

Avaliação do CBR Usando Ensaios de Caracterização do Solo com Modelagem via Boosted Trees

Paulo Victor Acácio Alves

Engenheiro Civil, Universidade Federal do Pará, Belém, Brasil, paulovictor.alves@coc.ufrj.br

Gerson Jacques Miranda dos Anjos

Professor, Universidade Federal do Pará, Belém, mirandadosanjos@gmail.com

Alberto Miranda

Engenheiro Civil, Universidade Federal do Pará, Belém, Brasil, alberto.miranda1997@gmail.com

Marcelo Seabra de Andrade

Engenheiro Civil, Universidade Federal do Pará, Belém, Brasil, eng.marceloseabra@gmail.com

RESUMO: A rápida e correta determinação do CBR é de fundamental importância na execução do projeto e nas obras de terra na geotecnia. A execução do ensaio para a determinação desse parâmetro é demorada e impactante no cronograma da obra. São encontrados na literatura internacional diversas formulações e modelos para prever esse índice, combinando diversos parâmetros do solo para fazer a determinação, geralmente falhando por serem executados através de modelos com pouca capacidade de prever a variável ou em uma quantidade de dados limitados para descrever o comportamento. Desse modo, se viu válida a criação de um programa que utiliza uma base de dados e um modelo mais robusto para prever esse índice, além de ter uma capacidade maior de adaptar-se as características dos solos encontrados no Brasil. No processo de criação do programa foi utilizado um boosted tree e foram usados os mais de 1200 dados que se teve acesso para a criação do modelo de predição, sendo que os dados foram tratados para a retirada de dados que possuam ruídos ou que tinham outliers, foi feita a separação dos dados para treino e validação, sendo separados 80% e 20%, respectivamente. Constatou-se que o modelo conseguiu aferir valores com uma enorme precisão e com elevada capacidade de generalização por valores que nunca teve contato, atingindo $R^2 = 0,994$.

PALAVRAS-CHAVE: CBR, Pavimentação, Boosted Trees, Inteligência Artificial, Aprendizado de Máquina.

ABSTRACT: The quick and correct determination of the CBR is of fundamental importance in the execution of the project and in the earthworks in geotechnics. The execution of the test to determine this parameter is time-consuming and has an impact on the work schedule. Several formulations and models are found in the international literature to predict this index, combining several soil parameters to make the determination, usually failing because they are executed through models with little capacity to predict the variable or in a limited amount of data to describe the behavior. . In this way, the creation of a program that uses a database and a more robust model to predict this index was validated, in addition to having a greater capacity to adapt to the characteristics of the soils found in Brazil. In the process of creating the program, a boosted tree was used and the more than 1200 data that had access were used to create the prediction model, and the data were treated to remove data that had noise or that had outliers, data was separated for training and validation, being separated 80% and 20%, respectively. It was found that the model was able to measure values with enormous precision and with a high capacity for generalization by values that it never had contact with, reaching $R^2 = 0.994$.

KEYWORDS: CBR, Paving, Boosted Trees, Artificial Intelligence, machine learning.

1 INTRODUÇÃO

Desde que se passou a construir estradas pavimentadas o grande objetivo foi melhorar as estradas de terra, protegendo-as da ação da água, do desprendimento de poeira e pedras, tornando a via mais segura e cômoda para a passagem de tráfego, tornando-as mais duráveis. As primeiras estradas construídas em solos argilosos que enlameavam pela ação da chuva, passaram a ser encascalhadas e ensaibradas. Posteriormente, as vias passaram a ser revestidas com macadame e pedra britada (Motta e Medina, 2015).

Os pavimentos rodoviários são formados por camadas variadas que compatibilizam as cargas oriundas do tráfego transmitidas pelo pneu, na qual, conforme se aproxima da superfície, a resistência desses materiais vai crescendo sendo obedecidas questões racionais e econômicas no seu dimensionamento. Sendo comum aferir a resistência das camadas constituídas por solo através do California Bearing Ratio (CBR), também conhecido no Brasil por Índice de Suporte Califórnia (ISC).

O ensaio para a determinação do CBR foi desenvolvido originalmente na California State Highway Department, na década de 30, como parte do estudo de falhas em pavimentos, sendo posteriormente incorporado pela Army Corps of Engineers para o dimensionamento de pavimentos flexíveis e em seguida em diversas normas ao redor do mundo. Seu propósito foi providenciar uma avaliação da estabilidade relativa para a pedra britada fina do material de base. Depois seu uso foi expandido para sub-bases. O ensaio consiste na mensuração na resistência do solo a penetração de 2,54 mm e 5,08 mm de um embolo rígido, com o valor dessa resistência sendo expressa em porcentagem das duas cargas padrões, adotando o maior entre os dois valores. Apesar das numerosas críticas e a queda em popularidade nos últimos anos, continua formando as bases de métodos empíricos de dimensionamento. O valor do CBR é usualmente utilizado para o projeto e como indicador de resistência e capacidade de suporte se subleito, sub-base e base de estradas rodoviárias e de aeródromos.

A determinação do valor do CBR é parte fundamental para o projeto de diversas estruturas na engenharia civil, sendo a rápida determinação, fundamental para reduzir o tempo da obra. Muitos estudos demonstraram o efeito do tipo de solo e as propriedades básicas no CBR, subsequentemente identificando muitas outras correlações entre o CBR e outros parâmetros do solo. Muitas das equações de correlação propostas não têm um alto coeficiente de correlação. Portanto, é possível concluir que a estimativa do CBR é difícil de obter usando os métodos estatísticos convencionais. A maioria das equações empíricas propostas não possuem uma boa acurácia nem uma solução generalizada, na qual, é devido a representação inadequada das propriedades do solo, presença de relação intrínseca entre os parâmetros e métodos de cálculo inconsistentes (Taskiran, 2010).

Baseado nos conceitos de mecânica dos pavimentos, hoje se reconhece que existem critérios mais adequados para nortear estas escolhas, a partir do entendimento do pavimento como um sistema em camadas sujeito a cargas repetidas. O CBR torna-se cada vez mais defasado, mas pelas condições regionais, na qual, os equipamentos para determinar o módulo resiliente não se tem disponível em todo o norte do Brasil e, muito dos equipamentos encontram-se com grandes filas pelos programas de pós-graduação, tornando a sua utilização inviável para uma grande gama de obras do país.

Com o que se apresenta, o desenvolvimento de inteligência artificial (IA) para a determinação do CBR pode ser uma alternativa viável. Os modelos de inteligência artificial podem simular associações que são altamente não lineares entre numerosos parâmetros de entrada e saída e podem, portanto, determinar previsões com uma acurácia maior do que os obtidos com regressões simples e múltiplas. Com isso foi pensado em como a IA poderia auxiliar na solução para que esse parâmetro fosse mais facilmente determinado na obra.

2 REVISÃO BIBLIOGRÁFICA

2.1 O Índice de Suporte Califórnia

O ensaio do Índice de Suporte Califórnia (DNIT - ME 172/2016) é precedido pela compactação do material nas características desejadas de umidade (w) e de peso específico seco (γ_d), em cinco camadas iguais, de forma a se ter uma altura total de solo de cerca de 12,5 cm após a compactação. Após o término da moldagem é retirado o disco espaçador e os moldes são invertidos e é colocado o prato-base perfurado. Sendo colocado no espaço deixado pelo disco espaçador do corpo de prova a haste de expansão com pesos anelares. É

encaixado, na haste de expansão, um extensômetro fixo ao tripé porta-extensômetro, ajustado na parte superior do cilindro, destinado a medir as expansões ocorridas a cada 24 horas até que se tenha completado 96 horas.

Com o término do período de embebição e sua retirada de imersão é iniciado o ensaio de penetração. Leva-se o molde a prensa e faz-se o assentamento do pistão de penetração no solo, através da aplicação de uma carga de, aproximadamente, 45 N, sendo aferida pelos deslocamentos do ponteiro do extensômetro do anel dinamométrico. Após é acionada a manivela pela prensa com a velocidade de 1,27 mm/min. Cada leitura no extensômetro é função de uma penetração do pistão no solo.

Para Black (1961) a falha da capacidade de suporte ocorre de acordo com a teoria da plasticidade quando a tensão passiva de Rankine nas cunhas ao redor do êmbolo é atingida, permitindo o solo levantar e o êmbolo mover-se para baixo em tensão constante. É dito também que o teste de CBR é uma forma de medir o módulo de deformação em condições particulares e não a capacidade última. A relação entre o valor do CBR e a capacidade de suporte última depende também do tipo de solo como do método de compactação.

A maior rigidez em solos leva que eles tenham uma maior zona rompida ao redor do êmbolo com penetrações de 2,5 mm. Para solos de baixa rigidez a capacidade de suporte não é atingida nos 5 mm, a resistência ao cisalhamento é mobilizada só em zonas locais nas extremidades do êmbolo. O uso das alternativas de penetração nas quais o CBR pode ser definido significa que o parâmetro pode refletir diferentes proporções de resistência e rigidez (Hight e Stevens, 1982).

2.2 Formulações na literatura

Os estudos relacionados ao CBR se fazem necessários por ser muito difundida no meio técnico, principalmente, pela sua fácil interpretação teórica e por uma grande disponibilidade de equipamentos em todo o território nacional. Com isso diversos autores na literatura buscaram desenvolver e aprimorar métodos para diminuir a demanda de tempo para se ter a ideia de como seria o comportamento do solo em campo, assim, diminuindo o tempo que é demandado na obra.

A literatura mostra que os parâmetros de entrada pouco variam de um autor para outro, sendo mais a forma como eles organizam e deixam de utilizar alguns em relação a outros o que mais diferencia. Os métodos de obter os modelos para aferir o CBR é algo que se diferencia entre os autores, desde regressões simples que tem baixa capacidade de descrever o comportamento de variáveis que são altamente não lineares, até modelos sofisticados com grande capacidade de predição e generalização.

Black (1961) aferiu o valor de CBR através da análise de ruptura ao redor do êmbolo pela sua similaridade com uma fundação. Para materiais granulares o crescimento do valor de CBR é grande, sendo evidenciado nesse estudo através das areias uniformes. Para a determinação do CBR tem que ser determinada a carga de ruptura e com a dificuldade de considerar o efeito de confinamento do molde e, também, sendo necessário determinar o valor da coesão como parâmetro para determinar o q_u .

Em seu trabalho sobre solos coesivos, Black (1962) conseguiu determinar uma correlação entre o CBR e o índice de plasticidade para diversos valores de índice de consistência - como mostra a Figura 1 - os valores apresentados consideram o solo saturado, tendo-se também valores que fazem a correção para estimar o CBR para solos não saturados. Sendo esses valores muito usados como guia na seleção de solos de Londres na época.




Figura 1. Relação entre CBR e índice de plasticidade para vários índices de consistência.

Taskiran (2010) utilizou a Rede Neural Artificial (RNA) e a Programação de Expressão Genética (PEG) para a predição do CBR de solos de granulação fina da Turquia. Para o treinamento da RNA foram extraídos 79% dos dados, correspondendo um grupo de 119 testes, e outros 21% foram usados para teste do modelo, que representa 32 testes. Os parâmetros de entrada para o RNA foram pertencentes a 3 grupos, entre eles, as propriedades índices que reflete a plasticidade, a granulometria e as propriedades de compactação. Com o uso do PEG ele conseguiu gerar uma função matemática que prediz o valor do CBR, sendo feitos modelos com diferentes números de entrada de variáveis para predizer o Índice de Suporte Califórnia, sendo os parâmetros de entrada iguais os da RNA. O modelo I com 7 parâmetros de entrada e o modelo V com 4 parâmetros obtiveram os melhores resultados do R^2 .

Este trabalho de Yildirim e Gunaydin (2011) usou como parâmetros para o estudo a análise granulométrica do material, os limites de Atterberg, o peso específico seco máximo e a umidade ótima do solo. As correlações foram obtidas por regressão simples, múltipla e por RNA estimando correlações entre os diversos modelos com coeficiente de determinação variando de 0,80-0,95. O seu uso é recomendado para análises preliminares de projeto. Para a regressão simples foram analisados os dados pelo método de regressão de mínimos quadrados, tendo obtido correlações fortes nas equações com porcentagem de pedregulho (G) e porcentagem de finos (F)

Bhatt e Jain (2014) demonstraram a eficiência da rede neural para predizer o valor do CBR, mas primeiro eles desenvolveram modelos para regressão linear simples e regressão linear múltipla, sendo achado coeficiente de determinação (R^2), respectivamente, de 0,62 e 0,88. Com o uso da Rede Neural Artificial (RNA) eles testaram os modelos com a entrada e retirada dos diversos 22 parâmetros. O melhor resultado foi de R^2 de 0,979 usando os parâmetros de porcentagem de pedregulho, porcentagem de areia, umidade ótima e peso específico seco máximo.

Bhardan et al. (2021a) possuíam para esse estudo 312 dados do projeto de uma ferrovia localizada na Índia, contando com seis parâmetros básicos de 5 tipos diferentes de solo. Outros 40 dados foram obtidos de ensaios para validação dos métodos apresentados, sendo, posteriormente, mostrada a comparação detalhada da acurácia do modelo. No estudo foram usados oito diferentes modelos de Extreme Learning Machine (ELM). O ELM-MPSO atingiu a melhor solução entre todos os modelos com $R^2 = 0,91$ e $RMSE = 0,0645$. Essa meta-heurística baseada em populações possui um grau de convergência mais rápido, sendo capaz de escapar das áreas de mínima local.

Em seu outro estudo, Bhardan et al. (2021b) usaram quatro métodos para criar modelos de previsão, sendo usados splines de regressão adaptativa multivariada com modelos lineares por partes, splines de regressão adaptativa multivariada com modelos cúbicos por partes, processo gaussiano de 23 regressão e programação genética. Foram usados neste trabalho 312 dados de CBR de uma obra ferroviária na Índia, sendo 250 para treino e 62 para teste de modelo, com a proposição de três equações para a determinação da variável dependente do estudo. Separadamente foram feitos no laboratório experimentos para verificar a confiabilidade de modelo. Os experimentos mostraram que o modelo spline de regressão adaptativa multivariada com os modelos lineares por partes obtiveram a maior acurácia, atingindo coeficiente de determinação (R^2) de 0,9686 e raiz do erro quadrático médio (RMSE) de 0,0359.

Os modelos utilizados no trabalho de Trong et al. (2021), são constituídos de três modelos de árvore de decisão, contendo, a poda de erro reduzido (REPT), a poda de erro reduzido baseado em superfície aleatória (RSS-REPT) e a Extra Tree (ET). O modelo foi desenvolvido com 214 amostras e com dez parâmetros de entrada. A ET mostrou-se o algoritmo mais robusto, conseguindo obter para os dados de teste $R^2 = 0,968$. O problema que podemos citar no uso dessas heurísticas é que seu uso fica limitado na faixa de valores que se utilizou para criar o modelo, como pode ser observado na faixa granulométrica de areia que limita seu uso entre 20- 30%.

2.3 Árvores de Decisão (Boosted Trees)

Sabe-se que o problema de aprendizado de máquina está ligado a procura num espaço de possíveis soluções, dada uma linguagem para representar as generalizações de exemplos e uma função de avaliação de hipóteses, o problema de aprendizado busca nesse espaço de hipóteses definido pela linguagem de representação.

Nas árvores de decisão usa-se a estratégia de dividir os problemas complexos em problemas mais simples, sendo progressivamente aplicada a mesma estratégia. As soluções dos diversos subproblemas podem ser agrupadas na forma de uma árvore, produzindo assim uma solução complexa. O poder contido nessa ideia está no fato da divisão de cada espaço de instâncias em subespaços e cada subespaço é ajustado usando diferentes modelos.

Para Faceli et al. (2019), a árvore de decisão é um grafo acíclico direcionado em cada nó ou é um nó de divisão, tendo dois ou mais sucessores, ou um nó folha. Sendo um nó folha contendo um rótulo com uma função. Quando se analisa o nó folha são considerados apenas os valores da variável alvo nos exemplos que chegam até ele. Nos casos mais simples, a função é a constante que minimiza a função custo. Nos problemas de regressão, que são o alvo dessa pesquisa, a constante que minimiza a função custo do erro médio quadrático é a média, já para a mediana que diminui a função custo do desvio absoluto. Um nó de divisão contém um teste condicional baseado nos valores do atributo, como percebe-se na Figura 2. Sendo cada árvore correspondente a uma região desse espaço. As regiões definidas pelas folhas da árvore são mutuamente excludentes, e a reunião delas cobre todo o espaço definido pelo atributo.




Figura 2. Uma árvore de decisão e as regiões de decisão no espaço de objetos.

Para o desenvolvimento dessa árvore foi usado o algoritmo de aprendizado Boosted Trees, em que, o boosting gerado é um método que agrega várias árvores. Diferencia-se da floresta aleatória por lidar com o erro criado pelas árvores anteriores, sendo as novas árvores formadas considerando o erro das anteriores e assim sucessivamente, sendo a forma desse modelo nomeada aprendizado sequencial. Com o boosting as árvores de decisão “fracas” tornam-se em aprendizados fortes. O boosting é um processo iterativo, no qual, pela dependência da árvore anterior, é difícil paralelizar o seu treinamento, torna seu tempo de treino maior. As árvores modificadas pelo processo de boosting são chamadas Boosted Trees.

3 METODOLOGIA

Para a execução desse trabalho foram utilizados resultados de CBR de 1211 amostras. Dessas amostras, um total de 462 foram retiradas do trabalho do Ferreira (2008) e as outras 749 vem do arquivo pessoal de Anjos (2022) que possui dados de diversas regiões do Brasil.

Os parâmetros de entrada usados no algoritmo foram o CBR, como o sendo a variável resposta desejada; os parâmetros de compactação como a umidade ótima e peso específico seco máximo, W_{ot} e $\gamma_{d,max}$; os limites de Atterberg, LL e LP; a porcentagem de areia, S; a porcentagem de pedregulhos, G; e a porcentagem de finos, que reúne argilas e siltes, F.

Para que fosse evitado que o modelo tivesse grande dificuldade de prever corretamente os valores, foi feita a retirada dos dados que continham ruídos e dados faltantes, após isso, foi feita a retirada dos dados com valores muito discrepantes – sendo considerado outliers – que poderiam causar uma perda de acurácia do modelo para prever esses valores muito afastados da tendência da maioria dos dados. Com o pré-processamento feito, foram separados 80% dos dados para o treinamento e 20% para o teste do modelo.

Com o programa desenvolvido, foi testado com vários índices e coeficientes estatísticos com o objetivo de avaliar qual a capacidade de previsão dele. Para isso foram utilizados quatro ferramentas estatísticas, sendo elas: Coeficiente de determinação, R^2 ; Raiz do Erro Quadrático Médio, RMSE; Erro Absoluto Médio, MAE; Erro Percentual Absoluto Médio, MAPE.

4 RESULTADOS

Para a elaboração do programa e do modelo foi feito o uso do Python como linguagem de programação. Com o modelo baseado no Boosted Trees foi possível combinar diversos variáveis de entrada, a fim de determinar a variável alvo. Para o modelo proposto os parâmetros utilizados para a determinação do CBR foram LL, LP, G, S, F, γ_d e Wot. Com isso foram usadas 4 ferramentas estatísticas para avaliar o modelo, conforme tabela 1.

Tabela 1. Ferramentas estatísticas do Trabalho.

Modelo	Índices de Performance			
	R ²	RMSE	MAE	MAPE
Boosted Trees	0,994	1,1771	0,718	0,0617

Após a construção do modelo a partir dos 1211 casos, no qual, o software foi usado para treinamento e a posterior validação. A Figura 3 mostra como comporta-se os valores calculados (ordenadas) pelos valores medidos (abscissas). Mostrou-se grande adequação do modelo, chegando próximo da reta ideal, obtendo R² = 0,994.




Figura 3. Gráficos de valores medidos x calculados pelo modelo.

O programa construído é de fácil utilização, após serem adicionadas as 8 variáveis no programa, conforme figura 4, ele apresenta o valor do CBR e da faixa dos mínimos e máximos valores que o grupo que ele se enquadra pode atingir.

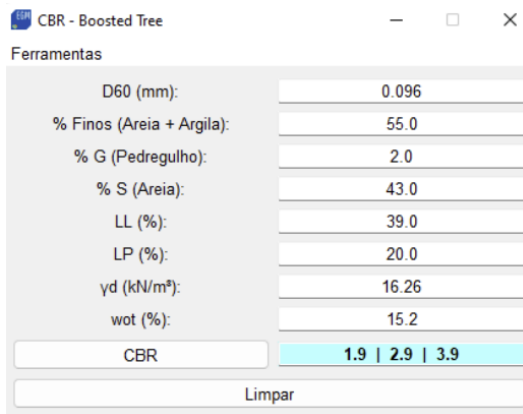
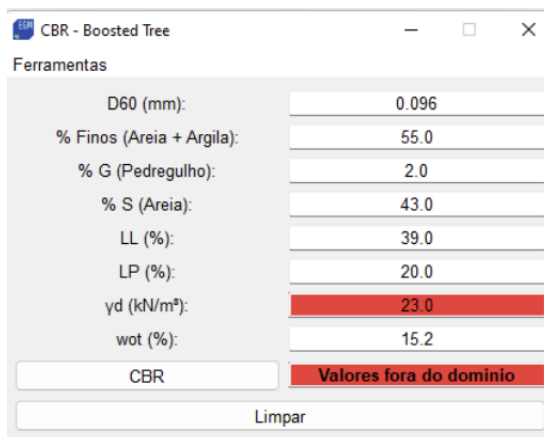


Figura 4. Programa em uso para obtenção do CBR.

A Figura 5 mostra uma das limitações dos algoritmos baseados em árvores de decisão, que é a impossibilidade de extrapolação, pois esses algoritmos agrupam valores não tendo a capacidade de prover valores para além das faixas que eles foram treinados.



Parâmetro	Valor
D60 (mm):	0.096
% Finos (Areia + Argila):	55.0
% G (Pedregulho):	2.0
% S (Areia):	43.0
LL (%):	39.0
LP (%):	20.0
γd (kN/m³):	23.0
wot (%):	15.2

CBR: **Valores fora do domínio**

Limpar

Figura 5. Uso fora da faixa que o programa foi desenvolvido.

5 CONCLUSÃO

Apesar dos novos modelos desenvolvidos na mecânica dos pavimentos, o CBR continua sendo um dos processos mais usados para quantificar a resistência do solo em projetos de aterro, barragens, estradas etc. Sabe-se que ensaios mais sofisticados ainda não são uma realidade para todo o país e que mesmo o ensaio de CBR é moroso e necessita, ao menos, 4 dias para se ter o resultado de uma amostra. Por essa problemática que foi desenvolvido o presente trabalho, com ele conseguimos viabilizar projetos com uma agilidade maior do que são usuais nas obras, apenas usando o aprendizado de máquina no desenvolvimento do programa.

Com o modelo desenvolvido tornou-se possível determinar com uma maior assertividade os valores de CBR em comparação com a literatura, pois, o que é observada nela, são formulações baseadas em pequenas quantidades de dados. Apesar de, em alguns casos, encontrar-se grandes valores de coeficiente de determinação, isso é gerado pela possível capacidade do modelo prever dentro do grupo de dados que ele foi exposto (*overfitting*) ou pela sua generalização para pequenas faixas de valores.

O estudo ainda se demonstrou valioso por corroborar com o crescimento do uso da inteligência artificial no aprendizado e criação de modelos eficazes em uma área que lida com problemas altamente não-lineares. Como sabe-se o CBR é um ensaio com diversas variáveis e os resultados no grupo de validação atingiram $R^2 = 0,994$.

Entende-se pelo algoritmo usado, que ele agrupa valores em pequenas faixas, sendo assim, ineficiente para extrapolações de resultados fora das usadas no trabalho, sendo validos para:

- $16,6 \% \leq LL \leq 74 \%$
- $10,6 \% \leq LP \leq 42,2 \%$
- $12,79 \text{ KN/m}^3 \leq \gamma_d \leq 22,73 \text{ KN/m}^3$
- $4,9 \% \leq Wot \leq 26,9 \%$
- $9 \% \leq F \leq 99 \%$
- $1 \% \leq S \leq 84,5 \%$
- $0 \% \leq G \leq 78 \%$
- $0 \text{ mm} \leq D60 \leq 10 \text{ mm}$

Portanto, o presente estudo teve como objetivo prever valores de CBR com parâmetros de fácil obtenção no laboratório e foi de grande valor para o desenvolvimento de projetos de engenharia, sem que com isso houvesse perda na precisão dos valores que seriam gerados em caso da execução do ensaio.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANJOS, G. J. M. *Acervo pessoal de dados*. 2022.
- BARDHAN, A. et. al. *Efficient computational techniques for predicting the California bearing ratio of soil in soaked conditions*. *Engineering Geology*. v. 291, p. 1-20, set. 2021.
- BARDHAN, A. et. al. *ELM-based adaptive neuro swarm intelligence techniques for predicting the California bearing ratio of soils in soaked conditions*. *Applied Soft Computing*. v. 110, p. 1-26, out. 2021.
- BHATT, S.; JAIN, P. K. *Prediction of California Bearing Ratio of Soils Using Artificial Neural Network*. *American International Journal of Research in Science, Technology, Engineering & Mathematics*. v. 8 (2), p. 156-161, set. 2014.
- BLACK, W. P. M. *The calculation of laboratory and in-situ values of California Bearing Ratio from bearing capacity data*. *Géotechnique*. v. 11, p. 14-21, mar. 1961.
- BLACK, W. P. M. *A Method of Estimating the California Bearing Ratio of Cohesive Soils from Plasticity Data*. *Géotechnique*. v. 12, p. 271-282, dez. 1962
- DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTE. DNIT 172/2016-ME. Solos – Determinação do Índice de Suporte Califórnia utilizando amostras não trabalhadas – Método de ensaio.
- FACELI, K. et. Al. *Inteligência Artificial: uma abordagem de aprendizado de máquina*. 1ª ed. Rio de Janeiro: Livros Técnicos e Científicos Editora Ltda, 2019.
- FERREIRA, J. G. H. M. *Tratamento de Dados Geotécnicos para Predição de Módulos de Resiliência de Solos e Britas Utilizando Ferramentas de Data Mining*. Tese de doutorado, COPPE/UFRJ: Rio de Janeiro, Brasil, 2008.
- HIGHT, D. W.; STEVENS, M. G. H. *An analysis of the California bearing ratio test in saturated clays*. *Géotechnique*. v. 32, p. 315-322, mar. 1982.
- MEDINA, J.; MOTTA, L.M.G. *Mecânica dos Pavimentos*. 3ª ed. Rio de Janeiro: Editora Interciência, 2015.
- TASKIRAN, T. *Prediction of California bearing ratio (CBR) of fine grained soils by AI methods*. *Advances in Engineering Software*. v. 41, p. 886-892, mar. 2010.
- TRONG, D. K. et. al. *On Random Subspace Optimization-Based Hybrid Computing Models Predicting the California Bearing Ratio of Soils*. *Materials*. v. 14, p. 1-20, out. 2021.
- Yildirim, B.; Gunaydin, O. *Estimation of California bearing ratio by using soft computing systems*. *Expert Systems with Applications*. v. 38, p. 6381-6391, maio. 2011.