

Modelagem Computacional de Parâmetros Empíricos para o Transporte e Retenção de Partículas em Meios Porosos Utilizando Redes Neurais MLP

Pedro A. P. Pinheiro,¹ Jocenrique C. O. Rios, Sidarta A. Lima, Adriano dos Santos
Universidade Federal do Rio Grande do Norte, UFRN, Natal, RN

A modelagem da retenção de partículas durante o transporte de suspensões em meios porosos tem sido extensivamente abordada na indústria do petróleo e engenharias civil, química e ambiental [4, 6, 7]. Em particular, na indústria do petróleo a retenção de partículas e o consequente bloqueio de poros podem ocorrer durante os processos de injeção de água do mar e reinjeção de água produzida [6, 7].

A retenção de partículas surge devido à mecanismos físico-químicos, tais como exclusão pelo tamanho e adsorção/dessorção. No mecanismo de exclusão pelo tamanho uma partícula é retida em um poro de raio inferior [1, 3]. Por sua vez, os fenômenos de adsorção/dessorção surgem devido aos efeitos físico-químicos entre as partículas e a fase sólida no meio poroso [4, 6]. A retenção e a consequente obstrução de poros provocam uma significativa redução da permeabilidade. Nesses cenários, pode ocorrer perda de injetividade e queda na produção dos hidrocarbonetos, gerando aumento nos custos de produção devido à necessidade de intervenções, tais como: acidificação, fluxo reverso ou fraturamento hidráulico [4, 6, 7].

Neste trabalho, o objetivo principal é construir uma ferramenta computacional baseada em uma rede neural perceptron multicamadas (MLP), capaz de quantificar numericamente os parâmetros do modelo matemático para um dado perfil da concentração efluente [1, 3]. Para tanto, o modelo matemático do problema direto para a concentração de partículas consiste de uma equação diferencial em regime hiperbólico dominante. Além disso, a concentração de partículas retidas é quantificada considerando uma EDO. Do ponto de vista da modelagem numérica, foi utilizado o método de Runge-Kutta para aproximar a equação da cinética de retenção. Por sua vez, para discretização da equação do transporte das partículas, propõe-se o esquema de volumes finitos de alta ordem Kurganov & Tadmor (KT), assegurando boa acurácia mesmo na presença de fortes camadas limites [2].

De posse de soluções numéricas, que consiste na evolução da concentração efluente para um dados conjuntos de parâmetros efetivos, é implementada uma rede MLP para quantificar o problema inverso [3]. As redes MLP permitem postular arquiteturas complexas, bem como simular numericamente com boa acurácia problemas fortemente não lineares [5]. Postulando convenientemente funções de ativação que permitem quantificar o sinal de saída em cada neurônio, o processo de treinamento denominado *backpropagation* consiste em quantificar os pesos sinápticos ótimos de modo a ajustar um conjunto de dados fornecidos a rede [5]. No contexto da aplicação proposta, o conjunto de dados de entrada consiste nos perfis de concentração efluente. Por sua vez, os valores de cada coeficiente efetivo são os dados de saída da rede. Na primeira etapa do processo, considerando uma estimativa para os pesos sinápticos, foi introduzida uma amostra da concentração efluente, obtendo como saída os valores aproximados para cada parâmetro efetivo. Em seguida, o erro entre os parâmetros efetivos obtidos pela rede neural e o conjunto de treinamento é utilizado para atualizar os pesos sinápticos. Concluído o processo de treinamento, os pesos sinápticos estarão ajustados e a rede neural estará apta a realizar previsões e tomada de decisões.

¹pedroappinheiro@outlook.com

Com o objetivo de demonstrar as potencialidades do modelo matemático e computacional apresentado, é proposto algumas simulações numéricas para o transporte de partículas em suspensão. Para as simulações numéricas foi postulado um comportamento linear para o fenômeno da retenção caracterizado pelos coeficientes de filtração e retenção λ e β , respectivamente [3]. Na figura 1 é apresentado a evolução da concentração efluente obtida pelo modelo numérico para diferentes valores dos coeficientes. Postulando diferentes valores de λ e β com os respectivos perfis adimensionais da concentração efluente, é realizado o treinamento da rede MLP para 2350 amostras considerando a função de ativação tangente sigmoide hiperbólica nas camadas escondidas e a função identidade na camada de saída. Utilizando o método de otimização bayesiana, foi obtida uma arquitetura composta de 4 camadas escondidas com 5, 40, 5 e 10 neurônios, respectivamente. Nas colunas 1 e 3 da tabela 1 estão disponíveis os valores obtidos pela rede MLP para os coeficientes de filtração e retenção. Por sua vez, nas colunas 2 e 4 é possível observar os valores reais fornecidos ao problema direto. Os erros relativos demonstrados nas colunas 5 e 6 retratam a boa acurácia nas previsões obtidas pela rede MLP. Como resultado principal, apresentamos uma primeira versão do aplicativo computacional baseado em redes neurais multicamadas, capaz de quantificar os parâmetros efetivos do transporte de partículas em suspensão e retidas para um dado perfil empírico da concentração efluente.




Figura 1: Evolução da Concentração Efluente.

λ_{MLP}	λ	β_{MLP}	β	Erro λ	Erro β
3.6997	3.7	2.2002	2.2	6.91e-05	1.11e-04
4.3998	4.4	0.99961	1	4.58e-05	3.93e-04
3.5004	3.5	0.19927	0.2	1.19e-04	3.64e-03
4.2006	4.2	12	12	1.39e-04	3.05e-05

Tabela 1: Valores Numéricos e Reais dos Coeficientes de Filtração e Retenção.

Referências

- [1] E. R. Gomes, A. Santos e S. A. Lima. “Numerical modeling of straining: the role of particle and pore size Distributions”. Em: **Transport in Porous Media** 120 (2017), pp. 535–551.
- [2] A. Kurganov e E Tadmor. “New high-resolution central schemes for nonlinear conservation laws and convection-diffusion equations”. Em: **Journal of Computational Physics** 160.1 (2000), pp. 241–282.
- [3] J. C. O. Rios, A. Santos e S. A. Lima. “Multiple retention mechanisms during transport in porous media”. Em: **Transport in Porous Media** 140 (2021), pp. 789–813.
- [4] J. et al Rouquerol. **Adsorption by powders and porous solids: principles, methodology and applications**. Academic press, 2013.
- [5] Ivan Nunes da Silva, Danilo Hernane Spatti e Rogério Andrade Flauzino. **Redes Neurais Artificiais. curso prático**. 1ª ed. São Paulo: ArtLiber Editora Ltda., 2010. Cap. 5, pp. 132–146.
- [6] K. S Sorbie. **Polymer-Improved Oil Recovery**. Springer Science+Business Media, 1991.
- [7] A.L.S. Souza et al. “Water management in Petrobras: developments and challenges”. Em: vol. All Days. OTC Offshore Technology Conference. OTC-17258-MS. 2005.