



Petroleum Research Research Article

Petroleum Research, 2022(August-September), Vol. 32, No. 124, 22-24
DOI:10.22078/PR.2022.4641.3088

Estimation of Total Organic Carbon Content and Kerogen Type from Well Log Data by Combining Artificial Neural Network and Metaheuristic Algorithms

Seyed Rasoul Seyedali^{1,2}, Bahram Alizadeh^{1,2*}, Iman Zahmatkesh¹ and Hashem Sarafdokht³

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

2. Petroleum Geology and Geochemistry Research Center (PGGRC), Shahid Chamran University of Ahvaz, Iran

3. Department of Geology, National Iranian South Oil Company (NISOC), Ahvaz, Iran

alizadeh@scu.ac.ir

DOI:10.22078/PR.2022.4641.3088

Received: November/07/2021

Accepted: February/02/2022

Introduction

Developing efficient methods to evaluate the petroleum potential of a source rock is of great importance for reducing the risk of oil and gas exploration. In recent years, qualitative and quantitative prediction of organic geochemical properties (e.g. total organic carbon) from well log data has been taken into consideration. For this purpose, a variety of empirical and artificial intelligence-based techniques are proposed [1,2]. Artificial neural network (ANN), which is a powerful computational technique capable of solving multivariate nonlinear problems, has been widely used in various research areas including petroleum exploration [3]. The learning process in ANNs is commonly performed by gradient-based back propagation (BP) algorithm. However, this technique is mainly suffered from the slow convergence rate and getting stuck in local optima [4]. Therefore, in order to improve the training of neural networks, metaheuristic algorithms have been efficiently applied to many problems [5].

In this study, which is performed on the Pabdeh Formation (Paleocene-Oligocene) in Mansuri oilfield (Dezful Embayment, SW Iran), artificial neural networks trained by back propagation as well as metaheuristic algorithms, including genetic algorithm and particle swarm optimization, are separately used for prediction of total organic carbon content and remaining petroleum potential from wireline data.

The most efficient method is then used for continuous estimation of organic richness and kerogen type with a high resolution.

Geographic and Geologic Setting

Dezful Embayment (SW Iran) is a relatively small depressed area extending over 60,000 km², in which almost all the oilfields of the Zagros Fold-Thrust Belt (ZFTB) are situated. It is separated from the adjacent areas by Balarud, Kazerun, and Mountain Front Fault Zones. The Mansuri oilfield is located in the northern Dezful Embayment and extends parallel to the NW-SE trend of the Zagros orogenic belt. One of the main source rocks in this area is considered to be Pabdeh Formation (Paleocene-Oligocene). This source rock is able to charge the Dezful Embayment reservoirs, especially Asmari (Oligocene-Miocene) Formation, where it attains appropriate thermal maturity [6].

Materials and Methods

In this study, a suite of 75 drill cutting samples were collected from Pabdeh Formation in nine wells penetrated throughout the Mansuri oilfield. Drilling additives were first removed from the samples. Then, the treated samples were crushed to the size of 80-mesh (0.180 mm). About 70 mg of each pulverized sample was weighed and analyzed by Rock-Eval 6 apparatus to determine their total organic carbon (TOC) content and remaining petroleum potential (S₂) parameters.

Genetic algorithm (GA) and particle swarm optimization (PSO) methods are among the population-based metaheuristic algorithms, which are able to optimize the weights and biases of the ANN during the learning process iteratively [7]. In this study, a three-layered perceptron artificial neural network was designed to predict TOC and S_2 Rock-Eval derived parameters from responses of the sonic (DT), neutron (NPHI), density (RHOB), and spectral gamma-ray (SGR) well logs. The dataset used for developing the ANN model was initially divided into training (70%) and testing (30%) sets considering the geological and geochemical characteristics of the studied formation. The data were then normalized to lie in the range [-1, 1]. The number of neurons in the hidden layer was set to six, and the tansig and purelin transfer functions were used in the hidden and output layers, respectively. In order to train the constructed artificial neural network, the Levenberg-Marquardt back propagation (ANN-BP), genetic algorithm (ANN-GA), and particle swarm optimization (ANN-PSO) methods were separately applied. The Performance of the neural networks during training was evaluated using mean square error (MSE). In both GA and PSO metaheuristic algorithms, the stop criterion was reached after 100 iterations.

Results and Discussion

In order to evaluate the performance of artificial neural networks applied in this study for the prediction of organic geochemical variables from the well log data, root mean square error (RMSE) and coefficient of determination (R^2) parameters were used. Comparing TOC and S_2 values measured by Rock-Eval analysis and those estimated by the artificial neural networks represents the higher efficiency of hybrid ANN models (ANN-GA and ANN-PSO) relative to ANN-BP technique (Fig. 1).




Fig. 1 Correlation of the measured and predicted TOC (a) and S_2 (b) geochemical parameters for the test data.

Overall, the ANN-PSO method provides more accurate predictions of TOC and S_2 parameters with R^2 values of 0.8548 and 0.9089, respectively (Fig. 2). This is in accordance with the lower RMSE values for estimation of the mentioned geochemical parameters using this technique.

Subsequently, the hydrogen index (HI) parameter was properly calculated based on the relationship between TOC and S_2 values derived from the ANN-PSO technique with an R^2 value of 0.6882. Generally, the kerogen types I, II, II/III, III, and IV can be distinguished with HI values of greater than 700, 400-700, 200-400, 50-200, and less than 50 mg HC/g TOC, respectively [8]. Accordingly, the ANN-PSO derived HI values in this study made it possible to differentiate various kerogen types with a classification accuracy of 74 percent (Fig. 3).




Fig. 2 Cross-plots of the measured versus ANN-PSO predicted TOC (a) and S_2 (b) geochemical parameters for the test data.




Fig. 3. Correlation of the measured and ANN-PSO predicted hydrogen index (HI) for the test data.

برآورد کل محتوی کربن آلی و نوع کروژن از داده‌های چاه‌پیمایی با بهره‌گیری از ترکیب شبکه عصبی مصنوعی و الگوریتم‌های فراابتکاری

سید رسول سیدعلی^{۱*}، بهرام علیزاده^{۲،۱*}، ایمان زحمتکش^۱ و هاشم صراف‌دخت^۲

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

۲- مرکز تحقیقات زمین‌شناسی و زمین‌شیمی نفت، دانشگاه شهید چمران اهواز، ایران

۳- گروه زمین‌شناسی، شرکت ملی مناطق نفت‌خیز جنوب، اهواز، ایران

تاریخ دریافت: ۱۴۰۰/۰۸/۱۶ تاریخ پذیرش: ۱۴۰۰/۱۱/۱۳

چکیده

ارزیابی پتانسیل هیدروکربن‌زایی سنگ منشأ به‌عنوان تابعی از کل محتوی کربن آلی و نوع کروژن از اهمیت بالایی در مطالعات اکتشافی نفت و گاز برخوردار است. هدف اصلی در این مطالعه، مقایسه عملکرد شبکه عصبی مصنوعی بر پایه روش آموزش پس انتشار (ANN-BP) و همچنین الگوریتم‌های فراابتکاری ژنتیک (ANN-GA) و ازدحام ذرات (ANN-PSO) به‌منظور برآورد پارامترهای ژئوشیمیایی کل کربن آلی (TOC) و پتانسیل باقی‌مانده هیدروکربنی (S_2) از طریق نمودارهای چاه‌پیمایی است. بدین منظور، سازند پایده (پالئوسن - الیگوسن) در میدان نفتی منصوری مورد مطالعه قرار گرفت. براساس نتایج برازش خطی بر روی داده‌های آزمون، روش ANN-PSO امکان برآورد پارامترهای TOC و S_2 حاصل از آنالیز راک-ایول را به‌ترتیب با ضریب تعیین (R^2) برابر با ۰/۸۵۴۸ و ۰/۹۰۸۹ فراهم آورده و عملکرد بهتری نسبت به روش‌های ANN-BP و ANN-GA به نمایش می‌گذارد. همچنین، برآورد پارامتر شاخص هیدروژن (HI) بر مبنای ارتباط میان مقادیر TOC و S_2 به‌واسطه این روش با ضریب تعیین ۰/۶۸۸۲ از دقت قابل قبولی برخوردار بوده و تفکیک انواع کروژن با دقت طبقه‌بندی ۷۴٪ را امکان‌پذیر می‌سازد. زون‌بندی ژئوشیمیایی سازند پایده بر مبنای غنی‌شدگی آلی و نوع کروژن با توجه به نتایج حاصل از روش ANN-PSO نشان‌دهنده سه بخش مجزا است، به‌طوری‌که بخش میانی (واحد شیل قهوه‌ای) با دارا بودن مقادیر قابل‌توجه کل محتوی کربن آلی و شاخص هیدروژن از پتانسیل هیدروکربن‌زایی بیشتری برخوردار بوده و در صورت رسیدن به بلوغ حرارتی مناسب می‌تواند نقش قابل‌توجهی در شارژ تله‌های نفتی میدان ایفاء نماید. بنابراین، تعیین دقیق اختصاصات هیدروکربن‌زایی سازند پایده با به‌کارگیری مدل پیشنهادی ANN-PSO در این مطالعه، کاهش عدم قطعیت در مدل‌سازی سیستم نفتی و متعاقباً افزایش قابل‌توجه کارایی اکتشاف در میدان نفتی منصوری را به‌دنبال خواهد داشت.

کلمات کلیدی: کل کربن آلی، نوع کروژن، شبکه عصبی مصنوعی، الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات.

*مسئول مکاتبات

آدرس الکترونیکی alizadeh@scu.ac.ir

شناسه دیجیتال: (DOI:10.22078/PR.2022.4641.3088)

مقدمه

کاهش ریسک اکتشاف منابع هیدروکربنی با بهره‌گیری از روش‌های علمی پربازده همواره به‌عنوان اولویتی اساسی در صنعت نفت مطرح بوده است. ساختارهای عظیم شناسایی‌شده در حوضه‌های رسوبی توسط روش‌های لرزه‌ای ممکن است به‌دلیل عدم وجود سنگ منشأ مؤثر با قابلیت زایش و رانش مقادیر کافی هیدروکربن، فاقد نفت و گاز باشند. بنابراین، توسعه روش‌هایی کارآمد به‌منظور ارزیابی پتانسیل هیدروکربن‌زایی سنگ منشأ جهت اطمینان از حضور، نوع و حجم هیدروکربن در ساختارهای اکتشافی امری ضروری است. اغلب روش‌های آزمایشگاهی به‌منظور ارزیابی ژئوشیمیایی سنگ منشأ با محدودیت‌هایی از قبیل نیاز به نمونه خرده حفاری یا مغزه، زمان‌بر بودن، هزینه بالا و همچنین، عدم پیوستگی داده‌ها بدلیل فواصل متغیر نمونه‌برداری روبرو هستند. بر این اساس و در تلاش به‌منظور ابداع روشی سریع و مقرون‌به‌صرفه جهت ارزیابی پیوسته سنگ منشأ بدون نیاز به انجام آنالیزهای مستقیم، برقراری ارتباط کمی و کیفی میان اختصاصات ژئوشیمیایی سنگ منشأ و داده‌های چاه‌پیمایی در دهه‌های اخیر مورد توجه قرار گرفته است. عمده مطالعات انجام‌شده در این زمینه بر روی تخمین پارامتر کل کربن آلی^۱ به‌واسطه روابط تجربی [۱ و ۲] و تکنیک‌های مبتنی بر هوش مصنوعی [۳-۶] که عمدتاً از دقت بالاتری برخوردارند تمرکز داشته‌اند. با این حال و در سالیان اخیر، داده‌های چاه‌پیمایی به‌منظور برآورد سایر اختصاصات ژئوشیمیایی سنگ منشأ مانند پتانسیل باقی‌مانده هیدروکربنی، شاخص هیدروژن و نوع کروژن نیز به‌کار برده شده‌اند [۷ و ۸]. رادیواکتیویته نسبتاً شدید، تمرکز قابل‌توجه اتم‌های هیدروژن و همچنین کاهش سرعت عبور صوت در بخش‌های غنی از ماده آلی به‌ترتیب سبب افزایش پاسخ نمودارهای پرتو گاما، نوترون و صوتی می‌گردد. همچنین، این بخش‌ها

به‌ویژه در صورت برخورداری از بلوغ حرارتی مناسب و متعاقباً پرشدگی منافذ و شکستگی‌ها به‌وسیله هیدروکربن‌های تولیدی، مقاومت بالایی از خود نشان می‌دهند. در مقابل و با توجه به چگالی کمتر مواد آلی در مقایسه با سایر اجزاء تشکیل‌دهنده سنگ، مقادیر نمودار چگالی در بخش‌های غنی از ماده آلی کاهش می‌یابد [۱ و ۳]. شایان ذکر است که در صورت بلوغ پایین مواد آلی و عدم رانش^۲ هیدروکربن از سنگ منشأ، چنین روابطی میان نمودارهای چاه‌پیمایی و پتانسیل باقی‌مانده هیدروکربنی نیز برقرار خواهد بود [۲ و ۷]. یکی از متداول‌ترین روش‌های محاسباتی هوشمند جهت حل مسائل عددی پیچیده با ماهیت غیرخطی که از کاربرد گسترده‌ای در علوم مختلف مانند مطالعات اکتشافی نفت و گاز برخوردار است، شبکه عصبی مصنوعی^۳ است. قابلیت یادگیری و تعمیم‌دهی ارتباط میان متغیرهای ورودی و هدف از ویژگی‌های اساسی این روش محسوب می‌شوند [۹]. فرآیند آموزش در شبکه عصبی مصنوعی به‌طور معمول با استفاده از الگوریتم پس انتشار^۴ که جزء روش‌های مبتنی بر گرادیان است صورت می‌پذیرد. با این حال، سرعت همگرایی پایین و قرارگیری در دام بهینه محلی به‌عنوان دو ضعف اساسی در به‌کارگیری این الگوریتم به‌شمار می‌روند [۱۰ و ۱۱]. بر این اساس و به‌منظور بهبود فرآیند آموزش شبکه عصبی مصنوعی، بهره‌گیری از الگوریتم‌های فراابتکاری^۵ در سالیان اخیر به‌طور قابل‌توجهی گسترش یافته است. این الگوریتم‌ها غالباً از فرآیند تکامل زیستی، رفتار جمعی و یا قوانین فیزیک الهام گرفته و در مقایسه با الگوریتم‌های مبتنی بر گرادیان از روش جستجوی تصادفی^۶ به‌منظور بهینه‌سازی بهره می‌گیرند [۱۲ و ۱۳].

1. Total Organic Carbon (TOC)

2. Expulsion

3. Artificial Neural Network (ANN)

4. Back Propagation (BP)

5. Metaheuristic

6. Stochastic Search

از مهم‌ترین الگوریتم‌های فراابتکاری که توسط محققین متعددی در دنیا جهت حل مسائل بهینه‌سازی مورد استفاده قرار گرفته‌اند می‌توان به الگوریتم‌های ژنتیک^۱ و بهینه‌سازی ازدحام ذرات^۲ اشاره نمود [۱۷-۱۴]. شبکه عصبی مصنوعی در ترکیب با الگوریتم‌های بهینه‌سازی ژنتیک و ازدحام ذرات جهت برآورد کل محتوی کربن آلی از داده‌های چاه‌پیمایی در برخی مطالعات مورد استفاده قرار گرفته است [۲۱-۱۸]. با این حال شبکه‌های عصبی ترکیبی تاکنون به‌منظور تعیین نوع کروژن از داده‌های پتروفیزیکی مورد توجه قرار نگرفته‌اند. هدف اصلی از مطالعه حاضر، به‌کارگیری داده‌های چاه‌پیمایی جهت برآورد مقادیر کل محتوی کربن آلی، پتانسیل باقی‌مانده هیدروکربنی و متعاقباً نوع کروژن سازند پابده در میدان نفتی منصوری (فروافتادگی دزفول، جنوب غرب ایران) با به‌کارگیری شبکه عصبی در ترکیب با الگوریتم‌های فراابتکاری ژنتیک (GA-ANN) و ازدحام ذرات (PSO-ANN) و سپس مقایسه عملکرد آن‌ها با شبکه عصبی مبتنی بر الگوریتم پس انتشار (ANN-BP) است. همچنین کارآمدترین روش به‌منظور برآورد پیوسته کل محتوی کربن آلی و نوع کروژن از داده‌های چاه‌پیمایی مورد استفاده قرار گرفته و زون‌بندی ژئوشیمیایی سازند مورد مطالعه بر مبنای اختصاصات مذکور صورت خواهد پذیرفت. براساس نتایج حاصله می‌توان تغییرات پیوسته پتانسیل هیدروکربن‌زایی، نوع هیدروکربن تولیدی و محیط ته‌نشست سنگ منشأ که در مطالعات اکتشافی از اهمیت بالایی برخوردارند را تعیین نمود.

زمین‌شناسی و موقعیت جغرافیایی منطقه

فروافتادگی دزفول^۳ ناحیه‌ای نسبتاً کوچک با گستره‌ای بالغ بر ۶۰/۰۰۰ km^۲ مربع واقع در جنوب غرب ایران بوده که عمده منابع نفتی کمربند چین‌خورده - رورانده زاگرس را در خود جای داده است [۲۲]. این ناحیه توسط گسل‌های بالارود،

پیشانی کوهستان و کازرون از نواحی مجاور مجزا شده و به‌وسیله گسل هندیجان - بهرگانسر به دو قسمت شمالی و جنوبی تقسیم گردیده است [۲۳ و ۲۴]. میدان نفتی منصوری به‌عنوان ساختار مورد مطالعه در این پژوهش در فروافتادگی دزفول شمالی و مجاور با ناحیه دشت آبادان قرار گرفته است (شکل ۱ الف). این میدان در فاصله تقریبی ۴۵ km جنوب شرقی شهرستان اهواز واقع شده و در محدوده طول جغرافیایی "۴۴°۴۸'۰۶" تا "۵۹°۴۸'۴۱" و عرض جغرافیایی "۴۶°۳۰'۱۶" تا "۰۴°۳۱'۱۶" قرار دارد. میدان نفتی منصوری در افق بنگستان دارای حدود ۴۳ km طول و ۵ تا ۶ km عرض بوده و به تبعیت از روند زاگرس در راستای شمال غرب جنوب شرق گسترش یافته است. از لحاظ ساختمانی، میدان نفتی منصوری به‌عنوان تاکیدیسی کشیده با دامنه‌های ملایم و کم‌شیب در نظر گرفته شده که برخلاف عمده میادین هیدروکربنی حوزه رسوبی زاگرس، شیب یال شمالی آن (۰ تا ۱۲ درجه) بیش از یال جنوبی (۰ تا ۸ درجه) است. این میدان در سطح دارای رخنمون نبوده و براساس نقشه‌های همتراز زیرزمینی^۴ و مقاطع لرزه‌ای، هیچ‌گونه آثاری از گسل‌خوردگی و یا بهم‌خوردگی تکتونیکی در آن مشاهده نمی‌شود [۲۵]. سازند پابده (پالئوسن - الیگوسن) به‌عنوان یکی از سنگ‌های منشأ اصلی در فروافتادگی دزفول و میدان نفتی منصوری شناخته شده که در صورت برخورداری از پتانسیل هیدروکربن‌زایی و بلوغ حرارتی مناسب و متعاقباً زایش و رانش مقادیر کافی هیدروکربن می‌تواند نقش قابل‌توجهی در شارژ مخازن این ناحیه به‌ویژه سازند آسماری (الیگوسن میوسن) (شکل ۱ ب) ایفاء نماید [۲۲]. برش الگوی این سازند در تنگ پابده واقع در شمال میدان نفتی لالی در مسجد سلیمان با ضخامت حدود ۷۹۸ m اندازه‌گیری و معرفی شده است.

1. Genetic Algorithm (GA)

2. Particle Swarm Optimization (PSO)

3. Dezful Embayment

4. Underground Contour (UGC) map

(الف)



(ب)

Period	Epoch	Stage	Formation
Tertiary	Pleistocene		Bakhtiari
	Pliocene		Labian
	Upper		Aghajari
			Mishan
	Middle		Gachsaran
			Asmari
	Lower		Alviz
	Oligocene		
	Eocene	Upper	Pabdeh
		Middle	Shahrak
		Lower	Hasanlu
	Palaeocene		
Cretaceous	Upper	Maestrichtian	Gurpi
		Campanian	Gurpi
		Santonian	Ilam
		Coniacian	
		Turonian	
		Cenomanian	Sarvak

شکل ۱ الف) موقعیت جغرافیایی میدان نفتی منصوری (MI) در فروافتدگی دزفول شمالی و مجاور با ناحیه دشت آبادان [۲۳] و ب) ستون چینه‌شناسی سازندهای کرتاسه بالایی - ترشیری در فروافتدگی دزفول [۲۴]

مطالعه پس از تیمار و رفع مواد افزودنی، به اندازه ۸۰ مش (معادل با ۰/۱۸۰ mm) پودر شدند. در ادامه و به منظور تعیین پارامترهای کل محتوی کربن آلی (TOC) و پتانسیل باقی مانده هیدروکربنی (S_2)، حدود ۷۰ mg از هر نمونه توزین شده و مورد آنالیز راک - ایول^۱ قرار گرفت.

آنالیز راک - ایول

آنالیز راک - ایول به عنوان روشی پرکاربرد و استاندارد در صنعت نفت جهت ارزیابی سنگ منشأ مورد استفاده قرار می‌گیرد.

سازند پابده در محل برش الگو شامل ۱۴۰ m شیل و مارن آبی و ارغوانی در قاعده (بخش شیل ارغوانی) بوده و در بخش باقی مانده از شیل‌های خاکستری و همچنین لایه‌های آهک رسی و گاهی چرت‌دار تشکیل شده است [۲۶].

مواد و روش‌ها

نمونه‌برداری و آماده‌سازی نمونه

جهت دستیابی به اهداف مورد نظر در این مطالعه، تعداد ۷۵ نمونه خرده حفاری مربوط به سازند پابده از ۹ چاه با پراکندگی مناسب در میدان نفتی منصوری انتخاب گردید. نمونه‌های مورد

از زمان ابداع این روش در اواسط دهه ۱۹۷۰ تاکنون، دستگاه‌های مختلف راک - ایول توسط انستیتو نفت فرانسه^۱ طراحی و به‌وسیله برخی شرکت‌ها تجاری شده‌اند [۲۷ و ۲۸]. در این پژوهش، به‌منظور تعیین اختصاصات ژئوشیمیایی نمونه‌های مورد مطالعه از دستگاه راک - ایول ۶ که نخستین بار توسط شرکت فرانسوی Vinci Technologies ارائه گردیده استفاده شده است. فرآیندهای متوالی پیرولیز^۲ و اکسیداسیون با استفاده از این دستگاه که به‌ترتیب در محدوده دمایی °C ۳۰۰-۶۵۰ و °C ۳۰۰-۸۵۰ با نرخ حرارتی °C/min ۲۵ صورت می‌پذیرد، اطلاعات ارزشمندی در خصوص پتانسیل هیدروکربن‌زایی سنگ منشأ فراهم آورده و در کاربردی نوین، تعیین پارامترهای کینتیکی زایش هیدروکربن را امکان‌پذیر ساخته است [۲۹ و ۳۰]. از مهم‌ترین خروجی‌های این دستگاه در طی مرحله پیرولیز می‌توان به سیگنال‌های S₁ (میزان هیدروکربن‌های آزاد موجود در نمونه با قابلیت تبخیر در دمای °C ۳۰۰) و S₂ (میزان هیدروکربن‌های حاصل از شکست حرارتی کروژن در محدوده دمایی °C ۳۵۰-۶۰۰) که توسط آشکارگر یونش شعله‌ای ثبت می‌شوند اشاره نمود. همچنین مقادیر CO₂ و CO تولید شده در طی پیرولیز به‌ترتیب به‌عنوان پیک‌های S₃ و S₃'CO/S₃CO توسط آشکارگر مادون قرمز به ثبت می‌رسند. از سوی دیگر و در مرحله اکسیداسیون که بعد از پیرولیز صورت می‌پذیرد، مقادیر CO₂ و CO حاصل از سوختن نمونه پیرولیز شده توسط آشکارگر مادون قرمز شناسایی و به‌ترتیب تحت عنوان سیگنال‌های S₄CO و S₄CO₂ ثبت می‌شوند. مقادیر اندازه‌گیری شده مذکور در طی مراحل پیرولیز و اکسیداسیون به‌منظور محاسبه کل محتوی کربن آلی مورد استفاده قرار می‌گیرند. پارامترهای T_{max} (دمای بیشینه پیک S₂)، شاخص هیدروژن، شاخص اکسیژن و شاخص تولید از سایر پارامترهای مهم قابل محاسبه با استفاده از مقادیر اندازه‌گیری شده راک - ایول در طی مراحل پیرولیز و اکسیداسیون بوده که از کاربرد بالایی در تفاسیر

ژئوشیمیایی برخوردارند [۲۸].

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی به‌عنوان مدل‌هایی محاسباتی با قابلیت یادگیری و کشف روابط غیرخطی و پیچیده میان مجموعه‌ای از متغیرها شناخته شده که از نحوه پردازش اطلاعات توسط سیستم عصبی زیستی مانند مغز انسان الهام گرفته‌اند. این شبکه‌ها دربرگیرنده مجموعه‌ای به هم پیوسته و کاملاً مرتبط از عناصر پردازنده اطلاعات به‌نام نورون مصنوعی یا گره^۳ هستند. ارتباط میان گره‌ها از طریق ضائبی به نام وزن^۴ که شدت ارتباط و یا میزان تأثیرگذاری آن‌ها بر یکدیگر را تنظیم می‌کند برقرار است [۳۱]. مدل پایه نورون مصنوعی برای نخستین بار توسط مک کولچ و پیتس با هدف شبیه‌سازی عددی رفتار نورون زیستی ارائه گردید [۳۲]. براساس این مدل، هر نورون به‌عنوان یک واحد محاسباتی عمل کرده که ورودی یا ورودی‌های متعدد را دریافت و پس از پردازش آن‌ها در صورت رسیدن به آستانه‌ای مشخص، فعال شده و نهایتاً منجر به ایجاد خروجی خواهد شد. به بیان بهتر، سیگنال (های) ورودی به نورون ابتدا در وزن‌های ارتباطی ضرب و پس از محاسبه مجموع آن‌ها که تحت عنوان مجموع وزن‌دار^۵ نیز خوانده می‌شود، مقداری ثابت تحت عنوان بایاس^۶ به آن افزوده می‌گردد. در نهایت، مقدار حاصله با عبور از تابع فعال‌سازی، خروجی نورون را تولید می‌کند (شکل ۲ الف). فرآیند مذکور از لحاظ ریاضیاتی به‌صورت زیر قابل بیان است:

$$y_i = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (1)$$

پارامترهای x_i و y_i در این معادله به‌ترتیب بیانگر ورودی و خروجی نورون هستند. همچنین، پارامترهای w_i ، f و b به‌ترتیب مبین تابع فعال‌سازی، وزن‌های ارتباطی و بایاس هستند [۳۳].

1. Institut Français du Pétrole (IFP)


2. Pyrolysis

3. Node

4. Weight

5. Weighted Sum (WS)

6. Bias



شکل ۲ الف) مدل ریاضیاتی نورون عصبی و ب) ساختار شبکه عصبی مصنوعی پرسپترون سه لایه [۳۳]

عملکرد شبکه در طی فرآیند آموزش براساس معادله زیر استفاده می‌شود:

$$MSE = \frac{\sum_{i=1}^n (y_{p,i} - y_{t,i})^2}{n} \quad (2)$$

پارامترهای $y_{p,i}$ ، $y_{t,i}$ و n در معادله فوق به ترتیب مبین خروجی پیش‌بینی‌شده، خروجی مطلوب و تعداد داده‌ها هستند. به‌طور کلی هدف از فرآیند آموزش، به حداقل رساندن تابع خطا از طریق بهینه‌سازی وزن‌ها و بایاس‌ها است. در طی آموزش شبکه با استفاده از الگوریتم پس انتشار، مقادیر وزن‌ها و بایاس‌ها در ابتدا به‌طور تصادفی تعیین می‌شوند. سپس این مقادیر به‌طور متوالی و براساس محاسبه و انتشار خطا به سمت لایه‌های قبلی در هر مرحله، به‌گونه‌ای تنظیم می‌شوند که تابع خطا کمینه گردد [۳۳].

الگوریتم ژنتیک

الگوریتم ژنتیک یکی از پرکاربردترین الگوریتم‌های فراابتکاری مبتنی بر جمعیت از نوع تکاملی بوده که از روش جستجوی تصادفی به‌منظور بهینه‌سازی بهره می‌گیرد. این الگوریتم که نخستین بار توسط هالند با هدف حل مسائل بهینه‌سازی مطرح شد، از نظریه انتخاب طبیعی الهام گرفته و بر مبنای قانون بقای اصلح عمل می‌کند [۳۵]. در این روش، راه‌حل‌های ممکن مسئله در مجموعه‌ای از کروموزوم‌ها (افراد) که تحت عنوان جمعیت شناخته می‌شود، ایجاد می‌گردند.

متداول‌ترین نوع شبکه‌های عصبی مصنوعی که تاکنون توسط محققین متعددی در حیطه‌های گوناگون علمی از جمله نفت و گاز مورد استفاده قرار گرفته است، پرسپترون چندلایه^۱ است. این شبکه از سه قسمت اصلی شامل لایه ورودی، لایه(های) پنهان و لایه خروجی تشکیل شده است. هر یک از لایه‌های مذکور دربرگیرنده یک یا چند نورون بوده که به‌صورت موازی با یکدیگر در ارتباط هستند. جریان سیگنال‌ها در یک جهت از لایه ورودی به سمت لایه خروجی صورت می‌پذیرد و بر این اساس، پرسپترون چندلایه نوعی شبکه با ساختار پیش‌خور^۲ به‌شمار می‌رود. نورون‌های لایه ورودی، داده‌های ورودی را دریافت و به نورون‌های لایه پنهان منتقل می‌کنند. داده‌ها پس از پردازش در لایه(های) پنهان به سمت لایه خروجی منتقل شده و نتیجه فرآیند به‌عنوان خروجی ارائه خواهد شد (شکل ۲ ب). فرآیند آموزش شبکه عصبی به‌طور معمول با استفاده از الگوریتم پس انتشار که جزء روش‌های یادگیری با نظارت^۳ به‌شمار می‌رود، صورت می‌پذیرد. در روش یادگیری با نظارت، داده‌های ورودی و خروجی مطلوب (هدف) به‌عنوان مجموعه داده آموزشی در شبکه ارائه و پس از طی شدن فرآیند آموزش بر مبنای ارتباط میان داده‌ها، مقادیر خروجی تخمین زده خواهد شد. دقت شبکه با به‌کارگیری یک تابع خطا که نشان‌دهنده اختلاف میان خروجی برآوردشده و خروجی مطلوب است، قابل ارزیابی است [۳۴]. به‌طور معمول از تابع خطای میانگین مربعات (MSE) به‌منظور ارزیابی

1. Multilayer Perceptron (MLP)
2. Feedforward
3. Supervised learning

به عبارتی، هر کروموزوم در جمعیت، معادل یک پاسخ برای مسئله است. به طور معمول، هر کروموزوم در جمعیت به صورت رشته‌ای از اعداد دودویی کد شده که مقادیر صفر و یک در آن معادل با ژن هستند. اعمال متوالی عملگرهای ژنتیک بر روی افراد حاضر در جمعیت، سبب ایجاد نسل‌های جدید با برآزش بیشتر می‌شود. اساساً الگوریتم ژنتیک از سه عملگر انتخاب^۱، تقاطع^۲ و جهش^۳ به منظور بهینه‌سازی بهره می‌گیرد [۱۲]. به طور خلاصه، نحوه عملکرد الگوریتم ژنتیک بدین صورت است که ابتدا جمعیتی از کروموزوم‌ها ایجاد و سپس برآزش هر کروموزوم در جمعیت از طریق تابع برآزش محاسبه می‌شود. براساس میزان برآزش، دو کروموزوم از میان جمعیت به عنوان والدین انتخاب خواهند شد. اگرچه انتخاب والدین به صورت تصادفی و بدون محاسبه تابع برآزش نیز امکان‌پذیر است، اما احتمال انتخاب افراد با برآزندگی بیشتر را کاهش خواهد داد. اعمال عملگر تقاطع بر روی والدین با توجه به احتمال تقاطع (Pc) سبب تولید یک یا دو فرزند از ترکیب آن‌ها می‌شود. در ادامه، دنباله ژنی فرزندان به واسطه عملگر جهش و با توجه به احتمال جهش (Pm) دچار تغییرات تصادفی می‌گردد. هدف از اعمال عملگر جهش، افزایش تنوع در کروموزوم‌ها یا جواب‌های احتمالی و اجتناب از قرارگیری در دام بهینه محلی^۴ است. در نهایت، فرزندان جدید با برآزش بیشتر در جمعیت جایگزین می‌شوند. فرآیندهای انتخاب، تقاطع، جهش و جایگزینی به طور متوالی و تا زمان تحقق شروط توقف بر روی نسل‌های جدید اعمال می‌شوند. الگوریتم ژنتیک پس از چندین بار تولید نسل، همگرا شده و به پاسخ تقریباً بهینه سراسری با بهترین برآزش در جمعیت پایانی خواهد رسید [۳۵ و ۳۶].

الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات که بر مبنای مفهوم هوش جمعی^۵ بنیان نهاده شده است، در دسته الگوریتم‌های فراابتکاری مبتنی بر جمعیت


قرار می‌گیرد. این الگوریتم از رفتار اجتماعی جانداران در طبیعت مانند پرواز گروهی پرندگان الهام گرفته و برای نخستین بار توسط کندی و ابره‌ارت معرفی گردیده است [۳۷]. بهینه‌سازی مسائل با استفاده از این الگوریتم در مقایسه با سایر الگوریتم‌های فراابتکاری از مزایایی مانند کم بودن پارامترهای تنظیمی، پیاده‌سازی آسان و هم‌گرایی سریع برخوردار است [۳۸ و ۳۹]. در این روش ابتدا مجموعه‌ای از راه‌حل‌های ممکن مسئله (ذرات) در فضای جستجو ایجاد و سپس موقعیت و سرعت ذرات بمنظور یافتن جواب بهینه، به طور مکرر بروزرسانی می‌شوند. با گذشت زمان و با توجه به تابع برآزش، موقعیت ذرات براساس بهترین تجربه فردی^۶ و بهترین تجربه سراسری^۷ تنظیم می‌گردد. بنابراین می‌توان اظهار داشت که الگوریتم PSO دارای یک حافظه بوده و هر ذره در طی فرآیند بهینه‌سازی، بهترین موقعیتی را که قبلاً در آن قرار گرفته به خاطر سپرده و اطلاعات آن را با سایر ذرات به اشتراک می‌گذارد. در نهایت تمامی ذرات از طریق بروزرسانی سرعت و موقعیت خود و با هدف دستیابی به راه‌حل بهینه سراسری به سمت موقعیت‌هایی با بیشترین برآزش حرکت می‌کنند [۴۰ و ۴۱]. در صورتی که سرعت و موقعیت ذره نام در زمان t به ترتیب با v_i^t و x_i^t مشخص شود، بروزرسانی سرعت و موقعیت ذره در هر بار تکرار (شکل ۳) از طریق معادلات زیر صورت می‌پذیرد:

$$v_i^{t+1} = \omega v_i^t + c_1 r_1 (p_{best,i}^t - x_i^t) + c_2 r_2 (g_{best}^t - x_i^t) \quad (۳)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (۴)$$

پارامترهای x_i^{t+1} و v_i^{t+1} در این معادلات به ترتیب نشان‌دهنده سرعت و موقعیت فعلی (بروزرسانی شده) ذره هستند.

1. Selection
2. Crossover
3. Mutation
4. Local Optimum
5. Swarm Intelligence
6. Personal
7. Global



$$\begin{aligned} v_i^{t+1} &= \omega v_i^t + c_1 r_1 (p_{best,i}^t - x_i^t) + c_2 r_2 (g_{best}^t - x_i^t) \\ x_i^{t+1} &= x_i^t + v_i^{t+1} \end{aligned}$$

شکل ۳ نحوه بروزرسانی سرعت و موقعیت ذرات در الگوریتم بهینه‌سازی ازدحام ذرات (PSO) [۴۱]

این مقدار در هر تکرار از طریق ضرب در پارامتری تحت عنوان نرخ تعدیل وزن اینرسی (ω_{damp})^۵ قابل بروزرسانی است [۴۲].

ترکیب شبکه عصبی مصنوعی و الگوریتم‌های فراابتکاری

همان‌طور که پیش‌تر ذکر شد، به‌کارگیری الگوریتم‌های فراابتکاری به‌منظور بهینه‌سازی وزن‌ها و بایاس‌های شبکه عصبی مصنوعی در طی فرآیند آموزش می‌تواند معایب مرتبط با الگوریتم‌های معمول مبتنی بر گرادیان از جمله سرعت پایین هم‌گرایی و قرارگیری در دام بهینه محلی را برطرف سازد. در این روش پس از تعیین ساختار پایه شبکه عصبی مصنوعی، الگوریتم‌های فراابتکاری مانند الگوریتم ژنتیک و ازدحام ذرات با هدف آموزش شبکه مورد استفاده قرار می‌گیرند. بدین منظور، ابتدا وزن‌ها و بایاس‌های شبکه عصبی مصنوعی به‌طور تصادفی تعیین و سپس عملیات بهینه‌سازی با استفاده از الگوریتم فراابتکاری در یک فضای d بعدی که d بیانگر تعداد کل وزن‌ها و

پارامتر ω بیانگر وزن اینرسی^۱ است که به‌منظور کنترل تأثیر سرعت قبلی بر سرعت فعلی ذره مورد استفاده قرار می‌گیرد. پارامترهای c_1 و c_2 یا ضرایب شتاب مقادیر مثبت ثابتی هستند که به‌ترتیب تحت عنوان پارامترهای یادگیری شناختی^۲ و اجتماعی نامیده شده و جهت وزن‌دهی به اهمیت تجربه فردی و سراسری به‌کار برده می‌شوند. همچنین، r_1 و r_2 اعدادی تصادفی با توزیع یکنواخت در بازه ۰ و ۱ هستند که نقش مهمی در الگوریتم PSO ایفاء می‌کنند، چراکه با حفظ ماهیت تصادفی بهینه‌سازی از هم‌گرایی زودرس و قرارگیری در دام بهینه محلی جلوگیری کرده و احتمال دستیابی به بهینه سراسری را افزایش می‌دهند. پارامترهای $pbest$ و $gbest$ نیز به‌ترتیب نشان‌دهنده بهترین موقعیت فردی و بهترین موقعیت سراسری تجربه‌شده توسط کل ذرات هستند [۴۰]. پارامتر وزن اینرسی به‌منظور کنترل و ایجاد توازن میان جستجوی سراسری و محلی که به‌ترتیب تحت عنوان اکتشاف^۳ و استخراج^۴ شناخته می‌شوند از اهمیت بالایی برخوردار است [۴۱]. به‌طور کلی، مقادیر بالاتر وزن اینرسی سبب افزایش قابلیت اکتشاف و مقادیر پایین‌تر موجب تسهیل هم‌گرایی به‌سمت بهینه محلی خواهد شد.

1. Inertia Weight

2. Cognitive

3. Exploration

4. Exploitation


5. Inertia Weight Damping Ratio

بوده و پارامترهای S و O نیز به ترتیب نشان دهنده تعداد داده‌های مجموعه آموزشی و تعداد نورون‌های خروجی هستند [۴۳]. جایگزینی کروموزوم‌ها در الگوریتم GA و همچنین، بروزرسانی موقعیت ذرات در الگوریتم PSO به منظور دستیابی به مقادیر بهینه وزن‌ها و بایاس‌های شبکه عصبی مصنوعی تا زمان تحقق شروط توقف ادامه خواهد یافت. شروط توقف به طور معمول با رسیدن به حداکثر تعداد تکرار مشخص، عدم بهبود برازش جمعیت در طی چند تکرار متوالی و یا دستیابی به نتیجه مطلوب با توجه به آستانه معینی از خطا محقق خواهد شد [۳۸ و ۴۴]. در این مطالعه از شبکه عصبی پرسپترون سه لایه جهت برآورد پارامترهای ژئوشیمیایی مطلوب (هدف) به واسطه داده‌های چاه‌پیمایی (ورودی) استفاده گردید. با توجه به ارتباط خطی مناسب میان نمودارهای چاه‌پیمایی صوتی (DT)، نوترون (NPHI)، چگالی (RHOB) و پرتو گاما (SGR) با مقادیر TOC و S₂ در سازند مورد بررسی شکل ۴، نمودارهای مذکور به عنوان ورودی در شبکه عصبی مورد استفاده قرار گرفتند.

بایاس‌هاست صورت می‌پذیرد. پس از اعمال عمل‌گرهای انتخاب، تقاطع و جهش بر روی جمعیت اولیه در الگوریتم GA، کروموزوم‌های با برازش بیشتر که در ارتباط با وزن‌ها و بایاس‌های بهینه شبکه عصبی هستند تولید و در جمعیت جایگزین خواهند شد. همچنین در الگوریتم PSO، ذرات از طریق بروزرسانی سرعت و موقعیت خود به سمت موقعیت‌هایی با بیشترین برازش که دربرگیرنده وزن‌ها و بایاس‌های بهینه شبکه هستند حرکت می‌کنند. لازم به ذکر است که برازش کروموزوم یا ذره نام در طی بهینه‌سازی وزن‌ها (w_i) و بایاس‌های (b_i) شبکه عصبی مصنوعی بر مبنای خطای میانگین مربعات (MSE) در هر تکرار به صورت زیر محاسبه می‌شود:

$$f(w_i, b_i) = \frac{1}{S} \sum_{k=1}^S \left[\sum_{l=1}^O \{t_{kl} - p_{kl}(w_i, b_i)\}^2 \right] \quad (5)$$

پارامتر f در این معادله بیانگر میزان برازش کروموزوم یا ذره به ترتیب در الگوریتم‌های GA و PSO است. همچنین، پارامترهای t_{kl} و p_{kl} در این معادله به ترتیب مبین خروجی مطلوب و خروجی پیش‌بینی‌شده با توجه به وزن‌ها و بایاس‌ها



شکل ۴ نمودارهای متقاطع نشان‌دهنده ارتباط خطی مناسب میان نگارهای چاه‌پیمایی صوتی (DT)، نوترون (NPHI)، چگالی (RHOB) و پرتو گاما (SGR) با پارامترهای ژئوشیمیایی (الف) کل محتوی کربن آلی (TOC) و (ب) پتانسیل باقی‌مانده هیدروکربنی (S₂)

به ترتیب برابر با ۰/۷، ۰/۵ و ۰/۱ لحاظ گردید.

بحث و بررسی

ارزیابی دقت برآورد شبکه‌های عصبی ترکیبی

به منظور ارزیابی عملکرد شبکه‌های عصبی ترکیبی جهت برآورد مقادیر کل محتوی کربن آلی و پتانسیل باقی مانده هیدروکربنی در این مطالعه، پارامترهای آماری ضریب تعیین (R^2) و همچنین خطای جذر میانگین مربعات (RMSE) که از طریق معادلات زیر محاسبه می‌شوند، بررسی گردید:


$$R^2 = \frac{\left(\frac{n \left(\sum_{i=1}^n y_{p,i} \cdot y_{t,i} \right) - \left(\sum_{i=1}^n y_{p,i} \right) \left(\sum_{i=1}^n y_{t,i} \right)}{\sqrt{\left[n \sum_{i=1}^n y_{p,i}^2 - \left(\sum_{i=1}^n y_{p,i} \right)^2 \right] \left[n \sum_{i=1}^n y_{t,i}^2 - \left(\sum_{i=1}^n y_{t,i} \right)^2 \right]}} \right)^2 \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{p,i} - y_{t,i})^2}{n}} \quad (7)$$

پارامترهای $y_{p,i}$ و $y_{t,i}$ و n در معادله فوق به ترتیب بیانگر خروجی پیش‌بینی شده توسط شبکه عصبی ترکیبی، خروجی مطلوب یا اندازه‌گیری شده توسط آنالیز راک - ایول و تعداد داده‌ها هستند. مقایسه میان مقادیر پیش‌بینی شده و اندازه‌گیری شده پارامترهای TOC و S_2 ، کارایی بالاتر شبکه‌های عصبی ترکیبی (ANN-GA و ANN-PSO) در مقایسه با شبکه عصبی مبتنی بر الگوریتم پس انتشار (ANN-BP) را در هر دو مرحله آموزش و آزمون به نمایش می‌گذارد (جدول ۱). همچنین، روش ANN-PSO در مقایسه با ANN-GA از عملکرد بهتری در برآورد پارامترهای ژئوشیمیایی هدف برخوردار است (شکل ۶).

شایان ذکر است که برخلاف اغلب مطالعات انجام‌شده در زمینه تخمین کل محتوی کربن آلی و پتانسیل باقی مانده هیدروکربنی سازند پابده در میادین نفتی فروافتادگی دزفول [۷ و ۴۵]، در این مطالعه از نمودار مقاومت (RT) به دلیل همبستگی پایین با پارامترهای ژئوشیمیایی مذکور (به ترتیب با ضریب تعیین ۰/۱۰۷ و ۰/۰۹۴۴) که می‌تواند ناشی از بلوغ ناکافی این سازند باشد، استفاده نگردید. پس از تعیین مقادیر ورودی شبکه، مجموعه داده‌ها با در نظر گرفتن اختصاصات ژئوشیمیایی و زمین‌شناسی سازند مورد مطالعه و همچنین تغییرات نمودارهای چاه‌پیمایی به دسته‌های آموزش (۰/۷۰) و آزمون (۰/۳۰) تقسیم و سپس در بازه [۱، ۱۰۰] نرمال شدند. تعداد نورون‌های شبکه عصبی در لایه پنهان براساس بهترین عملکرد شبکه و بر مبنای آزمون و خطا برابر با ۶ تعیین شد. تابع انتقال در لایه‌های پنهان و خروجی به ترتیب از نوع تانژانت سیگموئید^۱ و خطی^۲ تعیین و از تابع MSE جهت ارزیابی عملکرد شبکه در طی آموزش استفاده گردید. پس از تعیین ساختار و پارامترهای شبکه عصبی مصنوعی، الگوریتم پس انتشار لوبنرگ - مارکوارت^۳ به عنوان روشی متداول و کارآمد جهت آموزش شبکه عصبی منفرد (ANN-BP) به کار برده شد. همچنین، آموزش شبکه در حالت ترکیبی با به کارگیری الگوریتم‌های فراابتکاری ژنتیک (ANN-GA) و ازدحام ذرات (ANN-PSO) به طور مجزا و تا زمان تحقق شرط توقف که در این مطالعه رسیدن به ۱۰۰ تکرار در نظر گرفته شده است، صورت پذیرفت (شکل ۵). اندازه جمعیت اولیه در هر دو الگوریتم برابر با ۲۰ انتخاب گردید. مقادیر ω و θ_{damp} در الگوریتم ازدحام ذرات به ترتیب برابر با ۱ و ۰/۹۹ در نظر گرفته شد. همچنین، پارامترهای c_1 و c_2 در این الگوریتم به طور یکسان و برابر با ۲ انتخاب گردید. از سوی دیگر، در الگوریتم ژنتیک از عملگر انتخاب چرخ رولت^۴ استفاده شد. همچنین، مقادیر احتمال تقاطع، احتمال جهش و نرخ جهش^۵ در این الگوریتم


1. Tangent Sigmoid (Tansig)
2. Pure linear (Purelin)
3. Levenberg-Marquardt
4. Roulette-Wheel
5. Mutation Rate



شکل ۵ روندنمای مراحل آموزش شبکه عصبی مصنوعی در ترکیب با الگوریتم‌های فراابتکاری ژنتیک و ازدحام ذرات

جدول ۱ مقایسه آماری عملکرد شبکه عصبی مصنوعی بر پایه الگوریتم‌های آموزشی پس انتشار (ANN-BP)، ژنتیک (ANN-GA) و ازدحام ذرات (ANN-PSO) جهت برآورد پارامترهای ژئوشیمیایی مورد بررسی در این مطالعه

آزمون		آموزش		روش	پارامتر هدف
RMSE	R ²	RMSE	R ²		
۰/۴۰۵۸	۰/۷۸۳۰	۰/۳۹۶۳	۰/۸۱۴۶	ANN-BP	TOC (wt.%)
۰/۳۶۲۵	۰/۸۳۳۹	۰/۳۵۴۸	۰/۸۵۳۰	ANN-GA	
۰/۳۴۲۴	۰/۸۵۴۸	۰/۳۲۸۹	۰/۸۷۲۲	ANN-PSO	
۲/۶۱۶۷	۰/۸۲۴۳	۱/۸۱۵۷	۰/۹۰۵۵	ANN-BP	S ₂ (mg HC/g rock)
۲/۳۰۹۶	۰/۸۶۹۴	۱/۷۳۲۶	۰/۹۱۴۲	ANN-GA	
۱/۹۴۰۴	۰/۹۰۸۹	۱/۴۰۵۰	۰/۹۴۷۶	ANN-PSO	




شکل ۶ تطابق مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده پارامترهای الف) کل محتوی کربن آلی (TOC) و ب) پتانسیل باقی‌مانده هیدروکربنی (S_2) در داده‌های آزمون

منشأ به‌عنوان تابعی از محتوی هیدروژن قابل ارزیابی است [۴۶]. بنابراین، ارتباط میان پارامترهای کل محتوی کربن آلی و پتانسیل باقی‌مانده هیدروکربنی می‌تواند به‌منظور تعیین شاخص هیدروژن ($HI = S_2/TOC \times 100$) و متعاقباً نوع کروژن که به نوبه خود تعیین‌کننده نوع هیدروکربن تولیدی از سنگ منشأ است، مورد استفاده قرار گیرد. در این راستا، انواع کروژن‌های نوع I (شدیداً نفت‌زا)، II (نفت‌زا)، II/III (نفت‌زا و گاززا)، III (گاززا) و IV (عقیم یا خنثی) به‌ترتیب با مقادیر شاخص هیدروژن بیش‌تر از ۷۰۰، ۷۰۰-۴۰۰، ۴۰۰-۲۰۰، ۲۰۰-۵۰ و کمتر از ۵۰ mg هیدروکربن بر گرم کل کربن آلی ($mg\ HC/g\ TOC$) قابل تمایز هستند [۴۷]. همچنین، کروژن‌های نوع I، II و III به‌ترتیب منعکس‌کننده محیط‌های دریاچه‌ای، دریایی و قاره‌ای بوده و کروژن نوع IV نیز از مواد آلی نابرجا و شدیداً اکسیدشده منشأ گرفته است [۴۶ و ۴۸].

از لحاظ آماری و با توجه به نتایج حاصل از آنالیز برازش خطی (شکل ۷)، دقت بیشتر سیستم ANN-PSO به‌واسطه مقادیر بالاتر ضریب تعیین و همچنین خطای جذر میانگین مربعات کمتر مشخص می‌گردد. بر این اساس، شبکه عصبی مصنوعی در ترکیب با الگوریتم بهینه‌سازی ازدحام ذرات، امکان برآورد مقادیر کل محتوی کربن آلی و پتانسیل باقی‌مانده هیدروکربنی را به‌ترتیب با ضریب تعیین R^2 ۰/۸۵۴۸ و ۰/۹۰۸۹ و همچنین خطای جذر میانگین مربعات (RMSE) ۰/۳۴۲۴ و ۱/۹۴۰۴ در داده‌های آزمون فراهم آورده و می‌تواند به‌منظور تخمین پیوسته پارامترهای ژئوشیمیایی مذکور در سازند پابده با استفاده از داده‌های چاه‌پیمایی RHOB، NPHI، DT و SGR با کارایی بالا مورد استفاده قرار گیرد (جدول ۱).

تعیین شاخص هیدروژن و نوع کروژن

کیفیت ماده آلی و یا نوع کروژن موجود در سنگ



شکل ۷ نمودارهای متقاطع میان مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده پارامترهای (الف) کل محتوی کربن آلی (TOC) و (ب) پتانسیل باقی‌مانده هیدروکربنی (S_2) در داده‌های آزمون



به‌ویژه مدل‌سازی سیستم نفتی برخوردار است. شایان ذکر است که پتانسیل زایش نفت و گاز از سنگ منشأ به‌طور عمده تابعی از غنی‌شدگی آلی^۱ و نوع کروژن است. به‌طور کلی، سنگ‌های منشأ نابالغ با مقادیر کل کربن آلی کمتر از ۰/۵-۱، ۰/۵-۲، ۲-۴ و بیشتر از ۴٪ وزنی (%wt) به‌ترتیب پتانسیل ضعیف، متوسط، خوب، بسیار خوب و عالی را به‌منظور زایش هیدروکربن نشان می‌دهند. همچنین پتانسیل هیدروکربن‌زایی انواع کروژن با افزایش محتوی هیدروژن، افزایش می‌یابد [۴۶]. در این راستا و به‌منظور زون‌بندی ژئوشیمیایی سازند پابده در یکی از چاه‌های میدان نفتی منصوری، شبکه عصبی مصنوعی در ترکیب با الگوریتم فراابتکاری ازدحام ذرات به‌منظور تخمین پیوسته پارامترهای ژئوشیمیایی کل محتوی کربن آلی، پتانسیل باقی‌مانده است.

با توجه به دقت بیشتر سیستم ANN-PSO در برآورد پارامترهای TOC و S_2 از نمودارهای چاه‌پیمایی، نتایج حاصل از این روش به‌منظور تعیین شاخص هیدروژن مورد استفاده قرار گرفت (جدول ۲). بر این اساس، مقادیر شاخص هیدروژن برای داده‌های آزمون با ضریب تعیین $R^2 = 0.6882$ برآورد گردید (شکل ۸). همچنین، مقایسه کیفیت ماده آلی بر مبنای مقادیر اندازه‌گیری و پیش‌بینی‌شده شاخص هیدروژن، عملکرد مناسب روش ANN-PSO جهت طبقه‌بندی انواع کروژن با دقت ۷۴٪ را نشان می‌دهد. شایان ذکر است که بر مبنای نتایج حاصله، این روش از دقت بالاتری در تفکیک کروژن نوع II نسبت به انواع II/III و III برخوردار است.

زون‌بندی ژئوشیمیایی و ارزیابی پتانسیل هیدروکربن‌زایی زون‌بندی ژئوشیمیایی سنگ منشأ به‌منظور شناسایی و تفکیک نواحی دارای پتانسیل هیدروکربن‌زایی مناسب از اهمیت ویژه‌ای در مطالعات اکتشافی

جدول ۲ مقایسه شاخص هیدروژن و نوع کروژن حاصل از آنالیز راک - ایول (هدف) و روش ANN-PSO (خروجی) در داده‌های آزمون


شماره نمونه	شاخص هیدروژن (mg HC/g TOC)		نوع کروژن	
	هدف	خروجی	هدف	خروجی
۱	۱۲۱	۱۲۵	III	III
۲	۶۴۰	۵۲۹	II	II
۳	۲۵۲	۲۹۹	II-III	II-III
۴	۳۸۳	۲۳۱	II-III	II-III
۵	۱۱۳	۱۱۷	III	III
۶	۴۴۸	۴۰۲	II	II
۷	۱۰۷	۳۷۱	III	II-III
۸	۲۱۹	۱۱۵	II-III	III
۹	۱۹۰	۳۵۱	III	II-III
۱۰	۵۱۷	۵۷۱	II	II
۱۱	۵۶۹	۵۴۴	II	II
۱۲	۲۱۳	۲۵۵	II-III	II-III
۱۳	۱۶۸	۸۸	III	III
۱۴	۲۶۱	۲۵۹	II-III	II-III
۱۵	۱۳۲	۲۹۹	III	II-III
۱۶	۱۹۹	۲۱۶	III	II-III
۱۷	۲۲۲	۳۹۳	II-III	II-III
۱۸	۶۷۵	۵۲۹	II	II
۱۹	۴۵۹	۵۱۲	II	II
۲۰	۶۰۳	۵۸۰	II	II
۲۱	۵۶۳	۶۲۷	II	II
۲۲	۱۲۳	۲۵۸	III	II-III
۲۳	۱۸۴	۱۲۳	III	III



شکل ۸ الف) تطابق مقادیر شاخص هیدروژن اندازه‌گیری شده و پیش‌بینی شده به واسطه شبکه عصبی مصنوعی در ترکیب با الگوریتم بهینه‌سازی ازدحام ذرات (ANN-PSO predicted) و ب) رگرسیون خطی میان آن‌ها در داده‌های آزمون

محتوی کربن آلی در بخش‌های بالایی و پایینی سازند پابده به‌ترتیب برابر با ۱/۴۷ wt.% و ۱/۲۸ wt.% برآورد گردید. این بخش‌ها با برخورداری از شاخص هیدروژن کمتر (به‌ترتیب با میانگین ۲۸۳ HC/g TOC و ۲۰۲ mg HC/g TOC) به‌طور عمده دربرگیرنده کروژن‌های نوع III و II-III با پتانسیل تولید گاز و نفت بوده که به‌ترتیب منعکس‌کننده منشأ قاره‌ای و حدواسط مواد آلی تشکیل‌دهنده آن‌ها است. کاهش محتوی هیدروژن در مواد آلی بخش‌های بالایی و پایینی سازند پابده نسبت به واحد شیل قهوه‌ای (BSU) می‌تواند به‌دلیل کاهش تراز آب دریا در زمان رسوب‌گذاری آن‌ها باشد. در هر حال، بخش میانی سازند پابده در صورت رسیدن به بلوغ حرارتی مناسب می‌تواند به‌طور چشم‌گیری در زایش هیدروکربن و شارژ تله‌های نفتی میدان ایفای نقش نماید.

هیدروکربنی و همچنین شاخص هیدروژن و متعاقباً نوع کروژن از نمودارهای چاه‌پیمایی با قدرت تفکیک^۱ حدود ۱۵ cm به‌کار برده شد. با توجه به نتایج حاصل از زون‌بندی ژئوشیمیایی بر مبنای غنی‌شدگی آلی و نوع کروژن، سازند پابده در میدان نفتی منصوری از سه بخش قابل تفکیک با پتانسیل هیدروکربن‌زایی متفاوت تشکیل شده است (شکل ۹). بخش میانی سازند پابده با برخورداری از مقادیر بیشتر کل محتوی کربن آلی و شاخص هیدروژن (به‌ترتیب با میانگین ۲/۶۱ wt.% و ۲۸۳ mg HC/g TOC)، پتانسیل هیدروکربن‌زایی بیشتری نسبت به بخش‌های بالایی و پایینی به نمایش می‌گذارد. این بخش از سازند پابده که تحت عنوان واحد شیل قهوه‌ای^۲ نیز شناخته می‌شود [۴۹]، به‌طور عمده از کروژن نوع II با پتانسیل بالای زایش نفت تشکیل شده و با ته‌نشست سازند در محیط دریایی انطباق دارد. از سوی دیگر، میانگین کل



1. Resolution
2. Brown Shale Unit, BSU

نتیجه گیری

به منظور دستیابی به روشی بهینه و کارآمد جهت تخمین پارامترهای ژئوشیمیایی کل محتوی کربن آلی (TOC) و پتانسیل باقی مانده هیدروکربنی (S_2) از نمودارهای چاه پیمایی که امکان ارزیابی پیوسته شاخص هیدروژن (HI)، نوع کروژن و پتانسیل هیدروکربن زایی را فراهم می آورد، عملکرد شبکه عصبی مصنوعی بر پایه روش آموزش متداول پس انتشار (BP-ANN) و همچنین الگوریتم های فراابتکاری ژنتیک (ANN-GA) و ازدحام ذرات (ANN-PSO) بر روی سازند پابده (الیگوسن - میوسن) در میدان نفتی منصوری ارزیابی و مقایسه گردید. بدین منظور، نمودارهای چاه پیمایی صوتی (DT)، نوترون (NPHI)، چگالی (RHOB) و پرتو گاما (SGR) که همبستگی مناسبی با پارامترهای TOC و S_2 در سازند مورد مطالعه نشان دادند مورد استفاده قرار گرفتند. براساس نتایج حاصل از آنالیز برازش خطی میان مقادیر اندازه گیری شده و پیش بینی شده در داده های آزمون، تخمین پارامترهای TOC و S_2 حاصل از آنالیز راک - ایول با استفاده از روش ANN-PSO به واسطه ضریب تعیین (R^2) بیشتر (به ترتیب برابر با ۰/۸۵۴۸ و ۰/۹۰۸۹) و خطای جذر میانگین مربعات (RMSE) کمتر (به ترتیب برابر با ۰/۳۴۲۴ و ۱/۹۴۰۴) از دقت بالاتری نسبت به روش های ANN-BP و ANN-GA برخوردار است. برآورد شاخص هیدروژن بر مبنای ارتباط میان پارامترهای ژئوشیمیایی کل محتوی کربن آلی و پتانسیل باقی مانده هیدروکربنی ($HI = S_2/TOC \times 100$) به واسطه این روش با ضریب تعیین ۰/۶۸۸۲ دقت قابل قبولی را به نمایش گذاشته و امکان تفکیک انواع کروژن با دقت طبقه بندی ۷۴٪ را فراهم می آورد. با توجه به نتایج بدست آمده از روش ANN-PSO، زون بندی ژئوشیمیایی سازند

پابده در میدان نفتی منصوری بر مبنای تغییرات پیوسته غنی شدگی آلی و نوع کروژن صورت پذیرفت و بر این اساس، سه بخش مجزا با پتانسیل هیدروکربن زایی متفاوت شناسایی شد. بخش میانی سازند مورد مطالعه (واحد شیل قهوه ای) از پتانسیل هیدروکربن زایی بیشتری نسبت به بخش های بالایی و پایینی برخوردار بوده و به طور عمده از کروژن نوع II با منشأ دریایی و پتانسیل بالای نفت زایی تشکیل شده است. بنابراین، واحد شیل قهوه ای در صورت برخورداری از بلوغ حرارتی مناسب می تواند مقادیر قابل توجهی هیدروکربن تولید نموده و در شارژ تله های نفتی میدان مشارکت نماید. در مجموع می توان اذعان داشت که روش ANN-PSO در مقایسه با روش های ANN-BP و ANN-GA ارزیابی پتانسیل هیدروکربن زایی سازند پابده در میدان نفتی منصوری را با دقت بیشتری امکان پذیر ساخته و بر این اساس می تواند به عنوان ابزاری کارآمد در مطالعات سیستم نفتی مورد استفاده قرار گیرد.

تشکر و قدردانی

بدین وسیله از حمایت مالی معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز در قالب پژوهانه (GN: SCU.EG99.714) در انجام این تحقیق تشکر و قدردانی می گردد. نویسندگان این مقاله بر خود لازم می دانند از شرکت ملی مناطق نفت خیز جنوب به ویژه اداره پژوهش و فناوری به دلیل حمایت مالی و تأمین نمونه های مورد نیاز و همچنین مرکز تحقیقات زمین شناسی و زمین شیمی نفت دانشگاه شهید چمران اهواز جهت فراهم نمودن تسهیلات آزمایشگاهی مورد استفاده در این پژوهش قدردانی نمایند.

مراجع

- [1]. Meyer BL, Nederlof MH (1984) Identification of source rocks on wireline logs by density/resistivity and sonic transit time/resistivity crossplots, AAPG Bulletin, 68:121-129.
- [2]. Passey QR, Creaney S, Kulla JB, Moretti FJ, Stroud JD (1990) A practical model for organic richness from porosity and resistivity logs, AAPG Bulletin, 74:1777-1794.
- [3]. Huang Z, Williamson MA (1996) Artificial neural network modelling as an aid to source rock characterization, Marine and Petroleum Geology, 13:277-290.
- [4]. Kamali MR, Mirshady AA (2004) Total organic carbon content determined from well logs using ΔLogR and Neuro Fuzzy techniques, Journal of Petroleum Science and Engineering, 45:141-148.
- [5]. Alizadeh B, Najjari S, Kadkhodaie-Ilkhchi A (2012) 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 and Geosciences, 45:261-269.
- [6]. Siddig O, Ibrahim AF, Elkatatny S (2021) Application of various machine learning techniques in predicting total organic carbon from well logs, Computational Intelligence and Neuroscience, 2021:1-8.
- [7]. Alizadeh B, Maroufi K, Heidarifard MH (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.
- [8]. Asgari Nezhad Y, Moradzadeh A, Kamali MR (2018) A new approach to evaluate organic geochemistry parameters by geostatistics methods: A case study from Western Australia, Journal of Petroleum Science and Engineering, 169:813-824.
- [9]. Dreyfus G (2005) Neural networks: Methodology and applications, Berlin: Springer.
- [10]. Yu C C, Liu B D (2002) A backpropagation algorithm with adaptive learning rate and momentum coefficient, Proceedings of the 2002 International Joint Conference on Neural Networks, Honolulu, 1218-1223.
- [11]. Gowda CC, Mayya SG (2014) Comparison of back propagation neural network and genetic algorithm neural network for stream flow prediction, Journal of Computational Environmental Sciences, 2014:1-6.
- [12]. Katoch S, Chauhan SS, Kumar V (2021) A review on genetic algorithm: Past, present, and future, Multimedia Tools and Applications, 80:8091-8126.
- [13]. Hosseini Z, Gharechelou S, Nakhaei M, Gharechelou S (2016). Optimal design of BP algorithm by ACOR model for groundwater-level forecasting: A case study on Shabestar plain, Iran, Arabian Journal of Geosciences, 9:436.
- [۱۴]. خامه‌چی، قاسمی، کاشی م (۱۳۹۸) تخمین دقیق پارامترهای چاه‌آزمایی با استفاده از یک الگوریتم ترکیبی و مقایسه آن با یک نرم‌افزار رایج صنعتی، مجله پژوهش نفت، ۲۹: ۴۰-۲۸.
- [15]. Moazzeni A, Khamenechi E (2019) Drilling rate optimization by automatic lithology prediction using hybrid machine learning, Journal of Petroleum Science and Technology, 9:77-88.
- [16]. Pakdel M, Behroozsarand A (2020) Using hybrid artificial neural network-particle swarm optimization for prediction of HIPS mechanical properties, Journal of Petroleum Science and Technology, 10:53-66.
- [17]. Hosseini Z, Gharechelou S, Mahboubi A, Moussavi-Harami R, Kadkhodaie-Ilkhchi A, Zeinali M (2021) Shear wave velocity estimation utilizing statistical and multi-intelligent models from petrophysical data in a mixed carbonate-siliciclastic reservoir in Southwest of Iran, Iranian Journal of Oil and Gas Science and Technology, 10:15-39.
- [۱۸]. حسینی ز، محبوبی، کدخدائی ع (۱۳۹۶) آنالیز یک مدل‌سازی ترکیبی به‌منظور تعیین TOC در سنگ‌های منشأ میدان نفتی اهواز، مجله پژوهش نفت، ۲۷: ۵۹-۴۸.
- [19]. 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.
- [20]. Tabatabaei SME, Kadkhodaie-Ilkhchi A, Hosseini Z, Asghari Moghaddam 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.
- [21]. Wang P, Peng S, 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.
- [22]. 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, In: Leturmy P, Robin C, eds. Tectonic and Stratigraphic Evolution of Zagros and Makran during the Mesozoic-Cenozoic, London: Geological Society of London, Special Publications, 291-353.

- [23]. Sherkati S, Letouzey J (2004) Variation of structural style and basin evolution in the central Zagros (Izeh zone and Dezful Embayment), Iran, *Marine and Petroleum Geology*, 21:535-554.
- [24]. Sepehr M, Cosgrove JW (2004) Structural framework of the Zagros Fold-Thrust Belt, Iran, *Marine and Petroleum Geology*, 21:829-843.
- [۲۵]. مرادی م، موسوی حرمی س ر، صادقی ق (۱۳۹۴) تهیه مدل ژئواستاتیک مخزن آسماری میدان نفتی منصوری با استفاده از نرم افزار RMS، مجله پژوهش نفت، ۲۵: ۱۷۳-۱۸۵.
- [۲۶]. آقانباتی س ع (۱۳۸۳) زمین شناسی ایران، انتشارات سازمان زمین شناسی و اکتشافات معدنی کشور، تهران.
- [27]. Espitalié J, Laporte JL, Madec M, Marquis F, Leplat P, Paulet J, Boutefeu A (1997) Méthode rapide de caractérisation des roches mères, de leur potentiel pétrolier et de leur degré d'évolution, *Revue de l'Institut Français du Pétrole*, 32:23-42.
- [28]. Baudin F, Disnar J, Aboussou A, Savignac F (2015) Guidelines for Rock-Eval analysis of recent marine sediments, *Organic Geochemistry*, 86:71-80.
- [29]. Lafargue E, Marquis F, Pillot D (1998) Rock-Eval 6 applications in hydrocarbon exploration, production, and soil contamination studies, *Revue de l'Institut Français du Pétrole*, 53:421-437.
- [30]. Alizadeh B, Seyedali SR, Sarafdokht H (2019) Effect of bitumen and migrated oil on hydrocarbon generation kinetic parameters derived from Rock-Eval pyrolysis, *Petroleum Science and Technology*, 37:2114-2121.
- [31]. Walczak S, Cerpa N (2003) Artificial neural networks, In: Meyers RA, ed. *Encyclopedia of Physical Science and Technology*, 3rd ed., New York: Academic Press, 631-645.
- [32]. McCulloch WS, Pitts WH (1943) A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, 5:115-133.
- [33]. Graupe D (2013) *Principles of artificial neural networks*, 3rd ed., Singapore: World Scientific.
- [34]. Sairamya NJ, Susmitha L, George ST, Subathra MSP (2019) Hybrid approach for classification of electroencephalographic signals using time-frequency images with wavelets and texture features, In: Hemanth DJ, Gupta D, Balas VE, eds. *Intelligent data analysis for biomedical applications: Challenges and solutions*, Academic Press, 253-273.
- [35]. Holland JH (1975) *Adaptation in natural and artificial systems*, Ann Arbor: The University of Michigan Press.
- [36]. Sivanandam SN, Deepa SN (2008) *Introduction to genetic algorithms*, Berlin: Springer-Verlag.
- [37]. Kennedy J, Eberhart R (1995) Particle swarm optimization, *Proceedings of IEEE international conference on neural networks*, Perth, Australia, 1942-1948.
- [38]. Upendar J, Gupta CP, Singh GK, Ramakrishna G (2010) PSO and ANN-based fault classification for protective relaying, *IET Generation, Transmission and Distribution*, 4:1197-1212.
- [39]. Jain NK, Nangia U, Jain J (2018) A review of particle swarm optimization, *Journal of The Institution of Engineers (India): Series B*, 99:407-411.
- [40]. Chan FTS, Tiwari MK (2007) *Swarm intelligence: Focus on ant and particle swarm optimization*, Vienna: I-Tech Education and Publishing.
- [41]. de Almeida BSG, Leite VC (2019) Particle swarm optimization: A powerful technique for solving engineering problems, In: Del Ser J, Villar E, Osaba E, eds. *Swarm intelligence: Recent advances, new perspectives and applications*, London: IntechOpen, 31-52.
- [42]. Semero YK, Zhang J, Zheng D (2018) PV power forecasting using an integrated GA-PSO-ANFIS approach and Gaussian process regression based feature selection strategy, *CSEE Journal of Power and Energy Systems*, 4:210-218.
- [43]. Chau KW (2007) Application of a PSO-based neural network in analysis of outcomes of construction claims, *Automation in Construction*, 16:642-646.
- [44]. Nadi A, Tayarani-Bathaie SS, Safabakhsh R (2009) Evolution of neural network architecture and weights using mutation based genetic algorithm, *Proceedings of the 14th International CSI Computer Conference*, Tehran, Iran, 536-540.
- [۴۵]. جنت‌مکان ن. (۱۳۹۰) انطباق داده‌های ژئوشیمیایی آلی با چینه‌نگاری سکانسی جهت ارزیابی پتانسیل هیدروکربوری سازند پابده در میدان نفتی منصوری، پایان‌نامه کارشناسی ارشد، دانشگاه شهید چمران اهواز.
- [46]. Peters KE, Cassa MR (1994) Applied source rock geochemistry, In: Magoon LB, Dow WG, eds. *The petroleum system - From source to trap*, Tulsa: American Association of Petroleum Geologists.
- [47]. Langford FF, Blanc-Valleron MM (1990) Interpreting Rock-Eval pyrolysis data using graphs of pyrolyzable

hydrocarbons vs. total organic carbon, AAPG Bulletin, 74:799-804.

[48]. McCarthy K, Rojas K, Niemann M, Palmowski D, Peters K, Stankiewicz A (2011) Basic petroleum geochemistry for source rock evaluation, Oilfield Review, 23:32-43.

[49]. Alizadeh B, Opera A, Kalani M, Alipour M (2020) Source rock and shale oil potential of the Pabdeh Formation (Middle-Late Eocene) in the Dezful Embayment, southwest Iran, Geologica Acta, 18:1-22.

Geochemical zonation of Pabdeh Formation from organic richness and kerogen type points of view indicates three distinctive parts. The middle part in this formation, which is called Brown Shale Unit (BSU), demonstrates the higher petroleum generation potential by having the greater TOC and HI values and is mainly composed of marine type II kerogen (Fig. 4). The BSU is consequently capable of generating significant amounts of oil and gas where it experiences appropriate thermal maturity.




Fig. 4 Geochemical zonation of Pabdeh Formation in one of the wells of Mansuri oilfield based on the ANN-PSO derived TOC and HI parameters.

Conclusions

Comparing the performance of computational ANN-BP, ANN-GA, and ANN-PSO techniques to predict TOC and S_2 geochemical parameters from wireline data for Pabdeh Formation in Mansuri oilfield (SW Iran) represents the higher accuracy of the ANN-PSO method. Three distinctive parts are revealed in Pabdeh Formation based on the organic richness and kerogen type characteristics inferred from ANN-PSO derived TOC and HI ($S_2/TOC \times 100$) parameters, respectively. Among them, the middle part (Brown Shale Unit, BSU) is dominated by marine type II kerogen, and represents

more potential for hydrocarbon generation. Overall, it can be concluded that the ANN-PSO model designed in this study can be efficiently applied to evaluate the petroleum generation potential of the Pabdeh Formation; and therefore, it is able to enhance the accuracy of petroleum system modeling in the studied area.

Acknowledgments

We are grateful to the Research Council of Shahid Chamran University of Ahvaz for financial support (Grant Number SCU.EG99.714). National Iranian South Oil Company (NISOC), especially the Research and Technology office, and Petroleum Geology and Geochemistry Research Center (PGGRC) of Shahid Chamran University of Ahvaz are also acknowledged.

Nomenclatures

HI: Hydrogen index

MSE: Mean square error

PSO: Particle swarm optimization

TOC: Total organic carbon

References

1. Passey Q R, Creaney S, Kulla J B, Moretti F J, Stroud J D (1990) A practical model for organic richness from porosity and resistivity logs, AAPG Bulletin, 74: 1777-1794.
2. Kamali MR, Mirshady AA (2004) Total organic carbon content determined from well logs using ΔLogR and Neuro Fuzzy techniques, Journal of Petroleum Science and Engineering, 45:141-148.
3. Dreyfus G (2005) Neural networks: Methodology and applications, Berlin: Springer.
4. Yu CC, Liu BD (2002) A backpropagation algorithm with adaptive learning rate and momentum coefficient, Proceedings of the 2002 International Joint Conference on Neural Networks, Honolulu, 1218-1223.
5. Katoch S, Chauhan SS, Kumar V (2021) A review on genetic algorithm: Past, present, and future, Multimedia Tools and Applications, 80:8091-8126.
6. Bordenave ML, Hegre JA (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, In: Leturmy P, Robin C, eds. Tectonic and Stratigraphic Evolution of Zagros and Makran during the Mesozoic-Cenozoic, London: Geological Society of London, Special Publications, 291-353.
7. Chau KW (2007) Application of a PSO-based neural network in analysis of outcomes of construction claims, Automation in Construction, 16:642-646.
8. Langford FF, Blanc-Valleron MM (1990) Interpreting Rock-Eval pyrolysis data using graphs of pyrolyzable hydrocarbons vs. total organic carbon, AAPG Bulletin, 74:799-804.