

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



TÍTULO DO TRABALHO:

Estudo da aplicação de um modelo de ANN para a modelagem de permeabilidades relativas sob efeitos de salinidade

AUTORES:

Mateus Bertuzzi, Vinicius Czarnobay, Damianni Sebrão, Luiz A. Hegele Jr.

INSTITUIÇÃO:

Departamento de Engenharia de Petróleo, CESFI, Universidade do Estado de Santa Catarina

Estudo da aplicação de um modelo de ANN para a modelagem de permeabilidades relativas sob efeitos de salinidade

Resumo

Redes neurais artificiais têm sido empregadas para prever mudanças em curvas de permeabilidade relativa devido a variações na salinidade da água de injeção. Em trabalhos recentes, a incorporação de dados reais para treinamento, otimização de hiperparâmetros da rede e uma implementação de rede dupla para melhorar a normalização foram implementadas. Os modelos estão prontos para uso com a entrada de uma curva de permeabilidade relativa inicial, salinidade inicial e uma baixa salinidade projetada de interesse, tendo como saída a nova curva de permeabilidade relativa estimada. Aqui, propomos um estudo de validação aplicando os modelos treinados em novos dados reais. Dois ensaios experimentais foram coletados da literatura e as curvas foram comparadas às previsões do modelo. Observou-se uma boa predição das permeabilidades relativas normalizadas (formato das curvas) e desvios na predição dos pontos terminais, porém menos significativos para a fase óleo. Este estudo é importante avaliar a eficiência dos modelos quando aplicados a dados reais, garantindo o uso adequado em projetos de injeção de água projetada (EWI) e injeção de água de baixa salinidade (LSWI), auxiliando na modelagem da recuperação avançada para campos de petróleo.

Palavras-chave: Recuperação avançada de petróleo (EOR), injeção de água de baixa salinidade (LSWI), permeabilidades relativas, redes neurais artificiais (ANN).

Abstract

Artificial neural networks have been employed to predict changes in relative permeability curves due to variations in the salinity of injection water. Recent studies have incorporated real data for training, hyperparameter optimization, and a dual network implementation to improve normalization. These models are designed to take an initial relative permeability curve, initial salinity, and a target low salinity as inputs, outputting the estimated new relative permeability curve. This study proposes a validation process by applying the trained models to new real-world data. Two experimental datasets from the literature were collected, and the curves were compared to the model predictions. The results showed good prediction of normalized relative permeabilities (curve shapes) and deviations in predicting endpoint values, but minor for the oil phase. This study is important to evaluate the efficiency of the models when applied to real data, ensuring their appropriate use in engineered water injection (EWI) and low salinity water injection (LSWI) projects, thereby aiding in advanced recovery modeling for oil fields.

Keywords: Enhanced oil recovery (EOR), low salinity water injection (LSWI), relative permeabilities, artificial neural networks (ANN).

Introdução

A capacidade de escoamento de um fluido através do meio poroso de um reservatório, em um sistema multifásico, é determinada pelas curvas de permeabilidade relativa obtidas durante a exploração. Essas curvas fornecem informações essenciais sobre como diferentes fluidos, como água e óleo, se comportam e interagem dentro do meio poroso, bem como a capacidade de recuperação de petróleo em um reservatório sujeito à injeção imiscível. A permeabilidade relativa (k_r) está intrinsecamente ligada à condição de molhabilidade do sistema rocha-fluido, propriedade que se refere à preferência de um fluido em aderir à superfície dos grãos da rocha, o que influencia na distribuição dos fluxos no reservatório.

Alguns métodos de recuperação avançada (EOR) como a injeção de água de baixa salinidade (LSWI, de *low-salinity water injection*) promovem a alteração da molhabilidade do reservatório, levando-o a uma condição intermediária ou mais molhável à água, o que facilita o deslocamento do óleo e permite a redução da saturação de óleo residual (S_{or}). Desse modo, a LSWI melhora a eficiência da recuperação, além de possuir vantagens operacionais em relação a outros métodos EOR, devido à pouca necessidade de mudança no esquema de injeção de água convencional.

Dado o efeito da molhabilidade sobre as curvas de permeabilidade relativa, o uso de dois conjuntos de curvas k_r (para alta e para baixa salinidade) é o modo mais efetivo de definir a LSWI em uma simulação de reservatórios (Gilavand *et al.*, 2013). No entanto, ensaios experimentais para obtenção das curvas de permeabilidade relativa podem ser custosos e demorados, e modelos numéricos de LSWI são geralmente limitados a interpolações lineares, mesmo em simuladores comerciais. Para mitigar esses desafios e considerar a dinâmica complexa e não linear do escoamento em reservatórios, uma das soluções inovadoras desenvolvidas recentemente é o uso de métodos de aprendizado de máquina para prever o comportamento das curvas de permeabilidade relativa (Reginato *et al.*, 2019; Dang *et al.*, 2020; Reginato *et al.*, 2021). Tais métodos permitem a estimar novas curvas k_r por meio de uma modelagem baseada no aprendizado experiencial sobre dados já disponíveis.

Em Czarnobay *et al.* (2024), redes neurais artificiais (ANN, de *artificial neural networks*) foram treinadas com dados experimentais obtidos da literatura, para rochas carbonáticas e areníticas, gerando modelos representativos dos efeitos de salinidade reais reportados em estudos sobre o tema. Os hiperparâmetros da rede foram otimizados para cada modelo, e uma análise de erro numérico foi conduzida para confirmar o bom ajuste da rede. O presente trabalho tem como objetivo uma aplicação e breve validação desse modelo, contrastando a resultados de novos estudos sobre o efeito da redução da salinidade em curvas de permeabilidades relativas.

Metodologia

Por meio de uma revisão de trabalhos que apresentam curvas de permeabilidade relativa em condições de alta e baixa salinidade, buscou-se por curvas k_r inéditas aos modelos treinados. Foram selecionadas duas amostras de publicações que continham curvas k_r experimentais para LSWI aptas a comparação com o modelo. A Tabela 1 contém o tipo de rocha e teores de salinidade dessas amostras.

Tabela 1: Principais características das amostras trabalhadas.

Amostra	Autor	Rocha	TDS (ppm)
1	Khosravi <i>et al.</i> (2015)	Arenito	42000 - 4000
2	Mokhtari <i>et al.</i> (2022)	Arenito	40000 – 10000


Fonte: Acervo dos autores.

Khosravi *et al.* (2015) aponta que a simulação de reservatórios envolve incertezas significativas nas propriedades materiais, além do custo dos métodos experimentais tradicionais para estimar permeabilidades relativas e pressão capilar. O estudo determina essas propriedades para amostras areníticas, com e sem argila, sob baixa salinidade, usando um simulador acoplado a um algoritmo de otimização. Observou-se que a redução da salinidade diminuiu mais a permeabilidade relativa da água do que aumentou a do óleo, e a presença de argila deslocou as curvas para saturações mais altas. As curvas k_r experimentais apresentadas no estudo, que aqui são utilizadas para a validação do modelo, foram obtidas de experimentos de Rivet *et al.* (2010).

O trabalho de Mokhtari *et al.* (2022) aborda a injeção combinada de água de baixa salinidade e polímero para EOR. Dez testes laboratoriais avaliaram os efeitos da LSWI em amostras areníticas sem argila. Após os ensaios experimentais, as curvas k_r apresentadas foram estimadas por meio de software, indicando uma mudança para uma condição mais molhável à água e uma redução na S_{or} .

As curvas de permeabilidade relativa para alta salinidade (HS) e baixa salinidade (LS) desses estudos foram extraídas e interpoladas, para aplicação no modelo e posterior comparação gráfica. O modelo treinado utilizado é uma adaptação dos modelos de ANN apresentados em Czarnobay *et al.* (2024). Como representado na Figura 1, as entradas do modelo já treinado são os valores de saturação de água (S_w), valores de permeabilidade relativa à água (k_{rw}) e ao óleo (k_{ro}) da curva HS inicial, a salinidade inicial e o valor desejado para a nova salinidade. Dentro do modelo, as curvas são normalizadas para aplicação na rede treinada.

Figura 1: Esquema de entradas e saídas da aplicação do modelo treinado.



Fonte: Acevo dos autores.

Nos mais recentes modelos treinados e otimizados pelos autores, duas redes neurais artificiais são utilizadas para a modelagem do problema: uma para a predição de novos pontos k_r normalizados (estimando o formato da curva) e outra para a predição dos novos pontos terminais, usada para o retorno das curvas às variáveis originais. Na primeira, as entradas são a salinidade HS inicial, 20 pontos k_r da curva HS interpolados e normalizados pelo seu valor máximo, e a nova salinidade LS, tendo como saída os pontos normalizados da curva LS. Para a segunda, as entradas são as mesmas, com a inclusão dos


pontos terminais (S_{wi} , $1-S_{or}$, $k_{rw_{max}}$, $k_{ro_{max}}$), e a saída são apenas os novos pontos terminais das curvas LS. Os modelos estão prontos para uso, e mais detalhes serão apresentados em futura publicação. O código de programação para a aplicação dos modelos utiliza a biblioteca TensorFlow para a importação das redes treinadas.

As curvas HS das amostras 1 e 2 foram aplicadas no modelo, junto à salinidade respectiva e à baixa salinidade. As saídas do modelo foram então comparadas às curvas LS de cada amostra de referência. Com a estimativa gerada pela ANN, foi realizada uma análise dos erros em relação à curva real obtida diretamente dos artigos. Essa análise envolveu a comparação dos pontos normalizados e dos pontos terminais das curvas previstas em relação às reais, trazendo informações sobre a robustez e a capacidade de generalização da ANN.

Resultados e Discussão

A Figura 2 mostra as curvas de permeabilidade relativa de entrada (caso HS) e compara as curvas LS estimadas pelo modelo de ANN com as curvas LS de referência para cada amostra. Para a amostra 1 (Figura 2A), é possível notar um comportamento estimado muito similar ao da curva de referência. É perceptível um desvio entre os valores preditos e reais, porém o deslocamento das curvas para a direita foi representado, indicador da mudança a uma condição mais molhável à água. Na curva de permeabilidade relativa à água é possível notar uma boa concordância entre as curvas no início, porém um desvio ao se aproximar do valor máximo, que é sobrestimado pelo modelo. Para fase referente ao óleo obteve-se um valor de k_{ro} máximo muito similar ao dado na referência, apesar de um desvio no valor de saturação nesse ponto.

Figura 2: A) Comparação das curvas para amostra 1, B) Comparação das curvas para amostra 2.




Fonte: Acervo dos autores

Para a amostra 2 (Figura 2B), observa-se uma discrepância ligeiramente maior nos valores máximos de permeabilidade relativa das fases. Novamente, a curva de permeabilidade relativa à água foi similar à referência ao longo do aumento da saturação, porém divergente ao final. A curva de permeabilidade relativa ao óleo não foi corretamente predita, mostrando o deslocamento à direita não

observado na curva de referência, que mostra pouca mudança em relação à curva HS. Nesse caso, vale ressaltar que o comportamento observado na curva de referência diverge do que normalmente é encontrado em ensaios de LSWI. Curvas com um deslocamento mais pronunciado foram usadas para o treinamento da rede, o que explica tal diferença nas estimativas para o caso.

A Figura 3 compara os resultados normalizados pelo valor máximo de permeabilidade relativa para cada fase (óleo e água), permitindo uma comparação proporcional entre os resultados. Isso mostra os resultados brutos da aplicação da primeira rede, que prevê o formato das curvas antes da aplicação dos valores terminais que desfazem a normalização.

Figura 3: Comparativo entre as permeabilidades relativas estimadas e de referência, normalizadas pelos valores máximos, representando a predição do formato das curvas.



Fonte: Acervo dos autores

Para amostra 1 (Figura 3A) os coeficientes de determinação (R^2) da regressão linear foram de aproximadamente 0,987 para a curva k_{rw} e 0,997 para a curva k_{ro} . A raiz do erro quadrático médio (RMSE, de *root mean square error*) foi 0,055 para a curva k_{rw} e 0,020 para a curva k_{ro} . Tais resultados indicam uma boa previsão do modelo para o comportamento das curvas, especialmente para a fase óleo. A confirmação dos resultados favoráveis é evidenciada na amostra 2 (Figura 3B). Apesar da leve oscilação inicial, a regressão linear mantém um valor elevado de R^2 . O RMSE para a amostra 2 foi de 0,044 para a curva k_{rw} e de 0,050 para a curva k_{ro} .

Para a predição dos pontos terminais, pela segunda rede, obteve-se um RMSE de 0,086 para a amostra 1 e de 0,115 para a amostra 2, maiores que os erros encontrados no modelo de predição dos pontos normalizados. Os erros absolutos na predição dos pontos terminais são apresentados nas Tabelas 2 e 3.

Tabela 2: Valores dos pontos terminais e erros absolutos associados à amostra 1.

Dado	Referência	Modelo	Erro
$k_{rw_{max}}$	0,198	0,341	0,143
$k_{ro_{max}}$	0,838	0,868	0,031
S_{wi}	0,107	0,178	0,072
$1 - S_{or}$	0,795	0,853	0,057

Fonte: Acervo dos autores.

Tabela 3: Valores dos pontos terminais e erros absolutos associados à amostra 2.

Dado	Referência	Modelo	Erro
$k_{rw_{max}}$	0,252	0,404	0,153
$k_{ro_{max}}$	0,909	0,778	0,131
S_{wi}	0,205	0,242	0,037
$1 - S_{or}$	0,692	0,762	0,070

Fonte: Acervo dos autores.

Os erros absolutos indicam diferenças entre os valores preditos e reais, sendo mais considerável para as permeabilidades relativas máximas à água. Os erros obtidos na predição dos pontos terminais de saturação variaram de 0,03 a 0,07, o que é uma diferença pequena, mas que pode ter grande impacto nos resultados de uma simulação de recuperação, por exemplo. Uma vez que os pontos terminais preditos são usados para o retorno da normalização das curvas preditas pela primeira rede, isso pode explicar os maiores desvios observados nas curvas finais (Figura 2).

Apesar dos desvios observados, os resultados são promissores, mostrando o potencial das ANN na previsão de curvas de permeabilidade relativa em função da salinidade. A melhoria, especialmente das redes utilizadas na predição dos pontos terminais, pode melhorar o desempenho dos modelos. Com ajustes e otimizações, a tecnologia pode economizar investimentos significativos em testes experimentais, representando um avanço importante na redução de custos e aumento da eficiência nos processos de previsão de permeabilidade relativa.

Conclusões

O estudo aplicou modelos baseados em ANN previamente desenvolvidos para estimar alterações em permeabilidades relativas devido à efeitos de salinidade, comparando as predições do modelo aos resultados de duas amostras coletadas da literatura. Enquanto a predição dos pontos normalizados das curvas de permeabilidade relativa (representando a predição do formato das curvas) mostrou bons resultados, com alto coeficiente de determinação com a referência, a predição dos pontos terminais mostrou um maior desvio das estimativas em relação ao esperado. Como os modelos treinados realizam a predição de permeabilidades relativas normalizadas e pontos terminais em duas redes distintas, infere-se que a rede destinada à predição dos pontos terminais pode ser aprimorada, especialmente em relação à quantidade e qualidade dos dados de treinamento.

Os erros relativos foram maiores para a predição dos pontos terminais da fase água, e menores para a fase óleo. Tais resultados são promissores, dado o interesse nas informações da fase óleo, especialmente a saturação de óleo residual, que representa diretamente a capacidade de extração de óleo de um reservatório sob recuperação. Os modelos, desse modo, mostram-se como uma boa ferramenta de triagem inicial para projetos de LSWI: rapidamente é possível obter estimativas de novas curvas de permeabilidade relativa para menores salinidades, não tão distantes das obtidas por meios experimentais. A confiabilidade e qualidade dos resultados, vale ressaltar, não supera a importância de análises experimentais reais. Futuros trabalhos de validação podem aumentar a robustez do estudo analisando mais amostras, com tratamento estatístico, ou utilizando novos ensaios experimentais para comparação, permitindo confirmar o potencial econômico e inovador das técnicas de aprendizado de máquina para o tema.

Referências Bibliográficas

CZARNOBAY, Vinicius, LAMAS Luis F., SEBRÃO, Damianni, HEGELE JR., Luis A. Modeling alterations in relative permeability curves due to salinity using artificial neural networks. *Computational Geosciences*, p. 1-15, 2024.

DANG, Cuong et al. Ai based mechanistic modeling and probabilistic forecasting of hybrid low salinity chemical flooding. *Fuel*, Elsevier, v. 261, p. 116445, 2020.

GILAVAND, Mostafa et al. Simulation study of affecting parameters during low salinity water injection in carbonate reservoirs: from core to field scale. *Journal of Dispersion Science and Technology*, p. 1-11, 2023.

KHOSRAVI, Razieh; SIMJOO, Mohammad; CHAHARDOWLI, Mohammad. Low salinity water flooding: estimating relative permeability and capillary pressure using coupling of particle swarm optimization and machine learning technique. *Scientific Reports*, v. 14, n. 1, p. 13213, 2024.

MOKHTARI, Farzad; RIAHI, Siavash; ROSTAMI, Behzad. Experimental study of secondary and tertiary modes combined low salinity water and polymer flooding in sandstone porous media. *The Canadian Journal of Chemical Engineering*, v. 101, n. 2, p. 1095-1108, 2023.

REGINATO, Leonardo Fonseca et al. Prediction of wettability alteration using the artificial neural networks in the salinity control of water injection in carbonate reservoirs. In: ONEPETRO. Offshore technology conference Brasil, 2019.

REGINATO, Leonardo Fonseca et al. Optimization of ionic concentrations in engineered water injection in carbonate reservoir through ANN and FGA. *Oil & Gas Science and Technology – Revue d'IFP Energies nouvelles*, EDP Sciences, v. 76, p. 13, 2021.

RIVET, Scott M.; LAKE, Larry W.; POPE, Gary A. A coreflood investigation of low-salinity enhanced oil recovery. In: SPE Annual Technical Conference and Exhibition. SPE, 2010. p. SPE-134297-MS.