.2 Análise de dados de provas de carga e sondagem

Para complementar o banco de dados, foi necessário analisar várias provas de carga e relatórios de sondagens. Após a coleta destes dados, o banco de dados fora criado com auxílio da ferramenta computacional Excel. Tendo como base o trabalho de Oliveira (2018), os dados foram organizados, assim como apresentado na Tabela 2.

Com o objetivo de coletar primeiramente dados sobre o solo, foi necessário analisar relatórios de sondagens, onde foi possível determinar a composição do solo, NSPT, a profundidade do impenetrável, e alguns dados de projeto da estaca como comprimento, diâmetro e carga de projeto. Outro parâmetro que foi coletado com base na análise das sondagens foi o d (distância da ponta da estaca ao impenetrável do solo) (Figura 9) a partir de uma correlação entre o comprimento L do elemento estrutural, e qual o NSPT respectivo da camada onde a ponta da estaca se encontra.

Analisando as provas de cargas foi possível coletar informações importantes para o banco de dados. Primeiramente foi analisado a relação recalque e carga de ruptura através do método de Van der Veen (Figura 10)

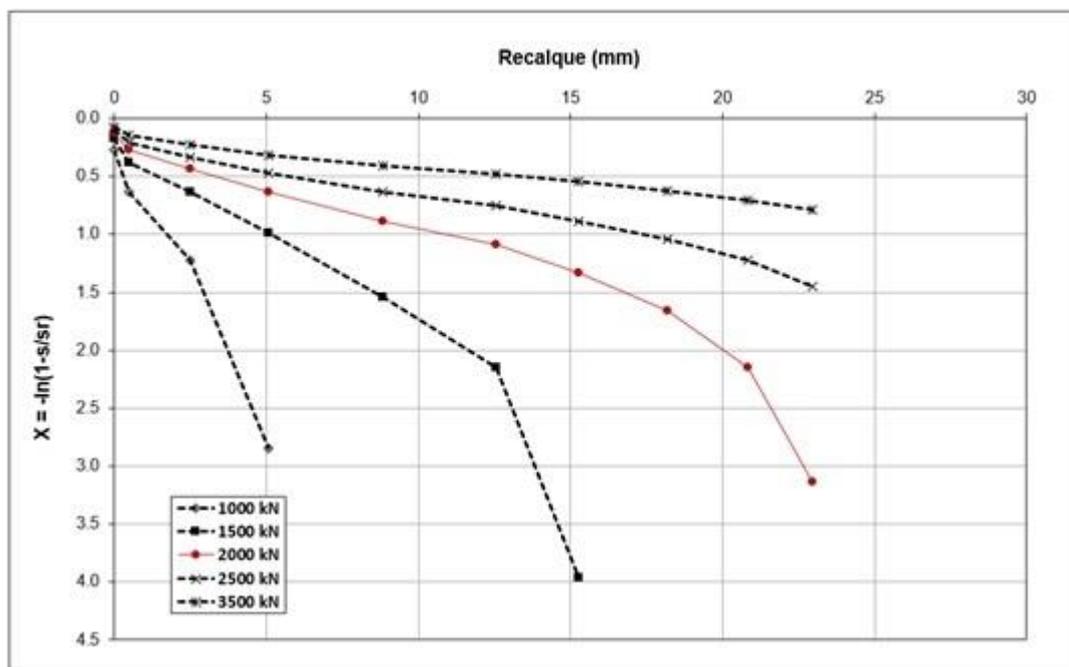


Figura 10 Exemplo da extrapolação da carga de ruptura através do método de Van Der Veen

Analisando a Figura 10 é possível concluir que, para a estaca analisada, a carga de ruptura considerada é de 2.000kN. Tendo como base a carga de ruptura, é possível analisar o gráfico de Recalque x Carga de ruptura (Figura 11), para aferir o recalque. Neste trabalho, o recalque analisado é o recalque residual ou plástico.

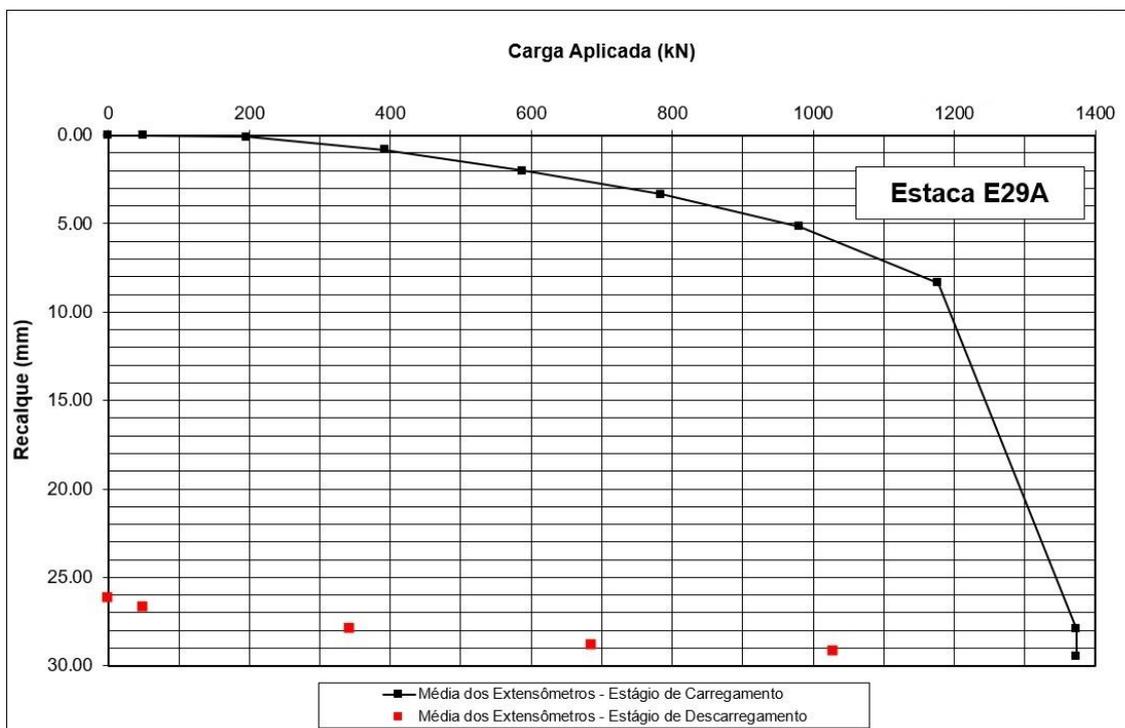


Figura 10 Exemplo de curva Carga x Recalque

Observando a Figura 11 é possível concluir que, na estaca analisada, o recalque residual é de aproximadamente 24 mm. Com estas informações, foi possível organizar o banco de dados conforme demonstrado na Tabela 2.

Houveram alguns relatórios de prova de carga, que não forneciam o gráfico do método de Van Der Veen, neste caso foi necessário estimar a carga de ruptura através do critério apresentado por Decourt, onde a deformação é igual a 10% (dez por cento) do diâmetro da estaca.

4.2 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*. Para desenvolver o código, foram escolhidas as seguintes bibliotecas demonstradas pelo Quadro 3.

Quadro 3 Bibliotecas utilizadas no algoritmo.

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

Fonte: Próprio autor

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. O modelo de predição do valor da carga de ruptura foi criado, usando como base nos dados de treinamento e na biblioteca *Scikit-learn*, como demonstrado pela Figura 12.

```
[ ] 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)
```

/usr/local/lib/python3.10/dist-packages/sklearn/ensemble/_forest.py:413: FutureWarning: `max_features='auto'` has
warn(
RandomForestRegressor
RandomForestRegressor(bootstrap=False, max_features='auto', n_estimators=1000,
n_jobs=-1, random_state=42)

Figura 11 implementação do modelo de *Random Forest*

Fonte: Próprio autor

O parâmetro `max_features='auto'`, foi definido para que o método escolhesse o melhor ponto de corte para definição das árvores de regressão. O critério `n_estimators= 1000` define o número máximo de árvores que podem ser criadas e o parâmetro `random_state=42` torna os resultados do modelo replicáveis. Já o critério Hiperparâmetro `n_jobs=-1`, é responsável por informar a quantidade de

processadores que o algoritmo poderá utilizar. O valor igual a -1 significa que a quantidade de processadores será ilimitada.

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 serão 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. Como forma da separação ser feita de modo aleatório, utilizou-se o parâmetro `train_test_split`.

É possível observar na Figura 13, uma representação simplificada do funcionamento das árvores de regressão por meio de um fluxograma de perguntas e respostas que levam a uma decisão tomada pelo modelo.

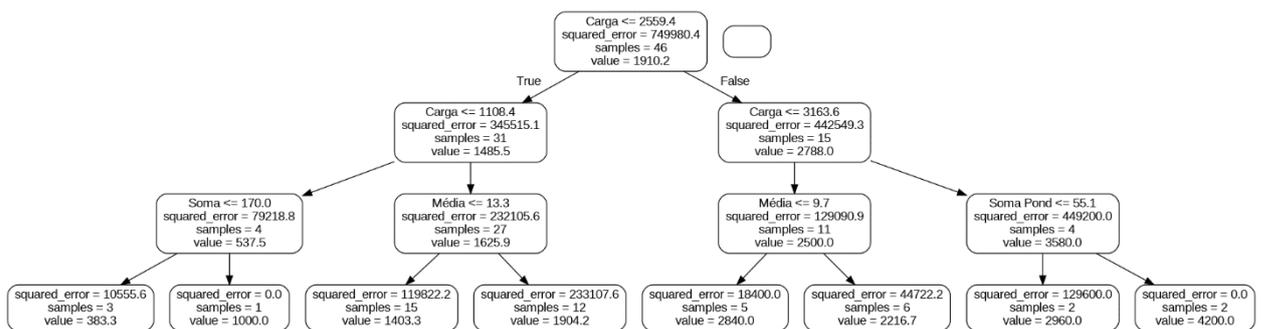


Figura 12 Fluxograma representando uma árvore pequena da floresta de regressão

Fonte: Próprio Autor

Baseado na análise entre os valores estimados pelo modelo com base nos dados de aprendizados e nos valores reais, é possível estimar a precisão da IA a partir do erro médio absoluto.

4.3 Erro médio absoluto

A precisão do modelo foi calculada através do erro médio absoluto, que é demonstrado pela Equação (6).

$$erros = \left| \frac{y_{pred} - y_{test}}{y_{total}} \right| * 100 \quad (6)$$

Onde,

Y_{pred} é a previsão;

Y_{test} é o valor verdadeiro;

Y_{total} é o número total de pontos de dados.

5. RESULTADOS E ANÁLISES

Os resultados serão apresentados primeiramente a partir da caracterização inicial do *dataset*. A Figura 14 apresenta as regiões administrativas em que foram obtidos os dados para análise desta pesquisa.

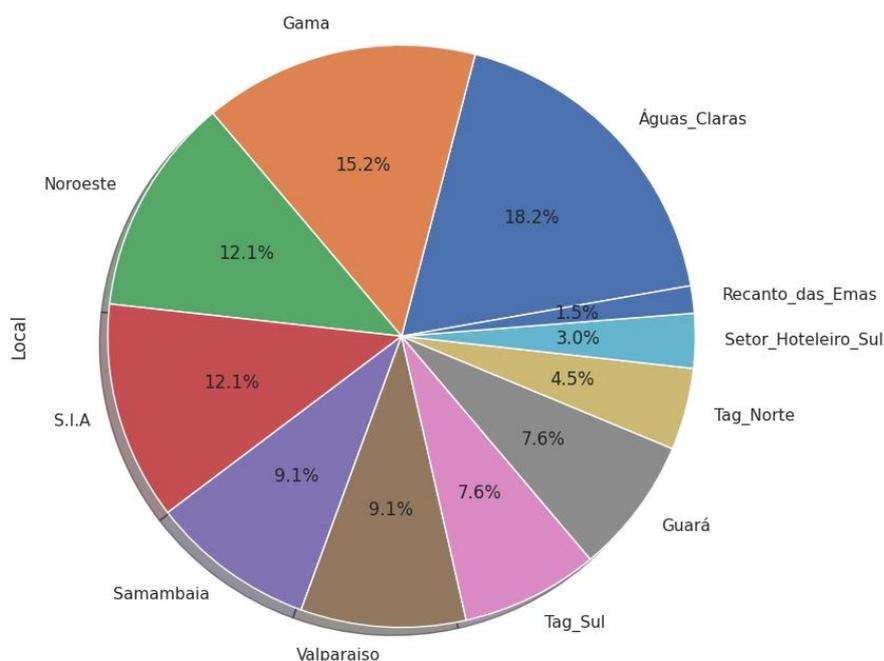


Figura 14 Gráfico Local x Entradas de dados

Fonte: Próprio Autor

Analisando a Figura 14, é possível afirmar que as regiões administrativas que agregaram maior número de dados às análises foram Águas Claras (27 provas de carga), Gama (23 provas de carga), Noroeste (18 provas de carga) e SIA (Setor de Indústria e Abastecimento) (18 provas de carga), respectivamente.

Ainda analisando os dados regionais, as Figuras 15, 16, 17 e 18 mostram algumas tendências características observadas em cada local analisado. A Figura 15 apresenta a correspondência entre o comprimento médio da estaca hélice com a região administrativa em que essa estaca se encontrava.

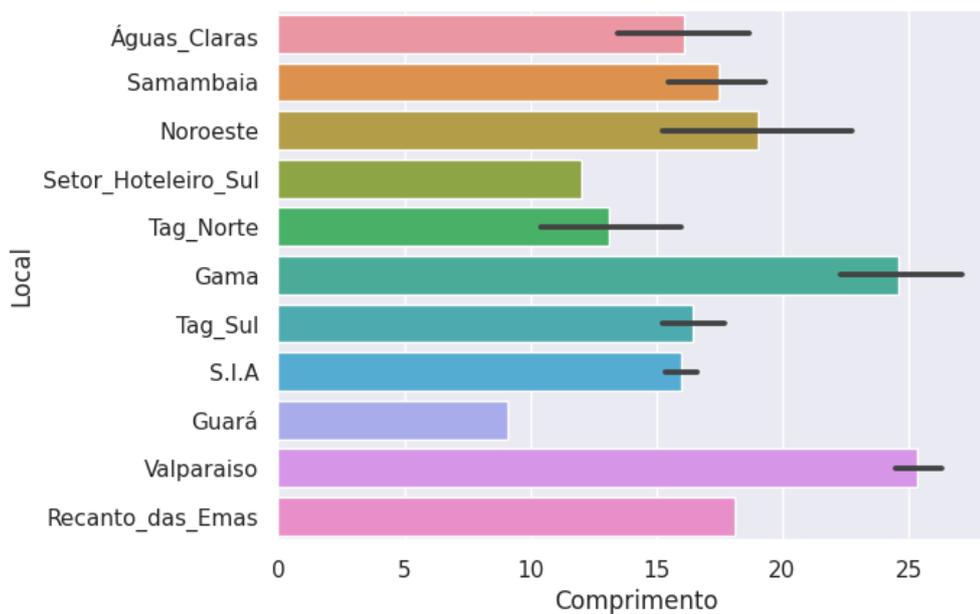


Figura 13 Gráfico Correspondência do Comprimento Médio x Local

Fonte: Próprio Autor

Observando a Figura 15, é possível concluir que os locais que apresentam as estacas com maiores comprimentos são Valparaiso e Gama. A Figura 16 apresenta a correspondência entre o diâmetro e a região administrativa das estacas analisadas.

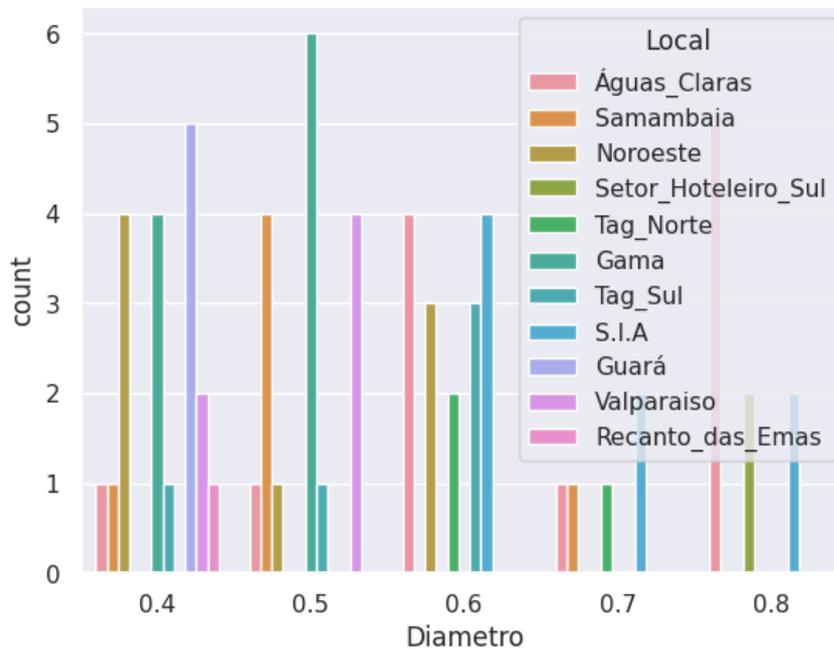


Figura 16 Gráfico Correspondência entre Diâmetro x Local

Fonte: Próprio Autor

Nota-se na Figura 16, que a região administrativa com a maior quantidade de estacas de diâmetro de 0,4 metros é o Guará, a região com maior quantidade de estacas com diâmetro de 0,5 metros é o Gama, as regiões com maior quantidade de estacas com diâmetro de 0,6m é o S.I.A e Águas Claras, a região com mais estacas com diâmetro de 0,7 metros é o S.I.A e a região com mais estacas com diâmetro de 0,8 metros é Águas Claras.

A Figura 17 apresenta a correspondência entre a média de recalque e a região administrativa das estacas analisadas.

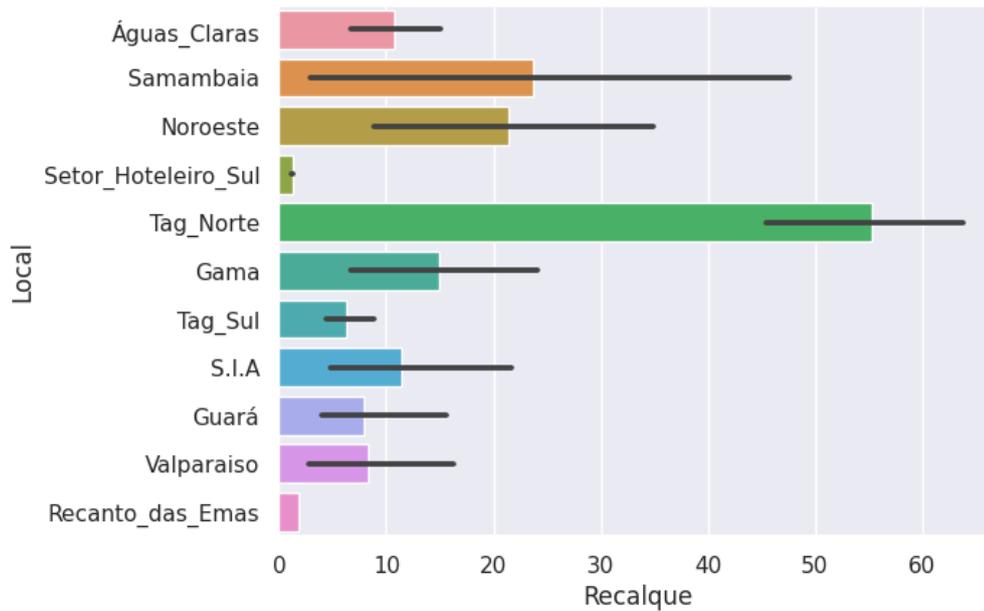


Figura 17 Gráfico correspondência Média de recalque x Local

Fonte: Próprio Autor

Observando a Figura 17, é possível afirmar que a região administrativa que apresenta o maior recalque médio é Taguatinga Norte. A Figura 18 apresenta a correspondência entre a média de carga de ruptura e o local das estacas analisadas

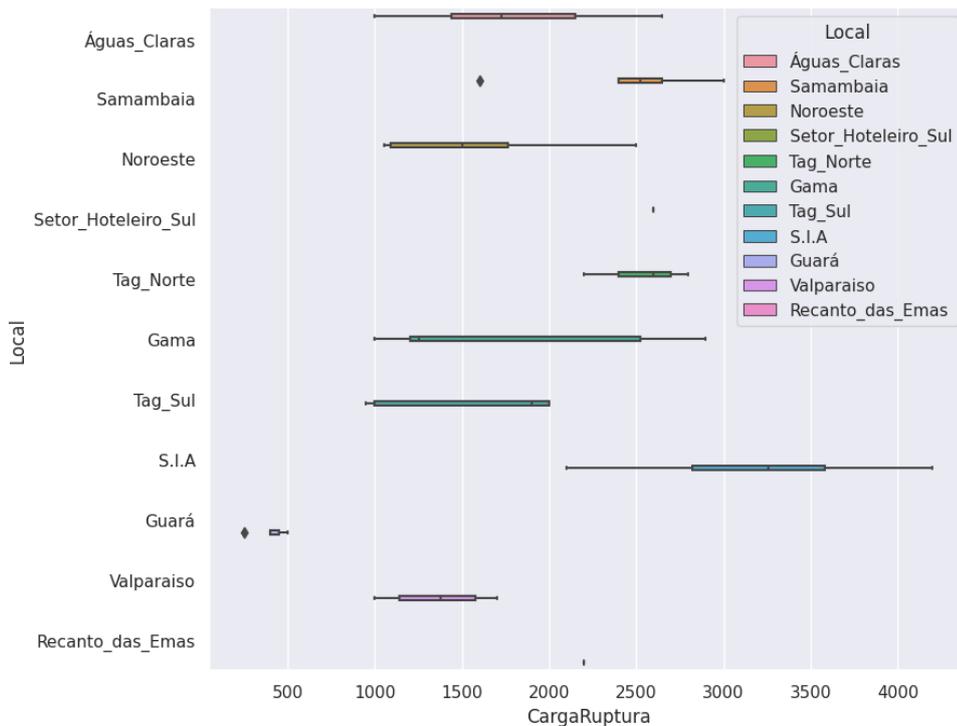


Figura 18 Gráfico Correspondência Carga de ruptura x Local

Fonte: Próprio Autor

Observando a Figura 18, pode-se afirmar que o local com as maiores cargas de ruptura é o S.I.A, variando entre 2000kN e 4000kN. A Figura 19 representa uma correspondência entre o recalque médio e o diâmetro médio.

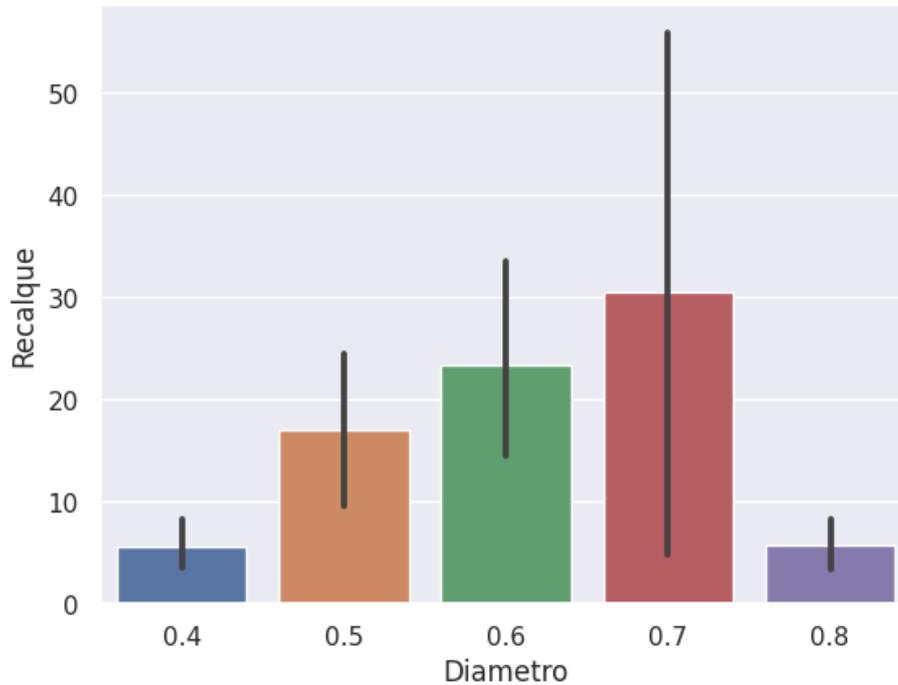


Figura 14 Correspondência Recalque médio x Diâmetro médio

Tendo como base a Figura 19, pode-se perceber que o diâmetro que apresentou o maior recalque foi o de 0,8 metros.

A figura 20 representa um gráfico de calor (*heatmap*). Este modelo representa o coeficiente de correlação de Pearson.

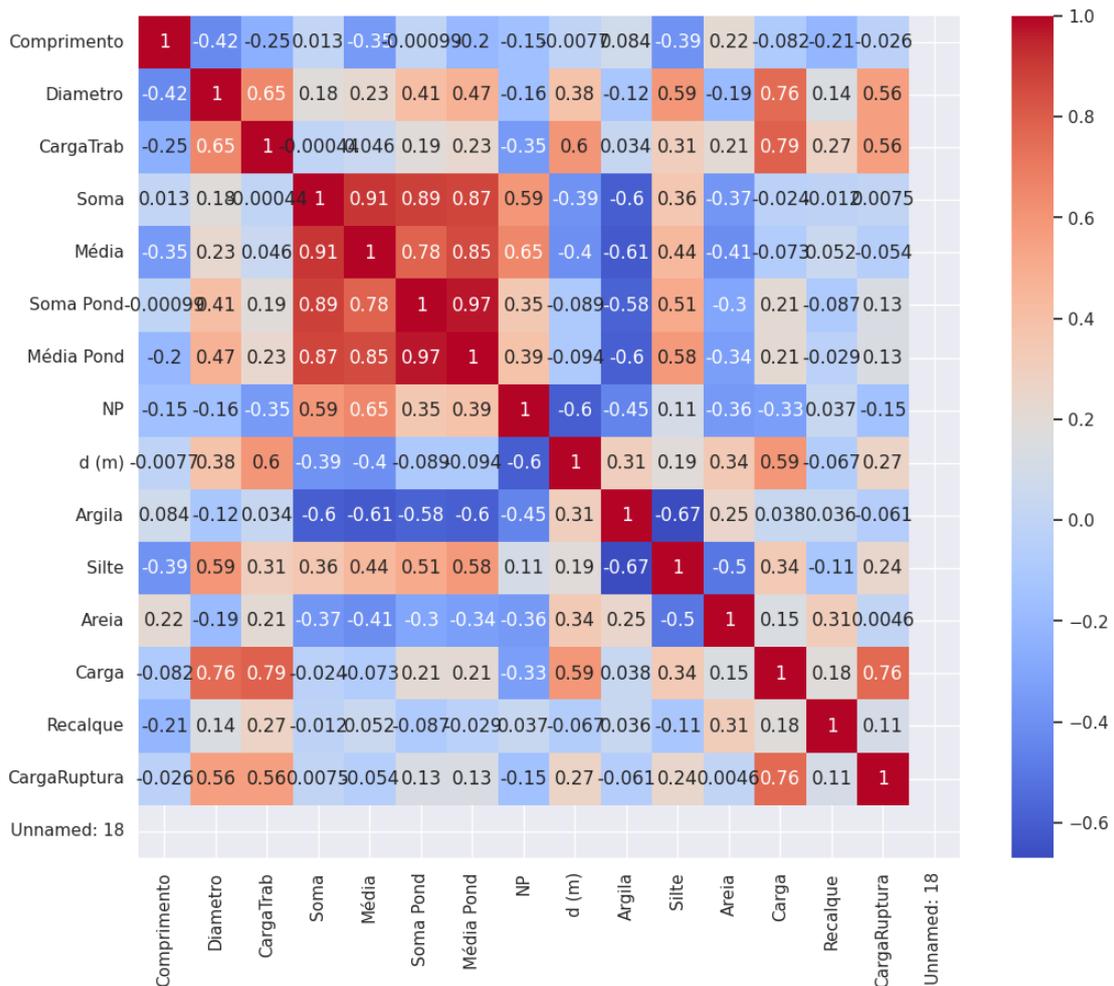


Figura 20 Gráfico de calor com o coeficiente de Pearson

Fonte: Próprio Autor

Observando a Figura 20, e tendo como base a classificação proposta por Cohen (1988), é possível afirmar que, no geral existe pouca relação linear (abaixo de 0,7) entre os dados. Porém, as variáveis Diâmetro e Carga de Trabalho apresentam escore médio, o que implica uma maior relação desta variável com a carga de ruptura.

5.2 Avaliação da precisão do modelo

A Figura 21 apresenta o cálculo do err médio absoluto, afim de encontrar a precisão do modelo utilizado.

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

Acurácia: 78.12 %.

Figura 21 Cálculo do erro médio absoluto

Fonte: Próprio Autor

Observando a Figura 21, nota-se que a precisão do modelo encontrada foi de 78,12%, o que é uma precisão considerada satisfatória.

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 22).

	Valor_Real	Valor_Previsto
1	1400	1460.50
47	1050	1533.10
65	2400	2036.00
15	2650	1210.70
26	1000	1239.10
55	1000	1211.75
43	1000	1874.00
10	1600	2500.00
42	4200	2300.00
45	1700	2014.20
18	2200	1975.30
7	2400	2854.05
11	1400	1371.65
12	1600	2404.35
14	2600	2600.00
0	1400	1455.25
4	2650	2477.30
19	2800	3382.40
16	2100	2231.20
49	1050	1530.90

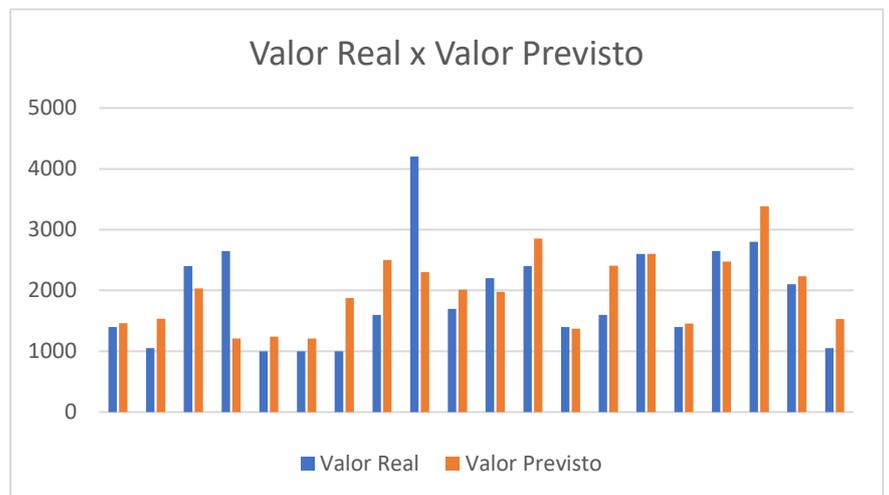


Figura 22 Comparação entre uma parte dos valores reais e dos previstos pelo modelo

Fonte: Próprio Autor

Tem como base os dados apresentados pela Figura 22, podemos perceber que a linha 10, foi a que demonstrou a maior discrepância de valor com a IA prevendo um valor 187,4% acima do real. Na Figura 23 é possível observar quais variáveis contribuem mais para o modelo de predição.

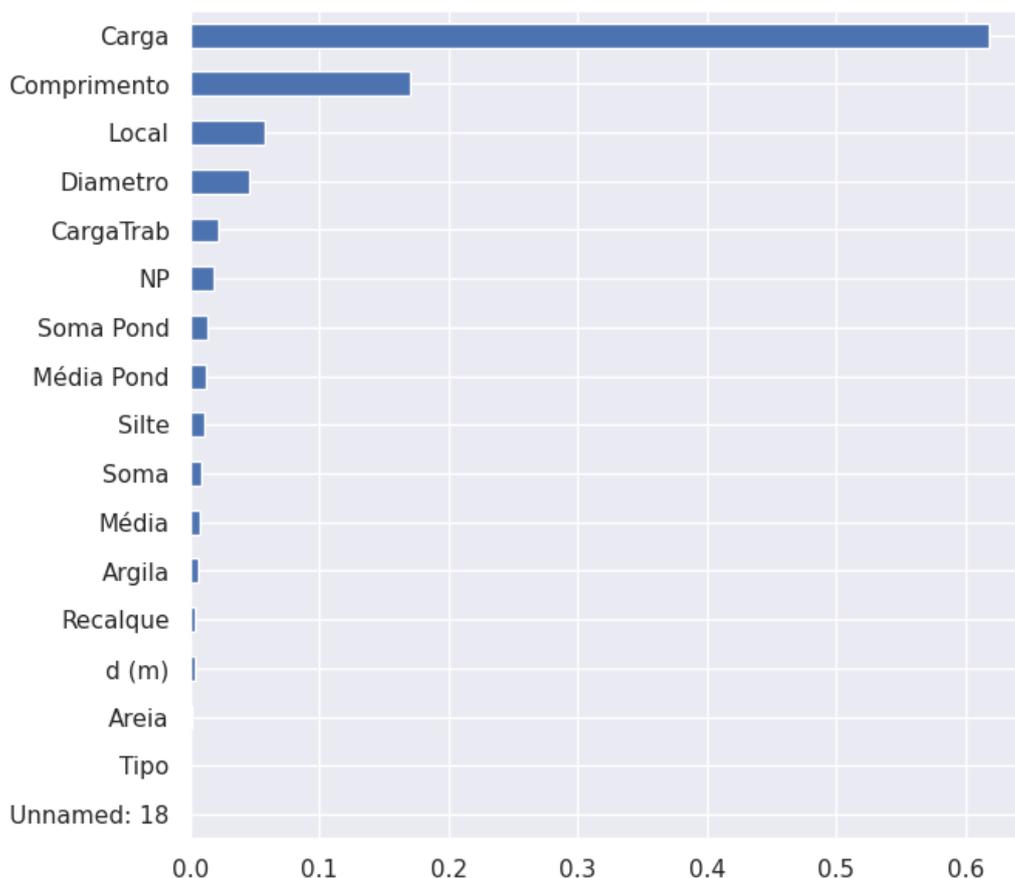


Figura 23 Gráfico de importância de cada variável

Fonte: Próprio Autor

Com base na Figura 23, pode-se concluir que as variáveis mais relevantes para o modelo é a carga seguido pelo comprimento. O que já era esperado, pois a capacidade de carga de uma estaca está diretamente relacionada com a geometria do elemento e geologia local.

Com relação aos parâmetros derivados das sondagens SPT, as variáveis silte e a soma do NSPT, são as variáveis mais relevantes. Isso se deu, devido ao fato de grande parte das estacas analisadas estarem assentadas em camadas de

silte, enquanto a soma do NSPT já se esperava um grau de importância grande, pois está relacionado com a resistência lateral das estacas.

6. CONSIDERAÇÕES FINAIS

Com base nos resultados apresentados, foi possível concluir que a região com maior entrada de dados no banco de dados analisado, foi Águas claras (a qual representa 18,2% dos dados, 27 provas de carga). Além de analisar qual região compõe a maior parte dos dados, foi possível analisar qual região possui elementos de fundação com maiores diâmetros, sendo o Gama a região administrativa tendo a maior média de diâmetros. Outra análise realizada foi o recalque médio de cada região administrativa, e a região de Taguatinga Norte foi a que apresentou o maior recalque médio. Além destas correlações, fora possível realizar a comparação entre as variáveis e correlacioná-las com o diagrama de Pearson para determinar sua importância.

Ao analisar a relevância das variáveis utilizadas, chegou-se a conclusão que a variabilidade geológica dos solos torna difícil a previsão, já que o comportamento do solo pode ser diferente mesmo estando na mesma região geográfica.

Desta forma, foi possível obter resultados com acurácia de 78,12%. Porém, vale ressaltar que existem limitações em relação ao resultado final, que influenciaram no valor da acurácia, tais como: o número limitado da amostragem de dados utilizada (67 provas de carga), a variabilidade geotécnica do perfil estratigráfico associado aos ensaios pontuais de SPT, o que dificulta a representatividade das condições do solo local, e o próprio aprendizado supervisionado utilizado (*Random Forest*) que quanto maior a dispersão de dados produz resultados com menor capacidade de previsão. que o método pode ser empregado, mas com cautela, em razão da previsão ter sido inferior a 90%.

A quantidade de dados para melhoramento da precisão é um fator essencial que deve permanecer em estudo. Para aumentar a acurácia, seria necessário também, utilizar outras técnicas computacionais, como redes neurais, já que o método escolhido (*Random Forest*) tem menor capacidade de adaptação a situações de grande dispersão de dados.

6.1 Sugestões Para Pesquisas Futuras

A sondagem por si só é um método de investigação pontual que nem sempre retrata as condições de campo em sua totalidade, o que pode provocar a dispersão de dados para análise. Dessa forma, propõe-se para estudos posteriores, a utilização de outros ensaios, como os geofísicos, que retratem de forma mais precisa e ampla o perfil geotécnico e possam se relacionar as sondagens de forma a permitir a elaboração de algoritmos mais precisos quanto a modelagem do solo. Propõe-se então, para estudos posteriores que sejam feitos algoritmos que consigam modelar o solo, e integrar os dados de ensaios geotécnicos com ensaios geofísicos para proporcionar uma melhor caracterização do subsolo. Sugere-se também a utilização de métodos computacionais diferentes para predição, como rede neural.

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT (2020). **NBR16903, Solo — Prova de carga estática em fundação profunda**, Rio de Janeiro 11p.

ABNT (2019). **NBR 6122 - Projetos e execuções de fundações**, Rio de Janeiro 33p.

CINTRA, J.C.A.; AOKI, N.; TSUHA, C.H.C.; GIACHETI, H.L. **Fundações: ensaios estáticos e dinâmicos**. 1.ed. São Paulo: Oficina de Textos, 2013.

CINTRA, J. C. A.; AOKI, N. **Fundações por estacas: projeto geotécnico**. São Paulo: Oficina de Textos, 2010, 96p.

DATA SCIENCE FOUNDATION, (2020). **Understanding Decision Trees with Python**. Disponível em <https://datascience.foundation/sciencewhitepaper/understanding-decision-trees-with-python> Acesso em: 25 set 2022.

DOBREV, D. (2004). **Applications of artificial intelligence in engineering problems**. SRIRAM, D, AND ADEY, R. UNITED KINGDOM: N. p., 1986. Web.

El Naqa, I., Murphy, M.J. (2015). **What Is Machine Learning?** In: El Naqa, I., Li, R., Murphy, M. (eds) Machine Learning in Radiation Oncology. Springer, Cham. Disponível em https://doi.org/10.1007/978-3-319-18305-3_1

IBM CLOUD EDUCATION, (2020). **Redes Neurais**. Disponível em <https://www.ibm.com/br-pt/cloud/learn/neural-networks>

JESUS B. V., (2019). **Experimentos de Previsão da Carga de Ruptura em Estacas Carregadas Axialmente à Compressão Utilizando Redes Neurais Artificiais (RNA)**, Dissertação (mestrado em engenharia civil) - Universidade do Rio de Janeiro, Centro de Tecnologia e Ciências Faculdade de Engenharia, Rio de Janeiro 2019.

KOK, J. N.; BOERS E. J. W.; KOSTERS, W. A.; PUTTEN, P. V. (2009). **Artificial Intelligence: Definition, Trends, Techniques, and Cases Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions**.

Leiden Institute of Advanced Computer Science, Leiden University, the Netherlands 2009.

Marangon, M. (2018) **Geotecnia de Fundações e Obras de Terra**. Apostila, disponível em < [Núcleo de Geotecnia \(ufff.br\)](http://www.nucleo.geotecnia.ufjf.br) Acesso em: 10 out. 2022.

MICROSFT, (2022) **Aprendizado profundo e o aprendizado de máquina - Azure Machine Learning**. Disponível em <<https://learn.microsoft.com/pt-br/azure/machine-learning/concept-deep-learning-vs-machine-learning> Acesso em: 31 out. 2022.

MOHAMED A. S., 2016. **State-of-the-art review of some artificial intelligence applications in pile foundations**. Department of Civil Engineering, Curtin University, Perth, WA 6845, Australia, 2014. Artigo publicado em Geoscience Frontiers 2016.

NAVID K., ANNAN Z., MAJIDREZA N., SHUI-LONG S. (2019). **Estimation of Bearing Capacity of Piles in Cohesionless Soil Using Optimised Machine Learning Approaches**. Civil and Infrastructure Engineering Discipline, School of Engineering, Royal Melbourne Institute of Technology Australia. Artigo publicado em Geotech Geol Eng 2019.

OFRIKHTER I. V., AND PONOMAREV A. B., (2021). **Estimation of Load-set Behavior of Driven Concrete Piles Using Artificial Neural Network and Cone Penetration Test**, Artigo publicado em Deep Foundations and geotechnical problems of territories (DFGC 2021) Journal of Physics: Conference Series 1928 (2021) 012055 IOP Publishing doi:10.1088/1742-6596/1928/1/012055 2021.

OLIVEIRA Y. M. (2018). **Machine Learning Aplicado na Estimativa do Coeficiente de Mola de Estacas com Validação por Meio de Provas de Carga Estáticas**. Tese de conclusão de curso (graduação em engenharia civil) - Centro Universitário de Brasília, Faculdade de Tecnologia e Ciências Sociais Aplicadas, Brasília 2018.

PENGZHEN LU, SHENGYONG CHEN AND YUJUN ZHENG. (2012). **Artificial Intelligence in Civil Engineering**. Artigo publicado em Mathematical Problems in Engineering Volume 2012.

Ongsulee, P., "**Artificial intelligence, machine learning and deep learning**," 2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE), 2017, pp. 1-6, doi: 10.1109/ICTKE.2017.8259629.

PYTHON SOFTWARE FOUNDATION (2022). **What Is Python? Executive Summary**. Artigo disponível em <<https://www.python.org/doc/essays/blurb/>>

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.

WANG, SC. (2003), **Artificial Neural Network**. In: **Interdisciplinary Computing in Java Programming**. The Springer International Series in Engineering and Computer Science 2003. VOL 743. SPRINGER, BOSTON, MA.