

12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

Construção de modelo de pressão de poros 1D a partir de perfil DT utilizando machine learning

AUTORES:

Clecio Mota Ribeiro
Francisco Lucas Damascena Silva
João Victor Gonçalves Castro
Erika Vitoria da Silva Carmo

INSTITUIÇÃO:

Universidade Federal do Ceará - UFC

CONSTRUÇÃO DE MODELO DE PRESSÃO DE POROS 1D A PARTIR DE PERFIL DT UTILIZANDO MACHINE LEARNING

Resumo

A utilização de aprendizado de máquina na exploração de petróleo e gás é inovadora e valiosa, permitindo a análise de grandes conjuntos de dados sísmicos e a identificação de padrões que relacionam o perfil sísmico à pressão de porosidade das rochas. Um procedimento foi desenvolvido para prever o comportamento do gradiente de pressão de poros em um poço sem perfil sônico conhecido. Utilizou-se um modelo de aprendizado de máquina (Random Forest) treinado com dados de outro poço que possuía o perfil DT. Em seguida, o Método de Eaton foi aplicado para calcular o gradiente. O projeto apresentou resultados satisfatórios tanto na predição do perfil sônico quanto na construção da curva de pressão de poros, demonstrando a aplicabilidade do aprendizado de máquina em projetos de perfuração e completação de poços.

Palavras-chave: aprendizado de máquina, poros, poço.

Abstract

The use of machine learning in oil and gas exploration is innovative and valuable, enabling the analysis of large seismic datasets and the identification of patterns that relate the seismic profile to rock porosity pressure. A procedure was developed to predict the pore pressure gradient behavior in a well without a known sonic profile. A machine learning model (Random Forest) was trained using data from another well that had the DT profile. Then, the Eaton Method was applied to calculate the gradient. The project showed satisfactory results both in predicting the sonic profile and in constructing the pore pressure curve, demonstrating the applicability of machine learning in drilling and well completion projects.

Keywords: machine learning, pore, well.

Introdução

Para executar um projeto de perfuração e completação de um poço, seja ele, exploratório, de extensão ou de desenvolvimento, é necessário um grande planejamento. Dentro da elaboração de um projeto de poço, está presente a construção de um modelo geomecânico das geopressões 1D. Ao analisar geopressões, trabalha-se com informações, como pressão de poros, pressão de fratura e pressão de sobrecarga, as quais ajudam no cálculo para encontrar a janela operacional do poço, definindo limites de massa específica dos fluidos utilizados para perfuração e completação e, assim, mantendo a integridade do poço, evitando Kicks, Blowouts e, consequentemente, perdas humanas.

Para o presente trabalho, além da posterior etapa de predição de uma curva para o gradiente de pressão de poros para um poço-objetivo e construção do modelo 1D, devido a falta do perfil sônico deste mesmo poço, foi necessário realizar antes a criação de um perfil DT por meio de machine learning com o auxílio de dados de outros dois poços próximos.

Metodologia


Para este trabalho, foram analisados poços do Campo de Lagoa Parda, localizado na porção emersa da Bacia do Espírito Santo. Os dados foram obtidos do site REATE da ANP, que disponibiliza informações técnicas sobre bacias sedimentares terrestres brasileiras. Devido à escassez de dados em muitos poços, decidiu-se criar um perfil sintético para um deles para avaliar a precisão de um modelo de aprendizado de máquina na predição de um perfil completo e usar esse perfil na construção do

gradiente de pressão de poros. Os poços selecionados foram: 1-LPB-1A-ES, 3-LPB-3-ES e 7-LPB-7-ES, sendo este último sem dados para o perfil sônico.

Predição do Perfil Sônico do poço

A primeira etapa do projeto se dá pela previsão do perfil sônico do poço-objetivo. A figura 1 mostra a metodologia aplicada no processo em forma de fluxograma. A etapa de coleta e tratamento de dados é fundamental para garantir resultados adequados para o estudo, uma vez que os dados disponíveis são limitados e alguns perfis são ausentes.


Figura 1 – Fluxograma da construção do Perfil Sônico (DT) Sintético



Fonte: Autor

Após a análise inicial dos dados dos poços, identificou-se que o poço 7-LPB-7-ES, cujo perfil sônico será obtido por machine learning, possui intervalos com ausência de dados em todos os perfis, dificultando a previsão. Para solucionar isso e obter resultados confiáveis, o poço foi dividido em subintervalos com diferentes quantidades de perfis e intervalos reduzidos. Por exemplo, entre 800 e 930 metros, há apenas dados de Gamma-Ray, enquanto entre 930 e 1115 metros, também estão presentes perfis de resistividade e espontâneo. No total, foram criadas 6 divisões, conforme mostrado na figura 2.

Figura 2 – Perfis e divisão de intervalos do Poço 7-LPB-7-ES



Fonte: Autor

Como forma de resumir a identificação dos intervalos do poço, a tabela 1 abaixo mostra os perfis que serão treinados pelo modelo e informados a máquina em cada região, o que acarreta variações no grau de confiança da previsão.

Tabela 1 – Perfis presentes em cada intervalo do Poço 7-LPB-7-ES

Intervalo	Perfis de Poço
Intervalo 1	GR
Intervalo 2	ILD, GR e SP
Intervalo 3	CALI, ILD, GR, SP e RHOB
Intervalo 4	ILD, GR e SP
Intervalo 5	GR
Intervalo 6	CALI, ILD, GR, RHOB, NPHI e PEF

Fonte: Autor

Antes de prever o perfil DT do poço 7-LPB-7-ES, é essencial avaliar a capacidade do modelo em prever novos dados. Para isso, foram usados dados de dois outros poços. A máquina deve ser informada apenas sobre os perfis presentes em cada subintervalo do poço-objetivo. Por exemplo, para prever o perfil DT do subintervalo 3 do poço 7-LPB-7-ES, apenas os perfis Gamma-ray, RHOB, ILD, Caliper e SP são utilizados. Essa metodologia é aplicada em todos os treinamentos conforme os subintervalos.

Machine learning

Para a predição do perfil DT, foram usados dois modelos de aprendizado de máquina: Regressão Linear e Random Forest. A Regressão Linear, sendo simples e interpretável, foi utilizada inicialmente para entender a relação entre variáveis. Em contraste, o Random Forest, um algoritmo poderoso baseado em árvores de decisão e aprendizado por conjunto, foi aplicado devido à sua robustez e eficácia com dados de alta dimensionalidade e grande volume.

O Random Forest também se destaca por mitigar problemas de sobreajuste e por sua interpretabilidade, tornando-se uma escolha popular em várias tarefas de aprendizado de máquina. Ambos os modelos foram avaliados quanto à precisão e semelhança ao comparar os perfis DT reais e previstos dos poços de treinamento.

Inicialmente, os dados dos dois poços de treino foram usados para comparar os perfis DT reais e previstos pelo modelo. Os dados de um poço (1-LPB-1A-ES ou 3-LPB-3-ES) foram divididos em 80% para treino e 20% para teste, e o modelo foi treinado com esses dados. Em seguida, previu-se o perfil DT do outro poço de treino, permitindo a comparação entre o perfil real e o previsto usando o erro quadrático (quanto mais próximo de 1, mais preciso). Esta comparação ajudou a definir qual perfil de treino seria usado para prever o poço 7-LPB-7-ES. Os resultados dos erros quadráticos para cada modelo de machine learning estão na tabela 2.

Tabela 2 – Erros quadráticos entre o perfil DT real e o perfil predito

Treinamento	Modelo Random Forest	Modelo Regressão Linear
Predição do Poço 3-LPB-3-ES pelos dados do Poço 1-LPB-1A-ES	0.925	0.813

Predição do Poço 1-LPB-1A-
ES pelos dados do Poço 3-
LPB-3-ES

0.7621

-

Fonte: Autor

Após analisar os testes realizados com os dois poços de treino com o objetivo de escolher aquele cujos dados seriam informados à máquina para posterior predição do perfil DT do poço 7-LPB-7-ES, os resultados mostraram ampla vantagem no uso do modelo de Random Forest para a previsão, sendo medido pelo coeficiente de determinação (R^2), e a determinação do poço 1-LPB-1A-ES como aquele cujos dados serão informados à máquina para predição do poço-objetivo. Os perfis DT previstos de cada intervalo subdividido são então transformados para arquivos em Excel e posteriormente unidos em um só documento. Assim, pode-se obter em forma visual o resultado da previsão do DT realizado pelo modelo de Random Forest.

Cálculo da Pressão de Poros

A pressão de poros é crucial para a geomecânica e a estabilidade de poços de petróleo. Terzaghi e Peck (1948) definiu tensões efetivas como a parte da tensão exercida pela carga de solo e a pressão de poros como a pressão exercida pelos fluidos no reservatório. A soma dessas parcelas representa a tensão total. Em termos de estabilidade de poços, a pressão de poros afeta a segurança desde a perfuração até o fechamento do poço. Durante essas operações, é necessário manter a pressão de fundo do poço (BHP) maior que a pressão de poros para garantir o fluxo adequado do óleo. Se a pressão de poros exceder a BHP, pode ocorrer um kick, levando a um possível blowout e graves acidentes.

A pressão de poros é um conceito geomecânico crucial. Em reservatórios de óleo ou gás, rochas porosas e permeáveis são formadas por grãos que exercem tensão uns nos outros, criando a tensão efetiva. O fluido nos espaços entre os grãos exerce pressão sobre a formação. Se o fluido for água, a pressão é chamada de hidrostática, representando a pressão da coluna de água até a profundidade de interesse (Zoback, 2007). Se houver óleo ou gás, a pressão é chamada de pressão de poros, refletindo a pressão da coluna de fluidos até a profundidade de interesse (Zoback, 2007). Assim, a pressão de poros é a pressão dos fluidos no reservatório.

Para que se entenda a importância da pressão de poros é importante entender a formulação matemática em que se baseia esse conceito. A pressão hidrostática (1) é função da profundidade e da densidade da água, dessa forma podemos representar:

$$P_{hyd} = \int_0^Z \rho w(Z) g dZ \quad (1)$$

em que ρw é a densidade da água, g é a aceleração da gravidade e Z a profundidade.

Para quantificarmos a da pressão de poros devemos incluir no cálculo da pressão hidrostática a parcela dos outros fluidos que estão presentes no reservatório. Há muitas formas de se obter a pressão de poros, seja por medição direta, feita durante a perfuração do poço, a partir de testes de formação, em testes feitos após a perfuração ou de forma analítica. Dentre os métodos analíticos, o Método de Eaton foi o escolhido para ser usado nesse trabalho para o cálculo da pressão de poros, uma vez que esse método permite a utilização de perfis sísmicos, como é o caso do perfil DT, para o cálculo da pressão de poros.

O Método de Eaton, ou Modelo de Velocidade de Eaton, utiliza a tendência de compactação de velocidade, que foi proposto por Eberhart-Phillips *et al.* (1989). Esse método assume uma relação empírica entre a porosidade da formação e as ondas sísmicas (V_p e V_s). Essa relação entre as ondas sísmicas e a porosidade se dá através dos *Normal Compactation Trends*, ou seja, através da compactação da formação geológica ao longo do tempo geológico. Essa compactação assume que a porosidade e a

densidade mudam à medida que são soterradas e submetidas às variações crescentes de temperatura e pressão.

À medida que se aprofunda nas camadas terrestres é possível observar tanto um aumento da temperatura quanto o aumento da pressão. Dessa forma, naturalmente, a porosidade dos materiais depositados tendem a diminuir. Já a densidade tende a aumentar, nessas condições. É nesses conceitos que se baseia o Método de Eaton.

Dessa forma Eaton deduziu matematicamente que era possível calcular pressão de poros a partir de dados de perfis de resistividade e sônicos. Ambas correlações matemáticas desenvolvidas para cada um dos tipos de perfis de poços, perfis de resistividade (1) e perfis sônicos (2), apresentam o equacionamento semelhante, sendo necessário conhecer a tensão de sobrecarga do reservatório (3), a pressão hidrostática em função da profundidade e o perfil.


$$P = S - (S - P_{hyd}) \left(\frac{R_{shlog}}{R_{shn}} \right)^{1,2} \quad (1)$$

$$P = S - (S - P_{hyd}) \left(\frac{\Delta T_n}{\Delta T_{log}} \right)^3 \quad (2)$$

$$\sigma_{ov} = \int_0^z \rho g dz \quad (3)$$

No caso do perfil sônico é necessário calcular o Normal Compaction Trend (Figura 3).

Figura 3 –Normal Compaction Trend do Poço 7-LPB-7-ES




Fonte: Autor

Com o *Normal Compaction Trend* em mãos é possível aplicar o equacionamento do Método de Eaton para perfis DT (Equação 2).

Resultados e Discussão

O projeto revelou resultados altamente promissores, indicando um desempenho positivo na predição do perfil sônico e posterior cálculo do gradiente de pressão de poros. Na primeira etapa, os dados obtidos através deste processo mostraram uma correspondência notável com as características esperadas (Perfis medidos do poço 7-LPB-7-ES), sugerindo uma precisão e confiabilidade significativa na predição. A figura 3 abaixo mostra o resultado da predição do perfil sônico que foi utilizado para o cálculo da pressão de poros.


Figura 4 –Resultado da predição do Perfil Sônico Sintético do Poço 7-LPB-7-ES



Fonte: Autor

Tendo encontrado resultados satisfatórios para a predição do perfil DT, é possível obter resultados coesos para o cálculo da pressão de poros, como pode ser visto na Figura 5. Mesmo sendo utilizado um método que possui pontos fracos, é possível concluir que o cálculo da pressão de poros foi satisfatório. Todavia, para tornar os dados obtidos mais fiéis a realidade é necessário compará-los à dados reais, de pressão estática ou RFT, medidos diretamente de poços.

Figura 5 – Gráfico de pressão de poros, pressão hidrostática e tensão vertical do Poço 7-LPB-7-ES, obtidas a partir do DT sintético



Fonte: Autor

Conclusões

Este estudo utilizou uma abordagem em duas partes a fim de realizar a análise geomecânica e a construção do modelo 1D. Primeiro, as técnicas de machine learning, como Regressão Linear e Random Forest, foram aplicadas para prever o perfil DT de poços com dados limitados, demonstrando boa precisão. Em seguida, o perfil DT predito foi utilizado para construir o modelo de pressão de poros e tensões, resultando em curvas adequadas para a análise geomecânica. Os resultados promissores destacam o potencial do aprendizado de máquina para realizar previsões de perfis e os resultados satisfatórios da aplicação do método de Eaton.

Agradecimentos

Agradecemos ao Professor Doutor Luis Glauber Rodrigues, pelos ensinamentos e conselhos não só em relação ao tema desse trabalho, mas por todas as ajudas a nós durante a graduação. Aos colegas e amigos do Grupo de Simulação Integrada Multiescala (GSIM) que compartilham o dia-a-dia conosco e a UFC pela estrutura que nos fornece para que trabalhos como esse sejam feitos.

Referências Bibliográficas

Terzaghi, K. & Peck, R.B. Soil Mechanics in Engineering Practice. McGraw Hill. New York, NY, USA. 1948.

Zoback, M. D. Reservoir Geomechanics. Cambridge University Press. New York, NY, USA. 2007.

D. Eberhart-Phillips, D-H. Han, and M. D. Zoback. Empirical relationships among seismic velocity, effective pressure, porosity, and clay content in sandstone. *GEOPHYSICS* 54: 82-89. 1989.