

# APLICAÇÃO DA GEOESTATÍSTICA PARA OTIMIZAÇÃO DA MODELAGEM GEOQUÍMICA EM ROCHAS RESERVATÓRIO CARBONÁTICAS DO PRÉ-SAL

Palavras-Chave: EOR, MINERAIS-TRAÇO, *MACHINE LEARNING*

Autores/as:

Felipe Fortuna Perez UNICAMP

Prof. Dr. Alfredo Borges de Campos(orientador) UNICAMP

---

## INTRODUÇÃO:

Estudos de modelagem geoquímica em geral trabalham com um grande volume de dados (Costa Lima *et al.*, 2019), o que exige das máquinas grande capacidade de processamento, podendo vir a sobrecarregá-las e atrasar a conclusão do estudo. Para lidar com este problema, diversas tecnologias foram desenvolvidas para simplificar o processo e diminuir os custos (Oliveira, 2022), entre elas suprimir informações de entrada que afetem pouco ou nada no resultado final do modelo. Neste contexto, tem-se destacado o *machine learning*, método computacional em que os computadores aprendem com o ambiente ao redor, emulando inteligência humana por meio de algoritmos computacionais (El Naqa & Murphy, 2015). Em especial o *Random Forests*, que abriga um algoritmo criador de inúmeras árvores de decisão de maneira aleatória (Breiman, 2001), e os resultados das diferentes combinações indicam qual das variáveis usadas interferem mais e quais interferem menos para o resultado global.

Na presente pesquisa, para a confecção das modelagens geoquímicas, estão sendo usados dados cedidos pela ANP (Agência Nacional de Petróleo) do poço 8-LL-4D-RJS localizado no Campo de Tupi da Bacia de Santos. Devido à grande concentração de CO<sub>2</sub> nos reservatórios, a injeção do CO<sub>2</sub> pelo método WAG (*Water Alternating Gas*), que é um importante método de recuperação de petróleo (Patrocínio & Pinto, 2018), ocorre desde 2012 no campo (ANP, 2020), o que torna a aplicação da modelagem geoquímica de interesse para a previsão de cenários de injeção de CO<sub>2</sub> na área.

Com isso, o objetivo da pesquisa é desenvolver e testar uma metodologia de simplificação da modelagem geoquímica por meio da exclusão de minerais traços, usando ferramentas da tecnologia *machine learning* como o *random forests*, associada a métodos estatísticos para dados de poços do Pré-sal da Bacia de Santos. É esperado que a inserção de alguns minerais-traço não tenham relevância necessária para sua inclusão nas modelagens geoquímicas ser justificada, podendo ser excluídos.

## METODOLOGIA:

Na presente pesquisa houve o treinamento no uso dos *softwares* principais, *Phreeqc* e *R*. Ambos possuem, respectivamente, as funções de modelagem geoquímica e análise estatística. A partir disso foi realizada uma modelagem geoquímica, com dados cedidos pelo Banco de Dados de Exploração e Produção da ANP, do poço 8-LL-4D-RJS, localizado na Bacia de Santos, relativa aos efeitos da injeção de salmoura carbonatada nas rochas reservatório do mesmo.

Na modelagem geoquímica realizada pelo *Phreeqc* foram introduzidos dados de entrada que incluíram a quantidade em mol por litro de cada mineral, a composição das soluções, a temperatura genérica do poço, a área de superfície de cada mineral e *scripts* em BASIC de taxas de reação para os minerais envolvidos retirados do trabalho de Zhang (2019), que são Calcita, Dolomita, Pirita, Quartzo, Microclínio (K-Feldspato), Barita, Esmectita e Ilita. A injeção de salmoura carbonatada foi simulada por um período de 15 anos na região com presença de óleo do poço (5117,88 m e 5133,75 m). A região foi dividida em 10 células de 15 metros cada, totalizando um caminho horizontal de 150 metros. Alguns dos dados de *input* estão representados na figura 1 abaixo.

Parâmetros iniciais da Modelagem ( <i>Input</i> )			Solução 0	Solução 1-10
		pH	7	7
Quantidade inicial de Dolomita	37,18 mol/L	pe	4	4
Quantidade inicial de Calcita	151,358 mol/L	C(4)	616 mg/L	42 mg/L
Quantidade inicial de Quartzo	17,144 mol/L	Ca	255 mg/L	255 mg/L
Quantidade inicial de Microclínio	0,488 mol/L	Cl(-1)	20500 mg/L	20500 mg/L
Quantidade inicial de Pirita:	0,0215 mol/L	K	395 mg/L	395 mg/L
Temperatura	65°C	Mg	670 mg/L	670 mg/L
Pressão	355,166 bar	Na	11000 mg/L	11000 mg/L

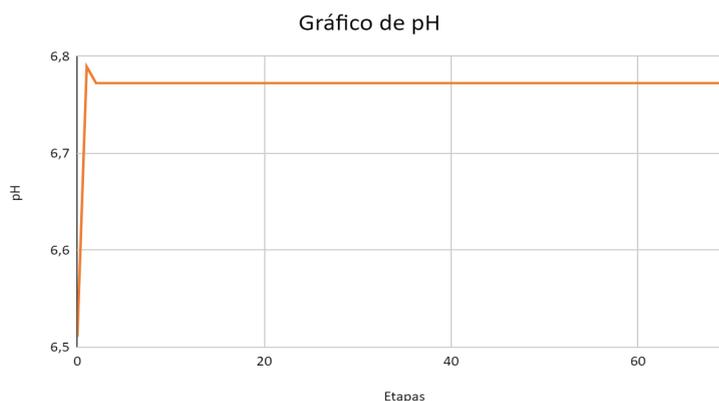
**Figura 1:** Dados de entrada usados no *phreeqc* para confecção da modelagem do poço 8-LL-4D-RJS.

Após isso, os dados de *output* são exportados em formato de texto para o *software Excel*, organizados e analisados em tabelas. Os dados de saída contêm valores de pH, Eh, e quantidade dos minerais ao longo das 71 etapas de injeção propostas, totalizando 15 anos de injeção de salmoura carbonatada.

## RESULTADOS PARCIAIS E DISCUSSÃO

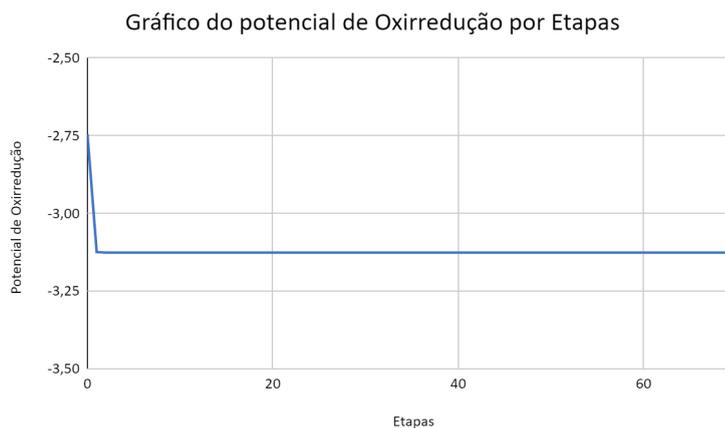
Os dados de saída foram organizados em 3 gráficos, mostrando a variação da quantidade dos minerais em mol/L e os valores de pe e pH em função do tempo. Dos 8 minerais presentes na modelagem, 3 deles, barita, ilita e esmectita, não apresentaram variações superiores a  $10^{-3}$  e não foram representados nos gráficos. Apenas a Pirita, que também não apresentou variações superiores a  $10^{-3}$ , foi representada no gráfico como exemplo.

A Figura 2 demonstra a variação do pH ao longo da modelagem. É possível notar que a partir de 1 ano há um aumento significativo do pH da salmoura injetada até a etapa 7, onde há o equilíbrio químico das reações no poço, estabilizando o pH.



**Figura 2:** Variação do pH *versus* Etapas nas proximidades do poço injetor

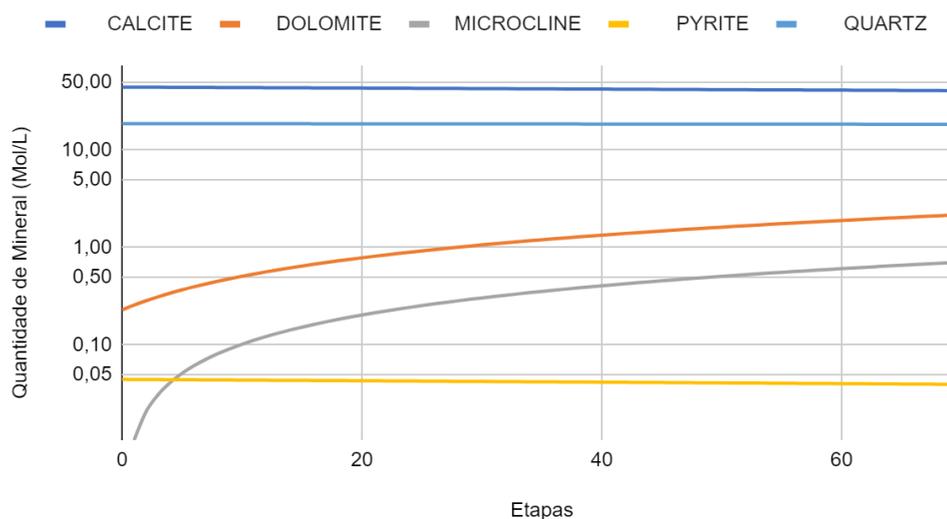
O segundo gráfico (Figura 3) representa o potencial de oxirredução da salmoura durante o período de transporte. Nota-se que a partir da etapa 4, o potencial de oxirredução diminui até se estabilizar na etapa 7. A estabilização se deve à ocorrência do equilíbrio químico entre as reações ocorrentes no poço.



**Figura 3:** Variação do Potencial de Oxirredução *versus* etapas nas proximidades do poço injetor.

Os minerais dolomita, calcita, pirita, microclínio e quartzo são representados na Figura 4. É possível observar que as concentrações de quartzo e calcita diminuem ao longo do tempo, enquanto as concentrações de dolomita e microclínio aumentam. Apenas a pirita apresenta uma curva totalmente estabilizada.

## Gráfico da Quantidade de Mineral por Etapa da Modelagem



**Figura 4:** Variação da quantidade dos minerais inseridos na modelagem *versus* etapas nas proximidades do poço injetor.

A partir da etapa 4, as curvas dos gráficos de quantidade de mineral *versus* tempo e dos gráficos de pH e pe se estabilizam, sugerindo um equilíbrio químico no sistema. É possível perceber, por ser um gráfico logarítmico, uma queda considerável da quantidade de calcita, o mineral mais abundante do poço (47,35% do total). Isto implica que a calcita é mais reativa com a salmoura carbonatada do que os outros minerais. Isso se dá ao fato da salmoura produzir ácido carbônico que reage com a calcita (Aum, 2011). A dolomita, outro carbonato, e o microclínio aumentam sua quantidade em mol/L, porém isso se deve a diminuição da quantidade de outros minerais. Assim a concentração de dolomita e microclínio aumentam relativamente. Ou seja, esses dois minerais apresentaram uma queda absoluta muito pequena ou reagiram muito pouco, indicando que podem ser mais resistentes à ação da salmoura carbonatada.

O quartzo apresentou uma curva bem estável, com diminuição baixa e constante, dada à sua grande resistência ao intemperismo (Mota, 2007), ou seja resistência às reações causadas pela salmoura carbonatada. A pirita não apresentou alterações significativas na curva, possivelmente pelos valores negativos de pe que caracterizam um ambiente redutor que é favorável para a sua presença (Duleba, 1994).

## CONCLUSÕES:

Os resultados preliminares permitem ilustrar como a litologia do Campo de Tupi interage com a injeção de CO<sub>2</sub>. Os minerais se alteram em proporções diferentes, há alterações no pH e no potencial de oxirredução da solução. Essas alterações são estabilizadas ao longo da modelagem, alcançando um estado de equilíbrio químico entre a salmoura e o poço.

Nos próximos passos, serão realizadas mais 9 modelagens geoquímicas com o mesmo enfoque para outros 9 poços fornecidos pela ANP. As 10 modelagens totais serão comparadas e analisadas posteriormente pelo algoritmo *Random Forests* com o intuito de otimizar as modelagens em relação à inserção de dados minerais-traço como *input*.

## BIBLIOGRAFIA

ANP. "Estudo sobre o aproveitamento gás natural do Pré-Sal." (2020) Disponível em: <<https://www.gov.br/anp/pt-br/centrais-de-contenido/publicacoes/livros-e-revistas/arquivos/aproveitamento-presal.pdf>>. Acesso em: 04/03/2022.

Aum, Pedro Tupã Pandava. *Aplicação de sistemas microemulsionados ácidos em acidificação de poços*. MS thesis. Universidade Federal do Rio Grande do Norte, 2011.

Breiman, Leo. "Random forests." *Machine learning* 45.1 (2001): 5-32.

Duleba, Wânia. "Interpretações paleoambientais obtidas a partir das variações na coloração das carapaças de foraminíferos, da Enseada do Flamengo, SP." *Boletim do Instituto Oceanográfico* 42 (1994): 63-72.

El Naqa, Issam, and Martin J. Murphy. "What is machine learning?." *machine learning in radiation oncology*. Springer, Cham, 2015. 3-11.

Lima, Mariana Quezado Costa, Clarissa Figueiredo Sampaio Freitas, and Daniel Ribeiro Cardoso. "Modelagem da informação para a regulação urbanística dos assentamentos precários em Fortaleza." *urbe. Revista Brasileira de Gestão Urbana* 11 (2019).

Mota, Jaedson Cláudio Anunciato, et al. "Atributos mineralógicos de três solos explorados com a cultura do melão na chapada do Apodi: RN." *Revista Brasileira de Ciência do Solo* 31 (2007): 445-454.

Oliveira, Lucas Abreu Blanes de. *Modelagem geoquímica e mineralógica dos reservatórios carbonáticos do pré-sal da bacia de Santos através de perfis de poços e inteligência artificial*. Diss. Universidade de São Paulo, 2022.

Patrocínio, Guilherme Augusto Ferraiolo, and Marcio Augusto Sampaio Pinto. "Recuperação melhorada de reservatórios de petróleo sob injeção WAG-CO<sub>2</sub> utilizando metamodelos." *Simpósio Internacional de Iniciação Científica e Tecnológica da USP-SIICUSP* (2018).

Zhang, Yilun, et al. "A library of BASIC scripts of reaction rates for geochemical modeling using phreeqc." *Computers & Geosciences* 133 (2019): 104316.