



Research Article

Determination of petrophysical rock types and permeability using machine learning methods in a heterogeneous reservoir, southwest of the Iran

Fatemeh Bahrami¹, Iman Zahmatkesh^{1*}

1-Department of Petroleum Geology and Sedimentary Basins, Faculty of Earth Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran

Received: 17 May 2024 Accepted: 09 Aug 2025

Extended Abstract

Introduction

The study and evaluation of hydrocarbon reservoirs, as vital arteries for energy supply in today's world, are of paramount importance. Petroleum engineers and geologists are constantly striving to understand these complex subsurface systems more accurately and comprehensively. These efforts are particularly significant for carbonate reservoirs, due to their unique characteristics and specific challenges. Carbonate reservoirs, owing to complex diagenetic processes, inherent heterogeneities, and extensive fracture structures, are among the most intricate types of hydrocarbon reservoirs. These complexities make accurate evaluation of petrophysical properties and prediction of their production behavior a major challenge. In this context, identifying and determining petrophysical rock types and their characteristics, including porosity, permeability, fluid saturation, and pore size distribution, play a key role in understanding reservoir behavior and optimizing production processes. Rock types, as fundamental building blocks of the reservoir, exhibit relatively homogeneous petrophysical properties within a defined volume of rock. Identifying and differentiating these types enables more accurate reservoir modeling and prediction of its behavior under different production conditions. However, precise determination of rock types in carbonate reservoirs, due to the high diversity of textures, structures, and diagenetic processes, requires the use of advanced and integrated methods. Traditional reservoir evaluation methods rely primarily on core data and well log information. Core data provides valuable information about the physical and chemical properties of the reservoir rock, but its preparation and analysis are costly and time-consuming, and it is usually limited to a small number of wells in the oil field. Well log information provides broader coverage in the field, but its interpretation requires specialized knowledge and experience, and its accuracy may be affected by various factors. For this reason, the use of modern techniques such as machine learning and clustering has received increasing attention as a powerful tool for analyzing reservoir data and extracting valuable information from it.

In this study, with the aim of overcoming the limitations of traditional methods and improving the accuracy of carbonate reservoir evaluation, self-organizing maps (SOM) have been used to cluster well log data and identify electrofacies. Using unsupervised learning algorithms, this method is able to identify hidden patterns in the data and classify similar data into separate groups. Electrofacies, as distinct petrophysical units in the reservoir, exhibit relatively uniform log characteristics and can be considered as representatives of rock types. By matching the identified electrofacies with core data and geological information, a more accurate model of the distribution of rock types in the reservoir can be created and its petrophysical properties can be estimated with greater precision. The ultimate goal of this study is to provide an efficient and reliable method for evaluating carbonate reservoirs using machine learning techniques and improving the accuracy of predicting their production behavior.

Citation: Bahrami, F. and Zahmatkesh, I., 2025. Determination of petrophysical rock types and permeability using machine learning methods, *Res. Earth. Sci.* 16(3), (149-167) DOI: 10.48308/esrj.2025.232122.1181

* Corresponding author E-mail address: i.zahmatkesh@scu.ac.ir



Materials and Methods

In this study, an integrated approach comprising machine learning-based clustering methods and artificial neural networks was employed to determine petrophysical rock types and estimate permeability in the Bangestan reservoir, located in southwestern Iran. This approach, utilizing well log data and core information, enables more accurate and efficient identification of reservoir characteristics.

The dataset used in this research includes information from nine wells in the Ahvaz oil field. Among these, five wells have core data (including porosity and permeability information) and have been used as reference wells for training and validating the models. The well logs used in this study include density (RHOB), neutron (NPHI), effective porosity (PHIE), sonic transit time (DT), and gamma (GR) logs. These logs, due to their wide coverage and sensitivity to petrophysical changes, have been selected as the main inputs for clustering and permeability estimation algorithms.

To determine petrophysical rock types, the Self-Organizing Maps (SOM) clustering method was used. This method, using an unsupervised learning algorithm, is able to classify similar data into separate groups. In this study, well log data from reference wells were input into the SOM network, and after training the network, the data were divided into 25 initial clusters. Then, by analyzing the petrophysical characteristics of each cluster and matching them with core information and hydraulic flow units, similar clusters were merged and, finally, five distinct petrophysical rock types were identified.

Hydraulic flow units, as a criterion for evaluating reservoir quality, were determined using the logarithm of the flow zone indicator (Log FZI) method. This method, using core porosity and permeability data, enables the separation of flow units with different hydraulic characteristics. Matching the identified electrofacies with hydraulic flow units, as a validation method, helped ensure the accuracy and precision of the clustering. To estimate permeability in the studied reservoir, artificial neural networks (ANN) were used. This method, using a supervised learning algorithm, is able to learn the relationship between input data (well logs) and output data (core permeability) and, based on that, estimate permeability in other parts of the reservoir. In this study, a multi-layer perceptron neural network with a hidden layer was used. The reference well data were divided into training and testing sets. The training set was used to train the network and adjust its weights, and the testing set was used to evaluate the network's performance and determine the accuracy of permeability estimation.

Permeability was estimated in two separate ways: 1) permeability estimation for the entire reservoir interval regardless of rock types, and 2) permeability estimation for each of the identified rock types separately. Comparing the results of these two methods allows for evaluating the impact of data clustering on the accuracy of permeability estimation.

To evaluate the performance of the clustering and permeability estimation models, various statistical measures were used. To evaluate clustering accuracy, the Silhouette index was used, and to evaluate permeability estimation accuracy, the correlation coefficient (R) and root mean squared error (RMSE) measures were used. These measures enable comparison of the performance of different models and determination of the best model for permeability estimation in the studied reservoir.

Results and Discussion

In this study, we successfully identified five distinct petrophysical rock types in the Bangestan reservoir using machine learning methods. These rock types were accurately determined using the SOM clustering algorithm and matching with core data and hydraulic flow units. The clustering results showed that each of these rock types has unique petrophysical characteristics that affect fluid flow behavior in the reservoir. Rock types 1 and 2 had the best reservoir quality, rock type 3 had the medium reservoir quality and rock types 4 and 5 had the lowest reservoir quality.

Matching the identified electrofacies with hydraulic flow units (FZI) showed a high correlation between the two. This correlation indicates that the SOM clustering method was well able to separate flow units with different hydraulic characteristics.

The results of permeability estimation using artificial neural networks (ANN) showed that this method is able to estimate permeability with acceptable accuracy. Comparison of permeability estimation results with core data showed that the correlation coefficient (R) between the estimated values and the actual values is around 0.9804. Also, the root mean square error (RMSE) is around 0.0778.

Comparing the results of permeability estimation for the entire reservoir interval with the results of permeability estimation for each of the rock types separately showed that data clustering has a positive effect on the accuracy of permeability estimation. In other words, permeability estimation for each of the rock types separately has higher accuracy than permeability estimation for the entire reservoir interval. This result

shows that considering the petrophysical characteristics of each of the rock types can help improve the accuracy of permeability estimation models.

The results of this study show that the use of machine learning methods can help improve the accuracy and efficiency of carbonate reservoir evaluation. The SOM clustering method, as a powerful tool for identifying petrophysical rock types, enables more accurate reservoir modeling and prediction of its production behavior. Also, artificial neural networks (ANN), as an efficient method for estimating permeability, enable quantitative evaluation of reservoir characteristics and optimization of production processes.

However, it should be noted that the results of this study are limited to the Bangestan reservoir in the Ahvaz oil field and may not be generalizable to other carbonate reservoirs. To generalize the results of this study to other reservoirs, more studies and examination of data related to those reservoirs are needed.


Conclusion

In this study, an integrated machine learning-based approach was presented for identifying petrophysical rock types and estimating permeability in the Bangestan carbonate reservoir. Using the SOM clustering algorithm, five distinct rock types were identified, each with unique petrophysical characteristics and flow behaviors. ANN models, trained separately for each rock type, were able to estimate permeability with acceptable accuracy. The results showed that data clustering and considering the petrophysical characteristics of each rock type significantly improved the accuracy of permeability estimation. This approach can be used as an efficient tool for evaluating carbonate reservoirs and optimizing production processes.

This study significantly enhances our understanding of the Bangestan reservoir characteristics and can serve as a foundation for developing more advanced models in hydrocarbon reservoir evaluation. The findings of this research may also contribute to optimizing production processes and managing oil resources, paving the way for future studies in this field.

Keywords: Electrofacies, Neural network, Bangestan reservoir, Clustering, Hydraulic flow unit, Self-organizing map.

تعیین گونه‌های سنگی پتروفیزیکی و تراوایی با استفاده از روش‌های یادگیری ماشین در یک مخزن ناهمگن، جنوب غرب ایران

فاطمه بهرامی^۱، ایمان زحمت‌کش^{۱*} 

۱- گروه زمین‌شناسی نفت و حوضه‌های رسوبی، دانشکده علوم زمین، دانشگاه شهید چمران اهواز، اهواز، ایران

(پژوهشی) دریافت مقاله: ۱۴۰۳/۰۲/۲۸ پذیرش نهایی مقاله: ۱۴۰۴/۰۵/۱۸

چکیده گسترده

مقدمه

مطالعه و ارزیابی مخازن هیدروکربنی، به عنوان شریان‌های حیاتی تأمین انرژی در دنیای امروز، از اهمیت بسزایی برخوردار است. مهندسان و زمین‌شناسان نفت همواره در تلاش برای درک دقیق‌تر و جامع‌تر این سیستم‌های پیچیده زیرزمینی بوده‌اند. این تلاش‌ها به‌ویژه در مورد مخازن کربناته، به دلیل ویژگی‌های منحصر به فرد و چالش‌های خاص آن‌ها، از اهمیت دوچندانی برخوردار است. مخازن کربناته، به دلیل فرآیندهای پیچیده دیاژنتیک، ناهمگنی‌های ذاتی و ساختارهای شکستگی گسترده، از پیچیده‌ترین انواع مخازن هیدروکربنی به شمار می‌روند. این پیچیدگی‌ها، ارزیابی دقیق خواص پتروفیزیکی و پیش‌بینی رفتار تولیدی آن‌ها را به یک چالش بزرگ تبدیل می‌کند. در این راستا، شناسایی و تعیین گونه‌های سنگی پتروفیزیکی (Petrophysical Rock Types) و ویژگی‌های آن‌ها از جمله تخلخل، تراوایی، اشباع سیالات و توزیع اندازه حفرات، نقشی کلیدی در درک رفتار مخزن و بهینه‌سازی فرآیندهای تولید ایفا می‌کند. گونه‌های سنگی، به عنوان واحدهای بنیادی سازنده مخزن، ویژگی‌های پتروفیزیکی نسبتاً همگنی را در یک حجم مشخص از سنگ نشان می‌دهند. شناسایی و تفکیک این گونه‌ها، امکان مدل‌سازی دقیق‌تر مخزن و پیش‌بینی رفتار آن در شرایط مختلف تولید را فراهم می‌سازد. با این حال، تعیین دقیق گونه‌های سنگی در مخازن کربناته، به دلیل تنوع بالای بافت‌ها، ساختارها و فرآیندهای دیاژنتیک، نیازمند استفاده از روش‌های پیشرفته و یکپارچه است. روش‌های سنتی ارزیابی مخازن، عمدتاً بر داده‌های مغزه و اطلاعات چاه‌پیمایی تکیه دارند. داده‌های مغزه، اطلاعات ارزشمندی در مورد خواص فیزیکی و شیمیایی سنگ مخزن ارائه می‌دهند، اما تهیه و تحلیل آن‌ها پرهزینه و زمان‌بر است و معمولاً محدود به تعداد کمی از چاه‌ها در میدان نفتی می‌باشد. اطلاعات چاه‌پیمایی، پوشش گسترده‌تری را در میدان فراهم می‌کنند، اما تفسیر آن‌ها نیازمند دانش و تجربه تخصصی است و دقت آن‌ها ممکن است تحت تأثیر عوامل مختلفی قرار گیرد. به همین دلیل، استفاده از تکنیک‌های نوین مانند یادگیری ماشین و خوشه‌بندی، به عنوان ابزاری قدرتمند برای تحلیل داده‌های مخزنی و استخراج اطلاعات ارزشمند از آن‌ها، مورد توجه روزافزون قرار گرفته است. در این مطالعه، با هدف غلبه بر محدودیت‌های روش‌های سنتی و بهبود دقت ارزیابی مخازن کربناته، از شبکه‌های عصبی خودسازمانده (Self-Organizing Maps) برای خوشه‌بندی داده‌های چاه‌پیمایی و شناسایی الکتروفاسیس‌ها استفاده شده است. این روش، با استفاده از الگوریتم‌های یادگیری بدون نظارت، قادر است الگوهای نهفته در داده‌ها را شناسایی کرده و داده‌های مشابه را در گروه‌های مجزا دسته‌بندی کند.

استناد: بهرامی، ف. و زحمت‌کش، ا.، ۱۴۰۴. تعیین گونه‌های سنگی پتروفیزیکی و تراوایی با استفاده از روش‌های یادگیری ماشین،

پژوهشهای دانش زمین: ۱۶ (۳)، (۱۶۷-۱۴۹)، ۱۱۸۱. DOI: 10.48308/esrj.2025.232122.1181

E-mail: i.zahmatkesh@scu.ac.ir

* نویسنده مسئول:



الکتروفاسیس‌ها، به عنوان واحدهای پتروفیزیکی متمایز در مخزن، ویژگی‌های لاگ نسبتاً یکسانی را نشان می‌دهند و می‌توانند به عنوان نماینده‌ای از گونه‌های سنگی در نظر گرفته شوند. با تطبیق الکتروفاسیس‌های شناسایی شده با داده‌های مغزه و اطلاعات زمین‌شناسی، می‌توان مدل دقیق‌تری از توزیع گونه‌های سنگی در مخزن ایجاد کرد و خواص پتروفیزیکی آن را با دقت بیشتری تخمین زد. هدف نهایی این مطالعه، ارائه یک روش کارآمد و قابل اعتماد برای ارزیابی مخازن کربناته با استفاده از تکنیک‌های یادگیری ماشین و بهبود دقت پیش‌بینی رفتار تولیدی آن‌ها است.

مواد و روش‌ها

در این پژوهش، به منظور تعیین گونه‌های سنگی پتروفیزیکی و تخمین تراوایی در مخزن بنگستان، واقع در جنوب غرب ایران، از یک رویکرد یکپارچه شامل روش‌های خوشه‌بندی مبتنی بر یادگیری ماشین و شبکه‌های عصبی مصنوعی استفاده شده است. این رویکرد، با بهره‌گیری از داده‌های چاه‌پیمایی و اطلاعات مغزه، امکان شناسایی دقیق‌تر و کارآمدتر ویژگی‌های مخزن را فراهم می‌سازد. مجموعه داده‌های مورد استفاده در این تحقیق شامل اطلاعات نه حلقه چاه در میدان نفتی اهواز است. از این تعداد، پنج حلقه چاه دارای داده‌های مغزه (شامل اطلاعات تخلخل و تراوایی) بوده و به عنوان چاه‌های مرجع برای آموزش و اعتبارسنجی مدل‌ها مورد استفاده قرار گرفته‌اند. لاگ‌های چاه‌پیمایی مورد استفاده در این مطالعه شامل لاگ‌های چگالی (RHOB)، نوترون (NPHI)، تخلخل موثر (PHIE)، زمان عبور صوتی (DT)، و گاما (GR) می‌باشند. این لاگ‌ها، به دلیل پوشش گسترده و حساسیت به تغییرات پتروفیزیکی، به عنوان ورودی‌های اصلی برای الگوریتم‌های خوشه‌بندی و تخمین تراوایی انتخاب شده‌اند. به منظور تعیین گونه‌های سنگی پتروفیزیکی، از روش خوشه‌بندی شبکه‌های عصبی خودسازمانده (SOM) استفاده شده است. این روش، با استفاده از یک الگوریتم یادگیری بدون نظارت، قادر است داده‌های مشابه را در گروه‌های مجزا دسته‌بندی کند. در این مطالعه، داده‌های چاه‌پیمایی مربوط به چاه‌های مرجع به عنوان ورودی به شبکه SOM داده شده و پس از آموزش شبکه، داده‌ها به ۲۵ خوشه اولیه تقسیم شده‌اند. سپس، با تحلیل ویژگی‌های پتروفیزیکی هر خوشه و تطبیق آن‌ها با اطلاعات مغزه و واحدهای جریان هیدرولیکی (Hydraulic Flow Units)، خوشه‌های مشابه با یکدیگر ادغام شده و در نهایت، پنج گونه سنگی پتروفیزیکی متمایز شناسایی شده‌اند. واحدهای جریان هیدرولیکی، به عنوان معیاری برای ارزیابی کیفیت مخزن، با استفاده از روش لگاریتم شاخص زون جریان (Log FZI) تعیین شده‌اند. این روش، با استفاده از داده‌های تخلخل و تراوایی مغزه، امکان تفکیک واحدهای جریان با ویژگی‌های هیدرولیکی متفاوت را فراهم می‌سازد. تطبیق الکتروفاسیس‌های شناسایی شده با واحدهای جریان هیدرولیکی، به عنوان یک روش اعتبارسنجی، به اطمینان از صحت و دقت خوشه‌بندی کمک کرده است. به منظور تخمین تراوایی در مخزن مورد مطالعه، از شبکه‌های عصبی مصنوعی (ANN) استفاده شده است. این روش، با استفاده از یک الگوریتم یادگیری با نظارت، قادر است ارتباط بین داده‌های ورودی (لاگ‌های چاه‌پیمایی) و داده‌های خروجی (تراوایی مغزه) را یاد بگیرد و بر اساس آن، تراوایی را در سایر نقاط مخزن تخمین بزند. در این مطالعه، از یک شبکه عصبی پرسپترون چندلایه (Multi-Layer Perceptron) با یک لایه پنهان استفاده شده است. داده‌های چاه‌های مرجع به دو مجموعه آموزشی و آزمایشی تقسیم شده‌اند. مجموعه آموزشی برای آموزش شبکه و تنظیم وزن‌های آن استفاده شده و مجموعه آزمایشی برای ارزیابی عملکرد شبکه و تعیین دقت تخمین تراوایی مورد استفاده قرار گرفته است. تراوایی، به دو روش جداگانه تخمین زده شده است: (۱) تخمین تراوایی برای کل اینتروال مخزن بدون در نظر گرفتن گونه‌های سنگی، و (۲) تخمین تراوایی برای هر یک از گونه‌های سنگی شناسایی شده به صورت جداگانه. مقایسه نتایج این دو روش، امکان ارزیابی تأثیر خوشه‌بندی داده‌ها بر دقت تخمین تراوایی را فراهم می‌سازد. به منظور ارزیابی عملکرد مدل‌های خوشه‌بندی و تخمین تراوایی، از معیارهای آماری مختلفی استفاده شده است. برای ارزیابی دقت خوشه‌بندی، از شاخص Silhouette و برای ارزیابی دقت تخمین تراوایی، از معیارهای ضریب همبستگی (R) و مجذور میانگین مربعات خطا (RMSE) استفاده شده است. این معیارها، امکان مقایسه عملکرد مدل‌های مختلف و تعیین بهترین مدل برای تخمین تراوایی در مخزن مورد مطالعه را فراهم می‌سازند.

نتایج و بحث

در این پژوهش، با استفاده از روش‌های یادگیری ماشین، موفق به شناسایی پنج گونه سنگی پتروفیزیکی متمایز در مخزن بنگستان شدیم. این گونه‌های سنگی، با استفاده از الگوریتم خوشه‌بندی SOM و تطبیق با داده‌های مغزه و واحدهای جریان

هیدرولیکی، به دقت تعیین شدند. نتایج خوشه‌بندی نشان داد که هر یک از این گونه‌های سنگی، دارای ویژگی‌های پتروفیزیکی منحصر به فردی هستند که بر رفتار جریان سیال در مخزن تأثیرگذار است. گونه‌های سنگی ۱ و ۲ دارای بهترین کیفیت مخزنی، گونه‌سنگی ۳ کیفیت مخزنی متوسط و گونه‌های سنگی ۴ و ۵ دارای پایین‌ترین کیفیت مخزنی بودند. تطبیق الکتروفاسیس‌های شناسایی شده با واحدهای جریان هیدرولیکی (FZI) نشان داد که همبستگی بالایی بین این دو وجود دارد. این همبستگی، نشان می‌دهد که روش خوشه‌بندی SOM به خوبی قادر به تفکیک واحدهای جریانی با ویژگی‌های هیدرولیکی متفاوت بوده است. نتایج تخمین تراوایی با استفاده از شبکه‌های عصبی مصنوعی (ANN) نشان داد که این روش، قادر به تخمین تراوایی با دقت قابل قبولی است. مقایسه نتایج تخمین تراوایی با داده‌های مغزه نشان داد که ضریب همبستگی (R) بین مقادیر تخمین زده شده و مقادیر واقعی، در حدود ۰/۹۸ است. همچنین، مجذور میانگین مربعات خطا (RMSE) در حدود ۰/۰۷۷۸ است. مقایسه نتایج تخمین تراوایی برای کل اینتروال مخزن با نتایج تخمین تراوایی برای هر یک از گونه‌های سنگی به صورت جداگانه نشان داد که خوشه‌بندی داده‌ها، تأثیر مثبتی بر دقت تخمین تراوایی دارد. به عبارت دیگر، تخمین تراوایی برای هر یک از گونه‌های سنگی به صورت جداگانه، دقت بالاتری نسبت به تخمین تراوایی برای کل اینتروال مخزن دارد. این نتیجه، نشان می‌دهد که در نظر گرفتن ویژگی‌های پتروفیزیکی هر یک از گونه‌های سنگی، می‌تواند به بهبود دقت مدل‌های تخمین تراوایی کمک کند. نتایج این پژوهش، نشان می‌دهد که استفاده از روش‌های یادگیری ماشین، می‌تواند به بهبود دقت و کارایی ارزیابی مخازن کربناته کمک کند. روش خوشه‌بندی SOM، به عنوان یک ابزار قدرتمند برای شناسایی گونه‌های سنگی پتروفیزیکی، امکان مدل‌سازی دقیق‌تر مخزن و پیش‌بینی رفتار تولیدی آن را فراهم می‌سازد. همچنین، شبکه‌های عصبی مصنوعی (ANN)، به عنوان یک روش کارآمد برای تخمین تراوایی، امکان ارزیابی کمی ویژگی‌های مخزن و بهینه‌سازی فرآیندهای تولید را فراهم می‌سازد. با این حال، لازم به ذکر است که نتایج این پژوهش، محدود به مخزن بنگستان در میدان نفتی اهواز است و ممکن است قابل تعمیم به سایر مخازن کربناته نباشد. برای تعمیم نتایج این پژوهش به سایر مخازن، نیاز به انجام مطالعات بیشتر و بررسی داده‌های مربوط به آن مخازن است.

نتیجه‌گیری

در این پژوهش، یک رویکرد یکپارچه مبتنی بر یادگیری ماشین برای شناسایی گونه‌های سنگی پتروفیزیکی و تخمین تراوایی در مخزن کربناته بنگستان ارائه شد. با استفاده از الگوریتم خوشه‌بندی SOM، پنج گونه سنگی متمایز شناسایی شدند که هر کدام ویژگی‌های پتروفیزیکی و رفتارهای جریانی منحصر به فردی داشتند. مدل‌های ANN، با آموزش جداگانه برای هر گونه سنگی، توانستند تراوایی را با دقت قابل قبولی تخمین بزنند. نتایج نشان داد که خوشه‌بندی داده‌ها و در نظر گرفتن ویژگی‌های پتروفیزیکی هر گونه سنگی، به طور قابل توجهی دقت تخمین تراوایی را بهبود می‌بخشد. این رویکرد، می‌تواند به عنوان یک ابزار کارآمد برای ارزیابی مخازن کربناته و بهینه‌سازی فرآیندهای تولید مورد استفاده قرار گیرد. این پژوهش به طور قابل توجهی درک ما از ویژگی‌های مخزن بنگستان را بهبود بخشید و می‌تواند به عنوان مبنایی برای توسعه مدل‌های پیشرفته‌تر در ارزیابی مخازن هیدروکربنی مورد استفاده قرار گیرد. نتایج این تحقیق همچنین می‌تواند به بهینه‌سازی فرآیندهای تولید و مدیریت منابع نفتی کمک کند و زمینه‌ساز مطالعات آینده در این حوزه شود.

واژگان کلیدی: رخساره الکتریکی، خوشه‌بندی، شبکه عصبی خود سازمانده، شبکه عصبی مصنوعی، مخزن بنگستان، واحد جریان هیدرولیکی.

مقدمه

تعیین گونه‌های سنگی، بر اساس مطالعات مغزه و پتروگرافی در مخازن ماسه‌سنگی بود (Davies and Vessell, 1996; Porras et al, 1999). در مطالعات انجام شده بعدی (Aplin et al, 2002; Ali-Nandalal and Gunter, 2003; Acosta et al, 2005; Rushing et al, 2008)

تهیه مدل رخساره (با گونه‌های سنگی) و تعیین خواص پتروفیزیکی در تمام مخازن هیدروکربنی بخصوص مخازن کربناته نقش کلیدی در تحقق برنامه‌های مدیریت و توسعه بهینه میادین هیدروکربنی را ایفا می‌نماید. اولین مطالعات

که رایج‌ترین و دقیق‌ترین این روش‌ها، خوشه‌بندی می‌باشد. روش‌های گوناگونی برای خوشه‌بندی وجود دارد که با توجه به نوع داده‌های موجود انتخاب و مورد بهره‌برداری قرار می‌گیرند. از جمله این روش‌ها می‌توان به خوشه‌بندی چند تفکیکی گرافیکی (MRGC: Multi Resolution Graph Clustering)، سلسه مراتبی (AHC: Ascendant Hierarchical Clustering)، روش پویا (DC: Dynamic Clustering) و شبکه عصبی خودسازمانده کوهنن (SOM: Clustering Self Organizing kohonen maps) اشاره کرد (Rahsepar et al, 2016). در این مطالعه برای دسته‌بندی یا خوشه‌بندی نمودارهای پتروفیزیکی از روش شبکه عصبی خود سازمانده کوهنن استفاده شده است. شبکه‌های عصبی خود سازمانده کوهنن (SOM) یکی از مهمترین مدل‌های شبکه عصبی بدون ناظر است که در زمینه‌های مختلفی از جمله تفسیر امواج لرزه‌ای (Strecker and Uden, 2002; Coleou et al, 2003)، آنالیز تصاویر و جهت حرکت بادها (Cassano et al, 2006; Fayos and Fayos, 2007) مورد استفاده قرار گرفته است. هدف این روش خوشه‌بندی، تعیین گروه‌بندی داده‌های شبیه به هم و متمایز کردن آنها از داده‌هایی است که از نظر آماری با دیگر گروه‌های داده‌ای اختلاف دارند. از دلایل استفاده از روش SOM در میان روش‌های آنالیز خوشه‌ای، قابلیت‌های ساختاری آن از جمله قدرت تفکیک بالا و دقیق رخساره‌ها است؛ همچنین در این روش تعیین تعداد خوشه‌ها به انتخاب کاربر بوده و برابر با لایه‌های خروجی است. از دیگر مزیت‌های این روش در مقایسه با روش‌های دیگر خوشه بندی می‌توان از قرار دادن نقشه (Map) همراه با خروجی نام برد، که از این جهت می‌توان آن را به عنوان بهترین روش خوشه‌سازی معرفی کرد. ضمناً برای مخازنی که تنوع لیتولوژی محدودی دارند، استفاده از روش شبکه عصبی خودسازمانده یا روش خوشه‌سازی SOM می‌تواند مناسب باشد. تعیین تراوایی در مخازن هیدروکربنی جزو اجزای جدا ناپذیر شبیه‌سازی مخزن، تسهیل برداشت نفت، عملیات تکمیل چاه و به طور کلی استراتژی‌های بهره‌برداری و اکتشافی است. علیرغم اهمیت حیاتی آن، تراوایی یکی از سخت‌ترین و بحث برانگیزترین ویژگی‌های پتروفیزیکی است که باید با دقت بالایی محاسبه شود. اخیراً روش‌های مختلف هوش مصنوعی به منظور پیش‌بینی این پارامتر اساسی با استفاده از داده‌های

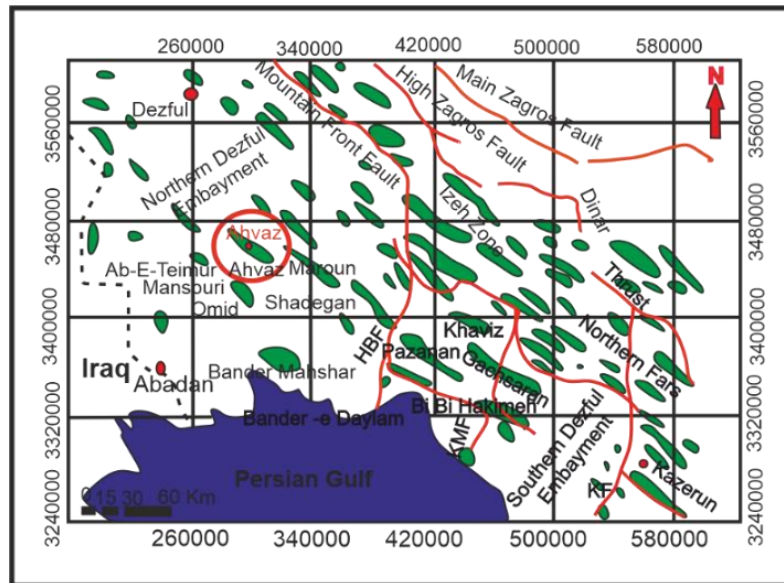
مبنای تعیین گونه‌های سنگی بر پایه پارامترهای تخلخل، تراوایی، مفاهیم رخساره الکتریکی و تعیین ویژگی‌های سیستم منافذ، نشانگر زون جریان و اشباع آب بوده است. به علت در دسترس نبودن مغزه برای همه‌ی چاه‌های یک میدان، امروزه بررسی داده‌های زیرسطحی مانند نمودارهای الکتریکی و تعیین و شناسایی رخساره‌های الکتریکی و تلفیق این داده‌ها با داده‌های زمین‌شناسی به یکی از پرکاربردترین بررسی‌های مخزن تبدیل شده است. با انجام روش‌های مطالعاتی زیرسطحی مانند استفاده از نمودارهای الکتریکی، رخساره‌هایی تعریف می‌شوند که پایه و اساس آنها دیگر ویژگی‌های مستقیم به دست آمده از سنگ‌ها نیست، که این رخساره‌ها را به صورت زیر عنوان رخساره‌های الکتریکی، معرفی می‌کنند (Serra and Sulpice, 1975). واژه رخساره الکتریکی برای اولین بار توسط سرا و ابوت (1982) به منظور توصیف مجموعه‌ای از پاسخ‌های لاگ‌ها معرفی شد. این پاسخ‌ها قادرند یک لایه را تعیین و مشخص کنند و به ما امکان می‌دهند آن لایه را از سایر لایه‌ها تمییز دهیم (Serra and Abbott, 1982). رخساره الکتریکی در اصل یک روش تحلیلی یا قطعی برای دسته‌بندی داده‌های پتروفیزیکی یا چاه‌نگارها است که نشان‌دهنده تغییر ویژگی‌های مخزنی یا زمین‌شناسی می‌باشد. در فرایند تعیین گونه‌های سنگی برقراری یک ارتباط بین خصوصیات پتروفیزیکی و مخزنی ضروری است. به عبارت دیگر برای تعیین گروه‌های سنگی، شناخت و بررسی پارامترهای تخلخل و تراوایی ضروری می‌باشد. این پارامترها به صورت مستقیم و در آزمایشگاه توسط آزمایش بر روی مغزه قابل محاسبه و اندازه‌گیری هستند اما با توجه به اینکه این داده‌ها فقط در نقاط خاصی از مخزن به دست آمده و تهیه آن مستلزم صرف وقت و هزینه بسیار بالایی است، لذا با استفاده از روش تعیین گونه سنگی می‌توان در سایر نقاط مخزن این ویژگی را پیش‌بینی کرد. در واقع در این روش رخساره‌های الکتریکی به دست آمده از دسته‌بندی یا خوشه‌بندی نمودارهای پتروفیزیکی، از طریق تطابق آن‌ها با داده‌های مستقیم تخلخل و تراوایی در چاه‌های مرجع صحت سنجی خواهد شد. بهترین نتیجه از تجزیه و تحلیل به عنوان مدل نهایی انتخاب و در چاه‌های فاقد مغزه انتشار داده خواهد شد. برای شناسایی رخساره‌های الکتریکی روش‌های بسیار متنوعی وجود دارد

است که رخساره عمیق آن در ناحیه لرستان و رخساره کم عمق آن در ناحیه برش الگو و فارس ساحلی گسترش دارد (Motiei, 1995). ترکیب سنگ شناسی سازند سروک در رخساره‌های عمیق شامل سنگ‌آهک‌های مارنی رسی تیره رنگ و نازک لایه است و در رخساره کم عمق سنگ‌آهک سفید رنگ توده‌ای و دارای رودیست و چرت می‌باشد. سازند سروک پس از سنگ‌آهک آسماری مهم‌ترین سنگ مخزن حوضه زاگرس را تشکیل می‌دهد. این سازند توسط سازند ایلام پوشیده می‌شود (Aganabati, 2004). سازند ایلام مانند سازند سروک به دو رخساره کم عمق و عمیق تقسیم می‌شود. رخساره عمیق این سازند در لرستان و رخساره کم عمق آن در خوزستان و فارس گسترش دارد. ترکیب سنگ شناسی سازند ایلام در رخساره عمیق شامل آهک‌های ریزدانه خاکستری با میان لایه‌هایی از شیل‌های سیاه رنگ می‌باشد و این سازند در رخساره عمیق از آهک‌های قلوهای تشکیل شده است. سن سازند ایلام را سانتونین - کامپانین مشخص شده است (Darvishzadeh, 1991). بطور کلی مبنا مطالعه فعلی در مخزن بنگستان میدان نفتی اهواز که از لحاظ سنگ شناسی کلی آهکی (Dunham, 1962) می‌باشد، مشخص ساختن کیفیت زون‌ها با تعیین گونه‌های سنگی در بخش‌های مختلف میدان است. از آنجا که هر زون می‌تواند از یک یا چند گونه سنگی با خصوصیات پتروفیزیکی و لیتولوژی تقریباً مشابه ایجاد شود، در ادامه ویژگی‌های دینامیکی و رفتاری تقریباً یکسان از خود نشان می‌دهند. شناسایی این زون‌ها از لحاظ کیفیت در بخش‌های مختلف میدان می‌تواند باعث کاهش ریسک حفاری و راهگشای حفاری‌های بعدی در آینده شود. بدین ترتیب، در این پژوهش ۵ گونه سنگی از توالی‌های مخزن بنگستان شناسایی شده که در ساختار زون بندی معرفی شده، آرایش یافته‌اند. در مطالعات جدید، مخزن بنگستان میدان اهواز به ۱۵ زون و زیر زون تقسیم‌بندی شده که عبارتند از A, B, C [C1, C2, C3], D, E [E1, E2] F [F1, F2], G [G1, G2], H, I, J

چاه‌پیمایی به کار برده شده‌اند (Huang et al, 1996; Aminian et al, 2003; Gholami et al, 2014; Elkhatny et al, 2018; Urang et al, 2020; Matinkia et al, 2023). با این حال پیش‌بینی ویژگی‌های مخازن ناهمگن همواره با دشواری‌های بسیاری همراه بوده است و به سختی پاسخ مناسبی به دست آمده است. در این مطالعه تلاش شده است تا با استفاده از گونه‌های سنگی و تخمین تراوایی در گونه‌های سنگی تعیین شده، خطای تخمین این پارامتر حیاتی کاهش داده شود. برای این منظور تخمین تراوایی در دو مرحله اصلی انجام می‌شود. در مرحله اول به کمک شبکه عصبی، تخمین تراوایی در کل چاه صورت می‌گیرد. در مرحله دوم برای هر کدام از الکتروفاسیس‌های موجود، به صورت جداگانه تعیین تراوایی انجام می‌شود و یک میانگین‌گیری کلی از پارامترهای ارزیابی صورت می‌گیرد. در نهایت به مقایسه بین پارامترهای ارزیابی برای دو روش مذکور پرداخته می‌شود.

منطقه‌ی مورد مطالعه

میدان نفتی اهواز در استان خوزستان، در قسمت مرکزی شهرستان اهواز، در منطقه فروافتادگی دزفول قرار گرفته است و دارای روند شمال‌غربی به جنوب‌شرقی، به موازات رشته کوه زاگرس می‌باشد. شکل ۱ موقعیت میدان نفتی اهواز را نسبت به میدان‌های اطراف نشان می‌دهد. رخنمون سطحی این میدان نفتی از سازندهای آجاجاری و آبرفت‌های عهد حاضر ایجاد شده است. میدان مورد مطالعه ساختار تاقدیسی دارد و تقریباً از آخرین بخش‌های ناحیه ساده چین‌خورده زاگرس به حساب می‌آید. این تاقدیس بر روی یک بالا آمدگی (هورست) که در طبقات قدیمی‌تر اتفاق افتاده است، قرار دارد. تاقدیس مذکور کم و بیش متقارن می‌باشد و شیب آن در دامنه شمالی بین ۱۰ الی ۲۱ درجه و در دامنه جنوبی بین ۶ الی ۱۲ درجه متغیر است. مخزن مورد مطالعه، از سازند سروک و ایلام از گروه بنگستان است. سازند سروک با سن آلبین - تورونین حاوی دو رخساره



شکل ۱: موقعیت میدان نفتی اهواز (Sherkati and Letouzey, 2004)

Fig. 1: Location of the Ahvaz oil field (Sherkati and Letouzey, 2004)

مواد و روش‌ها

روش‌های بسیار مختلفی برای تعیین گونه‌های سنگی جهت دسته‌بندی سنگ‌های مخزن به نواحی مجزا ارائه شده است که اساس بسیاری از آن‌ها داده‌های تخلخل و تراوایی می‌باشد. مهم‌ترین روش‌های رایج برای تعیین گونه‌های سنگی روش‌های رخساره الکتریکی و واحد جریان هیدرولیکی می‌باشد. در این مطالعه تعیین گونه‌های سنگی مخزن بنگستان با مدل رخساره الکتریکی و واحدهای جریان هیدرولیکی در نرم‌افزار ژئولاگ انجام شده است. تعیین رخساره‌های الکتریکی از داده‌های پتروفیزیکی مرتبط با خصوصیات مخزنی و با استفاده از روش شبکه عصبی (SOM) انجام شده است. رخساره‌های الکتریکی به دست آمده از طریق خوشه‌بندی نمودارهای پتروفیزیکی، در یک فرایند تکراری با نتایج واحدهای جریانی حاصل شده از داده‌های مستقیم تخلخل و تراوایی مغزه در چاه‌های مرجع تطابق داده شد. بهترین نتیجه از تجزیه و تحلیل به عنوان مدل نهایی انتخاب و در چاه‌های فاقد مغزه انتشار داده شد. در ادامه و بعد از تعیین گونه‌های سنگی، تراوایی با استفاده از داده‌های چاه پیمایی و بهره‌گیری از روش شبکه عصبی مصنوعی (ANN) در هریک از گونه‌های سنگی تعیین شده تخمین زده شد.

تعیین گونه‌های سنگی پتروفیزیکی یا رخساره الکتریکی رخساره‌های مخزنی در چاه‌های بدون مغزه به صورت مستقیم قابل تفکیک و تشخیص نیستند و از داده‌های

پتروفیزیکی استنباط می‌شوند. طبقه‌بندی رخساره‌های مخزنی منجر به ارتباط و انطباق خواص جریان با رخساره‌های خاص می‌گردد. داده‌های مغزه به صورت ناپیوسته هستند و در تمام چاه‌ها در دسترس نمی‌باشد. بنابراین منطقی به نظر می‌رسد تا با استفاده از داده‌های چاه‌پیمایی که به صورت پیوسته در تمام چاه‌ها موجود است، تقسیم‌بندی (خوشه‌بندی) پتروفیزیکی سازند انجام گیرد. برای انجام این کار معمولاً از روش‌های هوشمند و آماری استفاده می‌شود. به طور کلی خوشه‌بندی یک دسته‌بندی است که با اهداف مختلفی صورت می‌گیرد. در این پروژه هدف از تعیین خوشه‌بندی ایجاد مدل‌های رخساره‌ای برای تعیین کیفیت مخزن است. مدل رخساره الکتریکی بر اساس مراحل زیر انجام می‌شود:

- ۱) آماده‌سازی داده‌ها و تعیین واحدهای جریان هیدرولیکی
- ۲) انتخاب روش و انجام خوشه‌بندی
- ۳) مقایسه نتایج خوشه‌بندی با واحدهای جریان هیدرولیکی برای تعیین مدل نهایی گونه‌های سنگی در چاه‌های مرجع
- ۴) انتشار گونه‌های سنگی نهایی در تمامی چاه‌ها از جمله چاه‌های فاقد مغزه
- ۵) تعیین کنترل کیفیت گونه‌های سنگی

آماده‌سازی داده‌ها و تعیین واحدهای جریان هیدرولیکی

در این پژوهش از اطلاعات نه حلقه چاه به همراه داده‌های تخلخل و تراوایی بدست آمده از پنج حلقه چاه مخزن بنگستان میدان اهواز استفاده شده است. از چاه‌هایی که دارای اطلاعات مغزه هستند به عنوان اطلاعات مبنا برای آزمایش و ساخت مدل رخساره الکتریکی استفاده گردید. شکل ۲ نشان می‌دهد با توجه به تنوع لاگ‌های برداشت شده در چاه‌های این میدان و همینطور به منظور کسب نتیجه بهتر، از حداکثر لاگ‌های مشترک و سالم موجود در پنج حلقه چاه که عبارتند از: تخلخل موثر (PHIE)، میزان اشباع آب (SW)، چگالی (RHOB)، زمان عبور صوتی (DT)، لاگ گاما (SGR)، به عنوان مجموعه داده مبنا برای ساخت مدل استفاده شده است. همچنین جدول ۱ اطلاعات کاملی از پارامترهای آماری مربوط به داده‌های چاه‌پیمایی را نشان می‌دهد.

همانطور که پیش‌تر گفته شد برای تایید نتایج خوشه‌بندی می‌توان از داده‌های مغزه در قالب واحدهای جریانی استفاده نمود. بر این اساس قبل از انجام خوشه‌بندی برای تعیین واحدهای جریانی از روش دسته‌بندی لگاریتم شاخص زون جریانی (Log FZI) استفاده شد. در این پژوهش با استفاده از شاخص کیفیت مخزنی (رابطه ۱)، نسبت تخلخل به ماتریس (رابطه ۲) و شاخص زون جریانی (رابطه ۳)، لگاریتم زون جریانی (رابطه ۴) محاسبه گردید.

رابطه (۱)

$$RQI=0.0314 \sqrt{K/\emptyset}$$

رابطه (۲)

$$PMR=\emptyset/1-\emptyset$$

رابطه (۳)

$$FZI=RQI/PMR$$

رابطه (۴)

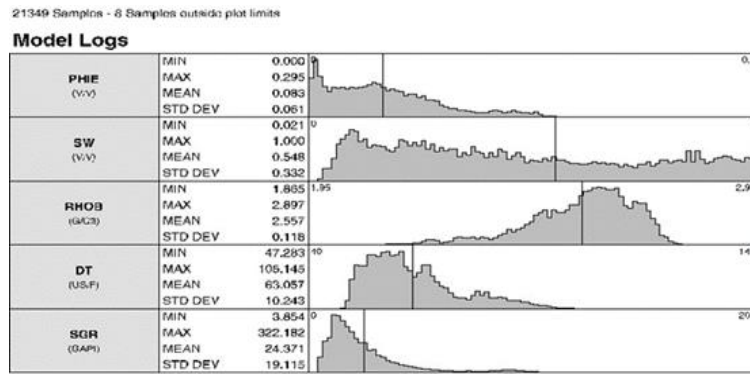
$$\text{Log FZI}=\text{LogFZI}$$

در این روابط K نشان‌دهنده تراوایی بر حسب میلی داری، \emptyset نشان‌دهنده تخلخل، RQI شاخص کیفیت مخزن، PMR نسبت تخلخل به ماتریس (نسبت پوکی) و FZI شاخص زون جریانی می‌باشد. شکل ۳ نشان می‌دهد که با استفاده از لگاریتم شاخص زون جریانی (LOG FZI) پنج واحد جریانی برای چاه‌های مورد نظر تعیین گردید. طبق شکل ۴ مشاهده شد واحدهای جریانی با بیشترین مقدار لگاریتم شاخص زون جریانی دارای مقدار تخلخل و تراوایی بالاتری بوده و کیفیت مخزنی بالاتری دارند. واحدهای جریانی با مقدار کمتر لگاریتم شاخص زون جریانی طبیعتاً مقدار تخلخل و تراوایی کمتری داشته و کیفیت مخزنی در آنها ضعیف‌تر است. به طور کلی از واحدهای جریانی شماره ۱ به سمت واحدهای جریانی شماره ۵ همزمان با کاهش مقدار لگاریتم شاخص زون جریانی، مقدار کیفیت مخزنی کاهش می‌یابد. به عبارتی واحدهای جریانی شماره ۱ و ۲ به دلیل وجود تخلخل و تراوایی مناسب به عنوان بهترین، و واحدهای جریانی شماره ۴ و ۵ به دلیل کاهش مقدار تخلخل و تراوایی، ضعیفترین واحدهای جریانی از نظر کیفیت مخزن در نظر گرفته شده است. در مرحله بعد با استفاده از داده‌های حاصل از لاگ‌های چاه‌پیمایی و روش خوشه‌بندی، رخساره‌ها تعیین می‌شوند، که می‌توان نتایج خوشه‌بندی در رخساره‌های لاگ را با نتایج واحدهای جریانی تطابق داد.

جدول ۱: توصیف کامل داده‌های چاه‌پیمایی

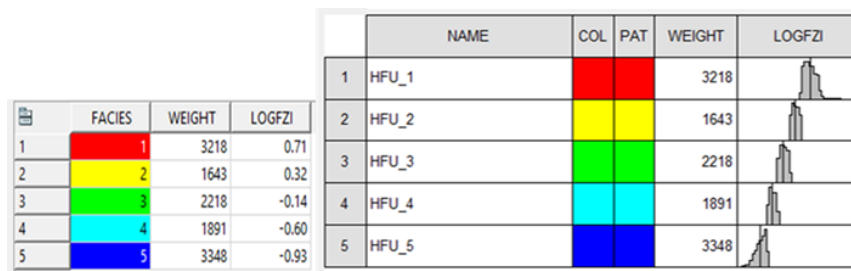
Table 1: Complete description of well logging data

Statistic	CGR	DT	NPHI	PEF	PHIE	RHOB	RT	SGR	Permeability
mean	23.59	72.33	0.16	4.96	0.10	2.51	168.71	41.17	317.43
std	21.36	10.96	0.07	1.17	0.06	0.13	510.28	25.95	1218.72
min	2.23	49.35	0.004	1.90	0.01	1.86	0.27	5.73	0.01
%25	9.62	63.61	0.10	4.30	0.06	2.46	2.85	23.38	0.01
%50	15.60	70.77	0.15	5.21	0.09	2.56	5.08	32.81	0.03
%75	29.72	81.95	0.21	5.88	0.14	2.60	17.48	52.06	42.49
max	94.59	105.06	0.40	8.29	0.29	2.81	2000	320.53	10000



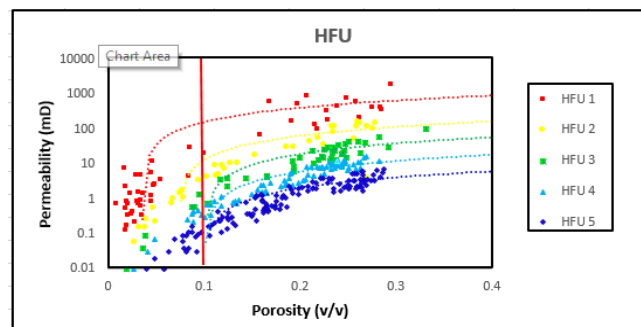
شکل ۲: لاگ‌های انتخاب شده برای مدل رخساره‌های الکتریکی.

Fig. 2: Selected logs for the electrofacies model.



شکل ۳: مدل واحد جریان هیدرولیکی برای میدان مورد مطالعه.

Fig. 3: Hydraulic flow unit model for the studied field



شکل ۴: نمودار تخلخل - تراوایی برای واحدهای جریان هیدرولیکی با استفاده از روش شاخص زون جریان.

Fig. 4: Porosity-permeability plot for hydraulic flow units using the Flow Zone Indicator (FZI) method.


به فضای یک‌بعدی به کار می‌رود و اصطلاح خودسازماندهی در آن به قابلیت یادگیری بدون نیاز به خروجی‌های معین اشاره دارد (Mukherjee, 1997). شبکه‌های SOM شامل نوروں‌های سازمان‌یافته‌ای هستند که از طریق روابط همسایگی (توپولوژی کوهنن) با یکدیگر در ارتباطند (Sfidari et al, 2012). مقایسه نتایج خوشه‌بندی با واحدهای جریان هیدرولیکی برای تعیین مدل نهایی گونه‌های سنگی در چاه‌های مرجع در این مطالعه برای مدل‌سازی گونه‌های سنگی پتروفیزیکی از روش شبکه عصبی خود سازمانده (SOM) استفاده گردید، که این مدل‌سازی با استفاده از نرم‌افزار ژئولاگ (Geolog 7)

انتخاب روش و انجام خوشه‌بندی

خوشه‌بندی، روشی پرکاربرد برای استخراج الگوهای پنهان از داده‌های حجیم از طریق تقسیم‌بندی آن‌ها به گروه‌های مشابه و متمایز است. این روش، که جزو الگوریتم‌های طبقه‌بندی و مدل‌سازی است، با شناسایی گروه‌های طبیعی در داده‌ها، به درک رفتار سیستم کمک می‌کند. از میان الگوریتم‌های مختلف خوشه‌بندی مانند MRGC، تحلیل سلسله مراتبی، خوشه‌بندی پویا و نقشه‌های خودسازمانده کوهنن (SOM)، در این پژوهش از روش SOM که نوعی شبکه عصبی بدون نظارت است، استفاده شد. روش SOM برای پیاده‌سازی مشخصه‌های غیرخطی از فضای چندبعدی

و بعد از تطابق هر باره نتیجه خوشه‌بندی و واحدهای جریان‌ی هیدرولیکی بدست آمد. بعد از تطابق قابل قبول نتیجه خوشه‌بندی و واحدهای جریان‌ی هیدرولیکی، در مرحله بعد انتشار رخساره لاگ‌ها به تمام چاه‌ها بدون مغزه صورت گرفت.

Paradigm2011.1) انجام شد. ابتدا با استفاده از روش خوشه‌بندی شبکه عصبی خود سازمانده، ۲۵ رخساره لاگ اولیه تعریف شد. سپس مطابق با شکل ۵ رخساره‌های با ویژگی‌های یکسان در هم ادغام شده و در انتها ۵ رخساره به عنوان رخساره الکتریکی در نظر گرفته شده است. شایان ذکر است که این مرحله از پژوهش در یک فرایند تکراری



شکل ۵: رخساره‌ها یا خوشه‌های تعریف شده با روش SOM بعد از ادغام.

Fig. 5: Electrofacies or clusters defined by the SOM method after merging

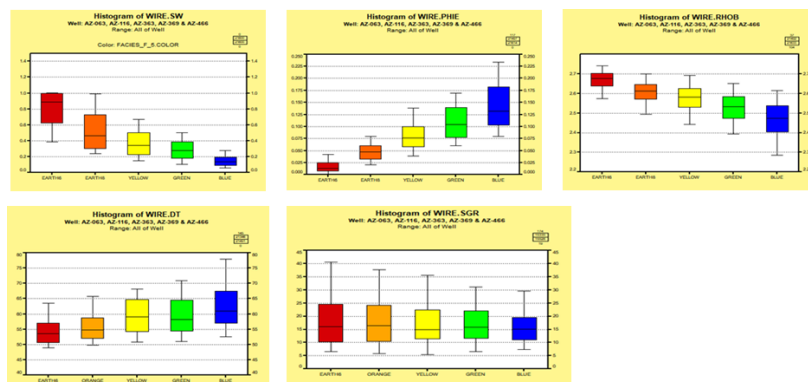
استفاده می‌شود؛ زیرا کراس پلات سطح اشباع آب و تخلخل موثر نقش بسیار مهم و تعیین کننده‌ای در تفکیک رخساره‌ها دارند. رخساره لاگ‌های شماره ۱ تا ۵ از نظر وضعیت مجموعه داده‌های مینا در شکل ۶ نشان داده شده‌اند. شماره رخساره لاگ‌ها به گونه‌ای است که از رخساره ۱ به سمت رخساره ۵ با کاهش میزان تخلخل و لاگ صوتی و افزایش میزان اشباع آب، چگالی و گاما، کیفیت مخزنی کاهش می‌یابد. بدین ترتیب نتایج به دست آمده از رخساره‌های لاگ که با واحدهای جریان‌ی تطابق داده شده منجر به تفکیک سه گروه از گونه‌های سنگی بر مبنای کیفیت مخزنی شده است. به نحوی که سه گروه گونه سنگی با کیفیت خوب، متوسط و ضعیف در مخزن مورد مطالعه قابل شناسایی است.

انتشار گونه‌های سنگی نهایی در تمامی چاه‌ها از جمله چاه‌های فاقد مغزه

پس از تعیین رخساره لاگ‌ها (گونه‌های سنگی) در چاه‌های مرجع، نوبت به انتشار آن به تمام چاه‌های بدون مغزه می‌باشد. انتشار رخساره لاگ‌های نهایی در چاه‌ها باعث می‌شود تا مدل رخساره‌ای ساخته شده در بقیه چاه‌های میدان توسعه داده شود. به این ترتیب با توسعه این مدل در تمامی چاه‌های میدان، رخساره‌های الکتریکی در تمامی چاه‌های میدان شبیه‌سازی شده است. با انجام این مهم می‌توان کیفیت مخزن در چاه‌های بدون مغزه را تعیین کرد.

تعیین کنترل کیفیت گونه‌های سنگی

پس از تعیین رخساره‌ها نوبت به کنترل کیفیت رخساره لاگ‌ها یا گونه‌های سنگی می‌رسد. در این مرحله از کراس پلات سطح اشباع آب (SW) در مقابل تخلخل موثر (PHIE)



شکل ۶: رخساره لاگ‌های شماره ۱ تا ۵ از نظر وضعیت به ترتیب SW, PHIE, RHOB, DT, و SGR می‌باشد.

Fig. 6: Facies logs No. 1 to 5 in terms of SW, PHIE, RHOB, DT, and SGR status, respectively

می‌شود. الگوریتم‌های آموزشی متنوعی جهت آموزش شبکه‌های عصبی به کار می‌رود. محبوب‌ترین و متداول‌ترین روش آموزشی در این شبکه‌ها، روش پس‌انتشار خطا (Error back propagation) می‌باشد. در این الگوریتم خروجی واقعی داده‌های مربوط به گروه آموزشی برای توسعه وزن‌ها در شبکه استفاده می‌شود. در فاصله زمانی مشخص، گروه تست برای ارزیابی توانایی پیش‌بینی شبکه استفاده می‌شود. آموزش تا زمانی ادامه دارد که خطای محاسبه شده بین خروجی‌های واقعی و پیش‌بینی شده برای گروه تست در حال کاهش باشد. در این مطالعه به طور معمول ۷۰ درصد از داده‌ها برای آموزش و یادگیری استفاده می‌شود. ۳۰ درصد دیگر داده‌ها نیز به عنوان داده‌های تست و ارزیابی مدل به کار برده شد. در مطالعه حاضر برای پیش‌بینی تراوایی پس از بررسی نمودارهای پتروفیزیکی مختلف، نمودارهای چگالی (RHOB)، نوترون (NPHI)، گاما (GR)، تخلخل موثر (PHIE) و زمان عبور صوتی (DT) به عنوان ورودی‌های مدل استفاده شد. از ورودی‌های فوق ذکر یکبار برای تخمین تراوایی در کل اینتروال مخزن و یکبار نیز برای هر یک از گونه‌های سنگی استفاده شد و در نهایت نتایج تخمین براساس شاخص‌های آماری مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) با یکدیگر مورد ارزیابی و مقایسه قرار گرفتند.

بحث و نتایج

در این پژوهش برای تعیین گونه‌های سنگی و تخمین تراوایی مخزن بنگستان از داده‌های پنج چاه دارای مغزه (تخلخل - تراوایی) استفاده شده است. به این نحو که در گام نخست از اطلاعات ۵ چاه به عنوان اطلاعات مبنا برای آزمایش و ساخت مدل رخساره الکتریکی استفاده گردید. با توجه به تنوع لاگ‌های برداشت شده در چاه‌های این میدان و به منظور کسب نتیجه بهتر از حداکثر لاگ‌های مشترک و سالم موجود در این ۵ چاه یعنی نمودارهای چگالی (RHOB)، تخلخل موثر (PHIE)، سطح اشباع آب (SW)، لاگ تصحیح شده گاما (CGR) و زمان عبور صوتی (DT) به عنوان مجموعه داده مبنا برای ساخت مدل استفاده شد (شکل ۲). پس از انتخاب روش طبقه‌بندی کوهنن و اجرای آن مدل‌هایی با درجه تفکیک متفاوت از خوشه‌ها (رخساره‌های الکتریکی) ایجاد گردید. پس از بررسی و

تخمین تراوایی با استفاده از شبکه عصبی مصنوعی (ANN)


شبکه عصبی مصنوعی (ANN) یک مدل محاسباتی و از روش‌های یادگیری ماشین می‌باشد. این شبکه، داده‌ها را پردازش کرده و به صورت توزیع شده و موازی یاد می‌گیرد. شبکه‌های عصبی مصنوعی چگونگی وابستگی بین متغیرهای ورودی و خروجی را می‌آموزند. یادگیری براساس تشخیص الگو است که یکی از نقاط قوت شبکه عصبی می‌باشد (Mohaghegh, 2000). شبکه عصبی الگوهای جدید را دسته‌بندی کرده و خروجی را بر پایه الگوهای آموخته شده پیش‌بینی می‌کند. این نوع از شبکه‌ها بیشتر زمانی کاربرد دارند که روابط بین پارامترها بسیار سخت و پیچیده باشد یا برای حل آن از طریق روش‌های مرسوم به مدت زمان زیادی نیاز داشته باشد. این نوع از شبکه‌ها به دو شکل نظارت شده و بدون نظارت به کار گرفته می‌شوند. یکی از ساده‌ترین و کارآمدترین نوع شبکه عصبی مدل پرسپترون چندلایه (Multi layer preceptron) است. یک شبکه عصبی پرسپترون معمولی شامل سه لایه (ورودی، میانی یا پنهان و خروجی) است. هر لایه به لایه عصبی بعدی متصل شده است. در نتیجه خروجی لایه اول به ورودی لایه بعدی تبدیل می‌شود. شبکه عصبی با تنظیم مکرر وزن ورودی‌ها تا هنگامی که نتایج تولید شده شبیه به خروجی‌های صحیح در مجموعه آموزشی باشد، یاد می‌گیرد. در نتیجه وزن‌دهی غیر خطی، شبکه عصبی می‌تواند مشکلات بسیار زیاد و پیچیده‌ای را مدیریت کند. یک شبکه عصبی مصنوعی قابل اعتماد باید بتواند یک خروجی مناسب و معقول را برای داده‌های ورودی که قبلاً توسط شبکه دیده نشده است، پیش‌بینی کند. به طور کلی خروجی یک شبکه عصبی پرسپترون را می‌توان به صورت رابطه ۵ نشان داد:

$$O = f(net), \quad net = b + \omega_1 x_1 + \dots + \omega_n x_n \\ = b + \sum \omega_i x_i$$

که در آن ω و b به ترتیب وزن و بایاس شبکه عصبی بوده و f نشان دهنده تابع فعالسازی (Activation function) است. که شامل یک فرمول ریاضی برای بروزرسانی وزن‌ها در شبکه است. پایگاه داده‌ای که قرار است به شبکه عصبی معرفی شود به دو گروه (آموزش و تست) تقسیم می‌شود. گروه آموزشی برای ایجاد شبکه و آموزش مدل استفاده

تراوایی بالا است و گونه سنگی غالب در این زون‌ها گونه سنگی شماره یک می‌باشد که همانطور که اشاره شد دارای کیفیت مخزنی بالا است، در زون‌های A و B همانطور که در شکل ۷ نیز مشخص است گونه‌های سنگی شماره ۴ و ۵ پدیده غالب بوده و کیفیت مخزنی ضعیف می‌باشد. همانطور که پیش‌تر اشاره شد مقادیر تخلخل موثر (PHIE) و آب اشباع شدگی (SW) نقش بسیار مهم و تعیین‌کننده‌ی در تفکیک رخساره‌ها دارند، با توجه مقادیر نمودارهای پتروفیزیکی در هر رخساره مشاهده شد که رخساره شماره ۱ و ۲ که کیفیت مخزنی بهتری دارند در زون‌های C1, C2, E1, E2, G2, I1-2 فراوان‌تر هستند و زون‌هایی که کیفیت مخزن مناسبی ندارند دارای رخساره ۵ می‌باشند که در زون‌های A, B, D, E1, F1, G1, H غالب می‌باشند. در گام دوم از این پژوهش پس از تعیین گونه‌های سنگی پتروفیزیکی به تخمین تراوایی از داده‌های چاه‌پیمایی پرداخته شد. برای پیش‌بینی تراوایی با استفاده از شبکه عصبی مصنوعی، یک شبکه عصبی پس انتشار با ۱ لایه پنهان استفاده شد. برای خروجی مطلوب از تخمین تراوایی، داده‌ها به صورت دو مجموعه آموزش و تست به کار برده شد. که در شبکه عصبی ۷۰ درصد از مجموعه داده‌ها برای آموزش و ۳۰ درصد برای تست ارائه گردید. در ارزیابی شبکه عصبی معمولاً از پارامترهای میانگین مجموع مربعات خطا (MSE)، مجذور مجموع مربعات خطا (RMSE) و یا ضریب همبستگی (R) استفاده می‌شود. کار اصلی الگوریتم یادگیری یک شبکه عصبی پیدا کردن یک خط است به گونه‌ای که نسبت به همه‌ی نقاط، بهترین موقعیت را داشته باشد. منظور از بهترین موقعیت این است که این خط رگرسیون باید به تمامی نقاط کمترین فاصله را داشته باشد، به بیانی دیگر می‌توان گفت که بهترین موقعیت یعنی کمترین مقدار MSE یا RMSE. بنابراین هر چقدر این مقدار خطا یا مجذور خطا کمتر باشد خط رگرسیون خط بهتری می‌باشد، که این نوعی معیار برای خوب بودن مدل ساخته شده می‌باشد.

ترکیب خوشه‌های مشابه برای هر کدام از مدل‌های رخساره‌ای توسعه داده شده نتیجه مدل در مقابل واحدهای جریان تعیین شده با روش شاخص منطقه‌ای جریانی (Log FZI) قرار گرفت و با آن مقایسه شد. به این وسیله، یک مدل رخساره‌ای با درجه تفکیک ۵ رخساره به عنوان مدل رخساره نهایی معرفی شد. با در نظر گرفتن محدوده تغییرات تخلخل و تراوایی مغزه و همچنین لاگ‌های پتروفیزیکی مختلف به خصوص تخلخل موثر و آب اشباع شدگی در هر رخساره می‌توان کیفیت مخزنی را پیش‌بینی نمود. تعیین کیفیت مخزن براساس داده‌های مینا به این صورت است که هر جا تخلخل موثر بیشتر باشد کیفیت مخزن بهتر می‌باشد، هر چه مقدار سطح اشباع آب بیشتر باشد یعنی مخزن دانه‌ریز بوده و هیدروکربن نتوانسته جایگزین آب شود، پس کیفیت مخزن ضعیف‌تر می‌باشد. براساس چگالی کیفیت مخزن به این صورت می‌باشد که هر چه مقدار چگالی یا دانسیته پایین‌تر باشد، تخلخل بیشتر و بنابراین کیفیت مخزن بهتر است. تاثیر لاگ سونیک یا زمان عبور صوتی بر کیفیت مخزن نیز به این صورت است که اگر تخلخل زیاد باشد زمان گذر عبور امواج صوت زیاد و سرعت صوت کم می‌باشد، لاگ گاما هم عمدتاً نشان‌دهنده وجود شیل است. که این خود نشان دهنده بخش‌های با کیفیت مخزنی کم یا فاقد کیفیت مخزنی است. با توجه به ملاحظات فوق ذکر، در مخزن مورد مطالعه گونه‌های سنگی ۱ و ۲ با میانگین تخلخل و تراوایی بالا و سطح اشباع آب کم دارای بهترین کیفیت مخزنی است و گونه سنگی ۳ کیفیت مخزن متوسط و گونه‌های سنگی ۴ و ۵ با سطح اشباع آب بالا و همچنین مقدار تخلخل و تراوایی کم دارای پایین‌ترین کیفیت مخزن می‌باشند. شکل ۵ مدل رخساره‌ای نهایی را در مخزن مورد مطالعه نشان می‌دهد همچنین، نتیجه حاصل از اجرای مدل در یک حلقه چاه میدان مورد مطالعه در شکل ۷ آورده شده است. همانطور که از نتیجه اجرای مدل در چاه‌ها مشخص است. در زون C1 و C2 از مخزن مورد مطالعه مقدار تخلخل موثر و



شکل ۷: نتیجه اجرای مدل رخساره‌های الکتریکی و واحدهای هیدرولیکی جریان در یکی از چاه‌های میدان مورد مطالعه همراه با پارامترهای پتروفیزیکی. از سمت چپ: ستون اول شامل عمق، ستون دوم شامل نگار پرتو گاما، ستون سوم شامل نگار نوترون، نگار چگالی و نگار جذب فتوالکتریک، ستون چهارم تخلخل موثر، ستون پنجم سنگ‌شناسی سازند بنگستان، ستون ششم گونه‌های سنگی حاصل از آنالیز خوشه‌ای (رنگ‌های آبی، سبز، زرد، نارنجی و قرمز به ترتیب نماینده رخساره‌های ۱، ۲، ۳، ۴ و ۵ می‌باشد). و ستون هفتم گونه‌های سنگی حاصل از روش‌های واحدهای جریانی را در سازند بنگستان نشان می‌دهد (رنگ‌های قرمز، زرد، سبز، فیروزه‌ای و آبی به ترتیب نماینده واحدهای جریانی ۱، ۲، ۳، ۴ و ۵ می‌باشد).

Fig. 7: Result of the electrofacies and hydraulic flow unit model implementation in one of the field's wells, along with petrophysical parameters. From left: the first column includes depth, the second column includes the gamma-ray log, the third column includes the neutron log, the density log, and the photoelectric absorption log, the fourth column effective porosity, the fifth column Bangestan Formation lithology, the sixth column rock types resulting from cluster analysis (blue, green, yellow, orange, and red represent facies 1, 2, 3, 4, and 5, respectively), and the seventh column shows the rock types resulting from flow unit methods in the Bangestan Formation (red, yellow, green, turquoise, and blue represent flow units 1, 2, 3, 4, and 5, respectively).

عصبی است بنابراین بهینه‌سازی ساختار شبکه به تعیین تعداد نرون‌های لایه میانی (یا پنهان) محدود می‌شود. از این جهت لایه میانی به عنوان جزئی کلیدی از ساختار شبکه عصبی نقش مهمی در قابلیت تخمین نگاشت و تشخیص الگوی داده‌های ورودی، بازی می‌کند. مطابق با آنچه گذشت تعداد نرون‌های ورودی برای تخمین تراوایی به عنوان پارامتر هدف برابر با ۵ می‌باشد. به علاوه تعداد نرون‌های خروجی برای تخمین طبیعتاً برابر با یک است. تعداد نرون‌های لایه میانی بعد از سعی و خطا و بررسی‌های زیاد ۸ نرون در نظر گرفته شد. شایان ذکر است که برای لایه خروجی و لایه میانی به ترتیب از تابع خطی و تابع تانژانت سیگموئیدی به عنوان تابع تحریک استفاده شده است. در این پژوهش برای تخمین پارامتر هدف یکبار تخمین تراوایی در کل داده‌های موجود از چاه‌های مختلف

برای تخمین تراوایی با استفاده از شبکه عصبی در ابتدا ورودی مناسب از داده‌های پتروفیزیکی انتخاب شد. به نحوی که پس از بررسی نمودارهای چاه‌پیمایی مختلف، نمودارهای چگالی (RHOB)، نوترون (NPHI)، تخلخل موثر (PHIE)، زمان عبور صوتی (DT)، اشعه گاما (GR) به عنوان ورودی‌های مدل برای تخمین تراوایی استفاده شد. برای خروجی مطلوب از تخمین تراوایی، داده‌ها به صورت دو مجموعه آموزشی و تست به کار برده شد. انتخاب معماری مناسب و الگوریتم آموزشی کارآمد دو مسئله مهم در هنگام کار با شبکه‌های عصبی است. نوع معماری شبکه در آموزش و عملکرد آن نقش بسزایی دارد و به معنی انتخاب بهینه تعداد لایه‌ها، تعداد نرون‌ها در هر لایه و نوع تابع تحریک هر نرون می‌باشد. تعداد نرون‌های لایه‌های ورودی و خروجی به ترتیب برابر با تعداد ورودی و خروجی شبکه

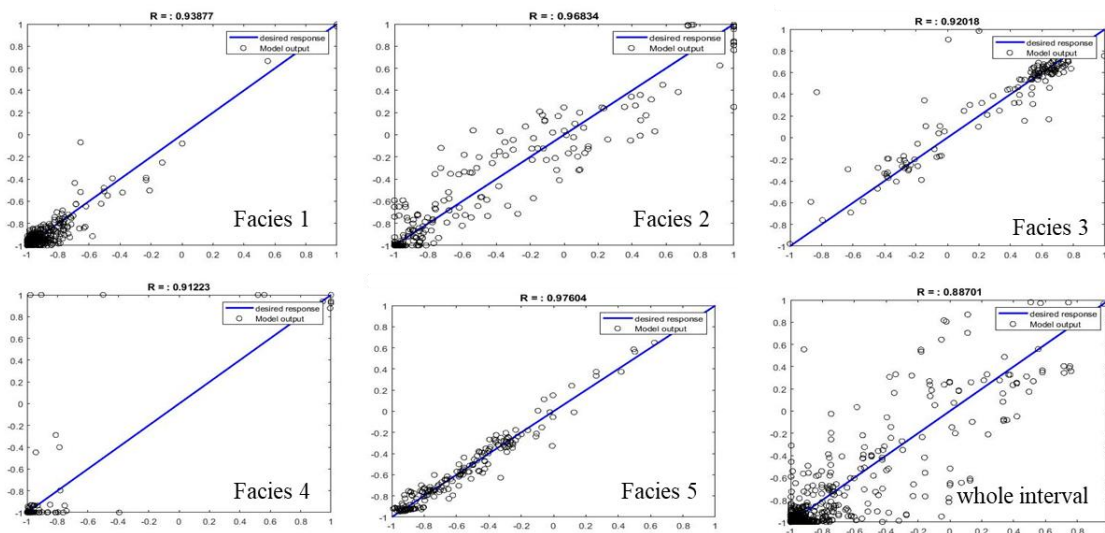
شکل ۸ ضریب همبستگی (R) به دست آمده برای تخمین تراوایی را در هر کدام از گونه‌های سنگی نشان می‌دهد. همچنین در شکل ۹ و ۱۰ داده‌های واقعی تراوایی در مقابل داده‌های تخمین زده شده توسط شبکه برای هر کدام از رخساره‌ها و کل اینتروال به ترتیب نشان داده شده است. با توجه به جدول ۲ و شکل‌های ۹ و ۱۰ می‌توان نتیجه‌گیری کرد که رویکرد استفاده شده در این تحقیق یعنی تخمین تراوایی مغزه در گونه‌های سنگی به خوبی می‌تواند مورد استفاده قرار گیرد. رویکردی که می‌توان با استفاده از آن سایر پارامترهای پتروفیزیکی را نیز بدست آورد.

انجام شد و در بار دوم تراوایی در هر کدام از گونه‌های سنگی تعیین شده تخمین زده شد. براساس شاخص‌های آماری مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) به عنوان پارامترهای ارزیابی می‌توان عملکرد شبکه عصبی را برای تخمین تراوایی با دو رویکرد متفاوت با هم مقایسه کرد. بهترین مقدار تخمین زده شده برای هر کدام از پارامترهای هدف با استفاده از شبکه عصبی در جدول ۲ آورده شده است. همانطور که در جدول ۲ مشاهده می‌شود میانگین تراوایی حاصل از رخساره‌ها نسبت به تراوایی حاصل از کل اینتروال نتایج بهتری ارائه می‌دهد.

جدول ۲: نتایج پارامترهای ارزیابی برای تخمین تراوایی در رخساره‌ها و همچنین اینتروال کامل مخزن (نتایج برای داده‌های تست ارائه شده‌اند).

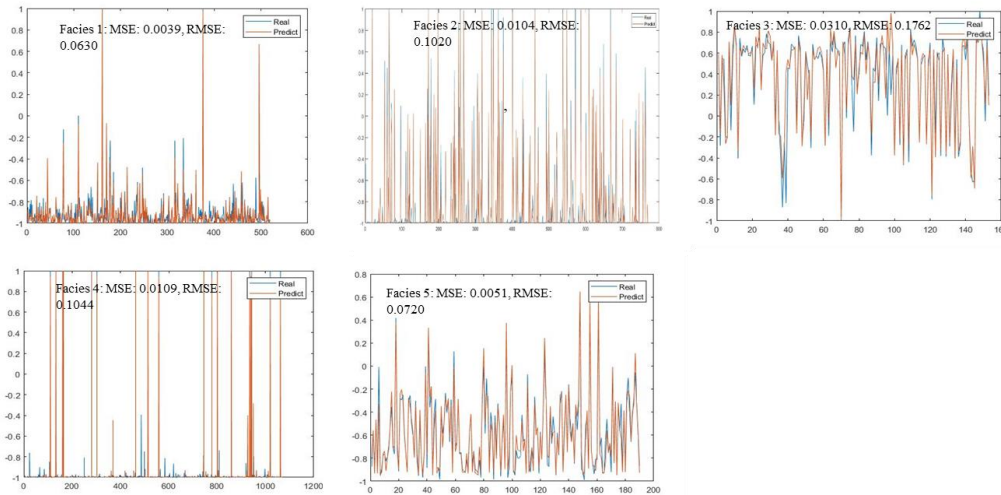
Table 2: Evaluation parameter results for permeability estimation in facies and the complete reservoir interval (results are presented for test data).

Data	R-Test	MSE	RMSE
Electofacies 1	0.9387	0.0039	0.0630
Electofacies 2	0.9683	0.0104	0.1020
Electofacies 3	0.9201	0.0310	0.1762
Electofacies 4	0.9122	0.0109	0.1044
Electofacies 5	0.9760	0.0051	0.0720
Average for all EF	0.9431	0.0123	0.0778
Whole interval	0.8870	0.0134	0.1161



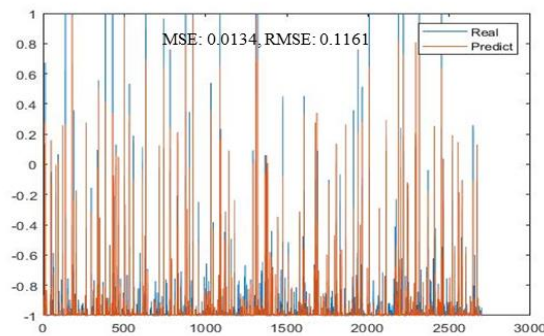
شکل ۸: مقایسه تراوایی اندازه‌گیری شده (Real) و مقادیر تخمین زده شده (Predicted) این پارامتر توسط شبکه عصبی مصنوعی در رخساره‌ها و اینتروال کامل مخزن.

Fig. 8: Comparison of measured permeability (Real) and predicted values of this parameter by the artificial neural network in facies and the complete reservoir interval.



شکل ۹: نمودار مقادیر تراوایی واقعی در مقابل تراوایی تخمین زده شده رخساره‌ها توسط شبکه عصبی مصنوعی.

Fig. 9: Plot of actual permeability values versus permeability estimated by the artificial neural network for facies.



شکل ۱۰: نمودار مقادیر تراوایی واقعی در مقابل تراوایی تخمین زده شده کل اینتروال توسط شبکه عصبی مصنوعی.

Fig. 10: Plot of actual permeability values versus permeability estimated by the artificial neural network for the entire interval.

نتیجه‌گیری

متوسط و گونه‌های سنگی ۴ و ۵ دارای کیفیت مخزنی ضعیف یا فاقد کیفیت مخزنی بودند. در گام دوم از این پژوهش، تراوایی با استفاده از شبکه عصبی مصنوعی (ANN)، یکبار در کل داده‌های موجود از چاه‌های مختلف و یکبار هم در هر کدام از گونه‌های سنگی تعیین شده تخمین زده شد. شاخص‌های آماری مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) به عنوان پارامترهای ارزیابی برای تخمین تراوایی استفاده شد. ضریب تطابق یا همبستگی برای حالت استفاده از گونه‌های سنگی برای داده آموزش و تست به ترتیب برابر با ۰/۹۸۰۴ و ۰/۹۴۳۱ و در حالت استفاده از کل داده‌های موجود برای تخمین تراوایی به ترتیب برابر با ۰/۹۳۰۸ و ۰/۸۸۷۰ است. مقدار خطا و میانگین مربعات خطا نیز در حالت استفاده از

این پژوهش با هدف تعیین گونه‌های سنگی پتروفیزیکی و تراوایی در دو گام در مخزن بنگستان یکی از میداین نفتی جنوب غرب ایران انجام شد. برای این منظور در گام نخست با استفاده از داده‌های چاه‌پیمایی چگالی (RHOB)، تخلخل موثر (PHIE)، سطح اشباع آب (SW)، لاگ تصحیح شده گاما (CGR) و زمان عبور صوتی (DT) و بهره‌گیری از روش خوشه‌بندی شبکه عصبی خود سازمانده، رخساره لاگ یا گونه‌های سنگی مشخص شد. گونه‌های سنگی در یک فرایند تکراری با واحدهای جریان تطابق داده شد بدینوسیله ۵ گونه سنگی پتروفیزیکی تعیین شد. از میان گونه‌های سنگی شناسایی شده گونه سنگی ۱ و ۲ دارای بهترین کیفیت مخزنی، گونه سنگی ۳ با کیفیت مخزنی

سپاسگزاری

نویسندگان بر خود لازم می‌دانند مراتب سپاس و قدردانی صمیمانه خود را از شرکت ملی مناطق نفت‌خیز جنوب و دانشگاه شهید چمران اهواز به منظور فراهم آوردن داده‌های زیرسطحی، امکانات آزمایشگاهی و سایت رایانه‌ای، و همچنین حمایت‌های ارزشمند در تسهیل انجام این پژوهش اعلام نمایند.

گونه‌های سنگی برای داده آموزش و تست به ترتیب برابر با ۰/۰۱۲۳ و ۰/۰۷۷۸ و برای کل اینتروال یا داده‌های موجود به ترتیب برابر با ۰/۰۱۳۴ و ۰/۱۱۶۱ بدست آمد. نتایج بدست آمده نشان می‌دهند که تخمین تراوایی با رویکرد استفاده شده در این تحقیق به خوبی می‌تواند دقت پیش‌بینی را برای این پارامتر مهم پتروفیزیکی افزایش دهد. بنابراین می‌توان از این رویکرد در تخمین سایر پارامترهای پتروفیزیکی نیز استفاده نمود.

References

- Abbaszadeh, M., Fujii, H. and Fujimoto, F.J.S.F.E., 1996. Permeability prediction by hydraulic flow units—theory and applications, v. 11(04), p. 263-271.
- Acosta, L., Marin, E., Labastidas, E., Bello, J., Jimenez, J., Cordoba, P., Pascual, J., Auxiette, G., Gou, Y. and Thorsen, B., 2005. Reservoir Study V9 of El Furrial Field, Venezuela. SPE Latin American and Caribbean Petroleum Engineering Conference, OnePetro.
- Ali-Nandalal, J. and Gunter, G., 2003. Characterising reservoir performance for the mahogany 20 gas sand based on petrophysical and rock typing methods. SPE Latin American and Caribbean Petroleum Engineering Conference, OnePetro.
- Aminian, K., Ameri, S., Oyerokun, A. and Thomas, B., 2003. Prediction of flow units and permeability using artificial neural networks. SPE Western Regional/AAPG Pacific Section Joint Meeting, OnePetro.
- Aplin, G.F., Dawans, J.M.L. and Sapru, A.K., 2002. New insights from old data: identification of rock types and permeability prediction within a heterogeneous carbonate reservoir using diplog and openhole log data. Abu Dhabi International Petroleum Exhibition and Conference, OnePetro.
- Bear, J., 1972. Dynamics of fluids in porous media. Elsevier, 757 p.
- Cassano, E.N., Lynch, A.H., Cassano, J.J. and Koslow, M.R.J.C.R., 2006. Classification of synoptic patterns in the western Arctic associated with extreme events at Barrow, Alaska, USA, v. 30(2), p. 83-97.
- Coléou, T., Poupon M. and Azbel, K.J.T.L.E., 2003. Unsupervised seismic facies classification: A review and comparison of techniques and implementation, v. 22(10), p. 942-953.
- Dunham, R.J., 1962 Classification of Carbonate Rocks According to Depositional Texture. In: Ham, W.E., Ed., Classification of Carbonate Rocks, AAPG, Tulsa, p. 108-121.
- Davies, D. and Vessell, R., 1996. Identification and distribution of hydraulic flow units in a heterogeneous carbonate reservoir: North Robertson Unit, west Texas. Permian Basin Oil and Gas Recovery Conference, OnePetro.
- Ebanks, W.J., 1987. Flow unit concept-integrated approach to reservoir description for engineering projects, v. 71, p. (CONF-870606-).
- Elkatatny, S., Mahmoud, M., Tariq, Z. and Abdurraheem, A.J.N.C., 2018. New insights into the prediction of heterogeneous carbonate reservoir permeability from well logs using artificial intelligence network, v. 30, p. 2683-2673.
- Fayos, J. and Fayos, C.J.P.O., 2007. Wind data mining by Kohonen neural networks, v. 2(2), p. e210.
- Gholami, R., Moradzadeh, A., Maleki, S., Amiri, S. and Hanachi, J.J.J.O.P.S., 2014. "Applications of artificial intelligence methods in prediction of permeability in hydrocarbon reservoirs, v. 122, p. 643-656.
- Gunter, G., Finneran, J., Hartmann, D. and Miller, J., 1997. Early determination of reservoir flow units using an integrated petrophysical method. SPE annual technical conference and exhibition, OnePetro.
- Huang, Z., Shimeld, J., Williamson, M. and Katsube, J.J.G., 1996. Permeability prediction with artificial neural network modeling in the Venture gas field, offshore eastern Canada, v. 61(2), p. 422-436.
- Matinkia, M., Hashami, R., Mehrad, M., Hajsaeedi, M.R. and Velayati, A.J.P., 2023. Prediction of permeability from well logs using a new hybrid machine learning algorithm, v. 9(1), p. 108-123.
- Mohaghegh, S.J.J.O.P.T., 2000. Virtual-intelligence applications in petroleum engineering: Part I—Artificial neural networks, v. 52(09), p. 64-73.
- Mukherjee, A.J.J.O.C.i.C.E., 1997. Self-organizing neural network for identification of natural modes, v. 11(1), p. 74-77.
- Porras, J., Barbato, R. and Khazen, L., 1999. Reservoir flow units: A comparison between three different models in the Santa Barbara and Pirital fields, North Monagas Area, Eastern Venezuela Basin. Latin American and Caribbean petroleum engineering conference, OnePetro.

Rushing, J.A., Newsham, K.E. and Blasingame, T.A., 2008. Rock typing—Keys to understanding productivity in tight gas sands. SPE Unconventional Reservoirs Conference, OnePetro.

Rahsepar, A., Kadkhodaie, A. and Bidhendi, M., 2016. Determination of reservoir electrofacies using clustering methods (MRGC, AHC, SOM, DYNCLUST) throughout ARAB part in SALMAN oil field 2S-05 well. Journal of Petroleum Research, v. 26(95-2), p. 107-117.

Serra, O. and Sulpice, L., 1975. Sedimentological Analysis of Shale-Sand Series from Well Logs. SPWLA 16th Annual Logging Symposium.

Serra, O.T. and Abbott, H.J.S.O.P.E.J., 1982. The contribution of logging data to sedimentology and stratigraphy, v. 22(01), p. 117-131.

Strecker, U. and Uden, R.J.T.L.E., 2002. Data mining of 3D poststack seismic attribute volumes using Kohonen self-organizing maps, v. 21(10), p. 1032-1037.

Sfidari, E., Kadkhodaie-Ilkhchi, A. and Najjari, S.J.J.O.P.S., 2012. Comparison of intelligent and statistical clustering approaches to predicting total organic carbon using intelligent systems, v. 86, p. 190-205.

Urang, J.G., Ebong, E.D., Akpan, A.E. and Akaerue, E.I.J.J.O.A.G., 2020. A new approach for porosity and permeability prediction from well logs using artificial neural network and curve fitting techniques: A case study of Niger Delta, Nigeria, v. 183, p. 104207.