



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE CRATEUS
CURSO DE ENGENHARIA CIVIL

WILLIAN LINO SOUSA

**MODELO EM APRENDIZAGEM DE MÁQUINA PARA PREVISÃO
DE CAPACIDADE DE CARGA DE FUNDAÇÕES DIRETAS**

CRATEÚS
2023

WILLIAN LINO SOUSA

MODELO EM APRENDIZAGEM DE MÁQUINA PARA PREVISÃO DE CAPACIDADE
DE CARGA DE FUNDAÇÕES DIRETAS

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia Civil
da Universidade Federal do Ceará, como
requisito parcial à obtenção do título de
bacharel em Engenharia Civil.

Orientador: Prof. Me. Marcio Avelino de
Medeiros

Co-orientador: Me. Lívio Antonio Melo
Freire

CRATEUS
2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

S698m Sousa, Willian Lino.

Modelo em aprendizagem de máquina para previsão de capacidade de carga de fundações diretas / Willian Lino Sousa. – 2023.

38 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Crateús, Curso de Engenharia Civil, Crateús, 2023.

Orientação: Prof. Me. Marcio Avelino de Medeiros.

Coorientação: Prof. Me. Lívio Antonio Melo Freire.

1. Machine Learning. 2. capacidade de carga. 3. fundações diretas. 4. modelagem. I. Título.

CDD 620

WILLIAN LINO SOUSA

MODELO EM APRENDIZAGEM DE MÁQUINA PARA PREVISÃO DE CAPACIDADE
DE CARGA DE FUNDAÇÕES DIRETAS

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia Civil
da Universidade Federal do Ceará, como
requisito parcial à obtenção do título de
bacharel em Engenharia Civil.

Aprovada em: 12/12/2023.

BANCA EXAMINADORA

Prof. Me. Marcio Avelino de Medeiros (Orientador)
Universidade Federal do Ceará (UFC)

Me. Lívio Antonio Melo Freire (Co-orientador)
Petrobrás

Prof. Me. Thiago Fernandes da Silva
Universidade Federal do Ceará (UFC)

Prof. Me. Felipe Carlos de Araújo Leal
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

A Deus.

Aos meus pais, familiares e a todos que participaram de forma direta ou indireta da minha trajetória acadêmica.

AGRADECIMENTOS

A Deus, por me permitir alcançar essa conquista.

A meu pais, pelo amor inefável, apoio e motivação na minha jornada acadêmica.

Ao Prof. Me. Marcio Avelino de Medeiros, pela excelente orientação e compromisso.

Ao Prof. Me. Lívio Antonio Melo Freire, pela excelente orientação e compromisso.

Aos amigos, pela presença, apoio e experiências de vida compartilhadas.

Aos colegas da universidade federal do ceará, pelas reflexões, críticas e sugestões recebidas.

“Machines take me by surprise with great frequency.” (Alan Turing)

RESUMO

O problema de estimar a capacidade de carga é essencial na engenharia civil, uma vez que o dimensionamento adequado das fundações é essencial para garantir a segurança e a estabilidade das estruturas. Estudos recentes vem empregando modelos em aprendizagem de máquina em problemas de fundações demonstrando significativa acurácia. O presente estudo buscou desenvolver um modelo para previsão da capacidade de carga em fundações diretas assentadas em diversos tipos de solos. Os resultados obtidos na revisão bibliográfica acerca do tema destacam a eficácia do uso de técnicas de machine learning em fundações diretas. Estudos mostraram que os modelos de aprendizado de máquina são capazes de fornecer estimativas precisas e confiáveis, superando as abordagens tradicionais baseadas em métodos empíricos. Além disso, a literatura também exploraram a influência de diferentes parâmetros geotécnicos e variáveis de entrada como: SPT, tipo de solo, cota de assentamento da sapata, presença do nível de água, entre outros, no desempenho dos modelos de machine learning. Eles mostraram que o uso de variáveis geotécnicas relevantes, como resistência ao cisalhamento do solo e características de compactação, pode melhorar significativamente a precisão dos dados de saída. O modelo criado foi calibrado com base na literatura já existente e foi determinado a partir de técnicas em Machine Learning, com o uso do algoritmo random forest, para previsão da capacidade de carga a partir da alimentação da máquina com os dados de entrada.

Palavras-chave: Machine Learning; capacidade de carga; fundações diretas; modelagem.

ABSTRACT

The problem of estimating load capacity is essential in civil engineering since adequate dimensioning of foundations is essential to guarantee the safety and stability of structures. Recent studies have been using machine learning models in foundation problems, demonstrating significant accuracy. The present study sought to develop a model for predicting the load capacity of direct foundations laid in different types of soil. The results obtained in the accurate literature review on the topic highlight the effectiveness of using machine learning techniques in direct foundations. Studies have shown that machine learning models are capable of providing accurate and reliable estimates, outperforming traditional approaches based on empirical methods. Furthermore, the literature also explored the influence of different geotechnical parameters and input variables such as: SPT, soil type, footing installation level, presence of water level, among others, on the performance of machine learning models. They showed that the use of relevant geotechnical variables, such as soil shear strength and compaction characteristics, can significantly improve the accuracy of the output data. The model created was calibrated based on existing literature and was determined using Machine Learning techniques, using the random forest algorithm, to predict the load capacity based on feeding the machine with input data.

Keywords: Machine Learning, carrying capacity, direct foundations, modeling.

LISTA DE FIGURAS

Figura 1	– Fundação rasa do tipo sapata	13
Figura 2	– Superfície potencial de ruptura	15
Figura 3	– Cunha de solo a base da sapata	15
Figura 4	– Cálculo da capacidade de carga, pelo aplicativo Kroki	19
Figura 5	– Árvore de decisão	20
Figura 6	– Esquema do experimento de erosão interna (adaptado de Lu & Wilson, 2012)	21
Figura 7	– Fluxograma metodológico	22
Figura 8	– Dimensões de uma sapata	24
Figura 9	– Validação cruzada para 5 folds	24
Figura 10	– Gráfico valor predito x valor real (1,00 x 1,00 m)	25
Figura 11	– Gráfico valor predito x valor real (1,50 x 1,50 m)	26
Figura 12	– Gráfico valor predito x valor real (2,00 x 2,00 m)	26
Figura 13	– Gráfico valor predito x valor real (2,50 x 2,50 m)	27
Figura 14	– Gráfico valor predito x valor real (3,00 x 3,00 m)	27
Figura 15	– Gráfico valor predito x valor real (1,00 x 1,00 m)	29
Figura 16	– Gráfico valor predito x valor real (1,50 x 1,50 m)	29
Figura 17	– Gráfico valor predito x valor real (2,00 x 2,00 m)	30
Figura 18	– Gráfico valor predito x valor real (2,50 x 2,50 m)	30
Figura 19	– Gráfico valor predito x valor real (3,00 x 3,00 m)	31

LISTA DE TABELAS

Tabela 1 – Fatores de fórmula (De Beer, 1967, apud Vesic, 1975	16
Tabela 2 – Fatores de capacidade de carga (Vesic, 1975)	16
Tabela 3 – Hiperparâmetros testados	28
Tabela 4 – Métricas calculadas	32

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Objetivos	12
1.1.1	Objetivo Geral	12
1.1.2	Objetivos Específicos	12
2	REFERENCIAL TEÓRICO	13
2.1	Fundações diretas	13
2.2	Capacidade de carga	13
2.3	Teoria de terzaghi	14
2.3.1	Contribuições de Vesic	16
2.4	Aprendizagem de Máquina (<i>Machine Learning</i> – ML)	17
2.5	<i>Machine Learning</i> na geotecnia	18
2.5.1	Programa para cálculo de capacidade de carga	18
2.5.2	Estimativa de coeficiente de mola de estaca	19
2.5.3	Previsão de erosão interna em solos com o uso de machine learning	20
2.5.4	Aprendizagem de máquina na determinação de parâmetros de resistência de filitos brandos	21
3	METODOLOGIA	22
3.1	Parâmetros base do solo	23
3.2	Modelagem em <i>Machine Learning</i>	23
3.3	Treinamento do modelo	23
3.4	Validação Cruzada utilizando K – <i> folds</i>	24
4	RESULTADOS	25
4.1	Resultados dos dados de testes	25
4.2	Otimização dos resultados	28
4.3	Validação do modelo	31
5	CONCLUSÃO	33
6	SUGESTÕES PARA PESQUISAS FUTURAS	34
	REFERÊNCIAS	35
	ANEXO A – BANCO DE DADOS CARREGADOS NA NUVEM DO GOOGLE DRIVE	37

1. INTRODUÇÃO

A Engenharia Geotécnica, especificamente na área de fundações, têm se atualizado cada vez mais na busca de modelos computacionais com maior acurácia em seus resultados. Ao longo dos últimos anos, com a disponibilidade maior de dados de campo, bem como o avanço computacional conquistado, o desenvolvimento de modelos em Machine Learning (aprendizagem de máquina) torna-se uma ferramenta poderosa na previsão de capacidade de carga de fundações.

Machine Learning é uma disciplina da área da Inteligência Artificial que se concentra no desenvolvimento de algoritmos e modelos que permitem aos sistemas de computador aprender e aprimorar seu desempenho em tarefas específicas, sem a necessidade de programação explícita (Alpaydin, E. 2010.)

As técnicas de machine learning têm sido utilizadas em várias áreas da engenharia civil, principalmente na geotecnia, como para susceptibilidade de deslizamento de terra (Marjanović et al., 2011; Tien Bui et al., 2016), para previsão de parâmetros geotécnicos (Ching & Phoon, 2019; Fikret Kurnaz & Kaya, 2018; Prayogo & Susanto, 2018; Puri et al., 2018) e detecção de anomalias em barragens (Belcher et al., 2016; Fisher et al., 2017, 2016).

O objetivo do trabalho é a criação de um modelo em aprendizagem de máquina, usando dados de entrada já conhecidos que foram obtidos em boletins de sondagem, como os parâmetros de um solo, cota do nível de água, cota de assentamento da sapata, ensaios SPT, para calibrar um modelo em Machine Learning, para a previsão da capacidade de carga em fundações diretas assentadas em diversos tipos de solo.

1.1 Objetivos

1.1.1 Objetivo Geral

Previsão da capacidade de carga em fundações diretas assentadas em diversos tipos de solo utilizando um modelo em aprendizagem de máquina.

1.1.2 Objetivos Específicos

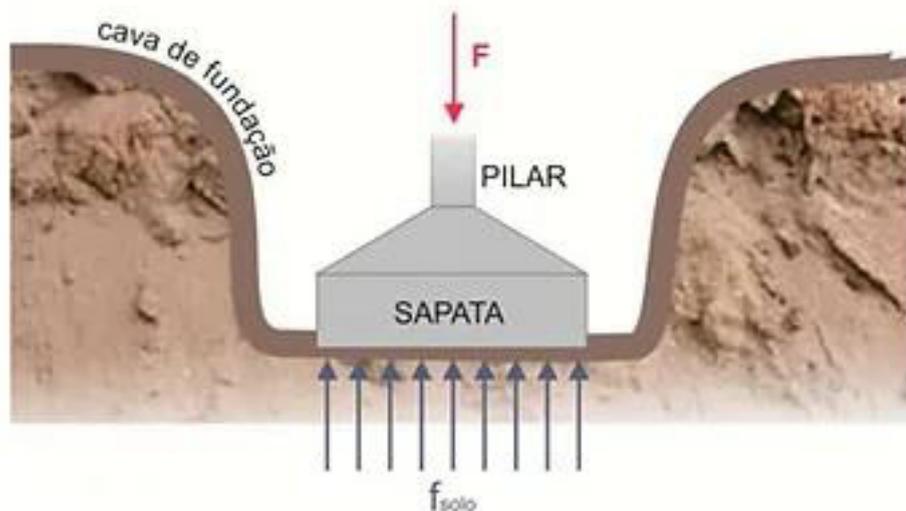
1. Criar um banco de dados de capacidade de carga em fundações diretas assentadas em diversos tipos de solo;
2. Calibrar um modelo em aprendizagem de máquina para previsão de capacidade de carga em diversos tipos de solo;
3. Comparar os valores de capacidade de carga obtidos no modelo de aprendizagem de máquina com o métodos teórico de Terzaghi.

2. REFERENCIAL TEÓRICO

2.1 Fundações diretas

De acordo com a NBR 6122/2022 a definição de fundação é um elemento de fundação cuja base está assentada em profundidade inferior a duas vezes a menor dimensão da fundação, recebendo aí as tensões distribuídas que equilibram a carga aplicada, para esta definição adota-se a menor profundidade, caso esta não seja constante em todo o perímetro da fundação, ilustrada na figura 1.

Figura 1- Fundação rasa do tipo sapata.



Fonte: <https://www.rarquitecturaereforma.com.br/single-post/2016/09/18/fundacoes-rasas-superficiais-diretas-brasil>

2.2 Capacidade de carga

A teoria da capacidade de carga de um sistema de sapata-solo, proposta por Terzaghi (1996), fornece uma estrutura para determinar a carga máxima que uma fundação de sapata pode suportar antes de ocorrerem assentamentos excessivos e falhas. Terzaghi desenvolveu essa teoria com base em observações de campo e laboratório, bem como em sua experiência prática em engenharia geotécnica.

A teoria de Terzaghi envolve a consideração de dois principais componentes de carga: a carga admissível e o assentamento. Ele formulou a capacidade de carga em termos de pressões admissíveis, que são as pressões máximas que o solo pode

suportar sem que ocorram falhas. A capacidade de carga da fundação é determinada comparando a carga aplicada com a pressão admissível do solo.

As principais premissas da teoria de Terzaghi incluem:

- A carga aplicada à fundação é distribuída uniformemente na base da fundação.
- O solo sob a fundação se comporta de maneira elástica e isotrópica sob pressões normais.
- O assentamento é diretamente proporcional à carga aplicada.
- A pressão admissível do solo é uma propriedade do solo que depende de seu tipo, consistência, umidade, e outras características geotécnicas.
- A fórmula básica que expressa a capacidade de carga em termos de pressão admissível (q) é mostrada na equação 1:

$$Q = A * q \text{ (equação 1)}$$

Onde:

Q é a carga aplicada na fundação,

A é a área da base da fundação,

q é a pressão admissível do solo.

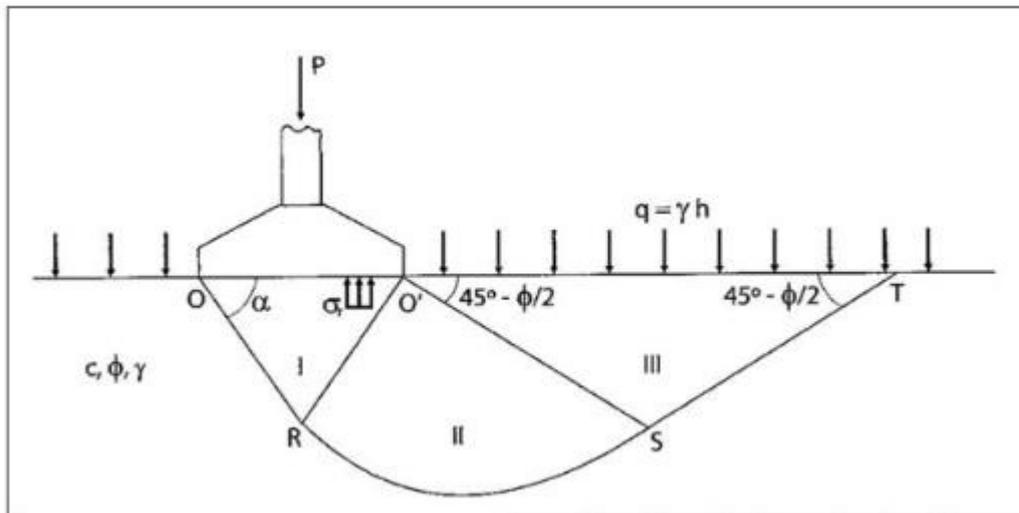
2.3 Teoria de Terzaghi

Terzaghi considera três hipóteses básicas:

- a) Trata-se de uma sapata corrida, com $L \gg \gg B$ (no mínimo 5x), simplificando a um problema bidimensional;
- b) A profundidade de embutimento da sapata é inferior à largura da sapata ($h < B$);
- c) O maciço de solo sob a base da sapata é rígido (pouco deformável), caracterizando uma ruptura generalizada.

O problema pode ser esquematizado como mostra a figura 2, na qual a superfície potencial de ruptura ORST é composta pelos trechos OR e ST e por um espiral logarítmica no trecho intermediário RS, formado por três zonas distintas (I, II, III) no maciço de solo com coesão C , ângulo de atrito ϕ e peso específico γ . Nessa notação γ é sempre o peso específico efetivo, enquanto C e ϕ geralmente representam os valores não drenados.

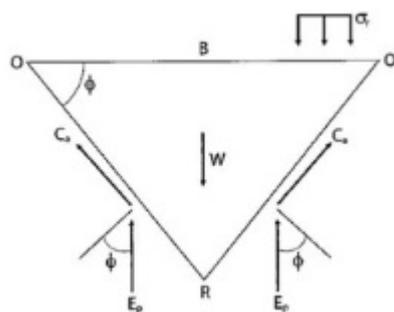
Figura 2 - Superfície potencial de ruptura



Fonte: Fundações diretas - projeto geotécnico / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero.

Na iminência da ruptura, em que a sapata aplica a tensão σ ao solo (princípio de ação e reação), examinemos a cunha de solo I, com peso próprio W . Nas suas fases OR e O'R, atuam o empuxo passivo E_p e as forças de coesão C_a , conforme esquematizado na figura 3, para o caso particular de $\alpha = \phi$.

Figura 3 – Cunha de solo a base da sapata



Fonte: Fundações diretas - projeto geotécnico / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero.

Fazendo a superposição de efeitos dos três casos particulares analisados, encontramos uma equação aproximada para a capacidade de carga do sistema sapata-solo como é mostrado na equação 2.

$$\sigma_r = c * N_c * S_c + q * N_q * S_q + 0,5 * \gamma * B * N_\gamma * S_\gamma \text{ (equação 2)}$$

Fonte: Fundações diretas - projeto geotécnico / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero.

2.3.1 Contribuições de Vesic

Para o cálculo da capacidade de carga temos as contribuições de Vesic (1967), com seus fatores de fórmula como parâmetros a serem consultados.

Tabela 1 – Fatores de fórmula (De Beer , 1967, apud Vesic, 1975)

Sapata	Sc	Sq	Sy
Corrida	1,00	1,00	1,00
Retangular	1+(B/L)(Nq/Nc)	1+(B/L)	1 – 0,4(B/L)
Circular ou quadrada	1+(Nq/Nc)	1+tgφ	0,60

Fonte: Fundações diretas - projeto geotécnico / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero.

Tabela 2 - Fatores de capacidade de carga (Vesic, 1975).

φ	Nc	Nq	Ny	Nq/Nc	tg φ
0	5,14	1	0	0,2	0,00
1	5,38	1,09	0,07	0,2	0,02
2	5,63	1,2	0,15	0,21	0,03
3	5,9	1,31	0,24	0,22	0,05
4	6,19	1,43	0,34	0,23	0,07
5	6,49	1,57	0,45	0,24	0,09
6	6,81	1,72	0,57	0,25	0,11
7	7,16	1,88	0,71	0,26	0,12
8	7,53	2,06	0,86	0,27	0,14
9	7,92	2,25	1,03	0,28	0,16
10	8,35	2,47	1,22	0,3	0,18
11	8,8	2,71	1,44	0,31	0,19
12	9,28	2,97	1,69	0,32	0,21
13	9,81	3,26	1,97	0,33	0,23
14	10,37	3,59	2,29	0,35	0,25
15	10,98	3,94	2,65	0,36	0,27
16	11,63	4,34	3,06	0,37	0,29
17	12,34	4,77	3,53	0,39	0,31

ϕ	Nc	Nq	Ny	Nq/Nc	tg ϕ
18	13,1	5,26	4,07	0,4	0,32
19	13,93	5,8	4,68	0,42	0,34
20	14,83	6,4	5,39	0,43	0,36
21	15,82	7,07	6,2	0,45	0,38
22	16,88	7,82	7,13	0,46	0,40
23	18,05	8,66	8,2	0,48	0,42
24	19,32	9,6	9,44	0,5	0,45
25	20,72	10,66	10,88	0,51	0,47
26	22,25	11,85	12,54	0,53	0,49
27	23,94	13,2	14,47	0,55	0,51
28	25,8	14,72	16,72	0,57	0,53
29	27,86	16,44	19,34	0,59	0,55
30	30,14	18,4	22,4	0,61	0,58
31	32,67	20,62	25,99	0,63	0,60
32	35,49	23,18	30,22	0,65	0,62
33	38,64	26,09	35,19	0,68	0,65
34	42,16	29,44	41,06	0,7	0,67
35	46,12	33,3	48,03	0,72	0,70
36	50,59	37,75	56,31	0,75	0,73
37	55,63	42,92	66,19	0,77	0,75
38	61,35	48,93	78,03	0,8	0,78
39	67,87	55,96	92,25	0,82	0,81
40	75,31	64,2	109,41	0,85	0,84
41	83,86	73,9	130,22	0,88	0,87
42	93,71	85,38	155,55	0,91	0,90
43	105,11	99,02	186,54	0,94	0,93
44	118,37	115,31	224,64	0,97	0,97
45	133,88	134,88	271,76	1,01	1,00
46	152,1	158,51	330,35	1,04	1,04
47	173,64	187,21	403,67	1,08	1,07
48	199,26	222,31	496,01	1,12	1,11
49	229,93	265,51	613,16	1,15	1,15
50	266,89	319,07	762,89	1,2	1,19

Tabela 1 - Fonte: Fundações diretas - projeto geotécnico / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero.

2.4 Aprendizagem de Máquina (*Machine Learning - ML*)

O Machine Learning tem uma ampla variedade de aplicações em diferentes setores e domínios. Sua capacidade de extrair insights valiosos dos dados e automatizar tarefas complexas e tem impulsionado avanços significativos em áreas

como:

1. Reconhecimento de padrões: O ML é amplamente utilizado em tarefas de reconhecimento de padrões, como reconhecimento de imagens e de voz, detecção de fraudes, análise de sentimentos em texto, entre outros.
2. Previsões e tomada de decisão: Os algoritmos de ML são aplicados para fazer previsões e tomar decisões com base em dados históricos e em tempo real. Essas aplicações podem abranger desde previsões de demanda de produtos e otimização de estoques até previsões de risco de crédito e personalização de recomendações.
3. Análise de dados e mineração de dados: O ML permite a descoberta de padrões ocultos e informações úteis em grandes conjuntos de dados, auxiliando na análise de dados e na extração de insights relevantes para apoiar a tomada de decisões.
4. Automação de tarefas e processos: O ML é empregado para automatizar tarefas e processos complexos, como chatbots, assistentes virtuais, veículos autônomos, otimização de cadeias de suprimentos e sistemas de recomendação.

Essas são apenas algumas das aplicações do Machine Learning, e seu potencial é vasto e em constante expansão, impulsionando inovações em diversas áreas.

2.5 Machine learning na geotecnia

2.5.1 Programa para cálculo de capacidade de carga

O aprendizado de máquina já vem sendo implantado na geotécnica em diversos setores e finalidades, como por exemplo o aplicativo Kroki, que calcula a capacidade de carga de acordo com a teoria e metodologia de Aoki-Velloso (1975), Décourt-Quaresma (1978), e Teixeira (1996).

O Kroki utiliza técnicas de aprendizado de máquina para automatizar parte desse processo. Através de um conjunto de dados de estacas previamente analisadas e informações geotécnicas, o aplicativo é capaz de aprender padrões e relações entre

os dados. Com base nesse aprendizado, ele pode fazer estimativas e prever a capacidade de carga de novas estacas com base em suas características.

Como mostra a figura 5, o layout do aplicativo kroki e suas alimentações de dados, que são: tipo de estaca, método de cálculo, nível d'água, SPT e tipo de solo.

Figura 4 - Cálculo da capacidade de carga, pelo aplicativo Kroki.

The screenshot shows the 'Cálculo Capacidade Carga Estaca' interface. At the top, there is a navigation bar with 'Home', 'Aplicativos', 'Kroki', 'Documentação', and 'Minha Conta'. Below the navigation bar, the title 'Cálculo Capacidade Carga Estaca' is displayed. The main content area is divided into several sections:

- Input Section:**
 - 'Tipo de Estaca' dropdown menu set to 'Escavada'.
 - 'Método de Cálculo' dropdown menu set to 'Aoki-Velloso'.
 - 'Nível d'água' input field with 'm' unit.
 - Checkboxes for 'Desconsiderar Rp' and 'Limitar Rp ≤RI'.
- Calculation Button:** A blue button labeled 'CALCULAR'.
- Output Section:**
 - 'SPT' input field with '1 m' and a trash icon.
 - 'Tipo de Solo' dropdown menu set to 'Areia'.
 - 'Profundidade' input field with '1 m' and a trash icon.
 - 'Resultados' table with columns for diameters (30, 40, 50, 60, 70 cm) and a note '*Unidades em Toneladas'.

Fonte: <https://www.kroki.com.br/app/calculo-capacidade-carga-estaca>

2.5.2 Estimativa de coeficiente de mola de estacas

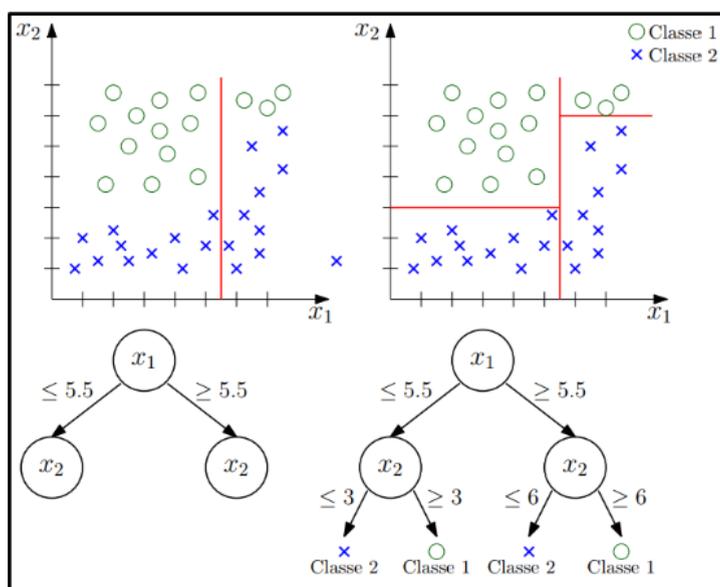
O trabalho de Oliveira, Yuri. *et al.* (2020), mostra como funciona a modelagem da ML no campo da geotecnia, no qual, apresentou uma máquina que fez estimativa de coeficiente de mola de estacas, usando como validação provas de cargas estáticas. Esse artigo utilizou para modelar sua máquina o modelo de aprendizagem *Random Forest Regressor*, no qual se baseia na construção de várias árvores de decisão.

Uma árvore de decisão é um modelo de aprendizado de máquina supervisionado que é frequentemente usado para resolver problemas de classificação e regressão. É uma representação gráfica de um conjunto de regras de decisão que são aplicadas sequencialmente para chegar a uma decisão final.

Uma árvore de decisão é composta por um conjunto de nós, onde cada nó representa uma condição ou atributo, e os ramos representam as possíveis saídas ou decisões a serem tomadas como mostra a figura 6. Os nós internos da árvore

são chamados de nós de decisão, enquanto as folhas são chamadas de nós de folha ou nós terminais, onde a decisão final é tomada.

Figura 5 – Árvore de decisão.



Fonte: Martins et. al (2016, p.24)

O modelo adotado nesse artigo, obteve resultados satisfatórios, sendo possível, ainda, melhorá-lo aumentando a quantidade de dados a serem implementados. De acordo com os autores, devido a grande variabilidade geotécnica e heterogeneidade dos solos tropicais residuais, os solos dificilmente será precisamente caracterizado, além disso, um dos dados de alimentação é a sondagem SPT (*Standard Penetration Test*) que tem pouca representatividade como parâmetro de rigidez do solo.

2.5.3 Previsão de erosão interna em solos com o uso de machine learning

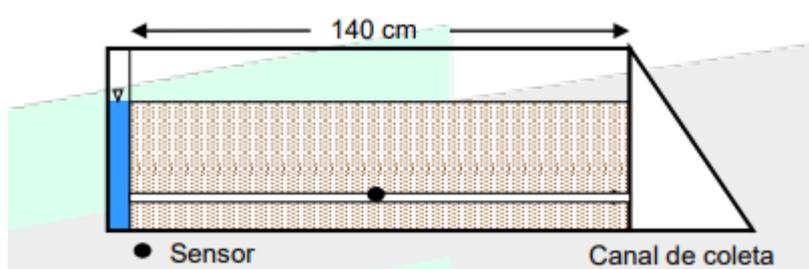
O trabalho de Cunha, Enzo. et al. (2022), mostra uma abordagem de análise da inteligência artificial por meio da aplicação de métodos de detecção acústica passiva e aprendizado de máquina, com o propósito de acompanhar e avaliar a presença de danos internos em um aterro experimental. Foram avaliados diversos estimadores de machine learning e diferentes tipos de pré-processamento.

Um sensor acústico foi empregado para realizar uma medição passiva de sons, constituído por dois discos piezoelétricos que operavam a uma frequência de ressonância de 50 kHz. O sensor capturou os sinais passivos do experimento, que

incluíam os ruídos gerados pelo fluxo de água e os ruídos ambientais, como mostra a figura 7.

O diâmetro do tubo aumentou de 6 mm para um valor equivalente a 94 mm no final do teste. A concentração média de sedimentos observada foi de 60,7 g/L. Notavelmente, o tubo de solo não sofreu colapso, mesmo sob condições de erosão extremas e aumento do diâmetro do tubo, como observado no estudo de Lu & Wilson em 2012.

Figura 6 – Esquema do experimento de erosão interna (adaptado de Lu & Wilson, 2012)



Fonte: Cunha, Enzo., Brasil, André. (2022). Previsão de Erosão Interna em Solos com o Uso de Machine Learning.

2.5.4 Aprendizagem de máquina na determinação de parâmetros de resistência de filitos brandos

No trabalho PINTO, Livia Aparecida Gonçalves; DA SILVA, José Margarida 2023, consiste em sugerir a aplicação de técnicas de Aprendizado de Máquina para prever os atributos geotécnicos de rochas de natureza branda, especialmente o filito.

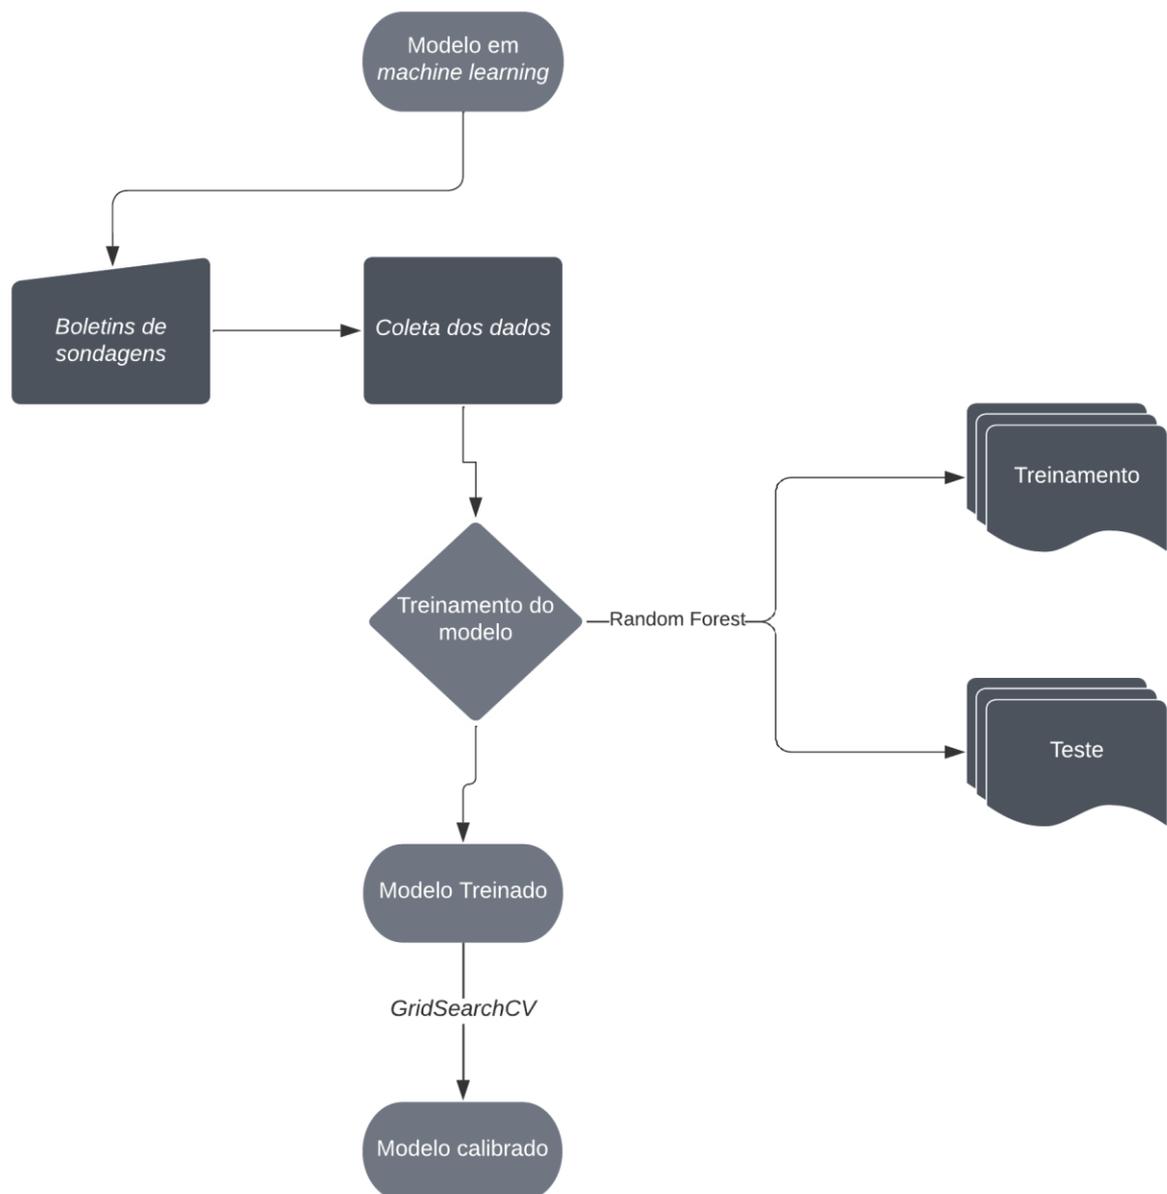
Foram empregados dados históricos provenientes de ensaios geotécnicos laboratoriais realizados em rochas mineradas na região do Quadrilátero Ferrífero. Através de uma otimização interativa, apoiada por técnicas de Inteligência Artificial, como Redes Neurais Artificiais e Regressão Linear.

Os resultados obtidos indicaram que a abordagem da Regressão Linear demonstrou ser eficaz na estimativa dos parâmetros de resistência das rochas filitos brandas, sugerindo possibilidades promissoras de aplicação em relação a outros atributos geotécnicos e tipos de rocha.

3. METODOLOGIA

O estudo foi desenvolvido a partir da criação de um banco de dados sobre os parâmetros do solo, onde esse banco de dados foi utilizado para o treinamento de aprendizagem de máquina, que foi obtido os valores de capacidade de carga, como mostra a figura 8.

Figura 7 – Fluxograma metodológico



Fonte: Autor (2023).

3.1 Parâmetros base do solo

Para esse estudo foi criado um banco de dados sobre os parâmetros do solo obtidos em sondagens que foram retiradas de nuvens de armazenamento das licitações executadas de diversas prefeituras espalhadas pelo Brasil. Nessas sondagens vinham o valor SPT, tipo de solo, cota, nível de água e para complementar os dados foram calculados ângulo de atrito, peso específico do solo e peso da camada de solo, para todas as sondagens. Para o cálculo do ângulo de atrito foi utilizada a metodologia de Texeira (1996) como mostra a equação 3 e para coesão foi utilizada a metodologia de Godoy (1996) como mostra a equação 4.

$$\phi = \sqrt[2]{20 * N_{spt}} + 15 \text{ (equação 3)}$$

$$C = 10 * N_{spt} \text{ (equação 4)}$$

3.2 Modelagem em *Machine Learning*

Nesse trabalho foi utilizado o algoritmo *random forest* pois são dados tabulares e poucos dados, de acordo com a literatura esse algoritmo é adequado para essa configuração de dados. Para as sondagens foi usado um total de noventa e cinco boletins de sondagens. Posteriormente, os dados foram particionados em dois conjuntos: um destinado ao treinamento e seleção do modelo de aprendizado de máquina, e outro para o teste e avaliação da capacidade de generalização do modelo. Essa separação foi realizada de maneira que setenta e cinco por cento das sondagens foram utilizadas para treinamento e vinte e cinco por cento para testes.

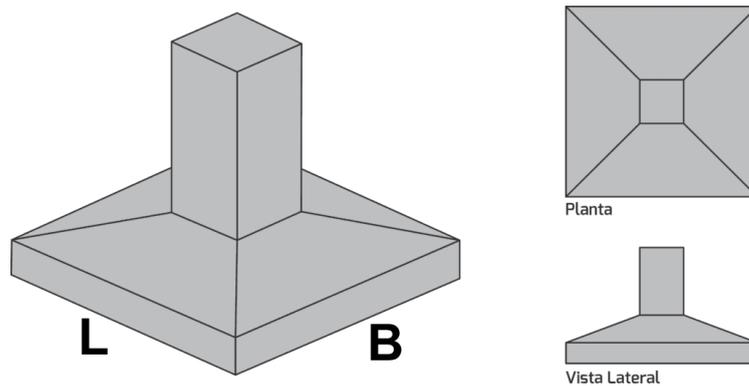
Para o funcionamento do modelo construído, é necessário solicitar os dados de entrada, que são tipo de solo, SPT, cota e peso da camada de solo acima da sapata, os demais parâmetros são previstos pelo modelo e com o apoio do livro *Fundações diretas - projeto geotécnico* / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero para obtenção da capacidade de carga.

3.3 Treinamento do modelo

Nesse trabalho o valor de saída do modelo em machine learning foi a capacidade de carga de sapata com geometria previamente definida, que para esse modelo são sapatas quadradas (L=B) como mostra a figura 9, dentre as dimensões

possíveis: 1,00 x 1,00 m, 1,50 x 1,50 m, 2,00 x 2,00 m, 2,50 x 2,50 m e 3,00 x 3,00 m.

Figura 8 – Dimensões de uma sapata.



Fonte: Autor (2023).

Após a calibração do modelo em machine learning, foram obtidos os valores previsto pelo modelo e feito uma comparação com os valores reais.

3.4 Validação Cruzada utilizando K - folds

Na validação cruzada utilizando k – *folds*, o conjunto de dados é dividido em k seguimentos. Dessa maneira, um classificador é treinado usando k – 1 partes da amostra e um valor de erro é calculado testando o classificador no segmento restante – repetindo o procedimento até que todas as amostras sejam usadas como teste. Por fim, a estimativa k-cv do erro é o valor médio dos erros cometidos em cada iteração (RODRIGUEZ; PEREZ; LOZANO; 2009). A figura 10 ilustra esse processo:

Figura 9 – Validação Cruzada para 5 folds

ITERAÇÃO 1	TESTE	TREINO	TREINO	TREINO	TREINO
ITERAÇÃO 2	TREINO	TESTE	TREINO	TREINO	TREINO
ITERAÇÃO 3	TREINO	TREINO	TESTE	TREINO	TREINO
ITERAÇÃO 4	TREINO	TREINO	TREINO	TESTE	TREINO
ITERAÇÃO 5	TREINO	TREINO	TREINO	TREINO	TESTE

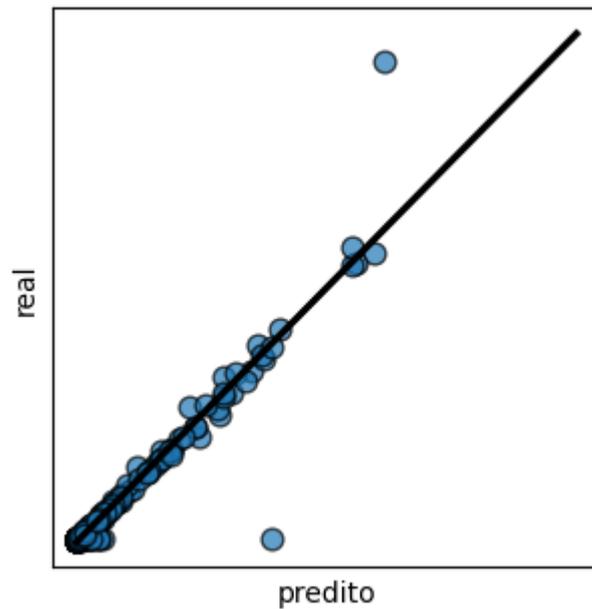
Fonte: Autor (2023).

4. RESULTADOS

4.1 Resultados dos dados de testes

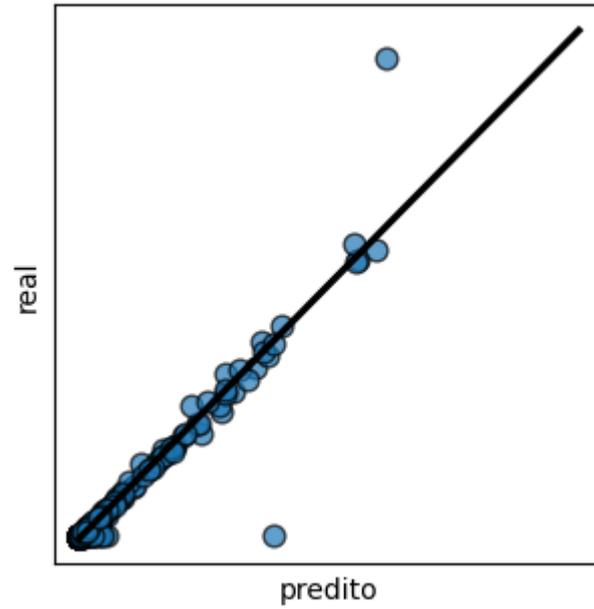
Após o treinamento do modelo, na etapa pré-processamentos dos dados foi feito a plotagem dos gráficos valor predito pelo modelo X valor real, onde foi comparado o valor predito com o valor real e foi gerado uma reta aproximada para descrever a linearidade dos resultados que visa traçar uma reta onde consegue explicar de forma mais exata a distribuição dos dados por meio de uma reta, para todas as geometrias definidas. Como mostrado nas figuras:

Figura 10 – Gráfico Valor predito x Valor real (1,00 x 1,00 m)



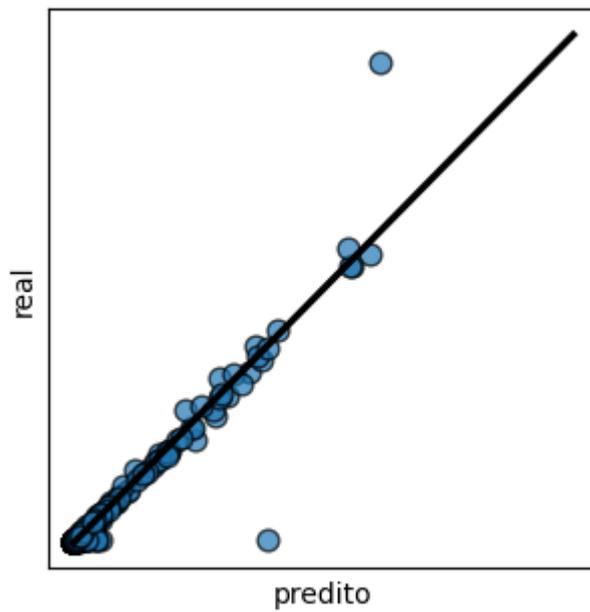
Fonte: Autor (2023).

Figura 11 – Gráfico Valor predito x Valor real (1,50 x 1,50 m)



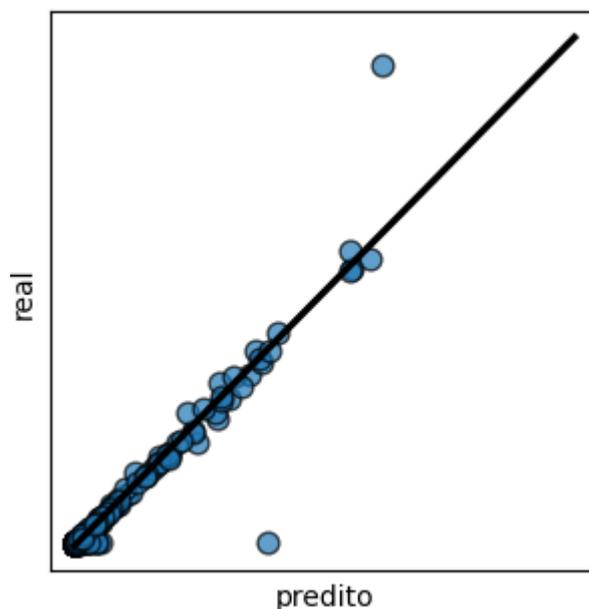
Fonte: Autor (2023).

Figura 12 – Gráfico Valor predito x Valor real (2,00 x 2,00 m)



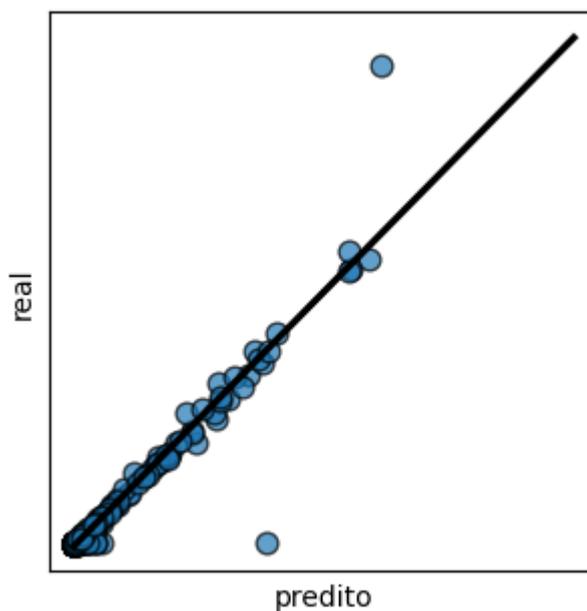
Fonte: Autor (2023).

Figura 13 – Gráfico Valor predito x Valor real (2,50 x 2,50 m)



Fonte: Autor (2023).

Figura 14 – Gráfico Valor predito x Valor real (3,00 x 3,00 m)



Fonte: Autor (2023).

Os resultados demonstrados avaliam a performance do modelo nas amostras de teste, onde dados conhecidos são usados para prever a capacidade de carga em fundações diretas. No entanto, para atribuir maior confiança às predições, foi utilizado a biblioteca GridSearchCV, para uma otimização das predições também na fase de treinamento, utilizando $k = 5$ folds.

4.2 Otimização dos resultados

Foi utilizado a função `GridSearchCV` para otimização dos valores previstos pelo modelo, onde foram aplicados hiperparâmetros e escolhido o qual obteve o melhor resultado.

Tabela 3 – Hiperparâmetros testados.

"N_estimators"	[200, 300, 400 ,500]
"Max_features"	['sqrt', 'log2']
"Max_depth"	[5, 10, 15, none]
tele" criterion"	['square_error']
"Random_state"	[18]

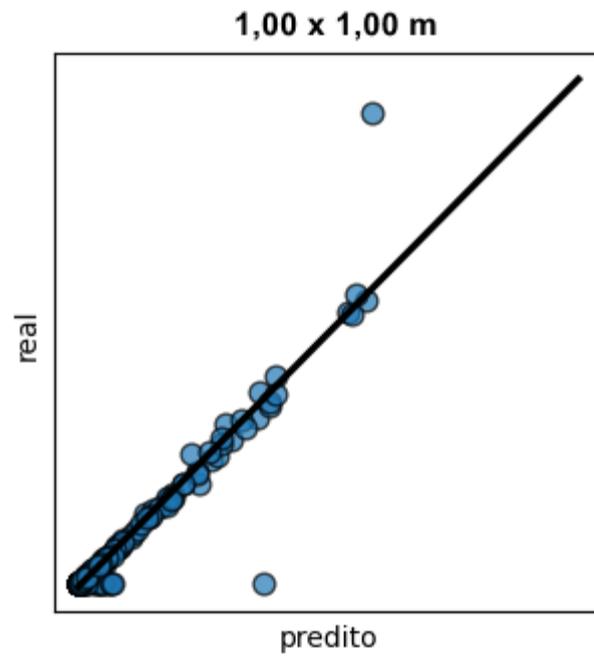
Fonte: Autor (2023).

Nessa etapa o *GridSearchCV* foi executado, obteve-se os melhores hiperparâmetros para uma melhor predição dos valores de capacidade de carga: {'criterion': 'squared_error', 'max_depth': 10, 'max_features': 'sqrt', 'n_estimators': 400, 'random_state': 18, cv=GroupKFold (n splits=5)}.

Na etapa de pós-processamento dos dados com o uso do `GridSearchCV` foi possível fazer a plotagem dos gráficos valor predito pelo modelo X valor real, onde foi comparado o valor predito com o valor real e foi gerado uma reta aproximada para descrever a linearidade dos resultados que visa traçar uma reta onde consegue explicar de forma mais exata a distribuição dos dados por meio de uma reta, para todas as geometrias definidas.

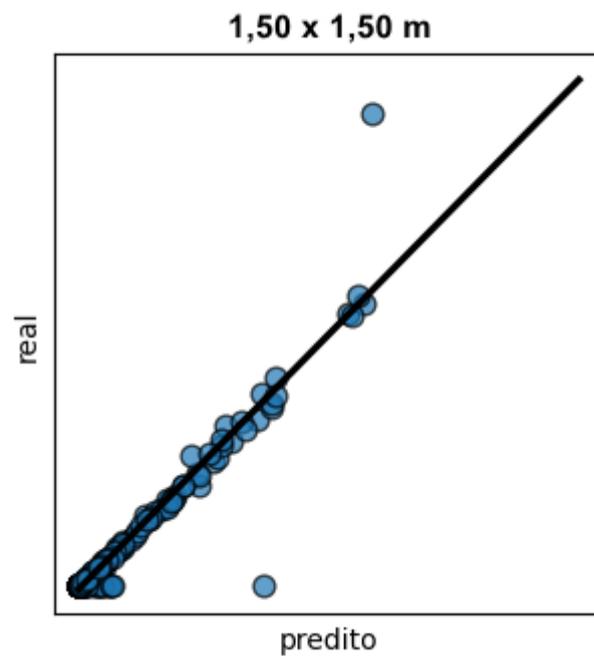
Para os poucos valores que ficaram fora da reta, foram valores que o modelo não conseguiu aprender na fase de treinamento. Os gráficos do modelo foram divididos por geometria de sapata, que podem serem observados nas figuras a seguir:

Figura 15 – Gráfico Valor predito x Valor real (1,00 x 1,00 m)



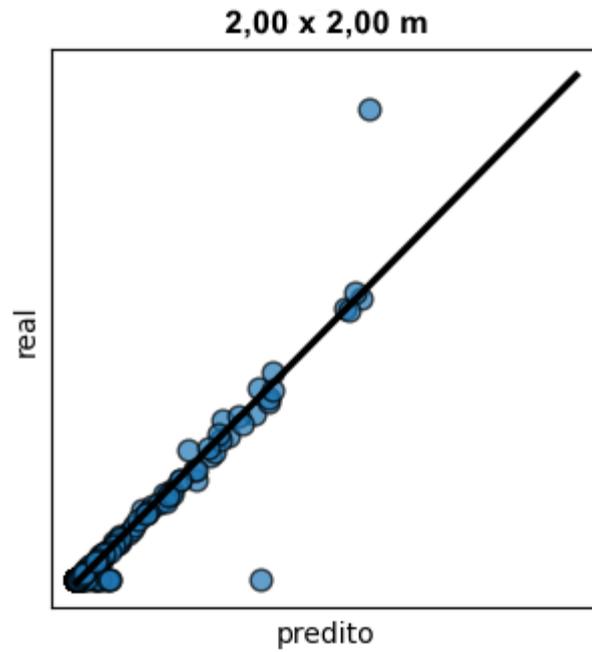
Fonte: Autor (2023).

Figura 16 – Gráfico Valor predito x Valor real (1,50 x 1,50 m)



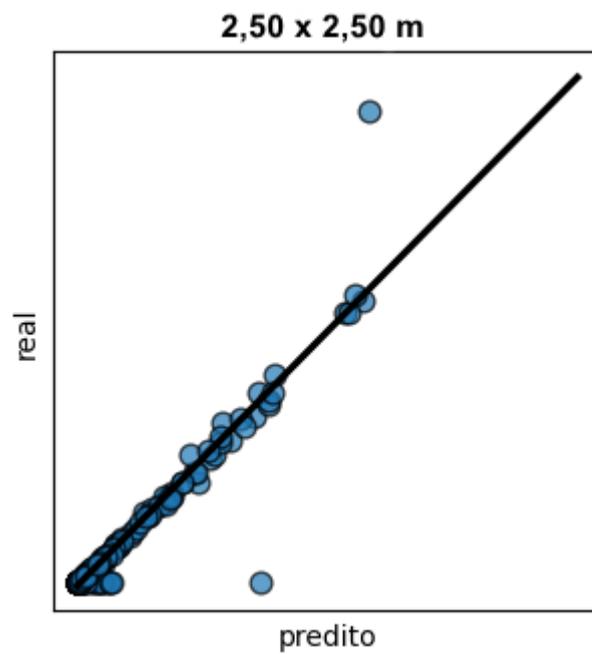
Fonte: Autor (2023).

Figura 17 – Gráfico Valor predito x Valor real (2,00 x 2,00 m)



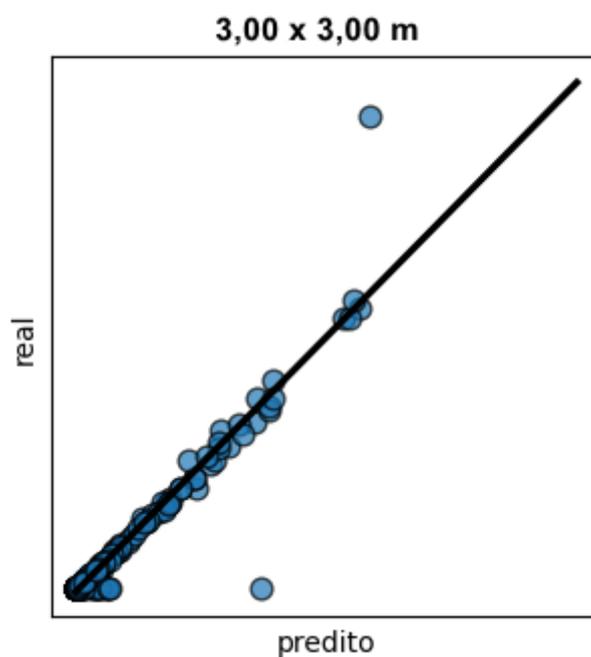
Fonte: Autor (2023).

Figura 18 – Gráfico Valor predito x Valor real (2,50 x 2,50 m)



Fonte: Autor (2023).

Figura 19 – Gráfico Valor predito x Valor real (3,00 x 3,00 m)



Fonte: Autor (2023).

Através da comparação dos valores preditos pelo modelo e o valor real, é possível afirmar que o modelo se ajustou com acurácia. Isso fica evidente ao observar a alta taxa de acertos e baixos desvios, o que significa que não houve uma grande diferença entre o valor real e o valor predito das amostras.

4.3 Validação do modelo

O erro absoluto (valor predito – valor real) e as métricas sobre o erro absoluto foi calculado. Os valores de capacidade de carga preditos pelo modelo foi comparado a um valor de capacidade de carga obtido a partir do método teórico de Terzaghi. As métricas são representadas em unidades de Mpa na tabela a seguir.

Tabela 4 – Métricas calculadas

Geometria da sapata					
	1,00	1,50	2,00	2,50	3,00
	x	x	x	x	x
	1,00	1,50	2,00	2,50	3,00
	m (e)				
Média	4,24	4,26	4,28	4,31	4,33
Mediana	0,58	0,55	0,56	0,56	0,56
Desvio padrão	12,29	12,35	12,41	12,47	12,54

Fonte: Autor (2023).

É possível notar que as precisões dos modelos são significativamente mais exatos para previsão de capacidade de carga com baixo valor da média dos erros, como também um valor pequeno de desvio padrão para as amostras analisadas, com poucas exceções. De fato, destaca-se uma diminuição das métricas de erro para valores de capacidade de carga acima de 1MPa, o que comprova um modelo em machine learning bem calibrado e com resultados precisos.

5. CONCLUSÃO

Esse trabalho criou um modelo em machine learning para previsão de capacidade de carga em fundações diretas com geometrias definidas, que são de 1 a 3 metros. A partir do modelo treinado obtido, pode-se chegar às seguintes conclusões:

- i. O banco de dados foi criado com parametros do solo bem diversificado, que contemplam diversos tipos de solo, para uma melhor calibragem do modelo, pois um banco de dados robusto significa um treinamento mais eficiente.
- ii. A calibragem do modelo em machine learning para estimativa da capacidade de carga obteve resultados satisfatórios e precisos, pois os valores preditos pelo modelo foram similares aos valores reais em todas as geometrias de sapatas previstas.
- iii. As métricas de erro usadas para validação do modelo em machine learning tiveram resultados significativos, e foram importantes para declarar o modelo acertivo.

Por fim, os estudos sobre estimativa de capacidade de carga em fundações diretas são importantes, bem como o uso de aprendizagem de máquina também tem um valor significativo na engenharia civil quando bem aplicada.

6. SUGESTÕES PARA PESQUISAS FUTURAS

Uma recomendação para futuras pesquisas seria realizar análises adicionais, abrangendo parâmetros adicionais, conforme mencionados a seguir. Isso seria fundamental para obter resultados mais abrangentes sobre o uso de machine learning para previsão de capacidade de carga em fundações.

- a) Realizar análise para solos colapsíveis e expansivos
- b) Aumento do banco de dados
- c) Realizar a previsão de capacidade de carga para sapatas com maiores dimensões e geometrias diferentes
- d) Implementar a previsão de capacidade de carga para fundações indiretas

REFERÊNCIAS

ALBUQUERQUE, Enzo Aldo Cunha; CAVALCANTE, André Luís Brasil. **Previsão de Erosão Interna em Solos com o Uso de Machine Learning**. 2022.

Alpaydin, E. 2010. **Introduction to machine learning**. MIT press Cambridge.

Associação Brasileira de Normas Técnicas (2023). NBR 6122: **Projetos e Execução de Fundações**, Rio de Janeiro, p. 8.

Belcher, W., Camp, T., & Krzhizhanovskaya, V. v. (2016). **Detecting Erosion Events in Earth Dam and Levee Passive Seismic Data with Clustering**. Proceedings - 2015 IEEE 14th International Conference on Machine Learning and Applications, ICMLA 2015, 903–910.

Bishop, C. M. (2006). **Pattern Recognition and Machine Learning**. Springer.

Ching, J., & Phoon, K.-K. (2019). **Constructing Site-Specific Multivariate Probability Distribution Model Using Bayesian Machine Learning**. Journal of Engineering Mechanics, 145(1), 04018126.

Fundações diretas - projeto geotécnico / José Carlos A. Cintra, Nelson Aoki, José Henrique Albiero – São Paulo : Oficina de Textos, 2011.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). **Deep Learning**. MIT Press.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). **The Elements of Statistical Learning**: Data Mining, Inference, and Prediction. Springer.

<https://www.kroki.com.br/app/calculo-capacidade-carga-estaca>

<https://www.rrarquiteturaereforma.com.br/single-post/2016/09/18/fundacoes-rasas-superficiais-diretas-brasilia>

Marjanović, M., Kovačević, M., Bajat, B., & Voženílek, V. (2011). **Landslide susceptibility assessment using SVM machine learning algorithm**. Engineering Geology, 123(3), 225–234.

Oliveira, Yure; Duboc, Gabriela; Aquino, Fernando; Guimarães, Marcos; Gonçalves, Ana; Oliveira, Patrícia (2020). **Machine Learning aplicado na estimativa do coeficiente de mola de estacas com validação por meio de provas de carga estáticas**.

PINTO, Livia Aparecida Gonçalves; DA SILVA, José Margarida. Aprendizagem de máquina na determinação de parâmetros de resistência de filitos brandos. **Research, Society and Development**, v. 12, n. 1, p. e19012139693-e19012139693, 2023.

RODRIGUEZ, J. D.; PEREZ, A.; LOZANO, J. A. **Sensitivity analysis of k-fold cross validation in prediction error estimation**. IEEE transactions on pattern analysis and machine intelligence, IEEE, v. 32, n. 3, p. 569–575, 2009.

Terzaghi, K., Peck, R. B., & Mesri, G. (1996). **Soil Mechanics in Engineering Practice**. Wiley.

ANEXO A – BANCO DE DADOS CARREGADOS NA NUVEM DO GOOGLE DRIVE

Link:<https://docs.google.com/spreadsheets/d/1GLXLwDr6xWM0iZpoeDgXLwbkJEj3Tw7d/edit?usp=sharing&oid=109949698148625696640&rtpof=true&sd=true>