Estimativa de Propriedades Petrofísicas em Reservatórios de Petróleo através de Modelos de Aprendizado de Máquina Supervisionados.

Larissa Carla de Oliveira, Mario Martins Ramos, Victor Matheus Joaquim Salgado Campos, Leonardo Guimarães Miquelluti.
Universidade Federal Fluminense - UFF.

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 determinação precisa das propriedades petrofísicas em reservatórios de óleo e gás desempenha um papel fundamental na indústria, influenciando diretamente a avaliação de reservas e o planejamento de produção. Este estudo propõe uma abordagem inovadora para estimar argilosidade, porosidade e saturação em reservatórios da Formação Namorado (reservatórios siliciclásticos) na Bacia de Campos, RJ, utilizando modelos de aprendizado de máquina supervisionados.

Inicialmente, a criação de dados sintéticos foi feita a partir da aplicação da Lei das Misturas em uma variedade de modelos petrofísicos distintos, ou seja, a partir da informação das propriedades físicas (densidade, vagarosidade, etc.) da matriz da rocha, da porosidade, fluido percolante, e quantidade de argila, calculava-se a resposta desde modelo aos perfis geofísicos. Entretanto, não houve a criação de vínculo espacial do dado; isto é, os dados sintéticos gerados não tinham profundidade e/ou alguma forma de continuidade associada, e portanto não possuíam a característica da correlação espacial, um fator essencial para representar dados geológicos. Uma vez com uma grande quantidade de dados (oriundos de diferentes modelos petrofísicos), separou-se os dados em conjuntos de treino e teste, e empregou-se várias metodologias distintas para a obtenção de um modelo preditivo eficiente. O método da regressão linear obteve uma eficiência de 99% em dados sintéticos com ruídos. A partir deste momento, optou-se por abordar formas de se gerar os dados sintéticos que consideravam a existência da correlação espacial; ou seja, os dados sintéticos devem apresentar uma certa continuidade e coerência em profundidade.

Uma revisão bibliográfica abrangente foi então realizada a fim de reunir dados de referência das propriedades petrofísicas em cinco poços de uma região escolhida (Campo de Namorado). Combinamos esses dados com informações sobre as principais fácies sedimentares dos reservatórios. Utilizando essas informações como base, criamos perfis sintéticos básicos, incluindo Tempo de Trânsito (DT), Densidade Aparente (RHOB), Radioatividade Gama (GR) e Neutrônico (NPHI), os quais foram projetados para representar uma ampla variedade de cenários. Utilizamos técnicas geoestatísticas como a simulação de Monte Carlo com correlação espacial (isto é, usando um sorteio baseado na covariância entre propriedades petrofísicas) para gerar respostas sintéticas dos perfis para diferentes combinações de fácies, variando argilosidade e porosidade em intervalos realistas, baseados em dados de poços do Campo de Namorado.

Esses dados sintéticos foram então empregados no treinamento de um modelo de regressão linear, e em seguida, o modelo de aprendizagem de máquinas treinado foi testado e refinado utilizando dados reais de poços. Através deste processo, obtivemos estimativas confiáveis de argilosidade e porosidade que se mostraram consistentes com métodos tradicionais de avaliação petrofísica, bem como com valores obtidos diretamente em laboratório.

Os resultados preliminares sugerem que a metodologia proposta forneça resultados confiáveis através da obtenção de estimativas precisas das propriedades petrofísicas em reservatórios de petróleo. Além disso, a abordagem baseada em aprendizado de máquina se mostra eficiente e escalável, permitindo a geração de um grande volume de dados sintéticos para treinamento e validação do modelo.