

Research Article

## Accurate Estimation of Residual Hydrocarbon Potential by Removing the Adverse Effects of Lithological Variations on the Training Process of Adaptive Neuro-Fuzzy Inference System

Khaled Maroufi <sup>1\*</sup>, Iman Zahmatkesh <sup>2</sup>

1- Faculty of Petroleum and Natural Gas Engineering, Sahand University of Technology, Tabriz, Iran.

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

**Keywords:** *Litho-based method, Source rock, Residual Hydrocarbon Potential ( $S_2$ ), Metaheuristic Algorithms, Adaptive Neuro Fuzzy Inference System.*

### 1-Introduction

The source rock's  $S_2$  parameter, residual hydrocarbon generation potential, is usually measured using Rock-Eval pyrolysis. It demonstrates hydrocarbons are generated by cracking the kerogen at a temperature range from about 350 to 650°C (Behar et al., 2001). However, this experiment is costly and time-consuming. Therefore, well logs are commonly used to evaluate source rocks qualitatively and/or quantitatively (e.g. Passey et al., 1990; Kadkhodaie-Ilkhchi et al., 2009; Sfidari et al., 2012; Alizadeh et al., 2013; Alizadeh et al., 2018). Moreover, along with increased exploration and development of source-related unconventional hydrocarbon resources, accurate estimation of  $S_2$  parameters through log data has become progressively essential.

Changes in lithology within an interval of possible sources also affect the well log responses. Consequently, artificial intelligence (AI) techniques may interpret these lithology-induced log responses as a signal for changes in the organic matter properties. Such an effect has been observed with the  $\Delta\text{LogR}$  method, for which the accuracy of estimated TOC values is not acceptable in calcareous lithologies (Alizadeh et al., 2018). Accordingly, there is a possibility that lithological variations interfere with the training process of AI systems.

This study used a new method to eliminate these possible effects from lithological variations and, therefore, high-precision  $S_2$  prediction. This proposed method is verified for its effectiveness and trustworthiness by applying it to the Pabdeh source rocks of SW Iran.

### 2-Material and methods

The preliminary dataset of this study includes  $S_2$  values resulting from rock-eval pyrolyzing of more than 200 cutting and core samples from source candidates throughout the Zagros fold belt (including Kazhdumi, Pabdeh, and Gurpi formations) and their corresponding log data. Before constructing the models, a comprehensive preprocessing was carried out over the dataset, including discriminating the samples affected by nonindigenous organic material using the  $S_1/\text{TOC}$  ratio, searching for and eliminating noisy data associated with bad hole conditions, depth-matching of logs recorded in different runs, and depth-matching of the rock samples and well logs. Then, three conventional methods, including ANFIS, ANFIS-

\* Corresponding author: maroufi@sut.ac.ir

DOI :10.22055/AAG.2022.41534.2306

Received: 2022-08-03

Accepted: 2022-09-11

GA and ANFIS-PSO, were utilized for modeling the relationship between wells logs and  $S_2$  values using the whole dataset (original ANFIS model and hybrid models). In the next step, a simple method was used to remove the effect of lithological variations. Indeed, the ANFIS method was employed again for modeling the relationship between wells logs and  $S_2$  values for each type of lithology (litho-based ANFIS model). Finally, the applicability of the proposed methodology was tested by performing it over the Pabdeh Formation in a well, and conclusions were drawn.

It should be mentioned that evaluating the constructed models and comparing their results have been carried out using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE) functions.

### 3-Results and discussions

#### 3.1. Estimating $S_2$ parameter using original ANFIS model

Designing an ANFIS model using the whole dataset has been carried out by employing Takagi–Sugeno–Kang (TSK) fuzzy system and fuzzy c-means (FCM) clustering method. Results showed that the original ANFIS model is relatively efficient in predicting  $S_2$  from the wells logs. However, the outputs also show non-negligible errors (MSE = 0. 677, RMSE = 0. 823 and MAPE = 11.42 for the unseen test data).

#### 3.2. Estimating $S_2$ parameter using hybrid models

As a traditional method for optimizing the original model, nature-inspired metaheuristic algorithms were used to adjust the antecedent and consequent variables of the ANFIS method. The computed error functions for the trained hybrid models revealed that, unlike the Genetic Algorithm (GA), the Particle Swarm Optimization (PSO) algorithm is successful in terms of increasing efficiency (MSE = 0. 665, RMSE = 0. 815, and MAPE = 9.61 for the unseen test data). Nevertheless, this algorithm could not enhance the accuracy of the estimations to a considerable extent.

#### 3.3. Estimating $S_2$ parameter using the litho-based method

As expected, the ANFIS litho-based models provided more reliable and accurate predictions than the traditional models, as reflected by the calculated error functions (overall MSE = 0. 216, RMSE = 0. 465, and MAPE = 6.73 for the unseen test data). Indeed, a significant increase in the accuracy of the estimated  $S_2$  values for the litho-based models verifies that the proposed methodology has successfully removed the adverse effect of lithological variations on the performance of IA techniques.

#### 3.4. Case study

Practical testing of the proposed litho-based method over Pabdeh source rocks in a well of SW Iran quarantined its applicability. Moreover, outputs of the litho-based ANFIS models were used to evaluate the Pabdeh Formation geochemically. While the upper and lower parts of the Pabdeh Formation are considered lean to fair limy source rocks, the middle shaly zone possesses a great hydrocarbon generation potential. These characteristics for the middle unit are related to the sea level rise during the Middle-Late Eocene, which facilitated the production and preservation of organic matter by expanding *the oxygen-minimum layer*.

### 4-Conclusion

This paper proposed a new approach, called the litho-based method, based on modeling the relationship between log data and  $S_2$  parameters for each type of lithology (shale, marl and limestone). The performance of the newly developed method was compared to those of the traditional ANFIS and hybrid models trained by a dataset containing all three types of lithologies. While traditional methods are reasonably efficient in estimating  $S_2$  from wells logs, the efficiency of the ANFIS technique increases substantially by eliminating the effects of lithological variations using the litho-based method. Therefore, it is recommended to use the litho-based method, instead of or along with traditional optimization approaches, for estimating other geochemical factors as well as petrophysical parameters (i.e. porosity, permeability, hydrocarbon saturation etc.) through log data.

## References

- Alizadeh, B., Maaroufi, K., Heidarifard, M.H., 2013. Evaluation of Organic Matter Content Achieved from Artificial Neural Network in a Sequence Stratigraphic Framework: A Case Study from Pabdeh Formation of Marun Oilfield. *Advanced Applied Geology* 3, 21-30.
- Alizadeh, B., Maroufi, K., Heidarifard, M.H., 2018. Estimating source rock parameters using wireline data: an example from Dezful Embayment, South West of Iran. *Journal of Petroleum Science and Engineering* 167, 857-868. <https://doi.org/10.1016/j.petrol.2017.12.021>.
- Behar, F., Beaumont, V., Penteado, H.L.D.B., 2001. Rock-Eval 6 technology: performances and developments. *Oil & Gas Science and Technology* 56, 111-134. <https://doi.org/10.2516/ogst:2001013>.
- Kadkhodaie-Ilkhchi, A., Rahimpour-Bonab, H., Rezaee, M., 2009. A committee machine with intelligent systems for estimation of total organic carbon content from petrophysical data: An example from Kangan and Dalan reservoirs in South Pars Gas Field, Iran. *Computers & Geosciences* 35, 459-474. <https://doi.org/10.1016/j.cageo.2007.12.007>.
- Passey, Q., Creaney, S., Kulla, J., Moretti, F., Stroud, J., 1990. A practical model for organic richness from porosity and resistivity logs. *AAPG Bulletin* 74, 1777-1794. <https://doi.org/10.1306/0C9B25C9-1710-11D7-8645000102C1865D>.
- Sfidari, E., Kadkhodaie-Ilkhchi, A., Najjari, S., 2012. Comparison of intelligent and statistical clustering approaches to predicting total organic carbon using intelligent systems. *Journal of Petroleum Science and Engineering* 86, 190-205. <https://doi.org/10.1016/j.petrol.2012.03.024>.

### HOW TO CITE THIS ARTICLE:

Maroufi, Kh , Zahmatkesh, I., 2023. Accurate estimation of residual hydrocarbon potential by removing the adverse effects of lithological variations on the training process of adaptive neuro-fuzzy inference system. *Adv. Appl. Geol.* 13(1), 278-298.

DOI :10.22055/AAG.2022.41534.2306

URL: [https://aag.scu.ac.ir/article\\_17992.html](https://aag.scu.ac.ir/article_17992.html)

©2023 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers

## تخمین کارآمد پتانسیل هیدروکربنی باقیمانده با حذف اثرات نامطلوب تغییرات سنگ‌شناسی بر روند آموزش سیستم استنتاج عصبی - فازی تطبیقی

خالد معروفی\*

دانشکده مهندسی نفت و گاز، دانشگاه صنعتی سهند، تبریز، ایران

ایمان زحمت‌کش

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

\*maroufi@sut.ac.ir

تاریخ دریافت: ۱۴۰۱/۰۵/۱۲ تاریخ پذیرش: ۱۴۰۱/۰۶/۲۰

### چکیده

با رونق اکتشاف و توسعه منابع هیدروکربنی نامتعارف، تخمین دقیق فاکتورهای وابسته به سنگ منشاء نظیر پتانسیل باقیمانده هیدروکربنی ( $S_2$ ) از طریق نگاره‌های چاه بیش از پیش اهمیت پیدا کرده است. به‌مانند ویژگی‌های مواد آلی، تغییرات سنگ‌شناسی در داخل یک توالی منشاء احتمالی نیز بر روی پاسخ نگاره‌های چاه اثر گذارند. این امکان وجود دارد که تکنیک‌های هوش مصنوعی این پاسخ‌های نگاره‌ای ناشی از سنگ‌شناسی را بعنوان نشانه‌ای از تغییر در میزان و یا ویژگی‌های مواد آلی تفسیر نمایند، که این مهم موجبات کاهش کارایی آنها را مهیا می‌کند. در مطالعه حاضر، روشی جدید تحت عنوان روش مبتنی بر سنگ‌شناسی ارائه شده است که اساس آن بر مدل‌سازی رابطه بین نگاره‌های چاه و پارامتر  $S_2$  برای هر کدام از انواع سنگ‌شناسی از طریق سیستم استنتاج عصبی - فازی تطبیقی (ANFIS) استوار است. کارایی روش پیشنهادی با روش‌های معمول ANFIS و هیبریدی که فرآیند آموزش آنها با استفاده از داده‌های واجد سنگ‌شناسی مختلف انجام شده است، مورد مقایسه قرار گرفت. نتایج نشان داد که روش مبتنی بر سنگ‌شناسی در زمینه حذف اثرات نامطلوب تغییرات سنگ‌شناسی بر روند آموزش مدل ANFIS موفق بوده که حاصل آن، تخمین بسیار دقیقتر مقادیر  $S_2$  می‌باشد. از میان روش‌های معمول، ترکیب الگوریتم بهینه‌سازی ذرات (PSO) با روش ANFIS کارایی بالاتری را نشان داد. لیکن، روش هیبریدی مذکور به اندازه روش مبتنی بر سنگ‌شناسی کارآمد نمی‌باشد. کاربردی بودن روش پیشنهادی با اجرای آن بر روی سازند پایده در یکی از چاه‌های جنوب غرب ایران تایید شد. در نهایت، پیشنهاد می‌شود تا از روش مبتنی بر سنگ‌شناسی جهت تخمین دیگر فاکتورهای ژئوشیمیایی و همچنین پارامترهای پتروفیزیکی از طریق نگاره‌های چاه، بهره گرفته شود.

**واژه‌های کلیدی:** روش مبتنی بر سنگ‌شناسی، سنگ منشاء، پتانسیل باقیمانده هیدروکربنی ( $S_2$ )، الگوریتم‌های فرامکاشفه‌ای، سیستم استنتاج عصبی - فازی تطبیقی

### ۱- مقدمه

یکی از عناصر اصلی جهت شکل‌گیری سیستم نفتی، سنگ منشاء غنی از ماده آلی است. تراوایی اندک سنگ‌های رسوبی ریزدانه نظیر شیل‌ها، مارن‌ها و سنگ آهک‌ها، شرایط لازم را برای محافظت از مواد آلی مهیا کرده و بر همین اساس، این سنگ‌ها عموماً بعنوان سنگ منشاء احتمالی مدنظر قرار می‌گیرند (Tissot and Welte, 1984; Hunt, 1996). روش معمول جهت ارزیابی سنگ‌های منشاء، انجام آزمایش پیرولیز راک‌ایول بر روی خرده‌ها یا مغزه‌های حفاری و تفسیر نتایج حاصله می‌باشد. از جمله پارامترهای مهم حاصل از آزمایش

پیرولیز راک‌ایول، پیک  $S_2$  می‌باشد. در واقع پارامتر یا پیک  $S_2$  مقدار هیدروکربن‌های حاصل از شکست حرارتی کروژن در بازه دمایی ۳۹۰ تا ۶۵۰ درجه سانتی‌گراد و در اتمسفر عاری از اکسیژن را نشان می‌دهد (Behar et al., 2001). بدین‌سان، پیک  $S_2$  معرف توانایی تولید فعلی یا باقیمانده نمونه موردآزمایش بوده و معیاری مهم جهت ارزیابی پتانسیل هیدروکربنی سنگ منشاء می‌باشد. از سوی دیگر، نسبت  $S_2$  به مقدار کل کربن آلی (Total Organic Carbon, TOC) به‌عنوان شاخص هیدروژن (Hydrogen Index) معروف بوده و تعیین‌کننده میزان و نوع هیدروکربن تولیدی از سنگ منشاء می‌باشد. این مهم به نوبه خود اهمیت تعیین پارامتر  $S_2$  را بیش

حاصل از تغییر در مقدار و ویژگی‌های مواد آلی تفکیک کنند، که این مهم پروسه‌ای دشوار است. به عبارتی دیگر، ممکن است پاسخ نگاره‌ها در اثر تغییرات سنگ‌شناسی بعنوان تغییر در ویژگی‌های مواد آلی فرض شود. از سوی دیگر، با افزایش کاربردهای علوم داده در سالهای اخیر، نیاز به داده‌های دقیق‌تر بیش از پیش مورد توجه قرار گرفته است. بر همین اساس، در این مطالعه تلاش شده است تا از طریق روشی جدید، اثر منفی تغییرات سنگ‌شناسی در روند آموزش بهینه سیستم هوشمند از نوع سیستم استنتاج عصبی - فازی تطبیقی (Adaptive Neuro Fuzzy Inference System, ANFIS) حذف شده و در نتیجه، مقادیر دقیق‌تری از پارامتر  $S_2$  از طریق نگاره‌های چاه مورد تخمین قرار گیرد. با توجه به اینکه از الگوریتم‌های فرامکاشف‌های (Metaheuristic algorithms) معمولاً جهت افزایش دقت سنجش پارامترهای وابسته به منشاء و مخزن از طریق سیستم‌های هوشمند بهره گرفته می‌شود، در این مطالعه الگوریتم‌های ژنتیک (Genetic Algorithm, GA) و بهینه‌سازی ازدحام ذرات (Particle Swarm Optimization, PSO) نیز مورد استفاده قرار گرفته و نتایج حاصل از آنها با نتایج روش پیشنهادی مورد مقایسه قرار گرفته است.

## ۲- زمین‌شناسی منطقه

این مطالعه بر روی نمونه‌های سنگ منشاء‌های احتمالی مربوط به ناحیه چین‌خورده زاگرس (فروافتادگی دزفول) انجام گرفته است (شکل ۱). اکثر ذخایر هیدروکربنی ایران در جنوب غرب کشور و در زون چین‌خورده زاگرس واقع شده است و سابقه بیش از ۱۰۰ ساله اکتشاف و تولید در این منطقه موجب شده است تا وضعیت زمین‌شناسی منطقه بخوبی شناخته‌شده باشد (Esrafil-Dizaji and Rahimpour-Bonab, 2019). زون چین‌خورده زاگرس با وجود تاقدیس‌های عظیم و طولیل با راستای عمدتاً شمال‌غربی - جنوب‌شرقی مشخص می‌شود که مخازن متعددی را در خود جای داده‌اند (Miliarensis and Iliopoulou, 2004). وجود توامان تمامی عوامل لازم جهت شکل‌گیری سیستم‌های نفتی نظیر سنگ منشاء غنی و بالغ، سنگ مخزن تراوا و متخلخل، پوش سنگ‌های کارا و تله‌های تاقدیسی موجب گشته تا ناحیه چین‌خورده زاگرس جزو غنی‌ترین نواحی هیدروکربنی دنیا محسوب شود. ذخایر این ناحیه عمدتاً در سازند آسماری به سن الیگومیوسن و گروه‌های بنگستان و خامی به سن کرتاسه تجمع یافته‌اند. توالی‌های مستعد سنگ منشاء از

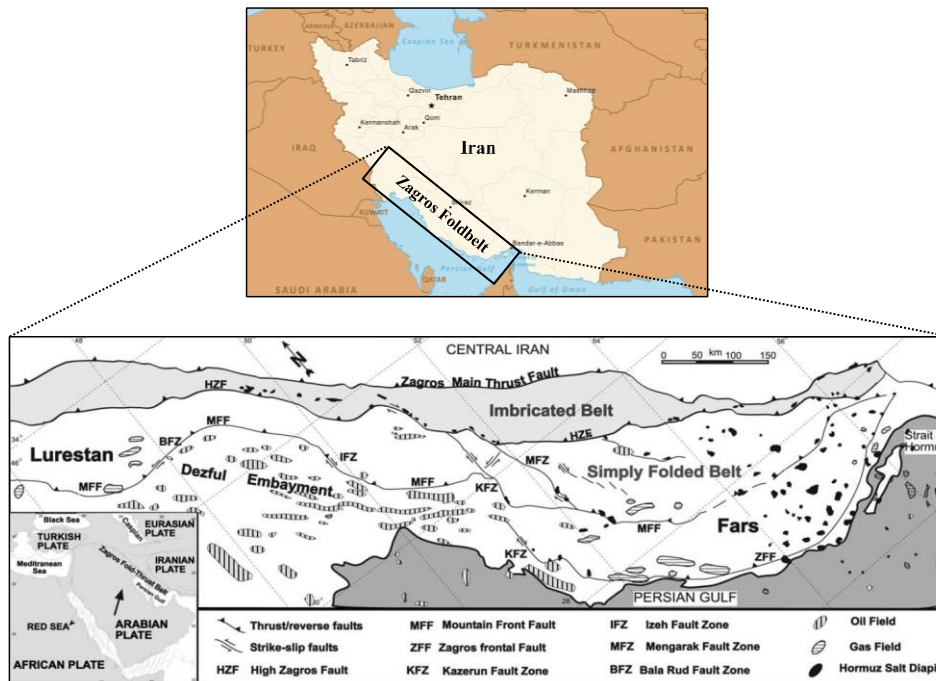
از پیش آشکار می‌کند. با اینحال، انجام آزمایشات ژئوشیمیایی نظیر پیرولیز راک‌ایول هزینه‌بر بوده و نمونه‌های قابل‌اعتماد از توالی‌های مستعد سنگ منشاء نیز همیشه در دسترس نمی‌باشند. بنابراین محققان مختلف تلاش کرده‌اند تا از روش‌های غیرمستقیم و کم‌هزینه جهت ارزیابی سنگ‌های منشاء بهره گیرند.

ویژگی‌های متفاوت مواد آلی نسبت به زمینه کانیایی سنگ‌های واجد آنها نظیر چگالی و سرعت موج صوتی کمتر، و مقاومت الکتریکی (وابسته به بلوغ) و محتوای هیدروژن بیشتر موجب گشته تا حضور این مواد بر روی پاسخ نگاره‌های چاه موثر بوده و بر همین اساس، امکان شناسایی و سنجش پارامترهای وابسته به آنها از طریق این نگاره‌ها میسر گردد (Herron et al., 1992; Luffel et al., 1988; Beers et al., 1945). خاصیت رادیواکتیویته سنگ‌های منشاء را مشخص نمود (Beers, 1945) و از آن زمان تاکنون افراد زیادی تلاش کرده‌اند تا سنگ‌های منشاء را از طریق نگاره‌ها شناسایی کرده و غنای آنها را با استفاده از فرمول‌های تجربی مورد سنجش قرار دهند (نظیر Schmoker, 1981; Mendelson, 1985; Fertl and Chilingar, 1988; Mann and Müller, 1988; Hertzog et al., 1990; Passey et al., 1989). از سوی دیگر، سیستم‌های هوشمند مختلف نظیر شبکه‌های عصبی مصنوعی، منطق فازی، آنالیز رگرسیونی و غیره نیز در چند دهه اخیر در این زمینه مورد استفاده قرار گرفته‌اند و نتایج قابل تاملی نیز فراهم آورده‌اند. با اینحال بیشتر این مطالعات معطوف به سنجش پارامتر TOC بوده‌اند (نظیر Kamali and Mirshady, 2004; Kadkhodaie-Ilkchi et al., 2009; Alizadeh et al., 2012a; Alizadeh et al., 2012b; Sfidari et al., 2012; Alizadeh et al., 2013; Tabatabaei et al., 2015; Alizadeh et al., 2022). برخی از آنها تلاش کرده‌اند تا دیگر فاکتورها نظیر پارامتر  $S_2$  را مورد تخمین قرار دهند (نظیر Alizadeh et al., 2018c; Nezhad et al., 2018; Wang et al., 2019; Kang et al., 2021; Sadeghtabaghi et al., 2021; Safaei-Farouji and Kadkhodaie, 2022).

تغییرات سنگ‌شناسی نیز به مانند تغییر در مقدار و ویژگی‌های مواد آلی بر روی پاسخ نگاره‌ها موثر بوده و این مهم می‌تواند روند آموزش سیستم‌های هوشمند را تحت تاثیر قرار دهد. در واقع، سیستم‌های هوشمند می‌بایست پاسخ نگاره‌ها در اثر تغییرات سنگ‌شناسی در یک توالی سنگ منشاء را از تاثیرات


Bordenave توسط محققان مختلف تشریح شده است (نظیر and Burwood, 1990, 1995; Bordenave and Hegre, 2010; Maroufi et al., 2017; Alizadeh et al., 2018b, (a).

ژوراسیک تا پالئوسن گسترش دارند و شامل سازندهای سرگلو، گرو، کزدمی، گورپی و پابده می‌باشند (شکل ۲). وضعیت ژئوشیمیایی سنگ‌های منشاء و ذخایر حاصل از آنها پیشتر



شکل ۱- جایگاه جغرافیایی و ساختاری ناحیه چین خورده زاگرس و زیرزون‌های آن (اقتباس از Sephr and Cosgrove, 2004).

Fig. 1. Geographic and structural setting of the Zagros fold belt and its sub-zones.



شکل ۲- شماتیک ستون چینه‌شناسی فروافتادگی دزفول شامل سنگ‌های منشاء، مخزن‌ها و پوش سنگ‌ها (Alizadeh et al., 2018a).

Fig. 2. Schematic stratigraphy of the Dezful Embayment including source rocks, reservoirs, and seals.

### ۳- روش کار

نمودار جریانی نحوه انجام مطالعه در قالب شکل ۳ ارائه شده است. بر همین اساس، مطالعه حاضر به شرح زیر انجام گرفت: در ابتدا داده‌های حاصل از آنالیز پیرولیز راکایول بر روی بیش از ۲۰۰ نمونه از سنگ‌منشاءهای ناحیه چین‌خورده زاگرس (میادین اهواز، مارون، کوپال، گچساران، پازنان، مسجدسلیمان، زیلویی و غیره) شامل سازندهای کژدمی، پابده و گورپی جمع‌آوری شده و مقادیر نگاره‌های متناظر با آنها استخراج گردید. سپس داده‌های موجود جهت اطمینان از صحت آنها مورد بررسی قرار گرفتند. نسبت  $S_1/TOC$  جهت اطمینان از عدم آلودگی نمونه‌ها به هیدروکربن‌های نابرجا مورد استفاده قرار گرفت. قرائت‌های نگاره‌ها نیز بررسی شده و مقادیر مربوط به شرایط بد حفرة حفاری از داده‌ها حذف گردید. در نهایت عمق نگاره‌ها با عمق نمونه‌های سنگی از طریق لایه‌های کلیدی منطبق گشت.

پس از اطمینان از صحت داده‌ها، مقادیر هر کدام از نگاره‌های موجود شامل گاما (CGR)، فاکتور جذب فتوالکتریک (PEF)، صوتی (DT)، نوترون (NPHI)، چگالی (RHOB) و مقاومت (LLD) با مقادیر  $S_2$  حاصل از آنالیز پیرولیز در قالب نمودارهای شکل ۴ مقایسه شده و بدین‌سان نگاره‌هایی که رابطه‌ای منطقی با تغییرات پارامتر  $S_2$  نشان دادند، مشخص گشتند. بررسی‌ها نشان داد که رابطه مناسبی مابین تغییرات نگاره‌های PEEF و LLD و نوسانات پارامتر  $S_2$  وجود نداشته و بر همین اساس، داده‌های نهایی این مطالعه شامل ۱۸۴ داده شامل نگاره‌های CGR، DT، NPHI و RHOB، و مقادیر  $S_2$  متناظر با آنها می‌باشد (جدول ۱). توزیع نمونه‌ها برای سازندهای کژدمی، پابده و گورپی به ترتیب ۶۹، ۷۳ و ۴۲ نمونه می‌باشد.

در این مطالعه از روش ANFIS (مدل اولیه) و ترکیب آن با الگوریتم‌های بهینه‌سازی GA و PSO (مدل‌های هیبریدی) جهت سنجش  $S_2$  از طریق نگاره‌های چاه بهره گرفته شد. بدین منظور، ۸۰ درصد داده‌ها جهت آموزش سیستم‌های هوشمند مورد استفاده قرار گرفت و ۲۰ درصد باقیمانده به منظور آزمون مدل‌های ساخته‌شده، انتخاب گردیدند.

در ادامه با مطالعه لاگ‌های زمین‌شناسی سرچاهی و بررسی نگاره‌های چاه، نوع سنگ‌شناسی هر کدام از نمونه‌ها مشخص گردید. بررسی‌ها نشان داد که حدود ۴۰ درصد نمونه‌ها از نوع شیل، ۳۰ درصد آنها از جنس مارن و مابقی سنگ آهک هستند. به منظور افزایش دقت تخمین پارامتر  $S_2$ ، داده‌های دسته‌های آموزش و آزمون (به‌عنوان روشی جدید) بر اساس نوع سنگ‌شناسی به انواع گروه‌های سنگی شامل شیل، مارن و آهک تقسیم‌بندی شده و از روش ANFIS جهت مدلسازی رابطه بین نگاره‌ها و پارامتر  $S_2$  برای هر کدام از گروه‌های سنگی، بصورت مجزا (مدل‌های ANFIS مبتنی بر سنگ‌شناسی یا litho-based models) استفاده شد.

در نهایت، نتایج حاصل از روش مبتنی بر سنگ‌شناسی با روش‌های معمول مقایسه شده و کاربردی بودن روش پیشنهادی با تعمیم آن به سازند پابده در یکی از چاه‌های منطقه، مورد بررسی قرار گرفت.

شایان ذکر است، ارزیابی کارایی مدل‌ها و مقایسه دقت آنها با همدیگر براساس توابع میانگین مربعات خطا (Mean Square Error, MSE)، ریشه میانگین مربعات خطا (Root Mean Square Error, RMSE)، درصد میانگین مطلق خطا (Mean Absolute Percentage Error, MAPE) و ضریب تعیین (Coefficient of Determination,  $R^2$ ) انجام گرفت. فرمول محاسبه این توابع عبارتند از:

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (\text{رابطه ۱})$$

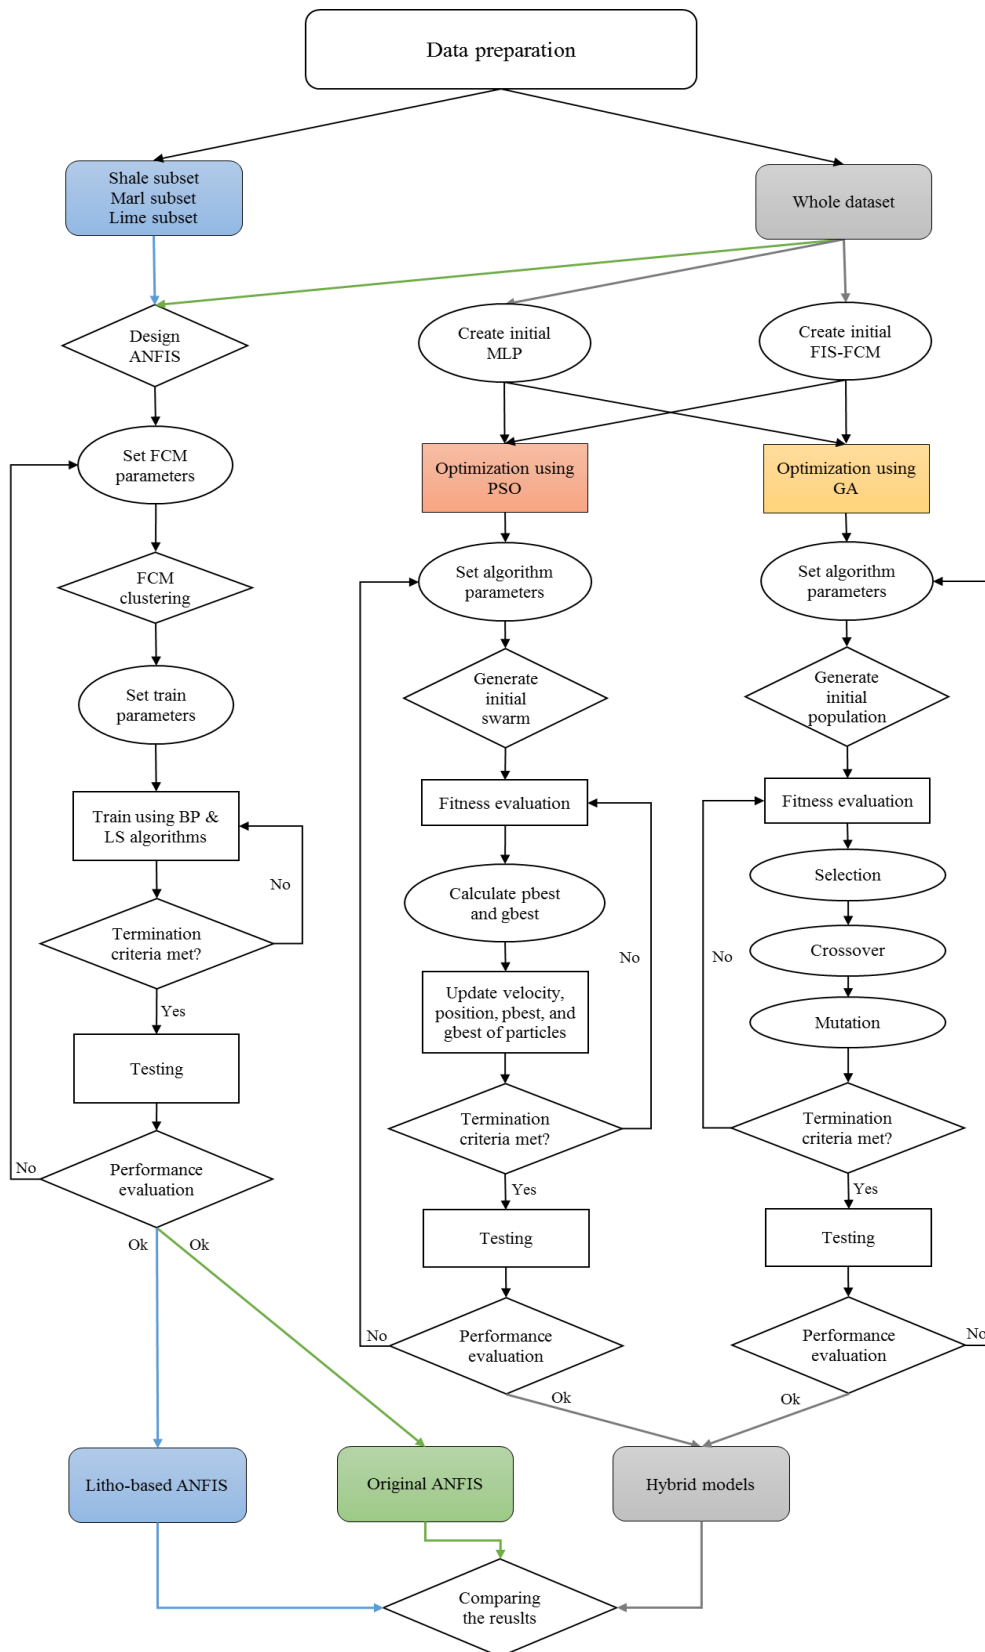
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad (\text{رابطه ۲})$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|t_i - y_i|}{t_i} * 100 \quad (\text{رابطه ۳})$$

$$R^2 = \left( \frac{\sum_{i=1}^N (t_i - \bar{t})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (t_i - \bar{t})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \right)^2 \quad (\text{رابطه ۴})$$

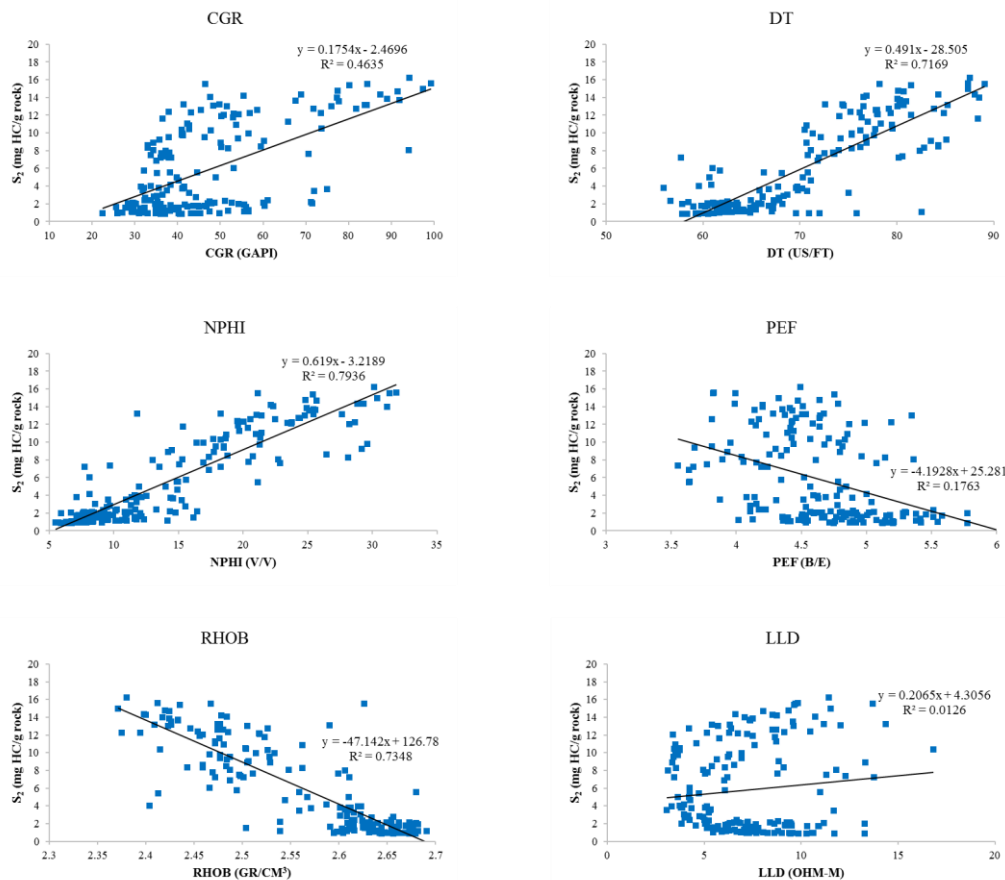
که در آنها،  $t_i$  برابر است با مقدار اندازه‌گیری شده در زمان/مکان  $i$ ،  $y_i$  عبارت است از مقدار تخمین زده‌شده در زمان/مکان  $i$ ،  $\bar{t}$  برابر است با میانگین مقادیر اندازه‌گیری شده،  $\bar{y}$  عبارت است از میانگین مقادیر پیش‌بینی شده و  $N$  تعداد تخمین‌ها را نشان می‌دهد.

در ادامه توضیح مختصری در مورد روش ANFIS و الگوریتم‌های بهینه‌سازی GA و PSO ارائه می‌شود.



شکل ۳- نمودار جریانیه نحوه انجام مطالعه شامل مراحل آماده‌سازی داده‌ها و فرآیند مدل‌سازی.  
 Fig. 3. Flowchart of the study including data preparation and modeling processes.





شکل ۴- نمودارهای متقابل جهت بررسی وجود رابطه مابین انواع نگاره‌ها و مقادیر  $S_2$  حاصل از آزمایش پیرولیز راکابول  
Fig. 4. Cross-plots showing the relationship between well logs and  $S_2$  values derived for Rock-Eval pyrolyzing.

جدول ۱- حداقل، حداکثر، میانگین، میانه و مد برای داده‌های ورودی (نگاره‌ها) و هدف ( $S_2$ ).

**Table 1.** Minimum, maximum, average, median, and mode for the input (well logs) and target data ( $S_2$ ).

Log/Parameter	Minimum	Maximum	Average	Median	Mode
CGR	22.49	99.21	47.13	41.99	30.29
DT	55.97	89.08	69.87	68.00	62.54
NPHI	2.37	2.69	2.57	2.60	2.65
RHOB	5.49	31.86	14.57	11.99	25.46
$S_2$	0.89	16.23	5.80	3.54	0.95

مقادیر حدواسط در نظر گرفته می‌شود، در چهارچوب شبکه‌های عصبی و جهت یافتن حداقل خطا مورد استفاده قرار می‌گیرد. به بیان دیگر، روش ANFIS از مجموعه‌ای از قواعد فازی اگر - آن‌گاه استفاده می‌کند تا میزان ارتباط مابین ورودی‌ها و خروجی‌ها را توصیف نماید (Wang, 2001; Walia et al., 2015). سیستم‌های فازی گوناگون توسط محققان مختلف ارائه شده است (نظیر Mamdani and Assilian, 1975; Tsukamoto, 1979; Takagi and Sugeno, 1983) که

### ۳-۱- سیستم استنتاج عصبی - فازی تطبیقی (ANFIS)

روش ANFIS از ترکیب سیستم استنتاج فازی (Fuzzy Inference System, FIS) با شبکه عصبی مصنوعی (Artificial Neural Network, ANN) حاصل می‌شود (Jang, 1993). در واقع در این روش، اصول سیستم استنتاج فازی که توسط زاده در سال ۱۹۶۵ مطرح شد و در آن بجای مفاهیم کلاسیک خوب و بد، زیاد و کم، بلی و خیر و غیره،

### لایه سوم (Rule strength normalization layer):

خروجی‌های لایه دوم در این لایه نرمال‌سازی می‌شوند.

### لایه چهارم (Rule consequent layer):

تطبیقی موجود در لایه چهارم، خروجی قوانین را براساس پارامترهای نتیجه اگر - آنگاه محاسبه می‌کند.

### لایه پنجم (Rule inference layer):

گره ثابت داشته و خروجی کلی سیستم را با جمع کردن تمامی ورودی‌ها از قوانین مختلف، محاسبه می‌کند.

پیش‌زمینه طراحی یک سیستم ANFIS، خوشه‌بندی داده‌ها به انواع دسته‌های فازی است. روش‌های مختلفی برای خوشه‌بندی داده‌ها وجود دارد که در این مطالعه از روش fuzzy c-means (FCM) استفاده شده است. فرآیند آموزش سیستم‌های ANFIS بر پایه روش TSK معمولاً بوسیله ترکیب الگوریتم‌های Backpropagation (BP) و Least Squares (LS) انجام می‌گیرد.


محبوبترین آنها مدل Takagi-Sugeno-Kang (TSK) است، زیرا این سیستم، مدلسازی روابط در مسائل پیچیده غیرخطی را با تعداد قوانین کمتری امکان‌پذیر می‌سازد (Kukolj, 2002). شماییک ساختار سیستم ANFIS براساس روش TSK برای دو ورودی و یک خروجی در شکل ۵ نمایش داده شده است. همانطور که در شکل مشخص است، چنین سیستمی دارای ۵ لایه به شرح زیر است (Abraham, 2005; Sabah et al., 2019; Yusefzadeh and Nadiri, 2021):

### لایه اول (Fuzzification layer):

تطبیقی می‌باشد و در آن میزان تعلق هر ورودی به هر کدام از دسته‌های فازی بوسیله توابع تعلق (membership functions, MFs) مشخص می‌شود.

### لایه دوم (Rule antecedent layer):

گره‌های ثابتی می‌باشد که قدرت یا وزن هر قانون فازی را مشخص می‌کنند.



شکل ۵- ساختار پایه مدل ANFIS با ۵ لایه بر اساس روش TSK که مرحله خوشه‌بندی آن توسط روش FCM انجام می‌گیرد.

Fig. 5. Basic structure of the 5-layered ANFIS model based on TSK system and FCM clustering.

### ۳-۲- الگوریتم ژنتیک

الگوریتم GA در سال ۱۹۷۵ توسط John Holland به‌عنوان تکنیکی تصادفی جهت بهینه‌سازی سیستم‌های هوشمند با الگوگرفتن از قوانین تکامل موجودات، معرفی شد. در این روش، ابتدا یک مجموعه تصادفی از افراد انتخاب می‌شوند. قابلیت و توانایی هر کدام از افراد جهت حل مساله توسط تابع شایستگی (fitness function) مشخص شده و مسیر تکامل براساس این پارامتر، ترسیم خواهد شد. در طول هر نسل، فرآیندهای انتخاب (selection)، ترکیب یا تقاطع (crossover) و جهش (mutation) بترتیب در مورد هر فرد جامعه به شرح زیر اعمال می‌شود (Velez-Langs, 2005; Sivanandam and Deepa, 2008; Rezakazemi et al., 2017):

**انتخاب:** در این مرحله، افراد با شایستگی بیشتر به‌عنوان بهترین پاسخ‌ها به مسئله موردنظر انتخاب می‌شوند (والدین).

**ترکیب:** طی این مرحله، والدین شایسته جهت تولید فرزندان جدید با هم ترکیب می‌شوند.  
**جهش:** این عملگر تغییراتی جزئی را جهت ایجاد تنوع ژنتیکی به فرزندان جدید اعمال می‌کند.  
 در نهایت شایستگی فرزندان جدید ارزیابی شده و در صورت برتری نسبت به والدین، جایگزین آنها می‌شوند. فرآیند مذکور بصورت مکرر ادامه یافته تا نتیجه دلخواه حاصل آید (Saemi et al., 2007; Sivanandam and Deepa, 2008).

### ۳-۳- الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم PSO نیز به مانند الگوریتم ژنتیک از طبیعت الهام گرفته شده است. این الگوریتم اولین بار توسط Kennedy و Eberhart در سال ۱۹۹۵ به منظور بهینه‌سازی توابع غیرخطی ابداع شد (Kennedy and Eberhart, 1995). روش PSO تلاش می‌کند تا فرآیند اشتراک اطلاعات در گروه‌های جانوری نظیر پرندگان در مسائلی نظیر یافتن غذا را به منظور حل مسائل پیچیده، شبیه‌سازی نماید. در این الگوریتم نیز ابتدا ازدحامی (swarm) از ذرات (particles) به عنوان راه‌حلی برای حل مسئله مورد نظر تشکیل شده و سپس توانایی هر ذره برای حل مسئله، بوسیله موقعیت و سرعت آن ذره مشخص می‌گردد. در ادامه، الگوریتم تلاش می‌کند تا با تغییر پی‌درپی موقعیت ذرات در فضای جستجو براساس بهترین موقعیت هر ذره (pbest) و بهترین موقعیت ازدحام (gbest)، سیستم را بهینه‌سازی نماید. فرآیند مذکور تا دستیابی به نتایج دلخواه ادامه می‌یابد (Trelea, 2003; Mousazadeh et al., 2021).

جدول ۲- پارامترهای بهینه جهت آموزش مدل‌های هیبریدی ANFIS-PSO و ANFIS-GA

Table 2. Optimum parameters for training of ANFIS-GA and ANFIS-PSO hybrid models.

ANFIS -GA		ANFIS -PSO	
Parameter	Value	Parameter	Value
Number of MFs	7	Number of MFs	8
Population size	80	Swarm size	85
Maximum number of iterations	400	Maximum number of iterations	400
Crossover percentage	60%	Cognition coefficient ( $C_1$ )	1.9
Mutation percentage	20%	Social coefficient ( $C_2$ )	1.9
Mutation rate	0.1	Inertia weight	0.65

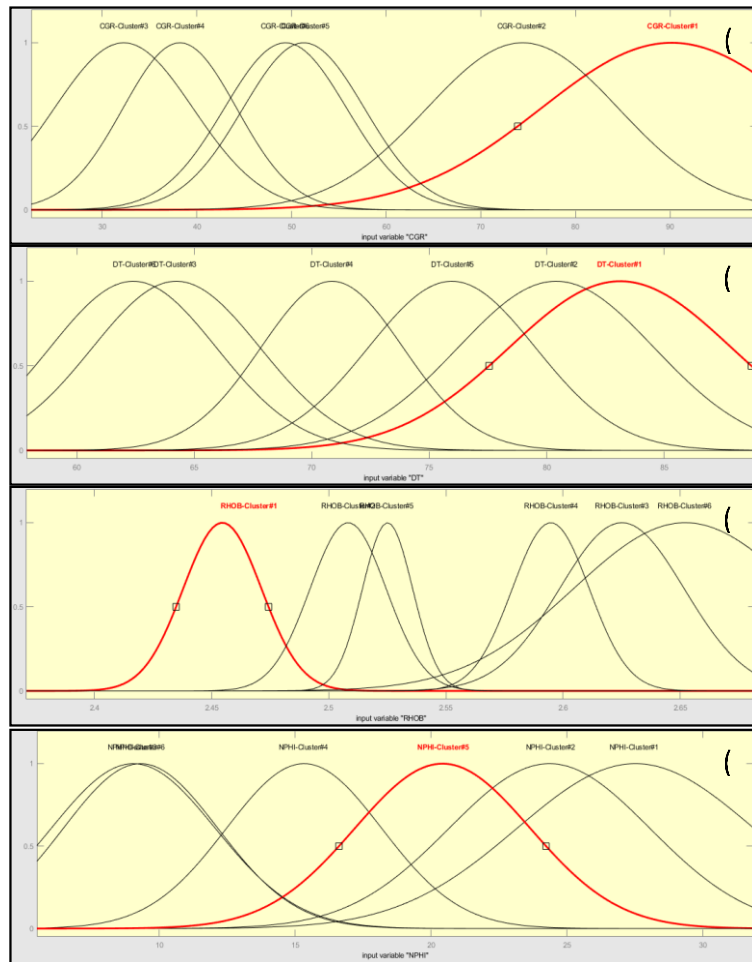
مقادیر تخمین‌زده شده توسط مدل با مقادیر سنجیده شده بوسیله آنالیز پیرولیز راکایول در قالب شکل ۷ مقایسه شده‌اند. همانطور که در شکل مشخص است، روند تغییرات مقادیر تخمین‌زده شده توسط مدل مشابه با روند تغییرات داده‌های واقعی است. ضمناً دقت مدل در زمینه تخمین پارامتر  $S_2$  برای داده‌های دسته آزمون نسبتاً خوب بوده و این مهم نشان از آموزش مناسب سیستم ANFIS طراحی شده دارد. در کل، با توجه به تابع ضریب تعیین و همچنین توابع خطای محاسبه شده برای سیستم (شکل ۷ و جدول ۳)، عملکرد مدل ANFIS آموزش‌یافته بوسیله نمونه‌های با سنگ‌شناسی مختلف (تمامی داده‌ها)، مناسب می‌باشد. با اینحال، بهره‌گیری از روش‌های بهینه‌سازی و همچنین مدل‌های مبتنی بر سنگ‌شناسی می‌تواند دقت تخمین‌ها را افزایش دهد.

### ۴- بحث

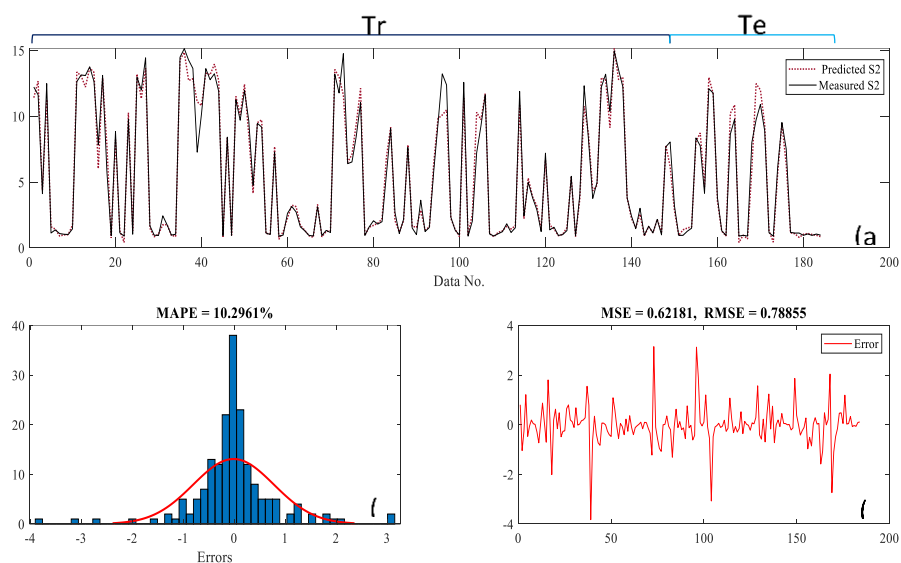
#### ۴-۱- تخمین پارامتر $S_2$ با استفاده از مدل ANFIS

#### اولیه

همانطور که پیش‌تر عنوان شد، از تمامی داده‌های موجود جهت ساخت مدلی از نوع ANFIS برای سنجش پارامتر  $S_2$  از طریق نگاره‌های منتخب استفاده شد. مدل ANFIS طراحی شده از نوع TSK بوده و خوشه‌بندی اولیه آن بر اساس روش FCM انجام گرفت. نوع توابع عضویت برای داده‌های ورودی از نوع گوسی (Gaussian) و برای داده‌های خروجی از نوع خطی (Linear) انتخاب شد. پس از آزمون سیستم با تعداد خوشه‌های مختلف مشخص شد که تعداد ۶ خوشه بهترین نتیجه را مهیا می‌کند (شکل ۶). فرآیند آموزش بوسیله ترکیب الگوریتم‌های BP و LS انجام گرفت و حداکثر تعداد تکرارها، ۴۰۰ تعیین شد.



شکل ۶- توابع عضویت حاصل از روش FCM برای نگاره‌های (a) CGR، (b) DT، (c) RHOB و (d) NPHI جهت سنجش مقادیر  $S_2$  توسط مدل ANFIS اولیه.  
 Fig. 6. FCM-derived MFs for CGR (a), DT (b), RHOB (c), and NPHI (d) logs to estimate  $S_2$  using original ANFIS model.



شکل ۷- مقایسه مقادیر  $S_2$  تخمین زده شده توسط مدل ANFIS اولیه با داده‌های واقعی (a)، میزان خطا (b) و هیستوگرام خطای آنها (c).  
 Fig. 7. Comparison of the predicted  $S_2$  values by original ANFIS model with the real data (a), and their corresponding errors (b) and error histogram (c).


بدین مهم از روش آزمون و خطا استفاده شد. جدول ۲، پارامترها و فاکتورهای بهینه انتخابی جهت آموزش مدل‌های هیبریدی را نشان می‌دهد.

نتایج حاصل از آموزش مدل‌های ANFIS-GA و ANFIS-PSO در قالب جدول ۳ و شکل‌های ۸ و ۹ ارائه شده‌اند. با توجه به توابع خطای محاسبه‌شده برای این مدل‌ها، استفاده از الگوریتم ژنتیک جهت بهبود کارایی روش ANFIS مثرتر نبوده و آموزش سیستم با این مدل نه تنها دقت را افزایش نداده است بلکه آن را کاهش داده است (MSE: ۰,۹۲۲، RMSE: ۰,۹۶، MAPE: ۱۳,۷۶ و  $R^2$ : ۰,۹۴ برای دسته آزمون). این مهم در حالی است که روند بهینه‌سازی مدل ANFIS توسط الگوریتم PSO تا حدودی موفقیت آمیز بوده و دقت تخمین‌ها نسبت به مدل معمول ANFIS، افزایش یافته است (MSE: ۰,۶۶۵، RMSE: ۰,۸۱۵، MAPE: ۹,۶۱ و  $R^2$ : ۰,۹۷ برای دسته آزمون). با اینحال، این افزایش کارایی چندان محسوس نبوده و کماکان میزان خطای سیستم غیرقابل اغماض می‌باشد.

#### ۴-۲- تخمین پارامتر $S_2$ با استفاده از مدل‌های هیبریدی

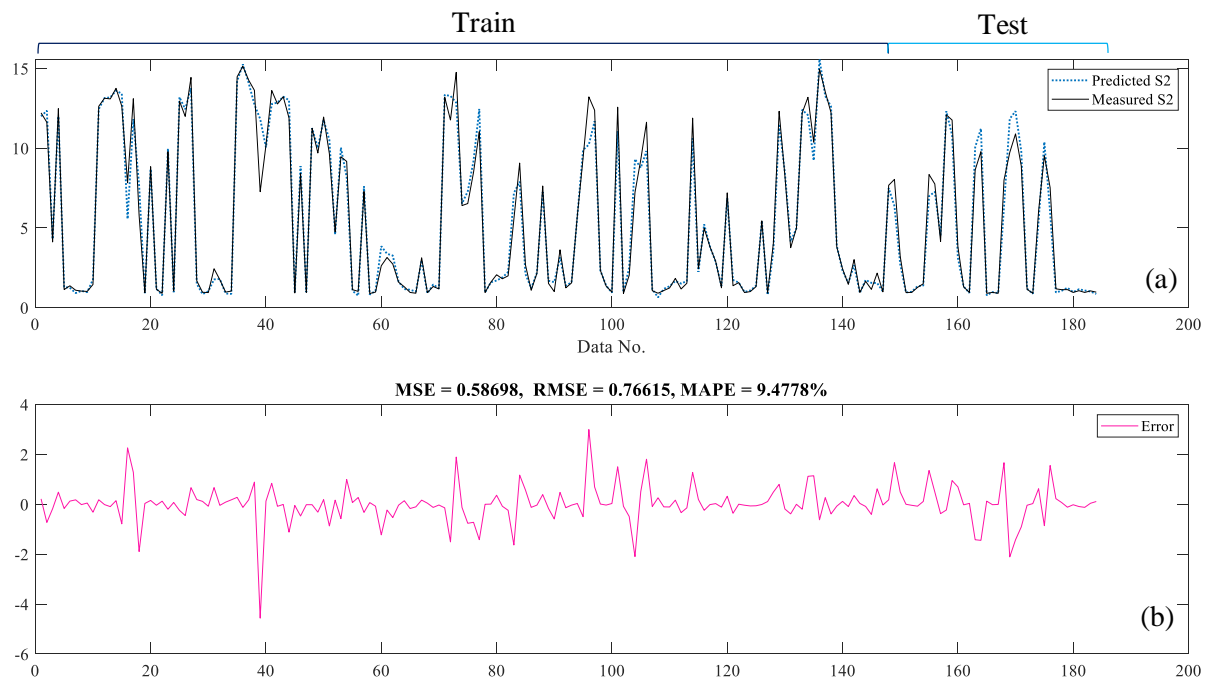
با توجه به اینکه محققان مختلف از الگوریتم‌های فرامکاشف‌های جهت افزایش دقت سیستم‌های هوشمند کلاسیک در مطالعات نفتی استفاده کرده‌اند (نظیر Chamkalani et al., 2014; Madoliat et al., 2017; Zahmatkesh et al., 2017; Fattahi, 2019; Zahmatkesh et al., 2020; (Mohsenipour et al., 2021; Mousazadeh et al., 2021 در این مطالعه نیز از ترکیب الگوریتم‌های GA و PSO با سیستم ANFIS (مدل‌های ANFIS-GA و ANFIS-PSO) به منظور افزایش دقت سنجش پارامتر  $S_2$  از طریق نگاره‌ها استفاده شد. در واقع، هر کدام از الگوریتم‌های نامبرده بصورت جداگانه جهت تنظیم دقیق متغیرهای پیش‌آیند (antecedent variables) و پس‌آیند (consequent variables) مربوط به روش ANFIS بکار گرفته شدند.

فرآیند بهینه‌سازی مدل از طریق الگوریتم‌های نامبرده شدیداً وابسته به تعیین مقادیر مناسب برای پارامترهای آنها (شامل اندازه جمعیت، درصد ترکیب، درصد جهش و غیره برای الگوریتم GA و اندازه ازدحام، ضرایب یادگیری و جامعه برای الگوریتم PSO) و همچنین فاکتورهای آموزش است. برای نیل



شکل ۸- مقایسه مقادیر  $S_2$  تخمین‌زده‌شده توسط مدل ANFIS-GA با داده‌های واقعی (a) و میزان خطا آنها (b).

Fig. 8. Comparison of the predicted  $S_2$  values by ANFIS-GA model with the real data (a) and their corresponding errors (b).



شکل ۹- مقایسه مقادیر  $S_2$  تخمین زده شده توسط مدل ANFIS-PSO با داده‌های واقعی (a) و میزان خطا (b).

Fig. 9. Comparison of the predicted  $S_2$  values by ANFIS-PSO model with the real data (a) and their corresponding errors.

مدل ANFIS اولیه در نظر گرفته شد.

همانطور که در جدول ۳ و شکل ۱۰ مشخص است، روش مبتنی بر سنگ‌شناسی میزان خطا را به مقدار زیادی کاهش داده است (مقدار کل MSE: ۰,۲۱۶، RMSE: ۰,۴۶۵، MAPE: ۶,۷۳ و  $R^2$ : ۰,۹۸۶ برای دسته آزمون). در واقع، با حذف اثر تغییرات سنگ‌شناسی بر روند آموزش مدل ANFIS، امکان مدل‌سازی دقیق‌تر رابطه بین نگاره‌ها و پارامتر  $S_2$  مهیا شده و کارایی مدل‌ها افزایش یافته است. این افزایش دقت خصوصاً در مورد دسته‌های سنگی مارن و سنگ آهک بیشتر بوده و انطباق تقریباً کامل مقادیر تخمین‌زده شده با مقادیر واقعی پارامتر  $S_2$  در شکل ۱۰ موید این مهم است. شایان ذکر است که تابع خطای MAPE معیار مناسب‌تری جهت مقایسه دقت مدل‌های مبتنی بر سنگ‌شناسی می‌باشد زیرا مقدار این تابع به بزرگی داده‌ها وابسته نیست. برعکس، توابع MSE و RMSE وابسته به مقدار یا بزرگی داده‌ها بوده و بر همین اساس، با کاهش مقدار  $S_2$  از شیل به مارن و سپس سنگ آهک، به‌شدت کاهش یافته‌اند.

#### ۴-۳- تخمین پارامتر $S_2$ با استفاده از مدل‌های ANFIS

##### مبتنی بر سنگ‌شناسی

همانطور که پیشتر مشخص شد، مدل ANFIS اولیه با اینکه نتایج نسبتاً خوبی مهیا نمود، اما با میزان خطای قابل‌ملاحظه‌ای نیز همراه بود. از سوی دیگر، الگوریتم‌های فرامکاشفه‌ای نیز نتوانستند خطای سیستم را به میزان قابل‌توجهی کاهش دهند. بر همین اساس، روش مبتنی بر لیتولوژی (litho-based method) به‌منظور حذف اثر نامطلوب تغییرات سنگ‌شناسی بر روند آموزش مدل ANFIS در زمینه سنجش  $S_2$  و در نتیجه، افزایش دقت تخمین‌ها مورد استفاده قرار گرفت. برای نیل بدین مهم، رابطه مابین نگاره‌ها و پارامتر  $S_2$  برای هر کدام از گروه‌های سنگی بصورت جداگانه توسط روش ANFIS مدل‌سازی شد. تعداد داده‌های موجود برای گروه‌های سنگی شیل، مارن و سنگ آهک برتیب ۶۹، ۵۹ و ۵۶ داده می‌باشد. براساس روش آزمون و خطا، تعداد ۶، ۵ و ۶ خوشه بترتیب برای گروه‌های سنگی مذکور، بهترین نتایج را فراهم آورد. مابقی پارامترها مشابه با

جدول ۳- توابع خطا براساس مقایسه مقادیر  $S_2$  تخمین زده شده توسط مدل های مختلف با مقادیر واقعی حاصل از پیرولیز راک ایول.

Table 3. The error functions comparing the estimated  $S_2$  values from different models with those of the Rock-Eval pyrolysis.<sup>a</sup>

Model	Train				Test				
	MSE	RMSE	MAPE	R <sup>2</sup>	MSE	RMSE	MAPE	R <sup>2</sup>	
Original ANFIS	0.608	0.780	10.01	0.975	0.677	0.823	11.42	0.964	
Hybrid	ANFIS-GA	0.656	0.810	11.59	0.973	0.922	0.960	13.76	0.945
	ANFIS-PSO	0.567	0.753	9.45	0.976	0.665	0.815	9.61	0.968
Litho-based ANFIS	ANFIS-shale	0.697	0.835	6.51	0.932	0.487	0.698	7.88	0.884
	ANFIS-marl	0.158	0.398	5.86	0.986	0.065	0.255	6.18	0.997
	ANFIS-lime	0.007	0.082	4.87	0.990	0.007	0.083	5.76	0.986
Overall	0.328	0.573	5.82	0.987	0.216	0.465	6.73	0.986	

<sup>a</sup> MSE = Mean Squared Error, RMSE = Root Mean Squared Error; MAPE = Mean Absolute Percentage Error, R<sup>2</sup> = Coefficient of Determination

جدول ۴- مقادیر  $S_2$  تخمین زده شده برای سازند پابده در یکی از چاه های جنوب غرب ایران با استفاده از مدل های آموزش دیده ANFIS اولیه، ANFIS-PSO و ANFIS مبتنی بر سنگ شناسی. جهت ارزیابی مجدد کارایی روش مبتنی بر سنگ شناسی، این نتایج با داده های واقعی مورد مقایسه قرار گرفته اند.

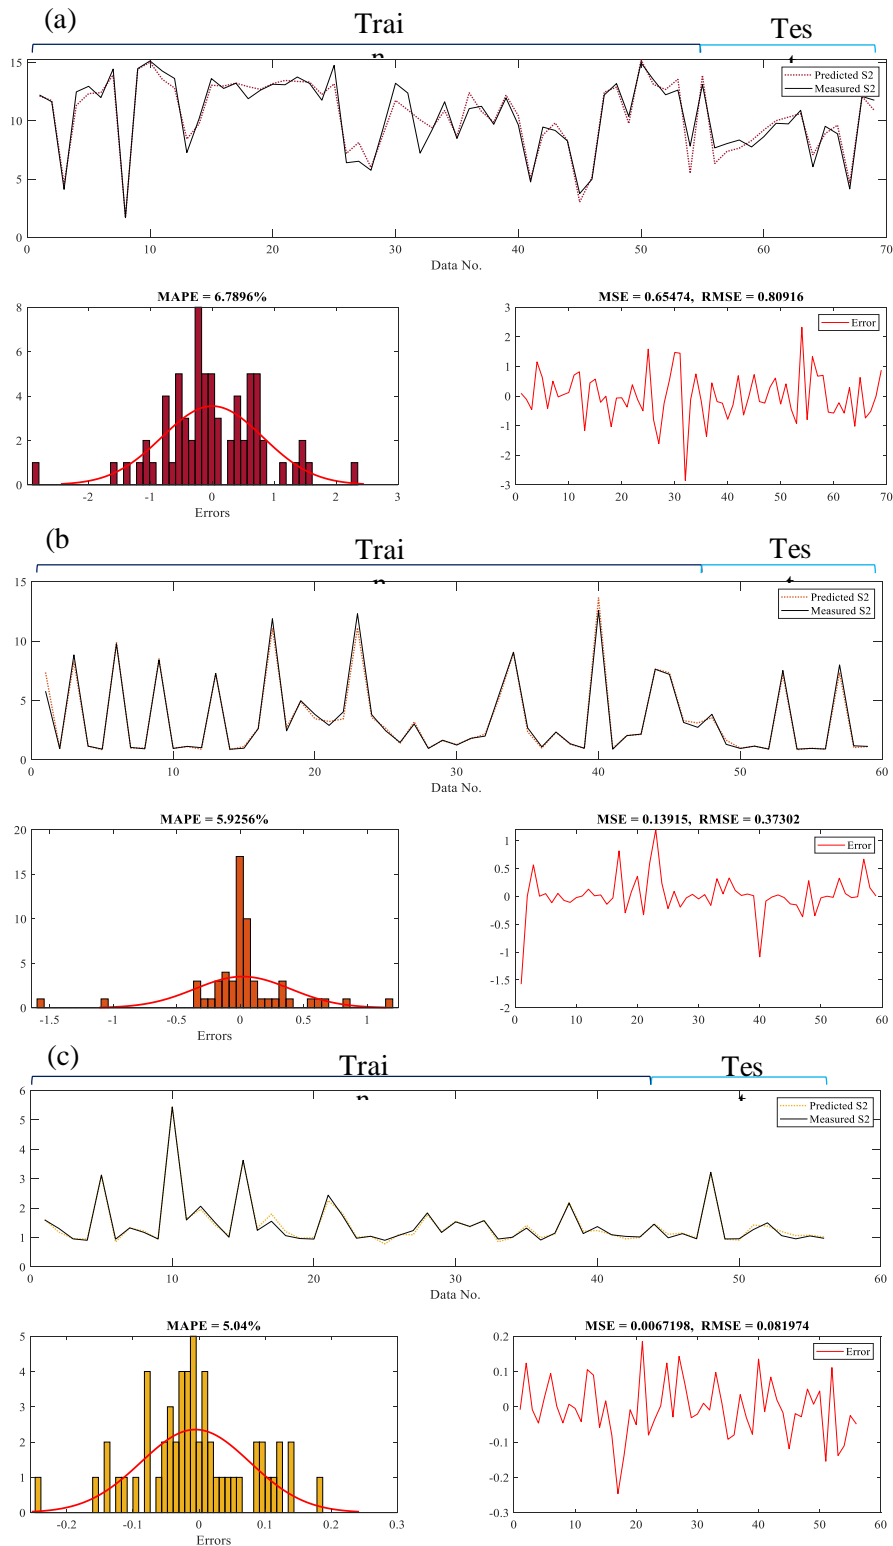
Table 4. The predicted  $S_2$  values for the Pabdeh Formation in a well from SW Iran using the trained original-ANFIS, ANFIS-PSO and litho-based-ANFIS models. The results are compared with the measured data in order to retest applicability of the proposed litho-based method.

Depth (m)	Measured $S_2$ (mg HC/gr rock)	Predicted $S_2$ (mg HC/gr rock)		
		Original ANFIS	ANFIS-PSO	Litho-based ANFIS
2812	1.18	0.98	1.11	1.14
2833	10.5	11.96	11.91	9.89
2852	16.31	15.33	15.67	15.65
2882	6.06	7.23	6.31	6.25
2918	9.26	8.95	10.66	10.52
2945	2.78	3.11	2.28	2.51
2964	1.1	1.05	0.86	0.98
2981	4.13	3.45	3.68	4.65
2985	1.74	2.03	2.07	1.71
2994	1.02	1.14	1.05	1.07
	MSE:	0.528	0.506	0.281
	RMSE:	0.727	0.712	0.530
	MAPE:	12.01	11.57	7.02
	R <sup>2</sup> :	0.978	0.982	0.988

مدل های آموزش یافته، مورد تخمین و ارزیابی قرار گرفت. بدین منظور، ابتدا مدل های ANFIS اولیه، ANFIS-PSO و ANFIS مبتنی بر سنگ شناسی جهت تخمین مقادیر  $S_2$  برای سازند مذکور مورد استفاده قرار گرفتند. سپس ۱۰ نمونه از چاه

#### ۴-۴- مطالعه موردی


به منظور سنجش مجدد کارایی روش پیشنهادی مبتنی بر سنگ شناسی و اطمینان از کاربردی بودن آن، پتانسیل تولیدی سازند پابده در یکی از چاه های جنوب غرب کشور توسط



شکل ۱۰- مقایسه مقادیر  $S_2$  تخمین زده شده توسط مدل ANFIS مبتنی بر سنگ شناسی با داده های واقعی و میزان و هیستوگرام خطای آنها برای زیردسته های شیل (a)، مارن (b) و سنگ آهک (c).

Fig. 10. Comparison of the predicted  $S_2$  values by litho-based-ANFIS method with the real data, and their errors and error histograms for shale (a), marl (b), and limestone (c) sub-datasets.





شکل ۱۱- لاگ S<sub>2</sub> تخمین زده شده بوسیله روش ANFIS مبتنی بر سنگ شناسی برای سازند پابده در یکی از چاه های جنوب غرب ایران.

Fig. 11. Predicted S<sub>2</sub> log using the litho-based method for the Pabdeh Formation in a well from SW Iran.

GA و PSO به منظور بهینه‌سازی مدل ANFIS طراحی شده، بهره گرفته شد. بررسی‌ها مشخص نمود که الگوریتم PSO از توانایی نسبتاً مناسبی جهت افزایش کارایی مدل ساخته شده برخوردار است. در واقع، آموزش متغیرهای وابسته به سیستم ANFIS بوسیله الگوریتم PSO خطای سیستم را کاهش داد، لیکن این کاهش خطا چشمگیر نمی‌باشد. برعکس، ترکیب الگوریتم GA با روش ANFIS نتایج قابل قبولی فراهم نمود. به‌عنوان روشی نوین، در این مطالعه روش مبتنی بر سنگ‌شناسی معرفی و مورد استفاده قرار گرفت. در این روش، داده‌های موجود براساس نوع سنگ‌شناسی به انواع دسته‌های شیل، مارن و سنگ آهک تقسیم شده و برای هر کدام از گروه‌ها، مدلی از نوع ANFIS طراحی و آموزش داده شد. نتایج نشان داد که بهره‌گیری از روش مبتنی بر سنگ‌شناسی با حذف اثر نامطلوب تغییرات سنگ‌شناسی بر روند آموزش سیستم‌های هوشمند، کارایی مدل‌ها را به مقدار مطلوبی افزایش می‌دهد، بطوریکه امکان تخمین بسیار دقیق پارامتر  $S_2$  از طریق نگاره‌ها میسر گشت (مقدار کل MSE: ۰,۲۱۶ ، RMSE: ۰,۴۶۵، MAPE: ۶,۷۳ و  $R^2$ : ۰,۹۸۶ برای دسته آزمون). کاربردی بودن روش پیشنهادی با استفاده از آن جهت سنجش پارامتر  $S_2$  و ارزیابی وضعیت پتانسیل هیدروکربنی فعلی سنگ منشاء پایده در یکی از چاه‌های جنوب غرب کشور مورد تایید قرار گرفت. در نهایت پیشنهاد می‌شود تا از روش مبتنی بر سنگ‌شناسی جهت سنجش دیگر پارامترهای وابسته به منشاء و مخزن از طریق نگاره‌ها نیز بهره گرفته شود.

#### قدردانی

نویسندگان مقاله بر خود لازم می‌دانند تا از همکاری بی‌شائبه مرکز پژوهشی زمین‌شناسی و زمین‌شیمی نفت دانشگاه شهید چمران اهواز در زمینه انجام آزمایشات و همچنین بخش ژئوشیمی آلی شرکت ملی مناطق نفت‌خیز جنوب به سبب در اختیار گذاشتن داده‌ها، تشکر و قدردانی نمایند.

موردنظر انتخاب شده و مقادیر  $S_2$  واقعی آنها از طریق آزمایش پیرولیز راکابول مورد سنجش قرار گرفت (این داده‌ها در روند آموزش مدل‌ها استفاده نشده‌اند). نتایج حاصله در قالب جدول ۴ ارائه شده است. مقایسه مقادیر تخمین‌زده شده توسط مدل‌ها با داده‌های واقعی، کارایی بالای روش مبتنی بر سنگ‌شناسی را مجدداً اثبات نموده و اطمینان لازم جهت استفاده از نتایج آن را، فراهم آورد.

بررسی‌ها نشان داد که مقدار پارامتر  $S_2$  در سازند پایده برای این چاه از ۰,۵ تا ۱۷,۶ میلی‌گرم هیدروکربن بر گرم سنگ متغیر است (میانگین: ۶,۱۴). براساس لاگ  $S_2$  تخمین‌زده شده توسط روش مبتنی بر سنگ‌شناسی (شکل ۱۱)، پتانسیل هیدروکربنی فعلی این سازند معطوف به بخش میانی آن بوده و این بخش که بیشتر شیلی می‌باشد، از توانایی بالایی جهت تولید هیدروکربن (در صورت رسیدن به بلوغ کافی) برخوردار است. در واقع، سازند پایده را می‌توان براساس نوسانات پارامتر  $S_2$  به ۳ بخش بالایی، میانی و پایینی تقسیم نمود. میزان پارامتر  $S_2$  برای بخش‌های بالایی و پایینی کمتر از ۵ بوده و برای بخش میانی عمدتاً بیشتر از ۵ می‌باشد. به نظر می‌رسد که شیلی بودن و پتانسیل هیدروکربنی بالای بخش میانی سازند پایده معلول افزایش سطح تراز آب دریا در زمان ائوسن میانی - پسین بوده است. در واقع افزایش تراز آب دریا، امکان تولید بیشتر مواد آلی و محافظت از آنها را با گسترش لایه حداقل اکسیژن (oxygen - minimum layer) مهیا نموده است.

#### ۵- نتیجه‌گیری

مطالعه حاضر با هدف تخمین دقیق پارامتر  $S_2$  با استفاده از نگاره‌ها انجام گرفت. بدین منظور ابتدا از تمامی داده‌های موجود با سنگ‌شناسی مختلف جهت ساخت مدلی از نوع ANFIS براساس روش TSK استفاده شد. نتایج نشان داد که شبکه ANFIS آموزش دیده علیرغم کارایی مناسب در زمینه تخمین پارامتر  $S_2$ ، با مقادیر خطای غیرقابل اغماض نیز همراه می‌باشد. بر همین اساس و جهت افزایش دقت سیستم، از الگوریتم‌های

#### مراجع

- Abraham, A., 2005. Adaptation of fuzzy inference system using neural learning. In: Nedjah, N., Macedo Mourelle, L. (Eds.), Fuzzy Systems Engineering. Studies in Fuzziness and Soft Computing. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/11339366\\_3](https://doi.org/10.1007/11339366_3).
- Alizadeh, B., Maarooft, K., Heidarfard, M., 2012a. Validation and comparison of artificial neural network (ANN) and  $\Delta\text{LogR}$  techniques in evaluating organic matter content of source rocks: Case study from

- Pabdeh Formation, Marun oilfield. *Journal of Stratigraphy and Sedimentology Researches* 28, 1-18. <https://doi.org/20.1001.1.20087888.1391.28.3.1.8>.
- Alizadeh, B., Maaroufi, K., Heidarifard, M.H., 2013. Evaluation of Organic Matter Content Achieved from Artificial Neural Network in a Sequence Stratigraphic Framework: A Case Study from Pabdeh Formation of Marun Oilfield. *Advanced Applied Geology* 3, 21-30.
- Alizadeh, B., Maroufi, K., Fajrak, M., 2018a. Hydrocarbon reserves of Gachsaran oilfield, SW Iran: Geochemical characteristics and origin. *Marine and Petroleum Geology* 92, 308-318. <https://doi.org/10.1016/j.marpetgeo.2017.08.040>.
- Alizadeh, B., Maroufi, K., Fajrak, M., 2018b. Oil-oil correlation, geochemical characteristics, and origin of hydrocarbons from Mansourabad oilfield, SW Iran. *Journal of African Earth Sciences* 147, 383-392. <https://doi.org/10.1016/j.jafrearsci.2018.06.008>.
- Alizadeh, B., Maroufi, K., Heidarifard, M.H., 2018c. Estimating source rock parameters using wireline data: an example from Dezful Embayment, South West of Iran. *Journal of Petroleum Science and Engineering* 167, 857-868. <https://doi.org/10.1016/j.petrol.2017.12.021>.
- Alizadeh, B., Najjari, S., Kadkhodaie-Ilkhchi, A., 2012b. Artificial neural network modeling and cluster analysis for organic facies and burial history estimation using well log data: A case study of the South Pars Gas Field, Persian Gulf, Iran. *Computers & Geosciences* 45, 261-269. <https://doi.org/10.1016/j.cageo.2011.11.024>.
- Alizadeh, B., Seyedali, S.R., Zahmatkesh, I., Sarafdokht, H., 2022. Applying artificial intelligent and empirical techniques for prediction of total organic carbon content from wireline data: A case study from Pabdeh Formation in Mansuri oilfield, SW Iran. *Petroleum Science and Technology* 40, 1-17. <https://doi.org/10.1080/10916466.2021.1945626>.
- Beers, R.F., 1945. Radioactivity and organic content of some Paleozoic shales. *AAPG Bulletin* 29, 1-22. <https://doi.org/10.1306/10.1306/3D933700-16B1-11D7-8645000102C1865D>.
- Behar, F., Beaumont, V., Pentead, H.L.D.B., 2001. Rock-Eval 6 technology: performances and developments. *Oil & Gas Science and Technology* 56, 111-134. <https://doi.org/10.2516/ogst:2001013>.
- Bordenave, M.L., Burwood, R., 1990. Source rock distribution and maturation in the Zagros orogenic belt: provenance of the Asmari and Bangestan reservoir oil accumulations. *Organic Geochemistry* 16, 369-387. [https://doi.org/10.1016/0146-6380\(90\)90055-5](https://doi.org/10.1016/0146-6380(90)90055-5).
- Bordenave, M.L., Burwood, R., 1995. The Albian Kazhdumi Formation of the Dezful Embayment, Iran: one of the most efficient petroleum generating systems. In: Katz, B.J. (Ed.), *Petroleum Source Rocks*. Springer, pp. 183-207. <https://doi.org/10.1007/978-3-642-78911-3-11>.
- Bordenave, M.L., Hegre, J.A., 2010. Current distribution of oil and gas fields in the Zagros Fold Belt of Iran and contiguous offshore as the result of the petroleum systems. *Geological Society, London, Special Publications* 330, 291-353. <https://doi.org/10.1144/SP330.14>.
- Chamkalani, A., Zendejboudi, S., Bahadori, A., Kharrat, R., Chamkalani, R., James, L., Chatzis, I., 2014. Integration of LSSVM technique with PSO to determine asphaltene deposition. *Journal of Petroleum Science and Engineering* 124, 243-253. <https://doi.org/10.1016/j.petrol.2014.10.001>.
- Esfarili-Dizaji, B., Rahimpour-Bonab, H., 2019. Carbonate reservoir rocks at giant oil and gas fields in SW Iran and the adjacent offshore: A review of stratigraphic occurrence and poro-perm characteristics. *Journal of Petroleum Geology* 42, 343-370. <https://doi.org/10.1111/jpg.12741>.
- Fattahi, H., 2019. Prediction of porosity in a carbonate reservoir using hybrid simulated annealing algorithm with artificial neural network-A case study. *Advanced Applied Geology* 8, 48-58. <https://doi.org/10.22055/AAG.2019.26801.1884>.
- Fertl, W.H., Chilingar, G.V., 1988. Total organic carbon content determined from well logs. *SPE formation evaluation* 3, 407-419. <https://doi.org/10.2118/15612-PA>.
- Herron, S., Letendre, L., Dufour, M., 1988. Source rock evaluation using geochemical information from wireline logs and cores. *AAPG Bulletin* 72 (CONF-8809346-).
- Hertzog, R. et al., 1989. Geochemical logging with spectrometry tools. *SPE formation evaluation* 4, 153-162. <https://doi.org/10.2118/16792-PA>.
- Hunt, M.J., 1996. *Petroleum geochemistry and geology*, 2nd ed. WH Freeman and company, New York, p. 743. <https://doi.org/10.1021/ef960184w>.

- Jang, J.S., 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics* 23, 665-685. <https://doi.org/10.1109/21.256541>.
- Kadkhodaie-Ilkhchi, A., Rahimpour-Bonab, H., Rezaee, M., 2009. A committee machine with intelligent systems for estimation of total organic carbon content from petrophysical data: An example from Kangan and Dalan reservoirs in South Pars Gas Field, Iran. *Computers & Geosciences* 35, 459-474. <https://doi.org/10.1016/j.cageo.2007.12.007>.
- Kamali, M.R., Mirshady, A.A., 2004. Total organic carbon content determined from well logs using  $\Delta\text{LogR}$  and Neuro Fuzzy techniques. *Journal of Petroleum Science and Engineering* 45, 141-148. <https://doi.org/10.1016/j.petrol.2004.08.005>.
- Kang, D., Wang, X., Zheng, X., Zhao, Y.-P., 2021. Predicting the components and types of kerogen in shale by combining machine learning with NMR spectra. *Fuel* 290, 120006. <https://doi.org/10.1016/j.fuel.2020.120006>.
- Kennedy, J., Eberhart, R., 1995. Particle swarm optimization, *Proceedings of ICNN'95-international conference on neural networks*. IEEE, pp. 1942-1948.
- Kukolj, D., 2002. Design of adaptive Takagi–Sugeno–Kang fuzzy models. *Applied Soft Computing* 2, 89-103. [https://doi.org/10.1016/S1568-4946\(02\)00032-7](https://doi.org/10.1016/S1568-4946(02)00032-7).
- Luffel, D., Guidry, F., Curtis, J., 1992. Evaluation of Devonian shale with new core and log analysis methods. *Journal of Petroleum Technology* 44, 1192-1197. <https://doi.org/10.2118/21297-PA>.
- Madoliat, R., Khanmirza, E., Pourfard, A., 2017. Application of PSO and cultural algorithms for transient analysis of natural gas pipeline. *Journal of Petroleum Science and Engineering* 149, 504-514. <https://doi.org/10.1016/j.petrol.2016.09.042>.
- Mamdani, E.H., Assilian, S., 1975. An experiment in linguistic synthesis with a fuzzy logic controller. *International journal of man-machine studies* 7, 1-13. [https://doi.org/10.1016/S0020-7373\(75\)80002-2](https://doi.org/10.1016/S0020-7373(75)80002-2).
- Mann, U., Müller, P.J., 1988. Source rock evaluation by well log analysis (Lower Toarcian, Hils syncline). In: Mattavelli, L., Novelli, L. (Eds.), *Organic Geochemistry in Petroleum Exploration*. Elsevier, pp. 109-119. <https://doi.org/10.1016/B978-0-08-037236-5.50017-8>.
- Maroufi, K., Alizadeh, B., Rokni, E., Fajrak, M., 2017. Integrating Reservoir Geochemistry and Engineering Approaches to Investigate Connectivity of Asmari and Bangestan Reservoirs in Gachsaran Oilfield. *Advanced Applied Geology* 7, 27-39. <https://doi.org/10.22055/aag.2017.20831.1650>.
- Mendelson, J.D., 1985. Petroleum source rock logging, Ph.D thesis, Massachusetts Institute of Technology.
- Miliaresis, G., Iliopoulou, P., 2004. Clustering of Zagros Ranges from the Globe DEM representation. *International Journal of Applied Earth Observation and Geoinformation* 5, 17-28. <https://doi.org/10.1016/j.jag.2003.08.001>.
- Mohsenipour, A., Soleimani, B., Zahmatkesh, I., Veisi, I., 2021. Estimation of nuclear magnetic resonance (NMR) log permeability by integrating artificial neural network and imperialist competition optimization algorithm (ICA) in one of the oil fields of southwestern Iran. *Arabian Journal of Geosciences* 14, 1-18. <https://doi.org/10.1007/s12517-021-08821-6>.
- Mousazadeh, F., Naeem, M.H.T., Daneshfar, R., Soulgani, B.S., Naseri, M., 2021. Predicting the condensate viscosity near the wellbore by ELM and ANFIS-PSO strategies. *Journal of Petroleum Science and Engineering* 204, 108708. <https://doi.org/10.1016/j.petrol.2021.108708>.
- Nezhad, Y.A., Moradzadeh, A., Kamali, M.R., 2018. A new approach to evaluate Organic Geochemistry Parameters by geostatistical methods: A case study from western Australia. *Journal of Petroleum Science and Engineering* 169, 813-824. <https://doi.org/10.1016/j.petrol.2018.05.027>.
- Passey, Q., Creaney, S., Kulla, J., Moretti, F., Stroud, J., 1990. A practical model for organic richness from porosity and resistivity logs. *AAPG Bulletin* 74, 1777-1794. <https://doi.org/10.1306/0C9B25C9-1710-11D7-8645000102C1865D>.
- Rezazakemi, M., Dashti, A., Asghari, M., Shirazian, S., 2017. H<sub>2</sub>-selective mixed matrix membranes modeling using ANFIS, PSO-ANFIS, GA-ANFIS. *International Journal of Hydrogen Energy* 42, 15211-15225. <https://doi.org/10.1016/j.ijhydene.2017.04.044>.
- Sabah, M., Talebkeikhah, M., Agin, F., Talebkeikhah, F., Hasheminasab, E., 2019. Application of decision tree, artificial neural networks, and adaptive neuro-fuzzy inference system on predicting lost circulation: A case study from Marun oil field. *Journal of Petroleum Science and Engineering* 177, 236-249. <https://doi.org/10.1016/j.petrol.2019.02.045>.

- Sadeghtabaghi, Z., Talebkeikhah, M., Rabbani, A.R., 2021. Prediction of vitrinite reflectance values using machine learning techniques: a new approach. *Journal of Petroleum Exploration and Production* 11, 651-671. <https://doi.org/10.1007/s13202-020-01043-8>.
- Saemi, M., Ahmadi, M., Varjani, A.Y., 2007. Design of neural networks using genetic algorithm for the permeability estimation of the reservoir. *Journal of Petroleum Science and Engineering* 59, 97-105. <https://doi.org/10.1016/j.petrol.2007.03.007>.
- Safaei-Farouji, M., Kadkhodaie, A., 2022. Application of ensemble machine learning methods for kerogen type estimation from petrophysical well logs. *Journal of Petroleum Science and Engineering* 208, 1-16. <https://doi.org/10.1016/j.petrol.2021.109455>.
- Schmoker, J.W., 1981. Determination of organic-matter content of Appalachian Devonian shales from gamma-ray logs. *AAPG Bulletin* 65, 1285-1298. <https://doi.org/10.1306/03B5949A-16D1-11D7-8645000102C1865D>.
- Sepehr, M., Cosgrove, J.W., 2004. Structural framework of the Zagros fold-thrust belt, Iran. *Marine and Petroleum Geology* 21, 829-843. <https://doi.org/10.1016/j.marpetgeo.2003.07.006>.
- Sfidari, E., Kadkhodaie-Ilkhchi, A., Najjari, S., 2012. Comparison of intelligent and statistical clustering approaches to predicting total organic carbon using intelligent systems. *Journal of Petroleum Science and Engineering* 86, 190-205. <https://doi.org/10.1016/j.petrol.2012.03.024>.
- Sivanandam, S., Deepa, S., 2008. Introduction to genetic algorithms, by springer berlin heidelberg new york. Springer, 453 p.
- Tabatabaei, S.M.E., Kadkhodaie-Ilkhchi, A., Hosseini, Z., Moghaddam, A.A., 2015. A hybrid stochastic-gradient optimization to estimating total organic carbon from petrophysical data: A case study from the Ahwaz oilfield, SW Iran. *Journal of Petroleum Science and Engineering* 127, 35-43. <https://doi.org/10.1016/j.petrol.2015.01.028>.
- Takagi, T., Sugeno, M., 1983. Derivation of fuzzy control rules from human operator's control actions. *IFAC Proceedings Volumes* 16, 55-60. [https://doi.org/10.1016/S1474-6670\(17\)62005-6](https://doi.org/10.1016/S1474-6670(17)62005-6).
- Tissot, B.P., Welte, D.H., 1984. Petroleum formation and occurrence. Springer-Verlag, New York, 966 p.
- Trelea, I.C., 2003. The particle swarm optimization algorithm: convergence analysis and parameter selection. *Information processing letters* 85, 317-325. [https://doi.org/10.1016/S0020-0190\(02\)00447-7](https://doi.org/10.1016/S0020-0190(02)00447-7).
- Tsukamoto, Y., 1979. An approach to fuzzy reasoning method. *Advances in fuzzy set theory and applications*.
- Velez-Langs, O., 2005. Genetic algorithms in oil industry: An overview. *Journal of Petroleum Science and Engineering* 47, 15-22. <https://doi.org/10.1016/j.petrol.2004.11.006>.
- Walia, N., Singh, H., Sharma, A., 2015. ANFIS: Adaptive neuro-fuzzy inference system-a survey. *International Journal of Computer Applications* 123, <https://doi.org/10.5120/ijca2015905635>.
- Wang, H., Wu, W., Chen, T., Dong, X., Wang, G., 2019. An improved neural network for TOC, S1 and S2 estimation based on conventional well logs. *Journal of Petroleum Science and Engineering* 176, 664-678. <https://doi.org/10.1016/j.petrol.2019.01.096>.
- Wang, K., 2001. Computational intelligence in agile manufacturing engineering. In: Gunasekaran, A. (Ed.) *Agile manufacturing: the 21st century competitive strategy*, Elsevier, pp. 297-315.
- Yusefzadeh, S., Nadiri, A.A., 2021. Estimation hydraulic conductivity via intelligent models using geophysical data. *Advanced Applied Geology* 11, 382-404. <https://doi.org/10.22055/AAG.2020.29223.1970>.
- Zahmatkesh, I., Mohsenipour, A., Amraei, A., 2020. Estimation of reservoir rock properties from conventional well log data by using a hybrid particle swarm optimization and neural network approach. *Advanced Applied Geology* 10, 96-109. <https://doi.org/10.22055/AAG.2020.31475.2047>.
- Zahmatkesh, I., Soleimani, B., Kadkhodaie, A., Golalzadeh, A., Abdollahi, A.M., 2017. Estimation of DSI log parameters from conventional well log data using a hybrid particle swarm optimization-adaptive neuro-fuzzy inference system. *Journal of Petroleum Science and Engineering* 157, 842-859. <https://doi.org/10.1016/j.petrol.2017.08.002>.