

CALIBRADOR PARA MODELOS DE FÍSICA DE ROCHA: abordagem metaheurística com alinhamento de estimativas

Danna Katherine Nieto Huertas, Rafael de Santiago

Programa de Pós-Graduação em Ciência da Computação,
Departamento de Informática e Estatística – Universidade Federal de Santa Catarina (UFSC)
Cx.P. 476 – 88040-370 Florianópolis – SC – Brasil
danna.nieto.h@posgrad.ufsc.br, r.santiago@ufsc.br

Bruno Barbosa Rodrigues

Centro de Pesquisas, Desenvolvimento e Inovação Leopoldo Américo Miguez de Mello -
CENPES/PETROBRAS
Av. Horácio Macedo, 950 - Cidade Universitária, Rio de Janeiro
bbrodrigues@petrobras.com.br

RESUMO

Este estudo descreve uma abordagem para a calibração de modelos de física de rocha utilizados na caracterização de reservatórios de petróleo. O objetivo é aprimorar a precisão desses modelos ajustando seus parâmetros de forma automática, de modo a apoiar o especialista. O método proposto emprega uma metaheurística populacional para explorar o espaço de soluções em busca dos ajustes que tornam o modelo mais próximo da realidade do reservatório. A metaheurística é utilizada para encontrar uma solução que minimiza o erro em relação aos dados observados. No final, cada modelo de física de rocha utilizado em cada profundidade é considerado e o que possuir melhor avaliação é selecionado. Para validar a eficácia desta abordagem, realizaram-se experimentos que demonstraram a capacidade da proposta em melhorar a calibração dos modelos de física de rocha.

PALAVRAS CHAVE. Calibração automática. Modelos de física de rocha. Metaheurística. EN&PG - PO na Área de Energia, Petróleo e Gás. MH - Metaheurísticas.

ABSTRACT

This study describes an approach for the calibration of rock physics models used in the characterization of petroleum reservoirs. The objective is to enhance the accuracy of these models by automatically adjusting their parameters, thereby assisting specialists in making inferences. The proposed method employs a population-based metaheuristic to explore the solution space, seeking adjustments that make the model more representative of the reservoir's reality. The metaheuristic is utilized to find a solution that minimizes the error relative to the observed data. Ultimately, each rock physics model used at different depths is considered, and the one with the best evaluation is selected. To validate the effectiveness of this approach, experiments were conducted that demonstrated the proposal's capability to improve the calibration of rock physics models.

KEYWORDS. Automatic calibration. Rock physics models. Metaheuristic. EN&PG - OR in the Energy, Oil, and Gas. MH - Metaheuristics.

1. Introdução

A otimização da produção e a gestão de reservatórios de petróleo apresentam desafios constantes [Seyyedattar et al., 2020]. A heterogeneidade dos reservatórios, refletida na diversidade de sua disposição inicial e os estímulos aos quais estão submetidos, gera um ambiente dinâmico e multifacetado. Essa variabilidade, que pode incluir mudanças na pressão, saturação, temperatura, propagação de ondas sísmicas e processos diagenéticos, entre outros aspectos próprios das rochas, requer uma abordagem especializada para seu manejo [Dias et al., 2021; Ali et al., 2020; Johari e Emami Niri, 2021; Wardhana e Pranowo, 2022].

Nesse contexto, a física das rochas surge como uma disciplina chave. Esta se concentra no estudo das relações entre as propriedades petrofísicas e elásticas das rochas [Mavko et al., 2020; Grana et al., 2021; Gohel e Naeini, 2021]. Segundo Avseth et al. [2005], seu principal objetivo é decifrar e compreender as relações sísmicas com o reservatório. Esta busca por determinar as propriedades fundamentais do subsolo desempenha um papel importante na exploração geofísica e na indústria de recursos naturais [Gulco e Anderson, 2022]. Ao fornecer base para a compreensão das formações geológicas subterrâneas, a física das rochas facilita a localização e avaliação eficaz de recursos, minimizando riscos, protegendo o meio ambiente e promovendo a inovação tecnológica no processo [Bagdassarov, 2021].

Dada a diversidade, complexidade dos estímulos e condições iniciais aos quais os reservatórios estão submetidos, os modelos de física das rochas tornam-se indispensáveis porque permitem simular diversos cenários a fim de prever como as propriedades petrofísicas e elásticas das rochas se adaptam sob diferentes condições de estresse [Dias et al., 2021; Johari e Emami Niri, 2021; Hossain et al., 2022; Gohel e Naeini, 2021]. A calibração dos modelos de rocha ajusta parâmetros para se alinhar com os dados, garantindo estimativas precisas [Vargas-Meleza e Valle-Molina, 2012]. Isso permite avaliar a confiabilidade das estimativas em diversos contextos geológicos, auxiliando na exploração de hidrocarbonetos [Moncayo et al., 2011; Mukerji et al., 2001; Downton et al., 2020; Bredesen et al., 2021].

De acordo com Gohel e Naeini [2021], a calibração manual de modelos de física de rocha, tradicionalmente realizada por especialistas em geologia, implica ajustes iterativos nos parâmetros do modelo até alcançar uma concordância aceitável com os dados observados, o que pode ser intensivo e subjetivo. Para mitigar esta incerteza, foram propostas diversas abordagens, incluindo métodos estatísticos, probabilísticos e matemáticos [Bachrach, 2006; Doyen, 2007; Spikes et al., 2007; Moyano et al., 2010; Grana e Della Rossa, 2010; Jensen, 2011; Ali et al., 2020; Heidari et al., 2020; Bredesen et al., 2021; Gohel e Naeini, 2021], bem como métodos de aprendizado profundo baseados em redes neurais convolucionais [Das et al., 2019; Biswas et al., 2019; Das e Mukerji, 2020], e métodos de otimização baseados em metaheurísticas populacionais, como o algoritmo genético [Curtis e Snieder, 1997; Moncayo et al., 2011; Nasrnia et al., 2023], o método de enxame de partículas [Wardhana e Pranowo, 2022; Wang et al., 2023], a otimização por colônia de formigas [Kadkhodaie-Ilkhchi, 2015; Nasrnia et al., 2023], e o algoritmo de colônia de abelhas [Niri et al., 2018; Sayyafzadeh et al., 2012; Niri e Arbat, 2019]. Estes métodos ajustam o modelo aos dados observados através da minimização de uma função de perda, o que demonstra sua eficácia na calibração de parâmetros de um reservatório. No entanto, o desafio persiste em minimizar completamente o viés agregado da heterogeneidade inerente ao fenômeno, que impacta na precisão dos resultados.

Este artigo apresenta os resultados que avaliam a precisão de um método proposto para calibrar parâmetros em modelos de física de rochas. O objetivo principal é minimizar a incerteza nas estimativas de parâmetros, aproximando-as do comportamento real do fenômeno. As principais contribuições do estudo são:

- Proposição de um método (no melhor do nosso conhecimento, inovador) para calibração automática de modelos de física de rochas, que utiliza método baseado em metaheurística populacional para realizar estimativas que são unificadas para prever dados de um poço. Este processo pode facilitar a tarefa do especialista.
- Os experimentos sugerem que o método proposto, em conjunto com a consideração das estimativas de valores petrofísicos adjacentes a diferentes profundidades, torna-se um método eficaz, preciso e reproduzível em ambientes sintéticos. Após múltiplas repetições, o método atinge um erro médio de predição de 0,0242 com uma variância de 0,0018.

O artigo segue a seguinte estrutura: na Seção 2, aborda trabalhos encontrados na literatura que discutem a calibração de modelos de física de rocha. Na Seção 3, o método proposto é apresentado. Os experimentos, resultados obtidos e análise deles são apresentados na Seção 4, e são expostas as considerações finais do estudo juntamente com algumas sugestões para trabalhos futuros na Seção 5.

2. Trabalhos Relacionados

A calibração de modelos de física de rochas para a caracterização de reservatórios pode ser considerada como um problema de otimização. Para isso, muitas propostas utilizam-se do erro entre um dado conhecido e o valor obtido pelo modelo ou método proposto. Segundo Kadkhodaie-Ilkhchi [2015] e Sayyafzadeh et al. [2012], os métodos de otimização baseados em metaheurísticas são reconhecidos na tarefa de calibrar os parâmetros de um reservatório. As metaheurísticas são estratégias de alto nível que coordenam e ajustam os métodos heurísticos para explorar eficientemente o espaço de soluções, que abrange todas as possíveis soluções para um problema [Maniezzo et al., 2010].

No estudo de Sayyafzadeh et al. [2012], sobre dois diferentes reservatórios sintéticos, foram comparados os métodos: colônia artificial de abelhas (ABC), algoritmo genético (GA), reconhecimento simulado (SA) e descida mais íngreme pré-condicionada (PCDM) para o ajuste histórico dos reservatórios. Observou-se que, devido à complexidade do ajuste histórico, a escolha do método de otimização é difícil. Embora o ABC possa se adaptar a diferentes tipos de dados, sua principal desvantagem é sua longa duração computacional devido à sua lenta velocidade de convergência. Em problemas industriais, não é prudente confiar apenas em uma única solução. Portanto, diferentes abordagens devem ser avaliadas e adaptadas de acordo com as condições físicas do reservatório em estudo e os objetivos do poço.

Niri et al. [2018] investigam a previsão da velocidade da onda de cisalhamento (V_s), uma medida crucial na avaliação de reservatórios de petróleo e gás, em dois conjuntos de dados de campos distintos. Comparando o desempenho de três métodos metaheurísticos - otimização baseada em aprendizado, competição imperialista e colônia de abelhas artificiais - com a correlação empírica amplamente utilizada de Greenberg-Castagna, os resultados demonstram que os métodos

metaheurísticos são mais eficientes e confiáveis. A colônia de abelhas artificiais apresenta um desempenho ligeiramente superior na previsão de V_s .

Em um estudo adicional, Niri e Arbat [2019] examinam o uso do algoritmo de colônia de abelhas artificiais para a caracterização de reservatórios. Os resultados mostram uma eficiência notável na estimativa da velocidade da onda de cisalhamento (V_s), mesmo em reservatórios com litologias semelhantes, mas sem dados registrados. Isso sugere que o ABC e outros métodos de otimização podem ser ferramentas valiosas para a caracterização de reservatórios, melhorando a precisão das estimativas mesmo em condições de dados limitados.

No estudo de Wardhana e Pranowo [2022], parâmetros de física de rochas são estimados por meio da otimização por enxame de partículas (PSO), em cinco cenários diferentes de modelagem. Os cenários incluem o uso de modelos como Kuster-Toksoz (KT) e a relação de Gassmann para calcular os módulos elásticos da rocha saturada. Além disso, vários casos são analisados, incluindo modelos com inclusões esféricas e fissuras do tipo penny, bem como combinações de KT e Gassmann. Os resultados mostram que, embora os modelos possam se ajustar bem aos módulos elásticos da rocha saturada, eles têm dificuldade em estimar com precisão os módulos da rocha sólida ou mineral. Além disso, enfatiza-se a importância de ser cauteloso com as suposições iniciais do modelo e os parâmetros da metaheurística PSO porque isso gera viés na estimativa.

Por fim, Nasrnia et al. [2023] exploram métodos inteligentes e métodos de otimização metaheurística para estimar parâmetros de reservatórios, incluindo a velocidade de corte. Eles usam redes neurais, lógica difusa e sistema de inferência difusa neuroadaptativa, juntamente com algoritmos como algoritmo genético e recozimento simulado. A combinação dessas abordagens mostra uma melhoria significativa na precisão das estimativas de velocidade de corte, demonstrando a eficácia dos algoritmos de otimização na caracterização e previsão do desempenho dos reservatórios de hidrocarbonetos.

3. Método Proposto

O método proposto para a calibração de modelos de física de rocha utiliza parâmetros elásticos, dados e estimativas que são aplicados a diferentes modelos de física de rochas ao longo de um poço. Esses modelos são integrados ao método, que faz uso de uma meta-heurística populacional para explorar cada modelo em todas as profundidades do poço. O objetivo principal é identificar os valores petrofísicos mais consistentes com os parâmetros elásticos e determinar qual modelo de física de rocha é mais adequado para cada profundidade específica.

A implementação do método proposto é detalhada no Algoritmo 1, conforme descrito a seguir. (i) *Preparação dos Dados*: inicialmente, o método recebe dois conjuntos de dados como entrada. O primeiro é uma sequência de parâmetros elásticos do poço (W), que estão ordenados por profundidade. O segundo conjunto de dados são os parâmetros estimados ou obtidos para o poço (P). Estes podem ser dados que já são conhecidos ou foram previamente estimados para o poço. (ii) *Criação da Sequência de Estimativas*: na linha 2, cria-se uma lista C para armazenar os dados obtidos em cada profundidade. Cada elemento de C é uma sequência c de estimativas de valores petrofísicos para a respectiva profundidade correspondente ao parâmetro elástico da mesma profundidade ($W[d]$). (iii) *Estimativa por Metaheurística Populacional*: durante cada iteração do laço na linha 7, são geradas estimativas utilizando uma metaheurística populacional, aplicado a cada profundidade (há um exemplo do uso de uma metaheurística populacional da Seção 3.1). Este processo é realizado para cada modelo de física de rocha utilizado (M). h_p

corresponde aos parâmetros de controle da metaheurística. (iv) *Armazenamento das Estimativas*: todas as partículas que contêm as estimativas são adicionadas à lista c . Em seguida, esta lista c é adicionada à lista C na posição correspondente à sua profundidade. É importante mencionar que as estimativas dentro da lista c são organizadas de menor para maior, com base no valor estimado da propriedade petrofísica que estamos tentando otimizar (alinhamento por ordenação dos valores). (v) *Alinhamento dos Valores Petrofísicos*: entre as linhas 16 e 22, os valores da propriedade petrofísica são alinhados de modo que R tenha $|M| \times \text{partículas}$ estimativas; cada uma com um valor encontrado para a propriedade petrofísica em cada profundidade. Cada r é uma estimativa para todo o poço.

Algorithm 1: Método proposto.

Input : Sequência de parâmetros elásticos do poço W , conjunto de parâmetros estimados/obtidos P

```

1 // estimativas candidatas
2  $C \leftarrow \text{lista}()$ 
3 // a cada profundidade
4 foreach  $d \leftarrow 1, 2, \dots, |W|$  do
5    $c \leftarrow \text{lista}()$ 
6   // a cada modelo de física de rocha
7   foreach  $m \in M$  do
8     // estimativas de propriedades petrofísicas para a
      profundidade  $d$  usando o modelo  $m$ 
9      $(S, S^{best}) \leftarrow \text{MetaheuristicaPopulacional}(h_p, m, W[d], P[d])$ 
10     $c.\text{adicionar}(S \cup \{S^{best}\})$ 
11  end
12   $C.\text{adicionar}(\text{ordenar}(c))$ 
13 end
14 // alinhamento de cada estimativa para o poço
15  $R \leftarrow \{\}$ 
16 foreach  $i \leftarrow 1, 2, \dots, |M| \times \text{partículas}$  do
17    $r \leftarrow \text{lista}()$ 
18   foreach  $d \leftarrow 1, 2, \dots, |W|$  do
19      $r.\text{adicionar}(C[d][i])$ 
20   end
21    $R \leftarrow R \cup r$ 
22 end
23 return  $R$ 

```

3.1. Enxame de Partículas para Modelos Física de Rocha

Motivados pelos resultados promissores obtidos por Wardhana e Pranowo [2022] na estimativa de propriedades petrofísicas, este estudo emprega a otimização por enxame de partículas (Particle Swarm Optimization - PSO) para a mesma finalidade. A metaheurística PSO, proposta por Kennedy e Eberhart [1995], é uma metaheurística populacional bioinspirada no comportamento de enxames em busca de alimento. Neste método, cada indivíduo da população, representado por uma partícula, explora o espaço de busca na procura por melhores soluções.

Como descrito no Algoritmo 2, a metaheurística PSO inicia criando um conjunto de partículas distribuídas aleatoriamente, formando o enxame S . Cada partícula s possui uma posição atual $s.x$, que representa uma solução candidata no espaço de busca. No contexto da petrofísica, isso pode ser um conjunto de parâmetros de um modelo de rocha. Além disso, cada partícula tem a sua melhor posição local $s.best$, que é a melhor solução encontrada por ela até o momento, e uma velocidade $s.v$ que determina a direção e a magnitude do seu movimento.

O método também mantém registro da melhor posição global encontrada por qualquer partícula do enxame S^{best} , que representa a solução mais promissora encontrada até o momento.

A cada iteração it do método, cada partícula atualiza sua velocidade e posição, buscando se aproximar da melhor solução global. Essa atualização da velocidade leva em consideração três fatores. O primeiro é a inércia w , que influencia o quanto a partícula mantém sua direção de movimento atual. O segundo fator é a aceleração da trajetória c_1 , que atrai a partícula em direção à sua melhor posição local. Por fim, a aceleração na direção do melhor do enxame c_2 atrai a partícula em direção à melhor posição global encontrada por todo o enxame.

Após a atualização da velocidade, a posição da partícula é ajustada e regularizada para garantir que permaneça dentro dos limites aceitáveis do espaço de soluções. O processo iterativo continua até que um critério de parada seja atingido.

Algorithm 2: Enxame de Partículas.

Input : número de partículas n , número de iterações it , coeficiente de inércia w , aceleração da trajetória c_1 , aceleração na direção do melhor do enxame c_2 , modelo de física de rocha m , dados elásticos do poço W , conjunto de parâmetros estimados/obtidos P .

```

1 // criação das partículas
2  $S \leftarrow \text{ovoEnxame}(n, W)$ 
3 // melhor partícula
4  $S^{best} \leftarrow \text{argmin}_{s \in S} \{ \text{funcao\_objetivo}(s) \}$ 
5 // a cada iteração
6 foreach  $i \leftarrow 1, 2, \dots, it$  do
7   // para cada partícula do enxame
8   foreach  $s \in S$  do
9     // define velocidade da partícula  $s$ 
10     $s.v \leftarrow w \times s.v + c_1 \times \text{rand}() \times (s.best - s.x) + c_2 \times \text{rand}() \times (S^{best} - s.x)$ 
11     $s.x \leftarrow \text{regularizar}(s.v + s.x)$ 
12  end
13   $S^{best} \leftarrow \text{argmin}_{s \in S} \{ \text{funcao\_objetivo}(s) \}$ 
14 end
15 return  $(S, S^{best})$ 

```

Para o estudo realizado, os parâmetros envolvidos na metaheurística foram $h_p = \langle \text{particulas}, it, w, c_1, c_2 \rangle$, os quais: $\text{particulas} \in \mathbb{N}$ corresponde ao número de partículas; $it \in \mathbb{N}$ é o número de iterações; $w \in [0; 1]$ é o coeficiente de inércia; $c_1 \in [0; 1]$ é a aceleração da trajetória; e $c_2 \in [0; 1]$ é a aceleração na direção do melhor do enxame.

4. Experimentos, Resultados e Análise

Esta seção detalha os experimentos e discute os resultados obtidos. Inicialmente, os dados de entrada para o método proposto são descritos. Em seguida, os parâmetros e outros aspectos dos experimentos são detalhados. Finalmente, uma análise dos resultados obtidos é fornecida.

4.1. Dados

O método desenvolvido baseia-se na utilização de dados provenientes de dois conjuntos de dados sintéticos. O primeiro conjunto, que conta com 328 registros de profundidade e porosidade, foi fornecido pelos autores Grana et al. [2021], e refere-se aos dados contidos no arquivo “data1.dat” do repositório correspondente a Grana et al. [2020]. O segundo conjunto de dados foi gerado a partir do primeiro, utilizando o modelo de “Soft Sand” para estimar os registros da nova variável V_p .

4.2. Experimentos

Nos experimentos, o método proposto busca estimar a porosidade de um poço a partir dos dados das ondas de velocidade primária (V_p), estabelecendo uma série de parâmetros constantes para este propósito.

O método proposto foi avaliado utilizando diversos modelos de física de rocha, como Wyllie, Reymer, Soft Sand, Stiff Sand, Spherical Inclusion e Berryman Inclusion, para estimar a porosidade de um poço Grana et al. [2021]. Alguns parâmetros foram fixados (sugeridos por [Grana et al., 2020]) na tentativa usar valores estimados por especialista: $K_{\text{mat}} = 36$, $\rho_{\text{mat}} = 2$, 65 , $K_{\text{fl}} = 2$, 25 , $\rho_{\text{fl}} = 1$, $\mu_{\text{mat}} = 45$, $G_{\text{fl}} = 0$, número de coordenação = 7, porosidade Crítica = 0, 4, pressão = 0, 02, razão de aspecto = 0, 2.

Para a metaheurística populacional PSO, foram utilizadas 10 partículas e um número de iterações igual a 50. Dentro do conjunto de partículas, cada uma representa uma porosidade inicial obtida aleatoriamente através de uma distribuição normal com média de 0, 2 e desvio padrão de 0, 3. Essas partículas interagem com seis modelos de física de rochas selecionados para os experimentos. A qualidade de cada partícula é determinada pelo erro quadrático entre o V_p obtido pelo modelo e o V_p conhecido. Além disso, são empregados coeficientes de inércia de 0, 8, acelerações na direção da partícula de 0, 1, e na direção da melhor partícula de 0, 15.

A função de avaliação de cada partícula na metaheurística PSO está definida na Equação (1). Nela, s corresponde a uma partícula, $s.\text{porosity}$ é a porosidade estimada para a partícula s , $s.V_p$ é valor de velocidade da onda P , $s.\text{RockPhysicsModel}(\cdot)$ é o modelo de física de rocha utilizado na partícula s , $s.\text{RockPhysicsModel}(s.\text{porosity})$ retorna o valor de velocidade da onda P utilizando a porosidade estimada e o modelo de física de rocha para s .

$$\text{avaliação}(s) = \left(s.\text{RockPhysicsModel}(s.\text{porosity}) - s.V_p \right)^2 \quad (1)$$

Depois dos alinhamentos obtidos pelo método proposto (Algoritmo 1), R será uma coleção de estimativas de porosidade para um poço. Cada estimativa $r \in R$, no qual $r = \langle r_1, r_2, \dots, r_k \rangle$, representa uma sequência de partículas, onde cada partícula r_d é referente a estimativa de r na profundidade d . Considere que r_1 corresponde a partícula da primeira profundidade na estimativa e r_k corresponda a partícula mais profunda na estimativa. Cada estimativa $r \in R$ recebe uma avaliação dada pela função definida na Equação (2).

Foram realizados dois experimentos, os quais estão divididos de acordo com o atributo proporcional da influência da diferença entre os resultados estimados de porosidade. Para os dois experimentos, utilizou-se $\alpha = 1$. No primeiro experimento, chamado de tipo A, $\beta = 0$, ou seja, a influência do fator de diferença entre as porosidades obtidas entre camadas é ignorada e as estimativas são avaliadas apenas pelo valor dado pela soma das avaliações dadas pela metaheurística populacional. No segundo experimento, chamado de tipo B, $\beta = 0,1$, o que significa que, além da soma das avaliações das estimativas dadas pela metaheurística populacional, é considerado 10% do valor da soma das diferenças dos valores das porosidades entre camadas de profundidade adjacentes. Considera-se que quanto menor $vEstimativa(r)$ melhor a estimativa.

$$vEstimativa(r) = \alpha \sum_{d=1}^k \frac{avaliacao(r_d)}{k} + \beta \sum_{d=1}^k \frac{|r_d \cdot porosity - r_{d+1} \cdot porosity|}{k} \quad (2)$$

Chama-se de “*Swarm-best*” a estimativa r que contém o menor valor de $vEstimativa(r)$ (Equação (2)).

Para analisar o desempenho de cada tipo de experimento, são apresentadas as Figuras 1 e 2, que demonstram os resultados obtidos nos experimentos tipo A e tipo B, respectivamente. Considere “Esperado” o valor real da porosidade ϕ ou velocidade V_P . Os gráficos estão alinhados de acordo com a profundidade lida do poço de entrada. Primeiramente, o erro quadrado em relação da melhor estimativa encontrada para porosidade foi para o tipo B, com erro quadrado significativamente menor (0,0134018) em comparação com o tipo A (0,0283992), o que evidencia uma vantagem no uso da diferença entre as porosidades entre camadas dada pelo comportamento do parâmetro β na Equação (2). No gráfico (a) de ambas figuras é possível verificar visualmente este alinhamento. Em (b), demonstra-se os valores de V_P (valor previamente conhecido - parâmetro elástico) obtidos em cada estimativa para os experimentos A e B, nos quais também há confirmação visual a aproximação. Em (c), é possível verificar um melhor alinhamento do experimento tipo B em relação a porosidade e V_P esperados. Por fim, os gráficos em (d) apontam que os modelos de Física de Rocha em cada profundidade apontados pelo experimento tipo B encontram um melhor ajuste ao esperado: modelo “Soft sand”.

Foram realizados 5 experimentos para o tipo A e 5 para o tipo B, sob as mesmas condições, com o objetivo de verificar se o comportamento se mantém para mais experimentos. Em todos os experimentos, as configurações presentes no tipo B obtiveram menor erro (melhor resultado). Na média dos experimentos para A e B, obteve-se o erro quadrado $0,0359 \pm 0,0013$ e $0,0242 \pm 0,0018$ respectivamente. Desse modo, os experimentos sugerem que o uso da diferença das porosidades entre camadas do experimento tipo B beneficiou a busca por resultados. Essas descobertas não apenas indicam um melhor desempenho médio para o tipo B, mas também uma menor variabilidade nos erros, o que sugere uma maior consistência e confiabilidade em seu desempenho sob as condições avaliadas.

5. Considerações Finais

Foi proposto um novo método para a calibração de modelos de física de rocha, utilizando metaheurística populacional. Alguns parâmetros foram fixados a partir de experimentos preliminares e os resultados obtidos foram disponibilizados e discutidos.




Figura 1: Experimento A: Influência de 0% da diferença entre os resultados estimados de porosidade.




Figura 2: Experimento B: Influência de 10% da diferença entre os resultados estimados de porosidade.

Acredita-se que o uso da estratégia de alinhamento das estimativas para um poço, a realização de várias execuções de uma metaheurística populacional para cada profundidade e cada modelo de física de rocha (do universo utilizado) tenha permitido o resultado obtido. Destaca-se também a utilização da função de estimativa (Equação (2)) que combina o erro quadrático médio e a diferença entre porosidades entre camadas de profundidade adjacentes, na qual o uso do valor da diferença auxiliou na obtenção de melhores resultados.

Como trabalhos futuros, destaca-se: (i) experimentar e comparar outras metaheurísticas populacionais; e (ii) ampliar os experimentos para outros poços (reais e sintéticos).

Agradecimentos

Este trabalho foi parcialmente financiado pela Petrobras S.A. através do Termo de Cooperação nro. 0050.012221.22.9.

Referências

- Ali, M., Ma, H., Pan, H., Ashraf, U., e Jiang, R. (2020). Building a rock physics model for the formation evaluation of the lower goru sand reservoir of the southern indus basin in pakistan. *Journal of Petroleum Science and Engineering*, 194:107461.
- Avseth, P., Mukerji, T., e Mavko, G. (2005). *Quantitative Seismic Interpretation: Applying Rock Physics Tools to Reduce Interpretation Risk*. Cambridge University Press.
- Bachrach, R. (2006). Joint estimation of porosity and saturation using stochastic rock-physics modeling. *Geophysics*, 71(5):O53–O63.
- Bagdassarov, N. (2021). p. i–ii. Cambridge University Press.
- Biswas, R., Sen, M. K., Das, V., e Mukerji, T. (2019). Prestack and poststack inversion using a physics-guided convolutional neural network. *Interpretation*, 7(3):SE161–SE174.
- Bredesen, K., Rasmussen, R., Mathiesen, A., e Nielsen, L. H. (2021). Seismic amplitude analysis and rock physics modeling of a geothermal sandstone reservoir in the southern part of the danish basin. *Geothermics*, 89:101974.
- Curtis, A. e Snieder, R. (1997). Reconditioning inverse problems using the genetic algorithm and revised parameterization. *Geophysics*, 62(5):1524–1532.
- Das, V. e Mukerji, T. (2020). Petrophysical properties prediction from prestack seismic data using convolutional neural networks. *Geophysics*, 85(5):N41–N55.
- Das, V., Pollack, A., Wollner, U., e Mukerji, T. (2019). Convolutional neural network for seismic impedance inversion. *Geophysics*, 84(6):R869–R880.
- Dias, J., Lopez, J. L., Velloso, R., e Perosi, F. (2021). A workflow for multiminerologic carbonate rock physics modelling in a bayesian framework: Brazilian pre-salt reservoir case study. *Geophysical Prospecting*, 69(3):650–676.
- Downton, J. E., Collet, O., Hampson, D. P., e Colwell, T. (2020). Theory-guided data science-based reservoir prediction of a north sea oil field. *The Leading Edge*, 39(10):742–750.
- Doyen, P. (2007). *Seismic reservoir characterization: An earth modelling perspective (EET 2)*. Earthdoc.
- Gohel, K. e Naeini, E. (2021). Automatic rock physics model calibration: Optimisation via segmented averages. In *82nd EAGE Annual Conference & Exhibition*, volume 2021, p. 1–5. European Association of Geoscientists & Engineers.
- Grana, D. e Della Rossa, E. (2010). Probabilistic petrophysical-properties estimation integrating statistical rock physics with seismic inversion. *Geophysics*, 75(3):O21–O37.

- Grana, D., Mukerji, T., e Doyen, P. (2020). Seismic Reservoir Modeling Python package. <https://github.com/seismicreservoirmodeling/SeReMpy/>.
- Grana, D., Mukerji, T., e Doyen, P. (2021). *Seismic reservoir modeling: Theory, examples, and algorithms*. John Wiley & Sons.
- Gullco, R. S. e Anderson, M. (2022). *Elements of Rock Physics and Their Application to Inversion and AVO Studies*. CRC Press.
- Heidari, A., Amini, N., Amini, H., Emami Niri, M., Zunino, A., e Hansen, T. M. (2020). Calibration of two rock-frame models using deterministic and probabilistic approaches: Application to a carbonate reservoir in south-west iran. *Journal of Petroleum Science and Engineering*, 192:107266. ISSN 0920-4105. URL <https://www.sciencedirect.com/science/article/pii/S092041052030348X>.
- Hossain, S., Junayed, T. R., e Haque, A. E. (2022). Rock physics diagnostics and modelling of the mangahewa formation of the maui b gas field, taranaki basin, offshore new zealand. *Arabian Journal of Geosciences*, 15(13):1177.
- Jensen, E. H. (2011). Methods for improved prediction of elastic, electrical and reservoir properties.
- Johari, A. e Emami Niri, M. (2021). Rock physics analysis and modelling using well logs and seismic data for characterising a heterogeneous sandstone reservoir in sw of iran. *Exploration Geophysics*, 52(4):446–461.
- Kadkhodaie-Ilkhchi, A. (2015). A systematic approach for estimation of reservoir rock properties using ant colony optimization. *Geopersia*, 5(1):7–17.
- Kennedy, J. e Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks*, volume 4, p. 1942–1948 vol.4.
- Maniezzo, V., Stützle, T., e Voß, S. (2010). *Matheuristics: Hybridizing Metaheuristics and Mathematical Programming*, volume 10 of *Annals of Information Systems*. Springer.
- Mavko, G., Mukerji, T., e Dvorkin, J. (2020). *The rock physics handbook*. Cambridge university press.
- Moncayo, E., Tchegliakova, N., e Montes, L. (2011). Inversión sísmica de datos pre-apilado mediante un algoritmo genético: Aplicado a zona de canales. *Revista Brasileira de Geofísica*, 29.
- Moyano, B., Jensen, E. H., e Johansen, T. A. (2010). *Quantitative calibration of rock-physics models*, p. 2496–2500. URL <https://library.seg.org/doi/abs/10.1190/1.3513357>.

- Mukerji, T., Jørstad, A., Avseth, P., Mavko, G., e Granli, J. (2001). Mapping lithofacies and pore-fluid probabilities in a north sea reservoir: Seismic inversions and statistical rock physics. *Geophysics*, 66(4):988–1001.
- Nasrnia, B., Falahat, R., Kadkhodaie, A., e Vijouyeh, A. G. (2023). A committee machine-based estimation of shear velocity log by combining intelligent systems and rock-physics model using metaheuristic algorithms. *Engineering Applications of Artificial Intelligence*, 126:106821.
- Niri, M. E. e Arbat, M. K. (2019). Application of artificial bee colony algorithm for estimation of reservoir rock physics properties.
- Niri, M. E., Kolajoobi, R. A., Arbat, M. K., e Raz, M. S. (2018). Metaheuristic optimization approaches to predict shear-wave velocity from conventional well logs in sandstone and carbonate case studies. *Journal of Geophysics and Engineering*, 15(3):1071–1083.
- Sayyafzadeh, M., Haghighi, M., Bolouri, K., e Arjomand, E. (2012). Reservoir characterisation using artificial bee colony optimisation. *The APPEA Journal*, 52(1):115–128.
- Seyyedattar, M., Zendeboudi, S., e Butt, S. (2020). Technical and non-technical challenges of development of offshore petroleum reservoirs: Characterization and production. *Natural Resources Research*, 29(3):2147–2189.
- Spikes, K., Mukerji, T., Dvorkin, J., e Mavko, G. (2007). Probabilistic seismic inversion based on rock-physics models. *Geophysics*, 72(5):R87–R97.
- Vargas-Meleza, L. e Valle-Molina, C. (2012). Avances y aplicaciones en física de rocas para exploración de hidrocarburos. *Ingeniería, investigación y tecnología*, 13:439–450.
- Wang, Z., Zhang, B., Gao, Z., e Gao, J. (2023). Seismic swarm intelligence inversion with sparse probability distribution of reflectivity. *Artificial Intelligence in Geosciences*, 4:1–8.
- Wardhana, S. G. e Pranowo, W. (2022). Rock-physics modeling by using particle swarm optimization algorithm. *Journal of Applied Geophysics*, 202:104683.