

# Avanços na predição de propriedades petrofísicas com integração de métodos convencionais e inteligência artificial

DOI: 10.5281/zenodo.17012712

Victoria Pires da Silva <sup>a\*</sup>

Despite advancements in renewable energy sources, fossil fuels — particularly oil — continue to dominate the global energy matrix, accounting for approximately 86% of global demand in 2024. Oil production involves high costs and complex technological processes, making accurate reservoir characterization essential before drilling operations. This step relies on analyzing parameters such as porosity and permeability, which are crucial for estimating a rock formation's storage and fluid flow capacity. Traditionally, reservoir characterization combines core sample analysis and geophysical well logging, supported by empirical models. However, in highly heterogeneous carbonate reservoirs, these methods often face significant limitations. To address these challenges, Zhang et al. proposed a hybrid model that integrates empirical correlations with machine learning algorithms, trained using actual core and well log data. The results showed high predictive performance, highlighting the potential of combining traditional methods with artificial intelligence to achieve more accurate and efficient reservoir characterization.

Mesmo com os avanços nas fontes renováveis, os combustíveis fósseis, especialmente o petróleo, ainda dominam a matriz energética mundial, representando cerca de 86% da demanda global em 2024. A produção de petróleo envolve altos custos e complexos processos tecnológicos, tornando essencial a caracterização precisa dos reservatórios antes da perfuração. Essa etapa baseia-se na análise de parâmetros como porosidade e permeabilidade, fundamentais para estimar a capacidade de armazenamento e fluxo do óleo nas rochas. Tradicionalmente, a caracterização envolve dados de testemunhos de rocha e perfilagem geofísica, aliados a modelos empíricos. No entanto, em reservatórios carbonáticos altamente heterogêneos, essas abordagens enfrentam limitações. Buscando superar esses desafios, Zhang *et al.* propuseram um modelo híbrido integrando correlações empíricas e algoritmos de *machine learning*, treinado com dados reais. Os resultados demonstraram alto desempenho, evidenciando o potencial da integração entre métodos.

<sup>a</sup>Universidade de Brasília (UnB). Campus Darcy Ribeiro. Instituto de Química (IQ/UnB).

\*E-mail: vickiprs@gmail.com

**Palavras-chave:** Caracterização de reservatórios; porosidade; permeabilidade; *machine learning*; petróleo.

Recebido em 18 de julho de 2025,  
Aprovado em 15 de agosto de 2025,  
Publicado em 31 de agosto de 2025.

## Introdução

Mesmo com os avanços no desenvolvimento de fontes renováveis, a indústria do petróleo ainda exerce um impacto significativo sobre a demanda global de energia. A 74ª edição da Revisão Estatística da Energia Mundial, elaborada pelo *Energy Institute* (EI) em parceria com a Kearney e a KPMG, analisou os dados energéticos referentes ao ano de 2024.<sup>1</sup> Verificou-se um aumento na demanda mundial por energia, sendo que aproximadamente 86% da matriz energética global continua composta por fontes fósseis, com destaque para o petróleo.<sup>1</sup> Os combustíveis fósseis derivados do petróleo são obtidos por meio de um processo que envolve a identificação, caracterização, exploração e perfuração de reservatórios localizados em rochas porosas que armazenam o óleo, além de etapas subsequentes, como o tratamento e refino.<sup>2</sup>

A extração de petróleo envolve processos complexos e tecnologias avançadas, que demandam altos investimentos. A perfuração de um poço, assim como a instalação das estruturas de produção, envolve custos extremamente altos.

Por isso, os processos de identificação e caracterização de reservatórios são essenciais para estimar a produção potencial e avaliar o custo-benefício das operações de perfuração e produção.<sup>2</sup>

Identificada uma região com considerável probabilidade de conter um reservatório de petróleo, caracterizada pela presença de rochas porosas, que armazenam e permitem o fluxo do óleo, e rochas selantes, que atuam como barreiras, o próximo passo é a caracterização da área por meio de estudos geológicos das formações rochosas presentes, de forma a descrever o reservatório e estimar sua qualidade, realizando sua modelagem para avaliar seu potencial exploratório.<sup>3,4</sup>

Para a caracterização, a análise de parâmetros como a permeabilidade — capacidade de um meio poroso de permitir a passagem de fluidos — e a porosidade — razão entre o volume poroso e o volume total da rocha — é fundamental, pois estes estão diretamente relacionados à capacidade da rocha de armazenar e conduzir o óleo. Por meio desses parâmetros, diversos modelos empíricos tradicionais podem

ser empregados para a predição e caracterização da área do reservatório. Contudo, em reservatórios com alta heterogeneidade na estrutura e distribuição de poros, composição complexa e processos de transformação típicos de rochas carbonáticas, a avaliação e a predição desses parâmetros constituem grandes desafios.<sup>4</sup>

No campo do petróleo, existem dois métodos principais para determinar esses parâmetros: as medições em testemunhos de rocha (*core measurements*) e os dados de perfilagem geofísica (*well logs*). O primeiro consiste na análise de amostras de rocha do reservatório para determinar suas propriedades físicas e químicas, enquanto o segundo envolve a utilização de instrumentos e sensores especializados para a medição dessas propriedades *in situ*.<sup>2, 4</sup>

No entanto, apesar de essenciais, as medições em testemunhos de rocha demandam tempo, alto custo e apresentam limitações, o que dificulta a obtenção de parâmetros representativos para toda a formação rochosa em questão. Já os dados de perfilagem geofísica relacionados à porosidade — como o perfil de densidade total e o perfil por nêutrons — e aqueles que abrangem tanto a porosidade quanto a permeabilidade — como os perfis sônicos e de ressonância magnética nuclear (RMN) — muitas vezes não fornecem interpretações precisas da formação, devido a incerteza nos parâmetros empíricos utilizados nas correlações, além da baixa adaptabilidade das mesmas às condições específicas de cada reservatório. Esse já é um desafio comum na caracterização de formações, mas, no caso de reservatórios de rochas compactas e altamente heterogêneas, esses problemas se tornam ainda mais evidentes.<sup>4</sup>

Com o avanço da tecnologia, o uso da inteligência artificial na caracterização de reservatórios tem se mostrado promissor, especialmente na área de métodos de aprendizado de máquina (*Machine Learning*), que envolve o desenvolvimento de algoritmos capazes de identificar padrões em dados, possibilitando a realização de previsões e estimativas fundamentadas. Pesquisas avançadas no setor petrolífero têm aplicado técnicas de *machine learning* integrando dados de perfilagem geofísica e de testemunhos para interpretar intervalos de poços, auxiliando na predição de parâmetros e, frequentemente, alcançando bons resultados.<sup>5</sup>

Visando aprimorar a confiabilidade e a eficiência na determinação de parâmetros, além de desenvolver métodos mais econômicos e rápidos, Zhang *et al.* analisaram amostras de *core measurements* e dados de perfilagem geofísica do

reservatório dolomítico do Cambriano Inferior, na Bacia de Tarim, com o objetivo de desenvolver um modelo preditivo de parâmetros utilizando *machine learning* e modelos empíricos adequados, apresentando assim uma nova alternativa integrada e completa para a caracterização de poços.<sup>4</sup>

## Metodologia

O artigo de Zhang e colaboradores analisou 253 amostras de testemunhos de rocha (*core samples*) e dados de perfilagem geofísica — incluindo raio gama (GR), densidade aparente (DEN) e tempo de trânsito sônico (DT) — de cinco poços dolomíticos na Bacia de Tarim, medindo-se porosidade e permeabilidade por meio de métodos laboratoriais específicos, respectivamente, com um porosímetro a gás QK-98 e um permeâmetro a gás GDS-90FA. Após um processo de limpeza e secagem, as porosidades foram determinadas com base na Lei de Boyle. Já na medição da permeabilidade das rochas, aplicaram-se métodos de estado estacionário e de declínio de pressão, com correção de Klinkenberg nos valores obtidos. Diversos modelos empíricos tradicionais foram aplicados para avaliar a adaptabilidade das correlações e caracterizar o reservatório. A análise do Indicador de Zona de Fluxo (FZI) e sua versão modificada (FZI\*), combinadas com a técnica de classificação “*Discrete Rock Type*” (DRT), foi utilizada para agrupar as amostras em diferentes unidades. Em seguida, foram empregados métodos de *machine learning*, como redes neurais artificiais (*BP neural networks*) e máquinas de vetores de suporte (SVM), otimizados por algoritmos genéticos (GA) e por enxame de partículas (PSO). Os modelos foram treinados com dados de 203 amostras de treino e validados com dados de 50 amostras de teste. Por fim, foi proposta uma abordagem integrada, combinando a análise FZI/FZI\*-DRT com técnicas de *machine learning* para a predição de porosidade e permeabilidade em reservatórios carbonáticos altamente heterogêneos.

No presente artigo, foi realizada uma revisão bibliográfica abrangente para explorar estudos relativos à aplicações de inteligência artificial na indústria de petróleo, em especial na caracterização de reservatórios petrolíferos. A metodologia envolveu a utilização das palavras-chave “*oil reservoir*”, “*reservoir characterization*”, “*machine learning*”, “porosidade” e “permeabilidade”. A busca foi conduzida em várias plataformas e bases de dados, incluindo o Periódicos CAPES através do acesso *cafe*, o *Elsevier* e o *Science Direct*. Foram selecionados livros e artigos relevantes acerca do assunto. A análise contemplou revisões sistemáticas e estudos experimentais, visando proporcionar uma visão abrangente

sobre as mais diversas técnicas de modelagem de poços. Além disso, foram considerados critérios de inclusão e exclusão para filtrar artigos que não atendiam aos padrões de qualidade ou relevância para o tema.

Resultados e discussão

Análises de Core Measurements e Well Logs

Inicialmente, na pesquisa conduzida por Zhang *et al.*, foram realizadas análises de testemunhos de rocha (*core measurements*), nas quais os valores de porosidade variaram entre 0,21% e 16,6%, sendo que mais de 85% das amostras apresentaram porosidade inferior a 4%. Esses dados evidenciam não apenas a heterogeneidade da formação, mas também uma predominância de zonas com baixa porosidade. Em relação à permeabilidade, os valores oscilaram de 0,001 mD a 10 mD, com aproximadamente metade das amostras situadas abaixo de 0,1 mD, o que reforça tanto a baixa permeabilidade do reservatório quanto sua variabilidade espacial. Na análise de perfilagem geofísica, foram adquiridos parâmetros como raio gama (GR), densidade aparente (DEN) e tempo de trânsito sônico (DT), os quais fornecem informações relevantes sobre porosidade e permeabilidade. Os resultados obtidos com essas medições reforçaram a natureza heterogênea do reservatório.<sup>4</sup>

Análise das Correlações Empíricas

Para a construção do modelo integrado, os dados referentes às 253 amostras foram divididos em dois grupos: 203 amostras para o treinamento do modelo e 50 para teste do mesmo. Inicialmente, cinco correlações foram aplicadas aos dados de treinamento para avaliar a adequação do modelo na predição da permeabilidade na área analisada e na caracterização do reservatório. Todos esses modelos foram desenvolvidos com base nas propriedades microscópicas dos poros. A Tabela 1 apresenta a tabela com cada correlação utilizada, indicando o autor, o tipo, a equação-base e observações relevantes sobre cada uma.<sup>4</sup>

No Modelo 1 (Modelo de Berg), cada diâmetro de grão (dg) possui uma relação específica entre porosidade e permeabilidade. No entanto, ao comparar os valores de diâmetro de grão estimados pelo modelo com os dados disponíveis na literatura para as rochas analisadas, observou-se uma superestimação significativa, o que evidencia que o modelo de Berg não é adequado para representar com precisão a relação porosidade-permeabilidade nas condições específicas do reservatório estudado.<sup>4</sup>

Tabela 1. Descrição das Cinco Correlações Modelo de Porosidade-Permeabilidade. Extraído da referência 4.

Índice	Autor	Tipo	Correlação
1	Berg (1975)	grain-based	$k = 8,4 \times 10^{-2} d_g^2 \varphi^{5,1}$
2	Winland (1980)	pore-based	$\log(r35) = -0,996 + 0,588 \log(k) - 0,864 \log(\varphi)$
3	Jennings and Lucia (2003)	fabric-based	$\log(k) = (9,7982 - 12,0838 \log(\lambda)) + (8,6711 - 8,2965 \log(\lambda)) \log(\varphi_{ip})$
4	Amaefule <i>et al.</i> (1993)	grain and pore-based	$k = 1014,24 (FZI)^2 \frac{\varphi^3}{(1 - \varphi)^2}$
5	Mirzaei - Paibam <i>et al.</i> (2015)	grain and pore-based	$k = 1014,24 (FZI^*)^2 \varphi$

No Modelo 2 (Modelo de Winland), os valores de raio do gargalo de poro (r35) obtidos variam de 29 nm a 40,7 µm, com amostras classificadas desde nanoporosas até megaporosas. Esses valores coincidem com os encontrados na literatura para as rochas estudadas, indicando que o modelo, embora ainda demande mais dados para ajuste fino, é adequado para representar a relação entre porosidade e permeabilidade do reservatório analisado.<sup>4</sup>

No Modelo 3 (Modelo de Jennings e Lucia), os tecidos texturais da rocha (*rock fabrics*) foram utilizados como base para a correlação, considerando o tamanho e a distribuição dos grãos. Uma análise comparativa entre a distribuição medida da permeabilidade e da porosidade e o gráfico de *rock fabrics* mostrou que as amostras não se enquadravam nas classes definidas por esse modelo. Isso ocorre porque ele é aplicável a amostras com porosidades superiores a 3,5%, enquanto as rochas deste estudo apresentam porosidades inferiores a 4%. Esses resultados reforçam que o método não é adequado para reservatórios com baixa porosidade e baixa permeabilidade, como o analisado.<sup>4</sup>


Os Modelos 4 (Ameafule) e 5 (Mirzaei-Paiaman) utilizam características tanto dos grãos quanto dos poros como base, sendo aplicados na identificação de unidades de fluxo hidráulico e na classificação de rochas. O Modelo 4 emprega o Indicador de Zona de Fluxo (FZI), enquanto o Modelo 5 utiliza uma versão aprimorada, o FZI\*. Neste estudo, os valores de FZI e FZI\* foram calculados a partir da porosidade e permeabilidade das amostras de testemunho, e a técnica de agrupamento *Discrete Rock Type* (DRT) foi utilizada para sua classificação.<sup>4</sup>

### Análise dos Métodos de *machine learning*

Além das correlações tradicionais, foram aplicados seis métodos de *machine learning* para avaliar a predição de propriedades em reservatórios dolomíticos heterogêneos. Os modelos testados foram: Regressão Linear, Redes Neurais Artificiais (ANN), Máquina de Vetores de Suporte (SVM), PSO-SVM, *Random Forest* e *Gradient Boosting*. Dentre eles, o PSO-SVM destacou-se pelo melhor desempenho, apresentando elevados coeficientes de determinação ( $R^2$ ) e baixos erros estatísticos, o que demonstra sua precisão.<sup>4</sup>

**Figura 1.** Fluxograma para a Predição Abrangente e Integrada dos Parâmetros de Porosidade e Permeabilidade.

Extraído da referência 4.



### Desenvolvimento de Modelo Integrado

Para aprimorar a caracterização do reservatório, foi proposta uma abordagem integrada que combina a predição dos índices FZI e FZI\* via *machine learning* com a análise de *Discrete Rock Type* (DRT) — técnica utilizada na caracterização de reservatórios para classificar as rochas em diferentes unidades distintas, com base em propriedades como porosidade, permeabilidade, tamanho e distribuição dos poros. Essa estratégia permite a estimativa indireta da permeabilidade a partir da porosidade e da classificação das unidades de fluxo hidráulico. A metodologia integrada superou os métodos que realizam a predição direta da permeabilidade por *machine learning*, especialmente em cenários de alta heterogeneidade e com dados limitados. Os resultados indicam que dividir o problema em etapas distintas reduz o impacto da heterogeneidade na qualidade das análises, aumentando significativamente a precisão e a capacidade de generalização do modelo, contribuindo assim para uma avaliação mais confiável e eficiente de reservatórios complexos. A Figura 1 ilustra o fluxograma da metodologia integrada proposta para a predição abrangente da porosidade e da permeabilidade.<sup>4</sup>

### Conclusões

A caracterização de reservatórios na indústria do petróleo é uma etapa essencial para o estudo de novos poços e seu potencial de exploração. Contudo, apesar dos avanços tecnológicos, essa etapa ainda está sujeita a erros e interpretações imprecisas, especialmente em reservatórios compactos e altamente heterogêneos. Parâmetros como permeabilidade e porosidade são fundamentais para a predição da área do reservatório, assim como para a avaliação da capacidade de armazenamento e do fluxo de fluidos na formação rochosa.<sup>4</sup>

Atualmente, no campo da pesquisa petrolífera, a caracterização de formações rochosas envolve tanto a análise direta de amostras de rocha (*core measurements*) quanto o uso de dados obtidos por sensores especializados via perfilação geofísica (*well logs*). A partir desses dados, são desenvolvidas e aplicadas correlações empíricas para prever o comportamento da área de interesse. No entanto, modelos baseados em inteligência artificial, especialmente os de aprendizado de máquina (*machine learning*), têm sido cada vez mais explorados como alternativa a essas correlações tradicionais.<sup>4</sup>

Apesar de promissores, tanto os métodos tradicionais quanto os baseados em *machine learning* apresentam limitações em formações rochosas com grande variabilidade de porosidade e permeabilidade, sobretudo quando há predominância de valores extremamente baixos desses parâmetros. Além disso, a aquisição e processamento de dados de testemunhos e perfilagem são processos custosos e demorados, o que ressalta a necessidade de abordagens mais eficientes.<sup>4</sup>

Visando superar essas limitações e integrar as vantagens de cada abordagem, Zhang *et al.* propuseram um modelo híbrido que combina técnicas de *machine learning* com correlações empíricas, utilizando dados de *core measurements* e perfilagem geofísica para o treinamento e validação dos algoritmos. Os resultados demonstraram alta acurácia e potencial de aplicação prática, evidenciando que a integração entre métodos tradicionais e inteligência artificial pode ser um caminho promissor para aprimorar a caracterização de reservatórios.<sup>4</sup>

O desenvolvimento de modelos mais precisos é essencial para evitar investimentos mal direcionados e perfurações em áreas de baixo custo-benefício, uma vez que a etapa de perfuração é altamente onerosa. Assim, a adoção de metodologias integradas pode representar um avanço significativo no desempenho e na sustentabilidade da indústria petrolífera.<sup>4</sup>

## Contribuições por Autor

A escrita do presente artigo e a revisão bibliográfica feita são de Victoria Pires da Silva.

## Conflito de interesse

Não há conflito de interesses.

## Agradecimentos

Agradeço ao PET-Química/IQ/UnB, à Secretaria de Educação Superior do Ministério da Educação (SeSU/MEC) e ao Decanato de Ensino de Graduação (DEG/UnB) por todo o apoio concedido através do Programa de Educação Tutorial. Ao Instituto de Química (IQ/UnB) e à Universidade de Brasília pelo suporte e espaço fornecidos.

## Notas e referências

- 1 E. Institute, Home, <https://www.energyinst.org/statistical-review/home>, (accessed 18 July 2025).
- 2 B. Guo, X. Liu and X. Tan, *Petroleum production engineering*, Gulf Professional Pub, Cambridge, MA, 2nd ed., 2017.
- 3 R. C. Selley and S. A. Sonnenberg, *Elements of petroleum geology*, Elsevier, Academic Press is an imprint of Elsevier, Amsterdam; Boston, Third edition., 2015.
- 4 Z. Zhang, H. Zhang, J. Li and Z. Cai, Permeability and porosity prediction using logging data in a heterogeneous dolomite reservoir: An integrated approach, *Journal of Natural Gas Science and Engineering*, 2021, **86**, 103743.
- 5 I. Goodfellow, Y. Bengio and A. Courville, *Deep learning*, The MIT press, Cambridge, Mass, 2016.