



Imam Khomeini International University
Vol. 7, No. 3, Autumn 2022



نشریه مهندسی منابع معدنی
Journal of Mineral Resources Engineering
(JMRE)

Research Paper

Introduction of Two Data-Driven Methods for Determining the Quality of Gas Facies in Western Australia

Asgari Nezhad Y.¹, Moradzadeh A.^{2*}

1- Ph.D Student, Dept. of Mining Engineering, University of Tehran, Tehran, Iran

2- Professor, Dept. of Mining Engineering, University of Tehran, Tehran, Iran

Received: 01 Mar. 2021 Accepted: 30 Jun. 2021

Abstract: In determining the optimal points of production drilling, it is important to identify areas of suitable reservoir quality. For this purpose, the use of geochemical data, which is usually small in number, is common. This data discontinuity creates information gaps. If one uses more continuous data so that its modeling accuracy is suitable, the drilling could be then performed with more success. In this study, seismic and well logs data were used to classify the quality of gas facies by two non-parametric statistical (Parzen) and supervised deep learning techniques (long-term short-term memory network (LSTM)). The LSTM network was then also optimized by two heuristic optimization methods (Imperialistic competition algorithm and Whale algorithm). The obtained results indicate that both methods produce good results in classification so that the modeling accuracy of gas facies quality using supervised deep learning technique (87%) is more than that of the non-parametric Parzen (83%) method. Moreover, the application of optimization algorithms has increased the classification accuracy. The best accuracy is related to the LSTM network optimized with the imperialistic competition algorithm (90%). Geochemical reports and well cores data show the high validity of these models.

Keywords: Quality of gas facies, LSTM network, Parzen, Imperialistic competition algorithm, Whale optimization algorithm.

How to cite this article

Asgari Nezhad, Y., and Moradzadeh, A. (2022). "Introduction of Two Data-Driven Methods for Determining the Quality of Gas Facies in Western Australia". Journal of Mineral Resources Engineering, 7(3): 59-75.

DOI: 10.30479/JMRE.2021.15158.1495

*Corresponding Author Email: a_moradzadeh@ut.ac.ir

COPYRIGHTS



©2022 by the authors. Published by Imam Khomeini International University.

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>)

INTRODUCTION

Due to the lack of geochemical data in hydrocarbon fields, the idea of using other exploration data to model geochemical parameters was proposed. Because of the complexity of unconventional gas reservoirs, the main pattern of TOC estimation, which is based on simple or multivariate regression fitting, has been replaced by intelligent methods using seismic data in recent years [1-4]. In this study, the main purpose is to model gas quality directly using acoustic impedance of seismic data and petrophysical logs using Parzen classifier and supervised deep learning algorithm (LSTM network) for the first time. Finally, the ability of LSTM network has been improved by two methods of imperialist competition algorithm (ICA) and whale algorithm (WOA).

MATERIALS AND METHODS

In this paper, two methods of Parzen and LSTM neural network are used to classify the quality of gas facies with acoustic impedance of two dimensional (2D) seismic data and well petrophysical logs. As well, the Whale and Imperialist competition algorithms have then used for optimization. They are described briefly:

Parzen classifier

In the Parzen classifier, the probability of each data belonging to each class is investigated by computing the probability density function (Equation 1).

$$P_n(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h_n} \varphi\left(\frac{x - x_i}{h_n}\right) \quad (1)$$

Where:

$P_n(x)$: a function for the parzen window with center x and radius of h_n

n : The number of data

x_i : is the data being studied ($i = 1, 2, \dots, n$) [5].

LSTM Network

The LSTM networks have a sequence structure, but its main difference with the recurrent neural network is that LSTM networks have four layers in each hidden layer (Figure 1). The key point in LSTMs is the cell state, the horizontal line running through the top of the diagram. The cell state is like a conveyor belt. The LSTM does have the ability to remove or add information to the cell state, carefully regulated by structures called gates. Gates are a way to optionally let information through. They are composed out of a sigmoid neural net layer and a pointwise multiplication operation [6].

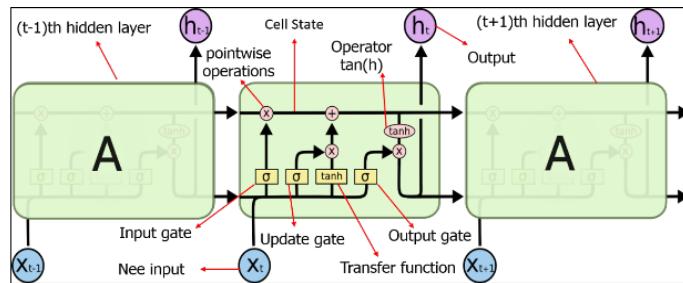


Figure 1. Duplicate units in the LSTM network with three hidden layers (each large rectangles) in each of them four layers interact with each other [6]

Imperialist Competition Optimization Algorithm

The ICA is a method in the field of evolutionary computing that finds the optimal answers to various optimization problems. The steps for performing this method are shown in Figure 2.

Whale optimization algorithm

This algorithm (WOA) is one of the heuristic optimization methods. The basis of the WOA is how to hunt humpback whales. A summary of the operation of the whale algorithm is as follows [8]:

- 1 .Create an initial population
- 2 .Calculate the suitability of each search factor
- 3 .Get the best initial search agent
- 4 .Update the current search agent position
- 5 .If maximum repetition is reached: End
6. Otherwise refer to step 2

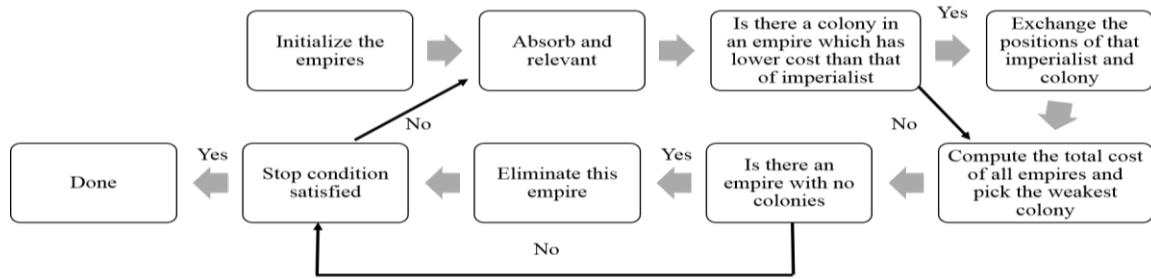


Figure 2. The steps of pseudo code for imperialist competition optimization algorithm [7]

RESULTS AND DISCUSSION

Modeling results of the Parzen classifier

The results of classification of good quality and bad quality facies by the Parzen method for the acoustic impedance of 2D seismic data can be seen in Figure 3A. It is seen that the Parzen modeling has acceptable accuracy, but at some depths (such as 1285 meters) some interlayers are appeared.

Modeling results of the LSTM

The gateways in the network work with the common sigmoid function to send the data to the next stage based on spatial sequences. The hyperbolic tangent function is used to transfer information from the gates to the state cell. The number of optimal hidden layers (obtained by repetition) was selected equal to 8. The modeling results are shown in Figure 3B. Some of the noise and interlayers that were present in the Parzen model have been removed in this model, and the boundaries of the layers are well separated from each other, except at a depth of 1380 meters.

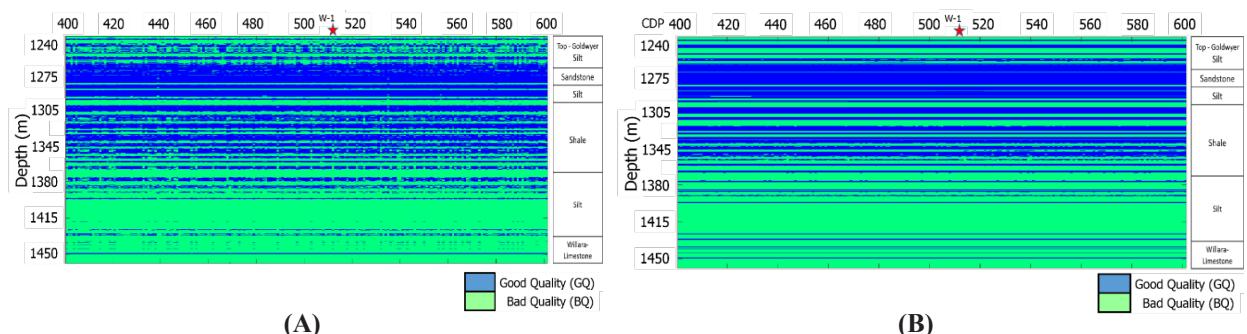


Figure 3. Two-dimensional cross section of the result of classification of gas facies quality along seismic profile with W-1 well using **A:** Parzen classifier and **B:** Supervised LSTM

Modeling with optimized LSTM network with ICA

The results of this optimized network for facies classification are shown in Figure 4A. As seen, the noise and interlayers in shale and silt layers have been disappeared. In other words, with the ICA optimized model, the complexities of the reservoir are well identified.

Modeling with optimized LSTM network with WOA

The second algorithm used to optimize the LSTM network was the whale algorithm. Figure 4B shows

the model optimized by this algorithm. The WOA optimized model properly identifies the layer boundaries. Moreover, in this model, the noise in the main model has been reduced sufficiently.

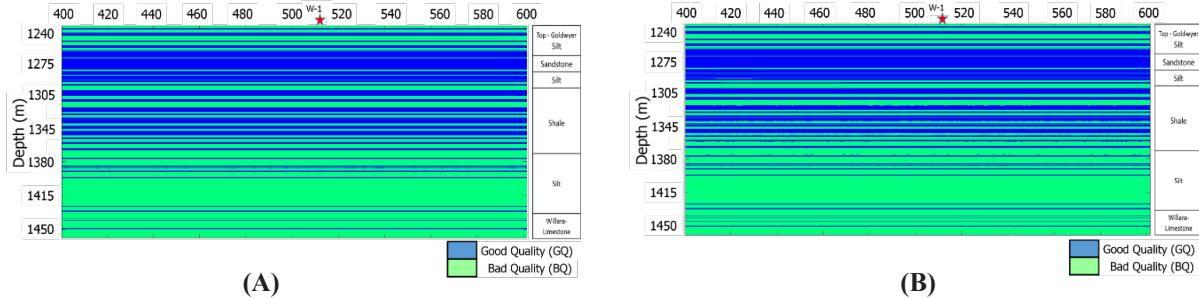


Figure 4. Two-dimensional cross section of the result of classification of gas facies quality along seismic profile with W-1 well using optimized LSTM by **A:** ICA and **B:** WOA

The modelling accuracy of the methods is evaluated at the well location on the profile. This is done by comparing the accuracy of the methods that provided by confusion matrix (Table 1) and visual comparison (Figure 5). The obtained results show that the accuracy of the ICA optimized LSTM network for classification and modeling of gas facies quality is (90%) better than those obtained by other methods.

Table 1. Comparison of confusion matrix and modeling accuracy with Parzen, simple and optimized LSTM network with two ICA and WOA methods

Classifiers	Confusion Matrix	Accuracy
Parzen	[87.3 12.7 19.3 80.7]	%84
LSTM	[89.2 10.8 15 85]	%87
Optimized LSTM by ICA	[92.3 7.7 12.2 87.8]	%90
Optimized LSTM by WOA	[91.5 8.5 13.4 86.6]	%89

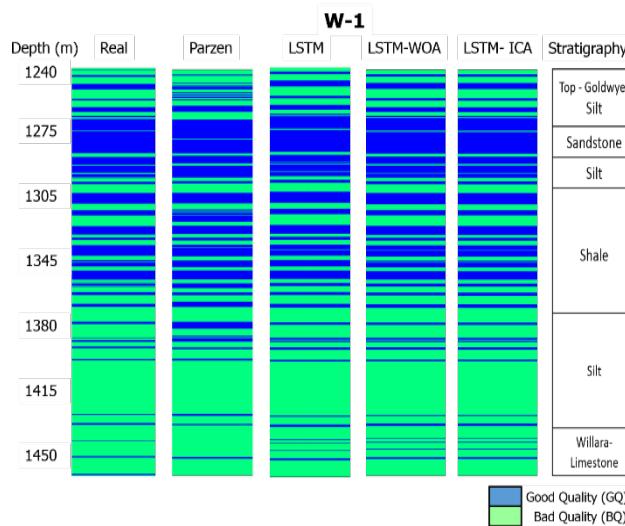


Figure 4. Image comparison between real data, Parzen classification results, simple LSTM network, LSTM network optimized by WOA and LSTM network optimized by the ICA at the well location (The right column depicts stratigraphic column of the well.)

CONCLUSION

Considering the results of modeling and examining the accuracy of each method, the following results have been obtained:

- The detection accuracy of quality zones using Parzen classifier was 84%.
- The accuracy of the proposed model using the supervised deep learning LSTM was 87%.
- The WOA has shown good performance with a 2% increase in accuracy (89%) compared to the simple LSTM network. Besides the ICA had the best performance between the two optimization algorithms in this study (90%).
- In general, the use of optimized LSTM network with ICA provided very good accuracy for classifying gas facies.

REFERENCES

- [1] Rui, J., Zhang, H., Zhang, D., Han, F., and Guo, Q. (2019). “*Total organic carbon content prediction based on support-vector-regression machine with particle swarm optimization*”. Journal of Petroleum Science and Engineering, 180: 699-706.
- [2] Wang, H., Wu, W., Chen, T., Dong, X., and 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.
- [3] Zhu, L., Zhang, C., Zhang, C., Zhang, Z., Nie, X., Zhou, X., Liu, W., and Wang, X. (2020). “*Forming a new small sample deep learning model to predict total organic carbon content by combining unsupervised learning with semisupervised learning*”. Applied Soft Computing, 83: 105596.
- [4] Sohail, G. M., Hawkes, C. D., and Yasin, Q. (2020). “*An integrated petrophysical and geomechanical characterization of Sembar Shale in the Lower Indus Basin, Pakistan, using well logs and seismic data*”. Journal of Natural Gas Science and Engineering, 78: 103327.
- [5] Duda, R. O., Hart, P. E., and Stork, D. G. (2012). “*Pattern classification*”. John Wiley & Sons.
- [6] Olah, Ch. (2015). “*Understanding LSTM Networks*”. Available on: <http://colah.github.io/posts/2015-08Understanding-LSTMs/>.
- [7] Atashpaz-Gargari, E., and Lucas, C. (2007). “*Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition*”. Paper Presented at the 2007 IEEE Congress on Evolutionary Computation.
- [8] Mirjalili, S., and Lewis, A. (2016). “*The whale optimization algorithm*”. Advances in Engineering Software, 95: 51-67.



معرفی دو روش مبتنی بر داده برای تعیین کیفیت رخساره‌های گازی در غرب استرالیا

یوسف عسگری نژاد^{*}، علی مرادزاده^{**}

۱- دانشجوی دکترا، دانشکده مهندسی معدن، دانشگاه تهران، تهران

۲- استاد، دانشکده مهندسی معدن، دانشگاه تهران، تهران

پذیرش: ۱۴۰۰/۰۴/۰۹

دریافت: ۱۳۹۹/۱۲/۱۱

چکیده

در تعیین نقاط بھینه حفاری‌های تولیدی مهم است که زون‌های با کیفیت مخزنی مشخص باشند. برای این منظور از داده‌های ژئوشیمیایی که معمولاً تعداد آن‌ها کم است استفاده می‌کنند. این گسستگی داده‌ها باعث ایجاد شکاف اطلاعاتی می‌شود. چنانچه از داده‌هایی با پیوستگی بیشتر استفاده شود طوری که دقت مدل‌سازی مناسب باشد، حفاری‌ها با شناسی بیشتری انجام می‌شود. در این مطالعه هدف بر این است تا کیفیت رخساره‌های گازی با استفاده از دو روش ناپارامتری آماری (پارزن) و تکنیک یادگیری عمیق با نظارت (شبکه عصبی بازگشتی حافظه کوتاه‌مدت بلند LSTM) و به کمک داده‌های نگار چاه و لرزه‌ای مدل شوند. همچنین در نظر است شبکه طراحی شده به وسیله دو روش بھینه‌سازی ابتکاری الگوریتم رقابت استعماری و الگوریتم نهنگ بھینه‌سازی شود. نتایج حاصل از این مطالعه نشان می‌دهد که هر دو روش نتایج خوبی در طبقه‌بندی دارند، طوری که مدل‌سازی کیفیت رخساره‌های گازی با استفاده از تکنیک یادگیری عمیق با نظارت با دقت بیشتری (۸۷٪) نسبت به روش ناپارامتری پارزن (۸۳٪) انجام گرفته است. همچنین با اعمال الگوریتم‌های بھینه‌سازی دقت شبکه بیشتر شده است. بهترین دقت مربوط به شبکه LSTM بھینه شده با الگوریتم رقابت استعماری (۹۰٪) است. گزارش‌ها و داده‌های ژئوشیمیایی مغزه‌های چاه، اعتبارسنجی بالای این مدل‌سازی‌ها را نشان می‌دهد.

کلمات کلیدی

کیفیت رخساره گازی، شبکه حافظه کوتاه‌مدت بلند، پارزن، الگوریتم رقابت استعماری، الگوریتم نهنگ.

استناد به این مقاله

عسگری نژاد، ی.، مرادزاده، ع.؛ "معرفی دو روش مبتنی بر داده برای تعیین کیفیت رخساره‌های گازی در غرب استرالیا". نشریه مهندسی منابع معدنی، دوره هفتم، شماره ۳، ص ۷۵-۵۹.

DOI: 10.30479/JMRE.2021.15158.1495



©

نویسنده

مشمول

و

عهده

دار

مکاتبات

نی

و

عهده

دار

مکاتبات

نی

*نویسنده مسئول و عهده دار مکاتبات Email: a_moradzadeh@ut.ac.ir

۱- مقدمه

برای کاهش هزینه‌های تولید از ذخایر نامتعارف گازی، شناسایی و مدل‌سازی رخساره‌های حاوی گاز با درجه بلوغ مناسب ضروری است. برای این منظور اولین گرینه، استفاده از داده‌های ژئوشیمیایی مانند مقدار کل کربن آلی (TOC) و درجه بلوغ (Tmax) است، اما به دلیل کمبود این نوع داده در میادین هیدروکربنی ایده استفاده از سایر داده‌های رایج اکتشافی برای مدل‌سازی پارامترهای ژئوشیمیایی مطرح شد. مطالعات نشان داده است که عموماً مواد ارگانیک در مقابل نگارهای پتروفیزیکی چاه، سبب تغییراتی از قبیل کاهش چگالی و نگار صوتی، افزایش رادیومتری و مقاومت ویژه می‌شوند. ضمن این که مقدار TOC و شاخص هیدروژن در این سازندها هم زیاد می‌شود [۲، ۱]. به دلیل پیچیدگی موجود در مخازن نامتعارف گازی، الگوی اصلی تخمین TOC که بر اساس برآش ساده و یا چند متغیره رگرسیونی بوده است، جای خود را در سال‌های اخیر به روش‌های هوشمند داده است [۳-۵]. تان و همکارانش^۲ برای تخمین و پیش‌بینی TOC در شیل‌های آلی از دو روش هوشمند تابع پایه شعاعی^۳ و ماشین بردار پشتیبان^۴ استفاده کردند و نتایج قابل توجهی گرفتند [۶]. استفاده از ماشین بردار پشتیبان در سال‌های بعد نیز برای مدل‌سازی پارامترهای ژئوشیمیایی مورد استفاده محققانی نظری وانگ و همکاران^۵ و نیز روی و همکاران^۶ قرار گرفت [۷، ۸]. همچنانی این روش با روش‌های دیگری مانند نزدیک‌ترین همسایگی K^۷ و شبکه عصبی پس انتشار^۸ مقایسه شد که روش نزدیک‌ترین همسایگی نتیجه بهتری در تخمین مقدار TOC داشت [۹].

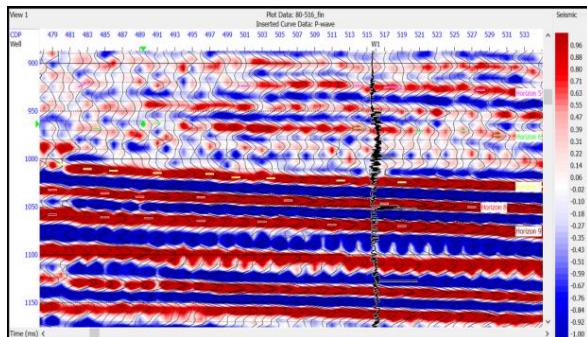
استفاده از داده‌های لرزه‌ای برای تخمین پارامترهای ژئوشیمیایی مانند TOC به مرور جای خود را در مطالعات مدل‌سازی رخساره‌های گازی باز کرده است که از میان آنها می‌توان به رابطه وارون بین TOC و مقاومت صوتی^۹ با استفاده از داده‌های لرزه‌ای [۱۰] و یا مطالعه‌ای در مورد تخمین و نقش TOC بر سرعت‌ها [۱۱] اشاره کرد. در سال‌های اخیر محققان از روش‌های پیچیده‌تری استفاده کردند که یکی از مهم‌ترین این روش‌ها، تکنیک‌های یادگیری عمیق است که با استفاده از داده‌های لرزه‌ای توائسته است مقدار TOC را در سنگ منشا تخمین بزنند [۱۵-۱۲]. سهیل و همکاران^{۱۰} سعی کردند که با استفاده از نگارهای پتروفیزیکی و داده‌های لرزه پارامترهای ژئوشیمیایی مربوط به شیل نفتی متعلق به حوضه

رسوبی ایندوس^{۱۱} پاکستان را مدل کنند [۱۶].

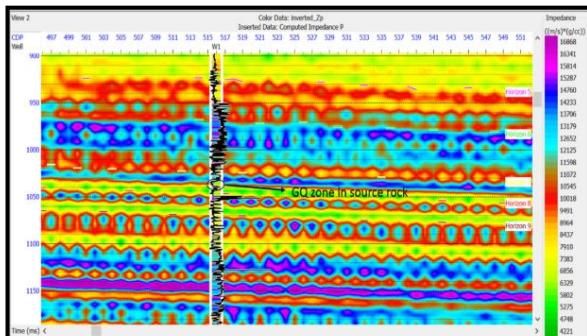
همان‌طور که مشخص شد در روش‌های گذشته عمدتاً مدل‌سازی‌ها بر اساس پارامترهای ژئوشیمیایی بوده است. به عنوان مثال مدل‌سازی‌های متعددی برای پارامتر TOC و درجه بلوغ ماده آلی انجام شده است. پس از این مدل‌سازی‌ها، محققان عمدتاً به صورت کیفی کیفیت رخساره‌ها را بررسی می‌کردند. در این مطالعه هدف اصلی بر این است تا برای اولین بار با استفاده از مقاومت صوتی حاصل از مدل‌سازی وارون داده‌های لرزه‌ای که بر روی یک پروفیل لرزه‌ای به دست آمده است و نگارهای پتروفیزیکی برای چاه مورد استفاده در آن پروفیل به مدل‌سازی کیفیت رخساره‌های گازی به صورت مستقیم اقدام شود. برای دستیابی به این هدف، داده‌های ورودی مدل در ابتدا آماده‌سازی شده و سپس با استفاده از دو روش طبقه‌بندی کننده پارزن و الگوریتم یادگیری عمیق با نظارت (شبکه حافظه کوتاه‌مدت بلند^{۱۲} (LSTM)) مدل کیفیت رخساره‌ها ارایه می‌شود. در نهایت با بهینه‌سازی شبکه LSTM با دو روش الگوریتم رقابت استعماری (ICA)^{۱۳} و الگوریتم نهنگ (WOA)^{۱۴} تلاش می‌شود عملکرد شبکه ارتقا یافته و نتایج به دست آمده با یکدیگر مقایسه و اعتبارسنجی شوند.

۲- زمین‌شناسی منطقه و داده مورد استفاده

منطقه مورد مطالعه حوضه رسوبی کنینگ^{۱۵} به عنوان یک حوضه بزرگ، پیچیده و دارای روند شمال غربی-جنوب شرقی است که در شمال غرب استرالیا قرار گرفته است [۱۶-۱۹]. حوضه کنینگ یک حوضه رسوبی کاملاً ساحلی است که در حدود ۵۹۵۰۰ کیلومتر مربع مساحت دارد. این روند شمال غربی به وسیله کراتون‌های پرکامبرین^{۱۶} که حوضه کانینینگ را احاطه کرده و زیر آن قرار دارد کنترل می‌شود [۱۸]. مطابق شکل ۱ در حاشیه شمال شرق این حوضه یک نواری از کراتون کیمبرلیتی پروتروزوئیک^{۱۷} قرار دارد در حالی که در نوار جنوب شرقی آن کراتون پیبلارای آرکن^{۱۸} مشاهده می‌شود [۲۰]. مخزن مورد بررسی در این مطالعه سازند گلدویر^{۱۹} است. جنس این مخزن عمدتاً از جنس شیل و ماسه‌های حاوی مواد آلی است. سازند گلدویر با ضخامت متوسط ۳۵۰ متر در تراس‌ها و سکوها، واقع شده و مقادیر TOC بالای دارد. سه واحد گلدویر با دوره‌های مختلف اکسایش اکسیداسیون در دوره دارویلین اردویسین میانی^{۲۰} مرتبط بوده‌اند که برای وقوع و حفظ ماده آلی مهم‌اند.



(الف)



(ب)

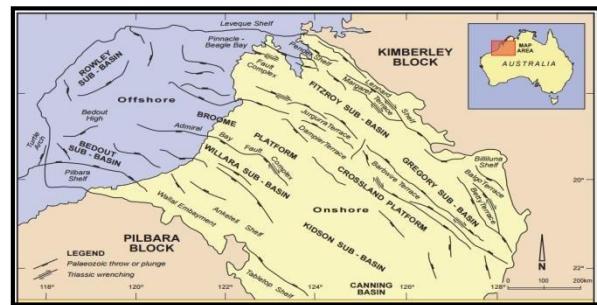
شکل ۲: (الف) مقطع لرزه‌ای و موقعیت چاه W-1، (ب) مقطع مقاومت صوتی حاصل از وارون سازی به روش مبتنی بر مدل در راستای پروفیل لرزه‌ای (که در آن نگار موج فشارشی در محل چاه W-1 نشان داده شده است).

۳- روش‌شناسی

در این مطالعه از دو روش پارزن و شبکه عصبی LSTM برای طبقه‌بندی کیفیت رخساره‌های گازی استفاده شده است. همچنین از دو روش الگوریتم نهنگ و رقابت استعماری برای بهینه‌سازی و افزایش دقت شبکه بهره برده شده است. در این مطالعه هدف استفاده از الگوریتم‌های بهینه‌سازی، بهینه کردن فرآیندها و نه تابع هزینه است. یعنی با استفاده از این الگوریتم‌ها اوزان شبکه و ضرایبی که باید در خروجی دروازه‌ها ضرب شوند تا به سلول حالت انتقال پیدا کنند، بهینه می‌شوند به نحوی که دقت شبکه افزایش می‌یابد. در ادامه این روش‌ها توضیح داده می‌شود.

۱-۳- طبقه‌بندی کننده پارزن

طبقه‌بندی کننده‌ها مستند به مشاهدات اولیه، تعدادی داده را در n کلاس معلوم ($w_1, w_2, w_3, \dots, w_n$) طبقه‌بندی می‌کنند. در طبقه‌بندی کننده پارزن، با محاسبه تابع چگالی



شکل ۱: نقشه حوضه رسوی کینینگ (نوار شمال شرقی آن بلوك کیمبرلیتی پروتروزوئیک بوده و نوار جنوب غربی آن بلوك پیلبارا است [۲۱].)

در این مطالعه از سه دسته داده کمی (نگارهای پتروفیزیکی چاه، داده‌های لرزه دوبعدی پس انبارش و داده‌های ژئوشیمی با مقدار TOC و Tmax) و همچنین گزارش‌های مغذه و تکمیل چاه استفاده شده است. از مقدار TOC، Tmax و گزارش‌های مغذه و تکمیل چاه برای اعتبارسنجی و تعیین کیفیت مخزن استفاده خواهد شد. نگارهای پتروفیزیکی شامل نگارهای گاما، نوترон، چگالی، صوتی، پتانسیل خودزا، لاترولوگ عمیق و قطرسنجی مربوط به یک چاه روی پروفیل لرزه‌ای است. مقدار مقاومت صوتی که از وارون سازی داده‌های لرزه‌ای به روش مبتنی بر مدل به دست می‌آید به عنوان ورودی مدل استفاده می‌شود. با توجه به این که مقاومت صوتی به عنوان یکی از پارامترهای مهم سنگ (منشا و مخزن) همواره مطلوب محققان بوده است می‌توان از این پارامتر کلیدی به عنوان نشانگر خارجی برای مدل سازی کیفیت رخساره‌های گازی (بر اساس داده‌های ژئوشیمیایی) استفاده کرد، بنابراین داده‌های مقاومت صوتی پروفیل لرزه‌ای وارون سازی شده در محل چاه مورد مطالعه (شکل ۲) به عنوان یکی از داده‌های ورودی به طبقه‌بندی کننده‌ها در نظر گرفته شده است.

با یک مقایسه کلی بین مقاومت صوتی ناشی از نگارهای پتروفیزیکی و پارامترهای ژئوشیمیایی TOC، Tmax می‌توان دریافت امکان جدایش ساده زون‌های با کیفیت خوب و بد با استفاده از مقاومت صوتی با روش‌های بصری و ساده وجود ندارد. همان‌طور که از شکل ۳-الف و ۳-ب مشخص است زون‌های خوب و بد با استفاده از تعیین حدود آستانه و یا روند کلی مقاومت صوتی قابل تشخیص نیستند، بنابراین باید از روش‌های دیگری برای تعیین الگوی مناسب برای تعیین کیفیت رخساره‌های گازی استفاده کرد.

کلاس‌های مختلف در آن بررسی می‌شود.
در روش پارزن توابع چگالی احتمال شرطی به صورت
رابطه ۲ معیار تصمیم‌گیری اند [۲۲]:

$$\text{if } P(w_1 | x) > P(w_2 | x) \rightarrow \text{کلاس تصمیم} = w_1 \quad (2)$$

$$\text{if } P(w_1 | x) < P(w_2 | x) \rightarrow \text{کلاس تصمیم} = w_2$$

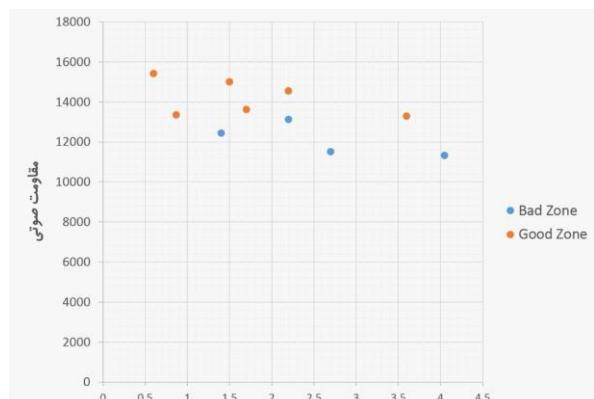
که در آن:
 w_1 : کلاس اول
 w_2 : کلاس دوم

x : ویژگی مورد نظر است که طبقه‌بندی می‌شود و به عبارت دیگر هدف محاسبه $p(w_i | x)$ احتمال قرار گرفتن داده مورد نظر در کلاس i به شرط ویژگی x است [۲۲].

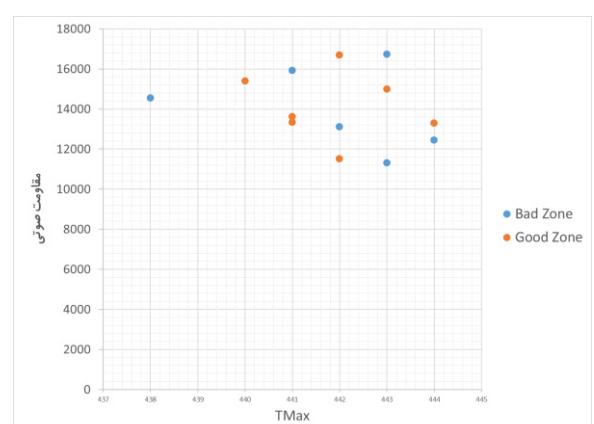
۲-۳- یادگیری عمیق

یادگیری عمیق زیرمجموعه‌ای از یادگیری ماشین^{۲۱} است که کامپیوترها را قادر می‌سازد تا مسایل پیچیده‌تری را حل کنند. یادگیری عمیق درباره استفاده شبکه‌های عصبی از نورون‌ها، لایه‌ها و ارتباطات داخلی بیشتر است. به طور کلی یادگیری عمیق به سه صورت نظارتی، غیرنظارتی و ترکیبی است [۲۳]. در یادگیری با نظارت از ابتدا دسته‌ها مشخص‌اند و هر یک از داده‌های آموزشی به دسته‌ای خاص نسبت داده شده است. در این مطالعه با توجه به این که از داده‌های دو بعدی (لرزه) و یک بُعدی (نگارهای پتروفیزیکی) برای مدل‌سازی رخساره استفاده می‌شود از شبکه عصبی بازگشتی حافظه کوتاه‌مدت بلند (LSTM) استفاده شده است که عملکرد آن به اختصار توضیح داده می‌شود. شبکه‌های LSTM ساختار دنباله‌ای دارد، اما تفاوت اصلی آن با شبکه عصبی بازگشتی در این است که در شبکه‌های LSTM چهار لایه در هر لایه پنهان وجود دارد که ساختاری ویژه است (شکل ۴). نحوه عملکرد و آموزش این شبکه به شرح ذیل است:

سلول حالت در حقیقت نوارنقاله‌ای است که دانش موجود برای انجام کار را از یک لایه به لایه دیگر به صورت خطی انتقال می‌دهد. علامت ضرب (حاصل بین صفر و یک است)، برای این است که دانش حفظ شود یا خیر و علامت جمع یعنی دانش جدید اضافه یا کم شود، اما این که چه داده‌ای و به چه صورتی به سلول حالت برود به وسیله دروازه‌ها تعیین می‌شود. دروازه‌ها با تابع سیگموئید، داده‌هایی بین صفر و یک تولید می‌کنند. پس با انجام عمل ضرب در سیگموئید می‌توان سهم



(الف)



(ب)

شکل ۳: (الف) نمودار مقاومت صوتی در مقابل مقدار TOC، (ب) نمودار مقاومت صوتی در مقابل مقدار TMax در چاه W-1

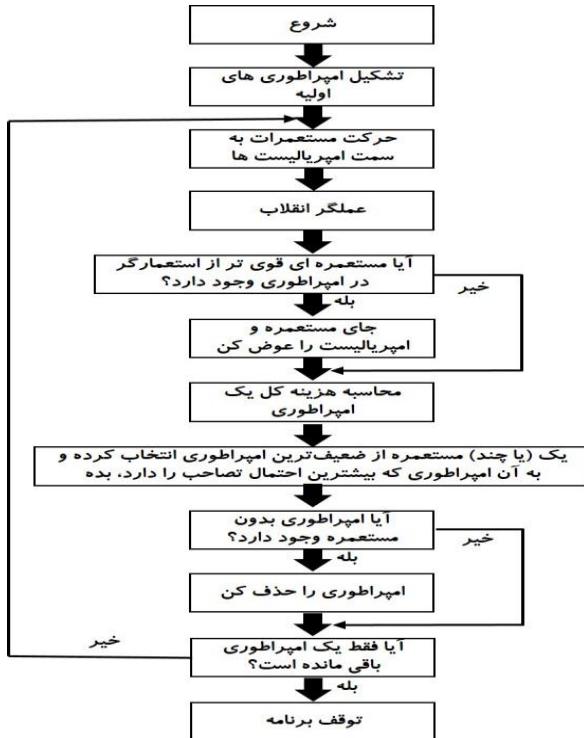
احتمال (رابطه ۱)، میزان احتمال تعلق هر داده به هر کلاس، بررسی می‌شود. در این روش داده به کلاسی تعلق می‌گیرد که احتمال تعلق آن بیشتر است.

$$P_n(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h_n} \varphi\left(\frac{x - x_i}{h_n}\right) \quad (1)$$

که در آن:
 $P_n(x)$: تابع پنجره پارزن
 $\varphi(x - x_i / h_n)$: تابعی است که اگر در ناحیه R_n با مرکز x و طول لبه یا شاعر پنجره پارزن h_n قرار گیرد برابر یک و در غیر اینصورت برابر صفر خواهد بود.
 x_i : که در آن $i=1, 2, \dots, n$ (داده‌هایی است که مورد مطالعه قرار می‌گیرد. لازم به توضیح است که شاعر پنجره پارزن مقدار شاعر حجمی است که احتمال قرارگیری نقاط در

تکامل اجتماعی- سیاسی، الگوریتمی برای حل مسایل ریاضی بهینه‌سازی ارایه می‌دهد. همانند همه الگوریتم‌های قرار گرفته در این دسته، الگوریتم رقابت استعماری نیز مجموعه اولیه‌ای از جواب‌های احتمالی را تشکیل می‌دهد. این جواب‌های اولیه در الگوریتم ژنتیک با عنوان "کروموزوم"، در الگوریتم ازدحام ذرات با عنوان "ذره" و در الگوریتم رقابت استعماری نیز با عنوان "کشور" شناخته می‌شوند. الگوریتم رقابت استعماری با روند خاصی که در ادامه می‌آید، این جواب‌های اولیه (کشورها) را به تدریج بهبود داده و در نهایت جواب مناسب مساله بهینه‌سازی (کشور مطلوب) را در اختیار می‌گذارد.

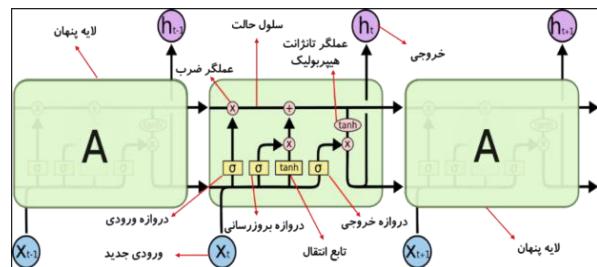
پایه‌های اصلی این الگوریتم را سیاست همسان‌سازی^{۲۲}، رقابت استعماری و انقلاب^{۲۳} تشکیل می‌دهند. این الگوریتم با تقلید از روند تکامل اجتماعی، اقتصادی و سیاسی کشورها و با مدل سازی ریاضی بخش‌هایی از این فرآیند، عملگرهایی را در قالب منظم به صورت الگوریتم ارایه می‌دهد که می‌توانند به حل مسایل پیچیده بهینه‌سازی کمک کنند. مراحل انجام این روش در شکل ۵ آمده است [۲۵].



شکل ۵: شبه کد مراحل انجام الگوریتم بهینه‌سازی رقابت استعماری [۲۵]

هر داده را در انتقال و مراحل بعدی تعیین کرد. در دروازه اول از سمت چپ که دروازه ورودی (فراموشی) نام دارد داده‌های جدید وارد شده و با تعیین مقداری بین صفر و یک و عملگر ضرب، حاصل به سمت سلوول حالت می‌رود. دروازه دوم از سمت چپ دروازه به روزرسانی نام دارد. داده جدید وارد این دروازه می‌شود و مانند دروازه قبلی از تابع سیگموئید عبور می‌کند، اما قبل از رسیدن به سلوول حالت با داده لایه قبلی که از تابع انتقال (تائزانت هیپربولیک) عبور می‌کند ترکیب شده و با عملگر ضرب به سمت سلوول حالت می‌رود تا به سلوول حالت اضافه (با عملگر جمع) شود. در حقیقت تابع انتقال دانش جدیدی تولید می‌کند و دروازه به روزرسانی سهم این دانش را برای انتقال به سلوول حالت تعیین می‌کند.

در ادامه برای ساخت خروجی شبکه ابتدا مقدار سلوول حالت از یک عملگر تائزانت هیپربولیک عبور می‌کند تا محدوده اعداد موجود در سلوول حالت جدید بین ۱-۱ و ۱ قرار گیرد. همچنین در دروازه سوم (دوازه خروجی) داده‌های مورد نیاز برای مدل کردن در عمق مورد نظر انتخاب شده و با تابع سیگموئید سهم هر یک تعیین می‌شود. در نهایت خروجی این دروازه در خروجی سلوول حالت که از عملگر تائزانت هیپربولیک عبور کرده در یکدیگر ضرب شده و حاصل را به عنوان خروجی معرفی می‌کند. خروجی مدل با داده‌های واقعی تطبیق داده شده و خطای دست می‌آید. برای کاهش خطای وزن‌هایی که در دروازه‌ها عمل می‌کنند بهینه می‌شوند تا خطای به حداقل برسد.



شکل ۴: واحدهای تکرار شونده در شبکه LSTM با سه لایه پنهان (هر یک از مستطیلهای بزرگ) (در هر لایه پنهان آن چهار لایه در تعامل با یکدیگر هستند [۲۴]).

۳-۳- الگوریتم بهینه‌سازی رقابت استعماری

الگوریتم رقابت استعماری (ICA) روشی در حوزه محاسبات تکاملی است که به یافتن پاسخ بهینه مسایل مختلف بهینه‌سازی می‌پردازد. این الگوریتم با مدل سازی ریاضی فرآیند

رابطه ۴ در محدوده [۱، ۰] نرمال کرد.

$$X_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (4)$$

که در آن:

X_{norm} : مقدار نرمال شده یک داده

x : مقدار واقعی همان داده

x_{min} : کمترین مقدار برای یک ویژگی

x_{max} : بیشترین مقدار برای یک ویژگی است.

در مرحله دوم، گُددگاری برای هر رخساره با استفاده از گزارش‌های ژئوشیمی آلی مغزه‌ها انجام پذیرفته است. مطالعات و اکتشافات موفق ذخایر نامتعارف گازی در شمال آمریکا و غرب استرالیا عمدتاً در مورد محلهایی با TOC و بلوغ بالا بوده است [۲۸، ۲۹]، بنابراین رخسارهایی که مواد آلی مناسب $TOC > 1$ و درجه بلوغ کافی $T_{max} > 440$ داشته باشند از نظر کیفیت رخساره خوب هستند [۳۰، ۳۱]، بنابراین در این مطالعه رخساره‌ها به دو کلاس خوب (کد ۱) و کلاس بد (کد ۰) تقسیم می‌شوند.

در مرحله سوم برای بحث در مورد دقت مدل‌های مورد استفاده (طبقه‌بندی)، از ماتریس درهم‌ریختگی^{۲۴} استفاده می‌شود. سطرهای این ماتریس معرف کلاس‌های واقعی و ستون‌های آن معرف کلاس‌های تصمیم برای داده‌های آزمون است. درایه‌های روی قطر اصلی این ماتریس بیانگر تصمیم صحیح است، بنابراین با ضرب کردن عدد ۱۰۰ در آن درایه می‌توان میزان درصد دقت کلاسه‌بندی برای آن کلاس خاص را به دست آورد، بنابراین درصد نسبت $R_d = ۰.۷۵$ ماتریس درهم‌ریختگی (مجموع درایه‌های قطر اصلی) به تعداد کلاس‌ها، معرف درصد دقت طبقه‌بندی خواهد بود.

۴- نتایج مدل‌سازی با طبقه‌بندی کننده پارزن

پس از آماده‌سازی داده‌ها برای جدایش رخساره‌های با کیفیت خوب از رخساره‌های با کیفیت بد، ابتدا از روش پارزن استفاده شده است (شکل ۶). برای این کار باید شاعع پنجره پارزن بهینه شود. شاعع بهینه شعاعی است که بیشترین دقت در آن دیده شود. شاعع بهینه به صورت دایره قرمز رنگ در شکل ۷ آورده شده است.

۴-۳- الگوریتم بهینه‌سازی نهنگ

الگوریتم بهینه‌سازی نهنگ (WOA) یکی از روش‌های بهینه‌سازی ابتکاری است. اساس روش WOA نحوه شکار نهنگ کوهان است [۲۶]. نهنگ‌های کوهان دار پرده‌ای را ایجاد می‌کنند که به وسیله حباب‌ها محاصره می‌شود و ماهی‌های کوچک را شکار می‌کنند. در این الگوریتم، موقعیت نهنگ نسبت به طعمه با رابطه ۳ مدل می‌شود [۲۷]:

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot |\vec{C} \cdot (\vec{X}^*(t) - \vec{X}(t))| \quad (3)$$

که در آن:

t : تعداد تکرار

\vec{X} : بردارهای وضعیت نهنگ

\vec{X}^* : بردار وضعیت بهترین راه حل

$\vec{A} = 2\vec{a} \cdot \vec{r} - a$

$\vec{C} = 2 \cdot rvector$

r vector : یک بردار تصادفی است $\in [0, 1]$.

خلاصه روند کار الگوریتم نهنگ به شرح زیر است [۲۷]:

۱. ایجاد جمعیت اولیه

۲. محاسبه برازنده‌گی هر عامل جستجو

۳. به دست آوردن بهترین عامل جستجوی اولیه

۴. به روزرسانی موقعیت عامل جستجوی فعلی

۵. اگر به حداقل تکرار رسید: پایان

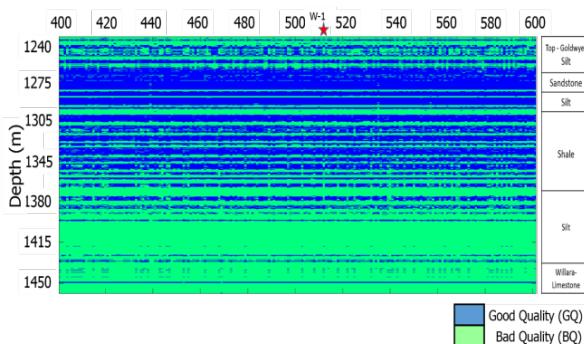
۶. در غیر اینصورت مراجعة به مرحله ۲

۴- بحث و نتایج

در این مطالعه طبقه‌بندی کیفیت رخساره‌های گازی با استفاده از دو روش پارزن و یادگیری عمیق انجام می‌گیرد. قبل از انجام طبقه‌بندی باید سه مرحله انجام شود. در مرحله اول داده‌های مقاومت صوتی و نگارهای پتروفیزیکی را نرمال کرده تا برای ورودی به مدل‌ها آماده شوند. در مرحله دوم کیفیت رخساره‌های گازی شناسه‌گذاری می‌شود و در مرحله سوم ملاک ارزیابی هر مدل تعیین خواهد شد.

در مرحله اول چون محدوده تغییرات داده‌های استفاده شده با هم متفاوت‌اند، اثر آن دسته از ویژگی‌ها که محدوده تغییرات کوچکتری دارند با آن‌هایی که دارای محدوده تغییرات بزرگتری‌اند در یک محدوده قرار نمی‌گیرند و ایجاد اختلال می‌کنند، بنابراین پیش از طبقه‌بندی باید مقادیر را به کمک

ناهمگنی، مواد آلی با بلوغ کم و یا تغییرات تخلخل و تراوایی در شیل و یا خطاهای مطالعه باشد.



شکل ۸: مقطع دوبعدی نتیجه طبقه‌بندی کیفیت رخساره‌های گازی در پروفیل لرزه‌ای و در حضور چاه W-1 با استفاده از طبقه‌بندی کننده پارزن

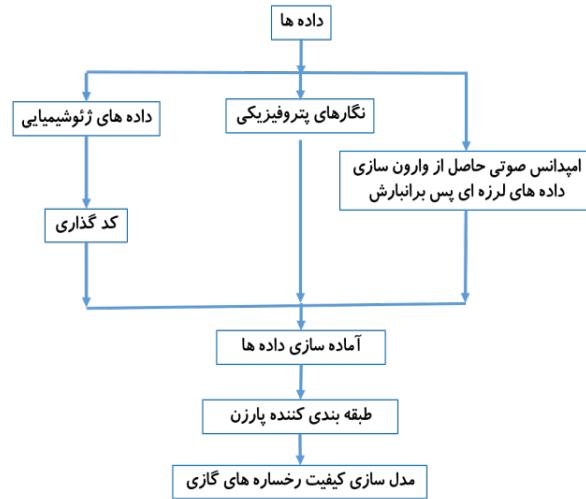
۲-۴- نتایج مدل‌سازی به روش شبکه LSTM

پس از پردازش داده‌ها اکنون مدل‌سازی و طبقه‌بندی کیفیت رخساره‌های گازی به وسیله شبکه عصبی بازگشتی LSTM (به عنوان یک تکنیک یادگیری عمیق با نظرارت) انجام می‌شود. دروازه‌های موجود در شبکه با تابع رایج سیگموئید کار می‌کنند تا داده‌ها را بر اساس سکانس‌های مکانی به مرحله بعدی بفرستند. برای انتقال اطلاعات از دروازه‌ها به سلول حالت از تابع تائزهای هیپربولیک استفاده شده است. تعداد لایه پنهان بهینه (که با تکرار به دست می‌آید) برابر ۸ است. به طور کلی شبکه مورد استفاده مشخصات مندرج در جدول ۱ را دارد. آموزش شبکه تا جایی پیش می‌رود که بهترین دقت به دست آید. نتایج مدل‌سازی در شکل ۹ آورده شده است.

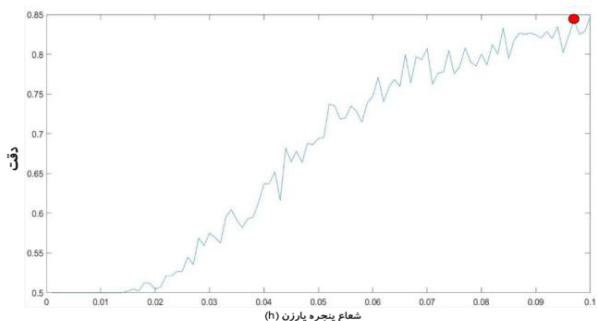
مانند شکل ۸، در شکل ۹ نیز دو زون کلی به لحاظ کیفیت قابل مشاهده است. با این تفاوت که در این شکل آشفتگی کمرنی دیده می‌شود، بنابراین کلیت مخزن به خوبی قبل مشاهده است. مدل ارایه شده دقت خوبی دارد و محدوده‌های حاوی ماده آلی با کیفیت مخزنی به خوبی از سایر زون‌ها جدا شده است.

۳-۴- مدل‌سازی با شبکه LSTM بهینه شده با الگوریتم رقابت استعماری

اولین الگوریتمی که برای بهینه‌سازی شبکه LSTM استفاده شد الگوریتم رقابت استعماری است. در ابتدا تعداد



شکل ۶: مراحل انجام کار مدل‌سازی با استفاده از طبقه‌بندی کننده پارزن



شکل ۷: تعیین شعاع پهینه پارزن در چاه W-1 (دایره قرمز رنگ)

پس از تعیین شعاع پهینه پارزن با استفاده از این شعاع بهینه، الگوریتم پارزن را اجرا کرده و دقت الگوریتم بررسی می‌شود. نتایج طبقه‌بندی رخساره‌های با کیفیت خوب و کیفیت بد به روش پارزن برای داده‌های مقاومت صوتی مقطع لرزه‌ای مورد مطالعه در شکل ۸ قابل مشاهده است.

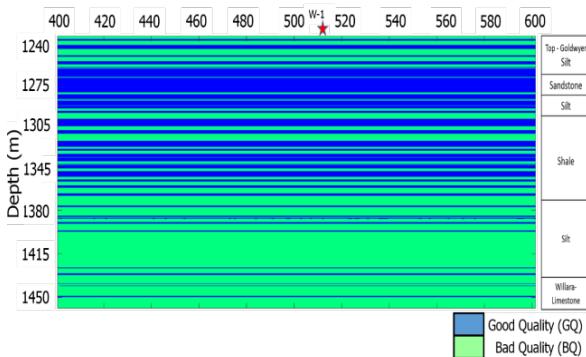
همان‌طور که در شکل ۸ مشخص است طبقه‌بندی کننده پارزن کیفیت رخساره‌های گازی را در دو بخش اصلی تقسیم کرده است. بخش اول واحدهای شیلی تا ماسه‌سنگی است که عمدها زون مخزنی‌اند. بخش دوم واحدهای سیلتی پایینی و آهک‌های سازند و یارا است که به خشک مخزنی (کیفیت بد) است. در این شکل همچنین می‌توان دید که در بخش شیلی آشفتگی نتایج بیشتر از سایر بخش‌ها است. این آشفتگی ممکن است به دلیل عوامل ساختاری مانند ناهمسانگردی،

جدول ۲: پارامترهای در نظر گرفته شده برای الگوریتم ICA در طبقه‌بندی

مقدار	پارامتر
۲۰	تعداد استعمارگر
۴۰	تعداد مستعمره‌ها
۰.۵	ضریب جذب (β)
۰.۲	ضریب هزینه میانگین کلونی‌ها (ξ)
۰.۱	نرخ انقلاب
۲۰۰	تعداد دهه‌ها
۰.۵	زاویه ضریب جذب (γ)
۰.۹۵	نسبت تضعیف

استعمارگرها و مستعمره‌ها به صورت تصادفی انتخاب می‌شوند. مستعمره‌ها با ضریب جذب β و زاویه جذب γ به سمت استعمارگرها حرکت می‌کنند. پس از جذب، مستعمره‌ها با فرآیند انقلاب (با نرخ تعیین شده) و تعویض با استعمارگرها مقایسه می‌شوند. اگر قدرت استعمارگری (قدرت خود استعمارگر + ضریبی از میانگین قدرت مستعمره‌ها ξ) کوچکتر از استعمارگر دیگر بود، نسبت تضعیف این استعمارگر حذف می‌شود. این فرآیند تا ادامه می‌یابد که فقط یک استعمارگر بماند (جدول ۲).

نتایج این شبکه بهینه‌سازی شده برای طبقه‌بندی رخساره‌ها در شکل ۱۰ آمده است.



شکل ۱۰: مقطع دوبعدی نتیجه طبقه‌بندی کیفیت رخساره‌های گازی در پروفیل لرزه‌ای با حضور چاه مورد مطالعه با استفاده از تکنیک یادگیری عمیق با نظارت بهینه شده با الگوریتم رقابت استعماری (ICA)

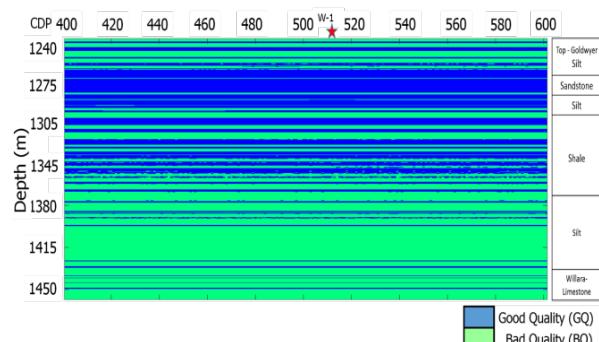
همان‌طور که دیده می‌شود میان لایه‌های ناپیوسته موجود در زون شیلی و سیلتی از بین رفته است. با توجه به این که این میان لایه‌های منقطع و ناپیوسته با تغییر روش بهینه‌سازی حذف شدند (در حالی که مدل اولیه با تغییر روش بهینه‌سازی چهار تغییر اساسی نشده است) می‌توان آن‌ها را نویزهای روش مطالعاتی در نظر گرفت، اما مشخص است که شبکه LSTM بهینه شده با الگوریتم رقابت استعماری دقیق‌تر برای مقطع لرزه‌ای ارایه داده است.

۴-۴- مدل‌سازی با شبکه LSTM بهینه شده با الگوریتم نهنگ

دومین الگوریتم مورد استفاده برای بهینه‌سازی شبکه LSTM، الگوریتم نهنگ است. شکل ۱۱ نتیجه مدل بهینه

جدول ۱: مشخصات شبکه LSTM مورد استفاده برای مدل‌سازی کیفیت رخساره‌های گازی

توضیحات	نوع
نگاره‌ای پتروفیزیکی و مقاومت صوتی	لایه ورودی
تابع سیگموئید	دروازه ورودی
تابع سیگموئید	دروازه بروزرسانی
تابع تائزات هیپربولیک	تبديل کننده ورودی به تابع حالت
تابع تائزات هیپربولیک	تبديل کننده خروجی به تابع حالت
تابع سیگموئید	دروازه خروجی
۰.۰۰۱	وزن اولیه منظم‌سازی
۴	محدوده منظم‌سازی
۰.۰۵	نسبت پراکندگی
۸	تعداد لایه پنهان
۵۰	گام

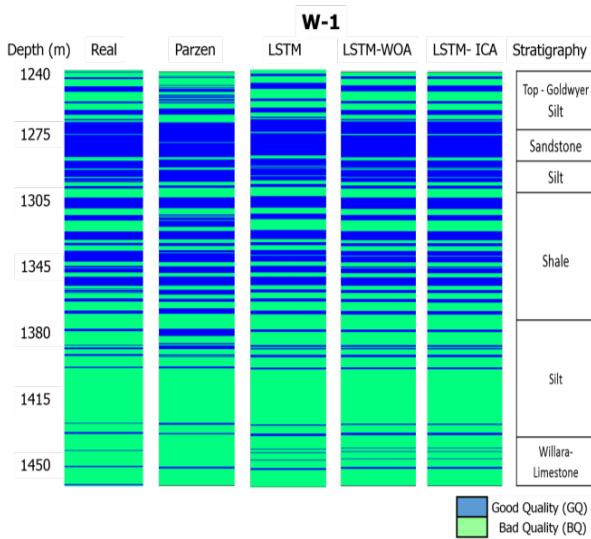


شکل ۹: مقطع دوبعدی نتیجه مدل‌سازی کیفیت رخساره‌های گازی در پروفیل لرزه‌ای با استفاده از تکنیک یادگیری عمیق با نظارت

طبقه‌بندی و مدل‌سازی کیفیت رخساره‌های گازی بهتر از سایر روش‌هاست (۹۰٪). همچنین شکل ۱۲ گویای این مطلب است که دقت روش شبکه LSTM بهینه شده (با هر دو الگوریتم LSTM بهینه‌سازی) بهتر از دو روش پارزن (۸۴٪) و شبکه ساده (۸۷٪) است.

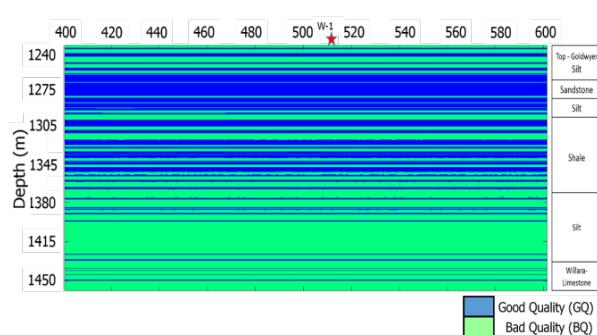
جدول ۳: مقایسه ماتریس درهم‌ریختگی و دقت پارزن و شبکه LSTM ساده و بهینه شده با دو روش رقابت استعماري و الگوریتم نهنگ

دقت مدل‌سازی	ماتریس درهم‌ریختگی	روش‌های مورد استفاده
٪۸۴	[87.3 12.7] [19.3 80.7]	روش پارزن
٪۸۷	[89.2 10.8] [15 85]	روش یادگیری عمیق با نظارت
٪۹۰	[92.3 7.7] [12.2 87.8]	روش یادگیری عمیق با نظارت بهینه شده با رقابت استعماري
٪۸۹	[91.5 8.5] [13.4 86.6]	روش یادگیری عمیق با نظارت بهینه شده با الگوریتم نهنگ



شكل ۱۲: مقایسه تصویری بین داده‌های واقعی (ستون سمت چپ)، نتایج طبقه‌بندی به روش پارزن (ستون دوم از سمت چپ)، شبکه LSTM ساده (ستون سوم از سمت چپ)، شبکه LSTM بهینه شده به وسیله الگوریتم نهنگ (ستون چهارم از سمت چپ)، شبکه LSTM بهینه شده به وسیله الگوریتم رقابت استعماري (ستون پنجم از سمت چپ)، در کنار ستون چینه‌نگاری (ستون سمت راست) در چاه مورد مطالعه

شده به وسیله این الگوریتم را نشان می‌دهد. در این شکل مشخص است که میان لایه‌های موجود، در بخش سیلتی (عمق ۱۲۵۰-۱۲۶۰ متر) کمتر شده است، اما در بخش شیلی (در عمق ۱۳۴۰-۱۳۵۰ متری) این میان لایه‌ها هنوز قابل مشاهده است. البته که به صورت چشمی بهبود دقت نسبت به مدل اولیه (شکل ۹) مشهود است.



شكل ۱۱: مقطع دو بعدی نتیجه طبقه‌بندی کیفیت رخساره‌های گازی در پروفیل لرزه‌ای با حضور چاه مورد مطالعه با استفاده از تکنیک یادگیری عمیق با نظارت بهینه شده با الگوریتم نهنگ (WOA)

برای بررسی بهتر دقت شبکه، نتیجه مدل‌سازی در محل چاه روی پروفیل بررسی می‌شود. این بررسی در دو بخش مقایسه دقت روش‌ها (جدول ۳) و مقایسه چشمی (شکل ۱۲) انجام می‌شود. جدول ۳ نتایج حاصل از ماتریس درهم‌ریختگی برای مطالعه درون چاه روی پروفیل لرزه‌ای را نشان می‌دهد. ستون دوم این جدول ماتریس درهم‌ریختگی است. این ماتریس نشان می‌دهد که دقت زون با کیفیت خوب در هر چهار مدل بیشتر از زون با کیفیت بد است. در روش پارزن این اختلاف دقت بین دو کلاس بیشتر به چشم می‌خورد. یکی از دلایل آن ممکن است این باشد که تعداد داده‌های موجود از زون با کیفیت خوب کمی بیشتر از داده‌های زون با کیفیت بد است، اما با مقایسه دقت کلاس‌ها در چهار مدل ارایه شده می‌توان گفت دقت شبکه LSTM (садه و بهینه شده) در هر دو زون نزدیک به یکدیگر و مستقل از نسبت داده‌های دو زون است. این موضوع در بحث اکتشاف که ممکن است در برخی از نقاط و زون‌های اکتشافی نبود (گپ) اطلاعاتی وجود داشته باشد یک مزیت محسوب می‌شود.

میانگین درایه‌های روی قطر اصلی این ماتریس دقت طبقه‌بندی را نشان می‌دهد که در ستون سوم جدول ۳ مشاهده می‌شود. در نهایت مشخص می‌شود که دقت روش شبکه LSTM بهینه شده با الگوریتم رقابت استعماري برای

- سطح اطمینان بالاتری در دقت نسبت به روش پارزن (در تعداد داده یکسان) دارد. از این دو نکته مهم را می‌توان دریافت که روش یادگیری عمیق با نظرات عملکرد خوبی در طبقه‌بندی و تفکیک کیفیت رخساره‌های گازی داشته است.
- روش بهینه‌سازی نهنگ با افزایش دو درصدی دقت (%) نسبت به شبکه LSTM ساده عملکرد مناسبی را نشان داده است.
 - روش رقابت استعماری با توجه به میزان افزایش دقیقی که برای طبقه‌بندی ارایه کرد در بین دو الگوریتم بهینه‌سازی در این پژوهش بهترین عملکرد را داشت (%).
 - در کل استفاده از شبکه LSTM بهینه شده با رقابت استعماری دقت بسیار مناسبی را برای طبقه‌بندی رخساره‌های گازی ارایه کرد.

۶- تازه‌های تحقیق

- طبقه‌بندی کیفیت رخساره‌های گازی با استفاده از داده‌های لرزه و نگارهای پتروفیزیکی با استفاده از روش پارزن
- استفاده از روش یادگیری عمیق با نظرات (شبکه LSTM) در شناسایی زون‌های با کیفیت خوب و بد مخزنی بهینه‌سازی مدل ارایه شده با استفاده از دو الگوریتم ابتکاری رقابت استعماری و نهنگ

۷- مراجع

- [1] Passey, Q., Creaney, S., Kulla, J., Moretti, F., and Stroud, J. (1990). "A practical model for organic richness from porosity and resistivity logs". AAPG Bulletin, 74(12): 1777-1794. DOI: 10.1306/0C9B25C9-1710-11D7-8645000102C1865D.
- [2] Herron, S. L. (1991). "In Situ Evaluation of Potential Source Rocks by Wireline Logs". Geochemical Methods and Exploration, Chapter 13. DOI: <https://doi.org/10.1306/TrHbk624C6>.
- [3] Mahmoud, A. A. A., Elkhatatny, S., Mahmoud, M., Abouelresh, M., Abdulraheem, A., and Ali, A. (2017). "Determination of the total organic carbon (TOC) based on conventional well logs using artificial neural network". International Journal of Coal Geology, 179: 72-80.

۵- نتیجه‌گیری

مدل‌سازی کیفیت رخساره‌های گازی برای انتخاب بهینه حفاری‌های تولیدی بسیار حائز اهمیت است. در این مطالعه با استفاده از داده‌های لرزه‌ای (مدل‌سازی وارون داده‌های پس برانبارش) و نگارهای پتروفیزیکی چاه سعی شد کیفیت رخساره‌های گازی در منابع نامتعارف گازی تعیین شود. مدل‌های مورد استفاده در این تحقیق، روش ناپارامتری پارزن و شبکه عصبی بازگشتی LSTM (به عنوان یکی از الگوریتم‌های یادگیری عمیق) بوده‌اند که شبکه LSTM به وسیله دو روش بهینه‌سازی رقابت استعماری و نهنگ بهینه شده‌اند. پس از مدل‌سازی و بررسی دقت هریک از این روش‌ها نتایج ذیل به دست آمد:

- با استفاده از طبقه‌بندی کننده پارزن که یک روش طبقه‌بندی ناپارامتری آماری است، دقت جدایش زون‌های با کیفیت در منابع نامتعارف گازی %۸۴ بوده است.
- دقت مدل ارایه شده برای طبقه‌بندی کیفیت رخساره‌های گازی با استفاده از الگوریتم با نظرات یادگیری عمیق برابر %۸۷ است.
- استفاده از شبکه عصبی بازگشتی LSTM به عنوان یکی از الگوریتم‌های یادگیری عمیق باعث شد که بتوان رابطه پیچیده بین داده‌های لرزه‌ای و نگارهای پتروفیزیکی با اندیس کیفیت رخساره گازی (کد صفر و یک) در ذخایر گازی نامتعارف با دقت مناسبی مدل شود.
- مقایسه بین مدل یادگیری عمیق با نظرات و طبقه‌بندی کننده پارزن نشان می‌دهد که با ارایه یک مدل پیچیده می‌توان دقت جدایش را بالا برد و پیچیدگی‌های موجود را به خوبی مدل کرد. به طوری که عدمه ایرادات روش پارزن که در مزر دولایه بوده است در روش شبکه LSTM به نحو مطلوبی اصلاح شده است.
- با توجه به تغییرات سکانسی، روش شبکه LSTM این تغییرات را به خوبی مدل کرده است. هرچند در برخی از عمق‌ها خطاهایی دیده می‌شود که البته به دلیل نازک لایه بودن اهمیت بالایی ندارد.
- تغییرات دقت در روش پارزن نسبت به روش شبکه LSTM بالاتر است که نشان می‌دهد شبکه LSTM

- S2 estimation based on conventional well logs". Journal of Petroleum Science and Engineering, 176: 664-678.*
- [14] Zhu, L., Zhang, C., Zhang, Z., Zhou, X., and Liu, W. (2019). "An improved method for evaluating the TOC content of a shale formation using the dual-difference $\Delta log R$ method". *Marine and Petroleum Geology, 102: 800-816.*
- [15] Zhu, L., Zhang, C., Zhang, C., Zhang, Z., Nie, X., Zhou, X., Liu, W., and Wang, X. (2020). "Forming a new small sample deep learning model to predict total organic carbon content by combining unsupervised learning with semisupervised learning". *Applied Soft Computing, 83: 105596.*
- [16] Sohail, G. M., Hawkes, C. D., and Yasin, Q. (2020). "An integrated petrophysical and geomechanical characterization of Sembar Shale in the Lower Indus Basin, Pakistan, using well logs and seismic data". *Journal of Natural Gas Science and Engineering, 78: 103327.*
- [17] Kennard, J., Jackson, M., Romine, K., Shaw, R., and Southgate, P. (1994). "Depositional sequences and associated petroleum systems of the Canning Basin, WA". Petroleum Exploration Society of Australia (PESA), pp. 657.
- [18] Quintavalle, M., and Playford, G. (2008). "Stratigraphic distribution of selected acritarchs in the Ordovician subsurface, Canning Basin, Western Australia". *Revue de Micropaléontologie, 51(1): 23-37.*
- [19] Garcia, M. P., Sanchez, G., Dentith, M., and George, A. (2014). "Regional structural and stratigraphic study of the Canning Basin, Western Australia". Department of Mines and Petroleum Government of Western Australia.
- [20] Cawood, P. A., and Korsch, R. (2008). "Assembling Australia: Proterozoic building of a continent". *Precambrian Research, 166(1-4): 1-35.*
- [21] Cadman, S. J., Pain, L., Vuckovic, V., and Le Poidevin, S. R. (1993). "Canning Basin, W.A.". Bureau of Resource Sciences, Australian Petroleum Accumulations, Report 9.
- [22] Duda, R. O., Hart, P. E., and Stork, D. G. (2012). "Pattern classification". John Wiley & Sons.
- [23] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2017). "ImageNet classification with deep convolutional neural networks". Paper presented at the Advances in neural information processing systems.
- [24] Olah, Ch. (2015). "Understanding LSTM Networks". Available on: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [4] Shalaby, M. R., Jumat, N., Lai, D., and Malik, O. (2019). "Integrated TOC prediction and source rock characterization using machine learning, well logs and geochemical analysis: Case study from the Jurassic source rocks in Shams Field, NW Desert, Egypt". *Journal of Petroleum Science and Engineering, 176: 369-380.*
- [5] Zhu, L., Zhang, Ch., Zhang, Ch., Wei, Y., Zhou, X., Cheng, Y., Huang, Y., and Zhang, L. (2018). "Prediction of total organic carbon content in shale reservoir based on a new integrated hybrid neural network and conventional well logging curves". *Journal of Geophysics and Engineering, 15(3): 1050-1061.*
- [6] Tan, M., Song, X., Yang, X., and Wu, Q. (2015). "Support-vector-regression machine technology for total organic carbon content prediction from wireline logs in organic shale: A comparative study". *Journal of Natural Gas Science and Engineering, 26: 792-802.*
- [7] Wang, P., Peng, S., and He, T. (2018). "A novel approach to total organic carbon content prediction in shale gas reservoirs with well logs data, Tonghua Basin, China". *Journal of Natural Gas Science and Engineering, 55: 1-15.*
- [8] Rui, J., Zhang, H., Zhang, D., Han, F., and Guo, Q. (2019). "Total organic carbon content prediction based on support-vector-regression machine with particle swarm optimization". *Journal of Petroleum Science and Engineering, 180: 699-706.*
- [9] Handhal, A. M., Al-Abadi, A. M., Chafeet, H. E., and Ismail, M. J. (2020). "Prediction of total organic carbon at Rumaila oil field, Southern Iraq using conventional well logs and machine learning algorithms". *Marine and Petroleum Geology, 116: 104347.*
- [10] Bello, H. D., Barzola, G., Portis, D., Tinnin, B., Handke, M., and Clemons, K. (2013). "Multiuse of Seismic and Attribute Mapping for Field Appraisal and Development in the Eagle Ford Shale: Mapping TOC, Porosity and Seal Integrity". Paper presented at the Unconventional Resources Technology Conference.
- [11] Altowairqi, Y., Rezaee, R., Evans, B., and Urosevic, M. (2015). "Shale elastic property relationships as a function of total organic carbon content using synthetic samples". *Journal of Petroleum Science and Engineering, 133: 392-400.*
- [12] An, P., and Cao, D. (2018). "Shale content prediction based on LSTM recurrent neural network". Paper presented at the SEG 2018 Workshop: SEG Maximizing Asset Value Through Artificial Intelligence and Machine Learning, Beijing, China, 17-19 September 2018.
- [13] Wang, H., Wu, W., Chen, T., Dong, X., and Wang, G. (2019). "An improved neural network for TOC, SI and

¹ Total Organic Carbon² Tan et al³ Radial Basic Function (RBF)⁴ Support Vector Machine (SVM)⁵ Wang et al⁶ Rui et al⁷ K nearest neighbors⁸ Backpropagation artificial neural network⁹ Acoustic Impedance¹⁰ Sohail et al¹¹ Indus Basin¹² Long Short Term Memory (LSTM)¹³ Imperialistic Competition Algorithm (ICA)¹⁴ Whale optimization algorithm (WOA)¹⁵ Canning Basin¹⁶ Precambrian Craton¹⁷ Proterozoic Kimberly Craton¹⁸ Archean Pilbara Craton¹⁹ Goldwyer²⁰ Middle Ordovician Darriwilian²¹ Machine Learning²² Assimilation²³ Revolution²⁴ Confusion Matrix²⁵ Trace

[25] Atashpaz-Gargari, E., and Lucas, C. (2007). “*Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition*”. IEEE Congress on Evolutionary Computation, 2007: 4661-4667. DOI: 10.1109/CEC.2007.4425083.

[26] Watkins, W. A., and Schevill, W. E. (1979). “*Aerial observation of feeding behavior in four baleen whales: Eubalaena glacialis, Balaenoptera borealis, Megaptera novaeangliae, and Balaenoptera physalus*”. Journal of Mammalogy, 60(1): 155-163.

[27] Mirjalili, S., and Lewis, A. (2016). “*The whale optimization algorithm*”. Advances in engineering software, 95, 51-67.

[28] Wei, J., and Guo, Q. (2011). “*Seismic technology in shale gas exploration and development*”. Paper presented at the 27th annual meeting proceedings. Beijing: Chinese Geophysical Society.

[29] Peng, Q., and Du, B. (2013). “*Study on geological condition of shale gas accumulation in Qiangtang Basin*”. Journal of Southwest Petroleum University (Science & Technology Edition), 35: 9-17.

[30] Suárez-Ruiz, I., Flores, D., Mendonça Filho, J. G., and Hackley, P. C. (2012). “*Review and update of the applications of organic petrology: Part 1, geological applications*”. International Journal of Coal Geology, 99: 54-112.

[31] Tissot, B. P., and Welte, D. H. (2013). “*Petroleum formation and occurrence*”. Springer Science & Business Media.