

Predição de fluxo em teste de injetividade via Physics-Informed Machine Learning(PIML)

Antonio C. B. de Andrade,¹ Sinesio Pesco²

Abelardo B. Barreto³

Departamento de Matemática/PUC-Rio, Rio de Janeiro, RJ

Na indústria de óleo e gás são frequentes problemas de fluxo envolvendo múltiplos fluidos. Uma das técnicas utilizadas para calcular a frente de avanço de dois fluidos é a teoria do Buckley-Leverett [1]. Nas técnicas envolvendo avaliação de formações, o processo de injeção de um determinado fluido, normalmente água e gás, permite estimar propriedades petrofísicas do reservatório. Neste caso, a simulação passa a envolver dois ou mais fluidos. A localização da frente de avanço, frente de choque ou simplesmente choque, é crucial para determinar o quão distante está a chegada da água no poço de produção. Esse problema pode ser modelado através de uma Equação Diferencial Parcial(EDP) dada por

$$\frac{\partial S_w}{\partial t_D} + \frac{\partial f_w(S_w)}{\partial x_D} = 0 \quad (1)$$

onde:

- $S_w(x_D, t_D)$ é a saturação da água, $f_w(S_w)$ é o fluxo fracionário da água, x_D e t_D são o espaço e o tempo adimensionais, respectivamente.

Nesta equação a derivada do fluxo fracionário define o movimento da frente de avanço através do reservatório linear. Note que a equação do Buckley Leverett afirma que a saturação de água se movimenta em um meio poroso a uma velocidade que pode ser analisada a partir da derivada do fluxo fracionário em relação a saturação da água. Vale salientar que se o fluxo fracionário depende apenas da saturação de água, então esta equação pode ser integrada para obter a solução analítica, por exemplo, através do Método das Características[2].

Tratando-se de um problema de Engenharia de Reservatórios, sabemos que aplicações desse tipo são categorizados no regime de dados pequenos[3]. Abordagem *Physics Informed Machine Learning* (PIML)[4] tem sido investigada em uma grande variedade de problemas físicos computacionais[4], com o objetivo de permitir que uma rede neural seja treinada para solucionar EDPs.

Nosso principal objetivo é desenvolver uma rede neural baseada no PIML para otimizar a solução de um problema de escoamento bifásico, água e óleo, em um meio poroso atrelado a uma EDP hiperbólica não-linear de primeira ordem, sujeita a condições iniciais e de contorno. Para isso, utilizaremos a *Fully connected Neural Network*(FNN) que consiste em 8 camadas ocultas com 20 neurônios cada. A função de ativação tangente hiperbólica é usada em todas as camadas ocultas. Utilizaremos o otimizador ADAM. Para o treinamento de dados, usaremos 300 pontos aleatórios distribuídos nas condições iniciais e de contorno, e 10000 pontos de colocação para o termo residual, os quais estão amostrados aleatoriamente no interior do domínio $x \in [0, 1]$, $t \in [0, 1]$.

A biblioteca de código aberto *Tensorflow*[5] criada para o aprendizado de máquina foi utilizada para a implementação da rede neural. A imagem a seguir é uma reprodução de [4] em que foi

¹toony.2015@icloud.com

²sinesio@puc-rio.br

³abelardo.puc@gmail.com

prevista a frente de avanço no tempo $t = 0.25$ de uma função de fluxo côncava denotada por $f_w(u) = \frac{u}{u + \frac{1-u}{M}}$, onde $M = \frac{\mu_o}{\mu_w}$ é a razão de viscosidade das fases (óleo e água) e u é a saturação da água S_w .




Figura 1: Predição da rede neural (em vermelho) com a solução exata (em azul) utilizando o Método das Características da EDP(1). Fonte: Autoria própria.

Um dos objetivos do nosso trabalho é seguir nesta direção incorporando ao modelo poços injetores e produtores e avançar no estudo do comportamento da frente de avanço para diferentes configurações destes poços no reservatório, como por exemplo, diferentes valores de vazões e permeabilidades.

Agradecimentos

O presente trabalho foi realizado com apoio da CAPES- Código de Financiamento 001, CNPq e Petrobras como parte do projeto TCBR 485.

Referências

- [1] J. C. Araujo e R. G. Marquez. “Problema de Buckley e Leverett: aproximação de funções para a estimativa da saturação de choque”. Em: **Revista Eletrônica Paulista de Matemática** 16 (2019).
- [2] R. Knobel. **An introduction to the mathematical theory of waves**. Student mathematical library. 1999. ISBN: 0-8218-2039-7.
- [3] P. P. Raissi e G. E. Karniadakis. “Physics-informed deep learning (Part I): Data-driven solutions of nonlinear partial differential equations”. Em: (2017). DOI: 10.1016/j.jcp.2018.10.045.
- [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** 1 (2020), pp. 19–37.
- [5] DIDATICATECH. **O que é TensorFlow? Para que serve?** Online. Acessado em 10/01/2023, <https://didatica.tech/o-que-e-tensorflow-para-que-serve/>.