

DOI: 10.47094/COBRAMSEG2024/761

## Previsão da taxa de penetração do TBM através de abordagens de aprendizado de máquina

Dianelys Vega Ruiz

Pesquisadora de pós-doutorado, Escola Politécnica da USP, São Paulo, Brasil, [dvegaruiz@usp.br](mailto:dvegaruiz@usp.br)

Tarcisio Barreto Celestino

Professor Doutor, Escola de Engenharia de São Carlos-USP, São Paulo, Brasil, [tbcelestino@gmail.com](mailto:tbcelestino@gmail.com)

Marcos Massao Futai

Professor Titular, Escola Politécnica da USP, São Paulo, Brasil, [futai@usp.br](mailto:futai@usp.br)

**RESUMO:** A máquina de perfuração de rocha, ou tuneladora (TBM), é uma máquina de engenharia para escavação de túneis subterrâneos em ambientes geológicos complexos. A previsão do desempenho do TBM é um fator essencial para o planejamento, estimativa de custos e para garantir o sucesso da escavação de túneis. A estimativa de parâmetros operacionais assim como as propriedades da rocha e as características do maciço rochoso, são fundamentais para definir a condição ideal de operação de uma tuneladora. A taxa de penetração tem sido definida na literatura como a principal medida do desempenho do TBM e é usada para avaliar a viabilidade de usar uma tuneladora em uma determinada condição de solo e prever a taxa de avanço. Incorporar os efeitos do tipo de rocha em modelos de previsão de desempenho pode melhorar a precisão das estimativas. Por esse motivo, vários tipos de modelos, teóricos e empíricos tem sido propostos na literatura. Contudo, a estimativa precisa do desempenho da máquina ainda pode ser um desafio, principalmente em condições geológicas complexas, uma vez que diferentes tipos de rochas respondem de forma diferente a forças de corte do TBM. Nesse sentido, o objetivo deste trabalho é apresentar abordagens mais modernas baseadas em aprendizado de máquina com o intuito de encontrar modelos preditivos mais precisos da taxa de penetração do TBM.

**PALAVRAS-CHAVE:** desempenho do TBM, perfuradora de túneis, taxa de penetração, modelo preditivo.

**ABSTRACT:** The rock boring machine, or tunnel boring machine (TBM), is an engineering machine for excavating underground tunnels in complex geological environments. Predicting the TBM performance is an essential factor for planning, cost estimation and ensuring the success of tunnel excavation. The estimation of operational parameters, as well as the rock properties and the rock mass characteristics, are fundamental to defining the ideal operating condition of a tunneling boring machine. The penetration rate has been defined in the literature as the main measure of TBM performance, and it is used to evaluate the feasibility of using a tunnel boring machine in a given ground condition and to predict the advance rate. Incorporating the effects of rock types into performance prediction models can improve the estimates accuracy. For this reason, several theoretical and empirical models have been proposed in the literature. However, the accurate estimation of the TBM performance is still a challenge, especially in complex geological conditions, as different rock types respond differently to TBM cutting forces. In this regard, this work aims to present modern approaches based on machine learning to predict TBM penetration rate with higher accuracy.

**KEYWORDS:** TBM performance, tunnel boring machine, penetration rate, predictive model

## 1 INTRODUÇÃO

A tunneladora é uma máquina usada para a escavação de túneis com uma cabeça de corte circular equipada com cortadores de disco, brocas de arrasto, raspadores e facas de corte (Figura 1). No passado, métodos convencionais de escavação de túneis, como métodos de perfuração e explosão e/ou escavadeiras mecânicas eram frequentemente empregados. Hoje em dia, com os avanços na tecnologia de TBMs, o uso de TBMs tem aumentado significativamente (YOUNG KO; MO SON; KON KIM, 2017).



Figura 1. TBM de blindagem dupla (double-shield) (a) durante a montagem e (b) uma visão da cabeça de corte (HASSANPOUR et al., 2009).

Os TBMs são usados para escavar em quase todos os maciços rochosos e sob condições geológicas variadas, variando desde solo mole a rochas duras. Os TBMs tornaram-se uma alternativa aos métodos tradicionais, trazendo várias vantagens que incluem a rápida escavação e taxas de avanço em comparação com métodos alternativos, oferecendo uma condição de trabalho mais segura. A previsão de desempenho de TBMs e a determinação de alguns parâmetros de projeto são elementos críticos no planejamento de um projeto de escavação mecânica pois tornaram-se cruciais para garantir o sucesso da operação de TBMs em rocha dura (MIRAHMADI; TABEEI; DEHKORDI, 2017).

A taxa de penetração é a principal medida do desempenho do TBM e é usada para avaliar a viabilidade de usar uma tunneladora em uma determinada condição de solo e prever a taxa de avanço da mesma. Os principais parâmetros na estimativa do desempenho da máquina são resistência da rocha, tenacidade, descontinuidade no maciço rochoso, tipo de TBM e suas especificações, entre outros. É importante definir uma penetração adequada em projetos de TBM para melhorar a eficiência do túnel, mas ainda há falta de estratégias otimizadas de penetração. Os operadores de TBM tendem a ajustar os parâmetros operacionais para atingir o máximo penetração, levando a um desgaste severo do cortador em túneis de rocha dura. Por isso, torna-se fundamental compreender os fatores que influenciam esse parâmetro, o que permite uma estimativa mais precisa dos tempos de parada e escavação.

Prever a taxa de penetração é de importância crucial para projetos de mineração e civis, pois pode minimizar os riscos associados aos custos de capital (XU et al., 2019). No entanto, é uma tarefa complexa e desafiadora devido à interação entre a tunneladora e o maciço rochoso. Muitos estudos destacam o uso de técnicas empíricas e teóricas na previsão do desempenho do TBM (HASSANPOUR et al., 2009), (STYPULKOWSKI; BERNARDEAU; JAKUBOWSKI, 2018), (PAN et al., 2019), (BENATO; ORESTE, 2015). Contudo, a estimativa precisa da taxa de penetração ainda pode ser um desafio, principalmente em condições geológicas complexas, devido à variabilidade de tipos de solos e rochas.

Na atualidade, com o aumento do desenvolvimento de técnicas computacionais, vários autores tem aplicado abordagens baseadas em aprendizado de máquina para previsão do desempenho de TBMs com resultados satisfatórios (XU et al., 2019), (KOOPIALIPOOR et al., 2019), (SALIMI et al., 2016), (FU; ZHANG; SONG, 2022), (EFTEKHARI; EFTEKHARI, 2022). Deve-se mencionar também que as capacidades de desempenho dos modelos de múltiplas variáveis são superiores às dos modelos de uma única variável. Isso se deve ao uso de parâmetros de entrada mais relacionados. Portanto, parece que as técnicas de inteligência

artificial (IA) e aprendizado de máquina (ML) podem ser a melhor escolha a ser aplicada para prever o desempenho do TBM usando vários parâmetros de entrada (XU et al., 2019).

Baseado nas premissas anteriores, este trabalho tem por objetivo testar duas abordagens bem conhecidas de aprendizado de máquina, Máquina de Vetores de Suporte (SVM) e Regressão do Processo Gaussiano (GPR), e avaliar seu uso como modelos preditivos da taxa de penetração do TBM. Para isso, são selecionados e analisados dois bancos de dados da literatura.

## 2 MATERIAIS E MÉTODOS

### 2.1 Banco de dados 1

O Queens Water Tunnel # 3, estágio 2 possui cerca de 7,5 km de comprimento e 7,0 m de diâmetro, foi escavado abaixo do Brooklyn e do Queens a uma profundidade média de 200 m abaixo do nível do mar no condado de Queens, no centro-oeste, usando um TBM de alta potência. Testemunhos de rocha foram retirados do lado do túnel em 151 locais diferentes ao longo do túnel de rocha dura fraturada, a fim de realizar testes de propriedades mecânicas de rocha intacta e testes de penetração de punção. Da mesma forma, os dados de campo do TBM foram analisados para obter a taxa de penetração do TBM em cada local de amostragem. Assim foi estabelecido o banco de dados composto pelos seguintes parâmetros: 1) resistência à compressão uniaxial (UCS), 2) resistência à tração do ensaio brasileiro (BTS), 3) índice de inclinação de pico ou Peak Slope Index (PSI), 4) orientação dos planos de fratura ( $\beta$ ), 5) distância entre os planos de fratura (DPW) e 6) taxa de penetração do TBM (PR). Na tabela 1 mostra-se a descrição estatística deste banco de dados.

Tabela 1. Descrição estatística do banco de dados 1 (Fonte: YAGIZ, 2008)

|          | UCS (MPa) | BTS (MPa) | PSI (kN/mm) | $\beta$ (°) | DPW (m) | PR (m/h) |
|----------|-----------|-----------|-------------|-------------|---------|----------|
| Min      | 118.3     | 6.7       | 25          | 2           | 0.05    | 1.27     |
| Máx      | 199.7     | 11.4      | 58          | 89          | 2       | 3.07     |
| Média    | 149.88    | 9.55      | 34.64       | 44.57       | 1.02    | 2.05     |
| Desvio   | 22.02     | 0.86      | 8.39        | 23.13       | 0.64    | 0.36     |
| Variança | 484.76    | 0.74      | 70.45       | 534.95      | 0.41    | 0.13     |

Número de mostras: 153

### 2.2 Banco de dados 2

O túnel PSRWT<sup>1</sup> foi escavado na área montanhosa da Península da Malásia com uma faixa de elevação de 100 a 1400 m. Três seções do túnel foram planejadas para escavação com TBM. Para estabelecer o banco de dados, os dados coletados foram divididos em duas categorias: (a) observações de campo e (b) testes de laboratório. No total, uma distância de 12649 m do túnel PSRWT para diferentes TBMs foi investigada. Para isso, foram selecionados segmentos com comprimento típico de 10 m e, por fim, foram observados/medidos 1286 segmentos. Vários parâmetros tais como o grau de intemperismo, resistência do maciço rochoso, espaçamento de descontinuidades, número de famílias de juntas, energia de perfuração, entre outros foram medidos e registrados cuidadosamente em cada segmento. Além disso, foram realizados testes de laboratório em mais de 150 amostras de blocos coletadas no local do túnel. O banco de dados usado neste estudo está composto por: 1) índice de qualidade de rocha (RQD), 2) Rock Mass Rating (RMR), 3) resistência à compressão uniaxial (UCS), 4) resistência à tração do ensaio brasileiro (BTS), 5) força de impulso da cabeça de corte (Fn), 6) revoluções por minuto (RPM) e 7) taxa de penetração (PR). Na tabela 2 mostra-se a descrição estatística deste banco de dados.

<sup>1</sup> Pahang-Selangor raw water transfer (PSRWT)

Tabela 2. Descrição estatística do banco de dados 2 (Fonte: KOOPIALIPOOR et al., 2019)

|          | RQD<br>(%) | UCS<br>(MPa) | RMR    | BTS<br>(MPa) | Fn<br>(kN) | RPM<br>(rev/min) | PR<br>(m/h) |
|----------|------------|--------------|--------|--------------|------------|------------------|-------------|
| Min      | 10         | 49           | 46     | 4.69         | 107.39     | 4.83             | 1.28        |
| Máx      | 95         | 185          | 95     | 15.1         | 511.53     | 11.79            | 3.75        |
| Média    | 54.96      | 120.53       | 69.69  | 9.47         | 278.16     | 8.58             | 2.4         |
| Desvio   | 27.09      | 36.78        | 12.92  | 2.44         | 122.11     | 2.29             | 0.53        |
| Variança | 733.66     | 1352.56      | 167.03 | 5.97         | 14910.55   | 5.23             | 0.29        |

Número de amostras: 100

### 2.3 Metodologia

Os bancos de dados apresentados anteriormente foram utilizados para treinar e validar os diferentes algoritmos de aprendizado de máquina. Para isso foi utilizado o Regression Learner App da caixa de ferramentas de estatística e aprendizado de máquina do software MATLAB R2022a, que permite treinar de forma manual ou automática modelos de regressão para prever dados usando aprendizado de máquina supervisionado. Como parte do estudo, foi realizada uma análise multivariada com os bancos de dados selecionados por meio de *Support Vector Machine* (SVM) e *Gaussian Process Regression* (GPR). Os parâmetros de entrada e saída dos modelos analisados são mostrados na Tabela 3.

Tabela 3. Parâmetros de entrada e saída dos modelos testados

| Banco de dados | Fonte                       | Entrada                     | Saída |
|----------------|-----------------------------|-----------------------------|-------|
| 1              | (YAGIZ, 2008)               | UCS, PSI, $\beta$ , DP      | PR    |
| 2              | (KOOPIALIPOOR et al., 2019) | RQD, UCS, BTS, RMR, TF, RPM | PR    |

Neste trabalho, o coeficiente de determinação ( $R^2$ ), o Erro Médio Quadrático (MSE), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Médio Absoluto (MAE) são utilizados para avaliar a acurácia e eficiência dos modelos, os quais são calculados de acordo com as seguintes expressões

$$R^2 = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \cdot (Y_i - \bar{Y})^2}} \quad (1)$$

$$MSE = \frac{1}{N} \sum_{i=1}^n (X_i - Y_i)^2 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (X_i - Y_i)^2} \quad (3)$$

$$MAE = \frac{1}{N} |X_i - Y_i| \quad (4)$$

onde  $X_i$  e  $Y_i$  são os valores previstos e medidos da observação  $i$  analisada,  $N$  é o número de observações e,  $\bar{X}$  e  $\bar{Y}$  são a média dos valores previstos e medidos, respectivamente.

### 3 RESULTADOS E DISCUSSÃO

Neste estudo foram aplicadas técnicas modernas de aprendizado de máquina para tentar encontrar modelos preditivos de taxa de penetração de TBM mais precisos. Dentre as técnicas modernas, SVM e GPR são abordagens poderosas e capazes de resultar em achados mais realistas no processo de previsão. Portanto, esses métodos foram aplicados para predição do desempenho do TBM. Os resultados obtidos para cada modelo e banco de dados são mostrados nas Tabelas 4 e 5.

Tabela 4. Resultados dos modelos de SVM e GRP para prever o PR com o Banco de dados 1

| Modelo                       | RMSE   | R <sup>2</sup> | MSE   | MAE    | Hiperparâmetros   |
|------------------------------|--------|----------------|-------|--------|---|
| SVM<br>Linear                | 0.2343 | 0.58           | 0.055 | 0.1927 | Kernel function linear, kernel scale automatic, box constraint automatic, epsilon automatic, standarsize data=true  |
| SVM<br>Quadratic             | 0.2269 | 0.61           | 0.051 | 0.1921 | Kernel function quadratic, kernel scale automatic, box constraint automatic, epsilon automatic, standarsize data=true   |
| SVM<br>Cubic                 | 0.2178 | 0.64           | 0.047 | 0.1751 | Kernel function cubic, kernel scale automatic, box constraint automatic, epsilon automatic standarsize data=true  |
| SVM<br>Fine Gaussian         | 0.2993 | 0.32           | 0.09  | 0.2257 | Kernel function Gaussian, kernel scale 0,5, box constraint automatic, epsilon automatic, standarsize data=true  |
| SVM<br>Medium Gaussian       | 0.2254 | 0.61           | 0.051 | 0.1838 | Kernel function Gaussian, kernel scale 2, box constraint automatic, epsilon automatic, standarsize data=true  |
| SVM<br>Coarse Gaussian       | 0.2589 | 0.49           | 0.067 | 0.2069 | Kernel function Gaussian, kernel scale 8, box constraint automatic, epsilon automatic standarsize data=true   |
| GPR<br>Rotational Quadractic | 0,2149 | 0,65           | 0,046 | 0,1803 | Basis function constant, Kernel function Rotational Quadratic, use isotropic kernel: true, Kernel scale automatic, signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true |
| GPR<br>Squared Exponential   | 0,2149 | 0,65           | 0,046 | 0,1803 | Basis function constant, Kernel function Squared Exponential, use isotropic kernel: true, Kernel scale automatic, Signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true  |
| GRP<br>Matern 5/2            | 0,213  | 0,65           | 0,045 | 0,178  | Basis function constant, Kernel function Matern 5/2, use isotropic kernel: true, Kernel scale automatic, Signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true           |
| GPR<br>Exponential           | 0,2112 | 0,66           | 0,045 | 0,1736 | Basis function constant, Kernel function Exponential, use isotropic kernel: true, Kernel scale automatic, Signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true          |

Como pode ser observado na Tabela 4, os valores de R<sup>2</sup> variaram na faixa de 0,32-0,66 para os dez algoritmos usando o banco de dados 1. O GRP forneceu o melhor resultado, sendo o valor de R<sup>2</sup> igual a 0,66. O melhor R<sup>2</sup> obtido neste estudo é igual ao reportado por (YAGIZ, 2008) que usou regressão linear por forward stepwise, podendo-se concluir que as técnicas utilizadas na análise deste banco de dados não trouxeram melhoria com respeito ao modelo de (YAGIZ, 2008).

Por outro lado, na Tabela 5 mostra-se que os resultados obtidos a partir da análise do banco de dados 2 forneceram valores de R<sup>2</sup> variando na faixa de 0,71-0,94 para os dez algoritmos testados. De igual forma, o GRP forneceu o melhor resultado, com valor de R<sup>2</sup> igual a 0,94. Em comparação aos resultados obtidos por (KOOPIALIPOOR et al., 2019), que usou redes neurais artificiais (ANN) e redes neurais profundas (DNN) para estimar a taxa de penetração e, obteve como melhores valores de R<sup>2</sup>=0,72 e R<sup>2</sup>=0,93 para ANN e DNN, respectivamente, os modelos preditivos através de SVM e GPR mostram-se mais precisos. No entanto, a

seleção do melhor modelo preditivo é um desafio, uma vez que os valores obtidos para  $R^2$  e RMSE são muito próximos entre si (KOOPIALIPOOR et al., 2019).

Tabela 5. Resultados dos modelos de SVM e GRP para prever o PR com Banco de dados 2

| Modelo                       | RMSE   | $R^2$ | MSE   | MAE    | Hiperparâmetros   |
|------------------------------|--------|-------|-------|--------|---|
| SVM<br>Linear                | 0.1694 | 0.9   | 0.029 | 0.1282 | Kernel function linear, kernel scale automatic, box constraint automatic, epsilon automatic, standarsize data=true  |
| SVM<br>Quadratic             | 0.1621 | 0.91  | 0.026 | 0.116  | Kernel function quadratic, kernel scale automatic, box constraint automatic, epsilon automatic, standarsize data=true   |
| SVM<br>Cubic                 | 0.1484 | 0.92  | 0.022 | 0.1098 | Kernel function cubic, kernel scale automatic, box constraint automatic, epsilon automatic standarsize data=true  |
| SVM<br>Fine Gaussian         | 0.2905 | 0.71  | 0.084 | 0.2304 | Kernel function Gaussian, kernel scale 0,61, box constraint automatic, epsilon automatic, standarsize data=true   |
| SVM<br>Medium Gaussian       | 0.1628 | 0.91  | 0.027 | 0.1168 | Kernel function Gaussian, kernel scale 2,4, box constraint automatic, epsilon automatic, standarsize data=true  |
| SVM<br>Coarse Gaussian       | 0.1731 | 0.9   | 0.03  | 0.1323 | Kernel function Gaussian, kernel scale 9,8, box constraint automatic, epsilon automatic standarsize data=true   |
| GPR<br>Rotational Quadractic | 0,1599 | 0,91  | 0,026 | 0,1237 | Basis function constant, Kernel function Rotational Quadratic, use isotropic kernel: true, Kernel scale automatic, signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true |
| GPR<br>Squared Exponential   | 0,1638 | 0,91  | 0,027 | 0,1295 | Basis function constant, Kernel function Squared Exponential, use isotropic kernel: true, Kernel scale automatic, Signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true  |
| GRP<br>Matern 5/2            | 0,1579 | 0,91  | 0,025 | 0,1231 | Basis function constant, Kernel function Matern 5/2, use isotropic kernel: true, Kernel scale automatic, Signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true           |
| GPR<br>Exponential           | 0,1327 | 0,94  | 0,018 | 0,099  | Basis function constant, Kernel function Exponential, use isotropic kernel: true, Kernel scale automatic, Signal standard deviation automatic, sigma automatic, standarsize data=true, Optimize numeric parameters: true          |

Na Figura 2 mostram-se os diagrama de ajuste e os erros entre a taxa de penetração medida e prevista para os dois melhores modelos preditivos obtidos para cada banco de dados, e na Figura 3 mostram-se os diagramas de distribuição da taxa de penetração prevista e medida correspondentes para cada um desses modelos, respectivamente.

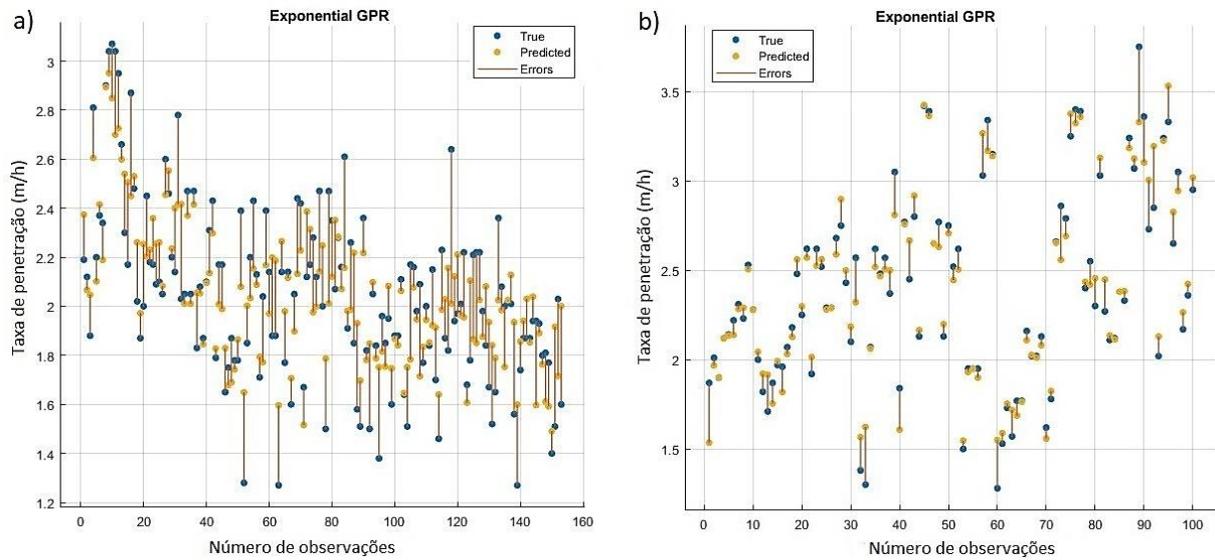


Figura 2. Diagrama de ajuste da Taxa de Penetração medida e prevista para o a) Banco de dados 1 e o b) Banco de dados 2.

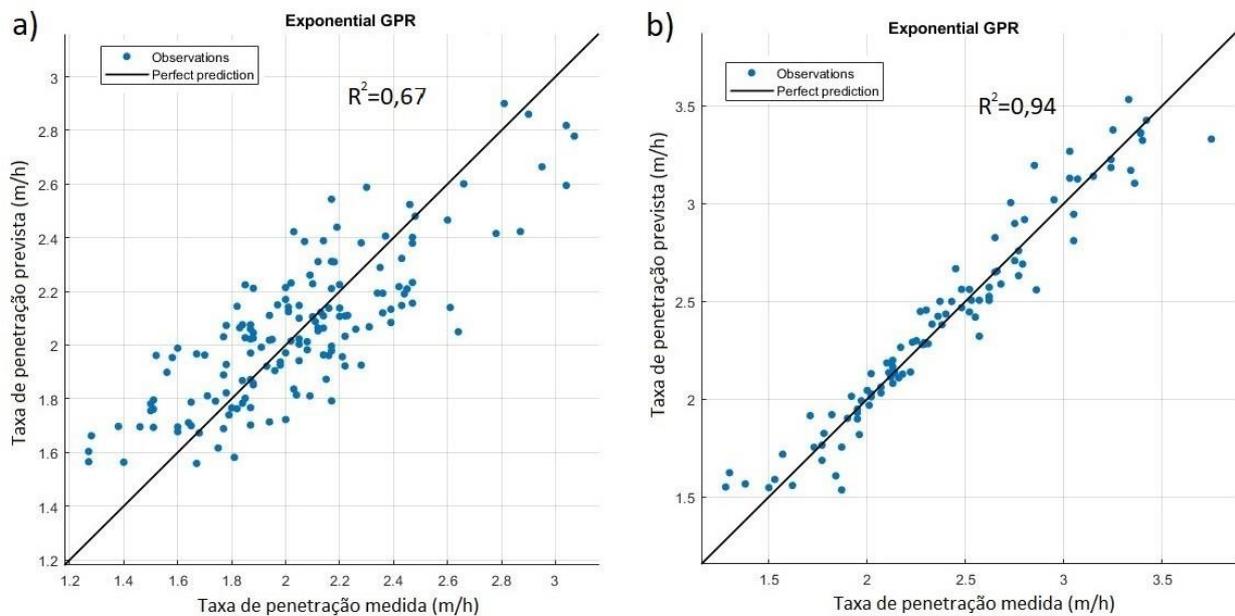


Figura 3. Diagrama de distribuição da taxa de penetração medida e prevista para o a) Banco de dados 1 e o b) Banco de dados 2.

### 3 CONCLUSÕES

Neste trabalho foram avaliados modelos baseados em aprendizado de máquina para previsão da taxa de penetração do TBM. Para isso, foram adotados dois bancos de dados da literatura, correspondentes ao Queens Water Tunnel #3 em Nova York e o túnel PSRWT na Malásia. Os bancos de dados foram construídos principalmente a partir de dados de campo, parâmetros do TBM durante a escavação do túnel e ensaios em laboratório. Os dados foram então analisados por meio de Máquinas de Vetores de Suporte (SVM) e modelos de Regressão de Processo Gaussiano (GPR), considerando diferentes conjuntos de parâmetros de entrada e, a taxa de penetração (PR) estabelecida como parâmetro de saída. Os resultados mostraram que o melhor modelo predictivo foi o GPR exponencial, com valores obtidos de  $R^2$  de 0,66 para o banco de dados 1 e 0,94

para o banco de dados 2, respectivamente. Baseado nisso, pode-se concluir que o método GPR exponencial tem a maior precisão ( $R^2$  máximo e RMSE, MSE e MAE mínimos) entre todos os outros modelos preditivos avaliados neste estudo. Além disso os valores de  $R^2$  obtidos neste estudo foram superiores aos obtidos por (KOOPIALIPOOR et al., 2019). Portanto, o método mostra-se uma ferramenta promissora para ser utilizada na previsão da taxa de penetração de TBMs em túneis. Contudo, para uma avaliação rigorosa destes algoritmos, a principal limitação continua sendo contar com suficientes dados de campo coletados durante excavação de túneis com TBM para diferentes condições geológicas, assim como parâmetros de diferentes tipos de máquinas em operação. Para trabalhos futuros, sugere-se avaliar outros algoritmos de aprendizado de máquina e a utilização de um banco de dados mais abrangente.

## REFERÊNCIAS BIBLIOGRÁFICAS

- BENATO, A.; ORESTE, P (2015). Prediction of penetration per revolution in TBM tunneling as a function of intact rock and rock mass characteristics. *International Journal of Rock Mechanics and Mining Sciences*, v. 74, p. 119–127.
- EFTEKHARI, M.; EFTEKHARI, N (2022). A Predictive Model for Estimating the TBM Penetration Rate Based on Hybrid ICA-ANN and DEA-AHP Algorithms. *Geotechnical and Geological Engineering*, v. 40, n. 6, p. 3191–3209.
- FU, T.; ZHANG, T.; SONG, X (2022). A Novel Hybrid Transfer Learning Framework for Dynamic Cutterhead Torque Prediction of the Tunnel Boring Machine. *Energies*, v. 15, n. 8, p. 2907, 1.
- HASSANPOUR, J. et al. (2009). Developing new equations for TBM performance prediction in carbonate-argillaceous rocks: a case history of Nowsod water conveyance tunnel. *Geomechanics and Geoengineering*, v. 4, n. 4, p. 287–297, 27.
- KOOPIALIPOOR, M. et al. (2019). Application of deep neural networks in predicting the penetration rate of tunnel boring machines. *Bulletin of Engineering Geology and the Environment*, v. 78, n. 8, p. 6347–6360, 17.
- MIRAHMADI, M.; TABEELI, M.; DEHKORDI, M. S (2017). Estimation of the specific energy of tunnel boring machine using post-failure behaviour of rock mass. case study: karaj-tehran water conveyance tunnel in iran. *Journal of Engineering Science and Technology*, v. 12, n. 9, p. 2488–2503.
- PAN, Y. et al. (2019). Full-Scale Linear Cutting Tests to Propose Some Empirical Formulas for TBM Disc Cutter Performance Prediction. *Rock Mechanics and Rock Engineering*, v. 52, n. 11, p. 4763–4783.
- SALIMI, A. et al. (2016). Application of non-linear regression analysis and artificial intelligence algorithms for performance prediction of hard rock TBMs. *Tunnelling and Underground Space Technology*, v. 58, p. 236–246.
- STYPULKOWSKI, J. B.; BERNARDEAU, F. G.; JAKUBOWSKI, J. (2018) Descriptive statistical analysis of TBM performance at Abu Hamour Tunnel Phase I. *Arabian Journal of Geosciences*, v. 11, n. 9, 30.
- XU, H. et al. (2019) Supervised Machine Learning Techniques to the Prediction of Tunnel Boring Machine Penetration Rate. *Applied Sciences*, v. 9, n. 18, p. 3715, 6.
- YAGIZ, S. (2008). Utilizing rock mass properties for predicting TBM performance in hard rock condition. *Tunnelling and Underground Space Technology*, v. 23, n. 3, p. 326–339.
- YOUNG KO, T.; MO SON, S.; KON KIM, T (2017). Comparative study of TBM performance prediction models. *ASEM 17 Anais...* In: *The 2017 World Congress on Advances in Structural Engineering and Mechanics (ASEM 17)*. [s.d.].