

SỬ DỤNG THUẬT TOÁN MẠNG NEURAL NHÂN TẠO TRONG TỐI ƯU BƠM ÉP NƯỚC CHO MỎ BẠCH HỔ

Đoàn Huy Hiền¹, Lê Thế Hùng¹, Trần Xuân Quý¹, Phạm Trường Giang¹, Nguyễn Minh Quý¹, Nguyễn Thế Đức²

¹Viện Dầu khí Việt Nam (VPI)

²Viện Cơ học, Viện Hàn lâm Khoa học và Công nghệ Việt Nam (VAST)

Email: hiendh.epc@vpi.pvn.vn

<https://doi.org/10.47800/PVSI.2025.03-02>

Tóm tắt

Sản lượng dầu ngoài khơi Việt Nam được khai thác chủ yếu từ vỉa chứa móng Bạch Hổ, nơi có chế độ dòng chảy rất phức tạp do sự phân bố không gian bất đồng nhất của các thuộc tính vật lý thạch học như độ rỗng, độ thấm và độ bão hòa nước. Do đó, phương pháp dự báo sản lượng dầu truyền thống dựa trên mô phỏng vỉa chứa thường thiếu chính xác hoặc đòi hỏi nhiều công sức và thời gian để tối ưu hóa các thông số thủy động lực học. Sự phát triển gần đây của các thuật toán học máy (machine learning - ML) sẽ giúp dự đoán được sản lượng dầu từ lưu lượng bơm ép nước của từng giếng bơm nhanh hơn và đáng tin cậy hơn. Một khi có thể dự đoán sản lượng dầu bằng phương pháp học máy, việc tối ưu hóa quá trình bơm ép nước có thể được triển khai bằng nhiều thuật toán tối ưu hóa khác nhau.

Trong nghiên cứu này, sử dụng thuật toán mạng neural nhân tạo (ANN) đã cho kết quả tốt nhất: hệ số tương quan giữa các giá trị dự đoán và giá trị thực tế lần lượt là 0,98 và 0,95 đối với tập dữ liệu huấn luyện và kiểm tra. Sau đó, thuật toán tối ưu Gauss-Newton được áp dụng để tìm ra lưu lượng bơm ép nước tối ưu nhất cho từng giếng bơm nhằm tăng sản lượng dầu. Kết quả cho thấy sản lượng dầu khai thác tăng trung bình 1,5% khi sử dụng các lược đồ bơm ép mới được tối ưu hóa.

Từ khóa: Tối ưu hóa bơm ép nước, mô phỏng vỉa chứa, mạng neural nhân tạo, học máy, mỏ Bạch Hổ.

1. Giới thiệu

Kể từ khi được đưa vào khai thác tới nay, mỏ Bạch Hổ (Lô 09-1, bể Cửu Long, ngoài khơi Việt Nam) đã có đóng góp lớn nhất vào tổng sản lượng dầu của Việt Nam. Dòng dầu đầu tiên của mỏ Bạch Hổ được khai thác từ vỉa chứa Miocene vào năm 1986, sau đó lần lượt từ vỉa chứa Oligocene và móng vào năm 1987 và 1988. Sản lượng dầu tích lũy được khai thác từ đá móng bể Cửu Long chiếm hơn 95% tổng sản lượng dầu của Việt Nam, trong đó hơn 90% từ mỏ Bạch Hổ - con số này bắt đầu suy giảm từ năm 2005. Từ năm 1996, phương pháp bơm ép nước (waterflooding) đã được triển khai tại mỏ Bạch Hổ để duy trì áp suất vỉa chứa.

Mục tiêu chính của bơm ép nước là điều chỉnh các biến điều khiển (manipulated variables) sao cho tổng sản lượng dầu được tối đa hóa. Do đó, lượng dầu khai thác phải được dự đoán dựa trên tổng lượng nước bơm ép, việc

này thường được thực hiện thông qua mô phỏng vỉa chứa động lực học. Quy trình bơm ép nước điển hình gồm 2 bước. Bước thứ nhất là dự đoán sản lượng tương lai dựa trên kết quả khớp lịch sử (history matching) từ mô phỏng vỉa chứa với lược đồ bơm ép nước hiện tại. Bước thứ hai là tối ưu hóa việc kiểm soát giếng (well control), gồm tối ưu hóa lưu lượng bơm và lắp đặt giếng bơm mới, bằng cách tối đa hóa lưu lượng dầu (Andrea Capolei và nnk, 2013 [1], Bjarne Foss và nnk, 2015 [2], Van den Hof và nnk, 2012 [3], Bjarne Foss và nnk, 2011 [4], J.D. Jansen và nnk, 2014 [5]). Phương pháp này xem xét tất cả ảnh hưởng của các quá trình vật lý và cho phép mô phỏng quá trình khai thác thực tế nhất có thể bằng cách giải các phương trình vi phân từng phần (partial differential equations). Độ chính xác của mô hình phụ thuộc vào mức độ phức tạp của các điều kiện địa chất, được thể hiện qua sự phân bố không gian của các thuộc tính vật lý thạch học như độ thấm, độ bão hòa nước và độ rỗng, cũng như năng lực của kỹ sư vỉa chứa trong việc thu thập dữ liệu để xây dựng và xác thực một mô hình vỉa chứa đủ chính xác. Đối với mô hình mô phỏng vỉa chứa quy mô lớn hoặc phức tạp, một lần chạy



Ngày nhận bài: 13/6/2025

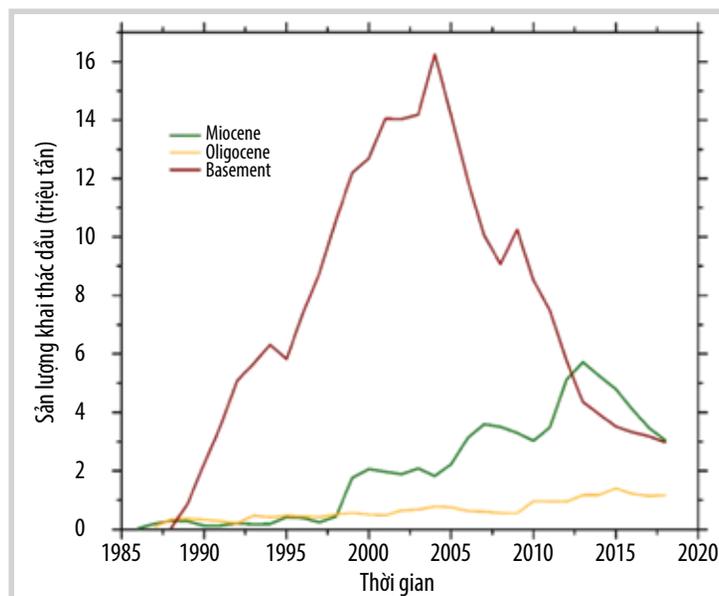
Ngày đánh giá và sửa chữa: 13 - 22/6/2025

Ngày duyệt đăng: 22/6/2025

mô phỏng thuận (forward simulation run) có thể mất từ vài giờ đến vài ngày để hoàn thành (Tailai Wen và nnk, 2014 [6]; Zhenyu Guo và nnk, 2018 [7]).

Thay vì mô phỏng vỉa chứa kiểu vật lý, các kỹ thuật mô phỏng không dựa trên vỉa chứa, như mô phỏng đường dòng (streamline simulation) (Khalid Aziz và nnk, 1979 [8], Akhil Datta-Gupta và nnk, 2007 [9], M.R. Thiele và nnk, 2010 [10]), mô hình điện dung - điện trở (capacitance resistance model - CRM) (Nguyen Anh Phuong, 2012 [11], Daniel Brent Weber và nnk, 2009 [12], Ali A. Yousef và nnk, 2006 [13], L.W. Lake và nnk, 2007 [14]) và mô hình kết nối giữa các giếng (interwell interconnection model) (Hui Zhao và nnk, 2016 [15], Zhenyu Guo và nnk, 2018 [7]) có thể là các phương pháp thay thế nhằm tối ưu hóa bơm ép nước. Những phương pháp này sẽ ước tính tác động của cặp giếng bơm ép và giếng khai thác thông qua việc đảo ngược các hệ số truyền dẫn (transmissibility coefficients) sao cho khớp với sản lượng thực tế tại giếng khai thác. Việc triển khai các phương pháp trên sẽ đẩy nhanh quá trình mô phỏng bằng cách đơn giản hóa dòng chảy, nhưng việc tinh chỉnh các thông số mô hình, như tính thấm tương đối, độ bão hòa nước ban đầu và tổng thể tích lỗ rỗng, đòi hỏi phải có các chuyên gia giàu kinh nghiệm để có được kết quả tin cậy.

Việc áp dụng các phương pháp tiêu chuẩn trong giai đoạn tối ưu hóa bơm ép nước đòi hỏi rất nhiều nỗ lực. Nhiều trường hợp không có đủ dữ liệu để xây dựng các mô hình phức tạp dựa trên vật lý, đặc biệt đối với vỉa chứa móng. Các đặc trưng vật lý thạch học như độ rỗng, độ thấm và độ bão hòa nước cục bộ phụ thuộc đáng kể vào mạng lưới nứt nẻ (fracture network) - vốn rất khó xác định từ dữ liệu địa chấn truyền thống. Do đó, để có được một mô hình chấp nhận được cần phải đưa ra nhiều giả định.



Hình 1. Sản lượng khai thác của bể Cửu Long theo thời gian.

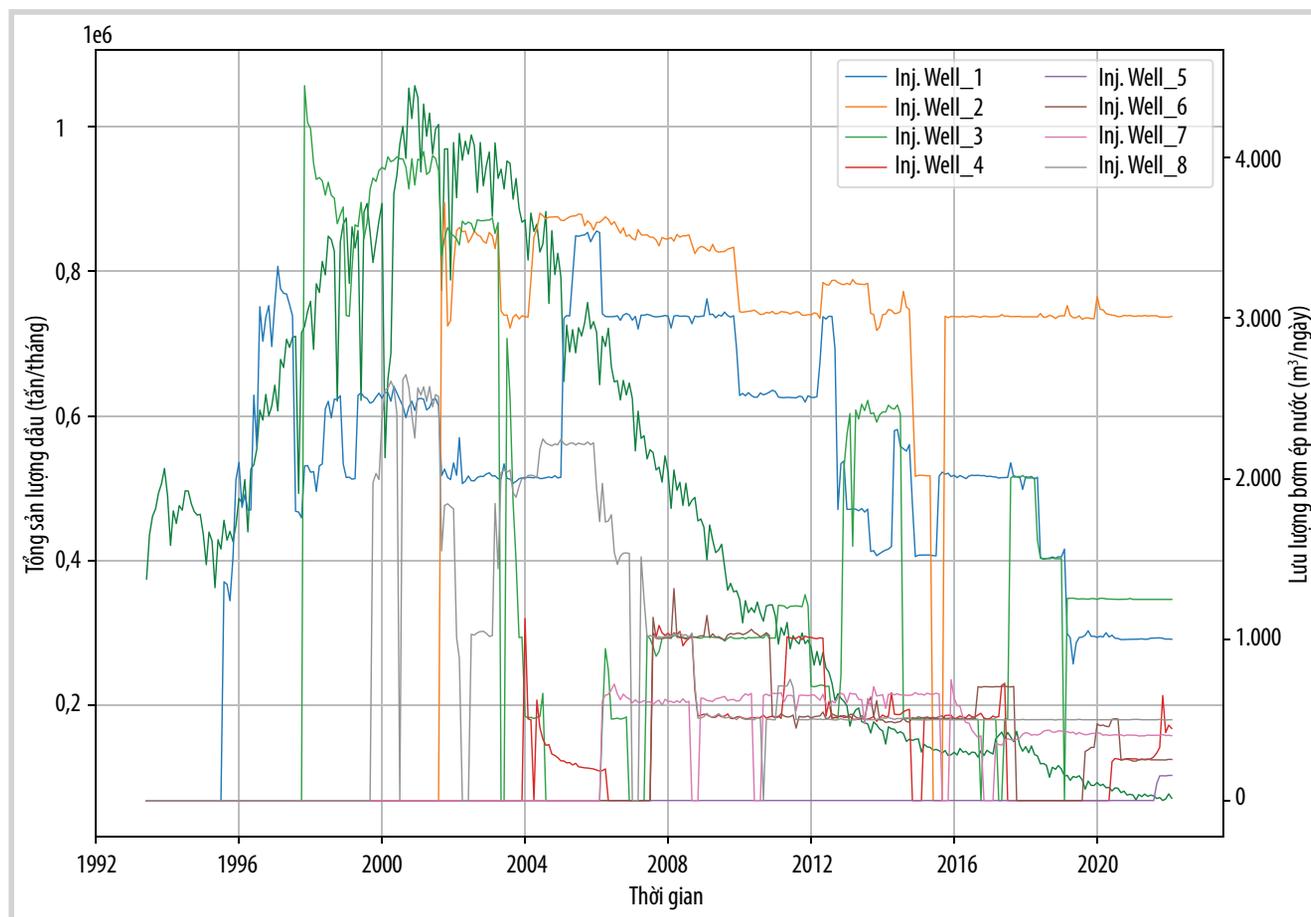
Gần đây, với sự phát triển của phương pháp học máy (ML), nhiều nghiên cứu đã áp dụng ML để dự đoán sản lượng dầu, tối ưu hóa lược đồ bơm ép nước nhằm nâng cao hiệu quả khai thác. Rui Zhang và nnk, 2021 [16] đã sử dụng chuỗi thời gian đa biến (multivariate time series) và phương pháp học máy tự hồi quy vector (vector autoregressive ML) để dự báo sản lượng dầu tại các vỉa chứa bơm ép nước. Trong nghiên cứu, các tác giả đã xác định các giếng bơm có ảnh hưởng đến giếng khai thác bằng cách tính hệ số tương quan đơn giản giữa lưu lượng bơm ép và lưu lượng khai thác dầu. Một số phương pháp ML khác như học tăng cường (reinforcement learning), mạng bộ nhớ dài hạn - ngắn hạn (long short-term memory network - LSTM network) đã được đề xuất để tối ưu hóa bơm ép nước (Farzad Hourfar và nnk, 2019 [17], Cuthbert Shang Wui Ng và nnk, 2022 [18]).

Trong nghiên cứu này, nhóm tác giả áp dụng quy trình làm việc (workflow) của Alfarizi và những người khác (Muhammad Gibran Alfarizi và nnk, 2022 [19]) kết hợp mạng neural nhân tạo (ANN) để dự đoán lưu lượng khai thác dầu và thuật toán tối ưu hóa Gauss-Newton nhằm tối ưu hóa quá trình bơm ép nước thông qua tối đa hóa giá trị hiện tại ròng (net present value - NPV).

Nhóm nghiên cứu đã thực hiện: i) thu thập số liệu về sản lượng dầu của các giếng khai thác cũng như lưu lượng bơm ép nước của các giếng bơm ép tại mỏ Bạch Hổ; ii) phân tích thống kê trên dữ liệu có sẵn để chọn lọc đặc trưng (feature selection); iii) tổng quan ngắn gọn về các phương pháp tiếp cận ANN cho bài toán hồi quy (regression problem) để dự đoán lưu lượng khai thác dầu của mỏ dầu đã cho từ lưu lượng nước bơm ép của các giếng bơm hiện tại; iv) đề xuất lược đồ bơm ép nước tối ưu nhằm nâng cao hiệu quả khai thác dầu bằng thuật toán tối ưu hóa Gauss-Newton.

2. Sản lượng dầu móng Bạch Hổ

Vỉa chứa móng nứt nẻ (fractured basement reservoir) được coi là một trường hợp đặc biệt trong ngành công nghiệp dầu khí. Do chế độ dòng chảy phức tạp, nhiều nghiên cứu đã được thực hiện để cải thiện việc khớp lịch sử sản lượng dầu (oil production history matching). Ví dụ, trong nghiên cứu của Lê Ngọc Sơn và nnk [20, 21], các thông số vật lý thạch học (petrophysical) và vỉa



Hình 2. Lưu lượng bơm ép và lưu lượng khai thác dầu tại khu vực móng trung tâm mỏ Bạch Hổ.

chứa như độ rỗng, độ thấm các thông số nén ép đá và kích thước tầng chứa nước (aquifer size) đã được điều chỉnh bằng cách sử dụng thuật toán tối ưu hóa trong quá trình mô phỏng nhằm đạt được kết quả khớp lịch sử sản lượng dầu tốt hơn. Một số phương trình thực nghiệm đã được đề xuất cho các mục đích này.

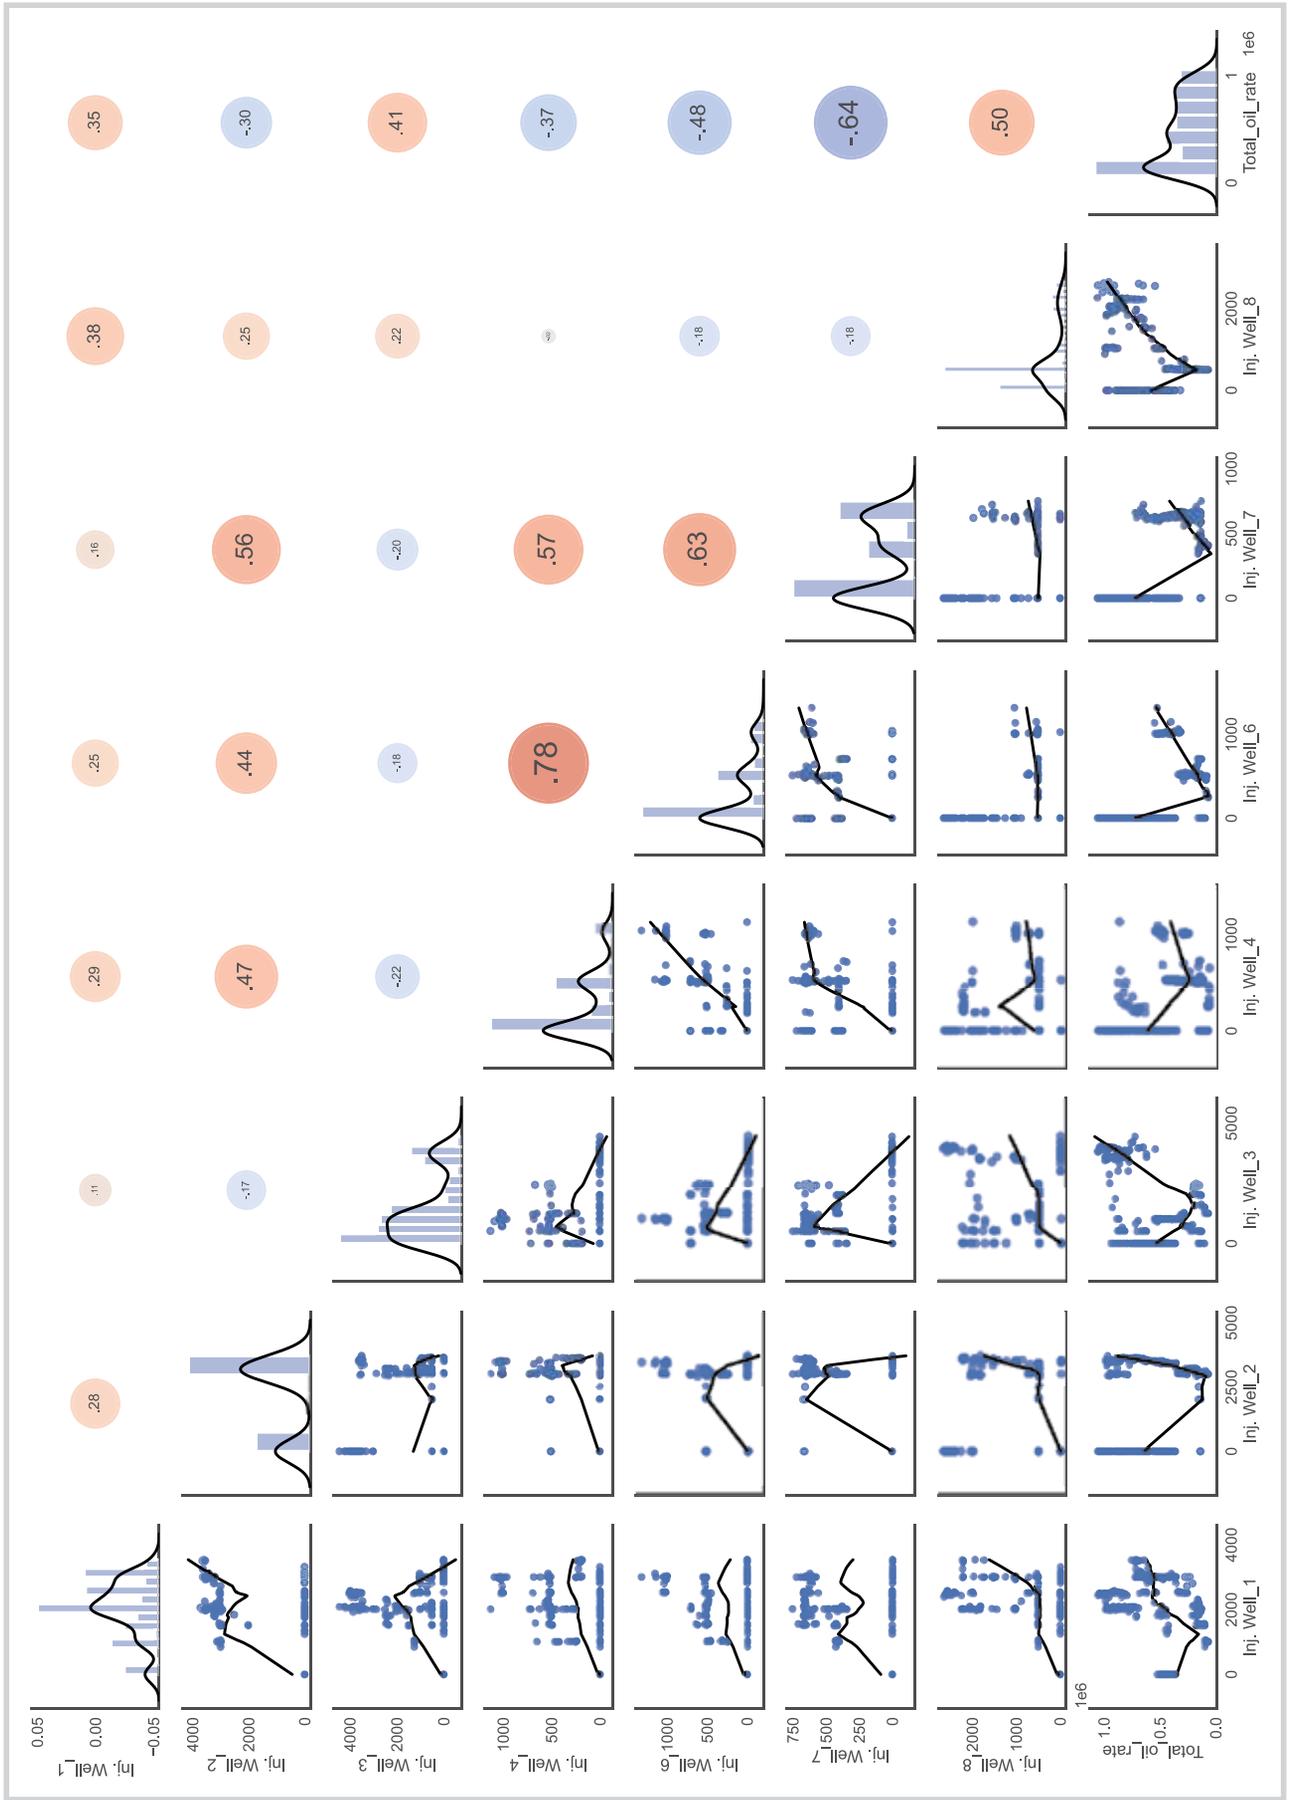
Tuy nhiên, các phương pháp học máy, vốn tiếp cận mục đích dự báo sản lượng dầu theo một cách khác, gần đây đã được sử dụng và ghi nhận nhiều thành công từ việc xem xét tài liệu. Chỉ dữ liệu thực tế về tổng sản lượng dầu từ các giếng khai thác và tốc độ bơm ép nước từ các giếng bơm mới được xem xét cho việc khớp và dự đoán tiếp theo.

Tại vỉa chứa móng Bạch Hổ, có gần 50 giếng bơm ép nước, tuy nhiên tại thời điểm nghiên cứu chỉ có 8 giếng đang hoạt động với lưu lượng bơm ép được thể hiện trong Hình 2 (trục dọc bên phải), cùng với tổng sản lượng dầu (trục dọc bên trái). Trong Hình 2, lưu lượng bơm ép tối đa khoảng 3.000 m³/ngày tại giếng bơm ép số 2, trong khi giếng bơm ép số 5 mới được kích hoạt lại với lưu lượng bơm ép trung bình 154,3 m³/ngày và sẽ không được xem

xét trong tối ưu hóa bơm ép nước cũng như dự đoán tổng sản lượng dầu. Do đó, chỉ sử dụng 7 giếng bơm ép nước làm các đặc trưng đầu vào (input features) trong bài toán học máy.

Hình 3 cho thấy các biểu đồ cặp (pair plots) giữa các giếng bơm và tổng sản lượng dầu, sự phân bố và hệ số tương quan Pearson giữa các cặp. Hệ số tương quan Pearson chỉ ra rằng 4 giếng bơm có tương quan nghịch (negatively correlated) với tổng sản lượng dầu, trong khi 3 giếng còn lại có tương quan thuận (positively correlated). Điều này về mặt thống kê có nghĩa là có thể sơ bộ giảm lưu lượng bơm từ 4 giếng bơm có tương quan nghịch và tăng tốc độ bơm từ 3 giếng tương quan thuận để tăng tổng sản lượng dầu (total oil productivity).

Ngoài ra, các hệ số tương quan không đủ cao để cho phép sử dụng tất cả lưu lượng bơm ép nước từ các giếng bơm ép này làm đặc trưng đầu vào cho dự đoán tổng sản lượng của mỏ dầu. Sau khi được chọn, các đặc trưng dữ liệu sẽ được xáo trộn (shuffled) và chọn ngẫu nhiên 80% cho huấn luyện (training) và 20% cho kiểm tra (testing).



Hình 3. Hệ số tương quan giữa lưu lượng bơm ép và lưu lượng khai thác dầu tại khu vực trung tâm mỏ Bạch Hổ.

3. Thuật toán ANN sử dụng cho dự báo khai thác

Trong nghiên cứu này, mô hình hồi quy (regression model) sẽ được sử dụng để ánh xạ lưu lượng bơm ép nước hiện tại từ các giếng bơm ép sang tổng lưu lượng dầu.

Theo thông lệ, $X = \{x_i\}_{i=1}^d \in R^{n \times d}$ biểu thị tập huấn luyện (training set), trong đó d là số lượng giếng bơm ép và n là số bước thời gian trong lịch sử bơm ép. Cột giá trị mục tiêu (target values) được biểu diễn dưới dạng vector $Y = \{y_i\}_{i=1}^n \in R^{n \times 1}$. Nói chung, bài toán đặt ra là cần tìm một hàm xấp xỉ $\hat{f}(x, \theta) : X \rightarrow Y$ bằng cách tối thiểu hóa hàm sai số (loss function) $\sum_{i=1}^n L(\hat{f}(x, \theta), y_i) \rightarrow \min \theta$, trong đó $\hat{f}(x, \theta)$ là mô hình hồi quy với tham số mô hình θ .

- Mô hình hồi quy tuyến tính

Mô hình hồi quy tuyến tính được định nghĩa là $\hat{f}(x, w) = w^T x + w_0$. Để huấn luyện mô hình này, việc tối thiểu hóa hàm sai số đối với các hệ số $w^T \in R^{n \times 1}, w_0 \in R$ sẽ được thực hiện để tìm ra tham số mô hình tốt nhất, được biểu diễn như sau:

$$[w^T, w_0] = \underset{w^T, w_0}{\operatorname{argmin}} \sum_{i=1}^n (w^T x_i + w_0 - y_i)^2 + R(w, \alpha) \quad (1)$$

Số hạng điều chuẩn (regularization term) $R(w, \alpha)$ sẽ loại bỏ các hệ số có giá trị cao nhằm tránh hiện tượng khớp quá mức (overfitting) và có thể giúp giảm thiểu hệ số của các đặc trưng có ảnh hưởng nhỏ đến biến mục tiêu. Có một số loại điều chuẩn:

$$\begin{aligned} \text{Lasso } R(w, \alpha) &= \alpha \sum_{j=1}^d |w_j| \quad (L_1 \text{ regularization}); \\ \text{Ridge } R(w, \alpha) &= \alpha \sum_{j=1}^d w_j^2 \quad (L_2 \text{ regularization}); \end{aligned}$$

Siêu tham số (hyperparameter) α liên quan đến điều chuẩn L_1/L_2 sẽ được tinh chỉnh bằng cách sử dụng các kỹ thuật điều chuẩn Lasso và Ridge của thư viện Scikit-learn cho thử nghiệm (Fabian Pedregosa và nnk, 2011) [22].

- Mạng neural nhân tạo (ANN)

Mô hình ANN có thể được biểu diễn dưới dạng:

$$\hat{f}(x) = \delta_k(w_k \delta_{k-1}(\dots w_2 \delta_1(w_1 x + b_1) + b_2) \dots) + b_k \quad (2)$$

Trong đó:

δ_i : Hàm kích hoạt (activation function);

k : Số lớp;

$w_i \in R^{out_i \times in_i}$: Ma trận trọng số (weight matrix);

b_i : Độ lệch (bias) cho lớp thứ i .

Tương tự mô hình hồi quy tuyến tính, việc tối thiểu hóa hàm sai số bình phương (squared loss function) giữa

giá trị tính toán và giá trị thực sẽ được thực hiện để khớp mô hình bằng cách sử dụng thuật toán giảm độ dốc ngẫu nhiên (stochastic gradient descent) hoặc phiên bản cải tiến có tên là Adam (Diederik P. Kingma và nnk, 2014 [23]) như sau:

$$[w_1, b_1, \dots, w_k, b_k] = \underset{w_1, b_1, \dots, w_k, b_k}{\operatorname{argmin}} \frac{1}{n} \sum_{i=1}^n (\hat{f}(x_i) - y_i)^2 \quad (3)$$

- Đánh giá mô hình

Để ước tính mức độ chính xác mà các mô hình dự đoán hoạt động trên toàn bộ tập dữ liệu, nhóm tác giả đã sử dụng sai số tuyệt đối trung bình (MAE) (mean absolute error) làm phương pháp chấm điểm cho kiểm chứng chéo 5 lần (five-folds cross-validation). Chỉ số lỗi này được định nghĩa như sau:

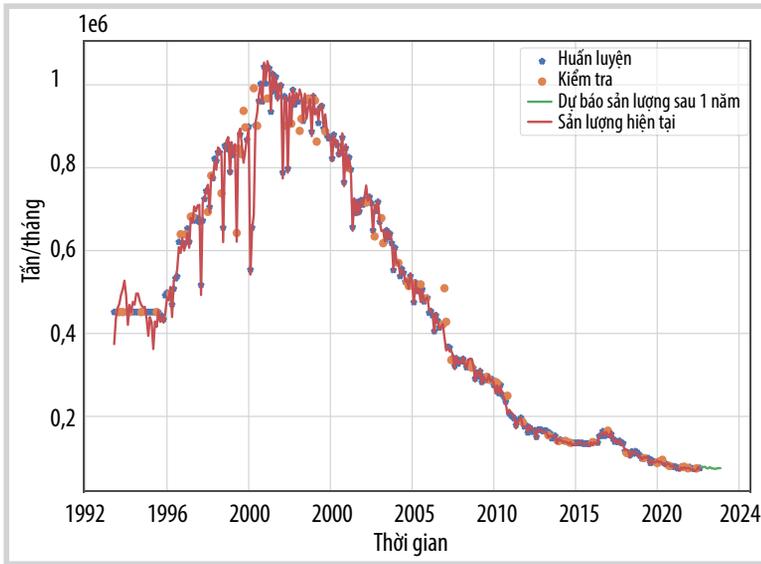
$$MAE(\hat{f}(x), y) = \frac{1}{n} \sum_{i=1}^n |\hat{f}(x_i) - y_i| \quad (4)$$

Để đánh giá khả năng áp dụng của mô hình trong thực tế và so sánh với đánh giá của nhà điều hành về hiệu quả của việc bơm ép, nhóm tác giả đã tiến hành thử nghiệm tính toán như sau:

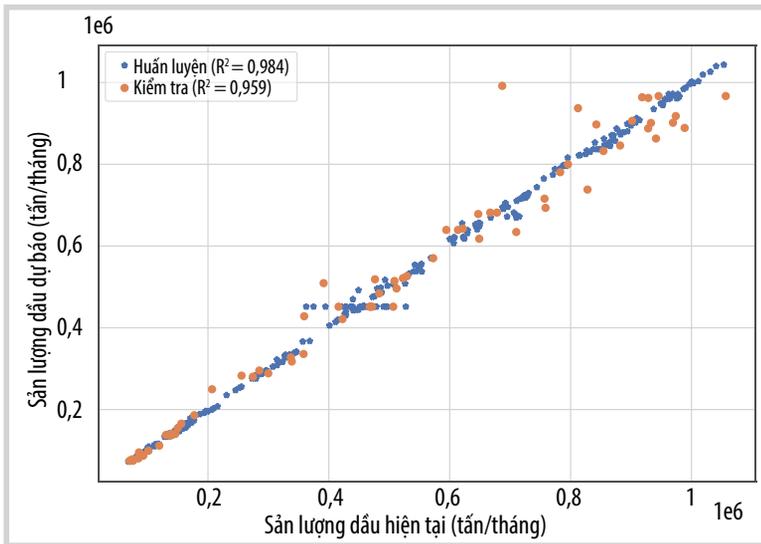
- Chia mẫu dữ liệu thành tập huấn luyện (80%) và tập kiểm tra (20%) và huấn luyện một số mô hình đã đề cập ở trên với các tham số mặc định cho việc lựa chọn mô hình;
- Tinh chỉnh để tối ưu hóa các tham số mô hình trên tập dữ liệu huấn luyện. Sau đó, mô hình sẽ được áp dụng cho tập dữ liệu kiểm tra để xác minh việc khớp quá mức (verifying the overfit) trước khi được quyết định lựa chọn.

Kết quả dự đoán ANN trên tập huấn luyện và kiểm tra của dữ liệu sau khi xáo trộn và được chọn ngẫu nhiên được thể hiện trong Hình 4a. Tại đây, dự đoán trước 1 năm được thực hiện bằng cách giữ nguyên lược đồ bơm ép của năm hiện tại, sau đó nhóm tác giả áp dụng mô hình ANN để dự đoán xa hơn và hiển thị dưới dạng đường cong màu xanh lam trong Hình 4a. Dự đoán này sẽ được sử dụng làm trường hợp cơ sở (based case) cho việc tối ưu hóa lược đồ bơm ép nước tiếp theo.

Các chỉ số MAE (sai số tuyệt đối trung bình) là 37.644,24 và 61.160,15 tương ứng cho tập dữ liệu huấn luyện và tập dữ liệu kiểm tra, trong khi hệ số tương quan (coefficients) của mô hình ML giữa các giá trị đầu ra của tập huấn luyện và kiểm tra với sản lượng dầu thực tế lần lượt là 0,985 và 0,959, như thể hiện trên Hình 4b. Hệ số xác định cao của mô hình ANN và sự khác biệt không lớn giữa tập dữ liệu

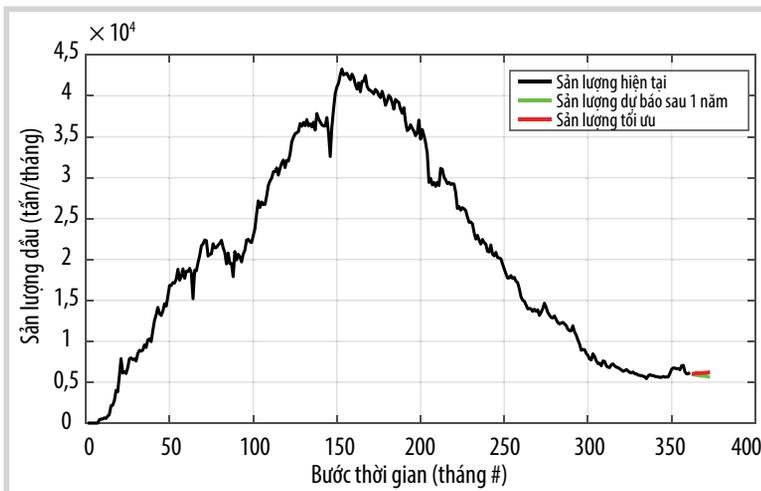


(a)



(b)

Hình 4. Lưu lượng khai thác dầu được sử dụng để huấn luyện, kiểm tra và dự báo sau đó 1 năm với giả thiết lưu lượng bơm ép vẫn giữ nguyên so với hiện tại (a); hệ số tương quan giữa kết quả dự báo cho tập huấn luyện và kiểm tra (b).



Hình 5. Kết quả tối ưu bơm ép.

huấn luyện và kiểm tra cho thấy mô hình này là chấp nhận được cho việc dự đoán và tối ưu hóa tiếp theo.

4. Tối ưu hóa bơm ép nước

Để tối ưu hóa lược đồ bơm ép nước (water injection scheme), hàm mục tiêu giá trị hiện tại ròng (NPV) được định nghĩa như sau:

$$NPV(u) = \sum_{i=1}^{n_t} \frac{(Q_o^i(u)P_o - Q_w^i(u)P_w - Q_{wi}^i(u)P_{wi})\Delta t_i}{(1 + \text{interest rate})^{\frac{t_i}{D}}} \quad (5)$$

Trong đó u là vector tham số tối ưu hóa; Q^i là lưu lượng bơm ép toàn mô tại bước thời gian i ; P là cho giá hoặc chi phí; các chỉ số dưới o, w và wi lần lượt chỉ dầu, nước khai thác và nước bơm ép; n_t là tổng số bước thời gian. Trong nghiên cứu này, giá dầu (P_o) được đặt là 90 USD/thùng, trong khi cả chi phí nước khai thác (P_w) và chi phí nước bơm ép (P_{wi}) đều là 3 USD/thùng. Hơn nữa, tham số tối ưu hóa được sử dụng ở đây là tốc độ bơm ép toàn mô. Do đó, bài toán tối ưu hóa sẽ liên quan đến việc điều chỉnh tốc độ bơm ép nước toàn mô trong vòng 12 tháng của năm tiếp theo.

Nhiều thuật toán tối ưu hóa có thể được sử dụng để tối đa hóa hàm mục tiêu (7) trong phương pháp điều chỉnh của nhóm tác giả đã mô tả trong Mục 3. Bảy thuật toán tối ưu hóa truyền thống khác nhau đã được tích hợp vào chương trình máy tính của nhóm tác giả gồm: Thuật toán giảm độ dốc dốc nhất (Steepest descent algorithm) (Roger Fletcher, 1987 [24], William H. Press và nnk, 1992 [25]); thuật toán Gauss-Newton (Gauss-Newton algorithm) (Roger Fletcher, 1987 [24], William H. Press và nnk, 1992 [25]); thuật toán xấp xỉ ngẫu nhiên xáo trộn đồng thời (simultaneous perturbation stochastic approximation - SPSA algorithm) (J.C. Spall 1992, 1998 [26, 27]); thuật toán SIMPLEX (SIMPLEX algorithm) (J.A. Nelder và nnk, 1965 [28]); thuật toán tập hợp hướng (Direction set algorithm) Roger Fletcher, 1987 [24]; William H. Press và nnk, 1992 [25]; thuật toán gradient liên hợp (Conjugate gradient algorithm) Roger Fletcher, 1987 [24]; William H. Press và nnk, 1992 [25]; thuật toán ma trận biến thiên (Variable metric algorithm) Roger

Bảng 1. Lưu lượng tối ưu các giếng bơm ép

Giếng bơm ép	Lưu lượng dòng hiện tại (m ³ /ngày)	Lưu lượng tối ưu (m ³ /ngày)	Thay đổi (m ³ /ngày)
1	416,8	407,1	-9,7
2	523,2	620,5	97,3
3	703,4	752,6	49,2
4	2.009,0	2.135,3	126,2
5	2.005,1	2.214,0	208,9
6	3.007,2	2.321,0	-686,2
7	602,7	635,4	32,6

Fletcher, 1987 [24]; William H. Press và nnk, 1992 [25]. Mô tả chi tiết về các thuật toán tối ưu hóa liệt kê trên đây có thể được tìm thấy trong các tài liệu tham khảo.

Đối với bài toán cụ thể tại mỏ Bạch Hổ, thuật toán Gauss-Newton đã được chọn và kết quả tối ưu hóa được thể hiện trong Hình 5 với lưu lượng bơm ép tối ưu được chỉ ra trong Bảng 1.

Nghiên cứu tối ưu hóa, dựa trên các thay đổi đề xuất đối với lưu lượng bơm ép nước, cho thấy rằng trong khi dự đoán tương lai theo lưu lượng hiện tại (đường màu xanh lục) tiếp tục đi xuống, thì lưu lượng tối ưu hóa (đường màu đỏ) đã làm chững lại phần suy giảm dốc nhất và giúp gia tăng nhẹ trong dự báo sản lượng ngắn hạn. Tác động tích cực này, dù nhỏ, đạt được nhờ phân bổ lại nước bơm ép, đáng chú ý nhất là giảm 686,2 m³/ngày tại giếng bơm ép số 7 (có khả năng là giếng có watercut cao) và chuyển hướng phần lớn lượng nước đó đến giếng bơm ép số 6 (+208,9 m³/ngày), giếng bơm ép số 4 (+126,2 m³/ngày), và giếng bơm ép số 2 (+97,3 m³/ngày). Việc điều chỉnh lưu lượng bơm ép tối ưu này nhằm mục đích cải thiện hiệu quả quét theo thể tích (volumetric sweep efficiency) bằng cách hướng dòng nước đến các khu vực chưa được quét trước đây của vỉa chứa, qua đó tối đa hóa lượng dầu còn lại có thể thu hồi.

5. Kết luận và kiến nghị

Một quy trình mới để tối ưu hóa bơm ép nước tại vỉa chứa móng Bạch Hổ đã được phát triển thành công, tích hợp mạng neural nhân tạo để dự báo sản lượng dầu với thuật toán tối ưu Gauss-Newton nhằm tối đa hóa giá trị hiện tại ròng. Mô hình mạng neural nhân tạo đã chứng tỏ được độ chính xác dự đoán chấp nhận được, thể hiện sự tương quan cao và sai khác rất nhỏ giữa sản lượng thực tế và sản lượng dự báo trên cả tập dữ liệu huấn luyện và tập dữ liệu kiểm tra.

Lược đồ bơm ép nước tối ưu hóa thu được đã cho thấy một phát hiện quan trọng: việc giảm đáng kể lưu lượng

bơm tại giếng bơm ép số 7 là yếu tố chủ đạo cho dự đoán gia tăng tổng sản lượng dầu và nâng cao NPV. Điều cốt yếu là, quy trình làm việc dựa trên dữ liệu này mang lại tốc độ tính toán nhanh hơn so với các phương pháp mô phỏng số truyền thống. Với ưu điểm như vậy, phương pháp này được khuyến nghị sử dụng cho việc sàng lọc và phân tích sơ bộ, nhưng kết quả thu được cần phải được xác thực bằng đánh giá chuyên môn và mô phỏng số đầy đủ trước khi triển khai thực tế ngoài mỏ.

Phương pháp tối ưu hóa hiệu quả và thực tiễn này được khuyến nghị để ứng dụng cho các vỉa chứa móng tương tự trong bể Cửu Long, bao gồm các mỏ Rồng, Sư Tử Nâu, và Sư Tử Trắng.

Tài liệu tham khảo

- [1] Andrea Capolei, Eka Suwartadi, Bjarne Foss, and John Bagterp Jørgensen, "Waterflooding optimization in uncertain geological scenarios", *Computational Geosciences*, Volume 17, Issue 6, pp. 991 - 1013, 2013. DOI: 10.1007/s10596-013-9371-1.
- [2] Bjarne Foss, Bjarne Grimstad, and Vidar Gunnerud, "Production optimization—facilitated by divide and conquer strategies", *IFAC-PapersOnLine*, Volume 48, Issue 6, pp. 1 - 8, 2015. DOI: 10.1016/j.ifacol.2015.08.001.
- [3] Paul M.J. Van den Hof, Jan Dirk Jansen, and Arnold Heemink, "Recent developments in model-based optimization and control of subsurface flow in oil reservoirs", *IFAC Proceedings Volumes*, Volume 45, Issue 8, pp. 189 - 200, 2012. DOI: 10.3182/20120531-2-NO-4020.00047.
- [4] Bjarne Foss and John Petter Jenson, "Performance analysis for closed-loop reservoir management", *SPE Journal*, Volume 16, Issue 1, pp. 183 - 190, 2011. DOI: 10.2118/138891-PA.

- [5] J.D. Jansen, R.M. Fonseca, S. Kahrobaei, M.M. Siraj, G.M. Van Essen, and P.M.J. Van den Hof, "The egg model-a geological ensemble for reservoir simulation", *Geoscience Data Journal*, Volume 1, Issue 2, pp. 192 - 195, 2014. DOI: 10.1002/gdj3.21.
- [6] Tailai Wen, Marco R. Thiele, David Echeverría Ciaurri, Khalid Aziz, and Yinyu Ye, "Waterflood management using two-stage optimization with streamline simulation", *Computational Geosciences*, Volume 18, Issue 3, pp. 483 - 504, 2014. DOI: 10.1007/s10596-014-9404-4.
- [7] Zhenyu Guo, Albert C. Reynolds, and Hui Zhao, "A physics-based data-driven model for history matching, prediction, and characterization of waterflooding performance", *SPE Journal*, Volume 23, Issue 2, pp. 367 - 395, 2018. DOI: 10.2118/182660-PA.
- [8] Khalid Aziz and Antonín Settari, *Petroleum reservoir simulation*. Society of Petroleum Engineers, 1979. DOI: 10.2118/9781613999646.
- [9] Akhil Datta-Gupta and Michael King, *Streamline simulation: Theory and practice*. Society of Petroleum Engineers, 2007. DOI: 10.2118/9781555631116.
- [10] M.R. Thiele, R.P. Batycky, and D.H. Fenwick, "Streamline simulation for modern reservoir-engineering workflows", *Journal of Petroleum Technology*, Volume 62, Issue 1, pp. 64 - 70, 2010. DOI: 10.2118/118608-JPT.
- [11] Nguyen Anh Phuong, "Capacitance resistance modeling for primary recovery, waterflood and water-CO₂ flood", University of Texas at Austin, 2012.
- [12] Daniel Brent Weber, "The use of capacitance-resistance models to optimize injection allocation and well location in waterflood", University of Texas at Austin, 2009.
- [13] Ali A. Yousef, Pablo Gentil, Jerry L. Jensen, and Larry W. Lake, "A capacitance model to infer interwell connectivity from production-and injection-rate fluctuations", *SPE Reservoir Evaluation & Engineering*, Volume 9, Issue 6, pp. 630 - 646, 2006. DOI: 10.2118/95322-PA.
- [14] L.W. Lake, X. Liang, T.F. Edgar, A. Al-Yousef, M. Sayarpour, and D. Weber, "Optimization of oil production based on a capacitance model of production and injection rates", *Hydrocarbon economics and evaluation symposium Dallas, Texas, U.S.A., 1 - 3 April 2007*. DOI: 10.2118/107713-MS.
- [15] Hui Zhao, Zhijiang Kang, Xiansong Zhang, Haitao Sun, Lin Cao, and Albert C. Reynolds, "A physics-based data-driven numerical model for reservoir history matching and prediction with a field application", *SPE Journal*, Volume 21, Issue 6, pp. 2175 - 2194, 2016. DOI: 10.2118/173213-PA.
- [16] Rui Zhang and Hu Jia, "Production performance forecasting method based on multivariate time series and vector autoregressive machine learning model for waterflooding reservoirs", *Petroleum Exploration and Development*, Volume 48, Issue 1, pp. 201 - 211, 2021. DOI: 10.1016/S1876-3804(21)60016-2.
- [17] Farzad Hourfar, Hamed Jalaly Bidgoly, Behzad Moshiri, Karim Salahshoor, and Ali Elkamel, "A reinforcement learning approach for waterflooding optimization in petroleum reservoirs", *Engineering Applications of Artificial Intelligence*, Volume 77, pp. 98 - 116, 2019. DOI: 10.1016/j.engappai.2018.09.019.
- [18] Cuthbert Shang Wui Ng, Ashkan Jahanbani Ghahfarokhi, and Menad Nait Amar, "Production optimization under waterflooding with Long Short-Term Memory and metaheuristic algorithm", *Petroleum*, Volume 9, Issue 1, pp. 53 - 60, 2022. DOI: 10.1016/j.petlm.2021.12.008.
- [19] Muhammad Gibran Alfarizi, Milan Stanko, and Timur Bismukhametov, "Well control optimization in waterflooding using genetic algorithm coupled with artificial neural networks", *Upstream Oil and Gas Technology*, Volume 9, 2022. DOI: 10.1016/j.upstre.2022.100071.
- [20] Le Ngoc Son, Mahmoud Jamiolahmady, Jean-Marie Questiaux, and Mehran Sohrabi, "An integrated geology and reservoir engineering approach for modelling and history matching of a Vietnamese fractured granite basement reservoir", *EUROPEC/EAGE Conference and Exhibition, London, UK, 11 - 14 June 2007*. DOI: 10.2118/107141-MS.
- [21] Le Ngoc Son, Phan Ngoc Trung, Yoshihiro Masuda, Sumihiko Murata, Nguyen The Duc, Sunao Takagi, and Ahmad Ghassemi, "Development of a method for adjusting rock compaction parameters and aquifer size from production data and its application to Nam-Su fractured basement reservoir of Vietnam", *Journal of Petroleum Science and Engineering*, Volume 210, 2022. DOI: 10.1016/j.petrol.2021.109894.
- [22] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot, and

Edouard Duchesnay, "Scikit-learn: Machine learning in Python", *Journal of Machine Learning Research*, Volume 12, pp. 2825 - 2830, 2011.

[23] Diederik P. Kingma and Jimmy Ba, "Adam: A method for stochastic optimization", *3rd International Conference for Learning Representations, San Diego, 22 December 2014*. DOI: 10.48550/arXiv.1412.6980

[24] Roger Fletcher, *Practical methods of optimization, second edition*. John Wiley & Sons, 1987.

[25] William H. Press, William T. Vetterling, *Numerical in Fortran: the Art of Scientific Computing*. Cambridge University Press, 1992.

[26] J.C. Spall, "Multivariate stochastic approximation using a simultaneous perturbation gradient approximation", *IEEE Transactions on Automatic Control*, Volume 37, Issue 3, pp. 332 - 341, 1992. DOI: 10.1109/9.119632.

[27] J.C. Spall, "Implementation of the simultaneous perturbation algorithm for stochastic optimization", *IEEE Transactions on Aero space Electronic System*, Volume 34, Issue 3, pp. 817 - 823, 1998. DOI: 10.1109/7.705889.

[28] J.A. Nelder and R. Mead, "A simplex method for function minimization", *Computer Journal*, Volume 7, Issue 4, pp. 308 - 313, 1965. DOI: 10.1093/comjnl/7.4.308.

AN ARTIFICIAL NEURAL NETWORK APPROACH TO OPTIMIZE THE WATER FLOODING OF BACH HO OILFIELD, OFFSHORE VIETNAM

Doan Huy Hien¹, Le The Hung¹, Tran Xuan Quy¹, Pham Truong Giang¹, Nguyen Minh Quy¹, Nguyen The Duc²

¹Vietnam Petroleum Institute (VPI)

²Institute of Mechanics, Vietnam Academy of Science and Technology (VAST)

Email: hiendh.epc@vpi.pvn.vn

Summary

The predominant oil production offshore Vietnam originates from the Bach Ho basement reservoir, where the flow regime is highly complicated due to the heterogeneous spatial distribution of petrophysical properties such as porosity, permeability, and water saturation. Therefore, the conventional reservoir-simulation-based methods for forecasting oil production often yield limited accuracy or require substantial time and effort to optimize the dynamic parameters. Recent advances in machine learning (ML) algorithms enable more rapid and accurate prediction of oil production rates from water injection rates at individual injection wells. Once the oil rate prediction is achieved using ML approach, the waterflooding optimization can then be achieved by any suitable optimization algorithm.

In this research, an artificial neural network (ANN) algorithm is used, yielding very good results: the correlation coefficients between the predicted and actual values are 0.98 and 0.95 for training and testing datasets, respectively. Subsequently, the Gauss-Newton optimization algorithm is applied to determine the optimal water injection rates for each injection well, aiming to enhance oil productivity. The results show that the newly optimized injection schemes yield an average oil production increase of 1.5%.

Key words: Waterflooding optimization, reservoir simulation, artificial neural network, machine learning, Bach Ho oilfield.