

DOI: 10.47094/COBRAMSEG2024/99

AValiação DE MODELOS DE APRENDIZADO DE MÁQUINA PARA PREVISÃO DA DEFORMAÇÃO PERMANENTE DE SOLOS TROPICAIS

Francisco Michael Gonçalves Saraiva
IME, Rio de Janeiro, RJ, Brasil, michael.francisco@ime.eb.br

Antônio Carlos Rodrigues Guimarães
IME, Rio de Janeiro, RJ, Brasil, guimaraes@ime.eb.br

Orivalde Soares da Silva Júnior
IME, Rio de Janeiro, RJ, Brasil, orivalde@ime.eb.br

RESUMO: A deformação permanente é um parâmetro crucial no dimensionamento mecânico-empírico de pavimentos rodoviários, pois influencia diretamente a vida útil e a eficiência dessas estruturas. Devido à complexidade e à não-linearidade dos fenômenos envolvidos no estudo de pavimentação, os métodos tradicionais de análise, baseados em modelos empíricos ou teóricos, apresentam limitações e incertezas. Nesse contexto, as técnicas de aprendizado de máquina surgem como alternativas promissoras para modelar, classificar e otimizar os parâmetros relacionados aos solos e aos pavimentos. Este artigo propõe o estudo de diferentes técnicas de aprendizado de máquina para a seleção dos modelos mais promissores para a previsão da deformação permanente de solos. Para isso, utilizou-se uma biblioteca de aprendizado de máquina em Python, o Pycaret, e um solo analisado no ensaio triaxial de cargas repetidas. A partir do resultado do ensaio, foi criado um banco de dados com a tensão confinante, tensão de desvio, número de ciclos e deformação permanente. Os 19 modelos disponíveis na biblioteca foram hierarquizados pelo coeficiente de determinação (R^2) da validação cruzada com 10 dobras. Os resultados mostraram que o Extra Trees Regressor é o modelo de melhor desempenho nos dados de teste ($R^2 = 0,9983$), seguido pelo Decision Tree Regressor ($R^2 = 0,9948$), Gradient Boosting Regressor ($R^2 = 0,9938$) e outros. Além disso, é possível afirmar que as técnicas de aprendizado de máquina têm grande potencial de uso na previsão de deformação permanente, pois das 19 técnicas testadas, 8 apresentaram R^2 superior a 0,96 nos dados de teste e, portanto, são capazes de estimar a deformação permanente com alta precisão. Este trabalho contribui para a compreensão e a previsão da deformação permanente em solos tropicais, com potencial para melhorar a eficiência e a durabilidade dos pavimentos rodoviários construídos com esses solos. Além disso, o uso de aprendizado de máquina abre novas possibilidades para a modelagem e a previsão de comportamentos complexos na pavimentação.

PALAVRAS-CHAVE: Deformação permanente, Dimensionamento mecânico-empírico, Solos tropicais, Aprendizado de Máquina.

ABSTRACT: Permanent deformation is a crucial parameter in the empirical-mechanical design of road pavements, as it directly influences the lifespan and efficiency of these structures. Due to the complexity and non-linearity of the phenomena involved in pavement study, traditional analysis methods, based on empirical or theoretical models, present limitations and uncertainties. In this context, machine learning techniques emerge as promising alternatives to model, classify, and optimize parameters related to soils and pavements. This article proposes the study of different machine learning techniques for the selection of the most promising models for the prediction of permanent soil deformation. For this, a low-code machine learning library in Python, Pycaret, and soil analyzed in the repeated load triaxial test were used. From the test result, a database was created with the confining stress, shear stress, number of cycles, and permanent deformation. The 19 models available in the library were ranked by the coefficient of determination (R^2) of the 10-fold cross-validation. The results showed that the Extra Trees Regressor is the best-performing model on the test data ($R^2 = 0,9983$), followed by the Decision Tree Regressor ($R^2 = 0,9948$), Gradient Boosting Regressor ($R^2 = 0,9938$), and others. Furthermore, it is possible to affirm that machine learning techniques have great potential for use in predicting permanent deformation, as of the 19 techniques tested, 8 presented an R^2 greater than 0.96 on the test data and, therefore, are capable of estimating permanent deformation with high precision. This work

contributes to the understanding and prediction of permanent deformation in tropical soils, with the potential to improve the efficiency and durability of road pavements built with these soils. In addition, the use of machine learning opens up new possibilities for modeling and predicting complex behaviors in paving.

KEYWORDS: Permanent Deformation, Mechanistic-empirical pavement design, Tropical Soils, Machine Learning.

1 INTRODUÇÃO

Os métodos de dimensionamento de pavimentos passaram de puramente empíricos para métodos Mecanicistas-Empíricos (ME). Com a disponibilidade de microcomputadores de alta velocidade e métodos de teste sofisticados, a tendência para métodos mecanicistas é uma realidade. Esta evolução é um testemunho do progresso contínuo na engenharia de pavimentos e destaca a importância de adaptar novas tecnologias e metodologias (Huang, 2004).

A análise dos materiais constituintes das camadas do pavimento pelo ME é centrada no ensaio triaxial de cargas repetidas. Neste ensaio, o comportamento elasto-plástico são analisados e expressos, pelo módulo resiliente e pela deformação permanente (Santos, 2022). Este é um problema estrutural grave em pavimentos, por isso, algumas normas limitam o afundamento da trilha de roda para garantir a segurança e a eficiência dos pavimentos (Guimarães, 2009).

Embora a medição da deformação seja uma tarefa relativamente simples, sua previsão é extremamente complexa e requer consideração de vários fatores, incluindo as propriedades dos materiais do pavimento, as condições ambientais, distribuição de tensões e histórico de tensões ao longo da vida útil do pavimento (Lekarp, 2000).

Diversos modelos baseados em regressão foram propostos para descrever e prever a caracterização da deformação permanente dos materiais do pavimento. Esses modelos geralmente resultam de regressões e são função do número de ciclos de carga e/ou estado de tensões. No entanto, os modelos são limitados a prever a deformação permanente sob condições de múltiplas tensões e ciclos, mas geralmente falham em cobrir a complexidade do comportamento do solo (Alnedawi, 2021).

A ênfase no estudo de solos tropicais é crucial, pois suas características únicas, reconhecidas na engenharia geotécnica, também afetam seu comportamento em relação à deformação permanente. É importante ressaltar que esses solos são amplamente encontrados no Brasil. Portanto, os modelos de previsão de deformação permanente, originalmente desenvolvidos com base em solos de clima temperado, não serão adequados para prever a deformação nesse contexto tropical (Guimarães, 2009)

Observa-se que a aprendizagem de máquina, subcampo da Inteligência Artificial (IA), está se tornando comum em aplicações de engenharia geotécnica. Isso inclui previsão de explosões de rochas, monitoramento da saúde estrutural, análise de estabilidade de encostas e retroanálise do módulo de camada de pavimentos. Na área de subleitos e pavimentação, há um aumento significativo no número de publicações sobre esse assunto nos últimos anos. No entanto, o uso de técnicas de aprendizagem de máquina para prever a deformação permanente ainda é limitado. (Hao, 2022; Baghbani, 2022).

Assim, a previsão da deformação permanente em pavimentos rodoviários construídos com solos tropicais, é uma tarefa complexa que requer consideração de vários fatores e embora existam modelos baseados em regressão, muitas vezes não cobrem a complexidade do comportamento dos solos tropicais.

Portanto, este trabalho apresenta diferentes técnicas de inteligência artificial para prever a deformação permanente em pavimentos rodoviários construídos com solos tropicais.

O artigo está estruturado em: Introdução, estabelecendo o contexto e a relevância do estudo. A seção 2 se apresenta o aprendizado de máquinas com PyCaret. A seção 3 detalha os materiais e métodos utilizados na pesquisa. Resultados obtidos e discussão desses resultados nas seções 4 e 5. Ao final, apresenta-se a Conclusão, resumindo as descobertas e fazendo recomendações para pesquisas futuras.

2 APRENDIZADO DE MÁQUINA COM PYCARET

O PyCaret é uma biblioteca de aprendizado de máquina de baixo código em Python que permite que os cientistas de dados realizem experimentos completos com rapidez e eficiência. Para este estudo, foram abordadas 19 técnicas de regressão disponíveis no PyCaret. O nome de cada técnica pode ser observado nos resultados e maiores detalhamentos na documentação da biblioteca.

Os sistemas de aprendizado de máquina enfrentam desafios como a qualidade dos dados, o viés dos modelos e a complexidade dos algoritmos. Para lidar com isso, é comum dividir o conjunto de dados em dados de treinamento e dados de teste e uso de diferentes métricas para cada tipo de problema, como Coeficiente de Determinação (R^2), Erro Quadrático Médio (MSE), Erro Absoluto Médio (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Médio Absoluto (MAPE). O coeficiente de determinação é mais informativo e não possui as limitações das demais métricas citadas que podem variar de zero a infinito, Portanto, um único valor não fornece muita informação sobre o desempenho da regressão em relação à distribuição dos elementos de verdade fundamental (Chicco, Warrens e Jurman, 2021). Por isso, a escolha do R^2 como métrica de referência e a apresentação das demais métricas para avaliação dos erros.

As regressões buscam desenvolver um modelo com boa capacidade de generalização, ou seja, que tenha uma boa capacidade preditiva na presença de um conjunto de dados não utilizado para o treinamento do modelo. Isso pode ser alcançado através da validação cruzada, uma técnica estatística que ajuda a melhorar o desempenho dos modelos de aprendizado de máquina (Ikeagwuani, Nweke e Onah, 2023).

A validação cruzada K-fold é uma técnica usada em aprendizado de máquina para avaliar o desempenho de um modelo. Ela divide aleatoriamente o conjunto de treinamento em K subconjuntos distintos chamados de dobras (“folds”). O modelo é então treinado e avaliado K vezes. Em cada iteração, uma dobra é escolhida para avaliação e as outras K-1 dobras são usadas para treinamento (Gerón, 2021).

Por exemplo, se K for 5, o conjunto de treinamento seria dividido em 5 partes. Na primeira iteração, a primeira parte seria usada para avaliação e as outras 4 partes para treinamento. Na segunda iteração, a segunda parte seria usada para avaliação e as outras 4 (incluindo a primeira) para treinamento. Esse processo continuaria até que cada uma das 5 partes tivesse sido usada uma vez para avaliação. Os resultados de cada iteração são então médios para produzir uma métrica de desempenho final para o modelo.

Este método tem se mostrado eficaz para conjuntos de dados moderados, produzindo baixa variabilidade nas taxas de erro de teste e baixo viés em comparação com outros métodos de validação cruzada. Isso ocorre porque, ao treinar um modelo com validação cruzada k-fold, um conjunto menor de observações idênticas é usado no processo (Flach, 2012; Xiong et al., 2020).

3 MATERIAIS E MÉTODOS

O estudo em questão analisou um solo extraído de uma jazida localizada no município de Santa Maria da Vitória, na Bahia. Este solo apresenta granulometria heterogênea e quantidade significativa de laterita em processo de alteração.

O Índice de Suporte Califórnia (ISC) determinado como 94%, indicando uma alta capacidade de suporte de carga. A expansão da material medida em 0,1%, sugerindo uma baixa suscetibilidade a variações volumétricas em resposta a mudanças na umidade. A umidade ótima para compactação determinada como 11,4% e o peso específico máximo aparente seco medido em 2,02 g/cm³.

Importante ressaltar que o material foi caracterizado como não plástico, o que significa que não apresenta Limites de Liquidez (LL) e Plasticidade (LP). Esta característica é crucial para entender o comportamento do material em diversas condições de umidade.

Tabela 1. Pares de Tensões ensaiados

TC (MPa)	0,08	0,08	0,08	0,12	0,12	0,12
TD (MPa)	0,08	0,16	0,24	0,12	0,24	0,36

Em relação às classificações do solo, o material foi categorizado de acordo com várias normas. De acordo com a classificação do Transportation Research Board (TRB), o solo foi classificado como A-2-4. Segundo a classificação Unified Soil Classification System (USCS), o solo foi classificado como GM. E de acordo com

a classificação Miniatura, Compactado, Tropical (MCT), o solo foi classificado como NA'. Além desta caracterização, foram realizados ensaio foi realizado em uma célula triaxial com carga repetida com energia intermediária. Para este ensaio, foram executados seis pares de tensões confinante e de desvio (TC e TD) conforme apresentado na

Tabela 1. Foram aplicados 150.000 ciclos à frequência de 5 Hz em cada corpo de prova. As leituras foram feitas conforme recomendação da NORMA DNIT 179/2018- IE.

3.1 Metodologia

Inicialmente foi feita a coleta dos dados do ensaio Triaxial de Cargas Repetidas. Após a coleta de dados, o banco de dados foi transformado para as seguintes características: N, TC/PA, TD/PA, Def. P [%]. Neste contexto, N representa o número de ciclos, TC/PA é a tensão confinante dividida pela pressão atmosférica (PA), TD/PA é a tensão de desvio dividida pela pressão atmosférica, e Def. P [%] é a deformação permanente expressa em porcentagem. A pressão atmosférica (PA) é usada como referência para adequar as unidades de medida propostas por Guimarães (2009).

Após o ajuste do conjunto de dados, foi realizada uma Análise Exploratória de Dados (EDA). Esta análise permitiu uma melhor compreensão das características intrínsecas dos dados e suas inter-relações. Devido à grande variabilidade, uma transformação logarítmica na base 10 (\log_{10}) foi aplicada à coluna correspondente ao número de ciclos. Em seguida, o banco de dados foi dividido aleatoriamente, com 30% reservado para o conjunto de teste e os 70% restantes utilizados para o treinamento dos modelos. A coluna correspondente ao número de ciclos não transformado foi excluída durante o treinamento dos modelos.

A biblioteca de aprendizado de máquina Pycaret foi utilizada para a análise dos dados, permitindo o teste e comparação de 19 modelos de aprendizado de máquina diferentes. A eficácia dos modelos foi avaliada com base no coeficiente de determinação. As métricas apresentadas nesta etapa referem-se à média dos dados de teste da validação cruzada com 10 dobras. Conhecida como “10-fold cross-validation” é frequentemente utilizada em estudos semelhantes (Ikeagwuani, Nweke e Onah, 2023). Os modelos foram então treinados e ordenados com base no coeficiente de determinação (R^2) da validação cruzada. Os modelos com $R^2 > 0,9$ foram considerados de alto desempenho e avaliados no conjunto de teste para verificar sua generalização considerando a mesma proposição feita por Ikeagwuani et al. (2023).

Por fim, foram apresentados os modelos mais promissores para estimação da deformação específica do ensaio triaxial de cargas repetidas. O método encontra-se esquematizado na Figura 1.

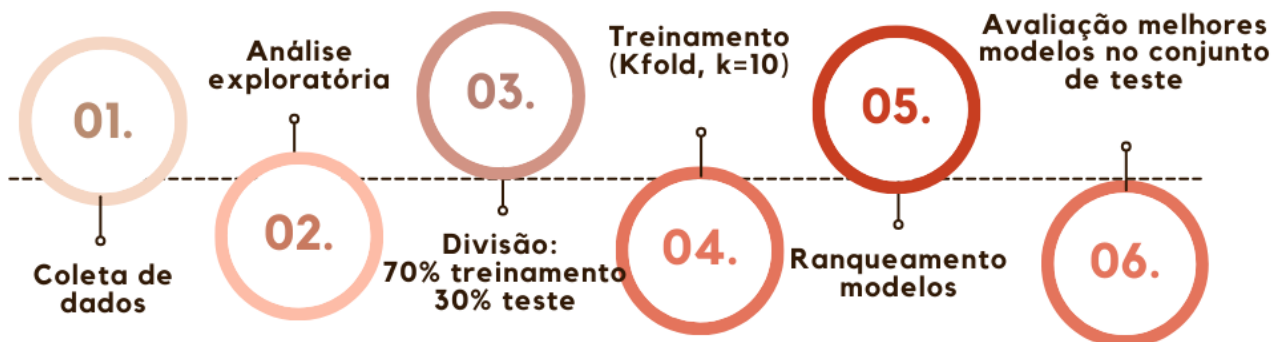


Figura 1. Fluxograma do Método

4 RESULTADOS

A coleta das 534 leituras do ensaio Triaxial de Cargas repetidas são representados na *Figura 2*.




Figura 2 - Dados do Ensaio Triaxial de Cargas Repetidas

Foi realizada uma análise integrada das quatro variáveis do ensaio Triaxial de Cargas Repetidas: N (Número de ciclos), TC/PA (Tensão confinante/Pressão atmosférica), TD/PA (Tensão de desvio/Pressão atmosférica) e Def. P [%] (Deformação permanente em %). Na Tabela 2 são apresentados os resultados da análise exploratória.

Tabela 2. Análise Exploratória dos Dados

Característica	N	TC/PA	TD/PA	Def. P [%]
Contagem	534,000	534,000	534,000	534,000
Média	30393,034	0,983	2,075	0,568
Desvio Padrão	34922,643	0,195	0,944	0,191
Mínimo	1,000	0,781	0,796	0,047
25%	800,000	0,789	1,231	0,458
50%	21000,000	0,982	1,917	0,613
75%	43000,000	1,178	2,540	0,697
Máximo	150000,000	1,183	3,792	0,910

- N (Número de ciclos): A variável N apresenta uma grande variação, com um desvio padrão de 34922.64. O número de ciclos varia de 1 a 150000, com uma média de aproximadamente 30393. A mediana é 21000, indicando que metade dos ciclos são inferiores a esse valor.
- TC/PA (Tensão confinante/Pressão atmosférica): A tensão confinante, quando normalizada pela pressão atmosférica, tem uma média de aproximadamente 0.98, com um mínimo de 0.78 e um máximo de 1.18. A mediana é muito próxima da média, sugerindo uma distribuição simétrica. O desvio padrão é 0.19, indicando uma variabilidade moderada nos dados.
- TD/PA (Tensão de desvio/Pressão atmosférica): A tensão de desvio, quando normalizada pela pressão atmosférica, tem uma média de aproximadamente 2.07. O valor mínimo é 0.80 e o máximo é 3.79. O desvio padrão é 0.94, indicando uma variação moderada nos dados.
- Def. P [%] (Deformação permanente em %): A deformação permanente varia de 0.05% a 0.91%, com uma média de 0.57%. A mediana é 0.61%, sugerindo que metade das observações têm uma deformação permanente inferior a esse valor. O desvio padrão é 0.19, indicando uma variabilidade moderada nos dados.

O desvio padrão para a variável explicativa N é relativamente elevado, indicando uma dispersão considerável dos valores em torno das médias. Esta variabilidade pode impactar a precisão de modelos de aprendizado de máquina, tornando necessário o uso de técnicas como normalização ou transformação dos dados. Para tratar a variável N, optou-se por aplicar uma transformação logarítmica na base 10 (N_log). Esta estratégia pode contribuir para melhorar a estabilidade do modelo e facilitar a interpretação dos resultados.

Com base nos resultados obtidos após a análise exploratória dos dados e transformação logarítmica do número de ciclos, foi executado o PyCaret configurado com as características apresentadas na Tabela 3. Os modelos foram avaliados com base nas métricas apresentadas anteriormente. Os resultados são apresentados na Tabela 4 com destaque para os modelos com um coeficiente de determinação (R^2) maior que 0,9 que foram considerados como tendo ótimo desempenho e foram avaliados com dados de teste.

Tabela 3. Configuração do PyCaret

Descrição	Valor
Variável Alvo	Def. P [%]
Tipo de Alvo	Regressão
Formato Original dos Dados	534 linhas e 5 colunas
Formato dos Dados Transformados	534 linhas e 4 colunas
Formato do Conjunto de Treinamento Transformado	373 linhas e 4 colunas
Formato do Conjunto de Teste Transformado	161 linhas e 4 colunas
Recursos Ignorados	1 (variável N)
Recursos Numéricos	3
Pré-processamento	Ativado
Gerador de Folds	KFold (10 folds)

Tabela 4. Resultados da Validação Cruzada K-fold

Modelo	MAE	MSE	RMSE	R^2	MAPE
Extra Trees Regressor	0,0031	0,0001	0,0070	0,9983	0,0081
Gradient Boosting Regressor	0,0073	0,0002	0,0126	0,9951	0,0181
Random Forest Regressor	0,0073	0,0002	0,0144	0,9934	0,0184
Extreme Gradient Boosting	0,0080	0,0002	0,0148	0,9926	0,0203
Light Gradient Boosting Machine	0,0104	0,0004	0,0187	0,9891	0,0301
Decision Tree Regressor	0,0087	0,0004	0,0190	0,9876	0,0206
K Neighbors Regressor	0,0095	0,0005	0,0219	0,9842	0,0346
AdaBoost Regressor	0,0259	0,0011	0,0332	0,9668	0,0572
Bayesian Ridge	0,0606	0,0058	0,0762	0,8298	0,1454
Ridge Regression	0,0607	0,0058	0,0763	0,8298	0,1461
Linear Regression	0,0604	0,0058	0,0762	0,8297	0,1449
Least Angle Regression	0,0604	0,0058	0,0762	0,8297	0,1449
Huber Regressor	0,0581	0,0061	0,0777	0,8214	0,1342
Passive Aggressive Regressor	0,0726	0,0072	0,0841	0,7909	0,1667
Orthogonal Matching Pursuit	0,0872	0,0119	0,1083	0,6495	0,2229
Lasso Regression	0,1578	0,0361	0,1897	-0,0361	0,4127
Elastic Net	0,1578	0,0361	0,1897	-0,0361	0,4127
Lasso Least Angle Regression	0,1578	0,0361	0,1897	-0,0361	0,4127
Dummy Regressor	0,1578	0,0361	0,1897	-0,0361	0,4127

Após a seleção dos melhores modelos, mantidos os mesmos hiperparâmetros, eles foram submetidos à validação com dados de teste. A Figura 3 mostra que o desempenho foi igualmente satisfatório com os dados de teste, com todos os R^2 superiores a 0,96.

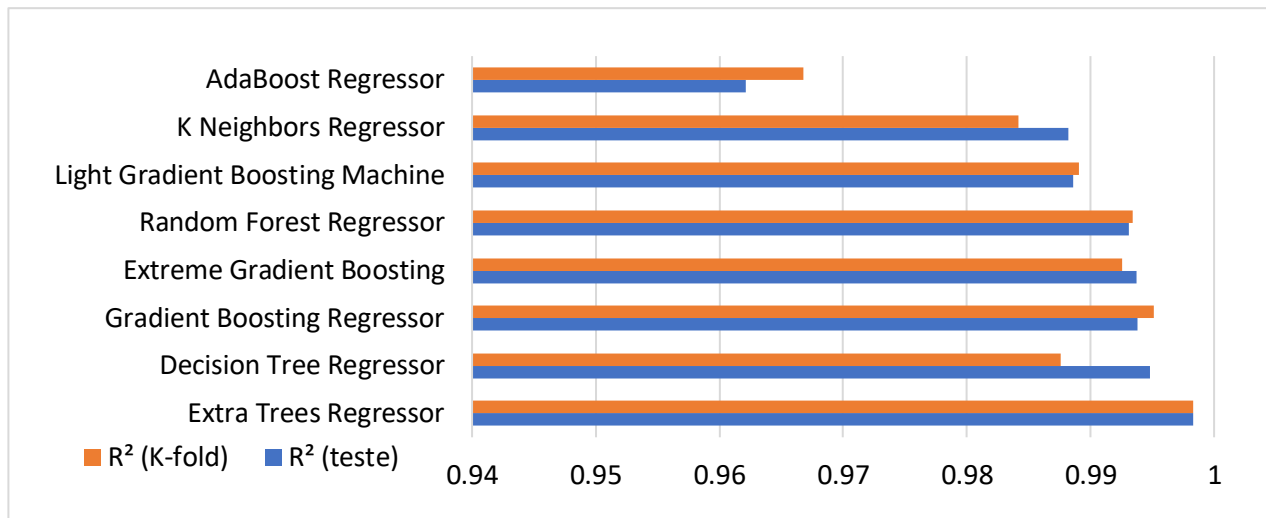


Figura 3. Resultado nos Dados de Teste

5 DISCUSSÃO

Este estudo utilizou uma abordagem inovadora de aprendizado de máquina para prever a deformação permanente de solos tropicais, com o ensaio triaxial de cargas repetidas como base. O Extra Trees Regressor se destacou como o modelo de melhor desempenho, seguido de perto pelo Decision Tree Regressor, Gradient Boosting Regressor e outros modelos avaliados.

A análise detalhada dos resultados destacou o grande potencial das técnicas de aprendizado de máquina na previsão da deformação permanente. De um total de 19 técnicas avaliadas, 8 apresentaram um coeficiente de determinação nos dados de teste superior a 0,96, indicando uma precisão notável na estimativa da deformação permanente.

As técnicas de aprendizado de máquina têm demonstrado um desempenho impressionante em diversos campos, incluindo soluções geotécnicas. Estudos recentes, como os de Hao e Pabst (2022) e Baghbani et al. (2022), destacaram o potencial dessas técnicas.

Este trabalho representa uma contribuição significativa para a compreensão e previsão da deformação permanente em solos tropicais, abrindo novos horizontes para melhorar a eficiência e durabilidade dos pavimentos rodoviários construídos com esses solos. Além disso, a aplicação do aprendizado de máquina abre novas possibilidades para a modelagem e previsão de comportamentos complexos na pavimentação, impulsionando avanços substanciais na engenharia de pavimentos.

Com o alto desempenho demonstrado por essas técnicas, pode-se sugerir a redução do número de pares de tensões de ciclos no ensaio. Isso levaria a uma economia significativa de tempo e recursos.

6 CONCLUSÃO E RECOMENDAÇÕES

Neste estudo, foram investigadas 19 técnicas de aprendizado de máquina com o objetivo de identificar as mais promissoras para a previsão da deformação permanente de solos tropicais. A análise foi realizada utilizando um conjunto de dados que não havia sido visto pelos modelos durante a fase de treinamento.

Os resultados indicaram oito técnicas com grande potencial para atingir o objetivo proposto. Estas incluem: Extra Trees Regressor, Decision Tree Regressor, Gradient Boosting Regressor, Extreme Gradient Boosting, Random Forest Regressor, Light Gradient Boosting Machine, K Neighbors Regressor e AdaBoost Regressor.

Cada uma dessas técnicas apresentou um desempenho notável, demonstrando a capacidade de generalizar bem para dados não vistos. Isso sugere que esses modelos podem ser eficazes na previsão da deformação permanente de solos tropicais em cenários do mundo real.

No entanto, é importante ressaltar que este estudo está limitado ao solo ensaiado. Portanto, recomenda-se que futuras pesquisas avaliem o desempenho desses modelos em relação às interpolações e extrapolações. Isso permitirá uma compreensão mais completa de como esses modelos podem se comportar quando aplicados a diferentes tipos de solo ou a condições de solo que variam das utilizadas neste estudo.

Além disso, seria benéfico explorar outras técnicas de aprendizado de máquina que não foram incluídas neste estudo. Com o rápido avanço da área de aprendizado de máquina, novas técnicas estão sendo constantemente desenvolvidas e algumas delas podem oferecer melhorias significativas no desempenho.

Em resumo, este estudo fornece uma base para futuras pesquisas na previsão da deformação permanente de solos tropicais usando técnicas de aprendizado de máquina. As técnicas identificadas aqui como as mais promissoras oferecem um ponto de partida valioso para esses esforços futuros.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALNEDAWI, A.; NEPAL, K. P.; AL-AMERI, R. Effect of loading frequencies on permanent deformation of unbound granular materials. *International Journal of Pavement Engineering*, v. 22, n. 8, p. 1008–1016, jul. 2021. ISSN 1029-8436, 1477-268X. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10298436.2019.1656807>.
- BAGHBANI, A.; CHOUDHURY, T.; COSTA, S.; REINER, J. Application of artificial intelligence in geotechnical engineering: A state-of-the-art review. *Earth-Science Reviews*, v. 228, p. 103991, maio 2022. ISSN 00128252. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0012825222000757>.
- CHICCO, D.; WARRENS, M.; JURMAN, G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Comput. Sci.*, 2021.
- FLACH, P. *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*. 2012.
- GERÓN, A. *Mãos à obra: aprendizado de máquinas com scikit-learn e tensorflow*. [S.l.]: Alta Books, 2021. ISBN 978-85-508-0902-1.
- GUIMARÃES, A. *Um Método Mecanístico Empírico para a Previsão da Deformação Permanente em Solos Tropicais Constituintes de Pavimentos*. Tese (Doutorado) — UFRJ, Rio de Janeiro, 2009.
- HAO, S.; PABST, T. Experimental Investigation and Prediction of the Permanent Deformation of Crushed Waste Rock Using an Artificial Neural Network Model. *International Journal of Geomechanics*, v. 22, n. 5, p. 04022032, maio 2022. ISSN 1532-3641, 1943-5622. Disponível em: <https://ascelibrary.org/doi/10.1061/%28ASCE%29GM.1943-5622.0002363>.
- HUANG, Y. H. *Pavement analysis and design*. 2nd ed. ed. Upper Saddle River, NJ: Pearson/Prentice Hall, 2004. ISBN 978-0-13-142473-9.
- IKEAGWUANI, C. C.; NWEKE, C.; ONAH, H. N. Prediction of resilient modulus of fine-grained soil for pavement design using KNN, MARS, and random forest techniques. *Arabian Journal of Geosciences*, 2023.
- LEKARP, F.; ISACSSON, U.; DAWSON, A. State of the Art. II: Permanent Strain Response of Unbound Aggregates. *Journal of Transportation Engineering*, v. 126, n. 1, p. 76–83, jan. 2000. ISSN 0733-947X. Publisher: American Society of Civil Engineers. Disponível em: <https://ascelibrary.org/doi/10.1061/%28ASCE%290733-947X%282000%29126%3A1%2876%29>.
- SANTOS, J. T. A. d.; SILVA, P. A. L. d.; GUIMARÃES, A. C. R. Determinação da incerteza de medição nos ensaios de deformação permanente de solos lateríticos. *TRANSPORTES*, v. 30, n. 2, p. 2678–2678, ago. 2022. ISSN 2237-1346. Disponível em: <https://www.revistatransportes.org.br/anpet/article/view/2678>.
- XIONG, Z.; CUI, Y.; LIU, Z.; ZHAO, Y.; HU, M.; HU, J. Evaluating explorative prediction power of machine learning algorithms for materials discovery using k-fold forward cross-validation. *Computational Materials Science*, 2020.