

# Aplicação de Técnicas de Aprendizado de Máquina na Previsão de Vazão em Meios Porosos

Vinicius O. Costa<sup>1</sup>, Angélica N. Caseri<sup>2</sup>, Sinesio Pesco<sup>3</sup>

Departamento de Matemática, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brasil

Estudos recentes mostram a importância de se prever a vazão do óleo na indústria do petróleo, principalmente pela questão de monitoramento e manutenção de reservatórios [1]. Séries históricas de produção em reservatórios de petróleo revelam correlações entre diversas propriedades, em particular, observa-se uma correlação entre vazão e pressão que será utilizada para prever valores da vazão. Em outros estudos [2], [3] foram mostradas aplicações de modelos preditivos para a previsão da vazão do óleo.

O objetivo deste trabalho foi prever os dados futuros da vazão em uma série histórica de um poço produtor considerando a base de dados histórica da vazão e pressão e utilizando algoritmos de machine learning, árvore de decisão [4] e gradient boosting [5].

Árvore de decisão é um algoritmo supervisionado de aprendizado de máquina que se baseia no conceito de dividir para conquistar. Nele é criado um grafo no formato de árvore e são classificados pontos de interesse de forma que a previsão de pontos futuros possa ocorrer de forma mais precisa.

Assim como o método anterior, gradient boosting é um algoritmo supervisionado de aprendizado de máquina que se baseia em fornecer modelos preditivos satisfatórios baseados em modelos preditivos fracos, os quais surgem em sua maioria de árvores de decisão.

No decorrer deste estudo foi utilizada uma base de dados com valores de pressão e vazão gerados de forma sintética baseados no comportamento real entre vazão e pressão de óleo. O gráfico abaixo (Figura 1) apresenta os dados utilizados.




Figura 1: Dados usados na pesquisa

Foi adotada a métrica de performance MAPE para validar o método aplicado. Esta métrica calcula o erro médio absoluto percentual dos valores em que foram feitas as previsões, ou seja, uma média da diferença em módulo entre os valores reais ( $x_i$ ) e os valores achados na previsão ( $y_i$ ).

<sup>1</sup>viniciuscosta0300@gmail.com

<sup>2</sup>angelikacaseri@gmail.com

<sup>3</sup>sinesio@puc-rio.br

$$MAPE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \cdot 100 \quad (1)$$

Para compor a previsão de um único passo de tempo da vazão foram consideradas as últimas sete observações da vazão e as últimas sete observações da pressão. Além disso, a série deverá ser dividida uma parte para treinamento e outra para teste, 75% e 25% dos dados respectivamente.

Dessa forma, puderam ser aplicados os algoritmo da árvore de decisão e gradient boosting e obter um resultado a ser observado. Para comparar a eficácia da previsão feita pelos modelos foi considerado um modelo naive, em que foi calculada a média móvel dos últimos sete passos de tempo da vazão.

Os resultados, utilizando o MAPE, são exibidos na Tabela 1:

Tabela 1: Comparação dos Modelos.

Método	MAPE
Média Móvel	0,74
Árvore de Decisão	0,14
Gradient Boosting	0,27

A partir dos resultados apresentados observa-se que o método apresentou resultados satisfatórios. Nota-se que o MAPE relacionado ao método de árvore de decisão é o mais otimizado examinando os modelos estudados.

Como continuação deste trabalho nota-se relevante a comparação com outros algoritmos, assim como a verificação da performance da solução com uma base de dados reais.

## Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico e Petrobras como parte do projeto TCBR 485.

## Referências

- [1] “INSIM-FT in three-dimensions with gravity”. Em: **Journal of Computational Physics** 380 (2019), pp. 143–169. ISSN: 0021-9991. DOI: <https://doi.org/10.1016/j.jcp.2018.12.016>.
- [2] Isabel Gonçalves, Thiago Silva, Abelardo Barreto e Sinesio Pesco. “Predicting oil field production using the Random Forest algorithm”. Em: **Anais Estendidos do XXXV Conference on Graphics, Patterns and Images**. SBC, 2022, pp. 134–139. DOI: [10.5753/sibgrapi.est.2022.23277](https://doi.org/10.5753/sibgrapi.est.2022.23277).
- [3] Yuejin Luo, P.A. Bern Bern e B.D. Chambers. “Flow-Rate Predictions for Cleaning Deviated Wells”. Em: **Paper presented at the IADC/SPE Drilling Conference, New Orleans, Louisiana** (1992). DOI: <https://doi.org/10.2118/23884-MS>.
- [4] Lior Rokach e Oded Maimon. “Decision Trees”. Em: vol. 6. Jan. de 2005, pp. 165–192. DOI: [10.1007/0-387-25465-X\\_9](https://doi.org/10.1007/0-387-25465-X_9).
- [5] Alexey Natekin e Alois Knoll. “Gradient Boosting Machines, A Tutorial”. Em: **Frontiers in neurorobotics** 7 (dez. de 2013), p. 21. DOI: [10.3389/fnbot.2013.00021](https://doi.org/10.3389/fnbot.2013.00021).