

**Gleyce de Souza Baptista**

***Machine Learning* para Previsão do  
Comportamento de Areias em Ensaios  
de Cisalhamento Direto e DSS**

**Dissertação de Mestrado**

Dissertação apresentada como requisito parcial  
para obtenção do grau de Mestre pelo Programa  
de Pós-graduação em Engenharia Civil do  
Departamento de Engenharia Civil e Ambiental  
da PUC-Rio

Orientadora: Marina Bellaver Corte

Rio de Janeiro

Abril de 2024



**Gleyce de Souza Baptista**

***Machine Learning* para Previsão do  
Comportamento de Areias em Ensaios de  
Cisalhamento Direto e DSS**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Civil da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

**Prof<sup>a</sup>. Marina Bellaver Corte**  
Orientador(a) e Presidente  
PUC-Rio

**Prof<sup>a</sup>. Raquel Quadros Velloso**  
PUC-Rio

**Prof. Gustavo Vaz de Mello Guimarães**  
UFRJ

Rio de Janeiro, 16 de abril de 2024.

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

### **Gleyce de Souza Baptista**

Graduou-se em Engenharia Civil pela Universidade Federal do Rio de Janeiro (UFRJ) em 2022. Iniciou sua carreira atuando como cientista de dados e atualmente trabalha como engenheira geotécnica, com ensaios de laboratório de solos. Ingressou em 2022 no curso de Mestrado em Engenharia Civil da Pontifícia Universidade Católica do Rio de Janeiro, na área de Geotecnia, desenvolvendo dissertação de mestrado na linha de pesquisa de Geomecânica Computacional.

### Ficha Catalográfica

Baptista, Gleyce de Souza

Machine Learning para Previsão do Comportamento de Areias em Ensaios de Cisalhamento Direto e DSS / Gleyce de Souza Baptista ; orientadora: Marina Bellaver Corte. – 2024.

112 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil e Ambiental, 2024.

Inclui bibliografia

1. Engenharia Civil e Ambiental - Teses. 2. Inteligência artificial. 3. Cisalhamento direto. 4. Direct simple shear. 5. Modelagem preditiva. 6. Comportamento de Areia. I. Corte, Marina Bellaver. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Civil e Ambiental. III. Título.

CDD: 624

## **Agradecimentos**

Agradeço inicialmente à toda minha família que eu amo tanto, especialmente ao meu pai por me proporcionar tanta inspiração, apoio e força para enfrentar os altos e baixos da vida. Aos meus afilhados, Ísis e Lucca, por todos os momentos de alegria, carinho e felicidade que me fizeram renovar as energias. Aos meus primos, tios e irmão, por compreenderem meus momentos de ausência e me incentivarem a continuar.

À minha orientadora, Marina, por toda a disponibilidade, incentivo, orientação, assistência, inspiração e apoio que recebi durante essa pesquisa.

Ao Departamento de Engenharia Civil da PUC-Rio, secretaria, professores e pessoal do laboratório de geotecnia que, de alguma forma, contribuíram para esta dissertação, envio meus agradecimentos por me proporcionar tanto conhecimento e por toda ajuda necessária.

A cada um dos meus amigos, que têm sido verdadeiras âncoras, mantendo a chama da amizade sempre viva e iluminada, minha gratidão é imensa.

Aos colegas e amigos da PUC-Rio, agradeço por tornarem a vida acadêmica mais leve e significativa.

Aos colegas e amigos da Benthic, vocês transformam o dia a dia de trabalho em algo especial, repleto de momentos de descontração e apoio. Um agradecimento especial aos meus gestores, Ana Carolina e André, pela disponibilidade, acessibilidade e compreensão.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## Resumo

Baptista, Gleyce de Souza; Corte, Marina Bellaver (Orientadora). ***Machine Learning para Previsão do Comportamento de Areias em Ensaios de Cisalhamento Direto e DSS***. Rio de Janeiro, 2024. 112p. Dissertação de Mestrado – Departamento de Engenharia Civil e Ambiental. Pontifícia Universidade Católica do Rio de Janeiro.

Na geotecnia, os parâmetros de resistência do solo são essenciais para qualquer projeto. Os ensaios de campo e laboratório são essenciais, mas ainda enfrentam muitas limitações práticas e financeiras. Além disso, métodos tradicionais, apoiados em relações empíricas ou teóricas, frequentemente não conseguem abranger a complexidade comportamental do solo. Diante disso, destaca-se a necessidade de explorar alternativas para superar essas barreiras. Neste contexto, a inteligência artificial surge como uma abordagem inovadora. Este estudo propõe um modelo preditivo para analisar a curva tensão-deslocamento em ensaios de cisalhamento direto e tensão-deformação em ensaios de cisalhamento simples (*Direct Simple Shear* - DSS) em areia. Após coletar e digitalizar dados de diversas fontes acadêmicas, formou-se uma base experimental robusta para treinar três algoritmos de *Machine Learning* (ML): *Support Vector Regression* (SVR), *Random Forest* (RF) e *Feedforward Neural Network* (FNN). Foram realizadas análises comparativas dos modelos, com foco particular na avaliação de métricas de desempenho e curvas dos ensaios de validação. O RF destacou-se por sua precisão e confiabilidade. Embora os modelos SVR e FNN tenham demonstrado utilidade, o RF emergiu como o mais eficaz. Este resultado reforça a viabilidade dos modelos de ML, particularmente o RF, como ferramentas valiosas para engenheiros geotécnicos e pesquisadores na previsão do comportamento de areias, mesmo com um conjunto de dados limitado.

## Palavras-chave

Inteligência Artificial; Cisalhamento Direto; Modelagem Preditiva;

## Abstract

Baptista, Gleyce de Souza; Corte, Marina Bellaver (Orientadora). **Machine Learning to Predict the Behavior of Sands in Direct Shear and DSS Tests**. Rio de Janeiro, 2024. 112p. Dissertação de Mestrado – Departamento de Engenharia Civil e Ambiental. Pontifícia Universidade Católica do Rio de Janeiro.

In geotechnics, soil resistance parameters are essential for any project. Field and laboratory tests are essential, but still face many practical and financial limitations. Moreover, traditional methods, relying on empirical or theoretical relationships, often fail to encompass the soil's behavioral complexity. In light of this, there is a highlighted need to explore alternatives to overcome these barriers. In this context, artificial intelligence emerges as an innovative approach. This study proposes a predictive model to analyze the stress-displacement curve in direct shear tests and stress-strain in Direct Simple Shear (DSS) in sand. After collecting and digitizing data from various academic sources, a robust experimental base was formed to train three Machine Learning (ML) algorithms: Support Vector Regression (SVR), Random Forest (RF), and Feedforward Neural Network (FNN). Comparative analyses of the models were conducted, with a particular focus on the evaluation of performance metrics and validation test curves. RF stood out for its accuracy and reliability. Although the SVR and FNN models demonstrated utility, RF emerged as the most effective. This result reinforces the viability of ML models, particularly RF, as valuable tools for geotechnical engineers and researchers in predicting the behavior of sands, even with a limited data set.

## Keywords

Artificial intelligence; Direct Shear; Predictive Modeling;

## Sumário

1	Introdução	19
1.1.	Considerações Iniciais	19
1.2.	Objetivos do Estudo	20
1.3.	Estrutura do Trabalho	21
2	Revisão Bibliográfica	22
2.1.	Resistência ao Cisalhamento	22
2.1.1.	Estado de tensão e critério de ruptura no solo	27
2.1.2.	Comportamento da areia submetida ao cisalhamento	33
2.1.2.1.	Comportamento contrátil e dilatante das areias	34
2.1.2.2.	Efeito do índice de vazios e tensão confinante no comportamento das areias	36
2.2.	Ensaio de Laboratório	39
2.2.1.	Cisalhamento Direto	40
2.2.2.	Cisalhamento Simples ( <i>Direct Simple Shear</i> - DSS)	42
2.3.	Conceitos básicos de <i>Machine Learning</i>	47
2.3.1.	Aplicações em Geotecnia	54
2.3.2.	Algoritmos	60
2.3.2.1.	<i>Decision Tree</i> (DT)	60
2.3.2.2.	<i>Random Forest</i> (RF)	64
2.3.2.3.	<i>Support Vector Regression</i> (SVR)	66
2.3.2.4.	Rede Neural Artificial (RNA)	70
2.3.3.	Fases de um projeto de <i>machine learning</i>	75
2.3.3.1.	Escolha do modelo	76
2.3.3.2.	Medidas de desempenho	77
2.3.3.3.	Comparação entre alguns modelos	81
3	Materiais e Métodos	83

3.1. Materiais utilizados	83
3.2. Métodos utilizados	85
3.2.1. Coleta de Dados	85
3.2.2. Pré-processamento dos Dados	86
3.2.3. Definição das Arquiteturas e Treinamento	87
3.2.4. Análise de Desempenho e Validação	88
4 Análise dos Resultados	90
4.1. Construção dos Modelos	90
4.2. Avaliação de desempenho	94
4.3. Ensaios de validação	96
4.3.1. Cisalhamento Direto	96
4.3.2. DSS	99
4.4. Análise dos parâmetros de entrada	101
5 Conclusões	104
6 Referências Bibliográficas	106



## Lista de Figuras

Figura 2.1 Definição geométrica do ângulo de atrito (Lambe e Whitman, 1969) .....	23
Figura 2.2 Representação microscópica do atrito entre dois corpos sólidos (Lambe e Whitman, 1969) .....	23
Figura 2.3 Bloco e uma superfície horizontal na condição (a) sem atrito e (b) com atrito parcial (adaptado de Taylor, 1948) .....	25
Figura 2.4 Bloco e uma superfície horizontal com mobilização total e deslizamento para (c) direita e (d) para esquerda (adaptado de Taylor, 1948) .....	26
Figura 2.5 Esquema de contato entre grãos (Pinto, 2009) .....	28
Figura 2.6 Representação das tensões normais e cisalhantes atuando no plano .....	28
Figura 2.7 Tensões principais atuantes nas faces do elemento cúbico .....	29
Figura 2.8 Determinação de tensões num plano genérico por meio do Círculo de Mohr (Pinto, 2009) .....	30
Figura 2.9 Círculo de Mohr das tensões totais e efetivas (Adaptado de Simões, 2015) .....	31
Figura 2.10 Representação do critério de Ruptura de Mohr (Pinto, 2009) .....	32
Figura 2.11 Envoltória de Ruptura de Mohr-Coulomb .....	33
Figura 2.12 Resultados típicos de ensaios em areia triaxial tipo CID; (a), (b) e (c) comportamento contrátil, (d), (e) e (f) comportamento dilatante (Pinto, 2009) .....	36
Figura 2.13 Curvas de tensão-índice de vazios para areia em quatro compacidades iniciais (Adaptado de Lee e Seed, 1967) .....	37
Figura 2.14 Gráfico de tensão-deformação-volume para areia compacta (Adaptado de Lee e Seed, 1967) .....	38
Figura 2.15 Gráfico de tensão-deformação-volume para areia fofa (Adaptado de Lee e Seed, 1967) .....	39
Figura 2.16 Cisalhamento no ensaio de cisalhamento direto (adaptado de VJ Tech, 2023) .....	40
Figura 2.17 Diagrama esquemático do ensaio de cisalhamento direto (Adaptado de Simões, 2015) .....	41
Figura 2.18 Resultados típicos de ensaio de cisalhamento direto em	

areia fofa (Lambe e Whitman, 1969) .....	41
Figura 2.19 Condições de tensão e deformação durante o cisalhamento no ensaio de DSS (Dyvik <i>et al.</i> , 1987).....	42
Figura 2.20 Diagrama esquemático do ensaio de DSS (Adaptado de ASTM, 2017) .....	43
Figura 2.21 Esquema do ensaio de DSS sob condições verdadeiramente não drenada e drenada a volume constante (Jannuzzi, 2013 <i>apud</i> Martins, 2023) .....	45
Figura 2.22 Condições de contorno do ensaio de DSS (Atkinson <i>et al.</i> , 1991) .....	45
Figura 2.23 Condição de deformação no ensaio de DSS e Cisalhamento Direto, respectivamente (Hanzawa <i>et al.</i> , 2007).....	46
Figura 2.24 Diagrama de Venn apresentando a relação entre IA, AM e AP (Adaptado de Goodfellow <i>et al.</i> , 2016) .....	48
Figura 2.25 Seleção de marcos notáveis em <i>machine learning</i> (Dramsch, 2019).....	49
Figura 2.26 Processo de construção de um classificador (Adaptado de Baranauskas <i>et al.</i> , 2000).....	51
Figura 2.27 Ilustração das etapas típicas de um processo de aprendizado (Adaptado de Mohri <i>et al.</i> , 2018) .....	51
Figura 2.28 Possíveis hipóteses $h(X)$ para a aproximação da função $f(X)$ (Baranauskas <i>et al.</i> , 2000).....	52
Figura 2.29 Modelos de classificação e regressão com diferentes ajustes (Adaptado de MathWorks, 2024) .....	53
Figura 2.30 Conjunto de treinamento e três hipóteses diferentes (Lorena e Carvalho, 2007) .....	54
Figura 2.31 Gráfico de quantidade <i>papers</i> com <i>machine learning</i> aplicado a geociências ao longo dos anos (Adaptado de Dramsch, 2020) .....	55
Figura 2.32 Número de publicações relacionadas ao desenvolvimento e aplicação de algoritmos de <i>machine learning</i> para previsão de propriedades do solo (Adaptado de Zhang <i>et al.</i> , 2022) .....	55
Figura 2.33 Artigos de periódicos publicados com foco na aplicação de <i>deep learning</i> na engenharia geotécnica ao longo dos anos (Adaptado de <i>Web of Science</i> , 2020 <i>apud</i> Zhang <i>et al.</i> , 2021) .....	57
Figura 2.34 Quantidade de artigos com aplicação de inteligência artificial para a estimativa da resistência ao cisalhamento dos solos (Adaptado de Carvalho <i>et al.</i> , 2022).....	59
Figura 2.35 Esquema árvore de decisão de regressão. (a) Representação esquemática da DT; (b) Visualização 3D referente à saída correspondente e (c) Diagrama do espaço do preditor. (Adaptado de James <i>et al.</i> , 2023) .....	61

Figura 2.36 Ilustração gráfica da técnica de <i>bootstrap</i> (Adaptado de James <i>et al.</i> , 2023).....	63
Figura 2.37 Ilustração gráfica da técnica de <i>bagging</i> (Adaptado de Raschka e Mirjalili, 2017) .....	64
Figura 2.38 Processo de criação de <i>Random Forests</i> (Brains, 2023) .....	65
Figura 2.39 Representação esquemática do modelo SVR (Adaptado de Scholkopf e Smola, 2002 <i>apud</i> Smola e Scholkopf, 2004).....	67
Figura 2.40 Arquitetura da máquina de regressão construída pelo algoritmo de SV (Adaptado de Smola e Scholkopf, 2004) .....	68
Figura 2.41 Exemplo de um caso não linearmente separável na dimensão dos dados iniciais (Russell e Norvig, 2020) .....	69
Figura 2.42 (a) Diagrama do neurônio biológico e (b) esquema de um nó na RNA (Adaptado de Fielding, 1999).....	71
Figura 2.43 Diagrama de uma rede neural com duas camadas ocultas e múltiplas saídas (Adaptado de James <i>et al.</i> , 2023) .....	72
Figura 2.44 Esquema de uma rede neural recorrente simples (James <i>et al.</i> , 2023) .....	72
Figura 2.45 Esquema mostrando como a CNN classifica a imagem (Adaptado de James <i>et al.</i> , 2023) .....	73
Figura 2.46 Exemplo de rede FNN com uma camada oculta (Adaptado de James <i>et al.</i> , 2023) .....	74
Figura 2.47 Gráficos e equações das funções de ativação sigmoid e ReLU (Adaptado de James <i>et al.</i> , 2023) .....	75
Figura 2.48 Abordagem sistemática para avaliar algoritmos de aprendizado de máquina (Adaptado de Baranauskas e Monard (2000).....	77
Figura 2.49 Matriz de confusão genérica (Adaptado de Fielding, 1999) .....	77
Figura 2.50 Curva ROC (Adaptado de Géron, 2019) .....	79
Figura 2.51 Conjunto de dados e o limite de decisão entre os modelos RF, SVM e DNN (Adaptado de Dramsch, 2020).....	82
Figura 2.52 Medidas estatísticas dos modelos de previsão: (a) coeficiente de determinação e (b) RMSE (Mahamat <i>et al.</i> , 2021).....	82
Figura 3.1 Exemplo de anomalia encontrada .....	87
Figura 4.1 Gráficos com dados digitalizados sobrepostos ao gráfico original para verificação da exatidão da digitalização .....	91
Figura 4.2 Exemplo de <i>plot</i> de gráficos individuais para detecção de possíveis anomalias .....	92
Figura 4.3 <i>Plot</i> coletivo para visão geral e detecção de anomalias .....	92
Figura 4.4 <i>Plot</i> de alguns gráficos individuais com dados interpolados e originais.....	93

Figura 4.5 <i>Plot</i> dos Gráficos interpolados juntos .....	94
Figura 4.6 Curvas de previsão nos ensaios de validação do modelo de RF no ensaio de Cisalhamento Direto.....	97
Figura 4.7 Curvas de previsão nos ensaios de validação do modelo de SVR no ensaio de Cisalhamento Direto .....	98
Figura 4.8 Curvas de previsão nos ensaios de validação do modelo de FNN no ensaio de Cisalhamento Direto .....	98
Figura 4.9 Curvas de previsão nos ensaios de validação do modelo de RF no ensaio de DSS.....	99
Figura 4.10 Curvas de previsão nos ensaios de validação do modelo de SVR no ensaio de DSS .....	100
Figura 4.11 Curvas de previsão nos ensaios de validação do modelo de FNN no ensaio de DSS .....	100
Figura 4.12 Gráfico de correlação de Pearson com os parâmetros de entrada dos ensaios .....	101
Figura 4.13 Gráfico de barras SHAP para ensaio de cisalhamento direto e DSS .....	102

**Lista de Tabelas**

Tabela 2.1 Comparação entre alguns modelos de ML (Adaptado de Zhang *et al.*, 2022) .....81

Tabela 3.1 Trabalhos utilizados para os ensaios de cisalhamento direto .....84

Tabela 3.2 Trabalhos utilizados para os ensaios de DSS .....85

Tabela 4.1 Dados estatísticos dos *inputs* utilizados .....91

Tabela 4.2 Avaliação de desempenho dos modelos .....95

## Lista de Símbolos

### Letras Romanas

$A_c$	Área de contato real
$A_T$	Área de contato aparente
$A(\theta)$	Algoritmo de aprendizado
$A_k$	Ativações na camada oculta
$B$	Número total de amostras <i>bootstrap</i>
$b$	Viés
$c$	Intercepto de coesão
$C$	Parâmetro de regularização
$CR$	Compacidade relativa
$C_m$	Modelos de classificação treinados
$ca(h)$	Acurácia do classificador
$ce(h)$	Taxa de classificação incorreta
$e_0$	Índice de vazios inicial
$e_{\min}$	Índice de vazios mínimo
$e_{\max}$	Índice de vazios máximo
$f$	Coeficiente de atrito
$f(X)$	Função não linear construída pela rede neural
$F_{at}$	Força de atrito
$G_s$	Densidade real dos grãos
$g(z)$	Função de ativação
$h(X)$	Função hipótese
$I$	Sinal de entrada
$J$	Número de regiões distintas
$k$	Vetores aleatórios
$k_0$	Coeficiente de empuxo no repouso
$mtry$	Número de atributos avaliados em cada divisão de um nó
$N$	Força normal

$n_{tree}$	Número de árvores de decisão
$P$	Força vertical
$P_m$	Previsão gerada no <i>bagging</i>
$P_x$	Previsão final
$q_u$	Tensão de escoamento do material
$R^2$	Coeficiente de determinação
$R_J$	Regiões
$s$	Resistência ao cisalhamento por unidade de área
$T$	Força tangencial
$T_m$	Amostras criadas a partir do conjunto original
$u$	Poropressão
$V$	Volume
$W$	Vetor de pesos
$X_p$	Vetor de entrada de $p$ variáveis
$x_i$	Atributos (ou características ou <i>features</i> )
$y_i$	Previsão (ou <i>target</i> )
$Z$	Conjuntos de dados

### Letras Gregas

$\alpha$	Ângulo de inclinação
$\hat{\alpha}^{*B}$	Estimativas de previsão
$\beta_k$	Parâmetros de vieses
$\gamma$	Deformação cisalhante
$\gamma_{kernel}$	Coeficiente <i>kernel</i> .
$\delta_h$	Deslocamento horizontal
$\delta_v$	Deslocamento vertical do <i>top cap</i>
$\Delta$	Variação
$\varepsilon$	Limiar de erros
$\varepsilon_a$	Deformação axial
$\varepsilon_v$	Deformação volumétrica
$\theta$	Parâmetros do modelo
$\xi$	Variáveis de folga
$\sigma$	Tensão normal média

$\sigma_1$	Tensão normal principal maior
$\sigma_2$	Tensão normal principal intermediária
$\sigma_3$	Tensão normal principal menor
$\sigma_v$	Tensão vertical
$\sigma_{v0}$	Tensão vertical total inicial
$\sigma_d$	Tensão desviadora
$\Sigma$	Acumulador
$\tau$	Tensão cisalhante
$\phi_u$	Ângulo de atrito do bloco
$\phi_{mob}$	Ângulo de atrito mobilizado
$\phi$	Ângulo de atrito
$\phi(X)$	Função de mapeamento para o espaço de características
$\psi$	Ângulo de dilatação



## Lista de Siglas

AI	<i>Artificial Intelligence</i>
AM	Aprendizado de Máquina
ANN	<i>Artificial Neural Network</i>
AP	Aprendizado Profundo
ASTM	<i>American Society for Testing and Materials</i>
BNN	<i>Bayesian Neural Networks</i>
CART	<i>Classification and Regression Tree</i>
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CID	<i>Consolidated Isotropic Drained</i>
CNN	<i>Convolutional Neural Network</i>
CP	Corpo de Prova
CPT	<i>Cone Penetration Test</i>
DT	<i>Decision Trees</i>
DSS	<i>Direct Simple Shear</i>
EDP	Equações Diferenciais Parciais
FEM	<i>Finite Element Method</i>
FNN	<i>Feedforward Neural Network</i>
FPR	<i>False Positive Rate</i>
FN	<i>False Negative</i>
FP	<i>False positive</i>
GP	<i>Genetic Programming</i>
IA	Inteligência Artificial
LGP	<i>Linear Genetic Programming</i>
LR	<i>Linear Regression</i>
LSTM	<i>Long Short-Term Memory</i>
MAE	<i>Mean Absolut Error</i>
MSE	<i>Mean Squared Error</i>

MEV	Microscópio de Eletrônico de Varredura
PNN	<i>Probabilistic Neural Network</i>
RF	<i>Random Forests</i>
ROC	<i>Receiver Operating Characteristic</i>
RMSE	<i>Root Mean Squared Error</i>
RBFNN	<i>Radial Basis Function Neural Network</i>
RNA	Rede Neural Artificial
SHAP	<i>Shapley Additive Explanations</i>
SPT	<i>Standard Penetration Test</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
TAE	Teoria de Aprendizado Estatístico
TBM	<i>Tunnel Boring Machines</i>
TP	<i>True Positive</i>

# 1

## Introdução

### 1.1. Considerações Iniciais

Na engenharia geotécnica, a investigação do local necessita que três tipos de atividades sejam realizadas: consultoria geotécnica, investigação de campo e ensaios de laboratório (Ahmed, 2014). Essas investigações visam a caracterização e a análise do comportamento mecânico de uma variedade de materiais geotécnicos, como solos, rochas e rejeitos de mineração, que são fundamentais em construções de grande porte, incluindo barragens, aterros, estruturas de contenção e fundações.

A obtenção de parâmetros de resistência ao cisalhamento confiáveis é, portanto, de suma importância para a engenharia geotécnica. Este processo envolve não apenas ensaios de campo, que proporcionam dados representativos das condições naturais do solo, mas também ensaios de laboratório, onde é possível exercer um controle mais rigoroso sobre as condições de ensaio.

Segundo Dyvik et al., 1987, para determinar os parâmetros geotécnicos relevantes numa situação de projeto, devem ser realizados ensaios de laboratório que simulem as condições de carregamento *in situ* o mais fielmente possível. Os ensaios de laboratório são particularmente valorizados pela precisão com que permitem medir variáveis críticas, como tensões, deslocamentos, deformações e propressão, facilitando uma análise detalhada do comportamento tensão-deformação-resistência dos materiais.

Entre os ensaios de laboratório mais antigos e estabelecidos na engenharia geotécnica, o ensaio de cisalhamento direto destaca-se por sua simplicidade e robustez, na determinação dos parâmetros de resistência do solo. Paralelamente, o ensaio de cisalhamento simples, do inglês *Direct Simple Shear* (DSS), tem ganhado popularidade no Brasil, apesar de sua adoção já consolidada em outros países. Este ensaio permite avaliar o comportamento de tensão-deformação-resistência de amostras de solo sob cisalhamento uniforme, em estado plano de deformação.

Portanto, apesar da importância crítica desses ensaios na avaliação das propriedades dos solos, as dificuldades práticas e financeiras na sua realização ressaltam a necessidade de buscar soluções alternativas. A abordagem tradicional, que frequentemente se baseia em relações empíricas ou teóricas entre parâmetros de resistência e outras propriedades dos solos, revelou-se limitada. Uma vez que o comportamento de resistência ao cisalhamento dos solos é afetado por diversos fatores que podem apresentar uma relação não-linear com a resistência ao cisalhamento. A utilização de tabelas empíricas para a determinação dos parâmetros de resistência ao cisalhamento, apesar de comum, frequentemente não abrange a complexidade do comportamento geotécnico dos solos. Essa lacuna na metodologia convencional abre uma porta para que outras propostas sejam testadas e consolidadas, principalmente com os avanços tecnológicos dos últimos anos. Os avanços tecnológicos na ciência da computação das últimas décadas, permitiu que diversos autores utilizassem ferramentas de inteligência artificial para construção de modelos de previsão dos parâmetros de resistência ao cisalhamento dos solos, como citado por Carvalho *et al.* (2022) e evidenciado por trabalhos como o de Kanungo *et al.* (2014). Com efeito, acredita-se que a inteligência artificial pode ser uma alternativa promissora às correlações tradicionais para a previsão do comportamento de solos, principalmente no que tange a definição de parâmetros de resistência ao cisalhamento na ruptura.

## **1.2. Objetivos do Estudo**

O objetivo geral deste estudo é desenvolver um modelo preditivo que utilize técnicas de aprendizado de máquina, do inglês *Machine Learning* (ML), para prever as curvas de tensão-deslocamento e tensão-deformação em ensaios geotécnicos de cisalhamento direto e DSS em areia. Este modelo pretende capturar a complexa interação entre as variáveis geotécnicas que influenciam o comportamento do solo sob carga de cisalhamento. Deseja-se que o modelo não apenas forneça estimativas acuradas das curvas de cisalhamento, mas que também possa ser uma ferramenta útil para engenheiros e pesquisadores na análise do comportamento do solo. O modelo proposto poderia ser considerado como uma ferramenta potencial também para verificar possíveis discrepâncias ou falhas nos resultados de ensaios, como problemas em equipamentos ou erros de operação.

Como objetivos específicos, este trabalho visa estudar os hiperparâmetros envolvidos nos modelos aplicados, a análise de desempenho e comparação entre três modelos de *machine learning* aplicados, bem como a avaliação geral do modelo na captura e previsão do formato das curvas para diferentes compacidades da areia.

### 1.3. Estrutura do Trabalho

O presente trabalho está estruturado em cinco capítulos. No primeiro capítulo, Introdução, são apresentadas as considerações iniciais seguidas pela definição dos objetivos e organização do trabalho.

A Revisão Bibliográfica, segundo capítulo, proporciona o embasamento teórico necessário, abordando tópicos como a resistência ao cisalhamento e ensaios de laboratório, essenciais para a compreensão do comportamento da areia. O capítulo avança para uma exploração dos conceitos básicos de *machine learning*, destacando suas aplicações em geotecnia e descrevendo os algoritmos pertinentes ao estudo. Por fim, esse capítulo aborda as fases de um projeto de *machine learning*, como a escolha do modelo e medidas de desempenho, fechando com comparativo entre alguns modelos.

No terceiro capítulo, Materiais e Métodos, são apresentados os materiais, os dados utilizados na formação do banco de dados. A metodologia também é explorada, iniciando com a coleta de dados, técnicas de pré-processamento utilizadas, e a metodologia de desenvolvimento do modelo, incluindo a seleção e otimização de hiperparâmetros.

A Análise dos Resultados, quarto capítulo, consiste na interpretação dos dados obtidos, a avaliação do desempenho dos modelos preditivos e a discussão sobre a relevância dos resultados em contextos práticos da engenharia geotécnica.

Por fim, o capítulo de Conclusões sintetiza os assuntos mais relevantes do estudo, enfatizando as implicações práticas e teóricas dos resultados, e propondo recomendações para trabalhos futuros.

## 2

### Revisão Bibliográfica

Este capítulo está estruturado em três itens principais. O primeiro tem a resistência ao cisalhamento dos solos como principal foco. O segundo aborda os ensaios de laboratório de solo que são objetos de estudo desse trabalho, *Direct Simple Shear* (DSS) e cisalhamento direto. Por fim, a terceira seção aborda os conceitos de *Machine Learning*, discutindo seu uso crescente para modelagem preditiva em engenharia geotécnica. Este capítulo estabelece a base teórica para os desenvolvimentos subsequentes do trabalho.

#### 2.1.

##### Resistência ao Cisalhamento

A compreensão da resistência ao cisalhamento do solo é fundamental na engenharia geotécnica. O atrito intergranular, incluindo a interconexão física entre os grãos, é um dos principais fatores que contribui para a resistência ao cisalhamento. Especificamente, em areias sedimentares sem cimentação intergranular, atrito intergranular é a única fonte significativa de resistência ao cisalhamento.

A base teórica do atrito foi, de acordo com Lambe e Whitman (1969), primeiramente articulados por Leonardo da Vinci no final do século XV, passado um período de esquecimento até sua redescoberta na França pelo engenheiro Amontons em 1699 e, posteriormente, reformulados por Coulomb em 1785.

Existem duas formas de expressar a resistência ao atrito, o primeiro pelo coeficiente de atrito ( $f$ ), conforme eq. (1):

$$T = f \cdot N \quad (1)$$

Onde  $T$  é a força tangencial e  $N$  é a força normal.

A segunda forma é pela definição do ângulo de atrito do bloco ( $\phi_u$ ), definido a partir do coeficiente de atrito conforme eq. (2):

$$\operatorname{tg} \phi_u = f \quad (2)$$

A interpretação geométrica do ângulo de atrito é dada, de acordo com Lambe e Whitman (1969), conforme Figura 2.1.




Figura 2.1 Definição geométrica do ângulo de atrito (Lambe e Whitman, 1969)

O comportamento do atrito é baseado em duas leis: a primeira lei enuncia que a força tangencial (T) necessária para causar movimento relativo entre dois corpos é proporcional a força normal (N) entre eles; a segunda enuncia que essa força tangencial (T) necessária é independente da dimensão dos dois corpos.

Na escala microscópica todas as superfícies são rugosas, até mesmo aquelas que estão polidas, sendo assim, dois corpos sólidos estarão em contato através dos pontos altos de algumas irregularidades conforme ilustrado na Figura 2.2.




Figura 2.2 Representação microscópica do atrito entre dois corpos sólidos (Lambe e Whitman, 1969)

A área de contato real ( $A_c$ ) representa uma fração tão relativamente pequena da área de contato aparente ( $A_T$ ) que faz com que as tensões normais nesses pontos de contato sejam extremamente elevadas, ainda que a força normal total seja baixa. Na teoria de Bowden e Tabor (1950 *apud* Beeler *et al.*, 2008), tensões normais expressivas levam ao escoamento do material nos pontos de contato, nesse caso a área de contato real entre os corpos sólidos é dada pela relação eq. (3).

$$A_c = \frac{N}{q_u} \quad (3)$$

Onde:  $N = \sum N_i$  é a força normal equivalente ao somatório das forças nos pontos de contato;

$A_c = \sum A_{ci}$  é a área de contato real total, equivalente ao somatório das áreas de contato reais em cada ponto de contato;

$q_u$  = Tensão de escoamento do material;

Considerando que a resistência ao cisalhamento por unidade de área ( $s$ ) nos pontos de contato é característica dos materiais em contato, a força tangencial externa ( $T$ ) necessária para separar esses contatos é dada pela eq. (4).

$$T = s A_c \quad (4)$$

Sendo  $T = \sum T_i$  é a força tangencial externa total equivalente ao somatório das forças tangenciais externas nos pontos de contato.

Dessa observação, deduz-se que a força tangencial ( $T$ ) necessária para causar deslizamento relativo entre corpos sólidos está diretamente relacionada à área de contato real ( $A_c$ ) entre eles. Sendo assim, aplicando a eq. (3) na eq. (4), obtém-se a eq. (5).

$$T = s \frac{N}{q_u} \quad (5)$$

Portanto, conclui-se que a força tangencial ( $T$ ) necessária para o deslizamento entre os corpos sólidos varia proporcionalmente à força normal ( $N$ ), conforme estabelece a primeira Lei do Atrito.

Ao analisar a eq. (1) em comparação com a eq. (5), verifica-se que o coeficiente de atrito ( $f$ ) é expresso pela eq. (6), concluindo assim que o coeficiente de atrito é uma característica inerente aos materiais em contato.

$$f = \frac{s}{q_u} \quad (6)$$

Taylor (1948) propôs uma visão global sobre o atrito em uma abordagem macroscópica. Ele examinou como blocos repousam e interagem com superfícies



planas em várias configurações. Quando um bloco é colocado em uma superfície plana, uma força vertical  $P$ , que inclui o peso do bloco, é aplicada. Isso resulta em uma força de reação normal ( $N$ ) da superfície ao bloco, conforme ilustrado na Figura 2.3 (a). Essa interação normal permite a existência de uma força de atrito ( $F_{at}$ ), que permanece inativa até que seja necessária para contrapor uma força tangencial aplicada ( $T$ ). A máxima força de atrito ( $F_{at}$ ) disponível pode ser calculada a partir da eq. (7):

$$F_{at} = N \cdot f = N \cdot \operatorname{tg} \phi \quad (7)$$

Onde  $\phi$  é o ângulo de atrito e  $f$  é o coeficiente de atrito, ambos refletindo as propriedades dos materiais em contato.

Se uma força tangencial menor ( $T'$ ) é aplicada ao bloco, definida pela eq. (8), a força resultante ( $R'$ ) das forças  $T'$  e  $P$  forma um ângulo  $\alpha$  com a normal à interface de contato. Esse ângulo  $\alpha$ , chamado de ângulo de inclinação da resultante, depende unicamente do sistema de forças em jogo, não das propriedades dos materiais. Para evitar o movimento do bloco causado pela força  $T'$ , uma parte da força de atrito ( $F_{at}$ ) é utilizada, resultando em um ângulo  $\phi_{mob} = \alpha$  com a normal. Como  $T'$  é menor que  $F_{at}$  e  $\alpha$  é menor que  $\phi$ , o bloco não desliza, conforme ilustra a Figura 2.3 (b).

$$T' = N \cdot \operatorname{tg} \phi_{mob} \quad (8)$$




Figura 2.3 Bloco e uma superfície horizontal na condição (a) sem atrito e (b) com atrito parcial (adaptado de Taylor, 1948)

Quando uma força tangencial  $T$ , definida pela eq. (9), igual à força de atrito máxima ( $F_{at}$ ), é aplicada, toda a força de atrito é empregada para resistir a  $T$ , levando  $\alpha$  a igualar  $\phi$ , e o bloco fica na iminência de deslizar para a direita, Figura 2.4 (c) ou para a esquerda Figura 2.4 (d).

$$T = F_{at} = N \cdot \operatorname{tg} \phi \quad (9)$$




Figura 2.4 Bloco e uma superfície horizontal com mobilização total e deslizamento para (c) direita e (d) para esquerda (adaptado de Taylor, 1948)

A partir da eq. (9), ao dividir essas forças pela área de contato entre o bloco e a superfície ( $A$ ), tem-se a relação descrita na eq. (10).

$$\frac{F_{at}}{A} = \frac{N}{A} \cdot \operatorname{tg} \phi \quad (10)$$

Definindo  $s$  como a resistência ao cisalhamento ( $F_{at}/A$ ) e  $\sigma$  como a tensão normal média ( $N/A$ ), a fórmula que descreve a iminência de deslizamento é apresentada na eq. (11).

$$\tau = s = \sigma \cdot \operatorname{tg} \phi \quad (11)$$

Onde  $\tau$  é a tensão cisalhante média entre o bloco e a superfície;  $s$  é a resistência ao cisalhamento entre o bloco e a superfície horizontal; e  $\sigma$  é a tensão normal média atuante entre o bloco e a superfície horizontal.

Taylor (1948) propôs uma analogia entre a resistência ao deslizamento em massas de solo e a resistência ao cisalhamento observada entre dois corpos sólidos. Essa resistência, tanto no solo quanto nos corpos sólidos, depende da tensão normal

no plano de contato e do ângulo de atrito, sendo este último conhecido como ângulo de atrito interno quando se trata de solos.

A análise da resistência ao cisalhamento em solos apresenta maior complexidade e requer uma compreensão mais detalhada do comportamento dos solos sob diferentes solicitações. No caso específico das areias, a resistência ao cisalhamento é influenciada principalmente por duas variáveis: a primeira relacionada ao atrito gerado pelo movimento e rotação entre os grãos de areia, e a segunda ao fenômeno conhecido como *interlocking*. Este último fenômeno se refere ao encaixe entre as partículas do solo, que depende do índice de vazios e da tensão normal efetiva (Taylor, 1948). Os tópicos a seguir abordarão alguns dos fatores que influenciam o comportamento das areias, como o efeito do índice de vazios e da tensão confinante (item 2.1.2.2).

#### **2.1.1.**

##### **Estado de tensão e critério de ruptura no solo**

Para compreender as tensões em solos, é crucial reconhecer que eles são compostos por partículas e que as forças aplicadas se propagam de partícula a partícula, suportadas também pela água nos vazios entre elas. Essa transmissão de forças varia conforme a dimensão e o tipo das partículas, ela ocorre nos pontos de contato, representando apenas uma fração da área total envolvida.

Ao se realizar um corte plano em uma massa de solo, conforme ilustrado pela Figura 2.5, observa-se que poucos grãos e vazios estão efetivamente em contato, e a representação esquemática desse contato, embora simplificada, ilustra a complexidade de definir tensões no solo. A realidade tridimensional e a seção transversal variada do solo dificultam a representação precisa dos pontos de contato e, por extensão, das tensões que se desenvolvem nesses pontos (Pinto, 2009).




Figura 2.5 Esquema de contato entre grãos (Pinto, 2009)

Na mecânica dos solos, as tensões são analisadas conforme o conceito da mecânica do contínuo, definidas como força por unidade de área, conhecidas como "tensões macroscópicas", termo citado por Lambe e Whitman (1969). As tensões de contato entre as partículas do solo, embora fundamentais, são raramente avaliadas diretamente devido à complexidade de mensuração. Por isso, considera-se um "ponto" no solo como um elemento cúbico de dimensões finitas que contém uma massa de solo representativa, com peso específico correspondente ao do solo onde está inserido. Este ponto está sujeito a tensões que são calculadas dividindo as forças que atuam nas faces do cubo pela área dessas faces, o que permite definir as tensões normais e de cisalhamento atuantes no elemento.

Em solos, compostos por sólidos, água e ar, os esforços são sentidos tanto pelo esqueleto sólido quanto pela água nos vazios. Nos solos secos, todos os esforços são suportados pelos sólidos, enquanto nos saturados, as tensões normais são transmitidas tanto pelos sólidos quanto pela água.

Na análise de tensões em mecânica dos solos, um plano genérico no interior do subsolo está sujeito a uma tensão que pode ser decomposta em duas componentes: a tensão normal ( $\sigma$ ), que é perpendicular ao plano, e a tensão cisalhante ( $\tau$ ), que é paralela ao plano, conforme ilustrado na Figura 2.6.




Figura 2.6 Representação das tensões normais e cisalhantes atuando no plano

No estudo de tensões, destaca-se o conceito de tensões principais,  $\sigma_1$  (principal maior),  $\sigma_2$  (principal intermediária) e  $\sigma_3$  (principal menor), que atuam em planos ortogonais onde as tensões de cisalhamento são nulas, conforme ilustrado na Figura 2.7. Em engenharia geotécnica, as tensões principais maiores e menores são de particular interesse, pois a resistência ao cisalhamento do solo e a análise de ruptura dependem dessas tensões (Pinto, 2009).




Figura 2.7 Tensões principais atuantes nas faces do elemento cúbico

Quando as direções principais de tensão em um ponto são conhecidas, as tensões em qualquer outro plano passando por esse ponto podem ser determinadas usando as equações de equilíbrio para um prisma triangular definido pelos planos principais e o plano considerado. As tensões normal e cisalhante em um plano genérico em relação às tensões principais podem ser deduzidas e chega-se nas eq. (12) e (13).

$$\sigma_{\alpha} = \frac{\sigma_1 + \sigma_3}{2} + \frac{\sigma_1 - \sigma_3}{2} \cos(2\alpha) \quad (12)$$

$$\tau_{\alpha} = \frac{\sigma_1 - \sigma_3}{2} \sin(2\alpha) \quad (13)$$

Onde,  $\alpha$  é o ângulo que o plano faz com a direção da tensão principal maior.

Outra forma de se obter o estado de tensões atuantes em todos os planos que passam por um ponto é através do círculo de Mohr. O círculo de Mohr (Figura 2.8) é representado por um gráfico onde o eixo horizontal (abcissas) indica as tensões normais e o eixo vertical (ordenadas), as tensões cisalhantes. Nesse sistema as eq. (13) e (18) definem um círculo como representado na Figura 2.8.




Figura 2.8 Determinação de tensões num plano genérico por meio do Círculo de Mohr (Pinto, 2009)

Terzaghi (1936) enunciou o Princípio das Tensões Efetivas, que foi crucial para entender como a água afeta a resistência de um solo saturado. Atiknson e Bransby (1978) propuseram a divisão do Princípio das Tensões Efetivas em duas partes, a primeira parte que define ‘tensão efetiva’ enquanto a segunda define seus efeitos. Ambas são descritas a seguir.

Primeira parte: “As tensões em qualquer ponto de uma seção em uma massa de solo podem ser computadas a partir das tensões principais totais  $\sigma_1$ ,  $\sigma_2$ ,  $\sigma_3$  que atuam neste ponto. Se os vazios do solo estiverem preenchidos com água sob uma pressão  $u$ , as tensões principais totais consistem em duas parcelas. Uma parcela de valor  $u$  que age na água e na parte sólida em todas as direções com igual magnitude. Essa parcela é denominada pressão neutra (ou poropressão). As parcelas remanescentes  $\sigma'_1 = \sigma_1 - u$ ,  $\sigma'_2 = \sigma_2 - u$  e  $\sigma'_3 = \sigma_3 - u$  são “sentidas” exclusivamente pelo esqueleto sólido do solo. Estas parcelas das tensões principais totais serão denominadas tensões principais efetivas.”

Portanto, a equação das tensões efetivas seguindo a primeira parte do princípio das tensões efetivas é definida pela eq. (14).

$$\sigma' = \sigma - u \quad (14)$$

A segunda parte define a importância da tensão efetiva. “Todos os efeitos mensuráveis oriundos de uma variação do estado de tensões, tais como compressão, distorção e variação da resistência ao cisalhamento, são exclusivamente devidos à variação do estado de tensões efetivas.”

Com a segunda parte do Princípio das Tensões Efetivas, fica mais evidente que o comportamento do solo é comandado pelas tensões efetivas nele atuantes.

Conhecidos os estados de tensões totais do solo e a poropressão naquele ponto, a partir da eq. (14) é possível determinar as tensões efetivas e o círculo de Mohr de tensões efetivas pode ser determinado. Observa-se que os círculos de Mohr das tensões efetivas possuem as mesmas dimensões dos círculos de Mohr das tensões totais, uma vez que a água não apresenta resistência ao cisalhamento. Outro ponto fundamental é que os círculos são deslocados horizontalmente em relação ao valor da poropressão ( $u$ ), conforme ilustrado na Figura 2.9.




Figura 2.9 Círculo de Mohr das tensões totais e efetivas (Adaptado de Simões, 2015)

O estudo da resistência e comportamento de um solo está relacionado com a análise do estado de tensões que provoca sua ruptura. Segundo Pinto (2009), os critérios de ruptura são formulações que procuram explicar as condições em que ocorre a ruptura dos materiais. Existem critérios que estabelecem máximas tensões de compressão, de tração ou de cisalhamento, deformações máximas enquanto outros se referem à energia de deformação.

O critério de ruptura que, de acordo com Pinto (2009), melhor representa o comportamento dos solos são os de Coulomb e de Mohr. O critério de Mohr é definido conforme uma observação experimental, nele a ruptura ocorre quando o círculo representativo do estado de tensões se encontra com a curva, que é a envoltória dos círculos relativos a estados de ruptura. A Figura 2.10 apresenta uma representação dessa envoltória observada por Mohr. Nessa figura, o círculo 'A' representa um estado de tensões tangenciando a envoltória em que se observa a ruptura, enquanto o 'B' representa um estado de tensões onde não foi observada sua ruptura (Pinto, 2009).




Figura 2.10 Representação do critério de Ruptura de Mohr (Pinto, 2009)

O critério de ruptura de Coulomb enuncia a condição de ruptura do solo com base nas Leis de atrito de Coulomb, discutidas anteriormente. Com isso, a resistência ao cisalhamento do solo, a partir do critério de Coulomb, varia com a tensão normal ao plano de ruptura, sendo função do ângulo de atrito e, eventualmente, de um intercepto coesivo ou de uma coesão verdadeira, conforme eq. (15).

$$s = \tau_{ff} = c + \sigma_{ff} \tan \phi \quad (15)$$

Onde  $s$  é a resistência ao cisalhamento;

$\tau_{ff}$  é a tensão cisalhante atuante no plano de ruptura na ruptura;

$\sigma_{ff}$  é a tensão normal atuante no plano de ruptura na ruptura;

$\phi$  é o ângulo de atrito;

$c$  é o intercepto de coesão ou coesão verdadeira.

O critério de Mohr-Coulomb é a combinação dos dois critérios onde a envoltória de ruptura de Mohr é representada pela equação do critério de Coulomb. No caso dos solos, conforme discutido anteriormente, a resistência é comandada pelas tensões efetivas, sendo assim a envoltória do critério de ruptura de Mohr-Coulomb é reformulada a partir das tensões efetivas como apresentado na eq. (16).

$$s = \tau_{ff} = c' + \sigma'_{ff} \cdot \tan \phi' \quad (16)$$

Onde  $\sigma'_{ff}$  é a tensão efetiva normal atuante no plano de ruptura na ruptura;

$\phi'$  é o ângulo de atrito efetivo;

$c'$  é o intercepto de coesão efetiva ou coesão verdadeira efetiva.



A Figura 2.11 apresenta uma representação da envoltória de ruptura considerando o critério de Mohr-Coulomb, com a representação de ruptura visto que o estado de tensões efetivas está tangenciando a envoltória. Importante observar que o critério não leva em consideração a influência da tensão principal intermediária ( $\sigma'_2$ ).




Figura 2.11 Envoltória de Ruptura de Mohr-Coulomb

Em areias secas ou saturadas, observa-se que em geral a coesão e o intercepto coesivo tendem a ser nulos ( $c' = 0$ ), resultando em uma representação gráfica através de uma reta que se origina no ponto zero. Importante observar, também, que devido à alta permeabilidade desses materiais, nas situações típicas de engenharia às quais a areia saturada está sujeita, qualquer excesso de poropressão gerado tende a ser dissipado quase instantaneamente. Por isso, é frequente a afirmação de que, nessas condições, não se verifica a geração de excesso de poropressão ( $\Delta u = 0$ ).

### 2.1.2.

#### Comportamento da areia submetida ao cisalhamento

De acordo com Pinto (2009), solos arenosos são aqueles em que a fração de areia é superior a 50%, onde o percentual de finos presente no solo não interfere significativamente no comportamento do conjunto do solo. As areias são bastante permeáveis e isso permite que, sob carregamento a que ficam submetidas em obras de engenharia, o tempo seja suficiente para a drenagem. Com isso, a resistência das areias é comumente definida em termos de tensões efetivas.

Segundo Lambe e Whitman (1969), existem vários fatores que determinam a resistência ao cisalhamento do solo granular seco e eles podem ser divididos em dois grupos. O primeiro grupo inclui fatores que afetam um solo específico: índice

de vazios, tensão confinante, a taxa de carregamento, entre outros. O segundo grupo inclui aqueles fatores que fazem a resistência de um solo ser diferente de outro, mesmo considerando uma relação de tensões e índice vazios: o tamanho e a forma das partículas, distribuição granulométrica etc.

As demonstrações mais antigas de mudanças de volume acompanhando deformações cisalhantes em areia, de acordo com Lee e Seed (1967), foram feitas por Reynolds (1885 *apud* Lee e Seed, 1967), que mostrou experimentalmente que areias compactas dilatam quando cisalhadas seguido diretamente de seus experimentos. Foi com Casagrande (1940 *apud* Lee e Seed, 1967) que os estudos feitos demonstraram a dependência do ângulo de atrito de uma areia na razão de vazios e as mudanças de volume associadas durante o cisalhamento. O autor mostrou que, enquanto areias compactas tendem a dilatar durante o cisalhamento e exibem um alto ângulo de atrito, areias fofas tem a tendência de se comprimir durante o cisalhamento e desenvolvem um ângulo de atrito muito menor. Ele definiu o índice de vazios crítico para descrever o estado particular de compacidade relativa em que uma areia cisalha sem mudanças de volume, demonstrou também que esse valor diminui à medida que a tensão confinante atuando na areia aumenta.

#### **2.1.2.1.**

##### **Comportamento contrátil e dilatante das areias**

Segundo Pinto (2009), os ensaios mais comuns de serem empregados para a determinação da resistência do solo são: cisalhamento direto e compressão triaxial. Para a análise do comportamento da areia nesse tópico será considerado um ensaio de compressão triaxial pois nele é possível conhecer os estados de tensões e os estados de deformações, além do controle da drenagem. Como na grande maioria das vezes as areias se submetem a carregamentos drenados, serão estudadas nesse tópico o comportamento das areias por ensaios triaxiais adensados hidrostáticamente (também conhecido como isostáticamente) de forma drenada, do inglês *Consolidated Isotropic Drained* (CID), com os corpos de prova saturados.

Durante um cisalhamento drenado, observa-se que as areias apresentam dois comportamentos volumétricos distintos: o comportamento contrátil, caracterizado pela redução do volume do solo sob cisalhamento, e o comportamento dilatante, onde ocorre um aumento do volume. O fenômeno que determina se um solo,

especialmente a areia, exibe um comportamento contrátil ou dilatante, é influenciado por uma combinação de fatores. Estes incluem principalmente o índice de vazios inicial ( $e_0$ ) ou, mais especificamente, a compacidade relativa (CR), bem como a tensão confinante ( $\sigma'_c$ ), ou normal, no início do cisalhamento (Pinto, 2009).

A Figura 2.12 apresenta os resultados típicos de areias em ensaios triaxiais tipo CID, com comportamentos contráteis e dilatantes, estes detalhados a seguir:

#### **Comportamento Contrátil:**

É possível observar que durante o aumento das deformações axiais ( $\varepsilon_a$ ), há um aumento gradual na tensão desviadora ( $\sigma_d = \sigma_1 - \sigma_3$ ), atingindo um valor máximo em deformações relativamente elevadas, conforme pode ser visto na Figura 2.12 (a). Ensaios conduzidos sob variadas tensões confinantes ( $\sigma_3$ ) indicam uma relação proporcional entre as tensões desviadoras geradas e as tensões confinantes utilizadas no ensaio (Figura 2.12 (a)). Essa relação sugere que, ao traçar os círculos de Mohr (Figura 2.12 (c)) correspondentes às tensões efetivas máximas (ponto de ruptura), obtém-se uma envoltória de resistência que intercepta a origem. O ângulo formado por esta envoltória com a horizontal é identificado como o ângulo de atrito interno da areia ( $\phi$ ). Adicionalmente, a Figura 2.12 (b) ilustra que, com o progresso das deformações axiais, há uma tendência de diminuição do volume dos corpos de prova (contração), sendo essa redução ligeiramente maior para tensões confinantes elevadas (modificado de Pinto, 2006).

#### **Comportamento Dilatante:**

Na aplicação de deformações axiais, a tensão desviadora aumenta rapidamente até alcançar um valor máximo, conhecido como resistência de pico, conforme ilustrado na Figura 2.12 (d). Após este pico, a tensão desviadora diminui gradualmente até estabilizar-se em um valor próximo ao da resistência residual. Essa perda de resistência após o pico pode ser atribuída a uma gradual diminuição do *interlocking* entre as partículas. Ensaios com diferentes tensões confinantes sugerem que as tensões desviadoras máximas (ruptura) são proporcionais às tensões confinantes dos ensaios. A envoltória de resistência de pico, tangenciando os círculos de Mohr das tensões efetivas máximas, também se inicia na origem (Figura 2.12 (f)). A partir desta envoltória, determina-se o ângulo de atrito de pico da areia ( $\phi_c$ ). Ademais, os círculos de Mohr das tensões efetivas na condição residual, que

também são proporcionais às tensões confinantes dos ensaios, definem uma outra envoltória que igualmente passa pela origem, estabelecendo o ângulo de atrito residual da areia. A Figura 2.12 (e) demonstra que, inicialmente, há uma pequena redução de volume no corpo de prova (contração), mas antes de atingir a resistência máxima, o volume começa a aumentar (dilatação), resultando em um volume final superior ao inicial. A Figura 2.12 (e) complementa esta análise, mostrando que tensões confinantes menores resultam uma leve contração inicial e maior dilatação subsequente (modificado de Pinto, 2009).

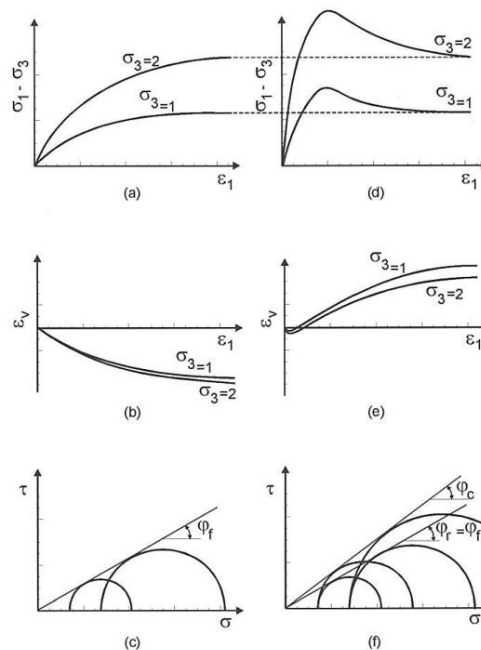


Figura 2.12 Resultados típicos de ensaios em areia triaxial tipo CID; (a), (b) e (c) comportamento contrátil, (d), (e) e (f) comportamento dilatante (Pinto, 2009)

### 2.1.2.2.

#### Efeito do índice de vazios e tensão confinante no comportamento das areias

Lee e Seed (1967) realizaram um amplo estudo com programa de ensaios triaxiais tipo CID e de compressão hidrostática. O material utilizado foi a Areia do Rio Sacramento, da Califórnia. Esta areia, peneirada entre as malhas #50 (0,297 mm) e #100 (0,149 mm), é composta principalmente por grãos de feldspato e quartzo, variando de subangular a subarredondado, com uma densidade de grãos  $G = 2,68$  e índices de vazios mínimo e máximo de, respectivamente,  $e_{\min} = 0,61$  e  $e_{\max} = 1,00$ . Nos ensaios de compressão hidrostática pelos autores,

o adensamento primário ocorreu quase instantaneamente, seguido por deformações volumétricas significativas atribuídas à compressão secundária. Após 120 minutos, as variações de volume foram tão reduzidas que se considerou a compressão secundária insignificante para a duração dos ensaios. Assim, adotou-se um procedimento padrão de adensamento com duração de 120 minutos.

As curvas de compressão hidrostática obtidas (Figura 2.13) revelaram que, sob baixas tensões hidrostáticas, a Areia do Rio Sacramento exibe baixa compressibilidade, independentemente da compacidade relativa inicial. Notou-se também que, com o aumento das tensões hidrostáticas (acima de  $100 \text{ kgf/cm}^2$ ), as areias sofrem compressão volumétrica significativa, resultando em corpos de prova inicialmente fofos sendo comprimidos até atingirem índices de vazios inferiores aos da areia compacta, com compacidade relativa ( $CR$ ) de 100%.




Figura 2.13 Curvas de tensão-índice de vazios para areia em quatro compacidades iniciais (Adaptado de Lee e Seed, 1967)

No estudo realizado por Lee e Seed (1967), foram realizados ensaios triaxiais com corpos de prova da Areia do Rio Sacramento em condições fofas ( $e_0 = 0,87$ ) e compactas ( $e_0 = 0,61$ ) para diferentes níveis de tensões confinantes ( $\sigma_3$ ). As Figura 2.14 e Figura 2.15 apresentam gráficos com as relações  $(\sigma_1/\sigma_3) \times \varepsilon_a$  e  $\varepsilon_v \times \varepsilon_a$ , sendo  $\varepsilon_a$  a deformação axial e  $\varepsilon_v$  a deformação volumétrica.

Ao analisar a Figura 2.14, que corresponde ao corpo de prova na condição compacta ( $CR = 100\%$ ), observa-se que o incremento da tensão confinante resulta em três consequências notáveis. Primeiramente, verifica-se uma redução das tensões máximas na relação entre as tensões principais  $(\sigma_1/\sigma_3) \times \varepsilon_a$ , impactando

diretamente a resistência do material. Em segundo lugar, ocorre um aumento no valor de  $\varepsilon_a$  no ponto de ruptura, indicativo de uma maior resistência sob condições de tensão elevada. Terceiro, constata-se uma diminuição da dilatância.

Adicionalmente, sob tensões confinantes elevadas, mesmo os corpos de prova com ( $e_0 = e_{min}$ ). podem apresentar redução de volume durante o cisalhamento, conforme ilustrado no gráfico  $\varepsilon_v \times \varepsilon_a$ . Portanto, com uma tensão confinante alta, comportamento de um corpo de prova de areia compacta pode assemelhar-se ao de uma areia fofa sob tensões confinantes mais baixas.




Figura 2.14 Gráfico de tensão-deformação-volume para areia compacta (Adaptado de Lee e Seed, 1967)

A Figura 2.15 mostra resultados similares para corpos de prova da Areia do Rio Sacramento preparados na condição fofa ( $e_0 = 0,87$ ). O padrão de comportamento é analogamente similar ao observado para os corpos de prova compactos, com algumas distinções. Para baixos valores de tensão confinante, a dilatância não é tão pronunciada quanto nos corpos de prova compactos. Além disso, sob altas tensões confinantes, a compressão é mais acentuada do que aquela observada nos corpos de prova compactos, indicando uma variação no comportamento mecânico em função da compactidade inicial do material.

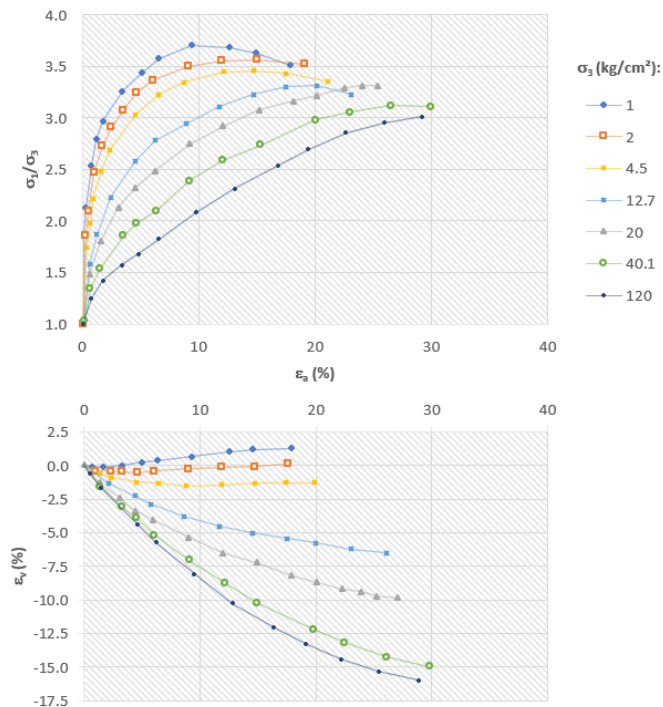


Figura 2.15 Gráfico de tensão-deformação-volume para areia fofa (Adaptado de Lee e Seed, 1967)

## 2.2. Ensaio de Laboratório

Ensaio de laboratório e de campo são ferramentas indispensáveis para investigar as propriedades físicas e mecânicas do solo, fundamentais na análise e projetos de engenharia de forma geral. Conforme mencionado por Corte (2016), os ensaios de laboratório têm diferentes graus de sofisticação e buscam representar as condições de ocorrência. Dentre os vários ensaios de laboratório existentes, pode-se citar:

- ensaio de compressão simples;
- ensaio de cisalhamento direto;
- ensaio de compressão triaxial;
- ensaio *ring shear*;
- ensaio triaxial cúbico;
- ensaio *hollow cylinder*;
- ensaio *direct simple shear*.

Neste trabalho será aprofundado os dois ensaios que fazem parte do escopo de estudo: o ensaio de cisalhamento direto e o ensaio de DSS (*Direct Simple Shear*).

### 2.2.1. Cisalhamento Direto

Segundo Corte (2016), o ensaio de cisalhamento direto é reconhecido como um dos mais tradicionais métodos para avaliar a resistência ao cisalhamento, se baseia diretamente no critério de Mohr-Coulomb. Alexandre Collin foi pioneiro na criação do primeiro dispositivo, por volta de 1980. Durante o ensaio, impõe-se uma tensão normal em um plano específico e observa-se a tensão de cisalhamento necessária para causar a ruptura.

O ensaio de cisalhamento direto tem como objetivo a determinação de algumas propriedades de resistência ao cisalhamento do solo. Essencialmente, o ensaio avalia a capacidade do solo de resistir a forças de cisalhamento. Nesse ensaio o cisalhamento ocorre no plano horizontal imposto pela caixa bipartida, conforme ilustrado na Figura 2.16.



Figura 2.16 Cisalhamento no ensaio de cisalhamento direto (adaptado de VJ Tech, 2023)

Das etapas do ensaio, tem-se inicialmente a colocação da amostra a ser testada no aparato de cisalhamento direto, seguida da aplicação de uma tensão normal e a amostra sofre o processo de adensamento. Em seguida, desbloqueia-se os quadros que seguram a amostra, permitindo o deslocamento horizontal de um quadro em relação ao outro a uma taxa constante de deformação por cisalhamento. Durante o processo, a força de cisalhamento e os deslocamentos horizontais são medidos à medida que a amostra é submetida ao cisalhamento (ASTM, 2003). A Figura 2.17 apresenta um diagrama esquemático do ensaio.






Figura 2.17 Diagrama esquemático do ensaio de cisalhamento direto (Adaptado de Simões, 2015)

Para cada tensão vertical nominal aplicada, são obtidos como resultados as curvas “tensão cisalhante sobre tensão normal ( $\tau/\sigma$ ) versus deslocamento horizontal relativo ( $\delta_h$ )” e “deslocamento vertical do *top cap* ( $\delta_v$ ) versus deslocamento horizontal relativo ( $\delta_h$ )”. De posse dessas curvas, identifica-se a razão  $(\tau/\sigma)_{máx}$ , que corresponde à ruptura do corpo de prova. A realização de diversos ensaios com corpos prova provenientes do mesmo material sob diferentes tensões verticais nominais leva a obtenção da envoltória de resistência do material, gráfico  $\tau \times \sigma$ . A Figura 2.18 apresenta curvas de resultados típicos do ensaio de cisalhamento direto em uma areia fofa.




Figura 2.18 Resultados típicos de ensaio de cisalhamento direto em areia fofa (Lambe e Whitman, 1969)

Considerando as limitações do ensaio, existem a impossibilidade do controle das condições de drenagem e ausência de medição da poro-pressão, sendo, portanto, os resultados dos ensaios dados em termos de tensões totais. Coutinho (2021) pontua que no caso de ensaios realizados em areias na condição submersa, os excessos de poro-pressão gerados por conta das deformações cisalhantes são rapidamente dissipados, sendo assim, o cisalhamento pode ser assumido como realizado sob condições drenadas e, com isso, as tensões efetivas podem ser assumidas como iguais às tensões totais.

### 2.2.2.

#### Cisalhamento Simples (*Direct Simple Shear* - DSS)

O ensaio de *Direct Simple Shear* (DSS), assim como o cisalhamento direto, também tem como objetivo a determinação de algumas propriedades de resistência ao cisalhamento do solo. No entanto, no DSS o cisalhamento não ocorre em um plano de ruptura horizontal imposto. O corpo de prova (CP) durante todo o ensaio é confinado lateralmente, por uma membrana reforçada ou por anéis justapostos que impedem que o CP tenha um deslocamento lateral, mas permitem a deformação cisalhante, enquanto o comprimento horizontal da amostra é constante (Dyvik et al., 1987). A Figura 2.19 apresenta as condições de tensão e deformação na amostra do ensaio de DSS.




Figura 2.19 Condições de tensão e deformação durante o cisalhamento no ensaio de DSS (Dyvik et al., 1987)

A principal referência para execução do ensaio de DSS é a norma norte-americana ASTM D6528-17 *Standard Test Method for Consolidated Undrained Direct Simple Shear Testing of Fine Grain Soils*. Esta norma, voltada para solos argilosos, abrange vários aspectos do ensaio, incluindo terminologias, descrição do

equipamento e instrumentação, preparação de amostras, procedimentos do ensaio, e métodos para cálculo e apresentação de resultados.

Os corpos de prova usados no DSS são geralmente cilíndricos, com dimensões que variam de acordo com o equipamento, mantendo uma proporção diâmetro/altura de pelo menos três para reduzir a não-uniformidade.

A montagem do ensaio passa pela etapa de colocação do corpo de prova no pedestal com um *topcap*, ambos com pedras porosas, e é envolvido por uma membrana de látex seguida de uma contenção lateral (membrana reforçada ou anéis justapostos), essencial para manter a deformação horizontal nula durante o carregamento vertical. A Figura 2.20 apresenta um diagrama esquemático ilustrativo da montagem típica do ensaio.




Figura 2.20 Diagrama esquemático do ensaio de DSS (Adaptado de ASTM, 2017)

O ensaio de DSS se divide em duas fases: a aplicação do carregamento vertical com o solo confinado lateralmente, seguida pela fase de cisalhamento simples. Durante o carregamento vertical, mede-se a deformação vertical com um transdutor de deslocamento vertical. Na fase de cisalhamento, a base do pedestal é deslocada horizontalmente, mantendo o *topcap* fixo, e mede-se a variação da força vertical e a força tangencial necessária para manter a velocidade constante e o deslocamento horizontal da base. A tensão vertical total e a tensão cisalhante no plano horizontal do corpo de prova são calculadas a partir dessas medidas.

Com relação à condição de drenagem na fase de cisalhamento é possível ter duas situações: o ensaio DSS verdadeiramente não drenado e o ensaio DSS drenado

a volume constante. Ambos os ensaios são realizados mantendo-se constante o volume do corpo de prova ( $\Delta V = 0$ ). Considerando a segunda parte do Princípio das Tensões Efetivas, para uma dada distorção ( $\gamma$ ), espera-se que as tensões efetivas verticais ( $\sigma'_v$ ) nos corpos de prova sejam idênticas nos dois tipos de ensaio, visto que o estado de deformações é equivalente.

No ensaio verdadeiramente não drenado, o impedimento da variação de volume do corpo de prova é garantido pelo fechamento da drenagem e pela saturação do corpo de prova. A tensão vertical total ( $\sigma_v$ ) é mantida constante e a resposta do solo às distorções impostas se manifesta através de variações de poropressão ( $\Delta u = \Delta u(\gamma)$ ). A tensão vertical efetiva ( $\sigma'_v$ ) é então calculada como  $\sigma'_v(\gamma) = \sigma_{v0} - \Delta u(\gamma)$ . No comportamento dilatante, observa-se um aumento na tensão efetiva devido ao excesso de poropressão negativa ( $\Delta u < 0$ ), e no comportamento contrátil, uma diminuição devido ao excesso de poropressão positiva ( $\Delta u > 0$ ). Em contraste, a fase de cisalhamento do ensaio DSS drenado a volume constante é caracterizada pelo controle da altura do corpo de prova. As variações na tensão vertical total ( $\Delta \sigma_v = \Delta \sigma_v(\gamma)$ ) ocorrem em resposta às distorções impostas e são ajustadas para prevenir mudanças de volume, conforme ilustrado na Figura 2.21. Nestas condições, a tensão vertical efetiva ( $\sigma'_v$ ) é determinada por  $\sigma'_v(\gamma) = \sigma_{v0} + \Delta \sigma_v(\gamma)$ , sem o desenvolvimento de excesso de poropressão ( $\Delta u = 0$ ).

A equivalência entre as tensões verticais efetivas em ambos os tipos de ensaio é comprovada pela igualdade das equações  $\sigma_{v0} - \Delta u(\gamma) = \sigma_{v0} + \Delta \sigma_v(\gamma)$ , indicando que as variações na tensão vertical total nos ensaios drenados são numericamente iguais às variações de poropressão nos ensaios não drenados, porém com sinais invertidos.

Dyvik *et al.* (1987) conduziu tanto ensaios drenados a volume constante quanto ensaios verdadeiramente não drenados, demonstrando a equivalência entre eles. Em um ensaio não drenado específico, a poro-pressão foi medida na base do corpo de prova, ilustrando essa igualdade.




Figura 2.21 Esquema do ensaio de DSS sob condições verdadeiramente não drenada e drenada a volume constante (Jannuzzi, 2013 *apud* Martins, 2023)

Conforme pontuado por Atkinson *et al.* (1991), na fase de cisalhamento do ensaio, as tensões normal e cisalhante são conhecidas apenas no plano horizontal. Esta limitação implica que apenas as coordenadas correspondentes a um único ponto no gráfico de  $\tau' \times \sigma'$ , não sendo possível construir um único círculo de Mohr. Conforme evidenciado na Figura 2.22.




Figura 2.22 Condições de contorno do ensaio de DSS (Atkinson *et al.*, 1991)

Villet *et al.* (1985) destacam a importância do *Direct Simple Shear* (DSS) na geotecnia experimental, salientando que este método simula mais precisamente algumas condições *in situ* do solo comparado a outros ensaios convencionais, como em uma estaca sujeita a carregamento vertical, por exemplo. Airey e Wood (1987) complementam, apontando a capacidade única do DSS de aplicar rotações dos eixos de tensão principais, uma característica frequente em situações reais de campo.

Kjellman (1951) destaca algumas vantagens do DSS em comparação com o ensaio de cisalhamento direto. Primeiramente, o DSS mantém o teor umidade da amostra estável por conta do uso da membrana de borracha. Além disso, no DSS, o

adensamento da amostra ocorre sem ser afetado por atrito ou adesão às paredes do equipamento. No DSS, a área da seção transversal da amostra se mantém constante durante o cisalhamento, diferentemente do que ocorre nos ensaios de cisalhamento direto, onde há redução desta área de cisalhamento conforme o deslocamento da amostra acontece (Figura 2.23). Apesar das tensões não serem distribuídas de maneira perfeitamente uniforme, o DSS representa uma significativa melhoria em relação a outros métodos. Contudo, Grognet (2011) identifica uma desvantagem do DSS: a dificuldade em determinar a magnitude e a direção das tensões principais durante o cisalhamento, um aspecto que é mais bem avaliado pelo ensaio de compressão triaxial e no ensaio *simple shear* (Corte, 2016).




Figura 2.23 Condição de deformação no ensaio de DSS e Cisalhamento Direto, respectivamente (Hanzawa *et al.*, 2007)

Os parâmetros de resistência ao cisalhamento dos solos são propriedades de engenharia geotécnica muito importantes para a previsão do comportamento do solo. A determinação dessas propriedades é fundamental para diversas análises e projetos em geotecnia. Diversos métodos para determinar esses parâmetros em solos foram propostos, geralmente através de ensaios em campo ou laboratório. Diferentes autores trabalharam na previsão desses parâmetros em solos usando relações matemáticas, como funções elípticas e hiperbólicas. Recentemente, técnicas de computação, incluindo Inteligência Artificial, têm sido usadas para resolver problemas variados em geociências e engenharia geotécnica (Kanungo *et al.* 2014).

### 2.3. Conceitos básicos de *Machine Learning*

A inteligência artificial (AI) abrange várias abordagens, sem uma definição unânime. Alguns pesquisadores veem a IA em termos de simulação do desempenho humano, enquanto outros adotam uma visão abstrata, destacando a racionalidade - a capacidade de agir adequadamente. A IA também varia em seu foco, com alguns estudando os processos internos de pensamento e outros observando comportamentos inteligentes externos. É essencial distinguir entre 'inteligência artificial' e 'aprendizado de máquina', um subcampo da IA focado na melhoria de desempenho com experiência. Nem todos os sistemas de IA usam métodos de aprendizado de máquina (Russell e Norvig, 2020).

De acordo com Goodfellow *et al.* (2016), a inteligência artificial (IA) é um campo com muitas aplicações práticas e tópicos de pesquisa ativos. *Softwares* inteligentes são procurados para automatizar o trabalho de rotina, compreender a fala ou imagens, fazer diagnósticos em medicina e apoiar a investigação científica básica. Os autores apresentaram a Figura 2.24 com a relação entre as diferentes disciplinas da IA. É possível observar que a IA é o campo mais abrangente, englobando a concepção de algoritmos capazes de simular aspectos do raciocínio e comportamento humano. O Aprendizado de Máquina - AM (*Machine Learning* - ML) é uma subcategoria da IA, focada no desenvolvimento de técnicas que permitem que as máquinas aprendam a partir de dados. O Aprendizado Profundo (AP), também conhecido como *Deep Learning*, é um tipo particular de aprendizado de máquina, uma especialização ainda mais específica que tem o potencial de modelar dados complexos.




Figura 2.24 Diagrama de Venn apresentando a relação entre IA, AM e AP (Adaptado de Goodfellow *et al.*, 2016)

Um modelo de *machine learning* pode ser definido, de acordo com Mohri *et al.* (2018), como métodos computacionais que utilizam a experiência (dados passados ao modelo) para melhorar o desempenho ou fazer previsões acuradas. Esses dados podem estar na forma de conjuntos de treinamento rotulados digitalmente por humanos ou outros tipos de informações obtidas por meio da interação com o ambiente. O autor enfatiza ainda que a qualidade e o quantidade desses dados são essenciais para o sucesso das previsões feitas pelo modelo.

Os modelos de *machine learning* podem ser utilizados para auxiliar na resolução de diversos problemas de diversas áreas, dentre eles pode-se citar: classificação de textos ou documentos (identificação de spam numa lista de *e-mails*); processamento de linguagem natural (marcação de classes gramaticais); processamento de fala (reconhecimento de voz); visão computacional (reconhecimento de objetos em imagens).

De acordo com Dramsch (2019) o campo do *machine learning* está testemunhando uma expansão rápida, com melhorias significativas impulsionadas por descobertas matemáticas, avanços em técnicas de engenharia e a crescente disponibilidade de vastos repositórios de dados. O autor apresenta em seu trabalho uma linha do tempo com o que ele chama de marcos notáveis em *machine learning*, apresentado na Figura 2.25.



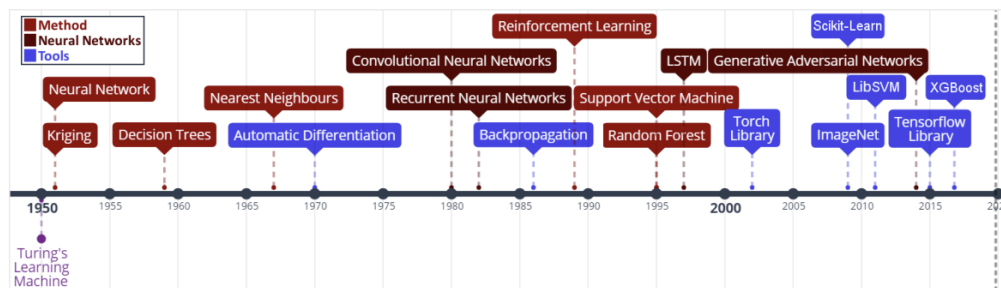


Figura 2.25 Seleção de marcos notáveis em *machine learning* (Dramsch, 2019)

No contexto do aprendizado de máquina, existem vários cenários que diferem conforme os dados de treino disponíveis, a forma como são recebidos e os dados de teste utilizados para avaliar o algoritmo de aprendizado. Mohri *et al.* (2018) cita sete tipos: Aprendizado supervisionado; não supervisionado; semi-supervisionado; transdutivo; *online*; reforçado e ativo. No aprendizado supervisionado, o modelo trabalha com exemplos rotulados e faz previsões para pontos não vistos, sendo comum em problemas de classificação, regressão e *ranking*, como a detecção de *spam*. O aprendizado não supervisionado, por sua vez, lida somente com dados não rotulados, o que torna desafiador avaliar quantitativamente o desempenho do aprendizado, como é o caso em problemas de agrupamento e redução de dimensionalidade.

James *et al.* (2023) explica que no aprendizado supervisionado, cada observação de preditor possui uma resposta associada, e o objetivo é modelar a relação entre preditores e respostas para previsão. Enquanto no aprendizado não supervisionado, não existe uma única resposta associada às observações, cada observação apresenta um vetor de medidas sem uma resposta associada.

Na área de *machine learning*, dentro do aprendizado supervisionado, depara-se com tarefas que têm sido alvo de extensos estudos, sendo duas delas a classificação e a regressão. A classificação envolve categorizar itens em grupos distintos, como classificar documentos em temas como política ou esporte, ou imagens em categorias como carros ou trens. Por outro lado, a regressão busca prever um valor numérico real para cada item, como o preço de ações ou a variação de indicadores econômicos, onde a exatidão é crucial e erros são mensurados pela diferença entre o valor real e o previsto. Outras tarefas relevantes incluem *ranking*, agrupamento (*clustering*); redução de dimensionalidade (*dimensionality reduction* ou *manifold learning*) (Mohri *et al.*, 2018).

Para entender a estrutura dos dados, considera-se um conjunto na forma  $(x_i, y_i)$ , onde  $x_i$  representa um exemplo (atributos ou instâncias) e  $y_i$  o rótulo correspondente (classe). O objetivo é desenvolver um classificador, também denominado como modelo, preditor ou hipótese, que seja capaz de prever de maneira precisa o rótulo de novos dados. Este processo de gerar um classificador a partir de um conjunto de dados exemplares é conhecido como treinamento. O classificador obtido pode ser descrito como uma função  $f$ , que recebe um dado  $x$  e retorna uma previsão  $y$  (Lorena e Carvalho, 2007).

Os rótulos ou classes são representações do fenômeno alvo das previsões. Em situações em que os rótulos apresentam valores discretos, está-se diante de um problema de classificação. Por outro lado, se os rótulos exibem valores contínuos, configura-se uma situação de regressão (Baranauskas *et al.*, 2000).

Baranauskas *et al.* (2000) apresenta a Figura 2.26 ilustrando um caso de processo de construção do classificador. Um classificador é definido como, essencialmente, uma hipótese ou modelo que, após treinado com um conjunto de dados - os quais incluem entradas e as saídas correspondentes - é capaz de fazer previsões acertadas sobre os rótulos de novas instâncias. Este modelo é construído a partir de dados estruturados que ele usa para mapear entradas e seus rótulos apropriados. Os autores pontuam que o conhecimento prévio acerca dos dados pode ser aplicado na seleção de parâmetros ou na inclusão de informações já conhecidas como entrada no modelo de aprendizado da máquina. Posteriormente, o classificador é tipicamente submetido a uma avaliação, e o processo pode ser reiterado, caso necessário.

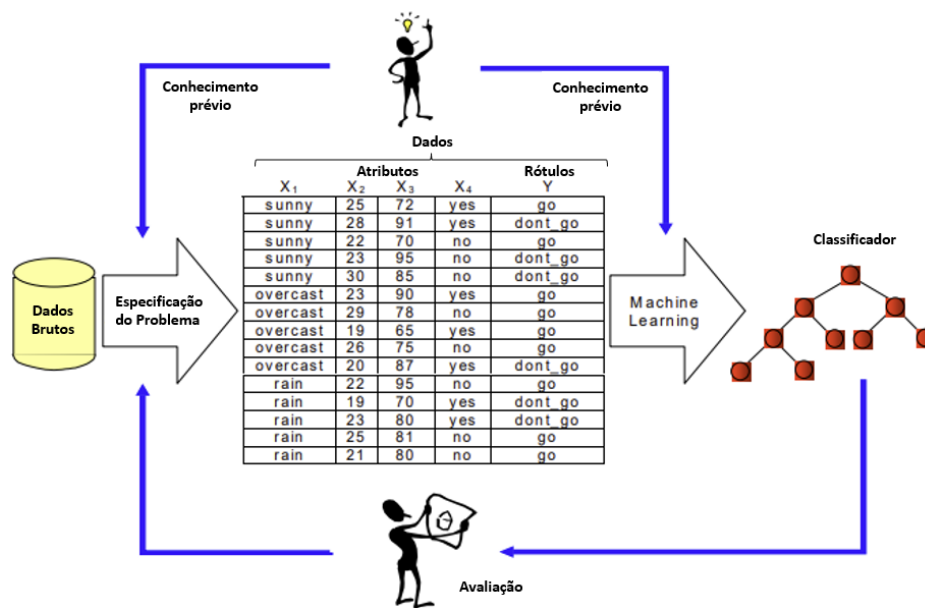


Figura 2.26 Processo de construção de um classificador (Adaptado de Baranauskas *et al.*, 2000)

Mohri *et al.* (2018) também apresentaram, através da Figura 2.27, um fluxo de trabalho típico em aprendizado de máquina supervisionado. Inicialmente, temos um conjunto de dados rotulados divididos em três partes: amostra de treino, dados de validação e amostra de teste. O algoritmo de aprendizado, denotado por  $A(\theta)$ , é aplicado à amostra de treino para aprender os parâmetros  $\theta$  do modelo. Conhecimento prévio é utilizado para determinar características relevantes e a seleção de parâmetros, o que influencia o ajuste do algoritmo. Os dados de validação são usados para ajustar os parâmetros  $A$  do modelo, refinando-o antes da avaliação final. Por fim, a amostra de teste é utilizada para avaliar a performance do modelo, oferecendo uma estimativa de como o algoritmo generalizará para dados novos e não vistos durante o treinamento.




Figura 2.27 Ilustração das etapas típicas de um processo de aprendizado (Adaptado de Mohri *et al.*, 2018)

Baranauskas *et al.* (2000) explica o funcionamento de um classificador, inicialmente definindo seu propósito: o modelo de aprendizado de máquina tem como objetivo aprender uma função  $h$  que represente uma boa aproximação da função  $f$ , que é desconhecida. Para ilustrar, considera-se um conjunto de instâncias representadas por pontos em um plano, identificados por círculos vermelhos na Figura 2.28 (a). O desafio reside em descobrir uma função  $h(X)$  que se ajuste a esses pontos. Uma abordagem inicial poderia ser a conexão direta desses pontos, criando uma linha poligonal, conforme ilustrado na Figura 2.28 (b). No entanto, essa pode ser uma simplificação excessiva da função  $f$  que se deseja aproximar. Na busca por uma representação mais acurada, pode-se optar por ajustar uma função polinomial suave, retratada em Figura 2.28 (c). No entanto, em determinados contextos, tal complexidade pode não ser desejável ou necessária, e uma função mais simples pode ser preferível. É o caso da função mostrada em Figura 2.28 (d), que propositalmente ignora um ponto, tratando-o como um *outlier* ou ruído no modelo. Essencialmente, o que se busca é um equilíbrio entre a simplicidade do modelo e sua capacidade de fazer previsões acuradas, levando em conta as particularidades dos dados e as necessidades da aplicação em questão.




Figura 2.28 Possíveis hipóteses  $h(X)$  para a aproximação da função  $f(X)$  (Baranauskas *et al.*, 2000)

Além disso, Baranauskas *et al.* (2000) apontam que é fundamental que o aprendizado de máquina consiga processar dados imperfeitos. Usualmente, as instâncias apresentam erros em suas descrições ou ausência de valores em algumas características. Esses erros podem ocasionar situações conhecidas como superajustamento (*overfitting*) e subajustamento (*underfitting*), esses são conceitos

do aprendizado de máquina que descrevem problemas de ajuste de um modelo aos dados. *Overfitting* acontece quando um modelo é tão complexo que se ajusta perfeitamente aos dados de treino, capturando ruído ou flutuações aleatórias como se fossem parte do padrão, resultando em uma performance ruim em dados não vistos, devido à sua incapacidade de generalizar. *Underfitting*, por outro lado, acontece quando um modelo é demasiado simples para captar a estrutura dos dados, resultando em um desempenho insatisfatório tanto nos dados de treino quanto nos dados de teste, por não conseguir capturar as tendências subjacentes dos dados.

A Figura 2.29 apresenta uma ilustração de como o limite de decisão de classificação e a linha de regressão seguem os dados de treinamento muito próximos no *overfitting* e não o suficiente no *underfitting*. Essas situações podem acontecer tanto em problemas de classificação quanto para regressão.

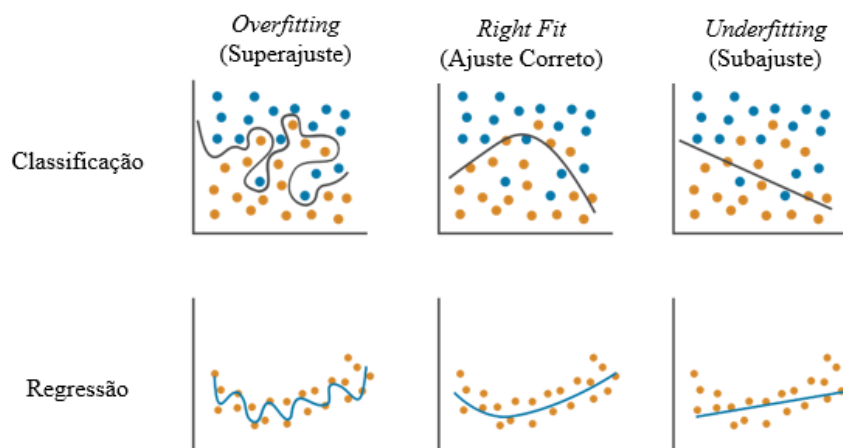


Figura 2.29 Modelos de classificação e regressão com diferentes ajustes (Adaptado de MathWorks, 2024)

Lorena e Carvalho (2007) apresentam uma exemplificação de diferentes hipóteses. A Figura 2.30 ilustra uma situação em que o objetivo do classificador é separar os dados das duas diferentes classes. Na imagem da Figura 2.30 (a), a hipótese que classifica corretamente, incluindo dois possíveis ruídos representando um caso com a ocorrência de um *overfitting* do modelo aos dados de treinamento. Enquanto na ilustração da Figura 2.30 (c) representa uma nova hipótese na condição de *underfitting*, pois o classificador não é capaz de se ajustar mesmo aos exemplos de treinamento. Na Figura 2.30 (b) um meio termo é apresentado, esse modelo tem

complexidade intermediária e classifica corretamente grande parte dos dados, sem se fixar demasiadamente em qualquer ponto individual.




Figura 2.30 Conjunto de treinamento e três hipóteses diferentes (Lorena e Carvalho, 2007)

Scikit-Learn (2024) afirma que frequentemente, o aspecto mais desafiador na resolução de problemas de aprendizado de máquina reside na seleção do estimador (modelo) mais adequado para a tarefa em questão. Estimadores distintos são mais apropriados para diferentes modalidades de dados e variados problemas analíticos. Este item será abordado no item 2.3.3.1.

### 2.3.1. Aplicações em Geotecnia

De acordo com Dramsch (2020), as geociências acompanharam de perto o desenvolvimento do aprendizado de máquina. Duas das aplicações de *machine learning* em geociências citadas pelo autor é a obtenção da granulometria através de imagens de Microscópio de Eletrônico de Varredura (MEV) e a previsão da magnitude de terremotos.

O acesso mais facilitado às ferramentas, conhecimento e computação das décadas recentes contribuíram com o aumento da aplicação dos algoritmos de aprendizado de máquina nas geociências. A Figura 2.31 apresenta trabalhos que aplicaram algoritmos de *machine learning* em diversos graus nas pesquisas em geociências ao longo dos anos, nela é possível ver um aumento significativo de publicações a partir de 2010. A bibliometria foi realizada com 242 artigos, considerando termos de pesquisa incluindo variações de termos de aprendizado de máquina e subdisciplinas geocientíficas (Dramsch, 2020).




Figura 2.31 Gráfico de quantidade *papers* com *machine learning* aplicado a geociências ao longo dos anos (Adaptado de Dramschi, 2020)

Zhang *et al.* (2022) apresentou trabalhos de pesquisa relativos à aplicação de *machine learning* na previsão das propriedades do solo, selecionando os mais conhecidos nas categorias de engenharia e geologia, conforme Figura 2.32. O autor destaca o crescimento exponencial que pode ser visto a partir do ano de 2018, que, de acordo com ele, está associado ao florescimento do *machine learning*. A linha vermelha representa o número acumulado de referências, destacando a crescente relevância da aprendizagem de máquina na análise de solo e suas aplicações nas disciplinas listadas, sugerindo um interesse crescente e uma possível expansão da aplicabilidade do *machine learning* nesses campos ao longo da última década.




Figura 2.32 Número de publicações relacionadas ao desenvolvimento e aplicação de algoritmos de *machine learning* para previsão de propriedades do solo (Adaptado de Zhang *et al.*, 2022)

As técnicas de aprendizado de máquina têm encontrado uma variedade de aplicações na modelagem das propriedades do solo, conforme Zhang *et al.* (2022) aponta em seu trabalho, algumas das técnicas e trabalhos de *machine learning* e suas aplicações são listadas a seguir:

- *Genetic programming* (GP) é aplicada para avaliar a sucção do solo (Cheng *et al.*, 2020).
- A *Support Vector Machine* (SVM), mais especificamente a sua variante *Support Vector Regression* (SVR), é utilizada análises de previsão de deslocamento de deslizamento hidrodinâmico (Wang *et al.*, 2020).
- Algoritmos baseados em árvores de decisão, como as *Decision Trees* (DT) e *Random Forests* (RF), são empregados para modelar a erosão do solo (Ai *et al.*, 2013) e a previsão do comportamento de *creep*, respectivamente, fornecendo estruturas semelhantes a fluxogramas e algoritmos de conjunto para tais fenômenos complexos (Zhang *et al.*, 2020 *apud* Zhang *et al.*, 2022).
- Kanungo *et al.* (2014) utilizou Rede Neural Artificial (RNA) e Árvore de Regressão (CART) para estimativa de parâmetros de resistência ao cisalhamento de solos não saturados.
- Por fim, as técnicas Bayesianas, como as *Bayesian Neural Networks* (BNN), são úteis para lidar com incertezas em problemas de geotecnia, como nas análises da resistência lateral não drenada de eixos perfurados em túneis (Goh *et al.*, 2005).

Zhang *et al.* (2021) apresentaram em seu trabalho uma pesquisa com 158 artigos relacionados com geotecnia que utilizaram algoritmos de *deep learning*, disciplina específica dentro do *machine learning*. Pode-se verificar, a partir da Figura 2.33, que a aplicação do *deep learning* na engenharia geotécnica foi extremamente limitada na primeira década do século XXI, enquanto o número de publicações aumentou acentuadamente na última década. Os autores pontuam que os dados de 2020 são parciais pois alguns artigos ainda estavam em processamento durante seu trabalho.






Figura 2.33 Artigos de periódicos publicados com foco na aplicação de *deep learning* na engenharia geotécnica ao longo dos anos (Adaptado de *Web of Science*, 2020 *apud* Zhang *et al.*, 2021)

Os métodos de *Deep Learning* têm revelado um amplo espectro de aplicações na engenharia geotécnica, algumas aplicações são apresentadas:

- A *Artificial Neural Network* (ANN) tem sido utilizada para avaliar a liquefação de solos arenosos com ensaios cíclicos (Baziar e Jafarian, 2007) e para previsão da tensão de *swelling* de solos, a partir de dados de ensaios de laboratório (Ikizler *et al.*, 2014);
- Outro exemplo é a aplicação de ANN na previsão de recalque de estacas, onde mais de mil casos foram analisados para melhorar a precisão das previsões de recalque (Nejad *et al.*, 2009);
- Já a *Long Short-Term Memory* (LSTM), uma variação de redes neurais recorrentes, tem sido empregada em projetos de túneis e para a previsão da taxa de penetração de *Tunnel Boring Machines* (TBM), oferecendo um modelo robusto para a simulação em tempo real e monitoramento de parâmetros operacionais de TBMs (Gao *et al.*, 2020a *apud* Zhang *et al.*, 2021);
- Uma aplicação da *Convolutional Neural Network* (CNN) que pode ser citada é a estimativa de velocidades das ondas P (primárias) e S (secundárias) a partir de imagens de rochas (Karimpouli e Tahmasebi, 2019).

Na literatura acadêmica brasileira existem contribuições no campo da engenharia geotécnica com uso de técnicas de *machine learning* e *deep learning*. Algumas delas são citadas a seguir.

- Oliveira *et al.* (2019) focou na aplicação de algoritmos de *machine learning*, especificamente *random forest*, para estimar o coeficiente de mola de estacas. Este trabalho utilizou um banco de dados que incluía informações de ensaios SPT e provas de carga estáticas.
- Outro trabalho é o de Araújo (2015), que empregou Redes Neurais Artificiais do tipo *perceptron* para estimar recalques em estacas. Este trabalho ilustra a eficácia das RNA na previsão de comportamentos geotécnicos complexos, contribuindo significativamente para o planejamento e projeto de fundações.
- O estudo de Dias (2023) apresenta uma abordagem da análise de susceptibilidade à liquefação dinâmica, utilizando técnicas estatísticas multivariadas, especificamente a Regressão Logística. Este trabalho baseou-se em um banco de dados de CPT e SPT da literatura.
- Barros (2020) utilizou de RNA no contexto de previsão de fenômenos de *piping* em barragens de terra homogêneas. Este estudo aproveitou dados de pesquisas anteriores para treinar o modelo de RNA;
- Silva (2020) apresentou um modelo de estimativa da condutividade hidráulica em solos não saturados, com 275 exemplos, a partir de um tipo de RNA conhecido como *perceptron* multicamadas.

Carvalho *et al.* (2022) direcionaram os estudos para a aplicação de inteligência artificial, incluindo *machine learning* e *deep learning*, especificamente para a estimativa dos parâmetros de resistência ao cisalhamento dos solos. A pesquisa foi feita por meio do acesso ao Portal Periódicos CAPES, onde os autores analisaram 18 artigos científicos do período de 2008 a 2018, conforme pode ser visto na Figura 2.34. Nestes trabalhos, foram identificadas a aplicação de 17 técnicas distintas de inteligência artificial.




Figura 2.34 Quantidade de artigos com aplicação de inteligência artificial para a estimativa da resistência ao cisalhamento dos solos (Adaptado de Carvalho *et al.*, 2022)

Entre os trabalhos referenciados por Carvalho *et al.* (2022), destacam-se diversas aplicações inovadoras de métodos de inteligência artificial na geotecnia.

- Utilização de *Artificial Neural Network* (ANN) na previsão do ângulo de atrito ( $\phi$ ). Este estudo analisou 54 conjuntos de dados extraídos da literatura, com ensaios de *Ring Shear* (Das e Bashudhar, 2008 *apud* Carvalho *et al.*, 2022);
- Técnicas de *Probabilistic Neural Network* (PNN) foram empregadas na estimativa da coesão ( $c$ ) e do ângulo de atrito ( $\phi$ ). Este trabalho se baseou a partir de 300 amostras de areia siltosa, submetidos a ensaios triaxiais do tipo UU (não adensado e não drenado) (Kiran, *et al.*, 2016).
- Outra aplicação notável envolve o uso de Programação Genética Linear (*Linear Genetic Programming* - LGP) em um conjunto de 88 amostras, visando a previsão de  $c$  e  $\phi$  com base em ensaios triaxiais do tipo UU (Mousavi *et al.*, 2011).

Estes exemplos destacam o potencial de integração entre a ciência de dados e geotecnia para resolver problemas complexos e variados. A sofisticação dos métodos de inteligência artificial permite não apenas avaliar, mas também otimizar as condições de desempenho e fazer previsões. As publicações associadas a esses estudos ilustram a diversidade e a profundidade com que as técnicas de aprendizado estão sendo integradas à pesquisa geotécnica, abrindo novos caminhos para análises preditivas e avaliações de risco mais precisas em projetos de engenharia geotécnica.

A obtenção de conjuntos de dados abrangentes e detalhados é um desafio reconhecido na aplicação de Inteligência Artificial (IA) em geotecnia, uma vez que

a realização de ensaios geotécnicos, essenciais para coletar essas informações, envolve processos complexos e onerosos. Muitas vezes, os dados resultantes desses ensaios são retidos por empresas privadas, que por razões de confidencialidade ou direitos proprietários, não permitem sua ampla divulgação ou uso em pesquisas. Apesar desses obstáculos, diversos autores têm demonstrado sucesso na implementação de modelos de IA com volumes variáveis de dados, como Carvalho *et al.* (2022) mostrou em seu estudo, onde o número de amostras utilizadas por diversos autores variou de 54 a 332. Esses modelos foram capazes de fornecer *insights* valiosos e previsões confiáveis, evidenciando a adaptabilidade e a eficiência do *machine learning* mesmo quando confrontado com limitações no tamanho dos *datasets*. Esta flexibilidade é especialmente valiosa na engenharia geotécnica, onde a qualidade e a especificidade dos dados são muitas vezes mais críticas do que a quantidade absoluta de dados disponíveis.

### **2.3.2. Algoritmos**

Esta seção detalha alguns algoritmos incluindo Árvore de Decisão (DT), Floresta Aleatória (do inglês *Random Forest* - RF), Regressão Vetorial de Suporte (*Support Vector Regression* - SVR) e Redes Neurais Artificiais (RNA). Cada algoritmo possui características distintas e é otimizado para tipos específicos de dados e problemas.

#### **2.3.2.1. Decision Tree (DT)**

Árvores de decisão (*Decision Trees* – DT) são fundamentadas na estratificação ou segmentação dos dados de previsão em regiões mais simples. Para a previsão utiliza-se a média ou a moda das respostas das observações de treinamento na mesma região. Esses métodos, que são estruturados em forma de árvore, são valorizados pela sua simplicidade e facilidade de interpretação, embora, conforme apontado por James *et al.* (2023), possam não ser tão acurados quanto outras técnicas de aprendizado supervisionado.

As metodologias envolvidas na construção de árvores de decisão incluem a geração de múltiplas árvores, cujos resultados são posteriormente combinados para

formar uma previsão de consenso. Este processo de combinação de múltiplas árvores pode frequentemente resultar em uma melhoria significativa na precisão da previsão, embora possa implicar em uma diminuição na capacidade de interpretação.

O processo de construção de uma árvore de decisão para regressão pode ser descrito em duas etapas fundamentais:

1. A divisão do espaço correspondentes o conjunto de valores possíveis para  $X_1, X_2, \dots, X_p$ , em  $J$  regiões distintas e não sobrepostas,  $R_1, R_2, \dots, R_J$ .
2. A aplicação de uma previsão uniforme para cada observação que se enquadre na região  $R_J$ , baseada na média dos valores de resposta das observações de treinamento presentes em  $R_J$ .

Para melhor ilustrar, James *et al.* (2023) apresentaram a Figura 2.35. Na Figura 2.35 (a), observa-se uma representação esquemática de uma árvore de decisão, onde cada nó interno (indicado pelas divisões com  $X_j \leq t_k$ ) representa um ponto de decisão baseado em um valor de corte específico, que bifurca os dados em subconjuntos mais homogêneos. As folhas da árvore, ou nós terminais ( $R_1, R_2, \dots, R_5$ ), representam as regiões no espaço dos preditores dentro das quais as previsões são feitas com base na média dos valores de resposta das observações de treinamento. A Figura 2.35 (b) fornece uma visualização tridimensional demonstrando como o espaço é separado em regiões distintas (cada cor representa uma região diferente). Por fim, a Figura 2.35 (c) é um diagrama bidimensional do espaço do preditor.

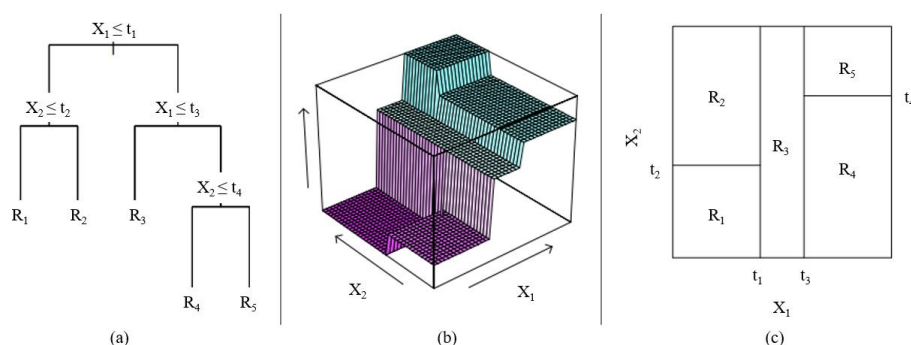


Figura 2.35 Esquema árvore de decisão de regressão. (a) Representação esquemática da DT; (b) Visualização 3D referente à saída correspondente e (c) Diagrama do espaço do preditor. (Adaptado de James *et al.*, 2023)

A ideia do aprendizado conjunto é selecionar uma coleção, ou conjunto (*ensemble*), de hipóteses e combinar suas previsões por meio de média, votação ou outro nível de aprendizado de máquina (Russell e Norvig, 2020).

O método de Florestas Aleatórias (*Random Forest*) é um dos que utiliza a técnica do aprendizado em conjunto. Para entender melhor esse algoritmo é necessário entender *bootstrap* e *bagging* que será abordado a seguir.

O *bootstrap* é uma ferramenta estatística que pode ser usada para quantificar a incerteza associada a um determinado estimador ou método de aprendizagem. O poder do *bootstrap* reside no fato ser facilmente aplicado em vários métodos de aprendizagem, incluindo alguns para os quais uma medida de variabilidade é difícil de obter e não é automaticamente produzida por *software* estatístico, conforme pontuado por James *et al.* (2023). Quando utilizado em conjunto com técnicas como árvore de decisão, ele pode ajudar a criar modelos mais robustos e menos propensos ao sobreajuste (*overfit*), pois cada árvore é construída a partir de uma amostra ligeiramente diferente dos dados.

A Figura 2.36 apresenta uma ilustração gráfica que ajuda a entender essa técnica. Considera um banco de dados original ( $Z$ ) em que existem 3 observações (Obs 1, 2 e 3), cada uma com seus valores correspondentes de  $X$  e  $Y$ . A técnica de *bootstrap* consiste em criar múltiplos conjuntos de dados de amostras ( $Z^{*1}, Z^{*2}, \dots, Z^{*B}$ ) a partir do conjunto de dados original ( $Z$ ), onde  $B$  é o número total de amostras *bootstrap* criadas. Cada conjunto de dados de amostra é construído através da seleção aleatória de observações do conjunto original com reposição. A partir disso, para cada amostra *bootstrap*, uma árvore de decisão é ajustada e uma estimativa para um parâmetro de interesse ( $\alpha$ ) é calculada. Ao final do processo, tem-se várias estimativas de  $\hat{\alpha}^{*1}, \hat{\alpha}^{*2}, \dots, \hat{\alpha}^{*B}$ . Uma média ou moda dessas estimativas pode ser usada para obter uma estimativa final mais estável e precisa para  $\alpha$ .

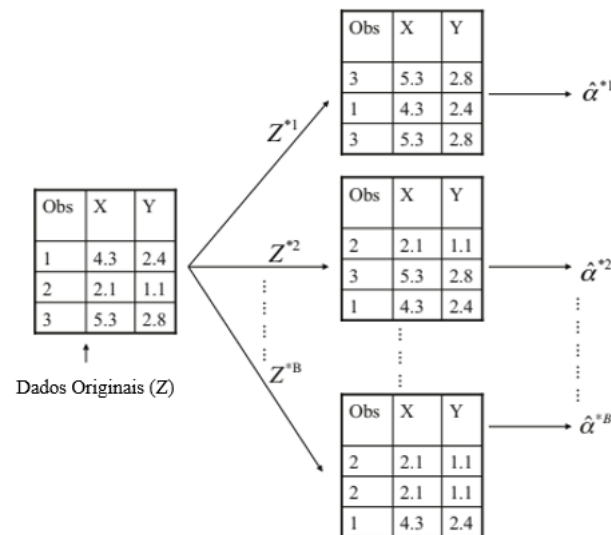


Figura 2.36 Ilustração gráfica da técnica de *bootstrap* (Adaptado de James *et al.*, 2023)

A técnica de *bagging* (*bootstrap aggregating*), consiste em extrair amostras de *bootstrap* (amostras aleatórias com substituição) do conjunto de treinamento inicial, razão pela qual o *bagging* também é conhecido como agregação de *bootstrap* (Raschka e Mirjalili, 2017).

O diagrama apresentado por Raschka e Mirjalili (2017) (Figura 2.37) fornece uma representação visual do processo de *bagging*. Inicialmente, múltiplas amostras de *bootstrap* ( $T_1, T_2, \dots, T_m$ ) são geradas a partir do conjunto de treinamento original. Os modelos de classificação ( $C_1, C_2, \dots, C_m$ ) são então treinados de forma independente. Cada modelo é capaz de gerar uma previsão ( $P_1, P_2, \dots, P_m$ ) para novos dados. Estas previsões individuais são então combinadas através de um processo de votação, que para problemas de classificação, é tipicamente um voto de maioria, onde a classe que recebe o maior número de votos é escolhida como a previsão final. No contexto da regressão, a combinação das previsões é frequentemente a média dos valores previstos. A previsão final  $P_x$  é obtida após a agregação das previsões de todos os modelos individuais, fornecendo assim uma saída única que é geralmente mais robusta do que as previsões dos modelos individuais.

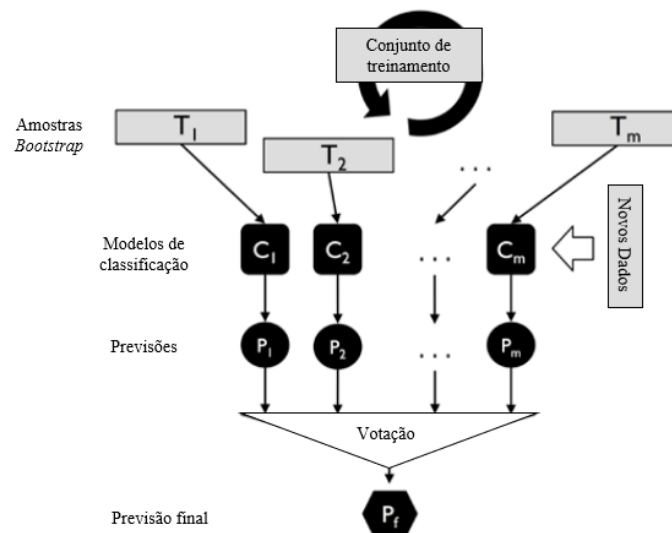


Figura 2.37 Ilustração gráfica da técnica de *bagging* (Adaptado de Raschka e Mirjalili, 2017)

### 2.3.2.2. **Random Forest (RF)**

Breiman (2001) define uma floresta aleatória (do inglês *Random Forest* - RF) como um classificador com uma coleção de classificadores estruturados em árvore  $\{h(x, k), k = 1, \dots\}$  onde  $\{k\}$  representa os vetores aleatórios independentes e distribuídos de forma idêntica e cada árvore dá um voto unitário para a classe mais popular na entrada  $x$ , no caso de um problema de classificação.

De forma mais abrangente, Zhang *et al.* (2022) diz que o modelo de RF consiste na construção de um "comitê" de Árvores de Decisão (DTs), cada um operando como um modelo preditivo autônomo e contribuindo individualmente para a decisão coletiva. O veredito do algoritmo, no caso de regressão, é determinado pela média das previsões de todas as árvores que compõem a floresta.

O diagrama da Figura 2.38 fornece uma representação visual do processo de criação de uma Floresta Aleatória (*Random Forest*). A 'Base de Treino' constitui o ponto de partida, onde múltiplos subconjuntos de dados são gerados. Para cada subconjunto aleatório de dados, uma árvore de decisão individual é treinada. A fase final do processo consiste na 'Agregação dos Resultados' das previsões de cada árvore individual, tipicamente por meio de voto majoritário para classificação ou média para regressão, para produzir uma 'Predição Final'.



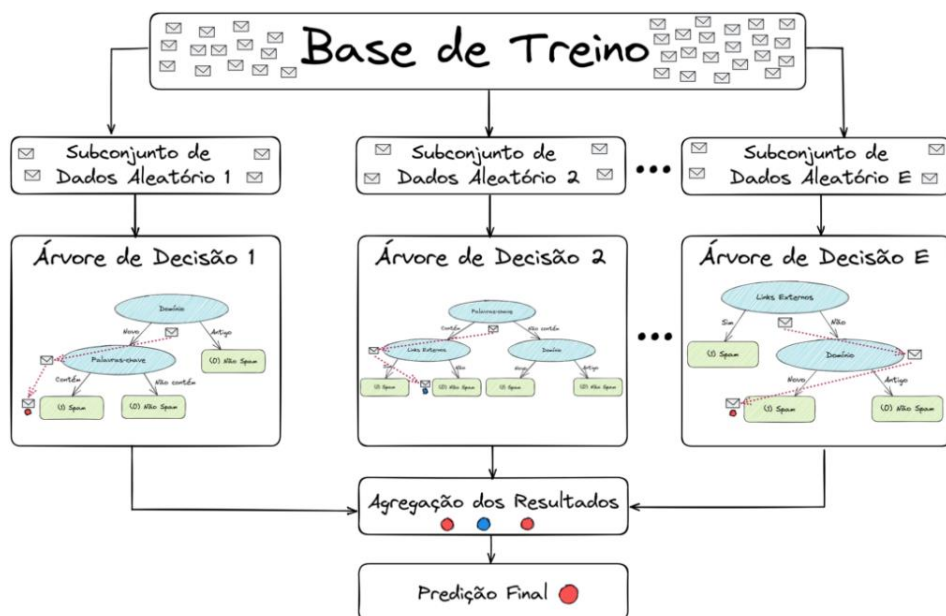


Figura 2.38 Processo de criação de *Random Forests* (Brains, 2023)

Conforme mencionado por Raschka e Mirjalili (2017), ao longo da última década, a metodologia das *Random Forests* consolidou-se como uma abordagem de destaque no domínio do aprendizado de máquina, reconhecida por sua eficácia classificatória, escalabilidade e simplicidade operacional. Os autores elencam quatro etapas importantes na construção e entendimento do algoritmo:

1. Selecionar aleatoriamente uma amostra de *bootstrap* de tamanho  $N$  (escolhendo aleatoriamente  $N$  amostras do conjunto de treinamento, com reposição).
2. Construir uma árvore de decisão fundamentada na amostra de *bootstrap* obtida. Para cada nó da árvore:
  - a. Efetuar a seleção aleatória de  $D$  atributos, sem reposição.
  - b. Dividir o nó utilizando a característica que oferece a melhor divisão segundo a função objetivo, por exemplo, maximizando o ganho de informação.
3. Replicar as etapas anteriores 1 e 2,  $k$  vezes.
4. Agregar as previsões de cada árvore para atribuir a etiqueta de classe através do voto majoritário no caso de classificação, ou de média, no caso de regressão.

Zhang *et al.* (2022) cita dois hiperparâmetros que se sobressaem em termos de importância quando uma RF é configurada, conforme pode ser visto na eq. (17):

o número de DTs, conhecido como 'ntree', e o número de atributos avaliados em cada divisão de um nó, denominado 'mtry'. Esses parâmetros são cruciais pois definem a estrutura e a capacidade preditiva do modelo. Para formar as DTs, emprega-se o método de *bagging* (*bootstrap aggregating*), que consiste em criar múltiplos conjuntos de dados de treinamento por meio de amostragem com substituição, ou seja, sorteando aleatoriamente e com a possibilidade de repetição, discutido anteriormente. De forma geral, cada conjunto de treinamento gerado pelo *bagging* inclui dois terços dos dados originais, deixando o terço restante, conhecido como "out of the bag", para ser usado como uma forma de teste interno da árvore, avaliando seu erro e performance preditiva.

$$y = \frac{1}{ntree} \sum_{i=1}^{ntree} y_i(X) \quad (17)$$

James et al. (2023) explicam que o método *random forest* aprimora a estratégia de *bagging* ao introduzir um elemento adicional de aleatoriedade no processo de seleção de características para as divisões em cada nó das árvores. Ao invés de considerar todas as características disponíveis para a divisão em um dado nó, um subconjunto aleatório de características é selecionado, o que promove a construção de árvores descorrelacionadas.

### 2.3.2.3.

#### **Support Vector Regression (SVR)**

As Máquinas de Vetores de Suporte, do inglês *Support Vector Machine* - SVMs, são embasadas pela teoria de aprendizado estatístico (TAE). Essa teoria estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com boa generalização, definida como a sua capacidade de prever corretamente a classe de novos dados do mesmo domínio em que o aprendizado ocorreu (Lorena e Carvalho, 2007).

As SVMs, quando aplicadas à problemas de regressão é conhecida como Regressão de Vetores de Suporte (SVR, do inglês *Support Vector Regression*). O método é fundamentado no princípio da minimização do risco estrutural. Esta técnica é particularmente útil quando nos deparamos com conjuntos de dados que não são linearmente separáveis no espaço original, de dimensão mais baixa. O SVR

supera essa limitação aplicando uma função de *kernel*, que projeta os dados para um espaço de maior dimensão. Neste espaço ampliado, torna-se viável encontrar um hiperplano que consiga separar eficazmente os conjuntos de dados, ou seja, um hiperplano que maximize a margem entre as categorias de dados que se deseja discriminar (Zhang *et al.*, 2022):

A Figura 2.39 apresenta uma representação do modelo e seus elementos. O SVR trabalha a partir da minimização do erro, maximizando a margem e considerando a flexibilidade através das variáveis de folga ( $\xi$ ), que permitem erros dentro de um certo limiar ( $\epsilon$ ). Os vetores de suporte são os pontos de dados mais próximos do hiperplano e têm uma função importante na definição da margem, que é a distância entre o hiperplano e esses pontos mais próximos.




Figura 2.39 Representação esquemática do modelo SVR (Adaptado de Scholkopf e Smola, 2002 *apud* Smola e Scholkopf, 2004)

No treinamento do SVR, o objetivo é descobrir um hiperplano que não apenas separe todos os conjuntos de dados, mas que também mantenha a maior "folga" ou margem possível entre as diferentes categorias, matematicamente ele pode ser expresso pela eq. (18) (Zhang *et al.*, 2022).

$$\min_{\xi, w, b} \frac{1}{2} \|W\|^2 + C \sum_{i=1}^m \xi_i \quad (18)$$

$$\text{s.a. } y_i(W^T \phi(X) + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, m, \quad \xi_i \geq 0$$

Onde  $m$  é um total de conjuntos de dados;

$\xi$  é o parâmetro de folga, ou margem, indicando o erro permitido;

$C$  é a regularização do parâmetro para impor uma penalidade em caso de erro.

Um exemplo de função *kernel* comumente utilizada na base, segundo Zhang et al. (2022), é apresentada na eq. (19), onde  $\gamma_{kernel}$  é o coeficiente *kernel*.

$$\phi(x_i, x_j) = \exp\left(-\gamma_{kernel} \|x_i - x_j\|^2\right) \quad (19)$$

Smola e Scholkopf (2004) apresentam, na Figura 2.40, uma visão geral gráfica das etapas do algoritmo SV da fase de regressão. O padrão de entrada (para o qual uma previsão deve ser feita) é mapeado no espaço de recursos por um mapa ( $\Phi$ ). Os produtos escalares são calculados e correspondem ao *kernel*  $k(x_i, x)$ . Finalmente, os produtos escalares são somados usando os pesos  $v_i = \alpha_i - \alpha_i^*$ . Esse termo somado à constante  $b$ , produz o resultado da previsão. Esta saída representa a previsão do modelo para um novo vetor de teste.

O processo descrito é muito semelhante à regressão em uma rede neural, com a diferença de que no caso SV os pesos na camada de entrada são um subconjunto dos padrões de treinamento (Smola e Scholkopf, 2004).




Figura 2.40 Arquitetura da máquina de regressão construída pelo algoritmo de SV

(Adaptado de Smola e Scholkopf, 2004)

Os resultados da aplicação do SVM exibem desempenho notavelmente competitivo, frequentemente excedendo o de outras metodologias consagradas em aprendizado de máquina, como as Redes Neurais Artificiais (RNAs) (Braga, 2000 e Haykin, 1999 *apud* Lorena e Carvalho, 2007)

Em geral, conforme citado por Mammone *et al.* (2009), devido à complexidade intrínseca dos problemas do mundo real, um espaço de hipóteses mais abrangente e representativo é essencial, ultrapassando a simplicidade das funções lineares. Assim, torna-se necessário incorporar funções mais sofisticadas para uma modelagem eficaz dos dados reais.

A Figura 2.41 (a) do Russell e Norvig (2020) mostra um exemplo de um espaço de entrada definido por atributos com exemplos positivos ( $y = +1$ ) dentro de uma região circular e exemplos negativos ( $y = -1$ ) do lado de fora. Apenas com essa imagem pode-se supor que não há um separador linear para este problema. Agora, reconsiderando os dados de entrada, ou seja, mapeando cada vetor de entrada ( $x$ ) para um novo vetor de valores de atributos,  $f(x)$ . Em particular, serão utilizadas três características expressas na eq. (22). Com isso, a verdadeira fronteira de decisão,  $\frac{x_1^2}{2} + x_2^2 \leq 1$ , é encontrada. Na Figura 2.41 (b) os mesmos dados são mostrados após o mapeamento em um espaço de entrada tridimensional  $(x_1^2, x_2^2, \sqrt{2}x_1x_2)$ . A fronteira de decisão circular em Figura 2.41 (a) torna-se uma fronteira de decisão linear quando vista em três dimensões em Figura 2.41 (b).

$$f_1 = x_1^2, f_2 = x_2^2, f_3 = \sqrt{2}x_1x_2. \quad (20)$$

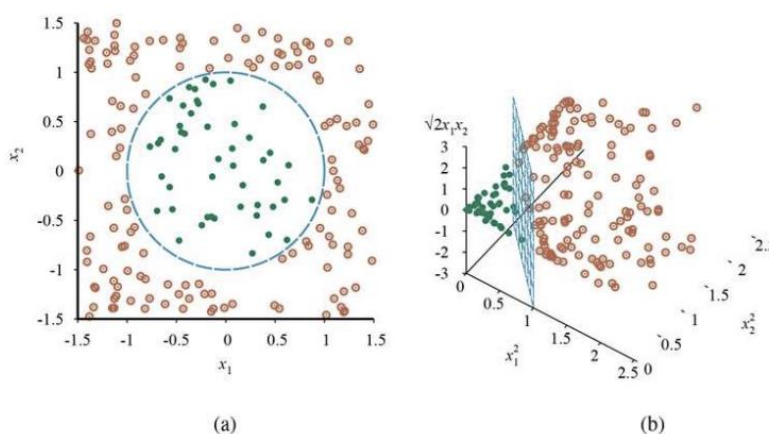


Figura 2.41 Exemplo de um caso não linearmente separável na dimensão dos dados iniciais (Russell e Norvig, 2020)

#### 2.3.2.4. Rede Neural Artificial (RNA)

Anthony e Bartlett (2009) afirmam que as redes neurais artificiais se tornaram populares na última década para diversas aplicações, desde previsão financeira até mecânica.

Os métodos de aprendizado de rede neural fornecem uma abordagem robusta para aproximar funções-alvo de valor real, discreto e vetorial. Essas redes demonstram uma eficácia notável, particularmente em tipos de problemas que envolvem a interpretação de dados sensoriais complexos oriundos do ambiente real. Atualmente, as redes neurais artificiais (RNAs) são reconhecidas entre as estratégias mais eficientes de aprendizado para tais contextos. O estudo das RNAs abrange uma motivação biológica inspirada pela observação de que sistemas de aprendizado biológicos são compostos por redes altamente complexa e interconectadas. Em uma analogia simplificada, redes neurais artificiais são construídas a partir de uma série de unidades simples interconectadas, onde cada unidade processa um número de entradas de valor real e produz uma única saída de valor real (Mitchell, 1997).

Fielding (1999) apresentou a Figura 2.42 (a) que ilustra uma comparação entre um neurônio biológico e sua representação simplificada em uma rede neural artificial (RNA). A representação esquemática da Figura 2.42 (b) demonstra um modelo de neurônio artificial. Os sinais de entrada ( $I_1, I_2,$ ) são análogos aos estímulos recebidos pelos dendritos em um neurônio biológico. Cada sinal de entrada é multiplicado por um peso sináptico  $w_{ij}$ , que é equivalente à força da sinapse em um neurônio biológico. Estes produtos são somados em um acumulador (indicado pelo símbolo  $\Sigma$ ), que corresponde à integração dos sinais de entrada em um neurônio biológico. A função de transferência, também conhecida como função de ativação, processa a soma ponderada dos sinais de entrada. Esta função determina o nível de ativação do neurônio artificial, similar ao processo que determina se um neurônio biológico vai disparar um impulso elétrico através do axônio. Finalmente, o resultado da função de transferência é transmitido como saída para outros nós da rede, imitando a propagação do sinal para outros neurônios através das sinapses. Russell e Norvig (2020) diferenciam as redes neurais de outros

métodos pela capacidade de interação entre as camadas, coisa que um modelo linear e um modelo de decisão não proporciona.




Figura 2.42 (a) Diagrama do neurônio biológico e (b) esquema de um nó na RNA  
 (Adaptado de Fielding, 1999)

Os principais tipos de redes neurais são Rede Neural *Feedforward* (*Feedforward Neural Networks* – FNN), Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNN) e Redes Neurais Recorrentes (*Recurrent Neural Networks* – RNN) (Russell e Norvig, 2020). James *et al.* (2023) complementam que as CNN são especializadas em classificação de imagens e RNN são utilizadas para problemas relacionados a séries temporais e outras sequências.

Russell e Norvig (2020) definem uma rede do tipo *feedforward* como uma rede que possui conexões apenas em uma direção. Em que cada nó calcula uma função de suas entradas e passa o resultado para seus sucessores na rede. As informações fluem pela rede dos nós de entrada para os nós de saída e não há laços (*loops*). Esse tipo de rede pode ser, segundo James *et al.* (2023), composta de apenas uma camada ou multicamadas, como exemplo da Figura 2.43.

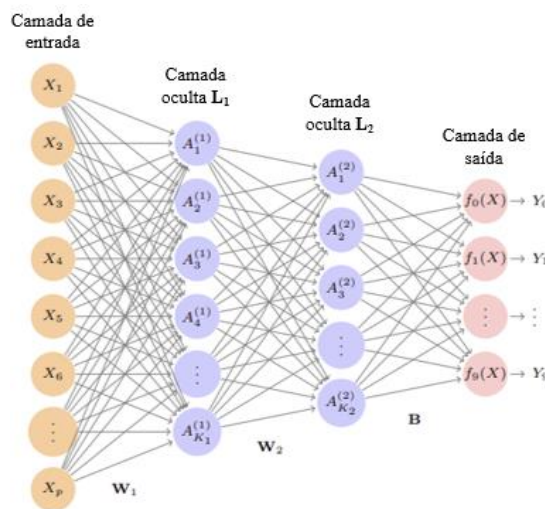


Figura 2.43 Diagrama de uma rede neural com duas camadas ocultas e múltiplas saídas  
(Adaptado de James *et al.*, 2023)

Uma rede recorrente (RNN), diferente da FNN, realimenta seus resultados intermediários ou finais em seus próprios insumos. Sendo assim, os valores dentro da rede formam um sistema dinâmico que possui estado interno ou memória. (Russell e Norvig, 2020). De acordo com o James *et al.* (2023), os dados de entrada da RNN são sequências, e os dados de saída podem ser sequenciais, como no caso de uma tradução de idioma, ou podem ser um dado escalar. A Figura 2.44 ilustra a arquitetura desse tipo de rede.




Figura 2.44 Esquema de uma rede neural recorrente simples (James *et al.*, 2023)

Segundo Russell e Norvig (2020), uma rede neural convolucional (CNN) é aquela que contém conexões espacialmente locais e possui padrões de pesos que são replicados nas unidades de cada camada. Um padrão de pesos que é replicado em múltiplas regiões locais é chamado de *kernel* e o processo de aplicação do *kernel* aos *pixels* da imagem (ou a unidades organizadas espacialmente em uma camada subsequente) é chamado de *convolução*. James *et al.* (2023) utiliza a Figura 2.45



para ilustrar a ideia por trás de uma rede neural convolucional em uma imagem de desenho animado de um tigre. A rede identifica características de baixo nível na imagem. Esses recursos são então combinados para formar recursos de nível superior. Com isso, a presença ou ausência destas características de nível superior contribui para a probabilidade de qualquer classe de saída.




Figura 2.45 Esquema mostrando como a CNN classifica a imagem (Adaptado de James *et al.*, 2023)

*Feedforward Neural Network* (FNN) é o algoritmo de ML mais comumente utilizado segundo Zhang *et al.* (2022), além de ser um dos modelos mais simples consistindo em camadas de entrada, ocultas e de saída e este será o modelo utilizado na presente pesquisa.

No modelo FNN, os dados de entrada fluem da camada de entrada para a camada de saída e o erro é propagado da camada de saída para atualizar todos os pesos e vieses até que a diferença entre os resultados previstos e reais seja minimizada (Rumelhart *et al.*, 1986).

Uma rede neural recebe um vetor de entrada de  $p$  variáveis  $X_1, X_2, \dots, X_p$  e constrói uma função não linear  $f(X)$  para prever a resposta  $Y$ . Para explicar melhor as equações matemáticas envolvidas, será utilizado o exemplo da Figura 2.46. Essa figura mostra uma rede neural *feedforward* para modelar uma resposta quantitativa usando  $p = 4$  preditores.




Figura 2.46 Exemplo de rede FNN com uma camada oculta (Adaptado de James *et al.*, 2023)

Na terminologia de redes neurais, os quatro recursos, ou *features*,  $(X_1, \dots, X_4)$  compõem as unidades na camada de entrada. As setas indicam que cada uma das entradas da camada de entrada leva a cada uma das  $K$  unidades ocultas (o valor de  $K$  é escolhido e neste exemplo vale 5). O modelo de rede neural tem o formado da eq. (21).

$$f(X) = \beta_0 + \sum_{k=1}^K \beta_k h_k(X) = \beta_0 + \sum_{k=1}^K \beta_k g \left( W_{k0} + \sum_{j=1}^p W_{kj} X_j \right) \quad (21)$$

A construção é feita em duas etapas. Primeiro, as  $K$  ativações  $A_k$  (eq. (22)),  $k = 1, \dots, K$ , na camada oculta são computadas como funções das características de entrada  $(X_1, \dots, X_p)$ .

$$A_k = h_k(X) = g \left( W_{k0} + \sum_{j=1}^p W_{kj} X_j \right). \quad (22)$$

Onde  $g(z)$  é uma função de ativação não linear, dois exemplos de função de ativação são apresentados na Figura 2.47. De acordo com James *et al.* (2023), a função de ativação chamada ‘sigmoid’ era bastante utilizada nas primeiras redes neurais, no entanto a escolha preferida em redes neurais modernas é a função de ativação ‘ReLU’ (unidade linear retificada).




Figura 2.47 Gráficos e equações das funções de ativação sigmoid e ReLU (Adaptado de James et al., 2023)

Pode-se pensar em  $A_k$  como uma transformação das variáveis de entrada original  $h_k(X)$ . Essas  $K$  ativações da camada oculta então alimentam a camada de saída, resultando na eq. (23).

$$f(X) = \beta_0 + \sum_{k=1}^K \beta_k A_k, \quad (23)$$

Ou seja, um modelo de regressão linear nas  $K = 5$  ativações. Todos os parâmetros de viéses do modelo  $\beta_0, \dots, \beta_k$  e os respectivos pesos  $W_{10}, \dots, W_{Kp}$  precisam ser estimados pelo modelo, a partir do treinamento dos dados.

De forma resumida, o modelo descrito na Figura 2.46 consegue fazer previsões de novas características ao computar cinco funções de ativação diferentes a partir dos dados de entrada  $X$ , e então as aplica em cada uma através de uma função de ativação  $g(\cdot)$  para transformá-la. O modelo final é então transformado em previsões. A não linearidade na função de ativação  $g(\cdot)$  é essencial, já que sem ela o modelo  $f(X)$  se reduziria a um modelo linear simples  $X_1, \dots, X_p$ . Além disso, ter uma função de ativação não linear permite que o modelo capture não linearidades complexas e efeitos de interação (James *et al.*, 2023).

### 2.3.3. Fases de um projeto de *machine learning*

Esta seção está separada em três partes que compõem de forma simplificada as fases de um projeto de *machine learning*: escolha do modelo, medidas de desempenho e, por fim, a comparação entre os modelos.

### 2.3.3.1. Escolha do modelo

Na discussão sobre aprendizado de máquina, Baranauskas e Monard (2000) salienta que, embora seja uma ferramenta potente, não existe um algoritmo que seja o melhor para todos os tipos de problemas. É essencial conhecer bem os pontos fortes e as limitações dos diferentes algoritmos disponíveis.

De acordo com Russell e Norvig (2020), o objetivo principal no aprendizado de máquina é escolher a hipótese que melhor se ajuste e minimize o erro em dados futuros, assumindo que estes se assemelhem aos dados históricos. Uma estratégia prática que pode ser eficaz, segundo Baranauskas e Monard (2000), é testar vários algoritmos, avaliar a precisão de cada um e escolher o mais adequado para o problema em questão. Ao fazer isso, geralmente lidamos com várias hipóteses e precisamos comparar modelos distintos ou ajustar hiperparâmetros dentro de um mesmo modelo.

Para evitar confusão e garantir que os resultados sejam confiáveis, é importante não usar o conjunto de teste até que o processo de treinamento e ajuste esteja completo. Russell e Norvig (2020) reforça a necessidade de três conjuntos de dados: um conjunto de treinamento para construir os modelos, um conjunto de validação para avaliar e selecionar o melhor modelo e, por fim, um conjunto de teste para validar o modelo escolhido de forma imparcial.

Segundo Russell e Norvig (2020) caso não se tenham dados suficientes para a formação desses três conjuntos, uma técnica chamada validação cruzada fold (*k-fold cross-validation*) pode ser utilizada. A ideia por trás da técnica é que cada exemplo tenha uma função dupla – como dados de treinamento e dados de validação – mas não ao mesmo tempo. Primeiro, divide-se os dados em subconjuntos iguais. Em seguida, são realizadas rodadas de aprendizagem; em cada rodada, os dados são apresentados como um conjunto de validação e os exemplos restantes são usados como conjunto de treinamento.

Russell e Norvig (1994 *apud* Baranauskas e Monard, 2000), propõem uma abordagem sistemática para avaliar algoritmos de aprendizado de máquina. A Figura 2.48 apresenta de forma resumida os passos da estratégia proposta.



Figura 2.48 Abordagem sistemática para avaliar algoritmos de aprendizado de máquina  
(Adaptado de Baranauskas e Monard (2000))

### 2.3.3.2. Medidas de desempenho

Na avaliação de modelos de classificação, diversas métricas são utilizadas para avaliar a performance do modelo. De acordo com Géron (2019), as principais métricas incluem a matriz de confusão, precisão (*precision*), sensibilidade (*recall*), a medida F1 (*F1-Score*) e a curva ROC (*Receiver Operating Characteristic*).

A matriz de confusão, exemplificada na Figura 2.49, é uma ferramenta detalhada que revela o número de previsões corretas e incorretas feitas por um modelo de classificação. Segundo Fielding (1999), ela resume o desempenho de um classificador.

		Grupo Real	
		1	2
Grupo Previsto	1	Correto Positivo Verdadeiro	Incorreto Positivo Falso
	2	Incorreto Positivo Falso	Correto Verdadeiro Negativo

Figura 2.49 Matriz de confusão genérica (Adaptado de Fielding, 1999)

A precisão, eq. (24), indica a proporção de previsões positivas que são corretas. A precisão é frequentemente utilizada em conjunto com a sensibilidade, eq. (25), ou *recall*, que mede a proporção de instâncias positivas reais que foram corretamente identificadas pelo modelo (Géron, 2019).

$$\text{precision} = \frac{TP}{TP + FP} \quad (24)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (25)$$

Onde TP é o número de positivos verdadeiros;

FP é o número de falsos positivos;

FN é o número de falsos negativos.

Segundo Géron (2019), para uma métrica que considere tanto a precisão quanto o *recall*, utiliza-se a medida F1 (*F1-Score*), conforme eq. (26), que é a média harmônica entre essas duas métricas. Diferente da média aritmética, a média harmônica enfatiza os valores mais baixos; por isso, um *F1-Score* alto só é possível se ambos, precisão e *recall*, forem altos, o que indica um equilíbrio entre as métricas.

$$F_1 - \text{Score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} = \frac{TP}{TP + \frac{FN + FP}{2}} \quad (26)$$

Outro instrumento analítico mencionado por Géron (2019) é a curva característica de operação do receptor (do inglês *receiver operating characteristic* - ROC), que é utilizada para avaliar a performance de classificadores binários. Essa curva compara a taxa de verdadeiros positivos (equivalente ao *recall*) com a taxa de falsos positivos (*False Positive Rate* – FPR). A Figura 2.50 apresenta um exemplo dessa curva.




Figura 2.50 Curva ROC (Adaptado de Géron, 2019)

Ainda para problemas de classificação, Baranauskas e Monard (2000) citam a taxa de erro de um classificador ou taxa de classificação incorreta,  $ce(h)$ . De acordo com os autores é uma medida muito comumente utilizada nesse tipo de problema. Essa taxa de erro é apresentada na eq. (27), ela compara cada instância rotulada com o rótulo previsto pelo classificador. O operador  $|E|$  retorna 1 se  $E$  for verdadeiro e zero caso contrário, e  $n$  é o número de instâncias. O complemento da taxa de erro, conhecida como a acurácia do classificador, denotada por  $ca(h)$ , é dado pela eq. (28).

$$ce(h) = \frac{1}{n} \sum_{i=1}^n |y_i \neq h(x_i)| \quad (27)$$

$$ca(h) = 1 - ce(h) \quad (28)$$

Onde,  $n$  é o número de instâncias no conjunto de dados;

$x_i$  é um vetor de todos os valores de recurso;

$y_i$  é a previsão;

$h$  é a função de previsão do sistema (hipótese).

Quando se trata de um problema de regressão, o erro preditivo pode ser estimado calculando a distância entre o valor verdadeiro e o previsto. Segundo Baranauskas e Monard (2000), as duas medidas que são mais comumente utilizadas são: o erro quadrático médio (MSE) e o erro médio absoluto (MAE), dados pelas eq. (29) e (30), respectivamente

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - h(x_i))^2 \quad (29)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - h(x_i)| \quad (30)$$

Géron (2019) apresenta outra medida de desempenho típica para problemas de regressão, que é a raiz do erro quadrático médio (*Root Mean Square Error* - RMSE). Essa medida dá uma ordem de quanto erro o sistema normalmente comete em suas previsões, com peso maior para erros grandes. A eq. (31) mostra a fórmula matemática para calcular o RMSE.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - h(x_i))^2} \quad (31)$$

Tanto o RMSE quanto o MAE são formas de medir a distância entre dois vetores: o vetor de previsões e o vetor de valores alvo. O cálculo do RMSE corresponde à norma euclidiana, enquanto o MAE corresponde à norma também chamada de norma Manhattan, medindo a distância entre dois pontos em uma cidade, por exemplo, se você só puder viajar ao longo de quarteirões ortogonais. Sendo assim, o RMSE é mais sensível a valores discrepantes do que o MAE (Géron, 2019).

O coeficiente de determinação ( $R^2$ ) é uma medida estatística que representa a relação linear entre o valor real e o valor previsto, apresentando-se sempre entre 0 e 1 e sendo independente da escala da variável dependente (James et al., 2023). Essa medida também é comumente utilizada para avaliar o desempenho das previsões feitas pelos modelos de ML. O  $R^2$  é representado pela eq. (32), onde  $y_i$  são os valores observados,  $\bar{y}$  é a média dos valores observados e  $\widehat{h(x_i)}$  são os valores previstos pelo modelo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \widehat{h(x_i)})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (32)$$



### 2.3.3.3. Comparação entre alguns modelos

No contexto do aprendizado de máquina, a seleção de um modelo adequado é um passo crítico que influencia diretamente a eficácia e eficiência da solução proposta. Com isso, a comparação dos modelos também constitui um passo importante num projeto de *machine learning*. A Tabela 2.1 apresentada por Zhang *et al.* (2022) apresenta um panorama comparativo, abordando as principais vantagens e limitações de algoritmos selecionados para utilização neste trabalho.

Tabela 2.1 Comparação entre alguns modelos de ML (Adaptado de Zhang *et al.*, 2022)

Algoritmo	Vantagens	Limitações
SVR	Minimização do risco estrutural; Rápida velocidade de treinamento	Pobre legibilidade e interpretabilidade; Previsão de saída única
RF	Forte capacidade de mapeamento não-linear	Previsão de saída única; Pobre capacidade de extrapolação
FNN	Forte capacidade de mapeamento não-linear; Previsão de saída múltipla	Numerosos hiper-parâmetros; Alto custo computacional

A Figura 2.51 apresentada uma comparação entre três modelos de aprendizado de máquina distintas para classificação de dados: RF, SVM e DNN (*Deep Neural Network*). Os dados são apresentados no gráfico superior com dois tipos de classes (Classe 0 e Classe 1) marcadas em vermelho e azul respectivamente, juntamente com dados de treino e teste. As figuras abaixo demonstram as fronteiras de decisão criadas por cada um dos algoritmos. Esta visualização é interessante para avaliar qual algoritmo fornece a melhor separação entre as classes, evidenciando a complexidade das fronteiras de decisão que cada método é capaz de capturar. Enquanto o RF e o SVM mostram fronteiras mais simples e lineares, o DNN parece modelar uma fronteira mais complexa e ajustada aos dados de teste. Segundo Dramsch (2020), enquanto o modelo de RF supera o SVM por uma pequena margem de 2,5% na precisão do treinamento, a diferença de desempenho é mínima (0,88%) no conjunto de teste, que é crucial para avaliar a generalização do modelo em dados novos.

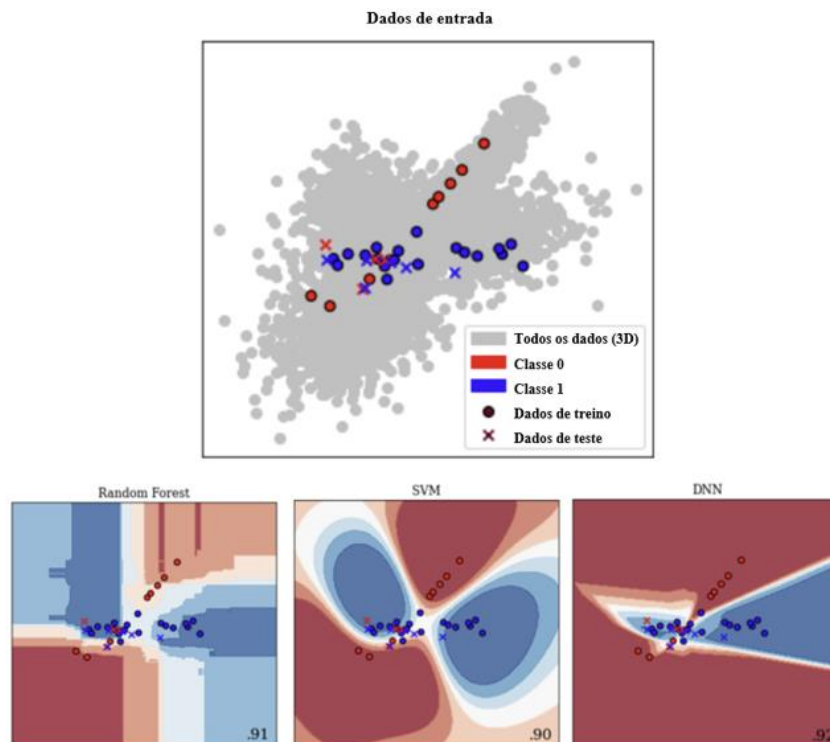


Figura 2.51 Conjunto de dados e o limite de decisão entre os modelos RF, SVM e DNN (Adaptado de Dramsch, 2020)

Mahamat *et al.* (2021) avaliou modelos de ML para prever a resistência à compressão de solo de cupins ativados por álcalis. Os modelos SVM, ANN e *Linear Regression* (LR) foram treinados e validados, sendo o SVM o mais acurado, seguido pela ANN e LR, respectivamente. Foram utilizadas as métricas de coeficiente de correlação ( $R^2$ ) e RMSE, conforme Figura 2.52.




Figura 2.52 Medidas estatísticas dos modelos de previsão: (a) coeficiente de determinação e (b) RMSE (Mahamat *et al.*, 2021)

### 3

## **Materiais e Métodos**

Este capítulo descreve a abordagem sistemática e as metodologias empregadas na investigação da previsão da curva de tensão *versus* deformação/deslocamento em areias, utilizando *algoritmos* de *machine learning*. A seção de 'Materiais' detalhará as fontes dos dados adotados neste estudo, que consistem em trabalhos acadêmicos de domínio público. Será apresentada uma descrição dos critérios de seleção dos estudos, bem como das características dos dados extraídos, fundamentais para a construção dos modelos de previsão. Na seção 'Métodos', será delineado o processo metodológico adotado, que se divide em quatro etapas principais: Coleta de Dados, Pré-processamento, Definição das Arquiteturas e Treinamento dos Modelos e Análise de Desempenho.

### **3.1.**

#### **Materiais utilizados**

Para a realização deste estudo, procedeu-se com uma pesquisa abrangente utilizando ferramentas de busca *online*, empregando palavras-chave relacionadas aos ensaios de cisalhamento direto e DSS. Esta pesquisa teve como alvo publicações científicas, artigos em periódicos especializados, conferências, trabalhos de conclusão de curso, dissertações de mestrado e teses de doutorado que contivessem dados experimentais específicos na forma de gráficos da relação tensão-deformação/deslocamento. Publicações que não atendiam a esse critério eram prontamente excluídas do conjunto de dados potenciais. Na seleção subsequente, avaliou-se a relevância do material estudado nos documentos pré-selecionados. Conforme o foco deste trabalho é em materiais arenosos, areia seca e com saturação total durante o ensaio, foram excluídos da análise trabalhos que envolviam outros tipos de materiais, tais como rejeitos, esferas de vidro, argilas e misturas argilosas, entre outros. A exclusão foi feita considerando a distinção de comportamento significativa destes materiais em comparação com a areia.

Para ensaios de cisalhamento direto, 7 pesquisas foram escolhidas, totalizando 205 ensaios individuais, os quais forneceram um total de 7.185 pares de dados de tensão *versus* deslocamento. Três desses ensaios foram designados para o conjunto de validação, o banco de dados foi separado em três partes e foram sorteados 3 ensaios no total sendo 1 ensaio de cada uma dessas partes. O objetivo dessa separação foi para evitar que os ensaios separados para validação fossem do mesmo autor.

Mediante a interpolação dos dados e o estabelecimento de um valor de corte de deslocamento horizontal para todos os ensaios excluindo-se os dados de validação, resultou em 3.434 pontos de dados. Os detalhes dos trabalhos selecionados, incluindo autores, ano de publicação, título, localização e quantidade de ensaios contribuintes, são sumarizados na Tabela 3.1.

Tabela 3.1 Trabalhos utilizados para os ensaios de cisalhamento direto

<b>Autor, Ano (ID)</b>	<b>Título do trabalho</b>	<b>Localização da areia</b>	<b>Quantidade de ensaios</b>
Coutinho, 2021 (C21)	Ensaio de Cisalhamento Direto na Areia da Praia de Ipanema	Ipanema	71
Marques e Oliveira, 2009 (M09)	Ensaio com a Areia de Hokksund para Projeto de Revitalização da Câmara de Calibração	Hokksund	20
Monteiro <i>et al.</i> , 2023 (M23)	Caracterização Geotécnica da Areia do Porto do Açú	Porto do Açú	16
Nunes, 2014 (N14)	Ensaio de caracterização geotécnica da areia da praia de Itaipuaçu	Itaipuaçu	29
Pinheiro, 2018 (P18)	Caracterização geotécnica em laboratório da areia da praia dos Cavaleiros – Macaé/RJ	Cavaleiros	24
Simões, 2015 (S15)	Caracterização geotécnica da areia da praia de Ipanema	Ipanema	30
Teles, 2013 (T13)	Estudo sobre os parâmetros de resistência e deformabilidade da areia de Hokksund	Hokksund	15

Para o ensaio de DSS, um conjunto de 8 estudos foi selecionado, compreendendo 100 ensaios e totalizando 2.793 pares de razão de tensão *versus* deformação. Da mesma forma, três ensaios foram destinados aleatoriamente para o conjunto de validação. Após processos similares de interpolação e um corte de deformação cisalhante, restaram 2.813 pontos de dados que também foram divididos para treinamento (80%) e teste (20%). A Tabela 3.1 oferece uma visão

geral dos estudos utilizados para o ensaio de DSS, incluindo as mesmas informações descritivas mencionadas anteriormente.

Tabela 3.2 Trabalhos utilizados para os ensaios de DSS

Autor, Ano (ID)	Título do trabalho	Localização da areia	Quantidade de ensaios
Adams, 2017 (AD17)	<i>Near-Surface Response of Beach Sand: An Experimental Investigation</i>	Beach of South Beach, Newport, Oregon	14
Kim, 2009 (KI09)	<i>Static Simple Shear Characteristics of Nak-dong River Clean Sand</i>	Nak-dong River e Fraser River	14
Lashkari <i>et al.</i> , 2020 (LA20)	<i>Instability of loose sand in constant volume direct simple shear tests in relation to particle shape</i>	Babolsar, Qare-Aqaj, Bushehr e Firoozkuh	15
Lashkari <i>et al.</i> , 2021 (LA21)	<i>Influence of linear coupling between volumetric and shear strains on instability and post-peak softening of sand in direct simple shear tests</i>	Firoozkuh	6
Schuck, 2022 (SC22)	Ensaio de cisalhamento simples na areia da Praia de Ipanema	Ipanema	30
Al Tarhouni e Hawlader, 2021 (TA21)	<i>Monotonic and cyclic behaviour of sand in direct simple shear test</i>	Ottawa	6
Vaid e Sivathayalan, 1996 (VA96)	<i>Static and cyclic liquefaction potential of Fraser Delta sand in simple shear and triaxial tests</i>	Fraser River	12
Zorzan, 2018 (ZO18)	Resistência ao cisalhamento do solo pelos ensaios de cisalhamento direto e DSS: análise experimental e aplicação na estabilidade de taludes	Solo A – Localização não identificada	3

### 3.2. Métodos utilizados

A metodologia contou com quatro principais etapas, são elas: coleta de dados; pré-processamento dos dados; definição das arquiteturas e treinamento e análise de desempenho e validação. As etapas foram feitas de forma independente para cisalhamento direto e DSS, considerando banco de dados diferentes para cada ensaio.

#### 3.2.1. Coleta de Dados

Após a seleção dos trabalhos que seriam utilizados conforme descrito no item 3.1, a metodologia utilizada para a etapa seguinte do estudo envolveu uma coleta

sistemática dos dados. Esta fase foi estruturada em três procedimentos específicos: a aquisição de dados gráficos, a digitalização desses dados e a análise de informações complementares ao estudo.

1. Aquisição de Dados Gráficos: Inicialmente, procedeu-se com a separação dos dados gráficos em imagens independentes de tensão-deformação/deslocamento disponíveis nos trabalhos selecionados.
2. Digitalização dos Dados: Utilizou-se o *software* “PlotDigitizer” (2024) para transcrever os dados dos gráficos salvos anteriormente. Este processo permite a conversão dos dados gráficos para formatos numéricos, pares de pontos, facilitando a subsequente análise estatística. Os gráficos foram então manipulados no ‘excel’ e foram sobrepostos aos gráficos originais para verificação da exatidão da digitalização.
3. Análise de Informações Complementares: Cada publicação selecionada foi examinada detalhadamente para extrair informações complementares referentes ao material e ao ensaio estudado (como índice de vazão inicial, tensão vertical, entre outros).

Essas etapas foram feitas de forma individual para cada trabalho e após esses procedimentos, a consolidação dessas informações resultou em um banco de dados unificado para cada tipo de ensaio.

### **3.2.2. Pré-processamento dos Dados**

A fase de pré-processamento dos dados é crucial na preparação de um projeto de *machine learning*. Esta etapa envolve limpar, organizar e transformar os dados coletados para garantir que sejam de alta qualidade e adequados para análises. O objetivo é assegurar que os dados reflitam as condições experimentais e estejam em formatos apropriados para os algoritmos de ML.

Após a coleta e consolidação dos dados, inicia-se a exploração destes através da visualização de gráficos dos ensaios individuais e gráfico de todos os ensaios consolidados. Isso permite identificar incompatibilidades ou anomalias, que podem surgir do processo de digitalização. Um exemplo de erro de digitação é apresentado na Figura 3.1, onde um dos ensaios tinham dados de ensaio que estavam com valores constantes erradamente. Outra anomalia identificada durante

o processo de digitalização foi a troca do eixo x com o eixo y no processo de digitalização. Todos os erros identificados foram prontamente corrigidos para garantia da confiança no banco de dados utilizado.




Figura 3.1 Exemplo de anomalia encontrada

Para garantir a consistência entre os dados, estabelecem-se critérios de padronização, como a uniformização dos intervalos de aquisição de dados através da interpolação. Isso ajuda a mitigar discrepâncias significativas e facilita a comparação entre os diferentes estudos. A interpolação gera dados em intervalos regulares, e após este processo, os dados são novamente sobrepostos e avaliados para confirmar a preservação de suas características originais. Além disso, também se faz necessário o estabelecimento de critérios para que todos os dados cheguem no mesmo ponto de deformação cisalhante/deslocamento horizontal final.

Um passo essencial antes da aplicação dos algoritmos de *machine learning* é a normalização dos dados. Este processo ajusta os valores dentro de um intervalo comum, evitando distorções nas análises e preservando a integridade das informações. A normalização é importante para assegurar que todos os dados contribuam da mesma forma para o aprendizado do modelo, sem que sejam influenciados por variações de escala. Neste trabalho, todos os parâmetros de entrada do modelo (*inputs*) estão sendo normalizados.

### 3.2.3. Definição das Arquiteturas e Treinamento

No desenvolvimento do modelo, uma etapa crucial consiste na seleção apropriada dos chamados hiperparâmetros para a arquitetura do modelo. Esta escolha deve ser guiada com o objetivo de otimizar tanto a capacidade preditiva quanto a generalização do modelo. Para alcançar uma configuração que

potencialize a capacidade preditiva e a generalização, propõe-se a realização de um estudo detalhado visando a identificação dos melhores parâmetros para os modelos de regressão. O estudo escolhido para este trabalho se baseará na aplicação de uma técnica de otimização conhecida como busca em grade (*Grid Search*), que permite a exploração sistemática de diversas combinações de parâmetros para determinar a configuração mais eficaz. Para a implementação da busca em grade, será definido um conjunto de valores possíveis para cada hiperparâmetro, configurando-se assim uma matriz multidimensional de opções. A ferramenta *GridSearchCV*, disponível na biblioteca *sklearn* do Python, será utilizada para automatizar este processo. A configuração da busca incluirá a avaliação do desempenho dos modelos por meio de validação cruzada, com um número de divisões estipulado em três, para garantir uma avaliação consistente e minimizar a variação nas estimativas de desempenho.

O critério de seleção dos melhores hiperparâmetros se dará através da análise de métricas como o erro absoluto médio (MAE), a raiz do erro quadrado médio (RMSE) e o coeficiente de determinação ( $R^2$ ), aplicadas ao conjunto de teste. Com a definição dos parâmetros mais adequados, pode-se seguir então ao treinamento dos modelos utilizando os dados previamente preparados e pré-processados.

O treinamento será desenvolvido de maneira a permitir que os modelos ajustem seus pesos internos para estabelecer uma correlação eficaz entre as variáveis de entrada e as saídas esperadas. Este processo será iterativo, com foco na minimização do erro de previsão, buscando-se assim aprimorar acurácia dos modelos.

#### **3.2.4. Análise de Desempenho e Validação**

Na fase de análise de desempenho e validação do modelo, é importante avaliar a eficácia dos modelos treinados utilizando métricas estatísticas apropriadas, como este trabalho trata sobre problemas de regressão, serão utilizados o erro absoluto médio (MAE), a raiz do erro quadrado médio (RMSE) e o coeficiente de determinação ( $R^2$ ). Esta avaliação será realizada utilizando os dados de teste, com o objetivo de comparar as previsões geradas pelos modelos com dados não vistos durante a fase de treinamento. A comparação nos dados de teste visa analisar os erros e a capacidade de generalização dos modelos desenvolvidos. Importante



ressaltar que a avaliação do modelo passa pelo entendimento do contexto do problema, ou seja, a utilização de uma única medida de desempenho, como o  $R^2$ , não é suficiente para concluir se o modelo está sendo adequado para aquela situação estudada.

Com isso, adicionalmente as métricas de desempenho, será empregado o conjunto de validação para realizar previsões das curvas de tensão-deformação cisalhante/deslocamento horizontal. Este procedimento tem como finalidade verificar a adequação dos modelos para aplicações práticas. Para complementar a análise, propõe-se a execução de uma avaliação comparativa entre os diferentes modelos desenvolvidos, com foco na identificação de qual modelo apresenta o melhor desempenho com base nas métricas selecionadas.

A linguagem de programação utilizada foi Python, devido à sua popularidade e à disponibilidade de bibliotecas especializadas em machine learning e análise de dados. Foram empregados diversos módulos, como Pandas para manipulação de dados, NumPy para operações numéricas, Scikit-learn para implementar modelos de machine learning, TensorFlow e Keras para construir e treinar redes neurais, e Matplotlib e Seaborn para visualização de dados. Além disso, foram utilizados módulos como GridSearchCV para ajuste de hiperparâmetros e joblib para salvar e carregar modelos treinados.

## 4 Análise dos Resultados

### 4.1. Construção dos Modelos

Na construção do banco de dados, os dados foram categorizados para facilitar a compreensão e o estudo das características e comportamentos dos solos. As categorias estabelecidas são: localização do material para identificação do solo estudado; Propriedades físicas do solo; Condição de preparação do corpo de prova e Resultados do ensaio. Os itens de cada categoria são apresentados a seguir:

- **Localização do Material:** Identificação da proveniência do solo estudado.
- **Propriedades Físicas do Solo:** Incluem o índice de vazios máximo ( $e_{m\acute{a}x}$ ), o índice de vazios mínimo ( $e_{m\acute{i}n}$ ) e a densidade real dos grãos ( $G_s$ ).
- **Condições Iniciais de Preparação do Corpo de Prova:** Índice de vazios inicial médio ( $e_0$ ) e compactidade relativa média ( $CR$ ).
- **Resultados do Ensaio:** Abrangem a tensão vertical de adensamento ( $\sigma_v$ ), a área corrigida do corpo de prova, a velocidade de cisalhamento do ensaio, o deslocamento horizontal ( $\delta_h$ ) no caso de cisalhamento direto e deformação cisalhante ( $\gamma$ ) no caso do DSS, a tensão de cisalhamento ( $\tau$ ) e a razão de cisalhamento ( $\tau/\sigma_v$ ).

Na fase de compilação do banco de dados, observou-se uma variabilidade na disponibilidade dos parâmetros coletados de diferentes fontes. É importante destacar que nem todas as contribuições incluíam o conjunto completo de parâmetros de interesse. Com isso, foi adotado o critério de não utilizar os parâmetros para os quais os dados estavam ausentes, com o objetivo de manter a integridade e a consistência do conjunto de dados analisado. Além disso, certos parâmetros foram empregados unicamente com o propósito de identificação das

amostras e, portanto, não foram incluídos na análise preditiva. Os parâmetros efetivamente utilizados para a modelagem, bem como as estatísticas descritivas dos dados, são detalhadamente apresentados na Tabela 4.1. Ressalta-se, também, que o conhecimento prévio acerca do funcionamento do ensaio e do comportamento do solo foram importantes na escolha dos parâmetros de entrada utilizados no modelo.

Tabela 4.1 Dados estatísticos dos *inputs* utilizados

Ensaio	<i>Input</i> (x)						<i>Target</i> (y)
Cisalhamento Direto	-	$G_s$	$e_0$	$CR$ (%)	$\sigma_v$ (kPa)	$\delta_h$ (mm)	$\tau/\sigma_v$
	Mín	2.643	0.428	8	12.50	0	-
	Máx	2.763	0.726	99	1600.00	5	-
DSS	-	$G_s$	$e_0$	$CR$ (%)	$\sigma_v$ (kPa)	$\gamma$ (%)	$\tau/\sigma_v$
	Mín	2.640	0.463	12	6.00	0	-
	Máx	2.780	1.060	91	750.00	20	-

Como uma das etapas de pré-processamento dos dados, foram feitas verificações da digitalização dos gráficos. A Figura 4.1 mostra o exemplo de um dos gráficos com dados digitalizados sobrepostos ao gráfico original para verificação da exatidão da digitalização. Esse processo foi realizado para todos os ensaios.




Figura 4.1 Gráficos com dados digitalizados sobrepostos ao gráfico original para verificação da exatidão da digitalização

Adicionalmente à validação da exatidão da digitalização, realizou-se o *plot* de gráficos de maneira individualizada para a identificação de potenciais anomalias, conforme ilustrado na Figura 4.2. A Figura 4.3, por sua vez, exibe o *plot* coletivo dos ensaios a fim de ter uma visão geral dos ensaios.

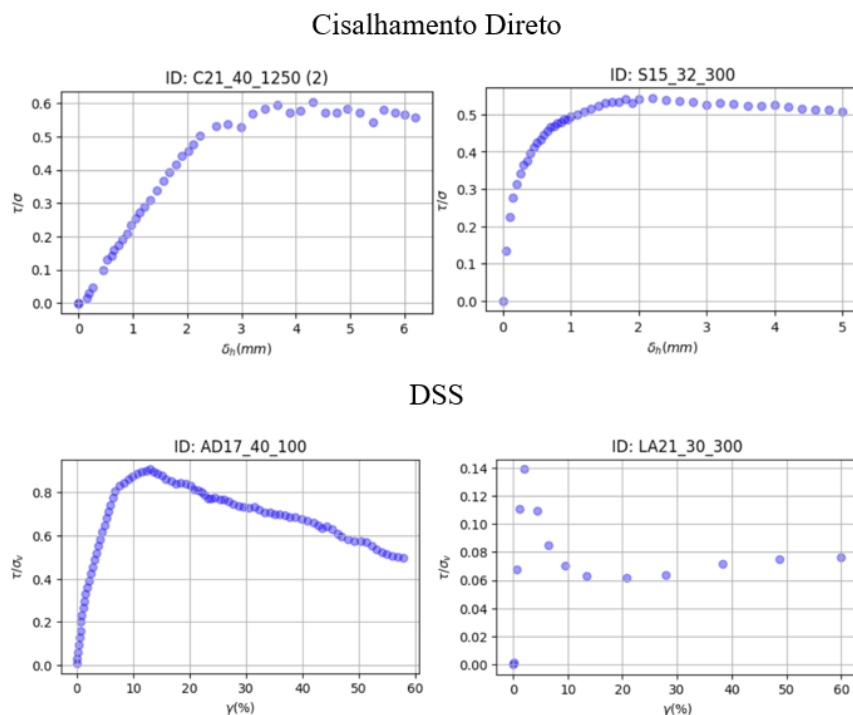


Figura 4.2 Exemplo de *plot* de gráficos individuais para detecção de possíveis anomalias

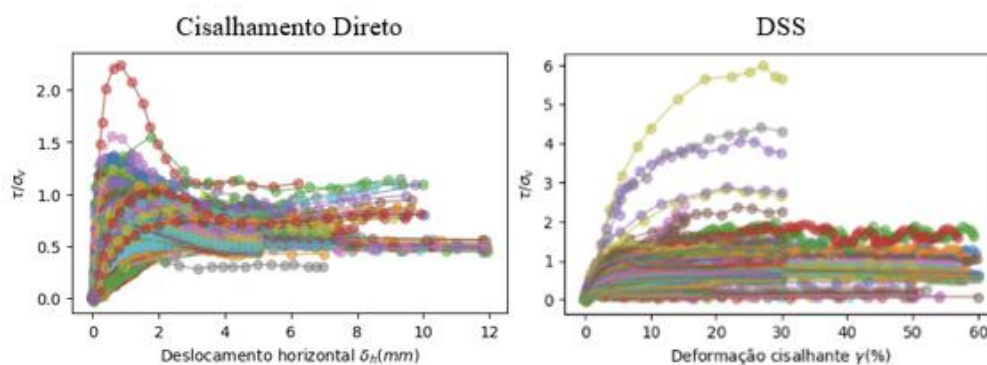


Figura 4.3 *Plot* coletivo para visão geral e detecção de anomalias

Ao plotar todos os gráficos conjuntamente, foi possível identificar discrepâncias nos deslocamentos horizontais e deformações cisalhantes (eixo x) entre os diferentes ensaios. Para mitigar esta variação, estabeleceu-se um valor padrão que buscasse abranger a maioria dos ensaios, sendo definidos 5 mm para o ensaio de cisalhamento direto e 20% para o ensaio de DSS. Observou-se também a

inconsistência nos intervalos de aquisição de dados ao longo dos ensaios, o que levou à necessidade de interpolação de pontos a fim de uniformizar esses intervalos. Essa diferença entre os intervalos de aquisição de dados dos ensaios é esperada visto que diferentes autores utilizaram diferentes máquinas com diferentes intervalos de aquisição. Para a uniformização, foram arbitrados intervalos de deformação de 0,7% para DSS e deslocamento horizontal de 0,3 mm para cisalhamento direto. Após essa etapa, procedeu-se com uma nova verificação dos gráficos, tanto de maneira individual (Figura 4.4) quanto coletiva (Figura 4.5), para assegurar a adequação das interpolações realizadas.

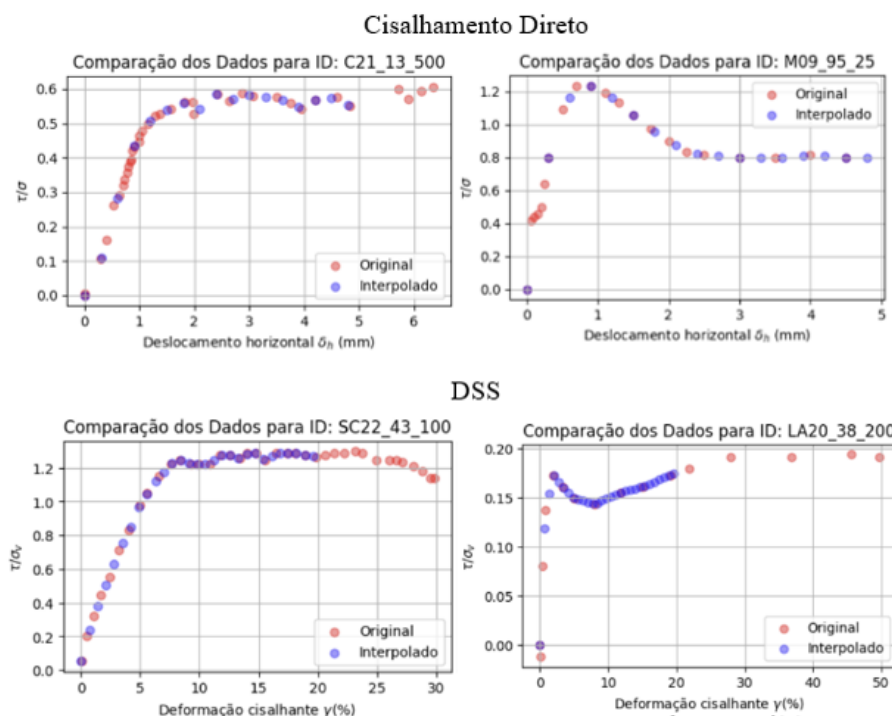


Figura 4.4 Plot de alguns gráficos individuais com dados interpolados e originais

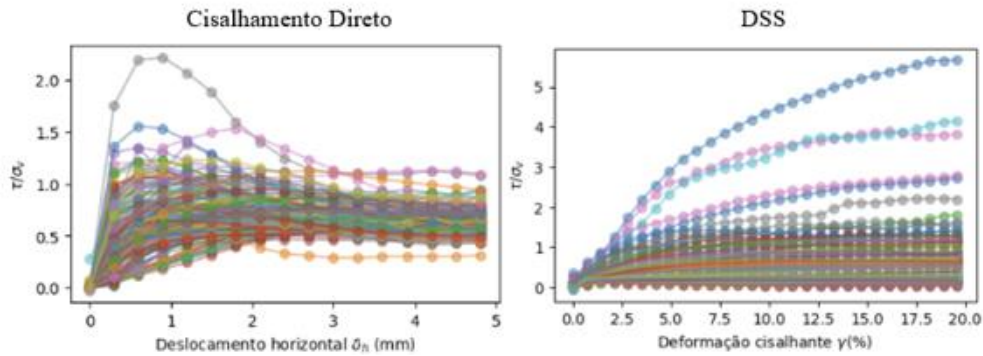


Figura 4.5 *Plot dos Gráficos interpolados juntos*

Os ensaios foram separados em grupos de treino, teste e validação. Para a fase de validação, o banco de dados total foi segmentado em três partes iguais, e de cada segmento, foram selecionados três números aleatórios. Com o objetivo de prevenir a inclusão de múltiplos ensaios de um mesmo autor no conjunto de validação. Os ensaios correspondentes a estes números aleatórios foram então excluídos do conjunto principal e reservados para a validação. O conjunto remanescente foi subdividido, destinando-se 80% dos dados ao treinamento e 20% ao teste.

Durante o treinamento dos modelos, manteve-se constante o intervalo no eixo x (correspondente ao deslocamento/deformação no gráfico de resistência), que foi utilizado como entrada tanto no treinamento quanto na fase de previsão. Com isso o modelo tem como objetivo apenas a previsão da tensão cisalhante normalizada pela tensão vertical (eixo y da curva de resistência). Adicionalmente, implementou-se uma condição de contorno, o ponto (0,0), que representa a ausência de tensão e, consequentemente, de deslocamento ou deformação, pois é considerado como uma das premissas do ensaio.

A seleção dos hiperparâmetros para o treinamento foi realizada por meio da técnica de busca em grade (*GridSearch*). um procedimento que avalia o desempenho do modelo com diferentes combinações de parâmetros. O processo emprega validação cruzada para determinar a configuração que minimiza os erros, conduzindo à escolha dos hiperparâmetros mais eficazes.

## 4.2. Avaliação de desempenho

Após o treinamento dos modelos com os hiperparâmetros definidos, as métricas de desempenho, especificamente o Erro Médio Absoluto (MAE), a Raiz

do Erro Quadrático Médio (RMSE) e o coeficiente de determinação ( $R^2$ ), foram calculadas. Os resultados dessas métricas para as fases de treino e teste estão apresentadas na Tabela 4.2.

Tabela 4.2 Avaliação de desempenho dos modelos

Ensaio	Modelo	Treino			Teste		
		MAE	RMSE	$R^2$	MAE	RMSE	$R^2$
Cisalhamento Direto	RF	0.01	0.02	0.99	0.03	0.05	0.96
	SVR	0.05	0.10	0.86	0.06	0.10	0.85
	FNN	0.09	0.13	0.75	0.09	0.13	0.74
DSS	RF	0.03	0.06	0.99	0.04	0.09	0.99
	SVR	0.10	0.20	0.92	0.11	0.22	0.91
	FNN	0.09	0.17	0.94	0.11	0.20	0.92

#### Ensaio de Cisalhamento Direto:

- O modelo RF demonstrou superioridade, conforme evidenciado por métricas de desempenho da Tabela 4.2, como um MAE e RMSE reduzidos durante o treinamento (0.01 e 0.02, respectivamente), além de  $R^2$  de 0.99, refletindo um alinhamento quase perfeito com os dados.
- Na fase de teste, observa-se um aumento relativamente pequeno do RF quando comparado ao treino nos valores de MAE e RMSE (0.03 e 0.05, respectivamente) e um  $R^2$  de 0.96, que pode indicar uma boa capacidade de generalização do modelo.
- Os modelos SVR e FNN apresentaram desempenho inferior ao RF. O SVR apresentou métricas de erro (MAE e RMSE) mais altas tanto no treino quanto no teste em comparação com o RF. O FNN teve um desempenho menos exato no treinamento, com MAE e RMSE maiores (0.09 e 0.13, respectivamente), e um  $R^2$  mais baixo (0.74). A performance no teste foi consistente com o treino, mantendo as métricas de erro aproximadamente constantes, mas com um  $R^2$  de 0.74, podendo refletir a menor capacidade de generalização entre os modelos.

#### Ensaio de DSS:

- O RF novamente se destacou, com um  $R^2$  de 0.99 no treinamento e no teste, apesar de um ligeiro aumento no MAE e RMSE.

- Os modelos SVR e FNN apresentaram métricas de erro maiores e  $R^2$  menor que o RF. O FNN teve um  $R^2$  ligeiramente superior (0.94) comparado ao SVR (0.92 no treino e 0.91 no teste).
- Esses resultados sugerem que os modelos de SVR e FNN tiveram o desempenho competente, porém não alcançaram o nível de generalização e capacidade de modelar dados do RF.

O modelo RF destacou-se consistentemente com um melhor desempenho geral nos dois tipos de ensaio, indicando uma excelente capacidade preditiva e uma tendência mínima ao *overfitting*. Os modelos SVR e FNN, apesar de apresentarem resultados aceitáveis, são superados pelo RF. Estes resultados sugerem que o RF é a melhor escolha para modelar os dados analisados.

### 4.3. Ensaio de validação

A seguir são apresentadas as curvas de resistência, nos tópicos separados por ensaio, das previsões realizadas pelos modelos nos conjuntos de dados designados para validação. Além da análise das curvas de resistência, propõe-se uma medida adicional de avaliação do conservadorismo das curvas previstas pelos modelos, focando na segurança para aplicação em projetos de geotecnia. Essa medida consiste na comparação entre os valores máximos das curvas previstas pelo modelo no eixo y e os valores máximos das curvas reais obtidas nos ensaios de validação, conforme descrito na eq. (33). A diferença resultante dessa comparação pode servir como indicador do caráter conservador da previsão: um resultado positivo implica que o modelo superestimou a resistência e beneficiou, assim, a segurança.

$$\text{dif} = \text{máx}(y_{\text{previsão}}) - \text{máx}(y_{\text{real}}) \quad (33)$$

#### 4.3.1. Cisalhamento Direto

As Figura 4.6, Figura 4.7 e Figura 4.8 exibem os resultados das curvas de previsões dos modelos utilizando os ensaios de validação para o ensaio de Cisalhamento Direto, destacando as diferenças entre os valores máximos previstos e os valores reais - com as previsões modeladas em vermelho e os dados reais em



azul. Para esta avaliação, três ensaios completos foram selecionados, e as previsões foram realizadas pelos três modelos estudados.

As curvas geradas pelo modelo RF se alinharam bem com os dados de validação, tanto para materiais contráteis quanto dilatantes, demonstrando boa aderência em termos de forma e tendência (Figura 4.6). As diferenças entre as curvas do RF e os dados de validação variaram de 0.01 a -0.03, indicando que o modelo tende a subestimar ligeiramente a tensão máxima, mas com alta exatidão geral. As curvas do RF se mantiveram próximas às curvas de validação ao longo de toda a extensão do eixo de deformação, sugerindo que o modelo captura com exatidão a relação tensão-deformação horizontal do material geotécnico estudado.




Figura 4.6 Curvas de previsão nos ensaios de validação do modelo de RF no ensaio de Cisalhamento Direto

O modelo SVR, por sua vez, Figura 4.7, apresentou previsões particularmente no ID M23\_27\_300, que são quase indistinguíveis dos dados de validação, o que pode indicar uma precisão notável. No entanto, no ID S15\_88\_150, a previsão diverge ligeiramente, indicando uma variação na capacidade do modelo de capturar picos de tensão. Observa-se, ainda, que neste ID o modelo demonstrou uma curva com um leve crescimento pós-ruptura, não esperado para esse ensaio de acordo com os dados. As medidas de diferenças entre máximos desse modelo também foram baixas, variando de -0.01 a 0.03.




Figura 4.7 Curvas de previsão nos ensaios de validação do modelo de SVR no ensaio de Cisalhamento Direto

Para o modelo de FNN, Figura 4.8, as curvas apresentam uma aderência menor aos dados de validação, quando comparados ao RF e SVR, com algumas variações na forma das curvas, como visto no ID M23\_27\_300. Isto pode refletir uma sensibilidade a variações nos dados de entrada ou uma menor estabilidade no ajuste do modelo. As diferenças variam de -0.03 a 0.11, com dois casos de dif positivos, podendo indicar uma tendência do FNN a superestimar a tensão máxima em 2 dos 3 casos.




Figura 4.8 Curvas de previsão nos ensaios de validação do modelo de FNN no ensaio de Cisalhamento Direto

Os três modelos demonstram potencial na previsão da curva tensão-deslocamento em ensaios de cisalhamento direto, com o RF e SVR oferecendo um equilíbrio favorável entre exatidão da previsão e segurança com os baixos valores de dif e boa capacidade de capturar o formato da curva, sendo os mais recomendados para utilização. O FNN pode exigir uma avaliação mais criteriosa para garantir que suas previsões se alinhem consistentemente com as expectativas.

### 4.3.2. DSS

Para o ensaio de DSS, o modelo *Random Forest* (RF), ilustrado na Figura 4.9, evidenciou um desempenho conforme antecipado pelas métricas de avaliação previamente discutidas. A forma das curvas do RF, particularmente no ID SC22\_65\_500, é quase indistinta da curva de validação, refletindo um modelo bem ajustado. As diferenças variam de -0.01 a 0.02, indicando uma aproximação aos dados reais.




Figura 4.9 Curvas de previsão nos ensaios de validação do modelo de RF no ensaio de DSS

O SVR está apresentado na Figura 4.10. Observa-se uma variação maior na forma das curvas quando comparadas aos valores de validação, especialmente no ID TA21\_87\_400, onde a previsão do SVR apresenta um pico mais acentuado. Este comportamento pode indicar uma sensibilidade elevada do modelo SVR a certas características dos dados de entrada. No modelo SVR, a medida da diferença entre máximos ficou relativamente alta, variando de -0.01 a 0.49, com a maior discrepância apontando para uma previsão potencialmente mais conservadora.




Figura 4.10 Curvas de previsão nos ensaios de validação do modelo de SVR no ensaio de DSS

Para o modelo FNN, não mostraram resultados considerados satisfatórios em 2 das 3 curvas, em termos de forma e magnitude, como visto no ID TA21\_87\_400 e SC22\_65\_500. O FNN apresenta diferenças que vão de -0.08 a 0.07, sugerindo que a maior parte dos casos podem subestimar a tensão quando comparadas aos dados reais.




Figura 4.11 Curvas de previsão nos ensaios de validação do modelo de FNN no ensaio de DSS

Dos três modelos utilizados para o ensaio de DSS, o único que conseguiu apresentar um desempenho significativo com relação ao formato da curva e medida dif baixo foi o RF, conforme esperado a partir das métricas de desempenho. Vale ressaltar que o banco de dados de DSS tem uma quantidade menor de ensaios quando comparado ao ensaio de Cisalhamento Direto. Mesmo com a quantidade de dados limitada, o modelo ainda mostrou um desempenho satisfatório, com destaque ao RF. Ressalta-se que não foi possível avaliar o desempenho dos modelos de DSS em uma areia que apresentasse o comportamento dilatante, por conta do sorteio dos ensaios utilizados para validação.

#### 4.4. Análise dos parâmetros de entrada

Neste tópico serão estudados os parâmetros de entrada a partir da análise da correlação e do gráfico que apresenta a influência dos parâmetros no modelo de RF.

Os gráficos de correlação, Figura 4.12, fornecem uma visão quantitativa da influência de diversos parâmetros nos resultados dos ensaios de cisalhamento direto e DSS, com a tensão de cisalhamento ( $\tau$ ) como referência, pois o *target* é um dado normalizado pela tensão vertical. Esses gráficos revelam as complexidades envolvidas na avaliação dos efeitos de diferentes parâmetros geotécnicos sobre a resistência ao cisalhamento dos solos.

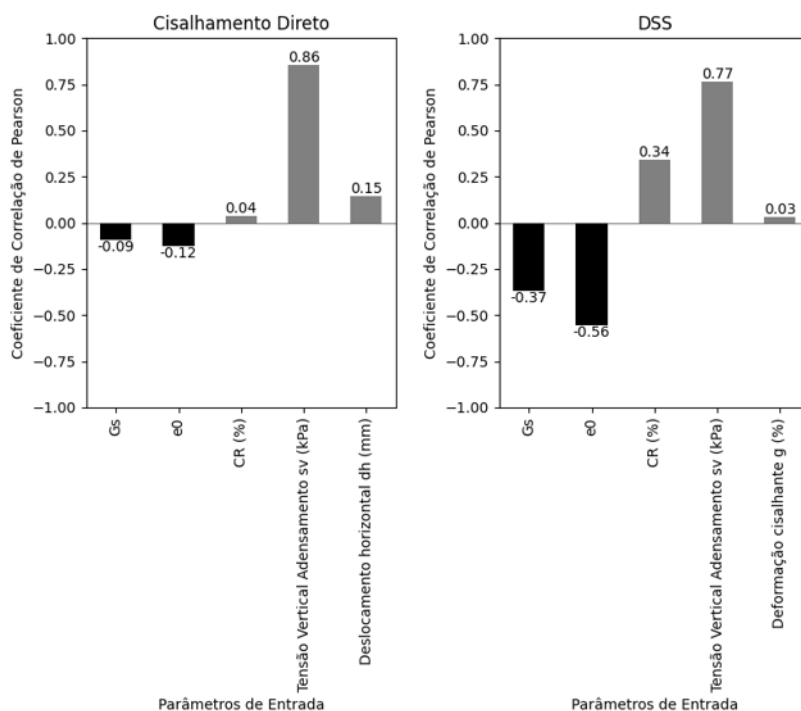


Figura 4.12 Gráfico de correlação de Pearson com os parâmetros de entrada dos ensaios

Em ambos os ensaios, a correlação mais expressiva parece ser com a tensão vertical de adensamento ( $\sigma_v$ ), o que sugere que, conforme a tensão aplicada sobre o solo aumenta, há um impacto considerável na tensão de cisalhamento, o que era esperado a partir do estudo da resistência ao cisalhamento abordado no item 2.1. Em contraste com o esperado, para o ensaio DSS, a deformação cisalhante exibiu uma correlação quase insignificante, enquanto outros parâmetros variaram de correlações fracas a fortes, apesar de um conjunto de dados mais limitado. Para o

cisalhamento direto, com exceção da tensão vertical de adensamento, todas as outras variáveis demonstraram correlações negligíveis. Na resistência ao cisalhamento das areias, conforme estudado no item 2.1, sabe-se que a curva de resistência pode alterar seu formato conforme variação do valor do  $e_0$ , por exemplo. No entanto, a correlação direta entre esses fatores e a resistência ao cisalhamento nem sempre é evidente ou linear, refletindo a complexa interação das variáveis que governam o comportamento do solo.

No contexto de aprendizado de máquina, existem algumas formas de se obter a importância de cada variável de entrada na previsão do modelo, uma delas é com a utilização de técnicas de Inteligência Artificial Explicativa como o SHAP (*SHapley Additive exPlanations*). De forma simplificada, o SHAP é uma abordagem da teoria de jogos para explicar a saída de qualquer modelo de aprendizado de máquina (Lundberg e Lee, 2017).

O gráfico da Figura 4.13 é um gráfico de barras SHAP. Este gráfico é usado para resumir a importância das características (*features*) em um modelo de aprendizado de máquina, nesse caso foi analisado o modelo de RF, pois apresentou o melhor desempenho para os dois ensaios.




Figura 4.13 Gráfico de barras SHAP para ensaio de cisalhamento direto e DSS

Na Figura 4.13, cada barra representa uma *feature* diferente do modelo. A largura da barra indica a importância média dessa *feature*. Na escala horizontal

( $\text{mean}(|\text{SHAP value}|)$ ) mostra o valor absoluto médio do impacto SHAP para cada *feature*. Este valor é uma medida de quão importante a *feature* é para as decisões do modelo em média, sobre todas as amostras, analisadas a partir dos dados de teste. Ao lado de cada barra tem-se um valor positivo para os dois ensaios. Isso não significa que a contribuição da *feature* seja sempre positiva, mas sim que o valor absoluto do efeito dessa *feature*. O SHAP considera tanto os efeitos positivos quanto negativos e os converte em uma medida de impacto unidirecional usando o valor absoluto. Esse gráfico serve como referência para mostrar a importância média das *features*, e não como os diferentes valores dessas *features* afetam a previsão.

Para o ensaio de cisalhamento direto, o *CR* surge como o fator mais influente, seguido pela tensão vertical de adensamento ( $\sigma_v$ ) e, em menor grau, pelo deslocamento horizontal ( $\delta_h$ ). Esta hierarquia de importância reflete a relevância do *CR* na determinação da curva de resistência prevista pelo modelo. A tensão vertical de adensamento ( $\sigma_v$ ), também desempenha um papel significativo, conforme esperado.

No ensaio DSS, observa-se que a tensão vertical de adensamento ( $\sigma_v$ ) tem a maior influência, destacando-se significativamente sobre os outros parâmetros. O *CR* e a deformação cisalhante ( $\gamma$ ) também apresentam impactos notáveis.

Para o ensaio de cisalhamento direto, o *CR* apresenta a maior correlação de Pearson e o maior valor de SHAP, indicando que é o fator mais influente na resistência ao cisalhamento do solo a partir da ótica da análise de dados e da previsão do modelo. No caso do ensaio DSS, a tensão vertical de adensamento ( $\sigma_v$ ) também é o parâmetro mais impactante, segundo o gráfico SHAP. No entanto, o *CR* e a deformação cisalhante ( $\gamma$ ) aparecem com valores de SHAP significativos e positivos, sugerindo uma influência considerável sobre a resistência ao cisalhamento. A correlação de Pearson para a deformação cisalhante é moderada, o que, juntamente com o valor de SHAP, ressalta a relevância do parâmetro.

Essas descobertas e análises dos *inputs* são essenciais para o refinamento de modelos preditivos em geotecnia, permitindo aos engenheiros identificarem quais parâmetros requerem atenção especial durante a fase de coleta de dados e análise.

## 5 Conclusões

Neste estudo foram realizadas análises do desempenho de modelos de aprendizado de máquina, *machine learning*, aplicados à previsão da curva de razão de tensão-deslocamento/deformação em ensaios geotécnicos de cisalhamento direto e DSS. Utilizando uma base de dados composta por 205 ensaios de cisalhamento direto e 100 ensaios de DSS, extraída de uma variedade de pesquisas, procedeu-se à construção de modelos específicos para cada tipo de ensaio. Uma parcela dos dados foi reservada para validação, enquanto o restante foi distribuído entre conjuntos de treino e teste, seguindo a proporção padrão de 80/20. A busca em grade (*GridSearch*) provou ser uma ferramenta indispensável na otimização dos hiperparâmetros, indicando modelos de alto desempenho e confiabilidade.

Com relação ao desempenho dos modelos, o modelo *Random Forest* (RF) destacou-se consistentemente, exibindo alta precisão e alinhamento com os dados reais, uma característica reforçada pela estabilidade das métricas de desempenho do treinamento para a fase de teste. Esta robustez foi evidente nos valores de  $R^2$  próximos à unidade, refletindo uma forte capacidade de previsão e sugerindo um modelo bem calibrado. Os modelos *Support Vector Regression* (SVR) e *Feedforward Neural Network* (FNN), embora apresentassem resultados aceitáveis, foram superados pelo RF, nos ensaios de Cisalhamento Direto e DSS. Este resultado foi consistentemente observado nas métricas de avaliação - MAE, RMSE e  $R^2$  - tanto nos dados de treino e teste quanto na validação. As diferenças nas previsões, métrica proposta no presente trabalho, representaram quão próximas as previsões estavam dos dados reais, no modelo de RF foram significativamente baixas, sugerindo confiabilidade na previsão do modelo. Vale ressaltar, considerando a importância da segurança em aplicações geotécnicas, que esses mesmos valores baixos de dif podem apontar para possibilidades de aprimoramentos, possivelmente com fatores de segurança, para utilização desses modelos em projetos de geotecnia.



Importante ressaltar que mesmo com um conjunto de dados relativamente limitado, os modelos alcançaram resultados promissores, indicando que o enriquecimento do banco de dados poderia ampliar ainda mais a eficácia e a confiabilidade das previsões. Entretanto, ressalta-se também sua aplicabilidade restrita ao tipo de solo estudado.

Neste estudo, foi explorada a aplicação de inteligência artificial (IA) na geotecnia, desmistificando a percepção de que os modelos de *machine learning* são uma "caixa preta". O destaque de desempenho no estudo foi o modelo de RF, que demonstrou ser superior na previsão do comportamento do solo, mesmo com o conjunto de dados relativamente limitado. A utilização de inteligência artificial explicativa para avaliar este modelo reforçou a confiança nos resultados e indicou o potencial de métodos de IA transparentes e interpretáveis na geotecnia.

Este trabalho evidencia que o *machine learning* tem um potencial significativo para aprimorar a análise em engenharia geotécnica, sugerindo alternativas e complementos aos métodos tradicionais. A integração da IA na geotecnia é vista como um avanço que pode levar a projetos mais seguros e confiáveis, marcando um passo importante na exploração da sintonia entre tecnologias computacionais avançadas e a engenharia geotécnica.

Como sugestão de trabalhos futuros, propõe-se investigar a inclusão de outras variáveis de entrada que possam capturar outras relações do comportamento do solo, como características microestruturais. A aplicação de técnicas de aprendizado de máquina mais avançadas, como técnicas de *deep learning*, podem oferecer esclarecimentos adicionais sobre padrões complexos nos dados. Por último, há um campo vasto para a aplicação dessas técnicas em uma diversidade maior de materiais geotécnicos, como rejeitos de mineração e solos argilosos, abrindo novas frentes no campo da engenharia geotécnica e contribuindo para a segurança e inovação na engenharia geotecnia.

Como parte desse trabalho, um *software* chamado 'GSandy' foi criado. Ele permite a utilização dos modelos aqui desenvolvidos para realização de simulações das curvas de razão de tensão x deslocamento horizontal ou razão de tensão x deformação cisalhante. A aplicação permite que os usuários façam interação com os modelos treinados bem como acessar as referências e o banco de dados dos trabalhos utilizados.

- ADAMS, R. K. **Near-Surface Response of Beach Sand: An Experimental Investigation**. 2017. Corvallis: Oregon State University, 2017.
- AHMED, E. M. A. (2014). **Codes of Practice for Geotechnical Engineering Site Investigations (SI)**. Journal of BRR, 16, 58–78.
- AI, L., Fang, N. F., Zhang, B., & Shi, Z. H. (2013). **Broad area mapping of monthly soil erosion risk using fuzzy decision tree approach: Integration of multi-source data within GIS**. International Journal of Geographical Information Science, 27(6), 1251–1267.
- AIREY, D. W.; WOOD, D. M. **An evaluation of direct simple shear tests on clay**. Geotechnique, v. 37, n. 1, p. 25–35, 1987.
- AL TARHOUNI, M. A.; HAWLADER, B. **Monotonic and cyclic behaviour of sand in direct simple shear test conditions considering low stresses**. Soil Dynamics and Earthquake Engineering, v. 150, p. 106931. 2021.
- ANTHONY, M.; BARTLETT, P. L. **Neural Network Learning: Theoretical Foundations**. Nova York: Estados Unidos da América pela Universidade de Cambridge, 2009.
- ARAÚJO, C. B. C. DE. **Aplicação das Redes Neurais Artificiais do Tipo Perceptron na Estimativa de Recalques em Estacas**. 2015. Dissertação de Mestrado—Fortaleza: Universidade Federal do Ceará, 2015.
- ASTM, D.-04. **Standard test method for direct shear test of soils under consolidated drained conditions**. 2003. Disponível em: <<https://www.astm.org/d3080-04.html>>. Acesso em: 22 nov. 2023.
- ASTM, D.-17. **Standard Test Method for Consolidated Undrained Direct Simple Shear Testing of Fine Grain Soils**. 2017. Disponível em: <<https://standards.iteh.ai/catalog/standards/sist/4cd12af4-391e-4e4d-a5d3-26d884d2fe3a/astm-d6528-17>>. Acesso em: 22 nov. 2023.

- ATKINSON, J.; BRANSBY, P. L. **The mechanics of soils : An introduction to critical state soil mechanics**. McGraw-Hill Book Co, 1978. 375 p. ISBN(0070840776).
- ATKINSON, J. H.; LAU, W. H. W.; POWELL, J. J. M. **Measurement of soil strength in simple shear tests**. Canadian Geotechnical Journal, v. 28, p. 255–262, 1991.
- BARANAUSKAS, J. A.; MONARD, M. C. **Reviewing Some Machine Learning Concepts and Methods**. São Carlos. 2000.
- BARROS, M. L. DE. **Machine Learning Aplicado à Previsão de Piping em Barragens de Terra Homogêneas**. Monografia —Brasília: Universidade de Brasília, 2020.
- BAZIAR, M. H.; JAFARIAN, Y. (2007). **Assessment of liquefaction triggering using strain energy concept and ANN model: Capacity Energy**. Soil Dynamics and Earthquake Engineering, 27(12), 1056–1072.
- BEELER, N. M.; TULLIS, T. E.; GOLDSBY, D. L. **Constitutive relationships and physical basis of fault strength due to flash heating**. Journal of Geophysical Research: Solid Earth, v. 113, n. 1, 4 jan. 2008.
- BRAINS. **Random Forests: Algoritmos Baseados em Árvores**. Disponível em: <<https://brains.dev/2023/random-forests-algoritmos-baseados-em-arvores/>>.
- Acesso em: 20 jan. 2024.
- BREIMAN, L. **Random Forests**. Kluwer Academic Publishers, v. 45, p. 5–32, 2001.
- CARVALHO, M. G.; et al. **Aplicações de inteligência artificial na determinação de parâmetros de resistência ao cisalhamento do solo: um mapeamento sistemático da literatura**. 2022. Research, Society and Development, v. 11, n. 1, p. e27711124506.
- CHENG, Z. L.; ZHOU, W. H.; GARG, A. (2020). **Genetic programming model for estimating soil suction in shallow soil layers in the vicinity of a tree**. Engineering Geology, 268.
- CORTE, M. B. **Desenvolvimento de Equipamento para Ensaio Simple Shear**. 2016. Dissertação de Mestrado—Porto Alegre: Universidade Federal do Rio Grande do Sul, 2016.

- COUTINHO, J. V. M. **Ensaio de Cisalhamento Direto na Areia da Praia de Ipanema**. 2021. Dissertação de Mestrado—Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2021.
- DIAS, E. S. **Análise de Susceptibilidade à Liquefação Dinâmica com Uso de Técnicas Estatísticas Multivariadas**. 2023. Trabalho Final de Curso—Ouro Preto: Universidade Federal de Ouro Preto.
- DRAMSCH, J. S. **Machine Learning in 4D Seismic Data Analysis Deep Neural Networks in Geophysics**. 2019. Tese de Doutorado—Lyngby-Tårn: Universidade Técnica da Dinamarca.
- DRAMSCH, J. S. **70 years of machine learning in geoscience in review**. 2020. A PREPRINT.
- DYVIK, R. et al. **Comparison of truly undrained and constant volume direct simple shear tests**. 1987. *Geotechnique*, v. 37, n. 1, p. 3–10.
- FIELDING, A. H. **Machine Learning Methods for Ecological Applications**. 1999. Nova York: Springer US.
- GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2019. Second Edition ed. O'Reilly Media, Inc.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. 2016. MIT Press. Disponível em: < <http://www.deeplearningbook.org>. >. Acesso em: 11 dez. 2023.
- GOH, A. T. C.; KULHAWY, F. H.; CHUA, C. G. (2005). **Bayesian Neural Network Analysis of Undrained Side Resistance of Drilled Shafts**. *Journal of Geotechnical and Geoenvironmental Engineering*, 131(1), 84–93.
- GROGNET, M. **The boundary conditions in direct simple shear tests, development for peat testing at low vertical stress**. 2011.
- HANZAWA, H. et al. **Comparative Study Between the NGI Direct Simple Shear Apparatus And the Mikasa Direct Shear Apparatus**. *Soils And Foundations - Japanese Geotechnical Society*, v. 47, n. 1, p. 47–58, 2007.
- IKIZLER, S. B. et al. **Prediction of swelling pressures of expansive soils using soft computing methods**. *Neural Computing and Applications*, 24(2), 473–485. 2014.

- JAMES, G. et al. **An Introduction of Statistical Learning with Applications in Python**. 2023.
- KANUNGO, D. P.; SHARMA, S.; PAIN, A. **Artificial Neural Network (ANN) and Regression Tree (CART) applications for the indirect estimation of unsaturated soil shear strength parameters**. *Frontiers of Earth Science*, v. 8, n. 3, p. 439–456. 2014.
- KARIMPOULI, S.; TAHMASEBI, P. **Image-based velocity estimation of rock using Convolutional Neural Networks**. *Neural Networks*, 111, 89–97. 2019.
- KIM, Y. S. **Static simple shear characteristics of Nak-dong River clean sand**. *KSCE Journal of Civil Engineering*, v. 13, n. 6, p. 389–401. 2009.
- KIRAN, S.; LAL, B.; TRIPATHY, S. S. **Shear strength prediction of soil based on probabilistic neural network**. *Indian Journal of Science and Technology*, 9(41). 2016.
- KJELLMAN, W. **Testing the Shear Strength of Clay in Sweden**. *Géotechnique*, v. 2, n. 3, p. 225–232. 1951.
- LAMBE, T. W.; WHITMAN, R. V. **Soil Mechanics**. Massachusetts: Massachusetts Institute of Technology, 1969.
- LASHKARI, A.; FALSAFIZADEH, S. R.; RAHMAN, M. M. **Influence of linear coupling between volumetric and shear strains on instability and post-peak softening of sand in direct simple shear tests**. *Acta Geotechnica*, v. 16, n. 11, p. 3467–3488, 1 nov. 2021.
- LASHKARI, A. et al. **Instability of loose sand in constant volume direct simple shear tests in relation to particle shape**. *Acta Geotechnica*, v. 15, n. 9, p. 2507–2527, 2020.
- LEE, L. K.; SEED, H. B. **Drained Strength Characteristics of Sands**. *Journal of Soil Mechanics and Foundations Division*, p. 117–141, 1967.
- LORENA, A. C.; DE CARVALHO, A. C. P. L. F. **Uma Introdução às Support Vector Machines**. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 20 dez. 2007.
- LUNDBERG, S. M.; LEE, S.-I. **A Unified Approach to Interpreting Model Predictions**. 2017, Long Beach. 31st Conference on Neural Information Processing Systems, 2017. Disponível em: <<https://github.com/slundberg/shap>>. Acesso em: 03 fev. 2024.

MATHWORKS. **What Is Overfitting?** Disponível em: <<https://www.mathworks.com/discovery/overfitting.html>>. Acesso em: 15 abr. 2024.

MAHAMAT, A. A. et al. **Machine Learning Approaches for Prediction of the Compressive Strength of Alkali Activated Termite Mound Soil**. Applied Sciences, v. 11, n. 11, p. 4754, 22 maio 2021.

MAMMONE, A.; TURCHI, M.; CRISTIANINI, N. **Support vector machines**. John Wiley & Sons, Inc., v. 1, p. 283–289, 2009.

MARQUES, F. de L.; OLIVEIRA, F. da S. **Ensaio com a Areia de Hokksund para Projeto de Revitalização da Câmara de Calibração**. XXXI Jornada Giulio Massarani de Iniciação Científica, Artística e Cultural, n. 856, Rio de Janeiro, 2009.

MARTINS, W. L. DE O. **Comparação dos Valores de Resistência Não-Drenada de Uma Argila Marinha Obtidos Através dos Ensaio de Cisalhamento Direto e Cisalhamento Simples (Direct Simple Shear)**. 2023. 71 p. Projeto de Graduação—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2023.

MITCHELL, T. M. **Machine Learning**. McGraw-Hill Science/Engineering/Math. 342 p. 1997.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine Learning second edition**. Second Edition ed. Cambridge: Massachusetts Institute of Technology, 2018.

MONTEIRO, D. P.; DANZIGER, B. R.; LIMA, B. T. **Caracterização Geotécnica da Areia do Porto do Açú**. 2023, 10º Seminário de Engenharia de Fundações Especiais e Geotecnia, 2023.

MOUSAVI, S. M. et al. **Nonlinear Genetic-Based Simulation of Soil Shear Strength Parameters**. J. Earth Syst. Sci. 120, No. 6 pp. 1001–1022. Indian Academy of Sciences. 2011.

NUNES, V. P. **Ensaio de Caracterização Geotécnica da Areia da Praia de Itaipuaçu**. 2014. Projeto de Graduação—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2014.

OLIVEIRA, Y. M. et al. **Machine Learning Aplicado na Estimativa do Coeficiente de Mola de Estacas com Validação por Meio de Provas de Carga Estáticas**. Geocentro. 2019.

- PINHEIRO, G. P. **Caracterização Geotécnica em Laboratório da Areia da Praia dos Cavaleiros-Macaé/RJ**. 2018. Macaé: Universidade Federal do Rio de Janeiro, 2018.
- PINTO, C. S. **Curso Básico de Mecânica dos Solos**. 3ª Edição ed. São Paulo: Oficina de Textos, 2009.
- PlotDigitizer**. Disponível em: <<https://plotdigitizer.com>>. Acesso em: 25 out. 2023.
- NEJAD, F. P. et al. **Prediction of pile settlement using artificial neural networks based on standard penetration test data**. Computers and Geotechnics, 36(7), 1125–1133. 2009.
- RASCHKA, S.; MIRJALILI, V. **Python machine learning : machine learning and deep learning with Python, scikit-learn, and TensorFlow**. Packt Publishing. 622 p. 2017.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning representations by back-propagating errors**. Nature Publishing Group, v. 323, 1986.
- RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. Fourth Edition ed. Pearson, 2020. ISBN(9780134610993).
- SCHUCK, T. E. S. **Ensaio de cisalhamento simples na areia da Praia de Ipanema**. 2022. 177 p. Dissertação de Mestrado—Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2022.
- SCIKIT-LEARN. **Choosing the right estimator**. Disponível em: <[https://scikit-learn.org/stable/tutorial/machine\\_learning\\_map/index.html](https://scikit-learn.org/stable/tutorial/machine_learning_map/index.html)>. Acesso em: 05 fev. 2024.
- SILVA, J. P. DE O. **Aplicação de Redes Neurais Artificiais do Tipo Perceptron Para Previsão da Condutividade Hidráulica em Solos Não Saturados**. 2020. Dissertação de Mestrado—Fortaleza: Universidade Federal do Ceará, 2020.
- SIMÕES, F. B. **Caracterização Geotécnica da Areia da Praia de Ipanema**. 2015. Projeto de Graduação—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2015.
- SMOLA, A. J.; SCHOLKOPF, B. **A tutorial on support vector regression \***. Statistics and Computing, v. 14, p. 199–222, 2004.

TAYLOR, D. W. **Fundamentals of Soil Mechanics**. New York: State College of Agriculture at Cornell University, 1948. 700 p.

TELES, G. L. V. **Estudo Sobre os Parâmetros de Resistência e Deformabilidade da Areia de Hokksund**. 2013. Projeto de Graduação—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2013.

TERZAGHI, K. V. **The Shearing Resistance of Saturated Soils and the Angle Between the Planes of Shear**. International Conference on Soil Mechanics and Foundation Engineering (Harvard), 1936.

VAID, Y. P.; SIVATHAYALAN, S. **Static and cyclic liquefaction potential of Fraser Delta sand in simple shear and triaxial tests**. Can. Geotech. , v. 33, p. 281–289, 1996.

VILLET, W. C. B.; SITAR, N.; JOHNSON, K. A. **Simple Shear Tests on Highly Overconsolidated Offshore Silts**. 17th Offshore Technology Conference, 1985.

VJ TECH. **Introduction to Direct Simple Shear (DSS) Testing**. Disponível em: <<https://www.vjtech.co.uk/vj-tech/case-studies/introduction-to-direct-simple-shear-dss-testing>>. Acesso em: 20 nov. 2023.

WANG, R. et al. (2023). **Hydrodynamic landslide displacement prediction using combined extreme learning machine and random search support vector regression model**. European Journal of Environmental and Civil Engineering, 27(6), 2345–2357.

ZHANG, P.; YIN, Z. Y.; JIN, Y. F. **Machine Learning-Based Modelling of Soil Properties for Geotechnical Design: Review, Tool Development and Comparison**. Archives of Computational Methods in Engineering, v. 29, n. 2, p. 1229–1245. 2022.

ZHANG, W. et al. **Application of deep learning algorithms in geotechnical engineering: a short critical review**. Artificial Intelligence Review, v. 54, n. 8, p. 5633–5673, 1 dez. 2021.

ZORZAN, L. G. **Resistência ao Cisalhamento do Solo pelos Ensaio de Cisalhamento Direto e DSS: Análise Experimental e Aplicação na Estabilidade de Taludes**. 2018. Trabalho Final de Conclusão de Curso—Curitiba: Universidade Federal do Paraná, 2018.