

Ứng dụng mạng Neuron nhân tạo để tính toán sự thay đổi áp suất của dòng chảy đa pha trong môi trường liên tục

Phạm Sơn Tùng¹, Võ Trâm Oanh¹

¹ Trường Đại học Bách khoa - Đại học Quốc gia Thành phố Hồ Chí Minh

TỪ KHOẢ

Áp suất dòng chảy đáy giếng
Dòng chảy đa pha
Mạng neuron nhân tạo

TÓM TẮT

Dự đoán chính xác về sự giảm áp suất là điều quan trọng phải có trong suốt vòng đời của giếng để thiết kế ống hiệu quả hơn và hoạt động sản xuất tối ưu hơn. Triển khai đồng hồ đo áp suất là một biện pháp phổ biến để đo áp suất dòng chảy đáy giếng (FBHP). Ngoài ra, một số mô hình cơ khí và mối tương quan thực nghiệm cho dòng đa pha đã được đề xuất để tránh tiêu tốn chi phí đáng kể và tốn thời gian khi can thiệp vào một giếng đang sản xuất. Tuy nhiên, kết quả của các kỹ thuật dự đoán gần đây cho thấy mức độ chính xác khá thấp, vì vậy phương pháp cải tiến là cần thiết để giải quyết vấn đề này. Bài báo này liên quan đến nghiên cứu gần đây của chúng tôi về việc sử dụng Mạng neuron nhân tạo (ANN) để dự đoán sự sụt giảm áp suất trong các giếng đa pha. Mô hình ANN được phát triển dựa trên nhiều dữ liệu sản xuất bề mặt khác nhau bao gồm tốc độ dòng chảy của dầu, tốc độ dòng chảy của khí, tỷ lệ khí-dầu, áp suất đầu giếng, nhiệt độ đầu giếng, áp suất đáy giếng, nhiệt độ đáy giếng. Các bộ dữ liệu thu thập được từ giếng X tại mỏ Hải Thạch Mộc Tinh được thống kê sần lọc và nhập vào các mô hình ANN. Các mô hình được đề xuất bao gồm một loạt các biến với số lượng tế bào thần kinh khác nhau của các lớp ẩn. Kết quả giữa các tập dữ liệu khác nhau là các bản ghi và so sánh thống kê với nhau để chọn lỗi ít nhất.

KEYWORDS

Flowing bottom-hole pressure
Multiphase flow
Artificial neuron network

ABSTRACT

It is immense important to have accurate prediction of pressure drop over the life of the well to design more effective tubing and optimum production operation. A deployment of pressure gauge is a common practice to measure flowing bottom-hole pressure (FBHP). Additionally, some mechanic models and empirical correlations for multiphase have been proposed in order to avoid a significant expense and time-consuming of intervening a producing well. Nevertheless, the recent prediction techniques present a low level of accuracy in the result, the improvement method is needed to tackle this problem. This paper reports our recent study on the use of an Artificial Neural Networks (ANN) to predict the pressure drop in multiphase flowing wells. The ANN model is developed based on numerous different surface production data including oil flow rate, gas flow rate, gas-oil ratio, wellhead pressure, wellhead temperature, bottom-hole pressure, bottomhole temperature. The collected data sets from the flowing well X at Hai Thach Moc Tinh field are normalized and imported into the ANN models. The proposed models covered a wide range of variables with different neuron number of hidden layers. The results between different data set are records and compared statistically to each other in order to choose the least error.

1. Giới thiệu

Thiết kế thích hợp của các hệ thống hoàn thành giếng và hệ thống nâng nhân tạo, cũng như tối ưu hóa và dự báo chính xác hiệu suất sản xuất, đòi hỏi một phương pháp đáng tin cậy và chính xác để ước tính giảm áp suất trong dòng chảy đa pha cho những giếng dọc. Do sự phức tạp của dòng chảy đa pha, hầu hết các dự đoán giảm áp suất đều dựa trên mối tương quan thực nghiệm hoặc bán thực nghiệm (Hagedorn và Brown (1961), Duns và Ros (1963), Orkiszewski (1967), Beggs and Brill (1973), Mukherjee và Brill (1985). Nhiều nghiên cứu đã được tiến hành để kiểm tra và điều tra

khả năng áp dụng của các mối quan hệ đó trên một loạt các dữ liệu. Hầu hết các nghiên cứu thừa nhận rằng không có kết nối duy nhất nào được tìm thấy có thể áp dụng trên tất cả các phạm vi biến với độ chính xác đủ. Tuy nhiên, khi các giá trị sai lầm bị bỏ qua, một cuộc điều tra thống kê không tìm thấy lợi ích đáng kể cho các mô hình cơ học so với các mối tương quan thực nghiệm hiện tại về khả năng dự đoán áp suất.

Mặc dù mạng lưới thần kinh nhiều lớp được phát hiện vào những năm 1960, chúng không được khám phá kỹ lưỡng cho đến những năm 1980. Bản đồ tự tổ chức dựa trên học tập cạnh tranh đã được giới thiệu vào những năm 1970. Trong những năm 1980,

*Liên hệ tác giả: phamsontung@hcmut.edu.vn

Nhận ngày 06/01/2022, sửa xong ngày 15/03/2022, chấp nhận đăng 28/04/2022

Link DOI: <https://doi.org/10.54772/jomc.03.2022.359>

mạng lưới thần kinh đã trải qua một thời kỳ phục hưng. Mạng lưới thần kinh hoạt động tương tự như các tế bào thần kinh trong não. Mạng lưới thần kinh nhân tạo gần đây đã trở nên phổ biến vì khả năng giải quyết một loạt các vấn đề dầu mỏ phức tạp. Osman và cộng sự [2] đã đề xuất một mạng lưới mới để dự đoán áp suất lỗ dưới chảy trong dòng chảy đa pha đối với giếng thẳng đứng. Khi họ so sánh mạng lưới của họ với các mô hình thực nghiệm và cơ học thông thường, họ phát hiện ra rằng ANN là phương pháp tối ưu nhất. Mohammadpoor và cộng sự [3] đã phát triển một mạng lưới thần kinh nhân tạo mới (ANN) để dự đoán áp suất dòng chảy đáy giếng trong các giếng dầu đa pha theo phương thẳng đứng trong các mỏ dầu của Iran. Ông đã đánh giá nhiều lớp tế bào thần kinh của ANN và các chức năng đào tạo khác nhau và chọn lớp tốt nhất có lỗi thấp nhất. Trong các giếng chảy đa pha thẳng đứng, một mô hình Mạng neuron nhân tạo cũng được đề xuất để dự đoán áp suất chảy dưới đáy giếng và kết quả là áp suất giảm. Mô hình thể hiện tốt hơn các mô hình truyền thống với hệ số tương quan là 0,9222 và sai số trung bình tuyệt đối 3,5% sau khi đánh giá một loạt các tập dữ liệu, bao gồm 413 bộ dữ liệu trường thu được trong nỗ lực nghiên cứu. Những phát hiện thống kê nói trên thu được bằng cách sử dụng một lớp ẩn của mạng lưới neuron hướng tới nguồn cấp dữ liệu trong mô hình dự đoán. 2011 (Jahanandish và Salimifard) [4]. Li và cộng sự [5] đã đề xuất một chiến lược kết hợp bao gồm quy trình tính toán tương quan giữa dòng đa pha và các mô hình Mạng neuron nhân tạo. Các mô hình mạng neuron lan truyền trở lại đã được kết hợp thành một kỹ thuật tính toán chính xác để ước tính gradient áp suất, dẫn đến tăng độ chính xác dự đoán và phạm vi dự đoán rộng hơn. Tỷ lệ không chính xác tuyệt đối trung bình thấp nhất, theo mô hình, là 3,1 %. Kỹ thuật kết hợp kết quả có độ chính xác trung bình tuyệt đối phần trăm là 23,0 % khi so sánh với các mối tương quan trong dòng đa pha. Mô hình, mặt khác, đã được sử dụng với một máy tính áp suất đáy giếng được tích hợp vào giao diện người dùng. Medhat và Hassan [6] đã trình bày dự đoán về áp suất lỗ dưới chảy cho các giếng dầu thẳng đứng bằng các mô hình mạng thần kinh, sử dụng bộ dữ liệu lịch sử từ nhiều mỏ dầu khác nhau. Sử dụng một kỹ thuật học máy mạng thần kinh nhân tạo, Spesivtsev et al. [7] đã tạo ra một mô hình để dự báo áp suất lỗ dưới đa chiều. Họ đã sử dụng một bộ dữ liệu gồm 3500 mẫu mà họ tạo ra với trình mô phỏng.


Hệ thống ANN được thiết kế trên ba yếu tố cơ bản chính; cụ thể là thuật toán, chức năng chuyển giao và một yếu tố xử lý tín hiệu được gọi là tế bào neuron Lippman và Lippman [8]. Mạng lưới bao gồm ít nhất ba lớp cấu trúc; cụ thể là lớp đầu vào, (các) lớp ẩn và lớp đầu ra. Lớp ẩn bao gồm một số tế bào neuron. Mỗi tế bào neuron tham gia các thông số đầu vào bằng các kết nối được gọi là trọng lượng và chức năng phụ trợ được gọi là thiên vị Burbidge và cộng sự [9].

Nghiên cứu hiện tại tập trung vào việc xác định bộ số liệu áp suất đáy giếng bằng cách sử dụng Mạng neuron nhân tạo. Các bộ dữ liệu khác nhau xem xét số lượng tế bào neuron đào tạo khác nhau đã được đề xuất để tìm ra các thông số đầu vào hiệu quả nhất. Các bộ dữ liệu này được tách thành các bộ đào tạo, xác nhận chéo và thử nghiệm theo tỷ lệ 3: 1: 1. Tập hợp con thử nghiệm của dữ liệu đã được sử dụng để kiểm tra độ chính xác dự đoán của mô hình và so sánh nó với các mối tương quan hiện có và các mô hình cơ học không được phát hiện bởi mô hình ANN trong giai đoạn đào tạo. Các mạng chuyển tiếp nguồn cấp dữ liệu nhiều lớp đã được chọn cho mô hình ANN được tạo vì khả năng thể hiện các bản đồ chức năng phi tuyến tính giữa đầu vào và đầu ra. Một lớp đầu vào (chứa chín tế bào thần kinh đầu vào hoặc nút) đại diện cho các thông số đầu vào (tốc độ dòng chảy dầu, tốc độ lưu lượng khí, tỷ lệ khí-dầu, áp suất đầu giếng, nhiệt độ đầu giếng, nhiệt độ đáy giếng), hai lớp ẩn và một lớp đầu ra (chứa một nút) đại diện cho máy ép lỗ dưới.

2. Phương pháp luận


2.1. Mạng lưới thần kinh nhân tạo

Ann được tạo thành từ ba lớp: đầu vào, đầu ra và các lớp ẩn. Dữ liệu đầu vào của hệ thống được đọc từ một nguồn bên ngoài vào một loạt các biến trong lớp đầu vào. Theo cách tương tự, lớp đầu ra lưu trữ dữ liệu hoặc kết quả dự kiến, có thể là một số vectơ. Lớp đầu vào nhận dữ liệu lúc đầu và gửi nó đến lớp ẩn đầu tiên để xử lý. Như minh họa trong Hình 1, dữ liệu được xử lý từ lớp ẩn đầu tiên được chuyển sang các lớp ẩn tiếp theo để xử lý [10]. Cuối cùng, lớp đầu ra lấy dữ liệu từ lớp được che giấu cuối cùng và đưa nó đến một nguồn bên ngoài. Không có mối liên hệ trực tiếp giữa các lớp ẩn và thế giới bên ngoài, và toàn bộ quy trình xử lý được che giấu khỏi chúng ta (Hình 2).



Hình 1. Đầu vào, đầu ra, lớp ẩn ANN [10].

Việc thu thập dữ liệu, chuẩn bị dữ liệu, xây dựng mạng lưới, mạng đào tạo và mạng thử nghiệm là năm quy trình trong quy trình mô hình hóa ANN. Giai đoạn đầu trong việc tạo ra các mô hình ANN là thu thập và chuẩn bị dữ liệu mẫu. Các phương pháp chuẩn bị dữ liệu được thực hiện sau khi thu thập dữ liệu để đào tạo ANN hiệu quả hơn.



Hình 2. ANN với các lớp dữ liệu đầu vào và đầu ra.

Trước khi trình bày dữ liệu đầu vào cho mạng, nói chung là một thực hành tốt để thực hiện bình thường hóa dữ liệu, bởi vì trộn các biến với cường độ lớn và nhỏ sẽ nhầm lẫn thuật toán học tập về bản chất của từng biến và có thể buộc nó đến nhà thiết kế chỉ định số lớp ẩn, tế bào thần kinh trong mỗi lớp, chức năng truyền trong mỗi lớp, chức năng đào tạo, chức năng học tập trọng lượng / thiên vị và chức năng thực hiện.

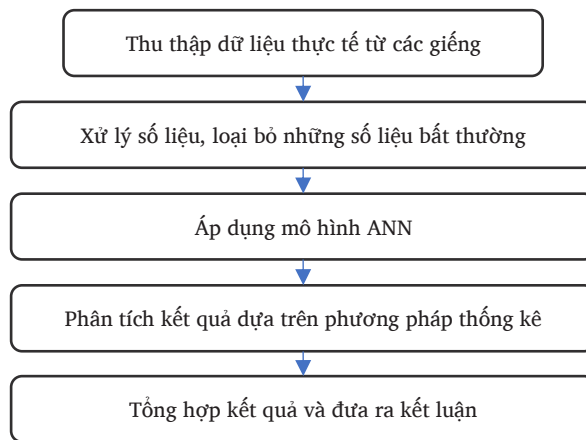
Trong giai đoạn đào tạo, trọng lượng được sửa đổi để đưa đầu ra thực tế (dự đoán) của mạng gần hơn với đầu ra mục tiêu (đo lường). Giai đoạn tiếp theo là đưa mô hình được xây dựng vào thử nghiệm. Tại thời điểm này, mô hình được tiếp xúc với dữ liệu chưa biết trước đây.

2.2 Quy trình tiến hành

Hình 3 hiển thị quy trình làm việc chung để xác định áp suất đáy giếng bằng cách sử dụng các mô hình ANN. Quy trình được tiến hành từ bước thu thập dữ liệu từ các giếng đến việc đưa ra những kết luận cho toàn bộ nghiên cứu.

Dữ liệu được sử dụng trong nghiên cứu này được thu thập từ giếng X tại mỏ Hải Thạch- Mộc Tinh, tổng cộng 1568 bộ dữ liệu, ban đầu. Dữ liệu được sử dụng để phát triển mô hình bao gồm tốc độ dầu lên tới 44M mscf/ngày từ năm 2015 đến năm 2019. Ngoài ra, các bộ dữ liệu đã được xử lý trước để loại trừ dữ liệu sai lệch như các giá trị âm của áp suất và lưu lượng. Số lượng dữ liệu sau đó đã giảm xuống còn 350. Dữ liệu được chia thành ba phần, 75 % điểm dữ liệu được sử dụng để đào tạo các mạng, 15 % điểm dữ liệu được sử dụng để xác thực và 15% điểm dữ liệu được xem xét để kiểm tra mạng được đào tạo. Sau các bước xử lý trước, dữ liệu đã được thay đổi để phù hợp với các biểu mẫu đầu vào trong mạng ANN. Dữ liệu đầu vào bao gồm 7 tính năng là tốc độ dòng chảy dầu, tốc độ dòng khí, tỷ lệ khí-dầu, áp suất đầu giếng, nhiệt độ đầu giếng, áp suất lỗ đáy, nhiệt độ lỗ đáy. Bảng 1 hiển thị các biến ANN và đơn vị của chúng. Số lượng tế bào thần kinh được đào tạo đã được thay đổi để xem xét ảnh hưởng của số lượng tế bào thần kinh được đào tạo khác nhau đối với áp suất được tính toán và đạt được kết quả hiệu quả nhất. Sau quá trình đào tạo, lỗi được tính toán giữa áp suất lỗ dưới xác định và áp suất đo để xác định độ chính xác của mạng. Phân tích thống kê các tế bào thần kinh đào tạo khác nhau bằng cách so sánh dữ liệu ước tính so với dữ liệu thực tế đã được hiển thị. Bắt đầu từ việc thu thập dữ liệu sản xuất lịch sử đến phân tích

kết quả được tính toán bởi các mô hình ANN so với dữ liệu đo lường thực tế, các kết luận được đưa ra.



Hình 3. Quy trình chung được áp dụng trong công việc này.

Bảng 1. Hình minh họa một số dữ liệu đầu vào.

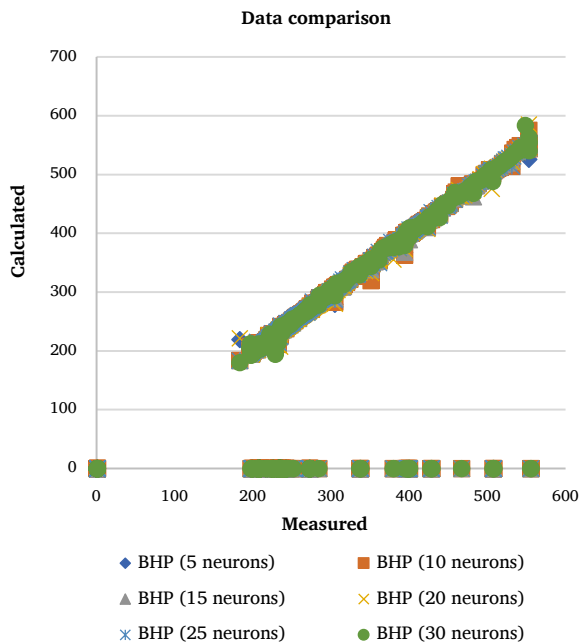
Features	Unit	1	2	3	4	5
Oil Flow Rate	m ³ /day	668,0646346	441,0308	393,6526	64,38986	144,6784
Gas Flow Rate	Km ³ /day	1248,772935	821,1886	733,4063	113,2674	263,3467
Gas-Oil Ratio		1869,239697	1861,976	1863,08	1759,087	1820,221
Wellhead Pressure	Bara	441,8849941	449,814	450,7792	455,3987	450,9861
Wellhead Temperature	°C	85	84	77	57	51
Bottomhole Temperature		137	137	137	133	132
Bottomhole Pressure	Bara	553,1664	552,5458	553,718	553,3043	545,0995

3. Kết quả và thảo luận

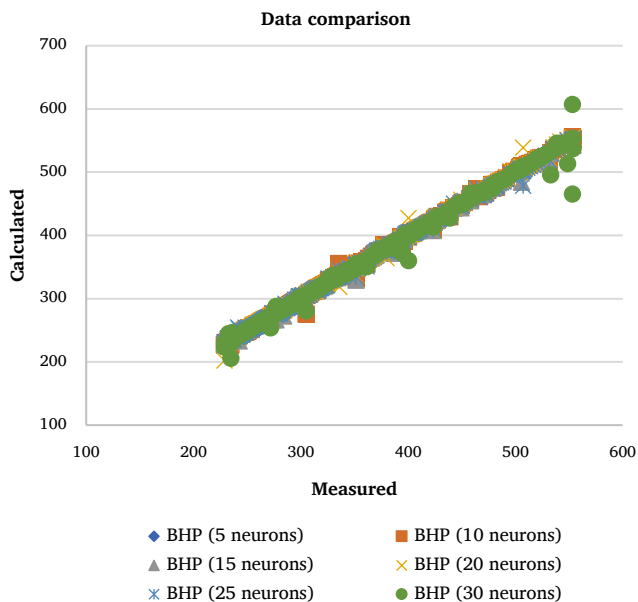
Sau quá trình tiền xử lý và loại bỏ những số liệu nhiễu trong bộ dữ liệu ban đầu, ba bộ dữ liệu khác nhau đã được sử dụng làm dữ liệu để luyện mạng neuron với mô hình Neural Net Fitting với số neuron lần lượt từ 5 đến 30 (với mỗi lần thay đổi 5 đơn vị). Để chứng minh tính chính xác của các mô hình dự đoán, kết quả của quá trình tính toán được so sánh với áp suất đo được tại hiện trường. Các thông số thống kê như Sai số toàn phương trung bình (MSE), Hiệu phương sai (C), Hệ số tương quan (R), Hệ số góc và Hệ số tự do của phương trình tương quan đã được sử dụng để so sánh.

Từ Hình 4 dưới đây, áp suất dòng chảy ở đáy giếng dự đoán thu được so với các giá trị đo được có sai số lớn nhất, các số liệu nhiễu khác nhau từ các bộ dữ liệu ban đầu là nguyên nhân chính dẫn đến hệ quả này. Do đó, áp suất đáy giếng được tính toán không nằm trong đường xu hướng 45 ° được vẽ giữa dữ liệu ước tính và thực tế. Để cải thiện độ chính xác, các bộ dữ liệu ban đầu được lọc để loại bỏ những dữ liệu nhiễu của lưu lượng dòng khí và lưu lượng condensate, vì vậy tổng số bộ số liệu giảm xuống còn 350 dữ liệu. Quá trình luyện mạng ANN được lặp lại cho bộ số liệu sau khi sà lọc, kết quả hiển thị trong Hình 5. Áp suất đáy giếng nhiễu đã được loại bỏ khỏi bộ dữ liệu thứ hai, do đó những áp suất tính được bằng 0 không còn tồn tại và

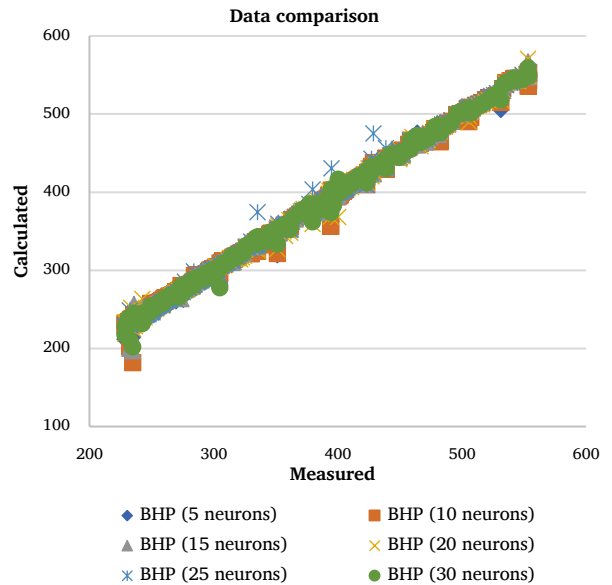
kết quả cho thấy mức độ sai số được cải thiện đáng kể (Hình 5). Tiếp tục loại bỏ những số liệu áp suất đáy giếng nhiễu trong bộ dữ liệu thứ 2, bộ số liệu mới được nhập vào ANN để luyện mạng lần nữa với cùng những số neuron như lần trước. Hình 6 cho thấy kết quả được cải thiện đáng kể, kết quả chính xác hơn so với các bộ dữ liệu được thử nghiệm trước đó cho áp suất trên 500 bara.



Hình 4. Sự tương quan giữa áp suất được tính toán bằng ANN và áp suất đo được ở đáy giếng cho các bộ dữ liệu ban đầu.



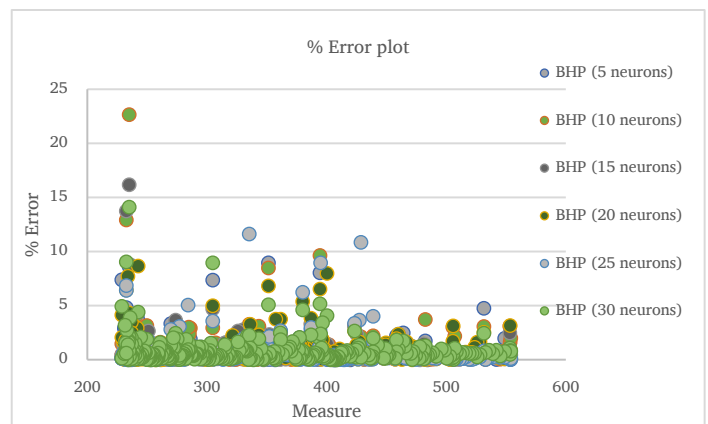
Hình 5. Sự tương quan giữa áp suất được tính toán bằng ANN và áp suất đo được ở đáy giếng cho các dữ liệu được xử lý trước.



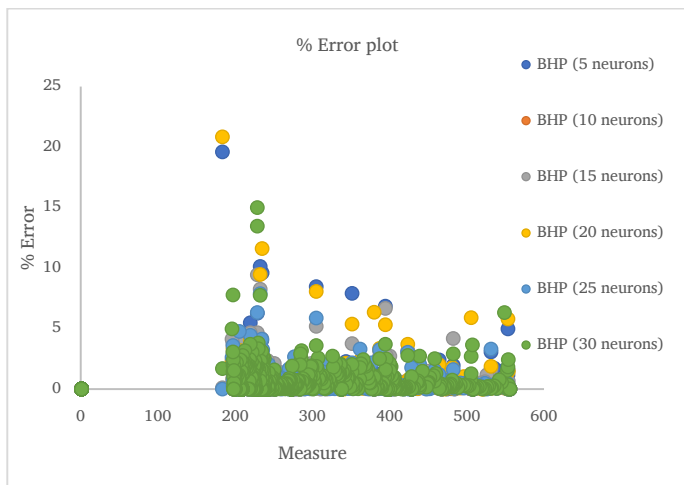
Hình 6. Sự tương quan giữa áp suất được tính toán bằng ANN và áp suất đo được ở đáy giếng cho các dữ liệu thứ ba.

Đa phần sai số lớn nằm trong khoảng áp suất bé hơn 300 bara (Hình 7-9). Nguyên nhân chính dẫn đến sai số lớn có thể do sự mất ổn định của áp suất đáy giếng trong quá trình gần đóng giếng.


Hệ số tương quan giữa các giá trị thực tế và dự đoán vượt quá 0,99 cho tất cả các bộ dữ liệu. Ngoài ra, kết quả chính xác phụ thuộc vừa phải vào số lượng tế bào neuron. Đối với bộ dữ liệu đầu tiên, hiệu suất của mô hình ANN với 25 tế bào neuron bị lu mờ so với quy trình luyện mạng bao gồm 5, 10, 15, 20, 30 tế bào neuron, trong khi các mô hình phát triển với 10 tế bào neuron và 15 tế bào neuron cho thấy lỗi tối thiểu cho bộ dữ liệu thứ hai và thứ ba. Những kết quả này cho thấy từ độ chính xác tổng thể của xu hướng chính xác hơn 98%. Tất cả các số liệu thống kê về hiệu suất mạng được minh họa trong Bảng 2.



Hình 7. Sai số của áp suất được tính toán bằng ANN và áp suất đo được ở đáy giếng cho các bộ dữ liệu được xử lý trước.



Hình 8: Sai số của áp suất được tính toán bằng ANN và áp suất đo được ở đáy giếng cho các bộ dữ liệu ban đầu.




Hình 9. Sai số của áp suất được tính toán bằng ANN và áp suất đo được ở đáy giếng cho các dữ liệu thứ ba.

Bảng 2. Một số hệ số thống kê của mạng ANN.


Number of Neurons		5	10	15	20	25	30
The first dataset	Covariance	7300,611	7331,409	7253,77	7376,389	7322,487	7313,558
	Correlation coefficient, R	0,998654	0,998611	0,99905	0,998776	0,999381	0,99866
	Slope	0,994901	0,999098	0,988518	1,005228	0,997882	0,996665
	Intercept	1,948462	0,572875	4,015943	-3,33806	0,849969	2,159248
The second dataset	Mean squared error, MSE	22,47081	11,92206	12,39136	17,70123	13,1822	55,03092
	Covariance	8283,395	8325,848	8288,026	8360,585	8265,47	8288,871
	Correlation coefficient, R	0,998673	0,999293	0,999282	0,998944	0,999272	0,996727
	Slope	0,991358	0,996439	0,991913	1,000596	0,989213	0,992014
The third dataset	Intercept	3,057974	0,967952	2,669196	-0,13475	3,214806	2,141015
	Mean squared error, MSE	22,25736	31,15542	17,3894	24,65324	25,27256	20,69198
	Covariance	8379,055	8294,319	8400,7	8382,974	8462,042	8396,786
	Correlation coefficient, R	0,998677	0,998201	0,998976	0,998572	0,998539	0,998771
Slope	0,996081	0,986007	0,998654	0,996546	1,005946	0,998188	
	Intercept	1,367434	4,946677	0,056886	0,393409	-1,86112	0,472897

Tuy nhiên, các sai số giữa những mạng ANN có số neuron khác nhau hầu như không đáng kể. Sai số chênh lệch chỉ trong khoảng 1%. Hình 10 – 13 biểu thị kết quả khi luyện mạng ANN tương ứng với số


neuron cho ít sai số nhất của từng trường hợp. Tóm lại, số neuron khi luyện mạng ANN không ảnh hưởng nhiều đến kết quả và trong một vài trường hợp, nếu cần độ chính xác tuyệt đối, phép thử thay đổi số neuron là cần thiết.




Hình 10. Sai số của mạng ANN bao gồm 5 neuron của các bộ dữ liệu ban đầu.



Hình 11. Sai số của mạng ANN bao gồm 25 của các bộ dữ liệu ban đầu.



Hình 12. Sai số của mạng ANN bao gồm 10 của các bộ dữ liệu được xử lý trước.



Hình 13. Sai số của mạng ANN bao gồm 15 của các bộ dữ liệu thứ ba.

4. Kết luận

Nghiên cứu này đã trình bày dự đoán áp suất lỗ dưới trong giếng dọc bằng cách sử dụng mô hình ANN kết hợp với phân tích dữ liệu để đạt được mô hình tối ưu. Hiệu quả của các mô hình ANN được xây dựng phụ thuộc vào các yếu tố khác nhau như dữ liệu đầu vào và đầu ra, một số đào tạo thần kinh. Đặc biệt, dữ liệu đầu vào được triển khai đóng một vai trò thiết yếu trong việc xây dựng các mô hình ANN. Do đó, dữ liệu ban đầu nên được áp dụng một số bộ lọc để phát hiện và loại bỏ các biến dự phòng để tối ưu hóa kết quả. Tổng cộng có 1568 bộ dữ liệu được sàng lọc để phát triển mô hình ANN. Để xác định mô hình nào là chính xác, tính toán hồi quy đã được sử dụng cho từng trường hợp. Kết quả đã chứng minh rằng mô hình ANN phát triển cho phép dự đoán áp suất lỗ dưới với sự phù hợp đáng kể với áp suất đo về hệ số tương quan là 0,99 và sai số bình phương trung bình tối thiểu. Mặc dù mô hình ANN có thể được sử dụng như là công cụ hiệu quả để dự đoán áp suất lỗ dưới, số lượng tế bào thần kinh cho mỗi trường hợp nên được xem xét cho kết quả tối ưu.

Lời cảm ơn

Nghiên cứu được tài trợ bởi Trường Đại học Bách khoa – ĐHQG-HCM trong khuôn khổ Đề tài mã số To-ĐCDK-2021-07.

Tài liệu tham khảo

[1]. T. H. Ahmed, "Reservoir engineering handbook", Elsevier, 2021.
 [2]. Osman, E. A., Mohammed A. A., and Mohammed A. A., "Artificial Neural Network Model for predicting bottom-hole flowing pressure in vertical multiphase flow" Society of Petroleum Engineers, 2005. Doi: <https://doi.org/10.2118/93632-MS>
 [3]. Mohammadpoor M, Shahbazi K, Torabi F, Firouz ARQ, "A new methodology for prediction of bottomhole flowing pressure in vertical multiphase flow in Iranian oil fields using artificial neural networks (ANNs)" Society of Petroleum Engineers SPE Latin American and

Caribbean Petroleum Engineering Conference, 1-3 December. DOI: <https://doi.org/10.2118/139147-MS>

[4]. Jahanandish, B. and Salimifard, H. J. , " Predicting Bottomhole Pressure in vertical multiphase flowing wells using artificial neural networks" Journal of Petroleum Science and Engineering, vol. 75, no. 3-4, pp. 336-342, 2011.
 [5]. Li, X., Miskimins, J., and Hoffman, B. T., "A combined bottom-hole pressure calculation procedure using multiphase correlations and artificial neural network models" SPE Annual Technical Conference and Exhibition, 2014. DOI: <https://doi.org/10.2118/170683-MS>
 [6]. Medhat, A., Hassan, Y, " Neural networks for flow bottom hole pressure prediction" Int. J. Energy a Clean Environ, pp. 1839-1856, 2016.
 [7]. Spesivtsev, P., Sinkov, K., Sofronov, I., Zimina, A., Umnov, A., Yarullin, R., Vetrov, D., "Predictive model for bottomhole pressure based on machine learning" Journal of Petroleum Science and Engineering, vol. 166, pp. 825-841, 2018.
 [8]. R. P. Lippmann, "An introduction to computing with Neural Nets", IEEE ASSP Magazine, pp. 4-22, 1987.
 [9]. R. Burbidge, M. Trotter, B. Buxton, S. Holden, "Drug design by machine learning: support vector machines for pharmaceutical data analysis" Computers & Chemistry, vol. 26, no. 1, pp. 5-14, 2001.
 [10]. Schalkoff, R, "Artificial Neural Networks" McGraw-Hill, pp. 62-92, 1997