

Mô hình hóa thuộc tính vỉa dầu khí với các thuộc tính địa chấn và mạng nơ-ron nhân tạo

Mai Cao Lân^{1,*}, Trương Khắc Hòa²



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

TÓM TẮT

Bài báo tập trung vào việc phân tích các thuộc tính địa chấn và ứng dụng thuật toán luyện mạng nơ-ron nhân tạo nhằm thiết lập mô hình tương thạch học để dựa vào đó xây dựng mô hình độ rỗng của vỉa dầu khí. Đầu tiên, dữ liệu thuộc tính địa chấn và dữ liệu log tương đá, log độ rỗng sẽ được mô hình hóa theo quy trình chuẩn trên Petrel (Schlumberger). Sau đó các mô hình này được trích xuất và sử dụng làm dữ liệu đầu vào cho các thuật toán luyện mạng có giám sát SOM, kết quả thu được một mô hình mạng thể hiện mối quan hệ giữa thuộc tính địa chấn và tương đá. Tiếp theo, mô hình mạng đó được sử dụng để xây dựng mô hình 3 chiều của tương đá. Bằng cách tương tự, mô hình độ rỗng 3 chiều được xây dựng bằng thuật toán luyện mạng Fitnet. Trong nghiên cứu này, các bước luyện mạng, xây dựng mô hình tương đá và mô hình độ rỗng được triển khai trên công cụ MATLAB và mô hình kết quả sau đó được so sánh với mô hình được xây dựng bằng phần mềm chuyên dụng Petrel. Sự tương đồng về dạng phân bố của độ rỗng giữa hai mô hình kết quả cho thấy nền tảng tính toán được sử dụng trong nghiên cứu này là tương tự với các giải thuật trong phần mềm Petrel. Bài báo góp phần làm rõ hơn nền tảng tính toán của phần mềm này vốn chưa được đi sâu tìm hiểu tại Việt Nam và từ đó giúp nâng cao hiệu quả sử dụng phần mềm trong việc mô hình hóa thuộc tính vỉa dầu khí.

Từ khoá: Mô hình thuộc tính vỉa, mô hình độ rỗng, mạng nơ-ron nhân tạo (ANN), bản đồ tự sắp xếp (SOM), thuộc tính địa chấn, mô hình tương đá

¹Khoa Kỹ thuật Địa chất & Dầu khí, Trường ĐH Bách khoa, ĐHQG-HCM, Việt Nam

²Trung tâm Kỹ thuật, Tổng Công ty Thăm dò & Khai thác Dầu khí (PVEP-ITC), Việt Nam

Liên hệ

Mai Cao Lân, Khoa Kỹ thuật Địa chất & Dầu khí, Trường ĐH Bách khoa, ĐHQG-HCM, Việt Nam

Email: maicaolan@hcmut.edu.vn

Lịch sử

- Ngày nhận: 31-12-2019
- Ngày chấp nhận: 24-9-2021
- Ngày đăng: 04-11-2021

DOI : 10.32508/stdjet.v4iS13.657



Bản quyền

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



GIỚI THIỆU

Các phương pháp truyền thống trong mô hình hoá thuộc tính vỉa chứa dầu khí đều dựa trên những giải thuật tính toán địa thống kê theo đó từ nguồn dữ liệu ban đầu hạn chế tại các giếng thăm dò (như tài liệu địa vật lý giếng khoan, mẫu lõi, v.v...), thông tin tại các vị trí không có mẫu trong khu vực lân cận với giếng có dữ liệu thăm dò sẽ được tạo ra thêm sau mỗi bước tính và thông tin mới tạo ra này sẽ được nhập chung với nguồn dữ liệu ban đầu để trở thành dữ liệu cho các bước tính toán kế tiếp. Quy trình tính toán tuần tự này sẽ được tiếp tục theo hướng ngày càng có nhiều vị trí trong khu vực khảo sát được bổ sung ngày càng nhiều thông tin hơn dựa vào nguồn dữ liệu “cứng” (hard data) ban đầu kết hợp với nguồn dữ liệu “mềm” (soft data) vừa được tạo ra ở các bước trước theo nguyên tắc xác suất có điều kiện (conditional probability). Dù đã được sử dụng rộng rãi trong thời gian qua, các phương pháp truyền thống luôn cho kết quả chứa đựng nhiều yếu tố không chắc chắn do dựa trên nền tảng xác suất thống kê.

Một hướng tiếp cận hiện đại đang dần phổ biến trong mô hình hóa thuộc tính vỉa chứa là đưa vào sử dụng nguồn dữ liệu “cứng” có sẵn từ tài liệu địa chấn trong

toàn khu vực khảo sát theo hướng phân tích và xây dựng mối quan hệ giữa các thuộc tính địa chấn với các thuộc tính vỉa chứa. Hướng tiếp cận này, một mặt giải quyết vấn đề nguồn dữ liệu ban đầu hạn chế đối với các phương pháp truyền thống (chỉ giới hạn ở các giếng thăm dò), mặt khác loại bỏ việc sử dụng dữ liệu “mềm” qua các tính toán trên nền tảng xác suất thống kê bằng cách kết hợp sử dụng mạng nơ-ron nhân tạo (Artificial Neural Network- ANN) với các thuật toán luyện mạng phù hợp.

ANN là mô hình xử lý thông tin được mô phỏng dựa trên hoạt động của hệ thống thần kinh của con người với một số lượng lớn các nơ-ron được gắn kết để xử lý thông tin. ANN giống như bộ não con người, được học bởi kinh nghiệm (thông qua huấn luyện), có khả năng lưu giữ những kinh nghiệm hiểu biết (tri thức) và sử dụng những tri thức đó trong việc dự đoán các dữ liệu chưa biết¹.

Kỹ thuật luyện mạng nơ-ron nhân tạo được chia thành 3 nhóm cơ bản: có giám sát (supervised); không giám sát (unsupervised); củng cố (reinforcement). Phương pháp luyện mạng không giám sát được sử dụng trong các bài toán phân nhóm dữ liệu. Phương pháp luyện mạng có giám sát được sử dụng trong các bài toán

Trích dẫn bài báo này: Lân M C, Hòa T K. **Mô hình hóa thuộc tính vỉa dầu khí với các thuộc tính địa chấn và mạng nơ-ron nhân tạo**. *Sci. Tech. Dev. J. - Eng. Tech.*; 4(S13):SI61-SI69.

hồi quy hoặc phân loại dữ liệu. Phương pháp cũng cổ được sử dụng trong các bài toán về tự động hoá². Trong lĩnh vực dầu khí, mạng nơ-ron nhân tạo đã được ứng dụng trong một số bài toán như phân loại tương đá³, phân nhóm tương địa chấn⁴, mô hình hoá vỉa ... Trong nghiên cứu này, kỹ thuật luyện mạng có giám sát với hai mô hình mạng nơ-ron nhân tạo được sử dụng để xây dựng mô hình tương đá và mô hình độ rỗng.

PHƯƠNG PHÁP

Trên cơ sở tận dụng nguồn thông tin có sẵn từ dữ liệu địa chấn trong khu vực khảo sát ở giai đoạn thăm dò cũng như chủ trương giảm thiểu mức độ không chắc chắn do các thuật toán địa thống kê của các phương pháp truyền thống, hướng tiếp cận mô hình hoá thuộc tính vỉa dầu khí với các thuộc tính địa chấn được triển khai qua 3 nhóm thao tác chính: (a) Phân tích và xử lý số liệu địa chấn; (b) xây dựng mô hình tương thạch học; và (c) xây dựng mô hình thuộc tính vỉa (trong nghiên cứu này là mô hình độ rỗng). Quy trình chi tiết các bước trong việc mô hình hoá thuộc tính vỉa dầu khí được trình bày ở Hình 1.

Phân tích dữ liệu địa chấn

Để phù hợp với mục tiêu xây dựng mô hình tương thạch học và mô hình độ rỗng, các thuộc tính địa chấn trích xuất từ khối địa chấn 3D gốc sẽ được lựa chọn theo mục đích sử dụng sao cho chúng có tương quan tốt nhất với đặc tính tương thạch học và độ rỗng của vỉa dầu khí.

Hiện tại, đã có hàng trăm thuộc tính địa chấn được giới thiệu và phân loại dựa vào mục đích sử dụng⁵. Trong các nhóm thuộc tính địa chấn ở Bảng 1, nhóm thuộc tính Instantaneous giúp hỗ trợ nhận dạng tương phản tương, độ rỗng tốt. Trong đó, **Instantaneous Frequency** và **Envelope** được ưu tiên chọn vì chúng có thể giúp nhận ra những biến đổi nhỏ về thạch học.

Khối địa chấn gốc (**Amplitude**) ban đầu được sử dụng để trích xuất các thuộc tính đã chọn trên và cũng được sử dụng trong quá trình phân tích bằng mạng nơ-ron nhân tạo.

Xử lý dữ liệu

Dữ liệu đầu vào bao gồm các khối thuộc tính địa chấn như Amplitude, Envelope, Instantaneous Frequency và log tương đá, log độ rỗng tại vị trí các giếng khoan X1, X2, X3 mô Y bốn trũng Malay-Thổ Chu được đưa vào mô hình cấu trúc đã được xây dựng trước đó, phù hợp với các vỉa cần được mô hình. Các khối thuộc tính được đưa vào mô hình khung bằng phương pháp

trung bình hóa mẫu (resampling), dữ liệu log được mô hình bằng phương pháp trung bình dữ liệu giếng khoan (well-log scale-up).

Đối với dữ liệu thuộc tính địa chấn, resampling chọn sử dụng một trong phương pháp trung bình (như trung bình số học – arithmetic, hình học – geometric, điều hoà – harmonic, căn bình phương tổng – RMS, ...) theo vùng để lấy giá trị thuộc tính địa chấn đưa vào mô hình⁶.

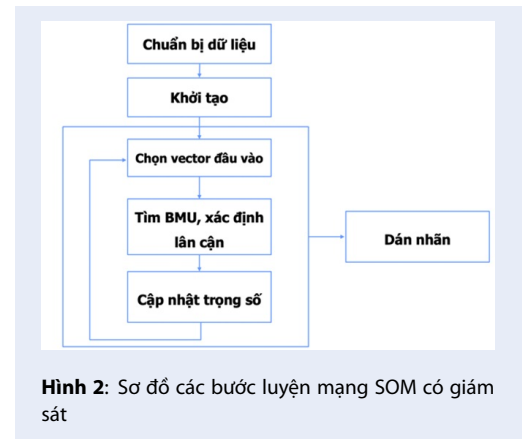
Đối với dữ liệu log giếng khoan, tương tự như resampling, phương pháp scale-up tính toán giá trị tại các ô mà giếng khoan đi qua theo một phương pháp tính trung bình được chọn, căn cứ vào các giá trị của log giếng khoan trong ô đó hoặc các ô lân cận⁷.

Trích xuất dữ liệu huấn luyện cho xây dựng mô hình tương

Từ mô hình log tương đá, trích xuất ra các vị trí các ô có dữ liệu cũng như dữ liệu trong các ô đó để sử dụng làm nhãn trong quá trình huấn luyện. Các mô hình thuộc tính địa chấn cũng được trích xuất để lấy dữ liệu tại các ô tương ứng với nhãn.

Khởi tạo và luyện mạng nơ-ron nhân tạo:

Trong khuôn khổ bài nghiên cứu này, mạng nơ-ron nhân tạo SOM (Self-Organizing Map) với thuật toán luyện mạng có giám sát⁸ được sử dụng để xây dựng mối quan hệ giữa thuộc tính địa chấn và tương thạch học.

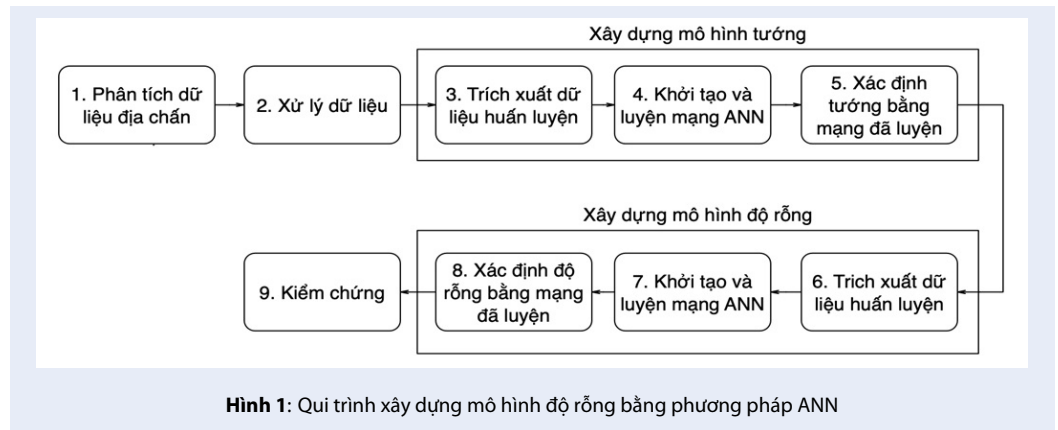


Hình 2: Sơ đồ các bước luyện mạng SOM có giám sát

Thuật toán luyện mạng có giám sát SOM được thực hiện theo các bước sau (Hình 2):

Bước 1: Chuẩn bị dữ liệu:

Dữ liệu đầu vào bao gồm dữ liệu huấn luyện và dữ liệu nhãn được ghép với nhau thành một bộ dữ liệu để huấn luyện mới. Dữ liệu nhãn được chuyển đổi thành dạng vector có số chiều bằng số loại dữ liệu cần



Bảng 1: Bảng phân loại các thuộc tính địa chấn⁵

Nhóm	Mục đích sử dụng
Instantaneous	Nhận dạng tương phản tương, độ rỗng, dấu hiệu trực tiếp của hydrocarbon, địa tầng, ...
Geometric	Giúp nhận dạng đứt gãy, cấu trúc, uốn nếp, bất đẳng hướng, nén ép,
Amplitude Accentuating	Xác định độ rỗng, địa tầng, biến đổi tương, dấu hiệu hydrocarbon
AVO	Giúp xác định chất lưu, tương đá, dấu hiệu hydrocarbon
Seismic Inversion	Tương đá, độ rỗng, hiệu ứng chất lưu
Spectral Decomposition	Độ dày vỉa, biến đổi địa tầng

được phân và đặt là 1 tại vị trí ứng với loại tương ứng, các vị trí còn lại đặt là 0 (ví dụ: cần phân thành 2 loại tương thạch học là cát, sét thì cát ứng với (1, 0), sét ứng với (0,1))

Bước 2: Khởi tạo mạng SOM:

Chọn SOM là một bản đồ vuông 2 chiều có số phần tử là $n \times n$. Mỗi phần tử là một vector có số chiều bằng với số chiều của vector đầu vào. Trọng số của mỗi vector đầu vào được khởi tạo bằng phương pháp ngẫu nhiên theo dữ liệu đầu vào.

Lưu ý vector đầu vào là dữ liệu đã được ghép nên có số chiều là số chiều của tập dữ liệu huấn luyện + số chiều của vector nhân.

Ngoài ra, cần chọn một số thông số cần thiết khác của SOM như vùng lân cận (neighborhood range), mức độ học (learning rate).

Bước 3: Chọn vector đầu vào:

Trong tập vector dữ liệu đầu vào, chọn ngẫu nhiên một vector để đưa vào huấn luyện.

Bước 4: Tìm BMU, xác định vùng lân cận:

BMU của vector đầu vào là một phần tử của SOM sao cho khoảng cách (Euclidean norm) từ nó tới vector đầu vào là nhỏ nhất.

Vùng lân cận để dùng để xác định các phần tử của SOM cần được cập nhật trọng số, đó là các phần tử có

khoảng cách (Euclidian) đến BMU nhỏ hơn $\frac{1}{2}$ độ dài lân cận. Sau mỗi bước cập nhật trọng số vùng lân cận sẽ được thu hẹp dần.

Bước 5: Cập nhật trọng số:

Trọng số của các phần tử lân cận BMU được cập nhật theo nguyên tắc dịch chuyển dần về phía vector đầu vào để tạo phân cụm, càng gần BMU thì mức độ dịch chuyển càng lớn và phụ thuộc vào mức độ học (learning rate). Mức độ học cũng như lân cận, được giảm dần về 0 sau mỗi bước cập nhật trọng số.

Bước 6: Lập lại bước 3 đến bước 5 một số lần là bội số của số phần tử trong tập huấn luyện. Số lần lập càng nhiều thì SOM càng được phân cụm tốt.

Bước 7: Dán nhãn:

Vector trọng số của mỗi phần tử SOM sau khi được huấn luyện được tách làm 2 phần, phần trọng số có số chiều bằng với số chiều của vector đầu vào ban đầu (khi chưa ghép với nhân) và phần nhân có số chiều bằng với số loại dữ liệu cần được phân (ví dụ: 2 loại tương cát và sét). Nhân của phần tử đó tùy vào vị trí của giá trị lớn nhất trong phần nhân theo cách chuyển đổi nhân ở **Bước 1**. Ví dụ: vị trí 1 tương ứng nhân là cát, vị trí 2 tương ứng với nhân là sét.

Như vậy, SOM sau khi huấn luyện có giám sát không những được phân cụm mà còn được đánh nhãn từng phần tử.

Xác định tương thích học bằng mạng đã luyện:

Từ tập dữ liệu bao gồm 3 khối thuộc tính ban đầu, sử dụng mạng SOM đã luyện để xác định BMU cho từng ô trong mô hình và lấy nhãn của BMU làm tương của ô đó. Xác định tương cho toàn mô hình ta thu được mô hình tương cần xây dựng.

Trích xuất dữ liệu huấn luyện cho xây dựng mô hình độ rỗng:

Tương tự như phương pháp trích xuất dữ liệu đối với xây dựng mô hình tương, khối mô hình độ rỗng ở vị trí các giếng khoan được trích những vị trí và giá trị tại các vị trí có dữ liệu để làm nhãn. 3 khối mô hình thuộc tính cùng với mô hình tương thích học thu được ở bước trên cũng được trích xuất các giá trị tương ứng với vị trí có giá trị trên mô hình độ rỗng log giếng khoan.

Khởi tạo và luyện mạng nơ-ron nhân tạo:

Đối với mô hình rỗng, dữ liệu nhãn có giá trị liên tục trong khoảng [0, 1] nên Fitnet – một mô hình mạng truyền thẳng (feed forward neural network)⁹ thường được sử dụng trong các bài toán hồi quy số liệu – phù hợp để xây dựng mô hình rỗng.



Hình 3: Sơ đồ các bước huấn luyện có giám sát mạng Fitnet

Việc khởi tạo và quá trình luyện mạng Fitnet được thực hiện như sơ đồ (Hình 3):

Bước 1: Chuẩn bị dữ liệu:

Dữ liệu huấn luyện và dữ liệu nhãn được tách thành 3 tập: tập huấn luyện (training set) được sử dụng để luyện mạng, tập kiểm chứng (validate set) được sử dụng để kiểm chứng mức độ chính xác của mạng trong quá trình huấn luyện và xác định thời điểm ngừng huấn luyện (khi sai số của mạng trên tập này tăng), tập kiểm tra (test set) được sử dụng để kiểm tra sai số của mạng sau khi được huấn luyện.

Bước 2: Khởi tạo:

Thiết lập các thông số cần thiết cho mạng như số phần tử trong lớp ẩn của mạng, phương pháp kiểm chứng, hàm luyện mạng.

Bước 3: Chọn vector đầu vào từ tập huấn luyện.

Bước 4: Tính toán đầu ra của mạng và so sánh với nhãn dữ liệu.

Bước 5: Cập nhật trọng số của các phần tử của mạng theo hàm huấn luyện theo nguyên tắc làm giảm sai số của đầu ra.

Bước 6: Tính toán sai số của mạng trên tập kiểm chứng, nếu sai số giảm so với bước huấn luyện trước đó thì quay lại Bước 3.

Kết thúc quá trình luyện mạng, ta thu được mạng ANN là mối quan hệ giữa dữ liệu đầu vào thuộc tính địa chấn và nhãn là độ rỗng.

Xác định độ rỗng bằng mô hình mạng đã luyện:

Dữ liệu 3 khối thuộc tính địa chấn và mô hình tương được chuyển đổi thành mô hình độ rỗng thông qua mạng Fitnet đã được huấn luyện.

Kiểm chứng:

Để kiểm chứng kết quả các mô hình xây dựng được bằng tính toán trên Matlab, các mô hình được chuyển đổi và đưa vào phần mềm Petrel để hiển thị. Ngoài ra, một mô hình tương và mô hình độ rỗng được xây dựng bằng mạng Neural Net của Petrel với cùng dữ liệu đầu vào để so sánh, đánh giá sự tương đồng với các mô hình xây dựng được trên Matlab.

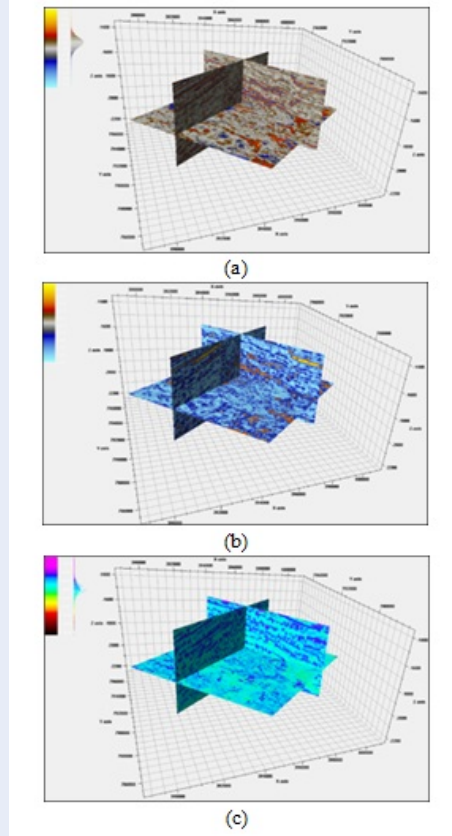
KẾT QUẢ

Phân tích tài liệu địa chấn:

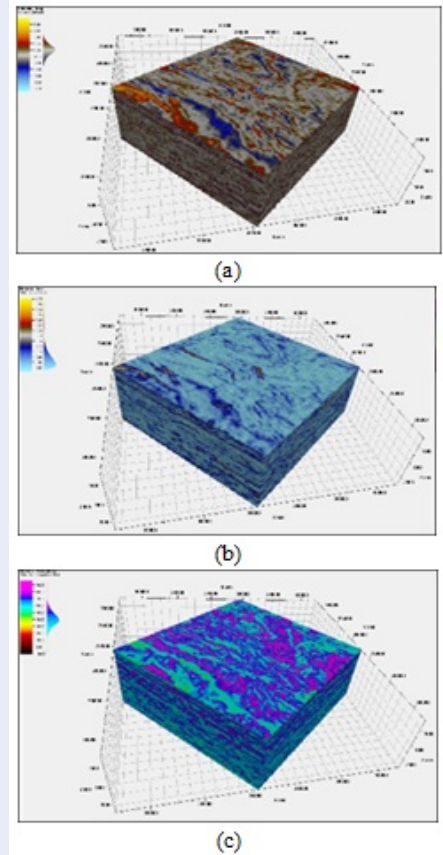
Tài liệu địa chấn 3D (Amplitude) được dùng để trích xuất 2 thuộc tính Envelope và Instantaneous Frequency, làm dữ liệu huấn luyện (Hình 4).

Xử lý dữ liệu

Dữ liệu sau khi được xử lý theo bước. 2.2 cho kết quả là 3 khối dữ liệu địa chấn (Hình 5) và dữ liệu log tương thích học và log độ rỗng tại các giếng khoan (Hình 6).



Hình 4: Các thuộc tính địa chấn sau khi được trích xuất (a)-Amplitude; (b)-Envelope; (c) Instantaneous Frequency



Hình 5: Các thuộc tính địa chấn sau khi được chuyển đổi (a)-Amplitude; (b)-Envelope; (c) Instantaneous Frequency

Trích xuất dữ liệu luyện mạng xây dựng mô hình tương:

Dữ liệu log tương được lọc trước để lấy các vị trí trong mô hình, sau đó dữ liệu các tương địa chấn được lọc theo các vị trí tìm được ở trên. Kết quả thu được bộ số liệu để luyện mạng (Hình 7).

Khởi tạo và luyện mạng

Do dữ liệu nhận tại vị trí các giếng khoan hạn chế (98 mẫu) nên nhiều mô hình mạng nơ-ron được xây dựng và mô hình được chọn sẽ có kết quả lỗi trên tập kiểm tra nhỏ nhất.

Dữ liệu trước khi được huấn luyện được tách ngẫu nhiên thành 2 tập: tập huấn luyện (training set), tập kiểm tra (test set) với tỉ lệ tương ứng 70:30. Kết quả đánh giá lỗi như Bảng 2.

Mô hình đầu tiên được lựa chọn vì lỗi trên tập kiểm tra là nhỏ nhất (13,33). Ngoài ra, lỗi trên toàn dữ liệu huấn luyện của mô hình cũng nhỏ nhất (4.08%).

Xác định tương thạch học bằng mạng đã luyện:

Sử dụng mạng nơ-ron đã luyện được, chuyển đổi dữ liệu đầu vào là 3 khối thuộc tính địa chấn thành mô hình tương thạch học (Hình 8).

Trích xuất dữ liệu luyện mạng xây dựng mô hình độ rỗng:

Tương tự như chuẩn bị dữ liệu xây dựng mô hình tương,

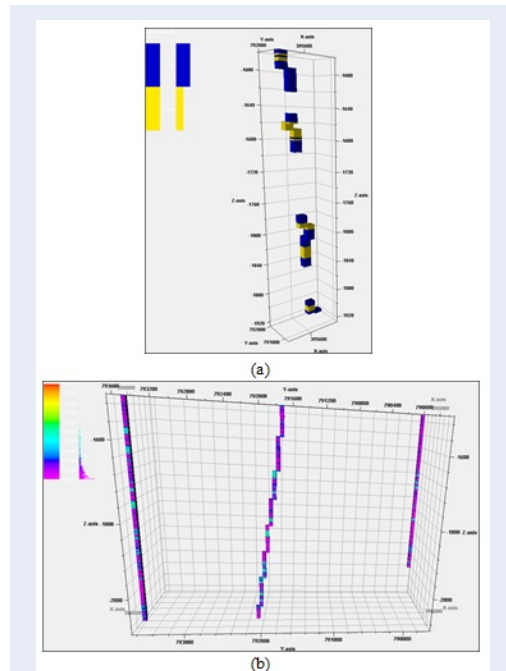
mô hình tương thạch học xây dựng bằng mạng SOM sẽ được sử dụng chung với ba mô hình thuộc tính địa chấn để làm dữ liệu đầu vào luyện mạng Fitnet (Hình 9).

Khởi tạo và luyện mạng

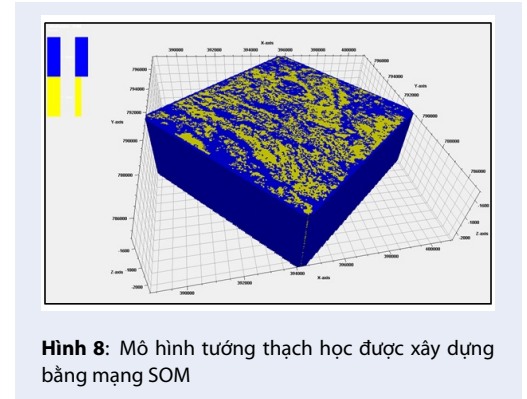
Kết quả đồ thị quá trình luyện mạng Fitnet như Hình 10 cho thấy quá trình huấn luyện dừng tại bước huấn luyện thứ 27 với sai số trung bình bình phương (MSE) trên tập kiểm chứng là **0.0049561**.

Bảng 2: Kết quả đánh giá lỗi sau luyện mạng SOM

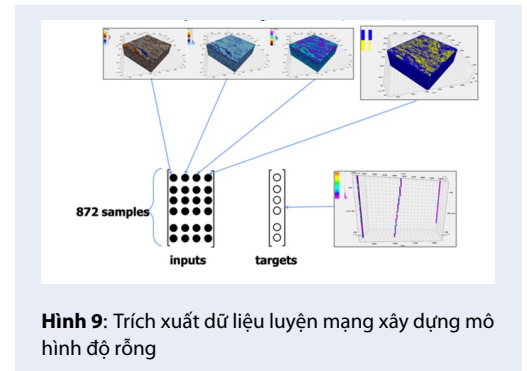
STT	Lỗi trên tập huấn luyện (%)	Lỗi trên tập kiểm tra (%)	Lỗi trên toàn dữ liệu huấn luyện (%)
1	0	13.33	4.08
2	0	26.67	8.16
3	0	33.33	10.20
4	0	36.67	11.22




Hình 6: Log giếng khoan sau khi được chuyển đổi (a)-Log tương thạch học tại 1 giếng khoan; (b)-Log độ rỗng tại 3 giếng khoan



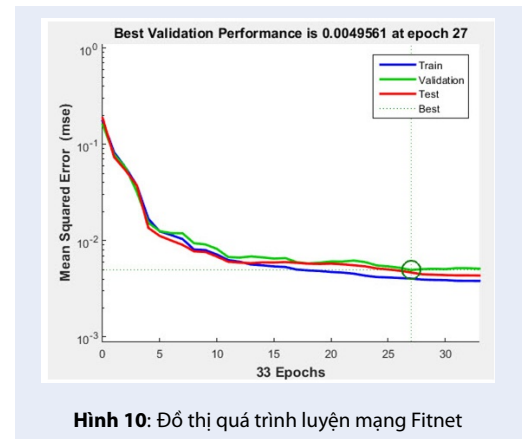
Hình 8: Mô hình tương thạch học được xây dựng bằng mạng SOM



Hình 9: Trích xuất dữ liệu luyện mạng xây dựng mô hình độ rỗng



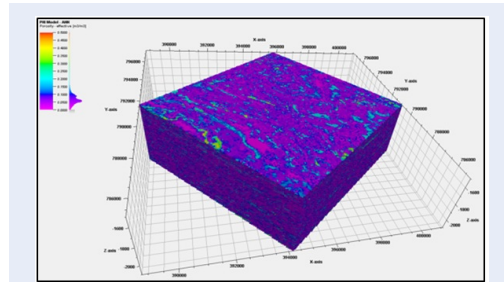
Hình 7: Trích xuất dữ liệu luyện mạng xây dựng mô hình tương



Hình 10: Đồ thị quá trình luyện mạng Fitnet

Xây dựng mô hình độ rỗng


Từ mạng Fitnet huấn luyện được ở trên, dữ liệu các khối mô hình thuộc tính địa chấn và mô hình tương được chuyển đổi thành mô hình độ rỗng (Hình 11).



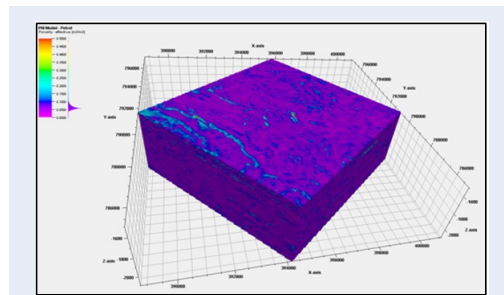
Hình 11: Mô hình độ rỗng được xây dựng bằng mạng Fitnet

Kiểm chứng

Sử dụng phương pháp Neural Net của phần mềm Petrel, với cùng dữ liệu đầu vào, chúng tôi đã xây dựng được mô hình tương (Hình 12) và mô hình độ rỗng (Hình 13).



Hình 12: Mô hình tương thạch học được xây dựng bằng Neural net trên Petrel



Hình 13: Mô hình độ rỗng được xây dựng bằng Neural net trên Petrel

Kết quả so sánh trên hình cho thấy phương pháp xây dựng mô hình bằng mạng nơ-ron nhân tạo cùng thuật toán huấn luyện khác nhau cho kết quả tương đương với phương pháp chuẩn xây dựng mô hình trên phần mềm Petrel.

KẾT LUẬN

Trong nghiên cứu này, qua khảo sát và phân tích chi tiết thuật toán luyện mạng có giám sát SOM, chúng tôi đã làm sáng tỏ được phương pháp tính toán của mô hình mạng này. Kết quả ứng dụng phương pháp này trong việc xây dựng mô hình tương thạch học và mô hình độ rỗng cho kết quả tương đương với kết quả trên phần mềm chuyên dụng Petrel của Schlumberger. Ngoài ra, kết quả nghiên cứu cũng cho thấy tính hiệu quả của hướng tiếp cận mô hình hoá thuộc tính vỉa bằng phân tích kết hợp dữ liệu địa chấn và dữ liệu địa vật lý giếng khoan. Mô hình kết quả nhờ vậy có độ tin cậy cao và giảm các yếu tố không chắc chắn. Dựa trên các kết quả đã đạt được từ nghiên cứu này, nhóm tác giả đã định hướng mở rộng khảo sát ứng dụng hệ phương pháp này cho các môi trường thành tạo khác nhau.

LỜI CẢM ƠN

Nhóm tác giả chân thành cảm ơn sự hỗ trợ của Trường Đại học Bách Khoa – Đại học Quốc gia Tp. HCM và Trung tâm Kỹ thuật thuộc Tổng Công ty Thăm dò & Khai thác Dầu khí trong suốt quá trình thực hiện nghiên cứu này.

DANH MỤC CÁC TỪ VIẾT TẮT

ANN: Artificial Neural Network - Mạng nơ-ron nhân tạo.

AVO: Amplitude Versus Offset hoặc Amplitude Variation with Offset - Nhóm thuộc tính chỉ ra sự phụ thuộc của biên độ địa chấn với khoảng cách giữa nguồn và máy thu.

BMU: Best Matching Unit - Vị trí trên SOM gần khớp nhất với vector dữ liệu đầu vào.

MSE: Mean Squared Error – Sai số trung bình bình phương.

SGS: Sequential Gaussian Simulation - Phương pháp địa thống kê thường được sử dụng trong xây dựng mô hình thuộc tính vỉa như độ rỗng, độ bão hoà nước.

SIS: Sequential Indicator Simulation - Phương pháp địa thống kê thường được sử dụng trong xây dựng mô hình thuộc tính vỉa như tương thạch học.

SOM: Self-Organizing Maps - Bản đồ tự tổ chức.

XUNG ĐỘT LỢI ÍCH

Nhóm tác giả cam đoan rằng không có bất kỳ xung đột lợi ích nào trong công bố bài báo.

ĐÓNG GÓP CỦA CÁC TÁC GIẢ

TS. Mai Cao Lân: Hướng dẫn khoa học, kiểm tra kết quả và hiệu chỉnh báo cáo.

ThS. Trương Khắc Hoà: Thực hiện nghiên cứu và viết báo cáo.

TÀI LIỆU THAM KHẢO

1. Bower BD, et al. The book of GENESIS - Exploring Realistic Neural Models with the GEneral NEural Simulation System. 2003;.
2. Nils N. Introduction to machine learning, San Francisco: Stanford University. 1996;.
3. Mai-Cao L, et al. A Self-Organizing Map, Machine Learning Approach to Lithofacies Classification. IJSSST. 2016;2016:16.
4. Roy MMKJA. Automatic Seismic Facies Classification with Kohonen Self. GEOHORIZONS. 2010;12.
5. Roden DSR. Seismic Interpretation with Machine Learning. GeoExpro. 2016;.
6. Armstrong T. Resampling of a 3D seismic data volume. trong 56th European Association of Geoscientists & Engineers Meeting, Vienna. 1994;Available from: <https://doi.org/10.3997/2214-4609.201409946>.
7. Christie M. Upscaling for Reservoir Simulation. Society of Petroleum Engineers. 1996;48(11). Available from: <https://doi.org/10.2118/37324-MS>.
8. Kohonen T. Self-Organizing Maps, The Third Edition, Springer. 2000;Available from: <https://doi.org/10.1007/978-3-642-56927-2>.
9. Haykin S. Feedforward neural networks: An introduction. 2004;.

Reservoir property modelling with seismic attributes and artificial neural network

Mai Cao Lan^{1,*}, Truong Khac Hoa²



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

ABSTRACT

This paper focuses on the analysis of seismic attributes and the application of training algorithms for artificial neural networks to build lithofacies model based on which porosity distribution across a reservoir is modeled. Firstly, seismic attribute and facies log, porosity log are modeled using the standard procedure of Petrel software (Schlumberger). After that, the resulting models are extracted and used as an input data for SOM-supervised algorithm. The result of this step is a map showing the relationship between seismic attributes and facies. In the next step, the map is used to build 3D facies model. With the same procedure, the 3D porosity model is built by Fitnet algorithm. In this work, ANN training, facies modeling and porosity modeling were implemented with MATLAB and the resulting models were compared to the ones that resulted from Petrel software. The good agreement in the porosity distribution patterns between the two models shows that the computational background used in this research is similar to that of Petrel software. The paper contributes to new insights into the fundamentals of computational algorithms used in Petrel which has not been thoroughly studied in Vietnam, and thus helps improve the software usage in reservoir properties modeling.

Key words: Reservoir properties model, Porosity model, Artificial Neural Network (ANN), Self-Organizing Map (SOM), Seismic Attribute, Facies Model

¹Faculty of Geology and Petroleum Engineering, HCM City University of Technology - VNU HCM, Vietnam

²Integrated Technical Center, PetroVietnam Exploration Production Corporation (PVEP-ITC, Vietnam)

Correspondence

Mai Cao Lan, Faculty of Geology and Petroleum Engineering, HCM City University of Technology - VNU HCM, Vietnam

Email: maicaolan@hcmut.edu.vn

History

- Received: 31-12-2021
- Accepted: 24-9-2021
- Published: 04-11-2021

DOI : 10.32508/stdjet.v4iS13.657



Copyright

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



Cite this article : Lan M C, Hoa T K. **Reservoir property modelling with seismic attributes and artificial neural network.** *Sci. Tech. Dev. J. – Engineering and Technology*; 4(S13):SI61-SI69.