

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,*}



Use your smartphone to scan this QR code and download this article

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

1 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, kĩ thuật mô phỏng vỉa, một kĩ 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 lí 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 lí 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

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:

DOI:



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.



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; ():1-10.

gian)¹¹ được dùng để mô phỏng vỉa 3 chiều (3D) và kết quả có hệ số xác định R² 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):

- 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.
- 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}.
- 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 $f_m(W, b, x_f, t_f)$.

- Tính hàm mất mát:** từng phần dự báo (f_b, f_o, f_m) sẽ được đánh giá mức độ sai lệch thông qua hàm mất mát:

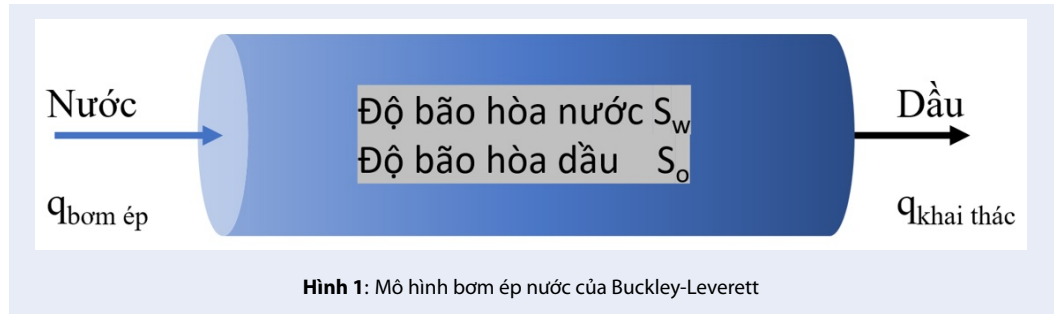
- Điều kiện biên và điều kiện ban đầu: Hàm mất mát của 2 điều kiện này là trung bình bình phương sai lệch giữa giá trị dự báo và giá trị tại các điều kiện. Các hàm này có dạng lần lượt là:

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

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

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].



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

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

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

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

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

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

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

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

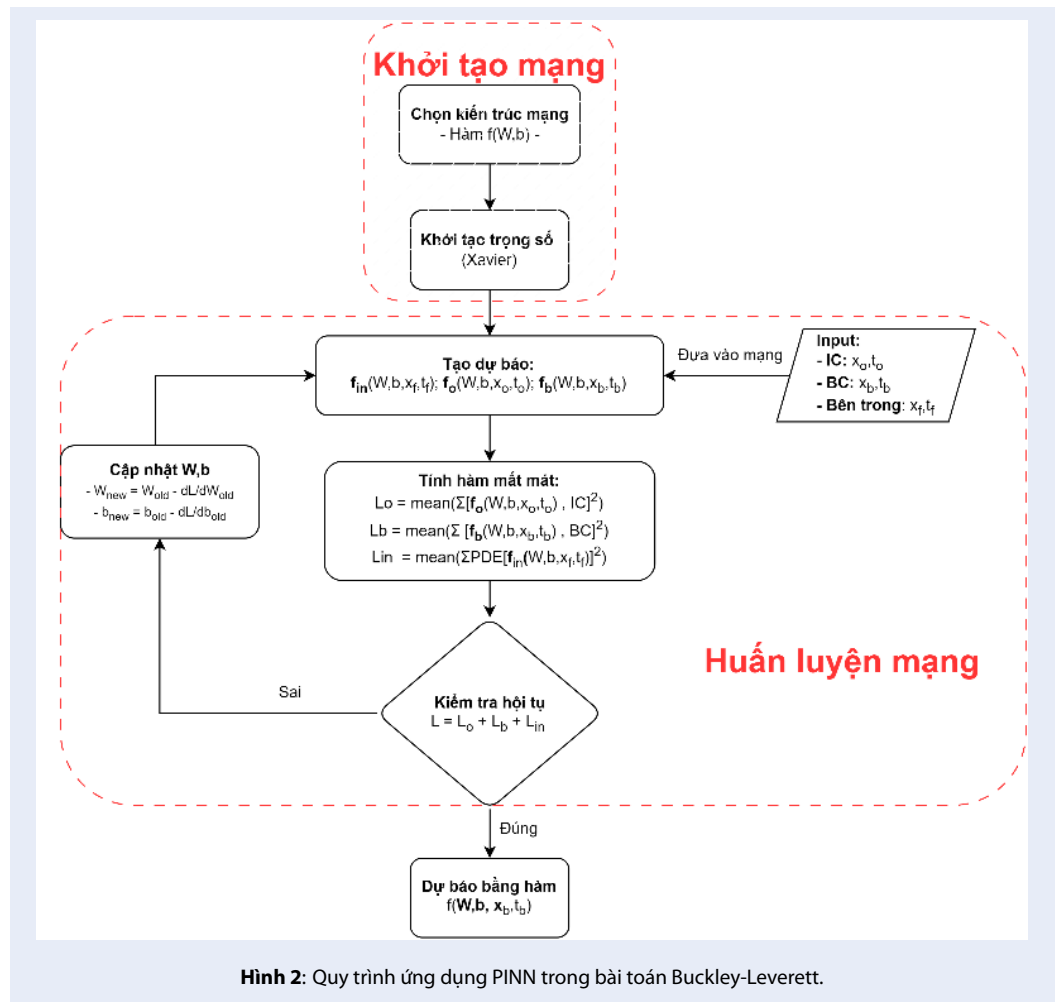
171 dL/db . Sau đó được dùng để cập nhật lại W, b theo
 172 các thuật toán dựa trên Gradient Descent, cụ thể là
 173 ADAM²⁵. Mục đích của việc cập nhật này để giảm
 174 thiểu sai lệch giữa các điều kiện biên và ban đầu cùng
 175 với phương trình (3). Khi sai số của từng phần trong
 176 hàm mất mát tổng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

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

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

188 KẾT QUẢ VÀ THẢO LUẬN

189 Phần này mô tả và phân tích độ chính xác của PINN
 190 khi so với nghiệm giải tích (giải bằng phương pháp
 191 đặc trưng – Method of Characteristics (MOC)²⁶)
 192 trong bài toán của Buckley-Leverett. Thêm nữa, các
 193 mô hình PINN được xây dựng và huấn luyện trên
 194 nền tảng thư viện Pytorch²⁷. Pytorch là một thư viện
 195 chuyên giải quyết các bài toán về Mạng nơ-ron nhân
 196 tạo và hỗ trợ tính đạo hàm rất nhanh và chính xác
 197 thông qua thuật toán Automatic Differentiation²⁴.
 198 Việc chọn kiến trúc mạng cho PINN bắt đầu từ việc
 199 tham khảo kiến trúc mạng của bài báo PINN gốc¹³ và
 200 bài nghiên cứu đầu tiên về PINN giải quyết bài toán
 201 Buckley-Leverett¹⁴, sau đó thay đổi để tìm kiến trúc
 202 tối ưu. Sau cùng, kiến trúc mạng gồm 8 lớp ẩn và
 203 20 nơ-ron/ lớp ẩn là tối ưu nhất. Thêm nữa, số điểm
 204 dữ liệu của điều kiện biên và ban đầu, cùng với điểm
 205 trong miền bài toán được chọn để đưa vào mạng lần
 206 lượt là 300, 300 và 10 000. Vì PINN là mô hình bán
 207 không giám sát, mọi bước thời gian ngoại trừ điều
 208 kiện ban đầu đều có thể được đưa vào kiểm tra tính
 209 chính xác kết quả. Trong bài nghiên cứu đầu tiên ứng
 210 dụng PINN giải phương trình Buckley-Leverett, tác



Hình 2: Quy trình ứng dụng PINN trong bài toán Buckley-Leverett.

211 giả Tchepeli sử dụng tỉ số linh động nước/dầu bằng
 212 1¹⁴. Bài nghiên cứu này mô hình hóa bài toán có độ
 213 linh động pha bơm ép (nước) gấp đôi pha bị bơm ép
 214 (dầu) để sát với thực tế hơn.

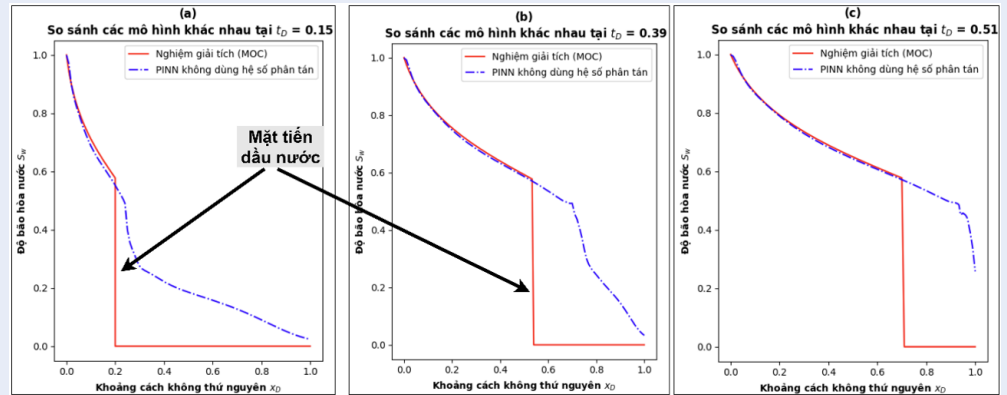
215 **a. Kết quả dự báo bằng PINN thuần túy**

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

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

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

233 Để giải quyết vấn đề đạo hàm không xác định tại mặt
 234 tiến dầu nước, hàm mất mát của phương trình vi phân
 235 L_{in} được tính theo phương trình (5) thay vì phương
 236 trình (3). Dự báo của PINN sau khi dùng phần phân
 237 tán cải thiện đáng kể so với lúc chưa dùng. Cụ thể,
 238 toàn bộ dự báo của PINN gần như khớp một cách
 239 hoàn hảo với nghiệm giải tích tại 3 bước thời gian
 240 t_D lần lượt là 0.15, 0.39, 0.51 ở Hình 4(a)(b)(c). Tuy
 241 nhiên, khi quan sát kĩ tại các mặt tiến dầu nước ở
 242 từng bước thời gian, dự báo bị sai lệch nhỏ so với
 243 nghiệm giải tích. Điều này là do chính bản thân hệ
 244 số phân tán được thêm vào phương trình Buckley-
 245 Leverett. Cụ thể là hàm giải từ phương trình (5) khác
 246 với hàm được giải từ phương trình (3). Mặc dù vậy,
 247 kết quả từ 3 bước thời gian của PINN dùng phần phân
 248



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.

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

251 Ngoài ra, nhóm tác giả sử dụng thư viện đơn giản
252 và được chuẩn hóa - Scikit-learn²⁸ để giải bài toán
253 Buckley-Leverett bằng FFNN (mạng nơ-ron yêu cầu
254 dữ liệu từ nghiệm giải tích). FFNN được huấn luyện
255 bằng $\frac{1}{2}$ của bộ dữ liệu từ nghiệm giải tích (đến $t_D =$
256 0.37), với đầu vào là (x_D, t_D) và đầu ra là S_w . Kiến
257 trúc mạng của FFNN được lấy từ PINN, gồm 8 lớp ẩn
258 và 20 nơ-ron/lớp ẩn. Nhìn tổng quát Hình 5, khi thời
259 điểm dự báo càng ở xa tập huấn luyện, dự báo S_w của
260 FFNN càng giảm độ chính xác. Cụ thể, tại thời điểm
261 $t_D = 0.39$ ngay sau thời điểm thuộc tập huấn luyện (t_D
262 $= 0.37$) - Hình 5(a), dự báo của FFNN gần như tương
263 đồng với nghiệm giải tích, ngoại trừ một số điểm gần
264 với mặt tiến dầu nước (S_w dự báo sai lệch trung bình
265 khoảng 0.02 – 3.4% so S_w của nghiệm giải tích). Tuy
266 nhiên, tại thời điểm $t_D = 0.51$ - Hình 5(b), dự báo S_w
267 của FFNN bắt đầu có nhiều vị trí bị sai lệch hơn so với
268 dự báo tại $t_D = 0.39$, lệch 0.015 và 0.02 – khoảng 2.0%
269 và 3.3% lần lượt tại $x_D = 0.25$ và $x_D = 0.65$. Xu hướng
270 sai lệch này tăng dần khi thời điểm dự báo càng xa thời
271 điểm huấn luyện mạng. Cụ thể, khi tại thời điểm $t_D =$
272 0.71 - Hình 5(c), dự báo S_w tại biên trái lệch lên 0.017
273 – khoảng 1.7% so với nghiệm giải tích, và tại $x_D = 0.25$,
274 sai lệch này tăng lên 1.2% khi so với dự báo tại $t_D =$
275 0.51 . Điều này cho thấy cách huấn luyện đưa dữ liệu
276 đầu vào khác với thông số cần dự báo của mạng nơ-
277 ron dựa vào dữ liệu như trong^{3,8,9} (cụ thể là FFNN)
278 kém hơn PINN về tính ổn định và độ chính xác khi ở
279 xa thời gian huấn luyện.

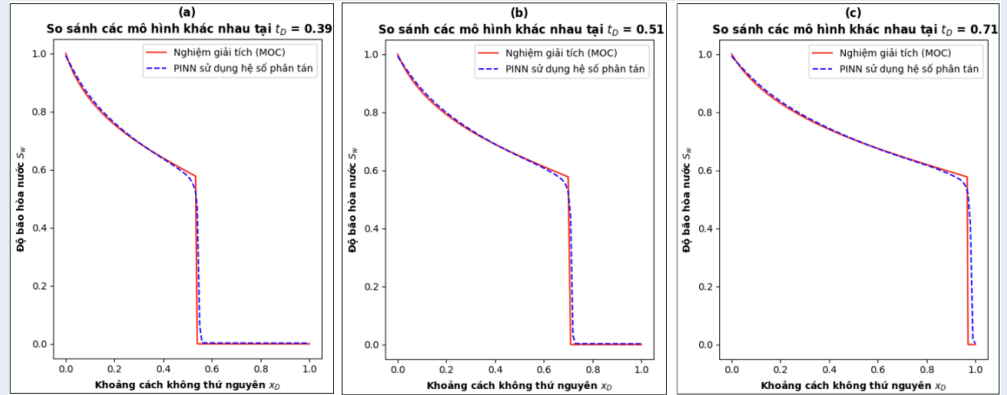
c. Quá trình huấn luyện của mạng nơ-ron nhân tạo

280 Error – MSE) giữa dự báo và nghiệm giải tích. Nhìn
281 chung từ Hình 6, độ chính xác của FFNN của thiện
282 đáng kể sau vài chục lần huấn luyện đầu tiên. Cụ
283 thể, khi MSE của tập huấn luyện (training) và tập
284 kiểm định (validation) giảm lần lượt từ 0.175 và 0.125
285 xuống còn dưới 0.006. Sau đó, các đường MSE của
286 2 tập dữ liệu dao động mạnh trong khoảng từ 0.0006
287 cho đến 0.004 và kết thúc ở lần huấn luyện thứ 695, với
288 giá trị MSE của 2 tập khoảng 0.0008; ngoài ra, chênh
289 lệch giữa MSE của 2 tập huấn luyện và kiểm định là
290 không đáng kể. Những điều này cho thấy mô hình có
291 khả năng khái quát hóa bài toán, có thể dự báo với kết
292 quả có độ chính xác cao tại các thời điểm nằm ngoài
293 tập huấn luyện.

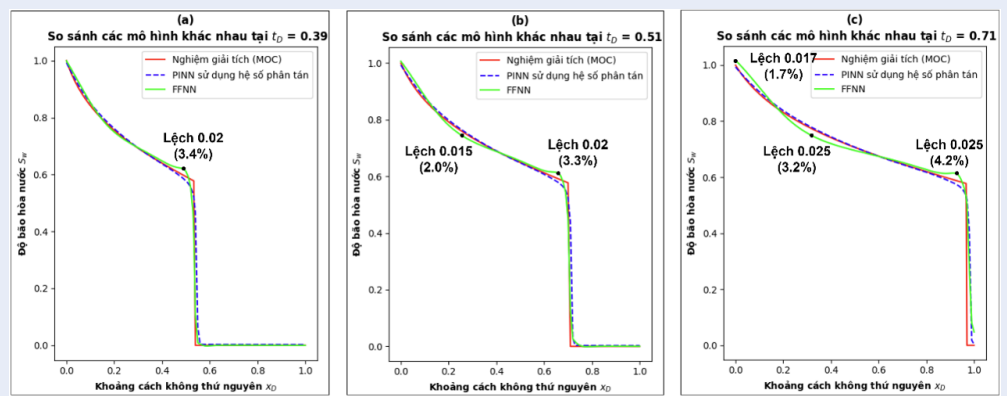
294 Ngoài ra, khi quan sát tổng Hình 6, MSE của tập val-
295 idation và tập training thì 2 tập này bắt đầu hội tụ rất
296 sớm (khoảng 100 lần huấn luyện đầu), nhưng vẫn có
297 thêm hơn 600 lần huấn luyện nữa mặc dù đã áp dụng
298 Early Stopping^b. Tuy nhiên, khi phóng to đường MSE
299 của 2 tập từ 0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

304 Chỉ số đánh giá quá trình huấn luyện của PINN cũng
305 là MSE, nhưng áp dụng với điều kiện biên (Boundary
306 Condition - BC), điều kiện ban đầu (Initial Condition
307 - IC) và phần phương trình vi phân (PDE). Cụ thể,
308 MSE của 3 phần lần lượt tương ứng với phương trình
309

^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.

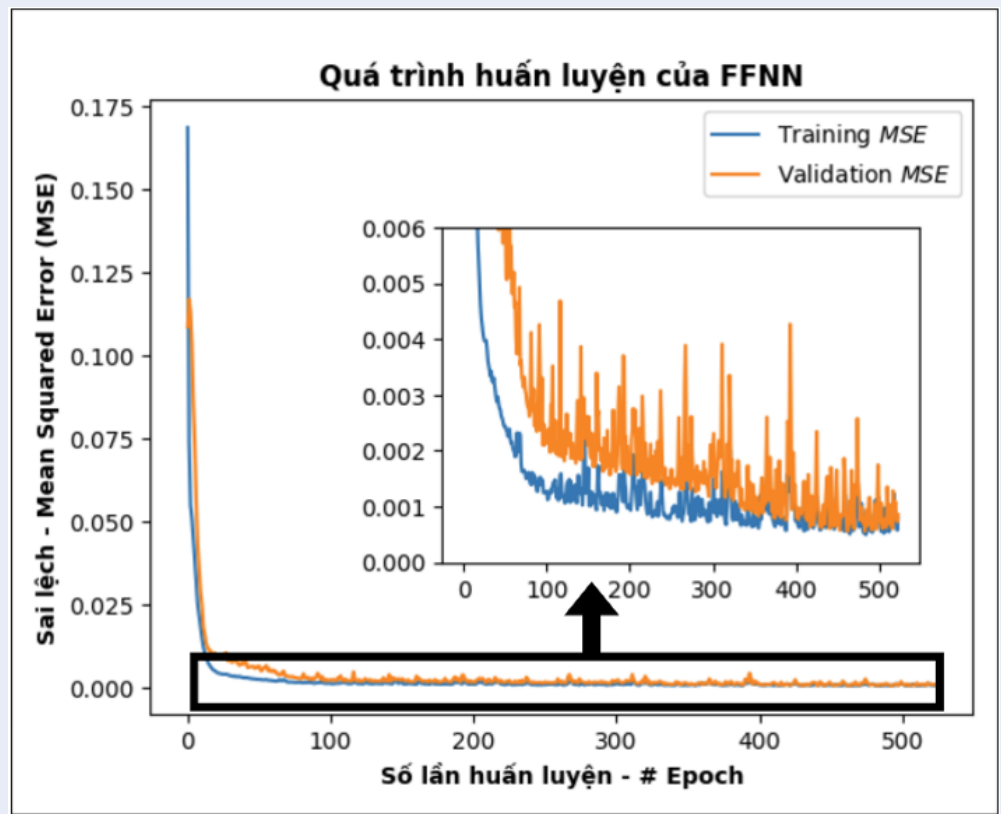


Hình 5: So sánh dự báo giữa các mô hình mạng nơ-ron nhân tạo (FFNN và PINN) trong bài toán Buckley-Leverett tại các bước thời gian của tập kiểm tra lần lượt tại (a) $t_D = 0.39$, (b) $t_D = 0.51$, (c) $t_D = 0.71$. Thời điểm dự báo càng xa tập huấn luyện, độ chính xác của đường S_w thuộc FFNN càng giảm,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

311 (1), phương trình (2), và phương trình (5). Khi quan
 312 sát Hình 7, cả 3 phần mất mát của hàm mất mát PINN
 313 dao động mạnh và liên tục trong suốt khoảng 15 000
 314 lần huấn luyện đầu do PINN phải đồng thời thỏa mãn
 315 3 điều kiện của hàm mất mát (IC, BC, PDE). Có thể
 316 thấy rõ nhất ở lần huấn luyện thứ 10 000, khi PINN
 317 chỉ thỏa mãn IC, nhưng PDE và BC lại không được
 318 thỏa mãn, MSE của PDE và BC tăng lần lượt lên đến
 319 0.003 và hơn 0.02, trong khi MSE của IC giảm xuống
 320 0.001. Sau đó, từng phần IC, BC, PDE mới bắt đầu
 321 hội tụ ở khoảng lần huấn luyện thứ 20 000 và kết thúc
 322 huấn luyện ở lần huấn luyện thứ 30 000. Ngoài ra, số
 323 lần huấn luyện PINN lớn hơn nhiều so với số lần huấn
 324 luyện FFNN (30 000 lần huấn luyện PINN so với 695
 325 lần huấn luyện FFNN).

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

- *Đòi hỏi lượng lớn điểm trong miền* (collocation 330
 points), khoảng 10 000 điểm. Điều này là do 331
 mạng nơ-ron nhân tạo hồi quy dựa trên sự kết 332
 nối các điểm dữ liệu lại với nhau để tạo nên 333
 đường cong dự báo liên kết các đặc trưng đầu 334
 vào. Thông thường, đối với các bài toán học 335
 giám sát (Supervised Learning), lượng dữ liệu 336
 cần thiết để đưa vào mô hình Deep Learning, 337
 hoặc thậm chí là Machine Learning thì cũng cần 338
 ít nhất vài nghìn dữ liệu. Sự khác biệt về bản chất 339
 này đòi hỏi một lượng lớn điểm trong miền, làm 340



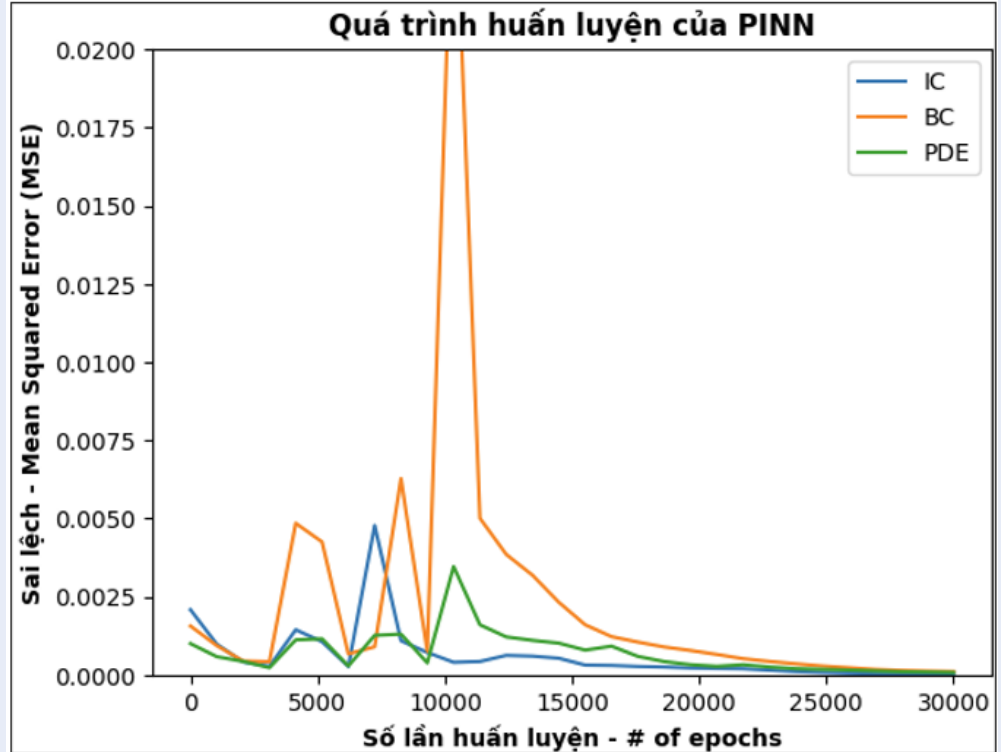
Hình 6: Sự thay đổi độ chính xác của FFNN trong quá trình huấn luyện trên tập huấn luyện (training) và tập kiểm định (validation). MSE của 2 tập dữ liệu chênh lệch không đáng kể và đều giảm nhanh trong khoảng vài chục lần huấn luyện đầu tiên.

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

344 • *Số lần huấn luyện PINN cao (từ chục nghìn cho*
 345 *đến trăm nghìn lần):* Do phải thỏa mãn đồng
 346 thời ít nhất hoặc hơn 3 điều kiện (Điều kiện
 347 biên, điều kiện ban đầu, phần dư của PDE), hàm
 348 mất mát của PINN khó hội tụ hơn khi so với
 349 một điều kiện của hàm mất mát thuộc các mô
 350 hình hồi quy có giám sát (Supervised regression
 351 model).

352 • *PINN có thể gặp khó khăn trong các bài toán đa*
 353 *chiều, và có miền lớn.* Như đã đề cập ở trên,
 354 PINN cần rất nhiều điểm trong miền (lên đến
 355 10 000 đối với bài toán không thứ nguyên). Ở
 356 các bài toán có thứ nguyên, số lượng điểm trong
 357 miền mà PINN đòi hỏi tăng lên nhiều hơn so
 358 với các bài toán không thứ nguyên. Điều này
 359 dẫn đến không đủ RAM hoặc VRAM để chứa
 360 ma trận giá trị của từng điểm, và giá trị của từng
 361 nơ-ron khi đưa dữ liệu vào, chưa kể đến ma trận
 362 đạo hàm của từng phần trong PDE.

363 Đối với vấn đề điểm trong miền cao ở các bài toán đa
 364 chiều và có thứ nguyên, việc chuyển đổi bài toán về
 365 không thứ nguyên giúp giảm đáng kể lượng bộ nhớ
 366 phải dùng cho PINN. Khi này, lượng điểm trong miền
 367 sẽ đáp ứng được yêu cầu về bộ nhớ. Vấn đề số lượng
 368 điểm vẫn cao hơn nhiều so với phương pháp số sau
 369 khi chuyển bài toán về không thứ nguyên rất để tìm ra
 370 hướng giải quyết do điều này thuộc về sự khác biệt về
 371 bản chất giữa PINN và phương pháp số truyền thống.
 372 Vấn đề này là một hướng nghiên cứu tiềm năng của
 373 PINN trong tương lai. Đối với số lần huấn luyện cao
 374 của PINN, việc so sánh tổng thời gian bao gồm cả thời
 375 gian huấn luyện và thời gian dự báo với thời gian đưa
 376 ra đáp án của phương pháp số không phải là một phép
 377 đo đánh giá công bằng. Mạng nơ-ron nhân tạo có thể
 378 được dùng lại để học chuyển tiếp cho bài toán gần
 379 giống, giúp giảm đi rất nhiều thời gian huấn luyện và
 380 số lần huấn luyện để mạng hội tụ. Thêm nữa, thời
 381 gian mạng đưa ra kết quả dự báo sau khi huấn luyện
 382 gần như tương ứng với thời gian thực (vài mili giây)
 383 nên nếu việc học chuyển tiếp tốt, PINN hoàn toàn có
 384 thể khắc phục điểm yếu này. 384



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.

385 KẾT LUẬN

386 Bài nghiên cứu này khảo sát tính ứng dụng của mạng
 387 nơ-ron thông tin vật lý vào một bài toán mô phỏng
 388 vĩa cơ bản – bài toán Buckley-Leverett. Tuy phải điều
 389 chỉnh phương trình vi phân ban đầu nhưng kết quả
 390 từ mô hình PINN cho ra rất sát với nghiệm giải tích.
 391 Kết quả cũng cho thấy PINN có thể được áp dụng cho
 392 các bài toán có nhiều sự không liên tục, thậm chí là
 393 mặt dốc như mặt tiến dầu nước. PINN còn khắc phục
 394 được nhược điểm của mạng nơ-ron nhân tạo truyền
 395 thống là có thể loại bỏ điều kiện tiên quyết khi sử dụng
 396 mạng nơ-ron nhân tạo: lượng dữ liệu lớn. Điều này
 397 giúp cho ứng dụng của mạng nơ-ron nhân tạo khả thi
 398 trong những vấn đề có lượng dữ liệu khan hiếm như
 399 mô phỏng vĩa. Ngoài ra, mô hình PINN sau khi huấn
 400 luyện đáng tin cậy và có thể sử dụng lâu dài hơn nhờ
 401 việc xem xét các thông tin vật lý của quá trình thực tế
 402 trong quá trình luyện mạng. Mặc dù thời gian huấn
 403 luyện PINN lớn hơn nhiều so với mạng nơ-ron thuần
 404 dữ liệu, nhược điểm này của PINN có thể được khắc
 405 phục bằng kĩ thuật học chuyển tiếp (Transfer Learning)
 406 và đây cũng là hướng phát triển tiếp của đề tài.
 407

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 (di-
 mensionless)

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

- 430 f_{in} : Hàm dự báo của mạng nơ-ron bên trong miền
 431 S_{wb} : độ bão hòa tại điều kiện biên
 432 S_{wo} : độ bão hòa tại điều kiện ban đầu
 433 L_b : Hàm mất mát của điều kiện biên
 434 L_o : Hàm mất mát của điều kiện ban đầu
 435 $L_{in}, LPDE$: Hàm mất mát của phương trình vi phân
 436 N_b : số điểm nằm tại điều kiện biên
 437 N_o : số điểm nằm tại điều kiện ban đầu
 438 M : tỉ số linh động
 439 ϵ : hệ số nghịch đảo của hằng số Péclet
 440 \bar{S}_w : dự báo của độ bão hòa nước
 441 R^2 : Hệ số xác định
- 442 **DANH MỤC TỪ VIẾT TẮT**
- 443 FFNN: Feed-forward Neural Network, mạng nơ-ron
 444 truyền thẳng
 445 LSTM: Long Short-Term Memory, Bộ nhớ dài-ngắn
 446 hạn
 447 PDE: Partial Differential Equation, phương trình vi
 448 phân riêng phần
 449 PINN: Physics-Informed Neural Network, mạng nơ-
 450 ron thông tin vật lý
 451 IC: Initial condition, điều kiện ban đầu
 452 BC: Boundary condition, điều kiện biên
 453 GRU: Gated Recurrent Unit
 454 MOC: Method of Characteristics, phương pháp đặc
 455 trưng
 456 RAM: Random Access Memory, bộ nhớ truy cập ngẫu
 457 nhiên
 458 VRAM: Video RAM, bộ nhớ truy cập ngẫu nhiên của
 459 Graphics Processing Unit (GPU)
- 460 **XUNG ĐỘT LỢI ÍCH**
- 461 Tác giả khẳng định rằng không có bất kì tranh chấp
 462 nào liên quan đến bài báo và công trình nghiên cứu
 463 này.
- 464 **ĐÓNG GÓP CỦA CÁC TÁC GIẢ**
- 465 Tiến sĩ Mai Cao Lân: Cán bộ hướng dẫn, định hướng,
 466 đánh giá mô hình, kết quả nghiên cứu và cập nhật bài
 467 báo.
 468 Phạm Đăng Trình: Tiến hành thực hiện nghiên cứu
 469 và viết bài báo.
- 470 **TÀI LIỆU THAM KHẢO**
- 471 1. Ertekin T, Abou-Kassem J, King G. Basic Applied Reservoir
 472 Simulation. Society of Petroleum Engineers; 2001; Avail-
 473 able from: [https://store.spe.org/Basic-Applied-Reservoir-](https://store.spe.org/Basic-Applied-Reservoir-Simulation--P12.aspx)
 474 [Simulation--P12.aspx](https://store.spe.org/Basic-Applied-Reservoir-Simulation--P12.aspx).
 475 2. Schmidhuber J. Deep learning in neural networks: An
 476 overview. Neural Networks. 2015;61:85-117; Available from:
 477 <https://doi.org/10.1016/j.neunet.2014.09.003>.
 478 3. Tuan NA. VPI-MLOGS: A WEB-BASED MACHINE LEARNING
 479 SOLUTION FOR APPLICATIONS IN PETROPHYSICS. Petroviet-
 480 nam Journal. 2022;10:46-52; Available from: [https://doi.org/10.](https://doi.org/10.47800/PVJ.2022.10-06)
 481 [47800/PVJ.2022.10-06](https://doi.org/10.47800/PVJ.2022.10-06).
4. Tan NN, Hung TNT, Son HK, Tung TV. SUPERVISED MA-
 482 CHINE LEARNING APPLICATION OF LITHOFACIES CLASSIFI-
 483 CATION FOR A HYDRODYNAMICALLY COMPLEX GAS - CON-
 484 DENSATE RESERVOIR IN NAM CON SON BASIN. Petroviet-
 485 nam Journal. 2022;6:27-35; Available from: [https://doi.org/10.](https://doi.org/10.47800/PVJ.2022.06-03)
 486 [47800/PVJ.2022.06-03](https://doi.org/10.47800/PVJ.2022.06-03).
 487 5. Thường LH, Ngô NV, Linh NT. TỰ ĐỘNG PHÁT HIỆN ẦM
 488 MÒN TRÊN BỀ MẶT ĐƯỜNG ỐNG DẪN KHÍ SỬ DỤNG TRÍ
 489 TUỆ NHÂN TẠO. Petrovietnam Journal. 2022;2:19-25; Available
 490 from: <https://doi.org/10.47800/PVJ.2022.02-03>.
 491 6. Mai-Cao L, Truong-Khac H. A Comparative Study on Different
 492 Machine Learning Algorithms for Petroleum Production Fore-
 493 casting. Improved Oil and Gas Recovery. 2022; Available from:
 494 <https://doi.org/10.14800/IOGR.1205>.
 495 7. Tú TĐ, Hùng LT, Quý TX, Hiền ĐH, Giang PT, Tùng LĐ. ỨNG
 496 DỤNG THUẬT TOÁN HỌC MÁY ĐỂ DỰ BÁO KHAI THÁC CHO
 497 ĐỐI TƯỢNG MÓNG NÚT NẾ, VÒM TRUNG TÂM, MỎ BẠCH
 498 HỒ. Petrovietnam Journal. 2022;9:16-23; Available from: <https://doi.org/10.47800/PVJ.2022.09-03>.
 499 8. AlAjmi MD, Alarif SA, Mahsoon AH. Improving Multiphase
 500 Choke Performance Prediction and Well Production Test Vali-
 501 dation Using Artificial Intelligence: A New Milestone. In: SPE
 502 Digital Energy Conference and Exhibition, Texas, 2015; Avail-
 503 able from: [https://onepetro.org/SPEDEC/proceedings-](https://onepetro.org/SPEDEC/proceedings-abstract/15DEC/3-15DEC/D031S022R003/182473)
 504 [abstract/15DEC/3-15DEC/D031S022R003/182473](https://onepetro.org/SPEDEC/proceedings-abstract/15DEC/3-15DEC/D031S022R003/182473).
 505 9. Zhang J, Cheung SW, Efeendi Y, Gildin E. Deep Model
 506 Reduction-Model Learning for Reservoir Simulation. In: SPE
 507 Reservoir Simulation Conference, Texas, 2019; Available from:
 508 <https://doi.org/10.2118/193912-MS>.
 509 10. Ghassemzadeh S, Perdomo MG, Haghighi M, Abbasnejad E.
 510 A data-driven reservoir simulation for natural gas reservoirs.
 511 Neural Computing and Applications. 2020; Available from:
 512 <https://doi.org/10.1007/s00521-021-05886-y>.
 513 11. Hochreiter S, Schmidhuber J. Long Short-Term Memory. Neu-
 514 ral Computation. 1997;9(8):1735-1780; PMID: 9377276. Avail-
 515 able from: <https://doi.org/10.1162/neco.1997.9.8.1735>.
 516 12. Ng CSW, Ghahfarokhi AJ, Amar MN. Production optimization
 517 under waterflooding with long short-term memory and meta-
 518 heuristic algorithm. Petroleum. 2023;9:53-60; Available from:
 519 <https://doi.org/10.1016/j.petlm.2021.12.008>.
 520 13. Raissi M, Perdikaris P, Karniadakis G. Physics-informed neu-
 521 ral networks: A deep learning framework for solving forward
 522 and inverse problems involving nonlinear partial differential
 523 equations. Journal of Computational Physics. 2019;378:686-
 524 707; Available from: <https://doi.org/10.1016/j.jcp.2018.10.045>.
 525 14. Fuks O, Tchelepi HA. LIMITATIONS OF PHYSICS INFORMED MA-
 526 CHINE LEARNING FOR NONLINEAR TWO-PHASE TRANSPORT
 527 IN POROUS MEDIA. Journal of Machine Learning for Model-
 528 ing and Computing. 2020;1(1):19-37; Available from: [https://](https://doi.org/10.1615/JMachLearnModelComput.2020033905)
 529 doi.org/10.1615/JMachLearnModelComput.2020033905.
 530 15. Fraces CG, Tchelepi H. Physics Informed Deep Learning for
 531 Flow and Transport in Porous Media. In: SPE Reservoir Simu-
 532 lation Conference, 2021; Available from: [https://doi.org/10.2118/](https://doi.org/10.2118/203934-MS)
 533 [203934-MS](https://doi.org/10.2118/203934-MS).
 534 16. Buckley S, Leverett M. Mechanism of Fluid Displacement
 535 in Sands. Transactions of the AIME. 1942;146(1):107-
 536 116; Available from: <https://doi.org/10.2118/942107-G>.
 537 17. Chorowski JK, Bahdanau D, Serdyuk D, Cho K, Bengio Y.
 538 Attention-Based Models for Speech Recognition. In: Ad-
 539 vances in Neural Information Processing Systems 28 (NIPS
 540 2015), 2015; Available from: <https://arxiv.org/abs/1506.07503>.
 541 18. Diab W, Chaabi O, Zhang W, Arif M, Alkobaisi S, Kobaisi
 542 MA. Data-Free and Data-Efficient Physics-Informed Neural
 543 Network Approaches to Solve the Buckley-Leverett Prob-
 544 lem. Energies. 2022; Available from: [https://doi.org/10.3390/](https://doi.org/10.3390/en15217864)
 545 [en15217864](https://doi.org/10.3390/en15217864).
 546 19. Rodriguez-Torrado R, Ruiz P, Cueto-Felgueroso L, Green MC,
 547 Friesen T, Matringe S, et al. Physics-informed attention-based
 548 neural network for hyperbolic partial differential equations:
 549 application to the Buckley-Leverett problem. Scientific Re-
 550 ports. 2022; Available from: [https://doi.org/10.1038/s41598-](https://doi.org/10.1038/s41598-2022-10338-4)
 551 [2022-10338-4](https://doi.org/10.1038/s41598-2022-10338-4).
 552

- 553 022-11058-2.
- 554 20. Almajid MM, Abu-Al-Saud MO. Prediction of porous media
555 fluid flow using physics informed neural networks. *Journal*
556 *of Petroleum Science and Engineering*. 2022; Available from:
557 <https://doi.org/10.1016/j.petrol.2021.109205>.
- 558 21. Dubey SR, Singh SK, Chaudhuri BB. Activation Functions in
559 Deep Learning: A Comprehensive Survey and Benchmark.
560 *Neurocomputing*. 2022;503:92-108; Available from: <https://doi.org/10.1016/j.neucom.2022.06.111>.
- 562 22. Glorot X, Bengio Y. Understanding the difficulty of training
563 deep feedforward neural networks. In: *Proceedings of the*
564 *13th International Conference on Artificial Intelligence and*
565 *Statistics (AISTATS) 2010, Italy, 2010*; Available from: <http://proceedings.mlr.press/v9/glorot10a>.
- 567 23. Corey A, Rathjens C, Henderson J, Wyllie M. Three-Phase
568 Relative Permeability. *Journal of Petroleum Technology*.
569 1956;8(11); Available from: <https://doi.org/10.2118/737-G>.
- 570 24. Bartholomew-Biggs M, Brown S, Christianson B, Dixon L. Auto-
571 matic differentiation of algorithms. *Journal of Computational*
572 *and Applied Mathematics*. 2000;124(1-2):171-190; Available
573 from: [https://doi.org/10.1016/S0377-0427\(00\)00422-2](https://doi.org/10.1016/S0377-0427(00)00422-2).
- 574 25. Kingma DP, Ba JL. ADAM: A METHOD FOR STOCHASTIC OP-
575 TIMIZATION. In: *ICLR 2015, 2015*; Available from: <https://arxiv.org/abs/1412.6980>.
- 577 26. Craig JFF. *The Reservoir Engineering Aspects of Waterflood-*
578 *ing*. New York: Society of Petroleum Engineers; 1971; Avail-
579 able from: [https://store.spe.org/The-Reservoir-Engineering-](https://store.spe.org/The-Reservoir-Engineering-Aspects-of-Waterflooding-Second-Edition-P945.aspx)
580 *Aspects-of-Waterflooding-Second-Edition-P945.aspx*.
- 581 27. Paszke A, Gross S, Massa F, Lerer A, Bradbury J,
582 Chanan G, et al. PyTorch: An Imperative Style, High-
583 Performance Deep Learning Library. *Neural Inform-*
584 *ation Processing Systems*. 2019; Available from:
585 [https://proceedings.neurips.cc/paper_files/paper/2019/hash/](https://proceedings.neurips.cc/paper_files/paper/2019/hash/bdbca288fee7f92f2bfa9f7012727740-Abstract.html)
586 *bdbca288fee7f92f2bfa9f7012727740-Abstract.html*.
- 587 28. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B,
588 Grisel O, et al. Scikit-learn: Machine Learning in Python. *Jour-*
589 *nal 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,*}



Use your smartphone to scan this QR code and download this article

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:

DOI :



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; ():1-1.