

Mô hình hóa dòng chảy 2 pha trong môi trường rỗng bằng mạng nơ-ron thông tin vật lý

Phạm Đăng Trình^{1,2}, Mai Cao Lân^{1,2,*}

TÓM TẮT

Dầu khí là nguồn tài nguyên vô cùng quý báu, và có đóng góp lớn vào nền kinh tế quốc gia. Tuy nhiên, nguồn tài nguyên này thường nằm sâu hàng ngàn mét dưới lòng đất. Vì vậy, sản lượng, điều kiện khai thác dầu khí không thể được đo đạc trực tiếp mà phải thông qua những mô hình mô phỏng. Cụ thể, các mô hình ở đây mô phỏng lại hành xử của chất lưu trong vỉa chứa dầu khí; từ đó dự báo và tối ưu hóa việc khai thác dầu khí. Bên cạnh các mô hình mô phỏng số truyền thống, mạng nơ-ron nhân tạo là một lựa chọn thay thế tốt. Bài nghiên cứu này khảo sát và đưa ra ưu-nhược điểm của cách tiếp cận của mạng nơ-ron thông tin vật lý (physic-informed neural network – PINNs) trong việc mô hình hóa quá trình khai thác dầu đơn giản bằng phương pháp bơm ép nước với bài toán Buckley-Leverett. Kết quả tính toán từ mô hình PINNs trong nghiên cứu này phù hợp rất tốt với nghiệm giải tích của phương trình. Kết quả nghiên cứu cũng cho thấy PINNs có thể được áp dụng cho các bài toán có sự thay đổi lớn về giá trị của các ẩn số trong không gian/thời gian và đặc biệt phù hợp cho các những vấn đề có lượng dữ liệu khan hiếm như trong khảo sát phương án phát triển/khai thác mỏ dầu khí. Ngoài ra, mô hình PINN sau khi huấn luyện đáng tin cậy và có thể sử dụng lâu dài hơn nhờ việc xem xét các thông tin vật lý của quá trình thực tế trong quá trình luyện mạng. Điều này cho thấy tính ứng dụng cao của mạng nơ-ron thông tin vật lý trong mô hình hóa dòng chảy 2 pha trong môi trường rỗng.

Từ khóa: Mạng nơ-ron nhân tạo, Mạng nơ-ron thông tin vật lý, Buckley-Leverett

¹Khoa Kỹ thuật Địa chất và Dầu khí – Đại học Bách Khoa TP.HCM, Việt Nam

²Đại học Quốc gia Thành phố Hồ Chí Minh, Việt Nam

Liên hệ

Mai Cao Lân, Khoa Kỹ thuật Địa chất và Dầu khí – Đại học Bách Khoa TP.HCM, Việt Nam

Đại học Quốc gia Thành phố Hồ Chí Minh, Việt Nam

Email: maicaolan@hcmut.edu.vn

Lịch sử

- Ngày nhận: 30-9-2023
- Ngày chấp nhận: 04-12-2023
- Ngày đăng: 31-12-2024

DOI : 10.32508/stdjet.v6iS17.1247



Bản quyền

© ĐHQG TP.HCM. Đây là bài báo công bố mở được phát hành theo các điều khoản của the Creative Commons Attribution 4.0 International license.



GIỚI THIỆU

Trong khai thác dầu khí, nguồn tài nguyên này luôn nằm bên dưới lòng đất, thường sâu hàng ngàn mét, nên lấy dữ liệu chất lưu và đất đá bên dưới là rất tốn công sức và tiền bạc. Do đó, kỹ thuật mô phỏng vỉa, một kỹ thuật kết hợp giữa toán, vật lý, và khoa học trái đất được sử dụng để mô tả hành xử của chất lưu trong vỉa¹.

Gần đây, một cách tiếp cận khác để mô hình hóa dòng chảy trong vỉa, đang gây nhiều sự chú ý trong ngành công nghiệp dầu khí nhờ vào sự bùng nổ của lượng dữ liệu, là các mô hình mạng nơ-ron nhân tạo. Mạng nơ-ron nhân tạo bao gồm một lớp đầu vào (chứa các đặc trưng của dữ liệu như đường log hay lưu lượng khai), một lớp đầu ra (chứa thông số cần dự báo như áp suất hay độ bão hòa), và nhiều lớp ẩn nằm giữa. Mỗi lớp chứa nhiều nơ-ron, mỗi nơ-ron là một hàm biến đổi phi tuyến tính và các nơ-ron liên kết với nhau qua từng lớp hình thành nên một hàm dự báo. Mỗi một nơ-ron xử lý và chuyển đổi dữ liệu đầu vào thành thông tin có ý nghĩa sau mỗi lớp trong mạng nơ-ron². Trong nước, mạng nơ-ron nhân tạo được ứng dụng trong nhiều lĩnh vực với kết quả rất tiềm năng, như dự báo đường log³, phân loại tương đá⁴, phát hiện

ăn mòn đường ống⁵, hay gần hơn với mô phỏng vỉa là dự báo khai thác^{6,7}. Tuy nhiên, những nghiên cứu trong nước về ứng dụng mạng nơ-ron nhân tạo trong mô phỏng vỉa còn hạn chế.

Trên thế giới, một nghiên cứu vào năm 2015 so sánh giữa các phương pháp tương quan truyền thống với một mạng nơ-ron truyền thẳng (Feedforward Neural Network – FFNN) để dự báo lưu lượng khai thác. Kết quả của FFNN vượt trội hơn hẳn các phương pháp truyền thống (sai số chỉ 13.92% so với hơn 50%)⁸. Sau đó 4 năm, ngoài các thông số như độ thấm và lưu lượng khai thác, áp suất tại thời điểm trước thời điểm dự báo được đưa vào mạng nơ-ron hồi quy (một dạng của mạng nơ-ron nhân tạo dùng cho bài toán chuỗi thời gian) nhằm tăng độ chính xác của dự báo⁹. Ngoài ra, vào năm 2020, dữ liệu mô phỏng từ những vùng vỉa lân cận và chính vỉa đang xét được thêm vào cùng với vật lý vỉa để dự báo áp suất vỉa đang xét bằng FFNN được nghiên cứu. Kết quả cho ra có thể so sánh được với ECLIPSE, một phần mềm thương mại trong mô phỏng vỉa sử dụng phương pháp số truyền thống¹⁰. Vào năm 2023, mạng nơ-ron bộ nhớ dài-ngắn hạn (Long-Short Term Memory – LSTM, một dạng mạng nơ-ron dùng trong bài toán chuỗi thời

Trích dẫn bài báo này: Trình P D, Lân M C. **Mô hình hóa dòng chảy 2 pha trong môi trường rỗng bằng mạng nơ-ron thông tin vật lý**. *Sci. Tech. Dev. J. - Eng. Tech.* 2024; 6(S17):111-121.

gian)¹¹ được dùng để mô phỏng vỉa 3 chiều (3D) và kết quả có hệ số xác định R^2 lên tới 0.99¹².

Mặt khác, thay vì phải yêu cầu dữ liệu có sẵn (well log, kết quả mô phỏng số, kết quả đo đạc thực địa...), mạng nơ-ron thông tin vật lý (Physics Informed Neural Network – PINN) đưa vào xem xét các định luật bảo toàn (khối lượng, động năng, khối lượng)¹³. Các định luật bảo toàn mô tả hành xử, tương tác ngoài đời thực của các sự vật hiện tượng trong tự nhiên, được mô tả dưới dạng phương trình vi phân (Partial Differential Equation – PDE). Trong năm 2020 và 2021 có hai nghiên cứu đầu tiên ứng dụng PINN để mô phỏng một vỉa đơn giản^{14,15}. Vỉa này thuộc bài toán Buckley-Leverett¹⁶, là vỉa một chiều có dòng chảy 2 pha, với một giếng bơm ép nước ở bên trái và 1 giếng khai thác dầu ở bên phải. Kết quả cho ra từ 2 nghiên cứu này gần như tương đồng với nghiệm giải tích giải từ phương trình vi phân Buckley Leverett, chỉ hơi lệch một chút tại các mặt tiến dầu nước^{14,15}. Vào năm 2022, cơ chế tự chú ý được lấy ý tưởng từ mạng thị giác máy tính¹⁷ kết hợp với PINN mô phỏng cùng bài toán cho ra dự báo với sai lệch không đáng kể và cải thiện độ chính xác ở các mặt tiến dầu nước¹⁸. Cùng năm, kiến trúc mạng encode-decoder GRU (Gated Recurrent Unit – một dạng của mạng nơ-ron) kết hợp với PINN cho ra kết quả chính xác, đặc biệt là tại mặt tiến dầu nước¹⁹. Ngoài việc dự báo độ bão hòa nước, PINN còn được ứng dụng để giải bài toán nghịch, tìm thêm độ thấm tương đối và độ nhớt khi kết hợp với nghiệm giải tích²⁰.

Trong bài nghiên cứu này, PINN được áp dụng để dự báo ứng xử của dòng chảy 2 pha trong môi trường lỗ rỗng một chiều, cụ thể là bài toán Buckley-Leverett. Mục tiêu chính là khảo sát tính ứng dụng của PINN thông qua mức độ sai lệch của mô hình. Phần còn lại của bài báo được bố cục như sau: phần 2 trình bày phương pháp luận, phần 3 trình bày và thảo luận kết quả của các mô hình, phần 4 kết luận bài nghiên cứu này.

PHƯƠNG PHÁP LUẬN

Bài nghiên cứu ứng dụng PINN để giải bài toán bơm ép nước để tăng cường thu hồi dầu trong môi trường cát dựa trên thí nghiệm của Buckley-Leverett vào năm 1942¹⁶. Mô hình thí nghiệm của Buckley-Leverett là một mô hình đơn giản hóa bài toán mô phỏng vỉa đa pha, đa chiều khi thêm vào một số giả thiết cho bài toán. Cụ thể, môi trường của chất lưu đồng nhất và đẳng hướng, cùng với 2 pha chất lưu trong môi trường không trộn lẫn, không nén được, và đẳng nhiệt. Toàn bộ miền của chất lưu dịch chuyển là miền một chiều, không thứ nguyên, gồm một đầu bơm ép nước bên trái và một đầu thu hồi dầu bên phải (Hình 1):

Quy trình sử dụng PINN để giải phương trình Buckley-Leverett

Bài nghiên cứu này sử dụng PINN để giải quyết bài toán thông qua khả năng xấp xỉ hàm số của mạng. Cụ thể, phần này trình bày quy trình sử dụng PINN đưa ra hàm dự báo (Hình 2):

- 1. Chọn kiến trúc mạng:** Đầu tiên, cấu trúc của hàm dự báo phải được định hình trước thông qua việc chọn số nơ-ron và số lớp ẩn cho mạng để hình thành kiến trúc của mạng, hay dưới dạng toán học là một hàm dự báo độ bão hòa - $f(W, b, x_D, t_D)$. Hàm này phụ thuộc vào biến độc lập là x_D và t_D , còn biến W và b (Weight - trọng số và bias - sai lệch của tất cả nơ-ron trong mạng) thay đổi trong quá trình huấn luyện.
- 2. Khởi tạo trọng số:** Sau khi PINN đã có kiến trúc, tất cả biến huấn luyện (trainable parameter) của mạng là W và b của từng nơ-ron được chọn một giá trị ngẫu nhiên^{a 21,22}.
- 3. Tạo dự báo:** khi có các giá trị W, b , hàm $f(W, b, x_D, t_D)$ được đưa vào 3 bộ dữ liệu đầu vào dựa trên 3 điều kiện của phương trình Buckley-Leverett để đưa ra giá trị dự báo. Các điều kiện đó là:

- Điều kiện biên: gồm các điểm nằm ngoài biên tại $x_D = 0$ với mọi t_D , có giá trị $S_{wb} = 1$ và có dạng chung là (x_b, t_b) . Dự báo từ điều kiện biên có dạng $f_b(W, b, x_b, t_b)$.
- Điều kiện ban đầu: gồm các điểm tại $t_D = 0$ với mọi x_D , có giá trị $S_{w0} = 0$ và có dạng chung là (x_b, t_b) . Dự báo từ điều kiện ban đầu có dạng $f_o(W, b, x_o, t_o)$.
- Phần phương trình vi phân: gồm các điểm nằm trong miền không thứ nguyên của bài toán với mọi x_D, t_D khác 0, có dạng chung là (x_f, t_f) . Dự báo từ phần này có dạng $f_{in}(W, b, x_f, t_f)$.

- 4. Tính hàm mất mát:** từng phần dự báo (f_b, f_o, f_{in}) sẽ được đánh giá mức độ sai lệch thông qua hàm mất mát:


- Điều kiện biên và điều kiện ban đầu: Hàm mất mát của 2 điều kiện này là trung bình bình phương sai lệch giữa giá trị dự báo và giá trị tại các điều kiện. Các hàm này có dạng lần lượt là:

$$L_b = \frac{1}{N_b} \sum_{i=1}^{N_b} (f_b - S_{wb})^2 \quad (1)$$

$$L_o = \frac{1}{N_o} \sum_{i=1}^{N_o} (f_o - S_{w0})^2 \quad (2)$$

Với N_b, N_o lần lượt là số điểm nằm tại điều kiện biên và điều kiện ban đầu.

^aTrong nghiên cứu này, phương pháp khởi tạo trọng số ngẫu nhiên được chọn là Khởi tạo Xavier [28] do hàm kích hoạt dùng hàm tanh [27].



- *Phần phương trình vi phân:* Hàm mất mát của phần này là trung bình bình phương khi đưa dự báo vào bên trái của phương trình Buckley-Leverett¹⁶:

$$\frac{\partial S_w(x_D, t_D)}{\partial t_D} + \frac{\partial f_w(S_w)}{\partial S_w(x_D, t_D)} \frac{\partial S_w(x_D, t_D)}{\partial x_D} = 0 \quad (3)$$

Với $S_w(x_D, t_D)$ là hàm cần tìm (được thay bằng hàm dự báo f_{in}). Hàm mất mát của phần phương trình vi phân (L_{in}) là trung bình bình phương vế trái của phương trình (3) khi đưa vào hàm f_{in} . Dòng chảy phân đoạn f_w theo công thức độ thấm tương đối loại Corey bậc hai²³ có dạng như sau:

$$f_w = \frac{S_w^2}{S_w^2 + (1 - S_w)^2 / M} \quad (4)$$

Với M là tỉ số linh động của pha bơm ép (nước) trên pha bị bơm ép (dầu), được chọn là 2 trong bài nghiên cứu này.

- Trong mô phỏng số, các bài toán có các vùng không liên tục và độ dốc cao rất dễ dẫn đến thuật toán cho ra kết quả sai. Trong bài toán Buckley-Leverett, mặt tiến dầu nước là một rào cản rất lớn trong việc đưa ra đáp án có độ chính xác cao. Vì vậy, một hệ số phân tán được thêm vào phương trình vi phân để giảm độ dốc, và sự không liên tục. Cụ thể trong bài toán này, hệ số phân tán tham khảo từ bài nghiên cứu của Tchelepi¹⁴ được thêm vào phương trình (3) như sau:

$$\frac{\partial S_w(x_D, t_D)}{\partial t_D} + \frac{\partial f_w(S_w)}{\partial S_w(x_D, t_D)} \frac{\partial S_w(x_D, t_D)}{\partial x_D} - \frac{\partial^2 S_w(x_D, t_D)}{\partial x_D^2} = 0 \quad (3)$$

5. **Cập nhật W, b:** Gradient của hàm mất mát tổng ($L = L_b + L_o + L_{in}$) được tính dựa trên đạo hàm tự động (Automatic Differentiation²⁴), cho ra dL/dW ,

dL/db . Sau đó được dùng để cập nhật lại W, b theo các thuật toán dựa trên Gradient Descent, cụ thể là ADAM²⁵. Mục đích của việc cập nhật này để giảm thiểu sai lệch giữa các điều kiện biên và ban đầu cùng với phương trình (3). Khi sai số của từng phần trong hàm mất mát tổng giảm đến gần bằng 0, hành xử của hàm dự báo $f(W, b, x_D, t_D)$, hay $\bar{S}_w$, bắt đầu đúng với bản chất của bài toán tại các điều kiện biên và điều kiện ban đầu cụ thể.


6. **Kiểm tra hội tụ:** quy trình dự báo rồi sử dụng dự báo để cập nhật W, b lặp đi lặp lại cho đến khi hàm mất mát tổng L cải thiện không đáng kể.

7. **Dự báo:** Sau khi đã huấn luyện xong, toàn bộ W và b của mạng được cố định, không thay đổi được. Khi này, hàm dự báo $f(W, b, x_D, t_D)$ được đưa vào không – thời gian cần dự báo (x_D, t_D) vào và cho ra giá trị dự báo $\bar{S}_w$.

KẾT QUẢ VÀ THẢO LUẬN

Phần này mô tả và phân tích độ chính xác của PINN khi so với nghiệm giải tích (giải bằng phương pháp đặc trưng – Method of Characteristics (MOC)²⁶) trong bài toán của Buckley-Leverett. Thêm nữa, các mô hình PINN được xây dựng và huấn luyện trên nền tảng thư viện Pytorch²⁷. Pytorch là một thư viện chuyên giải quyết các bài toán về Mạng nơ-ron nhân tạo và hỗ trợ tính đạo hàm rất nhanh và chính xác thông qua thuật toán Automatic Differentiation²⁴.

Việc chọn kiến trúc mạng cho PINN bắt đầu từ việc tham khảo kiến trúc mạng của bài báo PINN gốc¹³ và bài nghiên cứu đầu tiên về PINN giải quyết bài toán Buckley-Leverett¹⁴, sau đó thay đổi để tìm kiến trúc tối ưu. Sau cùng, kiến trúc mạng gồm 8 lớp ẩn và 20 nơ-ron/ lớp ẩn là tối ưu nhất. Thêm nữa, số điểm dữ liệu của điều kiện biên và ban đầu, cùng với điểm trong miền bài toán được chọn để đưa vào mạng lần lượt là 300, 300 và 10 000. Vì PINN là mô hình bán không giám sát, mọi bước thời gian ngoại trừ điều kiện ban đầu đều có thể được đưa vào kiểm tra tính chính xác kết quả. Trong bài nghiên cứu đầu tiên ứng dụng PINN giải phương trình Buckley-Leverett, tác



giả Tchelepi sử dụng tỉ số linh động nước/dầu bằng 1¹⁴. Bài nghiên cứu này mô hình hóa bài toán có độ linh động pha bơm ép (nước) gấp đôi pha bị bơm ép (dầu) để sát với thực tế hơn.


a. Kết quả dự báo bằng PINN thuần túy

Trong phần này, hàm mất mát của phương trình vi phân được tính bằng phương trình (3), không dùng hệ số phân tán để giảm bớt độ dốc của mặt tiến dầu nước. Kết quả dự báo có độ chính xác cao trước vị trí mặt tiến dầu nước ở từng bước thời gian (lần lượt là $t_D = 0.15$, $t_D = 0.39$, $t_D = 0.51$) ở Hình 3(a)(b)(c). Nhưng ở các vị trí nằm sau mặt tiến dầu nước, PINN hoàn toàn không thể dự báo được hành xử của độ bão hòa nước. Điều này là do sự khác biệt về bản chất giữa mạng nơ-ron nhân tạo và bài toán Buckley-Leverett. Cụ thể là đường S_w của nghiệm giải tích là một hàm xác định trên từng khoảng, còn đường của hàm dự báo của mạng nơ-ron nhân tạo là hàm liên tục. Vậy nên, đạo hàm không xác định tại mặt tiến dầu nước

làm cho L_{in} hay L_{PDE} bị tính toán sai, dẫn đến việc cập nhật W , b không chính xác.

b. Kết quả dự báo bằng PINN dùng hệ số phân tán

Để giải quyết vấn đề đạo hàm không xác định tại mặt tiến dầu nước, hàm mất mát của phương trình vi phân L_{in} được tính theo phương trình (5) thay vì phương trình (3). Dự báo của PINN sau khi dùng phần phân tán cải thiện đáng kể so với lúc chưa dùng. Cụ thể, toàn bộ dự báo của PINN gần như khớp một cách hoàn hảo với nghiệm giải tích tại 3 bước thời gian t_D lần lượt là 0.15, 0.39, 0.51 ở Hình 4(a)(b)(c). Tuy nhiên, khi quan sát kỹ tại các mặt tiến dầu nước ở từng bước thời gian, dự báo bị sai lệch nhỏ so với nghiệm giải tích. Điều này là do chính bản thân hệ số phân tán được thêm vào phương trình Buckley-Leverett. Cụ thể là hàm giải từ phương trình (5) khác với hàm được giải từ phương trình (3). Mặc dù vậy, kết quả từ 3 bước thời gian của PINN dùng phần phân



Hình 3: Dự báo độ bão hòa $\bar{S}_w$ của PINN không dùng hệ số phân tán so với nghiệm giải tích trong 3 bước thời gian lần lượt tại (a) $t_D = 0.15$, (b) $t_D = 0.39$ và (c) $t_D = 0.51$. Kết quả cho thấy PINN này không thể dự báo ở các vị trí nằm sau mặt tiến dầu nước.

tán (Hình 4(a)(b)(c)) khác biệt không đáng kể so với nghiệm giải tích.

Ngoài ra, nhóm tác giả sử dụng thư viện đơn giản và được chuẩn hóa - Scikit-learn²⁸ để giải bài toán Buckley-Leverett bằng FFNN (mạng nơ-ron yêu cầu dữ liệu từ nghiệm giải tích). FFNN được huấn luyện bằng $\frac{1}{2}$ của bộ dữ liệu từ nghiệm giải tích (đến $t_D = 0.37$), với đầu vào là (x_D, t_D) và đầu ra là S_w . Kiến trúc mạng của FFNN được lấy từ PINN, gồm 8 lớp ẩn và 20 nơ-ron/lớp ẩn. Nhìn tổng quát Hình 5, khi thời điểm dự báo càng ở xa tập huấn luyện, dự báo S_w của FFNN càng giảm độ chính xác. Cụ thể, tại thời điểm $t_D = 0.39$ ngay sau thời điểm thuộc tập huấn luyện ($t_D = 0.37$) - Hình 5(a), dự báo của FFNN gần như tương đồng với nghiệm giải tích, ngoại trừ một số điểm gần với mặt tiến dầu nước (S_w dự báo sai lệch trung bình khoảng 0.02 – 3.4% so S_w của nghiệm giải tích). Tuy nhiên, tại thời điểm $t_D = 0.51$ - Hình 5(b), dự báo S_w của FFNN bắt đầu có nhiều vị trí bị sai lệch hơn so với dự báo tại $t_D = 0.39$, lệch 0.015 và 0.02 – khoảng 2.0% và 3.3% lần lượt tại $x_D = 0.25$ và $x_D = 0.65$). Xu hướng sai lệch này tăng dần khi thời điểm dự báo càng xa thời điểm huấn luyện mạng. Cụ thể, khi tại thời điểm $t_D = 0.71$ - Hình 5(c), dự báo S_w tại biên trái lệch lên 0.017 – khoảng 1.7% so với nghiệm giải tích, và tại $x_D = 0.25$, sai lệch này tăng lên 1.2% khi so với dự báo tại $t_D = 0.51$. Điều này cho thấy cách huấn luyện đưa dữ liệu đầu vào khác với thông số cần dự báo của mạng nơ-ron dựa vào dữ liệu như trong^{3,8,9} (cụ thể là FFNN) kém hơn PINN về tính ổn định và độ chính xác khi ở xa thời gian huấn luyện.


c. Quá trình huấn luyện của mạng nơ-ron nhân tạo

Error – MSE) giữa dự báo và nghiệm giải tích. Nhìn chung từ Hình 6, độ chính xác của FFNN của thiện đáng kể sau vài chục lần huấn luyện đầu tiên. Cụ thể, khi MSE của tập huấn luyện (training) và tập kiểm định (validation) giảm lần lượt từ 0.175 và 0.125 xuống còn dưới 0.006. Sau đó, các đường MSE của 2 tập dữ liệu dao động mạnh trong khoảng từ 0.0006 cho đến 0.004 và kết thúc ở lần huấn luyện thứ 695, với giá trị MSE của 2 tập khoảng 0.0008; ngoài ra, chênh lệch giữa MSE của 2 tập huấn luyện và kiểm định là không đáng kể. Những điều này cho thấy mô hình có khả năng khái quát hóa bài toán, có thể dự báo với kết quả có độ chính xác cao tại các thời điểm nằm ngoài tập huấn luyện.


Ngoài ra, khi quan sát tổng Hình 6, MSE của tập validation và tập training thì 2 tập này bắt đầu hội tụ rất sớm (khoảng 100 lần huấn luyện đầu), nhưng vẫn có thêm hơn 600 lần huấn luyện nữa mặc dù đã áp dụng Early Stopping^b. Tuy nhiên, khi phóng to đường MSE của 2 tập từ 0 đến 0.006 thì MSE của 2 tập hội tụ ở khoảng hơn 500 lần huấn luyện. Sau đó, FFNN được huấn luyện thêm hơn 100 lần nữa để thỏa mãn tiêu chí Early Stopping thì quá trình huấn luyện FFNN mới dừng hẳn.

Chỉ số đánh giá quá trình huấn luyện của PINN cũng là MSE, nhưng áp dụng với điều kiện biên (Boundary Condition - BC), điều kiện ban đầu (Initial Condition - IC) và phần phương trình vi phân (PDE). Cụ thể, MSE của 3 phần lần lượt tương ứng với phương trình

^bEarly Stopping là một phương pháp dừng quá trình huấn luyện sau một số lần huấn luyện nhất định mà hàm mất mát của tập kiểm định không cải thiện đáng kể.



Hình 4: Dự báo độ bão hòa $\bar{S}_w$ của PINN dùng hệ số phân tán so với nghiệm giải tích trong 3 bước thời gian lần lượt tại (a) $t_D = 0.15$, (b) $t_D = 0.39$ và (c) $t_D = 0.51$. Độ chính xác PINN sử dụng hệ số phân tán cải thiện đáng kể so với PINN không dùng hệ số phân tán, gần như hoàn hảo khi so với nghiệm giải tích.




Hình 5: So sánh dự báo giữa các mô hình mạng nơ-ron nhân tạo (FFNN và PINN) trong bài toán Buckley-Leverett tại các bước thời gian của tập kiểm tra lần lượt tại (a) $t_D = 0.39$, (b) $t_D = 0.51$, (c) $t_D = 0.71$. Thời điểm dự báo càng xa tập huấn luyện, độ chính xác của đường S_w thuộc FFNN càng giảm, trong khi dự báo S_w của PINN có độ chính xác nhất quán tại mọi thời điểm.

(1), phương trình (2), và phương trình (5). Khi quan sát Hình 7, cả 3 phần mất mát của hàm mất mát PINN dao động mạnh và liên tục trong suốt khoảng 15 000 lần huấn luyện đầu do PINN phải đồng thời thỏa mãn 3 điều kiện của hàm mất mát (IC, BC, PDE). Có thể thấy rõ nhất ở lần huấn luyện thứ 10 000, khi PINN chỉ thỏa mãn IC, nhưng PDE và BC lại không được thỏa mãn, MSE của PDE và BC tăng lần lượt lên đến 0.003 và hơn 0.02, trong khi MSE của IC giảm xuống 0.001. Sau đó, từng phần IC, BC, PDE mới bắt đầu hội tụ ở khoảng lần huấn luyện thứ 20 000 và kết thúc huấn luyện ở lần huấn luyện thứ 30 000. Ngoài ra, số lần huấn luyện PINN lớn hơn nhiều so với số lần huấn luyện FFNN (30 000 lần huấn luyện PINN so với 695 lần huấn luyện FFNN).

Với cách tiếp cận của bài báo đối với mạng nơ-ron thông tin vật lý là theo hướng bán không giám sát (semi-supervised), có một vài thách thức lớn đối với PINN như sau:

- **Đòi hỏi lượng lớn điểm trong miền** (collocation points), khoảng 10 000 điểm. Điều này là do mạng nơ-ron nhân tạo hồi quy dựa trên sự kết nối các điểm dữ liệu lại với nhau để tạo nên đường cong dự báo liên kết các đặc trưng đầu vào. Thông thường, đối với các bài toán học giám sát (Supervised Learning), lượng dữ liệu cần thiết để đưa vào mô hình Deep Learning, hoặc thậm chí là Machine Learning thì cũng cần ít nhất vài nghìn dữ liệu. Sự khác biệt về bản chất này đòi hỏi một lượng lớn điểm trong miền, làm




Hình 6: Sự thay đổi độ chính xác của FFNN trong quá trình huấn luyện trên tập huấn luyện (training) và tập kiểm định (validation). MSE của 2 tập dữ liệu chênh lệch không đáng kể và đều giảm nhanh trong khoảng vài chục lần huấn luyện đầu tiên.

cho lượng bộ nhớ tạm thời (RAM hoặc VRAM) tồn đọng lượng nhiều hơn trong quá trình huấn luyện mạng.

- *Số lần huấn luyện PINN cao (từ chục nghìn cho đến trăm nghìn lần):* Do phải thỏa mãn đồng thời ít nhất hoặc hơn 3 điều kiện (Điều kiện biên, điều kiện ban đầu, phần dư của PDE), hàm mất mát của PINN khó hội tụ hơn khi so với một điều kiện của hàm mất mát thuộc các mô hình hồi quy có giám sát (Supervised regression model).
- *PINN có thể gặp khó khăn trong các bài toán đa chiều, và có miền lớn.* Như đã đề cập ở trên, PINN cần rất nhiều điểm trong miền (lên đến 10 000 đối với bài toán không thứ nguyên). Ở các bài toán có thứ nguyên, số lượng điểm trong miền mà PINN đòi hỏi tăng lên nhiều hơn so với các bài toán không thứ nguyên. Điều này dẫn đến không đủ RAM hoặc VRAM để chứa ma trận giá trị của từng điểm, và giá trị của từng nơ-ron khi đưa dữ liệu vào, chưa kể đến ma trận đạo hàm của từng phần trong PDE.

Đối với vấn đề điểm trong miền cao ở các bài toán đa chiều và có thứ nguyên, việc chuyển đổi bài toán về không thứ nguyên giúp giảm đáng kể lượng bộ nhớ phải dùng cho PINN. Khi này, lượng điểm trong miền sẽ đáp ứng được yêu cầu về bộ nhớ. Vấn đề số lượng điểm vẫn cao hơn nhiều so với phương pháp số sau khi chuyển bài toán về không thứ nguyên rất để tìm ra hướng giải quyết do điều này thuộc về sự khác biệt về bản chất giữa PINN và phương pháp số truyền thống. Vấn đề này là một hướng nghiên cứu tiềm năng của PINN trong tương lai. Đối với số lần huấn luyện cao của PINN, việc so sánh tổng thời gian bao gồm cả thời gian huấn luyện và thời gian dự báo với thời gian đưa ra đáp án của phương pháp số không phải là một phép đo đánh giá công bằng. Mạng nơ-ron nhân tạo có thể được dùng lại để học chuyển tiếp cho bài toán gần giống, giúp giảm đi rất nhiều thời gian huấn luyện và số lần huấn luyện để mạng hội tụ. Thêm nữa, thời gian mạng đưa ra kết quả dự báo sau khi huấn luyện gần như tương ứng với thời gian thực (vài mili giây) nên nếu việc học chuyển tiếp tốt, PINN hoàn toàn có thể khắc phục điểm yếu này.



Hình 7: Sự thay đổi từng phần thuộc hàm mất mát của PINN dùng hệ số phân tán trong quá trình huấn luyện, lần lượt là điều kiện ban đầu (IC), điều kiện biên (BC) và phần PDE (PDE). Hàm mất mát dao động rất nhiều trong quá trình huấn luyện do phải đồng thời thỏa mãn 3 phần mất mát.

KẾT LUẬN

Bài nghiên cứu này khảo sát tính ứng dụng của mạng nơ-ron thông tin vật lý vào một bài toán mô phỏng via cơ bản – bài toán Buckley-Leverett. Tuy phải điều chỉnh phương trình vi phân ban đầu nhưng kết quả từ mô hình PINN cho ra rất sát với nghiệm giải tích. Kết quả cũng cho thấy PINN có thể được áp dụng cho các bài toán có nhiều sự không liên tục, thậm chí là mặt dốc như mặt tiến dầu nước. PINN còn khắc phục được nhược điểm của mạng nơ-ron nhân tạo truyền thống là có thể loại bỏ điều kiện tiên quyết khi sử dụng mạng nơ-ron nhân tạo: lượng dữ liệu lớn. Điều này giúp cho ứng dụng của mạng nơ-ron nhân tạo khả thi trong những vấn đề có lượng dữ liệu khan hiếm như mô phỏng via. Ngoài ra, mô hình PINN sau khi huấn luyện đáng tin cậy và có thể sử dụng lâu dài hơn nhờ việc xem xét các thông tin vật lý của quá trình thực tế trong quá trình luyện mạng. Mặc dù thời gian huấn luyện PINN lớn hơn nhiều so với mạng nơ-ron thuần dữ liệu, nhược điểm này của PINN có thể được khắc phục bằng kỹ thuật học chuyển tiếp (Transfer Learning) và đây cũng là hướng phát triển tiếp của đề tài.

LỜI CẢM ƠN

Chúng tôi xin cảm ơn Trường Đại học Bách Khoa, ĐHQG-HCM đã hỗ trợ thời gian, phương tiện, và cơ sở vật chất cho nghiên cứu này.

DANH MỤC KÍ HIỆU

Các kí hiệu bên dưới đều không có thứ nguyên (dimensionless)

x_D : khoảng cách không thứ nguyên

t_D : thời gian không thứ nguyên

x_o : khoảng cách không thứ nguyên của điều kiện ban đầu

t_o : thời gian không thứ nguyên của điều kiện ban đầu

x_b : khoảng cách không thứ nguyên của điều kiện biên

t_b : thời gian không thứ nguyên của điều kiện biên

x_f : khoảng cách không thứ nguyên bên trong miền

t_f : thời gian không thứ nguyên bên trong miền

W : trọng số của nơ-ron

b : bias - sai lệch của nơ-ron

$f(W, b, x_D, t_D)$: Hàm dự báo của mạng nơ-ron

f_b : Hàm dự báo của mạng nơ-ron tại điều kiện biên

f_o : Hàm dự báo của mạng nơ-ron tại điều kiện ban đầu

f_{in} : Hàm dự báo của mạng nơ-ron bên trong miền
 S_{wb} : độ bão hòa tại điều kiện biên
 S_{wo} : độ bão hòa tại điều kiện ban đầu
 L_b : Hàm mất mát của điều kiện biên
 L_o : Hàm mất mát của điều kiện ban đầu
 L_{in}, L_{PDE} : Hàm mất mát của phương trình vi phân
 N_b : số điểm nằm tại điều kiện biên
 N_o : số điểm nằm tại điều kiện ban đầu
 M : tỉ số linh động
 ε : hệ số nghịch đảo của hằng số Péclet
 $\bar{S}_w$: dự báo của độ bão hòa nước
 R^2 : Hệ số xác định

DANH MỤC TỪ VIẾT TẮT

FFNN: Feed-forward Neural Network, mạng nơ-ron truyền thẳng
 LSTM: Long Short-Term Memory, Bộ nhớ dài-ngắn hạn
 PDE: Partial Differential Equation, phương trình vi phân riêng phần
 PINN: Physics-Informed Neural Network, mạng nơ-ron thông tin vật lý
 IC: Initial condition, điều kiện ban đầu
 BC: Boundary condition, điều kiện biên
 GRU: Gated Recurrent Unit
 MOC: Method of Characteristics, phương pháp đặc trưng
 RAM: Random Access Memory, bộ nhớ truy cập ngẫu nhiên
 VRAM: Video RAM, bộ nhớ truy cập ngẫu nhiên của Graphics Processing Unit (GPU)

XUNG ĐỘT LỢI ÍCH

Tác giả khẳng định rằng không có bất kì tranh chấp nào liên quan đến bài báo và công trình nghiên cứu này.

ĐÓNG GÓP CỦA CÁC TÁC GIẢ

Tiến sĩ Mai Cao Lân: Cán bộ hướng dẫn, định hướng, đánh giá mô hình, kết quả nghiên cứu và cập nhật bài báo.

Phạm Đăng Trình: Tiến hành thực hiện nghiên cứu và viết bài báo.

TÀI LIỆU THAM KHẢO

- Ertekin T, Abou-Kassem J, King G. Basic Applied Reservoir Simulation. Society of Petroleum Engineers; 2001;Available from: <https://store.spe.org/Basic-Applied-Reservoir-Simulation--P12.aspx>.
- Schmidhuber J. Deep learning in neural networks: An overview. Neural Networks. 2015;61:85-117;Available from: <https://doi.org/10.1016/j.neunet.2014.09.003>.
- Tuan NA. VPI-MLOGS: A WEB-BASED MACHINE LEARNING SOLUTION FOR APPLICATIONS IN PETROPHYSICS. Petrovietnam Journal. 2022;10:46-52;Available from: <https://doi.org/10.47800/PVJ.2022.10-06>.
- Tan NN, Hung TNT, Son HK, Tung TV. SUPERVISED MACHINE LEARNING APPLICATION OF LITHOFACIES CLASSIFICATION FOR A HYDRODYNAMICALLY COMPLEX GAS - CONDENSATE RESERVOIR IN NAM CON SON BASIN. Petrovietnam Journal. 2022;6:27-35;Available from: <https://doi.org/10.47800/PVJ.2022.06-03>.
- Thường LH, Ngô NV, Linh NT. TỰ ĐỘNG PHÁT HIỆN ẦM MÒN TRÊN BỀ MẶT ĐƯỜNG ỐNG DẪN KHÍ SỬ DỤNG TRÍ TUỆ NHÂN TẠO. Petrovietnam Journal. 2022;2:19-25;Available from: <https://doi.org/10.47800/PVJ.2022.02-03>.
- Mai-Cao L, Truong-Khac H. A Comparative Study on Different Machine Learning Algorithms for Petroleum Production Forecasting. Improved Oil and Gas Recovery. 2022;Available from: <https://doi.org/10.14800/IOGR.1205>.
- Tú TĐ, Hùng LT, Quý TX, Hiền ĐH, Giang PT, Tùng LĐ. ỨNG DỤNG THUẬT TOÁN HỌC MÁY ĐỂ DỰ BÁO KHAI THÁC CHO ĐỐI TƯỢNG MỎNG NÚT NẾ, VÒNG TRUNG TÂM, MỎ BẠCH HỒ. Petrovietnam Journal. 2022;9:16-23;Available from: <https://doi.org/10.47800/PVJ.2022.09-03>.
- AlAjmi MD, Alarifi SA, Mahsoon AH. Improving Multiphase Choke Performance Prediction and Well Production Test Validation Using Artificial Intelligence: A New Milestone. In: SPE Digital Energy Conference and Exhibition, Texas, 2015;Available from: <https://onepetro.org/SPEDEC/proceedings-abstract/15DEC/3-15DEC/D031S022R003/182473>.
- Zhang J, Cheung SW, Efendiev Y, Gildin E. Deep Model Reduction-Model Learning for Reservoir Simulation. In: SPE Reservoir Simulation Conference, Texas, 2019;Available from: <https://doi.org/10.2118/193912-MS>.
- Ghassemzadeh S, Perdomo MG, Haghighi M, Abbasnejad E. A data-driven reservoir simulation for natural gas reservoirs. Neural Computing and Applications. 2020;Available from: <https://doi.org/10.1007/s00521-021-05886-y>.
- Hochreiter S, Schmidhuber J. Long Short-Term Memory. Neural Computation. 1997;9(8):1735-1780;PMID: 9377276. Available from: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Ng CSW, Ghahfarokhi AJ, Amar MN. Production optimization under waterflooding with long short-term memory and meta-heuristic algorithm. Petroleum. 2023;9:53-60;Available from: <https://doi.org/10.1016/j.petlm.2021.12.008>.
- Raissi M, Perdikaris P, Karniadakis G. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. Journal of Computational Physics. 2019;378:686-707;Available from: <https://doi.org/10.1016/j.jcp.2018.10.045>.
- Fuks O, Tchalepi HA. LIMITATIONS OF PHYSICS INFORMED MACHINE LEARNING FOR NONLINEAR TWO-PHASE TRANSPORT IN POROUS MEDIA. Journal of Machine Learning for Modeling and Computing. 2020;1(1):19-37;Available from: <https://doi.org/10.1615/JMachLearnModelComput.2020033905>.
- Fraces CG, Tchalepi H. Physics Informed Deep Learning for Flow and Transport in Porous Media. In: SPE Reservoir Simulation Conference, 2021;Available from: <https://doi.org/10.2118/203934-MS>.
- Buckley S, Leverett M. Mechanism of Fluid Displacement in Sands. Transactions of the AIME. 1942;146(1):107-116;Available from: <https://doi.org/10.2118/942107-G>.
- Chorowski JK, Bahdanau D, Serdyuk D, Cho K, Bengio Y. Attention-Based Models for Speech Recognition. In: Advances in Neural Information Processing Systems 28 (NIPS 2015), 2015;Available from: <https://arxiv.org/abs/1506.07503>.
- Diab W, Chaabi O, Zhang W, Arif M, Alkobaisi S, Kobaisi MA. Data-Free and Data-Efficient Physics-Informed Neural Network Approaches to Solve the Buckley-Leverett Problem. Energies. 2022;Available from: <https://doi.org/10.3390/en15217864>.
- Rodriguez-Torrado R, Ruiz P, Cueto-Felgueroso L, Green MC, Friesen T, Matringe S, et al. Physics-informed attention-based neural network for hyperbolic partial differential equations: application to the Buckley-Leverett problem. Scientific Reports. 2022;Available from: <https://doi.org/10.1038/s41598-022-11058-2>.

20. Almajid MM, Abu-Al-Saud MO. Prediction of porous media fluid flow using physics informed neural networks. *Journal of Petroleum Science and Engineering*. 2022; Available from: <https://doi.org/10.1016/j.petrol.2021.109205>.
21. Dubey SR, Singh SK, Chaudhuri BB. Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark. *Neurocomputing*. 2022;503:92-108; Available from: <https://doi.org/10.1016/j.neucom.2022.06.111>.
22. Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks. In: *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS) 2010, Italy, 2010*; Available from: <http://proceedings.mlr.press/v9/glorot10a>.
23. Corey A, Rathjens C, Henderson J, Wyllie M. Three-Phase Relative Permeability. *Journal of Petroleum Technology*. 1956;8(11); Available from: <https://doi.org/10.2118/737-G>.
24. Bartholomew-Biggs M, Brown S, Christianson B, Dixon L. Automatic differentiation of algorithms. *Journal of Computational and Applied Mathematics*. 2000;124(1-2):171-190; Available from: [https://doi.org/10.1016/S0377-0427\(00\)00422-2](https://doi.org/10.1016/S0377-0427(00)00422-2).
25. Kingma DP, Ba JL. ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION. In: *ICLR 2015, 2015*; Available from: <https://arxiv.org/abs/1412.6980>.
26. Craig JFF. *The Reservoir Engineering Aspects of Waterflooding*. New York: Society of Petroleum Engineers; 1971; Available from: <https://store.spe.org/The-Reservoir-Engineering-Aspects-of-Waterflooding-Second-Edition-P945.aspx>.
27. Paszke A, Gross S, Massa F, Lerer A, Bradbury J, Chanan G, et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Neural Information Processing Systems*. 2019; Available from: https://proceedings.neurips.cc/paper_files/paper/2019/hash/bdbca288fee7f92f2bfa9f7012727740-Abstract.html.
28. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011;12:2825-2830.

Modeling of 2-phase flow in porous media using physics-informed neural network

Pham Dang Trinh^{1,2}, Mai Cao Lan^{1,2,*}

ABSTRACT

Oil and gas are valuable resources and make a great contribution to the national economy. However, this resource is often located thousands of meters underground. Therefore, oil and gas production and exploitation conditions cannot be measured directly but must be through simulations. Specifically, the models here simulate the behavior of fluids in oil and gas reservoirs to predict and optimize oil and gas exploitation. Besides traditional numerical simulation models, artificial neural networks are a good alternative. This study investigates and presents the advantages as well as disadvantages of the physics-informed neural network (PINNs) approach in the modeling of a simple oil production process by water flooding method with the Buckley-Leverett theory. The results from PINNs in this study agree quite well with the analytical solutions of the differential equation to be solved. The results from this work also show that PINNs can be applied to problems in which the unknowns have stiff changes with respect to space/time and that PINNs are absolutely suitable for problems where data availability is limited such as those for oilfield development/production planning. Furthermore, PINNs trained models are reliable and able to be utilized for long term production forecasts thanks to the consideration of physics information during the training of the network. This shows that PINNs would be highly applicable in the modeling of two-phase flows in porous media.

Key words: Artificial Neural Network, Physics-Informed Neural Network, Buckley-Leverett

¹Faculty of Geology and Petroleum Engineering – Ho Chi Minh City University of Technology, Vietnam

²Vietnam National University – Ho Chi Minh City, Vietnam

Correspondence

Mai Cao Lan, Faculty of Geology and Petroleum Engineering – Ho Chi Minh City University of Technology, Vietnam

Vietnam National University – Ho Chi Minh City, Vietnam

Email: maicaolan@hcmut.edu.vn

History

- Received: 30-9-2023
- Accepted: 04-12-2023
- Published Online: 31-12-2024

DOI : 10.32508/stdjet.v6iS17.1247



Copyright

© VNUHCM Press. This is an open-access article distributed under the terms of the Creative Commons Attribution 4.0 International license.



Cite this article : Trinh P D, Lan M C. **Modeling of 2-phase flow in porous media using physics-informed neural network.** *Sci. Tech. Dev. J. – Engineering and Technology* 2024; 6(S17):111-121.