Predição de Permeabilidade em ambientes Carbonáticas através de Física de Rochas Digital com Aprendizagem de maquina

Angela da S. Montalvão (CPGF, UFPA) e José Jadsom S. de Figueiredo (CPGF, UFPA, INCT-GP).

Copyright 2024, SBGf - Sociedade Brasileira de Geofísica
Este texto foi preparado para a apresentação no X Simpósio Brasileiro de Geofísica, Salvador, 8 a 10 de outubro de 2024. Seu conteúdo foi revisado pelo Comitê Técnico do X SimBGf, mas não necessariamente representa a opinião da SBGf ou de seus associados. É proibida a reprodução total ou parcial deste material para propósitos comerciais sem prévia autorização da SBGf.

Resumo

A caracterização petrofísica dos reservatórios continua sendo um desafio significativo no setor de petróleo e gás, devido à dependência de propriedades variáveis como litologia, porosidade e permeabilidade. A variação dessas propriedades no espaço influencia diretamente a quantidade e a qualidade dos recursos, além da eficácia da produção, introduzindo incertezas sobre os recursos existentes e o comportamento produtivo dos reservatórios. Portanto, torna-se essencial empregar metodologias que possam detalhar os tipos de rocha presentes em reservatórios carbonáticos em diferentes escalas (poço e laboaratório). Além disso, a abordagem pode ser estendida para a estimativa de outras propriedades, como a porosidade. Este estudo apresenta uma metodologia integrativa que combina imagens de microtomografia computadorizada de raios X (micro-CT) através de Física de Rochas Digital com algoritmos de inteligência artificial e dados laboratoriais, especialmente de amostras de rochas carbonáticas do pré-sal brasileiro da Formação Barra Velha/RJ e de formações análogas, como a de Barreiras/PA/MA. A partir da análise de permeabilidade e porosidade em amostras obtidas por core e micro-CT (3D), será possível validar os modelos de IA propostos. Esses modelos serão contrastados com abordagens matemáticas convencionais, como a fórmula de Kozeny-Carman, com o intuito de avaliar a precisão dos modelos baseados em aprendizado de máquina (AM) e aprendizado profundo (AP), assim como identificar possíveis áreas de aprimoramento. A análise inclui a avaliação e comparação da eficácia de diferentes modelos, incluindo redes neurais convolucionais, dados laboratoriais e modelos numéricos. Resultados recentes têm mostrado que a permeabilidade predita pelos modelos corrobora com as previstas em laboaratório.