

Solução da Equação de Buckley-Leverett para a injeção de gás em um reservatório utilizando PINN

Átila L. A. Silva¹, Sinesio Pesco², Abelardo B. Barreto³
 PUC-Rio, Rio de Janeiro, RJ

Neste trabalho utilizaremos a biblioteca disponível no Python chamada PyTorch [1] para desenvolver uma Rede Neural que utiliza a teoria de fluxo fracionário de Buckley-Leverett [2] para simular a injeção de gás em um reservatório saturado de água. Para tal, precisamos assumir que: (1) temos um escoamento unidimensional em um meio poroso homogêneo, incompressível, isotrópico e isotérmico, (2) há apenas duas fases fluindo no reservatório (água e gás), (3) as fases são incompressíveis, (4) existe equilíbrio local e (5) a gravidade e a capilaridade são desprezíveis. Com essas hipóteses, a equação adimensionalizada de Buckley-Leverett para a fase de gás é dada por:

$$\frac{\partial S_g}{\partial t_D} + \frac{\partial f_g}{\partial S_g} \frac{\partial S_g}{\partial x_D} = 0 \quad (1)$$

onde $S_g(x_D, t_D)$ é a saturação de gás, $f_g(S_g)$ é o fluxo fracionário do gás, t_D é o tempo e x_D é a distancia ambos adimensionalizados. A função de fluxo fracionário de gás é definida como a razão entre a mobilidade do gás e a mobilidade total (de gás e água) e é escrita como:

$$f_g = \frac{\lambda_g}{\lambda_T} = \frac{1}{1 + \frac{k_{rw}\mu_g}{k_{rg}\mu_w}} \quad (2)$$

Onde $k_{rj}(S_w)$, e μ_j são as permeabilidades relativas da fase j, respectivamente. Iremos aqui assumir que ambas as viscosidades são constantes e não dependem da pressão ou da temperatura. Usamos as funções de permeabilidade relativas (Corey et al., 1956)[3]. Utilizamos também as seguintes condições iniciais (I) e condições de contorno (J):

$$I : S_g(x_D, t_D = 0) = 0 \quad J : S_g(x_D = 0, t_D) = 1 - S_{wr} \quad (3)$$

Nosso objetivo é desenvolver uma rede neural PINN (Physics Informed Neural Network) que consiga prever com uma precisão razoável uma solução para a equação (1) adicionando um termo difusivo de acordo com Fuks and Tchelepi (2020)[4]. Para a função custo a definimos como:

$$\mathcal{L} = \mathcal{L}_R + \mathcal{L}_C \quad (4)$$

onde \mathcal{L}_R é o custo dos pontos de colocação, que são pontos selecionados aleatoriamente em nosso domínio de interesse e \mathcal{L}_C é o custo obtido pelas condições iniciais e de contorno que impomos na construção da rede. O resultado do treino podemos ver à esquerda da Figura 1 e o progresso da função custo podemos ver à direita.

¹atilaluna@id.uff.br

²sinesio@puc-rio.br

³abelardo.puc@gmail.com

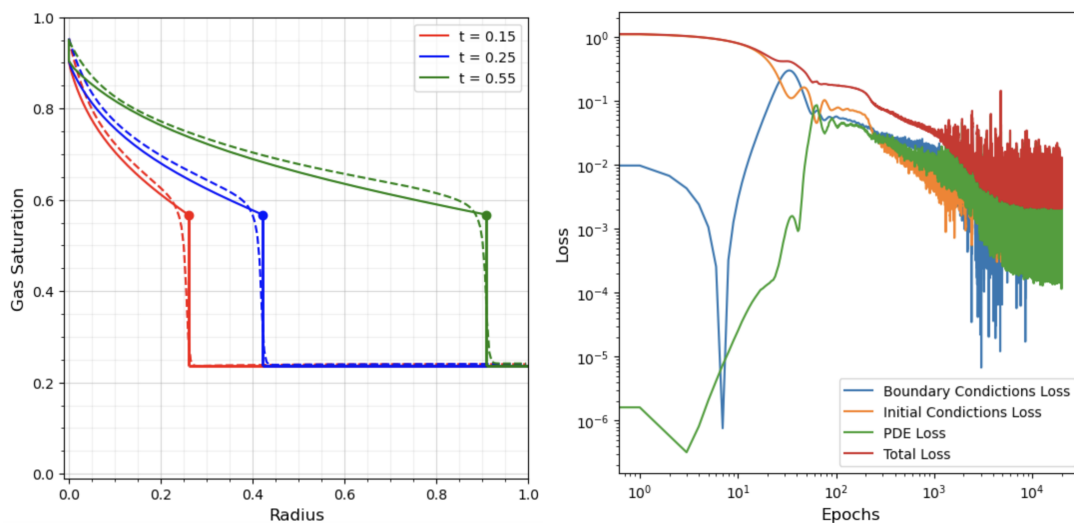


Figura 1: Solução analítica em comparação com a solução obtida com PINN e função custo

Uma das hipóteses de Buckley-Leverett é assumir que o gás é um fluido incompressível mas sabemos que o gás possui alta compressibilidade. Com isso buscamos explorar diferentes modelos de EDPs que incorporem compressibilidade. Mais ainda, podemos deixar alguns parâmetros sendo treináveis, como por exemplo o termo difusivo, pois vimos que alterando o valor dele, a função custo tende a melhorar ou piorar dependendo do caso. Por último desejamos utilizar dados reais e/ou sintéticos. De acordo com [5] a solução da rede neural ganha um impacto ainda maior na precisão com a adição de dados observados na função custo.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico e Petrobras como parte do projeto TCBR 485.

Referências

- [1] E. Stevens, L. Antiga e T. Viehmann. **Deep Learning with PyTorch**. United States of America: Manning Publications Co., 2020. ISBN: 9781617295263.
- [2] S. E. Buckley e M. C. Leverett. “Mechanism of Fluid Displacement in Sands”. Em: **Transactions of the AIME** (1942). DOI: 10.2118/942107-g.
- [3] A. T. Corey et al. “Three-Phase Relative Permeability”. Em: **Journal of Petroleum Technology** (1956). DOI: 10.2118/737-g.
- [4] O. Fuks e H. A. Tchelepi. “Limitations of Physics Informed Machine Learning for Nonlinear Two-phase Transport in Porous Media”. Em: **Journal of Machine Learning for Modeling and Computing** (2020), pp. 19–37. ISSN: 2689-3967.
- [5] M. M. Almajid e M. O. Abu-alsaud. “Prediction of Fluid Flow in Porous Media using Physics Informed Neural Networks”. Em: **Society of Petroleum Engineers** (2020), pp. 1–13. DOI: 10.2118/203033-MS.