

Estimation of reservoir rock properties from conventional well log data by using a hybrid particle swarm optimization and neural network approach

Iman Zahmatkesh^{1*}, Abouzar Mohsenipour¹, Amin Amraei²

1-Department of Geology, Faculty of Earth Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran

2-Petropars Company, Tehran, Iran

Keywords: Hybrid particle swarm optimization –neural network strategy (PSO–ANN), Reservoir parameters, Permeability, Particle swarm optimization

1-Introduction

The geomechanical and petrophysical parameters of the reservoir such as shear wave velocity, porosity and permeability are regarded as the most important elements in estimating reserves, reservoir simulation, and overall field exploitation and development strategies. Recently, several different methods of artificial intelligence techniques have been used to predict this fundamental parameter by using well log data. However, predicting the characteristics of heterogeneous reservoirs always has been facing many problems and an appropriate response is rarely achieved. This study offers an improved approach for reservoir parameters estimation by integration of stochastic optimization in the structure of a neural network system.

2-Methodology

Cost function minimization is the main objective of an ANN, which is achieved by adjusting weights and biases in the training process. The classical ANN training methods, such as backpropagation (BP) is the strong dependence upon the initial guess. Some researchers have used evolutionary methods to train neural networks and found that implementation of hybrid techniques such as PSO-based ANN provide a better predicting ability than the standard backpropagation algorithm (Grimaldi et al., 2004; Chau, 2007; Karimi and Yousefi, 2012; Dhanarajan et al., 2014; Zahmatkesh et al., 2017). In a PSO-based ANN, each particle represents a possible solution for minimizing the MSE. So after neural network constructed, we feed training data to the network whose weights and biases are determined by the particle's position. In every iteration, network get the outputs and compare it the desired outputs. This procedure will continue until stopping criterion is satisfied, in the other words found a position (weights) so that the network trained by PSO generates computed outputs that match the outputs of the training data.

3- Results and discussion

Experimental results revealed that PSO-ANN outperforms the other models of GA-ANN, ANN and ANFIS in terms of reliability and the ability to achieve the minimum estimation error, and PSO algorithm can be used for the purpose of improving the computational efficiency and performance of a neural network system.

4- Conclusion

In this paper, a new methodology is presented for reservoir parameters (shear wave velocity, porosity and permeability) estimation by combining artificial neural network and Particle Swarm optimization (PSO) in Asmari formation of Mansuri oilfield. Performance of proposed hybrid scheme was evaluated by comparing the results with the most common Neural Network and Nero-Fuzzy methods as well as hybrid genetic algorithm–neural network strategy (GA–NNN). Comparison of the results shows that PSO-ANN outperforms all the other

*Corresponding author: i.zahmatkesh@scu.ac.ir

DOI: 10.22055/AAG.2020.31475.2047

Received 2019-10-21

Accepted 2020-02-06

methods and it can be considered as a powerful tool for reservoir parameters estimation, especially in cases where a precise estimation criterion is crucial.

References

- Chau, K.W., 2007. Application of a PSO-based neural network in analysis of outcomes of construction claims. *Automation in Construction* 16, 642-646.
- Dhanarajan, G., Mandal, M., Sen, R., 2014. A combined artificial neural network modeling–particle swarm optimization strategy for improved production of marine bacterial lipopeptide from food waste. *Biochemical Engineering Journal* 84, 59–65.
- Grimaldi, E.M., Grimaccia, F., Mussetta, M., Zich, R.E., 2004. PSO as an effective learning algorithm for neural network applications. In *Computational Electromagnetics and Its Applications, 2004. Proceedings. ICCEA 2004. 2004 3rd International Conference on IEEE*, pp. 557–560.
- Karimi, H., Yousefi, F., 2012. Application of artificial neural network–genetic algorithm (ANN–GA) to correlation of density in nanofluids. *Fluid Phase Equilibria* 336, 79–83.
- Zahmatkesh, I., Soleimani, B., Kadkhodaie, A., Golalzadeh, A., Abdollahi, A.M., 2017. Estimation of DSI log parameters from conventional well log data using a hybrid particle swarm optimization–adaptive neuro-fuzzy inference system. *Journal of Petroleum Science and Engineering* 157, 842-859.

HOW TO CITE THIS ARTICLE:

Zahmatkesh, I., Mohsenipour, A., Amraei, A., 2020. Estimation of reservoir rock properties from conventional well log data by using a hybrid particle swarm optimization and neural network approach. *Adv. Appl. Geol.* 10(1), 96-109.

DOI: 10.22055/AAG.2020.31475.2047

url: https://aag.scu.ac.ir/article_15338.html?lang=en

تخمین پارامترهای مخزنی با استفاده از داده های چاه پیمایی و بهره گیری از ترکیب شبکه عصبی مصنوعی و الگوریتم بهینه سازی ازدحام ذرات

ایمان زحمت کش*

گروه زمین شناسی، دانشکده علوم زمین، دانشگاه شهید چمران اهواز، اهواز، ایران

ابوذر محسنی پور

گروه زمین شناسی، دانشکده علوم زمین، دانشگاه شهید چمران اهواز، اهواز، ایران

امین امرایی

شرکت پتروپارس، تهران، ایران

تاریخ پذیرش: ۱۳۹۸/۱۱/۱۷

تاریخ دریافت: ۱۳۹۸/۰۷/۲۹

*i.zahmatkesh@scu.ac.ir

چکیده

پارامترهای ژئومکانیکی و پتروفیزیکی مخزن همانند سرعت موج برشی، تخلخل و تراوایی از جمله پارامترهای مهمی هستند که در شبیه سازی مخازن هیدروکربوری و استراتژی های اکتشافی و بهره برداری نقش موثری ایفا می کنند. اخیراً روش های مختلف هوش مصنوعی به منظور پیش بینی این پارامترهای اساسی با استفاده از داده های چاه پیمایی به کار برده شده اند. با این حال پیش بینی ویژگی های مخازن ناهمگن همواره با دشواری های بسیاری همراه بوده است و به سختی پاسخ مناسبی به دست آمده است. در این مطالعه تلاش شده است تا پارامترهای مخزنی سرعت موج برشی، تخلخل و تراوایی با استفاده از روش نوین ترکیب شبکه عصبی مصنوعی و الگوریتم بهینه سازی ازدحام ذرات (PSO-ANN)، در مخزن هتروژن آسماری میدان منصوری تخمین زده شود. سپس عملکرد این مدل ترکیبی با هر کدام از روش های کلاسیک و مرسوم شبکه عصبی مصنوعی (ANN) و سیستم تطبیقی استنتاج نروفازی (ANFIS) و همچنین روش ترکیب شبکه عصبی مصنوعی و الگوریتم ژنتیک (GA-ANN) مورد مقایسه قرار گرفته است. نتایج نشان دهنده عملکرد بسیار مناسب روش ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه سازی ازدحام ذرات در تخمین پارامترهای مخزنی است. بنابراین می توان از مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه سازی ازدحام ذرات به عنوان یک روش قدرتمند در تخمین سایر پارامترهای مخزنی به خصوص در مواقعی که دقت بالای پیش بینی لازم باشد استفاده نمود.

کلمات کلیدی: الگوریتم ازدحام ذرات، مدل الگوریتم ازدحام ذرات-شبکه عصبی (PSO-ANN)، پارامترهای مخزنی، تراوایی

مقدمه

سرعت موج برشی، تخلخل و تراوایی جزو پارامترهای ضروری برای توصیف مخازن هیدروکربوری هستند که معمولاً بوسیله روش های آزمایش مغزه در آزمایشگاه و تفسیر داده های حاصل از آزمایش چاه (برای اندازه گیری تراوایی) یا اطلاعات حاصل از چاه آزمایی قابل کسب هستند. به دلیل زمان بری و پرهزینه بودن روش های فوق ذکر تاکنون روابط تجربی فراوانی برای محاسبه پارامترهای مخزنی فوق (به خصوص برای سرعت موج برشی) ارائه شده است (Anselmetti and Eberli, 1993; Bastoset al., 1998; Brocher, 2005; Domenico, 1984; Eberhart-Phillips et al., 1989; Garat et al., 1990; Gardner et al., 1974; Murphy and Hsu, 1993) اما به دلیل عدم تعمیم پذیری و وابستگی این روابط به منطقه و میدان مورد مطالعه نمی توان از آنها به شکلی عمومی استفاده نمود. برای غلبه بر این مشکل، در سال های اخیر روش های مختلف هوش مصنوعی با بهره گیری از داده های حاصل از لاگ های چاه پیمایی به طور فزاینده ای در جهت پیش بینی ویژگی های مختلف مخزنی مورد استفاده قرار گرفته است (Jamialahmadi and Javadpour, 2000; Labani et al., 2003; Lim, 2005; Nikraves et al., 2010) در این میان محققین

مختلف از شبکه های عصبی مصنوعی، سیستم استنتاج فازی-عصبی و یا سیستم های ترکیبی برای تخمین پارامترهای مختلف پتروفیزیکی (Kadkhodaie et al., 2009; Kadkhodaie- Ilkhchi and Amini, 2009; Tabatabaei et al., 2015) و توصیف مخزن (Moradi et al., 2017; Sfidari et al., 2012; Tokhmechi et al., 2018) استفاده نموده اند.

در چند دهه اخیر شبکه های عصبی مصنوعی به دلیل عملکرد موفق در زمینه تشخیص و شناسایی مدل در بسیاری از مسایل پیش بینی مورد استفاده قرار گرفته است. یکی از مرسوم ترین انواع شبکه های عصبی، شبکه عصبی پرسپترون چندلایه است که به طور موفقیت آمیزی در بازه وسیعی از کاربردها از جمله تخمین تابع مورد استفاده قرار گرفته است. مهمترین مسئله در ایجاد و توسعه یک شبکه عصبی فرایند آموزش شبکه است. به نحوی که میزان کارایی شبکه های عصبی به طور شگفت انگیزی به نحوه به روز رسانی وزن های شبکه طی فرایند آموزش بستگی دارد. متداول ترین الگوریتم آموزشی شبکه های عصبی، الگوریتم پس انتشار خطا است. که در یک فضای جستجوی مبتنی بر گرادینان و با توجه به خطای به دست آمده برای شبکه به اصلاح وزن های شبکه می پردازد. الگوریتم پس انتشار خطا به شدت به مقدار دهی اولیه وابسته است

عملگر ریاضی تصمیم‌گیری می‌کند که آیا نرون فعال شود یا خیر و اگر جواب مثبت باشد میزان خروجی را مشخص می‌سازد (شکل ۱a). بنابراین نرون یک واحد محاسبه‌ای است که یک برداری از مقادیر ورودی را گرفته و یک مقدار خروجی را تولید می‌کند. به عبارت دیگر هر نرون ورودی‌های وارد شده به شبکه را به یک خروجی پردازش می‌کند (Von Altrock, 1995). به نحوی که با استفاده از شبکه‌های عصبی و با انجام محاسبات روی داده‌های عددی، می‌توان دانش تجربی را فرا گرفته، ذخیره کرده و مورد استفاده قرار داد.

یکی از ساده‌ترین و کارآمدترین نوع شبکه عصبی مدل پرسپترون چندلایه (Multi-layer perceptron) است که متشکل از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشد (Meulenkamp and Grima, 1999). در ساختار این شبکه تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصلند. شکل ۱a شمای یک شبکه پرسپترون سه لایه را نشان می‌دهد. در این شکل نرون‌های هر لایه با تمام نرون‌های لایه بعدی یا قبلی ارتباط دارند، اما نرون‌های یک لایه با یکدیگر مرتبط نیستند، و این امر باعث عملکرد موازی نرون‌ها می‌شود. در شکل ۱a، هر دایره تجمیع شده عمل جمع و عملگر ریاضی است. بنابراین خروجی شبکه عصبی (در لایه آخر) را می‌توان به صورت زیر نشان داد:

$$\begin{aligned} O &= f(\text{net}), \quad \text{net} \\ &= b + \omega_1 x_1 + \dots + \omega_n x_n \\ &= b + \sum \omega_i x_i \end{aligned}$$

که در آن منظور از ω و b وزن و بایاس شبکه عصبی بوده و f نشان دهنده تابع فعال‌سازی (Activation function) است. که شامل یک فرمول ریاضی برای برورسانی وزن‌ها در شبکه است

آموزش شبکه عصبی

الگوریتم‌های آموزشی متنوعی جهت آموزش شبکه‌های عصبی به کار می‌رود. متداول‌ترین و محبوب‌ترین الگوریتم آموزشی این شبکه‌ها، الگوریتم پس-انتشار خطا (Error back propagation) می‌باشد. در این الگوریتم به عنوان یکی از روش‌های با سرپرست (Supervised) نمونه‌های ورودی برچسب خورده‌اند و خروجی موردانتظار هر یک از آنها از پیش مشخص است. لذا خروجی شبکه با این خروجی‌های ایده‌آل مقایسه شده و خطای شبکه محاسبه می‌گردد. در این الگوریتم ابتدا فرض بر این است که وزن‌های شبکه به طور تصادفی انتخاب شده‌اند. در هر گام خروجی شبکه محاسبه شده و بر حسب میزان اختلاف آن با خروجی مطلوب، وزن‌ها تصحیح می‌گردند تا در نهایت این خطا مینیمم شود (Nikraves and Aminzadeh, 2001).

الگوریتم پس انتشار خطا با وجود استفاده گسترده در آموزش شبکه‌های عصبی در حل برخی مسایل کارایی آن ناسازگار و غیرقابل پیش‌بینی بوده است. آهستگی سرعت همگرایی و ناتوانی در فرار کردن از بهینه‌های محلی دو مشکل اصلی الگوریتم پس انتشار خطا می‌باشد که بیشتر ناشی از طبیعت گرادینان این الگوریتم می‌باشد. در سال‌های اخیر تلاش‌های بسیاری برای برطرف کردن این مشکلات انجام شده که مهمترین آنها استفاده از الگوریتم‌های تکاملی و فرا ابتکاری به جای استفاده از الگوریتم معمول در آموزش شبکه عصبی بوده است. بر همین اساس در این مطالعه از الگوریتم تکاملی ازدحام ذرات برای آموزش شبکه عصبی استفاده شده است.

به همین دلیل احتمال گیر افتادن الگوریتم در نقاط بهینه محلی بسیار زیاد است. به علاوه همگرایی دیر و وابستگی به یک پارامتر نرخ یادگیری از دیگر ضعف‌های روش‌های مبتنی بر گرادینان است (Lin et al., 2012; Nawi et al., 2006). از این رو طی سالیان اخیر استفاده از الگوریتم‌های فرامکاشفه‌ای برای آموزش شبکه‌های عصبی مورد توجه محققین مختلف قرار گرفته است (Chau, 2007; Dhanarajan et al., 2014; Grimaldi et al., 2004; Karimi and Yousefi, 2012; Zahmatkesh et al., 2017) الگوریتم‌های فرامکاشفه‌ای عموماً با الهام از فرایندهای فیزیکی و بیولوژیکی در طبیعت به وجود آمده‌اند و غالباً به صورت گروهی عمل می‌کنند. این الگوریتم‌ها بر خلاف روش‌های کلاسیک بهینه‌سازی، به صورت تصادفی عمل کرده و جستجوی فضای مسئله را به صورت موازی و با توجه به تابع برازندگی انجام می‌دهند.


از نمونه این الگوریتم‌ها، الگوریتم ازدحام ذرات است که با الگوگیری و شبیه‌سازی رفتار پرواز دسته جمعی (گروهی) پرندگان یا حرکت دسته جمعی (گروهی) ماهی‌ها بنا نهاده شده است (Eberhart and Kennedy, 1995). این الگوریتم نسبت به الگوریتم‌های پرکاربردی مانند الگوریتم ژنتیک دارای مزایایی همچون مفهوم ساده، پیاده‌سازی آسان، پارامترهای کم برای تنظیم و همگرایی سریع است که امروزه توجه زیادی را به خود جلب کرده است و سبب استفاده و کاربردهای وسیع این الگوریتم در زمینه‌های مختلف شده است (Huang et al., 2005; Rini et al., 2016). الگوریتم ازدحام ذرات در حل بسیاری از مسایل بهینه‌سازی گسسته و غیرخطی پیوسته مورد استفاده قرار گرفته است و نتایج خوبی را در محیط‌های ثابت، نویزی و پیوسته در حال تغییر و دینامیک فراهم کرده است. همکاری و اشتراک گذاری اطلاعات بین ذرات پایه و اساس الگوریتم بهینه‌سازی ازدحام ذرات را تشکیل می‌دهد به علاوه الگوریتم ازدحام ذرات دارای حافظه است به گونه‌ای که دانش راه‌های خوب توسط همه ذرات حفظ می‌شود به عبارتی در این الگوریتم هر ذره‌ای از اطلاعات گذشته خود سود می‌برد در صورتی که چنین رفتاری در سایر الگوریتم‌های تکاملی مانند الگوریتم ژنتیک وجود ندارد و دانش قبلی مسئله یکباره با تغییر جمعیت از بین می‌رود.

در این مطالعه با استفاده از داده‌های چاه‌پیمایی در دسترس و ارزان و با بهره‌گیری از تکنیک ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی ازدحام ذرات، سرعت موج برشی، تخلخل و تراوایی تخمین زده خواهد شد. سپس عملکرد این روش با روش‌های معمول شبکه عصبی و سیستم تطبیقی استنتاج نروفازی و همچنین مدل ترکیبی شبکه عصبی و الگوریتم ژنتیک مقایسه خواهد شد.

روش کار

شبکه عصبی

شبکه عصبی، شبکه‌ای کاملاً به هم پیوسته‌ای از عناصر پردازنده‌ی اطلاعات است که از پیوستگی و عملکرد مغز انسان تقلید می‌کند. یک شبکه عصبی از واحدهای پردازشی اولیه و ساده‌ای به نام نرون (یا گره) و اتصالات بین این واحدها تشکیل می‌شود که این واحدهای اتصالی در حقیقت ضرایب یا فاکتورهای وزنی هستند. نرون‌ها عناصر ضروری شبکه عصبی مصنوعی می‌باشند و مشابه سیستم نرونی بیولوژیکی، به صورت موازی با هم ارتباط دارند. در یک نگاه کلی مدل یک شبکه عصبی شامل ورودی‌هایی است که در نقش سیناپس عمل می‌کنند. این ورودی‌ها در وزن‌هایی ضرب و با بایاسی مشخص جمع می‌شوند تا قدرت سیگنال را تعیین کنند در نهایت یک تابع فعال‌سازی یا



شکل ۱- (a) ساختار یک واحد پردازش شبکه عصبی و پارامترهای مربوط به آن و (b) ساختار شبکه عصبی پرسپترون سه لایه.

Fig. 1. (a) The structure of a neural network processing unit and the related parameters, and (b) The structure of a three-layer perceptron neural network.

الگوریتم ازدحام ذرات

الگوریتم ازدحام ذرات یک روش محاسباتی تکاملی و از نوع هوش جمعی است که در سال ۱۹۹۵ برای اولین بار توسط کندی و ابرهات ارائه گردید. این الگوریتم از رفتارهای اجتماعی یک دسته از پرندگان و گروهی از ماهی ها در یافتن غذا الهام گرفته شده است (Eberhart and Kennedy, 1995). اساس این الگوریتم بر تکرار جستجو در فضای مسئله توسط جمعیت تصادفی می باشد که در هر تکرار، تابع هدف مورد ارزیابی قرار می گیرد و سپس بهترین موقعیت هر ذره و بهترین موقعیت تمام ذرات به ترتیب با عنوان بهترین موقعیت محلی و بهترین موقعیت کلی تعیین می گردد. در واقع حرکت ذرات در این الگوریتم به دو عامل حرکت فردی و حرکت جمعی وابسته است و ترکیب این دو حرکت منجر به ایجاد یک مدل کار آمد جهت یافتن بهترین نقطه هدف در مسائل بهینه سازی می شود. بنا بر آنچه گفته شد، الگوریتم ازدحام ذرات متأثر از دو مؤلفه شناختی و اجتماعی می باشد. این بدین معنی است که موقعیت یک ذره در یک مرحله، مؤلفه ای از موقعیت قبلی، بهترین موقعیت فردی که آن ذره تا کنون تجربه کرده و بهترین موقعیتی که در کل اجتماع ذرات تاکنون تجربه شده می باشد. با حرکت ذره در طول زمان موقعیت ذره تغییر می نماید. $x^i[t]$ موقعیت ذره i ام در زمان t ام را مشخص می نماید. همچنین هر ذره برای حرکت نمودن در فضا نیاز به یک سرعت دارد $v^i[t]$ سرعت ذره i ام در زمان t ام را مشخص می نماید. با افزودن سرعت به موقعیت هر ذره، می توان موقعیت جدیدی برای ذره در نظر گرفت. معادله به روز نمودن موقعیت ذره در زیر آورده شده است (Kennedy et al., 2001). همچنین نحوه عملکرد الگوریتم ازدحام ذرات به صورت شماتیک در شکل ۲ مشخص شده است.

$$v^i[t+1] = wv^i[t] + c_1r_1(x^{i,best}[t] - x^i[t]) + c_2r_2(x^{gbest}[t] - x^i[t])$$

$$x^i[t+1] = x^i[t] + v^i[t+1]$$

جایی که w معرف وزن اینرسی و ضرایب C_1 و C_2 به عنوان عوامل یادگیری یا ضرایب شتاب شناخته می شوند همچنین r_1 و r_2 اعداد تصادفی در بازه ۰ و ۱ با توزیع یکنواخت می باشد. پارامتر وزن اینرسی قابلیت جمعیت ذرات را در اکتشاف مناطق بهینه فراگیر و محلی تنظیم می کند. به نحوی که مقادیر زیاد اینرسی باعث افزایش جستجوی تصادفی (random search) و تولید پاسخ های جدید می شود در حالی که مقادیر کمتر اینرسی باعث افزایش توانایی الگوریتم در پروراندن پاسخ های فعلی (local search) می شود. بنابراین بهتر است که در ابتدا برای ایجاد پاسخ های بیشتر و اکتشاف فراگیر در فضای جستجو، مقادیر زیادتری برای اینرسی وزنی در نظر گرفته شود و بتدریج جهت بهبود در استخراج راه حل بهینه، از مقدار آن کاسته شود. بنابراین می توان برای تعیین اینرسی وزنی از رابطه زیر استفاده نمود:


$$\omega = \omega_{max} \frac{\omega_{max} - \omega_{min}}{Itr_{max}} Itr$$

جایی که Itr_{max} ماکزیمم تعداد تکرارهای الگوریتم، ω_{min} وزن اینرسی اولیه و ω_{max} مقدار نهایی وزن اینرسی می باشد. ω وزن اینرسی در

سرعت همگرایی و بهبود جواب بهینه محلی شود. معمولاً ضرایب C_1 و C_2 را ثابت در نظر می‌گیرند و به عنوان پیش فرض، مقادیر $C_1 = C_2 = 2$ پیشنهاد شده است.

تکرار (itr) تا الگوریتم می‌باشد. در این رابطه معمولاً وزن اینرسی از $0/9$ به $0/4$ کاهش داده می‌شود.

ضرایب C_1 و C_2 در مولفه‌های اجتماعی و شناختی سرعت ذره نقش بسیار زیادی در راندمان ذره دارند و انتخاب مناسب آنها ممکن است باعث افزایش



شکل ۲- نحوه عملکرد الگوریتم ازدحام ذرات برای مشخص کردن موقعیت بهینه.

Fig. 2. Searching mechanism of a PSO for update of position and velocity.

چک کرده و در صورت برقرار بودن به بهترین وزن برای شبکه عصبی مصنوعی دست یافته‌ایم. شرط پایانی معمولاً به دو صورت در نظر گرفته می‌شود: ۱- خطای مینیمم مربعات برای شبکه از یک آستانه کمتر باشد ۲- تعداد تکرارهایی که از قبل مشخص باشد. در نهایت با برقرار شدن شرایط پایانی به شبکه عصبی با وزن‌های بهینه دست یافته‌ایم.

بحث و نتایج

در مطالعه حاضر پس از بررسی نمودارهای چاهپیمایی مختلف، نمودارهای چگالی (RHOB)، نوترون (NPHI) و سرعت موج فشارشی (Vp) به عنوان ورودی‌های مدل برای تخمین سرعت موج برشی استفاده شد. برای این منظور از اطلاعات دو حلقه چاه منصوری به عنوان داده‌های آموزش و از یک حلقه چاه دیگر میدان برای بررسی عملکرد الگوریتم‌های به کار گرفته شده در میدان استفاده شد. همچنین برای تخمین تراوایی و تخلخل موثر، پس از بررسی رابطه لاگ‌های مختلف با تراوایی و تخلخل در تعدادی از چاه‌های میدان منصوری نمودارهای پتروفیزیکی چگالی (RHOB)، نوترون (NPHI)، سرعت موج فشارشی (Vp)، لاگ گاما (CGR) و فتوالکتریک (PEF) انتخاب گردیدند. شایان ذکر است که برای تخمین پارامترهای پتروفیزیکی اخیر به دلیل ناهمگنی موجود در داده‌های ورودی از ۶۰ درصد داده‌ها برای آموزش شبکه و از مابقی داده‌های ورودی برای آزمایش و اعتبارسنجی استفاده گردید. همچنین پس از انتخاب ورودی‌های مناسب برای مدل‌های هوشمند، تمام داده‌ها اعم از ورودی‌ها و خروجی‌ها به بازه‌ی ۱- تا ۱ انتقال یافته و نرمال شدند.

در این مطالعه در ابتدا یک مدل شبکه عصبی پایه برای تخمین هرکدام از پارامترهای سرعت موج برشی، تراوایی و تخلخل ایجاد شد. انتخاب معماری مناسب و الگوریتم آموزشی کارآمد دو مسئله مهم در هنگام کار با شبکه‌های عصبی است. نوع معماری شبکه در آموزش و عملکرد آن نقش بسزایی دارد و به

ترکیب شبکه عصبی و الگوریتم ازدحام ذرات

همانطور که گفته شد پیدا کردن مقادیر بهینه وزن‌های یک شبکه عصبی در قالب یک مسئله بهینه‌سازی تعریف می‌شود. به دلیل معایبی که در استفاده از شبکه‌های معمول پس انتشار خطا وجود دارد در این مطالعه از الگوریتم متاهیوریستیک ازدحام ذرات به عنوان یک روش تکاملی جدید و قوی برای یافتن مقادیر بهینه در فضای جستجو استفاده شد.

در شکل ۳ فلوچارت روش ترکیبی PSO-ANN آورده شده است در این روش ترکیبی بعد از ایجاد ساختار پایه شبکه عصبی، از الگوریتم ازدحام ذرات جهت بهینه‌سازی وزن‌های شبکه استفاده می‌شود. برای این منظور لازم است که آموزش شبکه عصبی را به عنوان یک تابع در نظر بگیریم و هدفمان بهینه کردن آن در یک فضای n بعدی باشد. از این طریق ما کل شبکه عصبی مصنوعی را به عنوان یک ذره در یک فضای n بعدی در نظر گرفته‌ایم که n با تعداد کل وزن‌های شبکه عصبی برابر است. در الگوریتم ازدحام ذرات در ابتدا الگوریتم از تعداد مشخصی از ذرات تشکیل می‌شود که به طور تصادفی، مقدار اولیه می‌گیرند. این ذرات، بصورت تکرارشونده‌ای در فضای n بعدی مسئله حرکت می‌کنند تا با محاسبه مقدار بهینگی به عنوان یک ملاک سنجش، گزینه‌های ممکن جدید را جستجو کنند. بعد فضای مسئله، برابر با تعداد وزن-های شبکه عصبی است. اگر تعداد وزن‌ها برابر با n باشد، هر ذره در یک فضای n بعدی قرار دارد. بدین صورت که هر ذره یک موقعیت مکانی دارد و آن نقطه دارای n بعد است و هر بعد مکان آن ذره تعیین کننده‌ی یکی از وزن‌ها یا بایاس شبکه عصبی موردنظر می‌باشد.

ابعاد (وزن‌ها) هر ذره در هر تکرار زمانی، با توجه به بردار سرعت فعلی، بهترین موقعیت یافت شده توسط آن ذره و بهترین موقعیت یافت شده توسط بهترین ذره موجود در گروه، به روز رسانی می‌گردد. در انتها شرط پایانی را

و ضریب تطابق برای داده‌های تست، نتایج بهتری را نسبت به سایر روش‌ها حاصل کرده است. با توجه به نتایج مدل ترکیبی ازحام ذرات - شبکه عصبی نتایج تخمین سرعت موج برشی، تراوایی و تخلخل به ترتیب با خطاهای ۰/۰۰۸۴، ۰/۰۱۳۵، ۰/۰۰۹۳ و ضریب تطابق‌های ۰/۹۸۰۴، ۰/۹۱۷۹ و ۰/۹۸۴۶ در داده‌های آموزشی و خطای میانگین مربعات ۰/۰۱۹۰، ۰/۰۲۸۱، ۰/۰۱۴۱ و ضریب تطابق ۰/۹۷۸۹، ۰/۷۵۸۱ و ۰/۹۷۳۴ برای داده‌های آزمایش دارای تطابق بالایی با داده‌های واقعی هستند. درحالی‌که نتایج حاصل از مدل-های نروفازی (برای تخمین سرعت موج برشی و تخلخل) و شبکه عصبی (برای تخمین تراوایی) بالاترین خطا و کمترین ضریب تطابق را در تخمین پارامترهای مخزنی دارند. با بررسی مقادیر MSE و ضریب تطابق، نزدیکترین روش به سیستم ترکیبی الگوریتم ازحام ذرات - شبکه عصبی را می‌توان روش ترکیبی الگوریتم ژنتیک- شبکه عصبی دانست.

با توجه به نتایج بدست آمده می‌توان اظهار داشت که روش ترکیبی الگوریتم ازحام ذرات- شبکه عصبی در تعیین ویژگی‌های مخزنی همچون ویژگی‌های ژئومکانیکی و پتروفیزیکی بسیار توانمند است به نحوی که با دارا بودن کمترین تعداد متغیر یا به عبارتی پیچ تنظیم، در کمترین زمان و با بالاترین دقت، کار محاسبات و تخمین پارامترهای مخزنی را انجام می‌دهد.

نتیجه‌گیری


هدف اصلی این پژوهش ارائه و پیاده‌سازی یک روش نوین و کارآمد هوش مصنوعی برای مدل‌سازی و برقراری ارتباط بین داده‌های مخزنی و نگارهای چاه-پیمایی بوده است. از این رو برای تخمین پارامترهای مخزنی سرعت موج برشی، تخلخل و تراوایی از سیستم ترکیبی الگوریتم ازحام ذرات - شبکه عصبی استفاده شد. در این مدل بایاس و وزن‌های شبکه عصبی به عنوان یکی از چالش‌های اصلی استفاده از شبکه عصبی، بوسیله الگوریتم ازحام ذرات بروزرسانی می‌شود. بر اساس معیار کمترین مربعات خطا و ضریب همبستگی، نتایج مدل پیشنهادی در این تحقیق با هر کدام از روشهای پرکاربرد هوش مصنوعی از جمله شبکه عصبی مصنوعی، سیستم استنتاج فازی- عصبی و مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی مقایسه گردید. در نهایت نتایج تجربی حاصل از این تحقیق نشان داد که مدل ترکیبی الگوریتم ازحام ذرات - شبکه عصبی پیشنهادی نسبت به سایر روشهای مرسوم هوش مصنوعی بهتر عمل کرده است و می‌تواند به‌عنوان یک روش قدرتمند برای تخمین پارامترهای مخزنی علی‌الخصوص زمانی که دقت بالای پیش‌بینی امری ضروری است استفاده شود. علاوه بر آن نتایج حاصل از این مطالعه نشان داد که مدل ترکیبی الگوریتم ازحام ذرات - شبکه عصبی می‌تواند به‌عنوان ابزاری مؤثر برای پیش‌بینی سایر ویژگی‌های مخزنی از جمله سرعت موج استونلی، مقدار کل کربن آلی و غیره نیز استفاده شود.

معنی انتخاب بهینه تعداد لایه‌ها، تعداد نرون‌ها در هر لایه و نوع تابع تحریک هر نرون می‌باشد. تعداد نرون‌های لایه‌های ورودی و خروجی به ترتیب برابر با تعداد ورودی و خروجی شبکه عصبی است بنابراین بهینه‌سازی ساختار شبکه به تعیین تعداد نرون‌های لایه میانی (یا پنهان) محدود می‌شود. از این جهت لایه میانی به عنوان جزئی کلیدی از ساختار شبکه عصبی نقش مهمی در قابلیت تخمین نگاشت و تشخیص الگوی داده‌های ورودی، بازی می‌کند.

مطابق با آنچه گذشت تعداد نرون‌های ورودی برای هر کدام از پارامترهای مخزنی سرعت موج برشی، تراوایی و تخلخل به ترتیب برابر با ۳، ۵ و ۵ می‌باشد. به علاوه تعداد نرون‌های خروجی برای هر سه پارامتر برابر با یک است. تعداد نرون‌های لایه میانی بعد از سعی و خطا و بررسی‌های زیاد ۵، ۱۲ و ۶ نرون به ترتیب برای هر کدام از پارامترهای سرعت موج برشی، تراوایی و تخلخل در نظر گرفته شد. لازم به ذکر است که برای تخمین هر سه پارامتر مخزنی برای لایه خروجی و لایه میانی به ترتیب از تابع خطی و تابع تانژانت سیگموئیدی به عنوان تابع تحریک استفاده شده است. بهترین مقدار تخمین زده شده برای هر کدام از پارامترهای هدف با استفاده از شبکه عصبی در جدول ۱ آورده شده است.

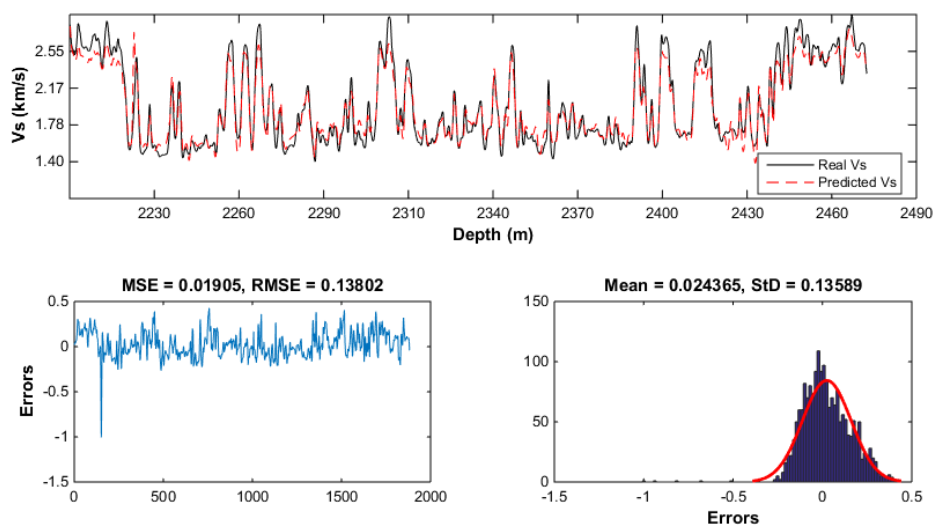
بعد از ایجاد ساختار شبکه عصبی پایه و بهینه، ترکیب الگوریتم ازحام ذرات- شبکه عصبی برای تخمین پارامترهای هدف با همان داده‌های ورودی بکار گرفته شد. در واقع در این مرحله وظیفه آموزش و به روز رسانی وزن‌های شبکه عصبی توسط الگوریتم ازحام ذرات صورت پذیرفت. برای این منظور جمعیت اولیه ذرات (بردارهای وزن) برای هر کدام از پارامترهای سرعت موج برشی، تراوایی و تخلخل به ترتیب برابر با ۱۵، ۴۵ و ۲۵ انتخاب گردید. مقادیر فاکتورهای یادگیری C_1 و C_2 با هم برابر و مساوی ۲ فرض شد. همچنین وزن اینرسی W به صورت خطی از ۰/۹ تا ۰/۴ کاهش می‌یابد. مقدار تخمین زده شده پارامترهای مخزنی سرعت موج برشی، تراوایی و تخلخل بوسیله مدل ترکیبی الگوریتم ازحام ذرات- شبکه عصبی در جدول ۱ گزارش شده است. همچنین، نمایش تطابق نموداری بین مقادیر واقعی و برآورد شده هر کدام از پارامترهای مخزنی در داده آزمایشی در شکل‌های ۴ تا ۷ آورده شده که حاکی از تطابق بالای مقادیر تخمین زده شده و واقعی توسط الگوریتم ترکیبی PSO-ANN است.

به منظور بررسی عملکرد مدل ترکیبی الگوریتم ازحام ذرات- شبکه عصبی و مقایسه آن با روش‌های پیشین هوش مصنوعی، از روش عصبی- فازی (ANFIS) و مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی (GA-ANN) نیز برای تخمین پارامترهای مخزنی هدف استفاده شد. مقایسه عملکرد مدل‌های فوق‌ذکر در تخمین هر کدام از پارامترهای مخزنی سرعت موج برشی، تراوایی و تخلخل به ترتیب در شکل‌های ۷، ۸ و ۹ آورده شده علاوه بر این نتایج همه روش‌های هوشمند استفاده شده و مقایسه آنها برای داده‌های آموزش و تست در جدول ۱ خلاصه شده است. مقایسه‌ها بر اساس دو معیار تعریف شده برای تعیین کارایی روش‌های هوشمند، یعنی مقایسه حاصل از مقادیر مجموع مربعات خطا (MSE) و ضریب همبستگی (R) صورت گرفته است. براساس MSE و ضریب همبستگی محاسبه شده، مشاهده گردید که روشهای هوشمند به طور کلی نتایج خوبی را در تخمین پارامترهای مخزنی ارائه می‌نمایند. سیستم ترکیبی الگوریتم ازحام ذرات - شبکه عصبی، طبق هر دو معیار MSE



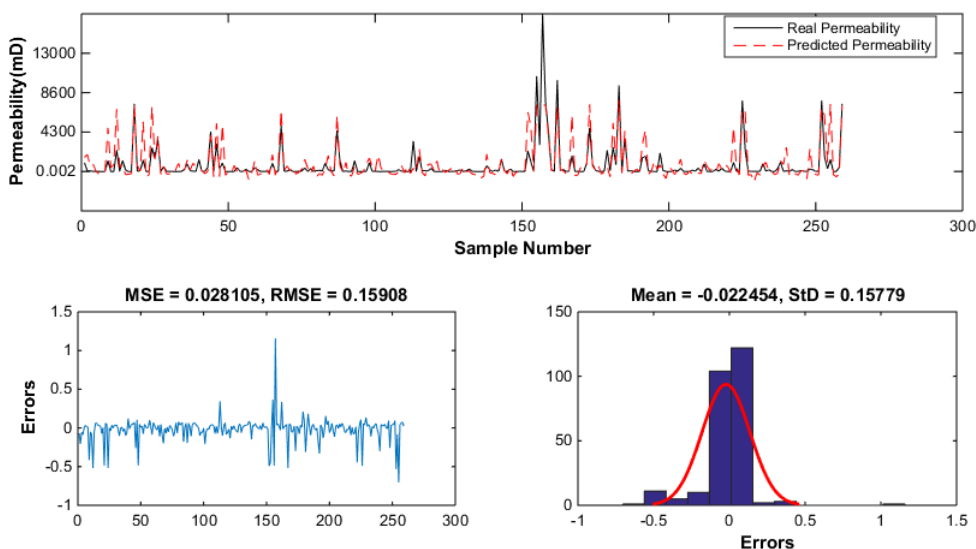
شکل ۳- فلوجارت روش پیشنهادی ترکیب الگوریتم ازدحام ذرات-شبکه عصبی (PSO-ANN).

Fig. 3. Flow chart for PSO-ANN.



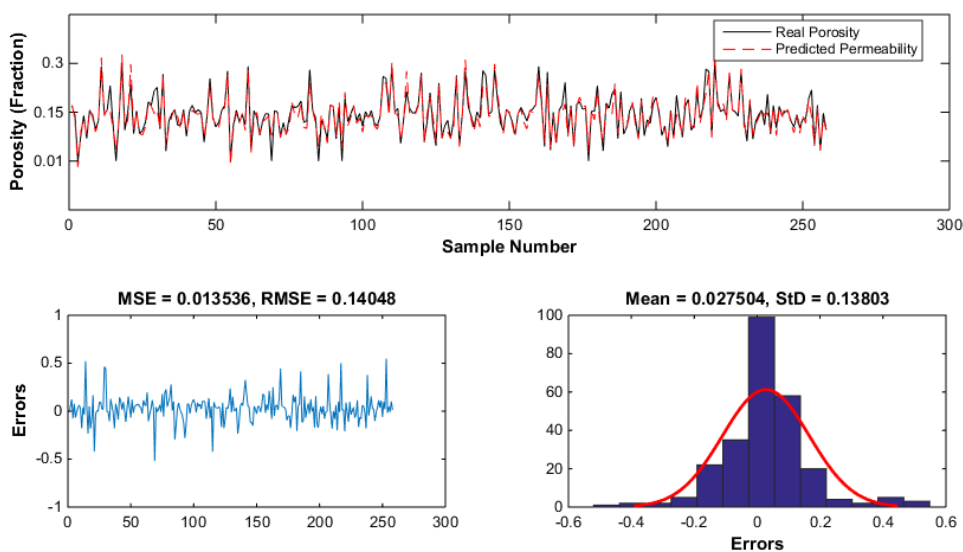
شکل ۴- تطابق سرعت موج برشی پیش‌بینی شده (Predicted) توسط مدل ترکیبی ازدحام ذرات-شبکه عصبی (PSO-ANN) و مقادیر واقعی (Real) سرعت موج برشی در چاه آزمایش.

Fig. 4. Comparison, error prediction and histogram error related to measured and predicted shear wave velocity using PSO-ANN model in test well.



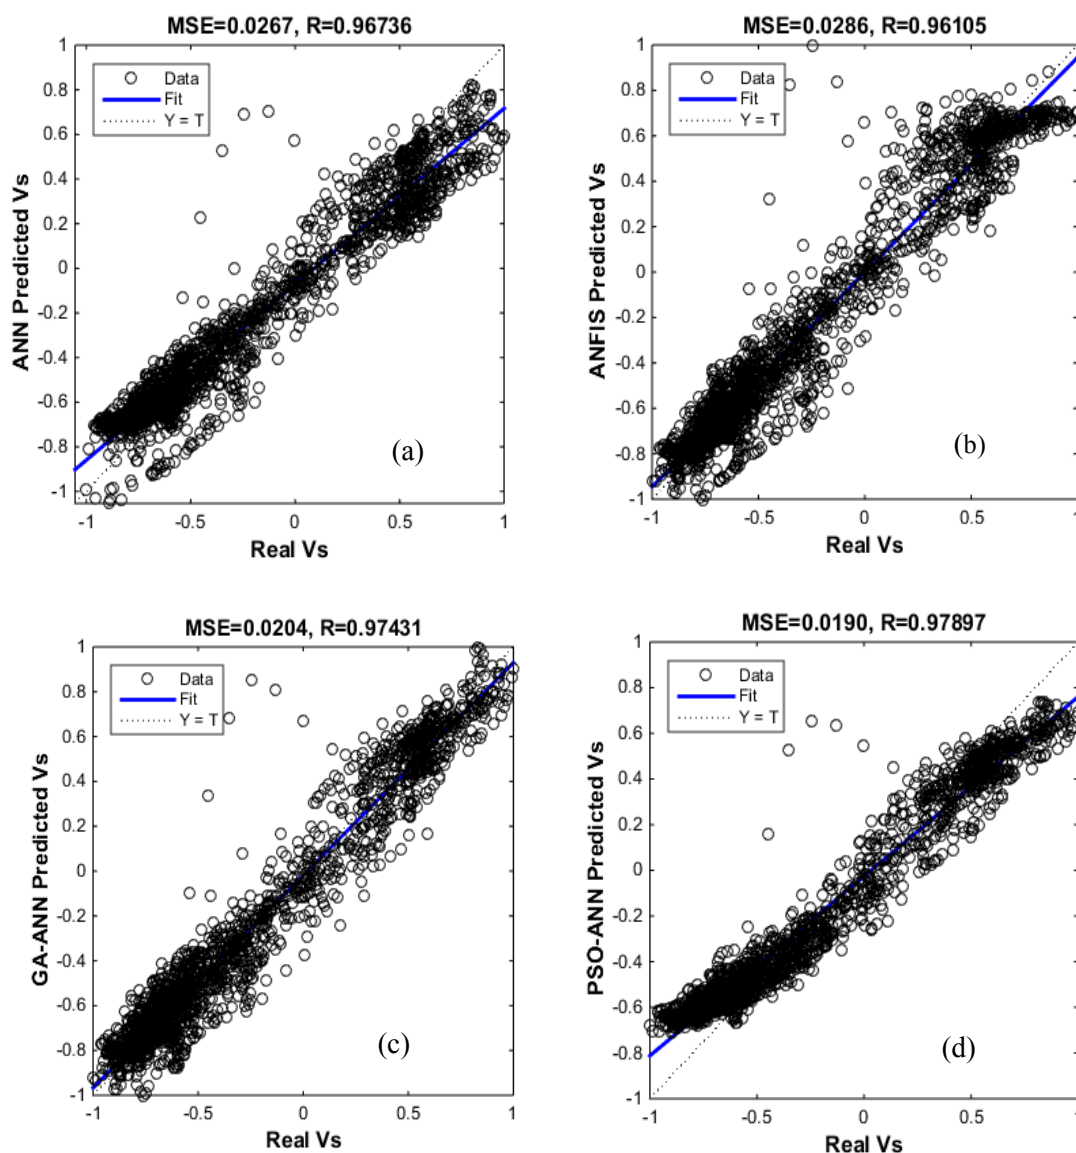
شکل ۵- تطابق تراوایی پیش‌بینی شده (Predicted) توسط مدل ترکیبی ازدحام ذرات-شبکه عصبی (PSO-ANN) و مقادیر واقعی (Real) تراوایی حاصل از مغزه در داده‌های آزمایش.

Fig. 5. Comparison, error prediction and histogram error related to measured and predicted permeability using PSO-ANN model in test well.



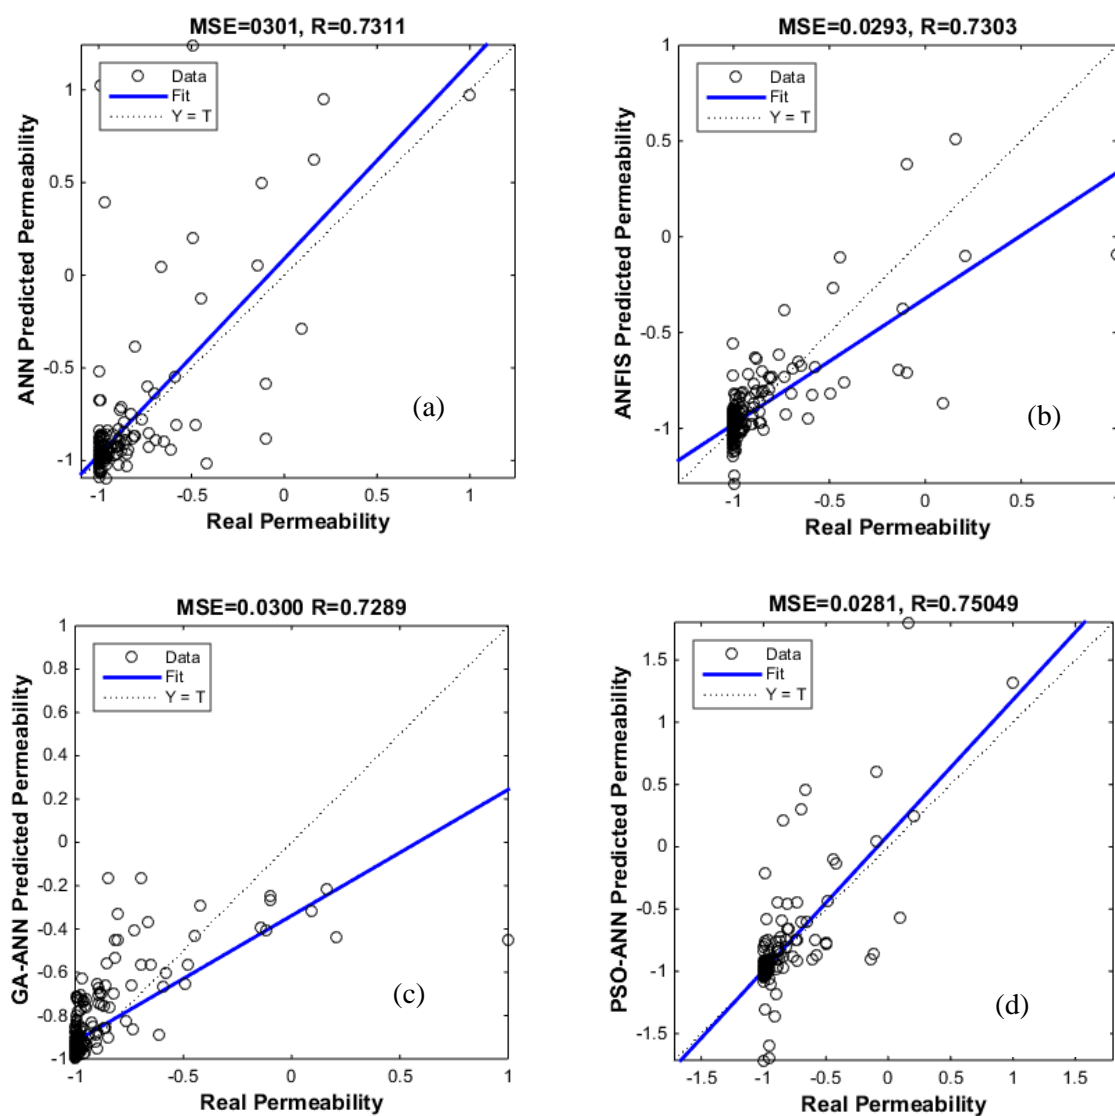
شکل ۶- تطابق تخلخل پیش‌بینی شده (Predicted) توسط مدل ترکیبی ازدحام ذرات-شبکه عصبی (PSO-ANFIS) و مقادیر واقعی (Real) تخلخل حاصل از مغزه در داده‌های آزمایش.

Fig. 6. Comparison, error prediction and histogram error related to measured and predicted porosity using PSO-ANFIS model in test well.



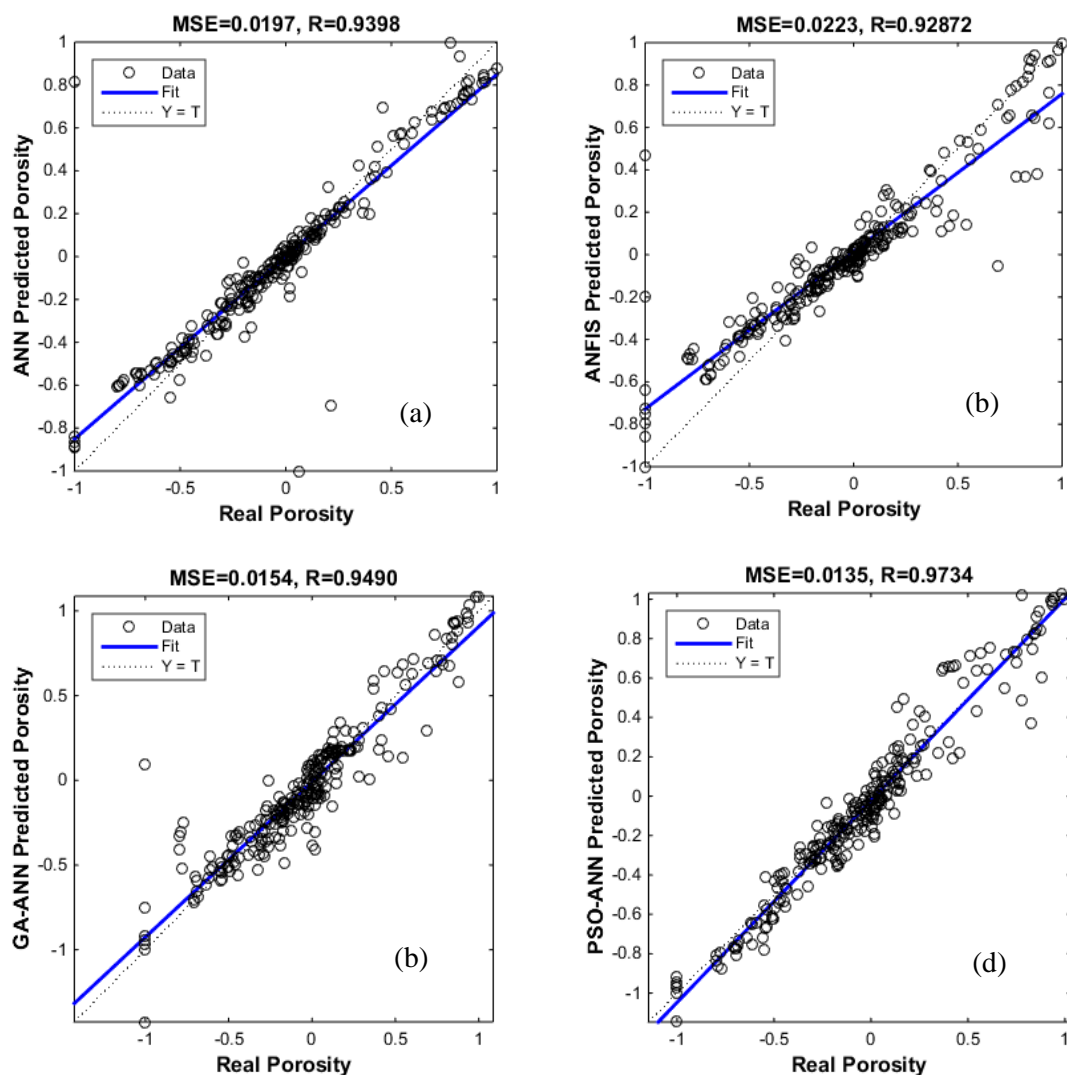
شکل ۷- مقایسه سرعت موج برشی اندازه‌گیری شده (Real) و مقادیر تخمین زده شده (Predicted) توسط روش‌های هوش مصنوعی شامل (a) شبکه عصبی مصنوعی (ANN)، (b) سیستم تطبیقی استنتاجی عصبی - فازی (ANFIS)، (c) مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی (GA-ANN) و (d) مدل ترکیبی الگوریتم ازدحام ذرات- شبکه عصبی (PSO-ANN).

Fig. 7. The comparison of the measured shear wave velocity (real) and the values (predicted) estimated using the artificial intelligence methods including, (a) artificial neural network (ANN), (b) the adaptive neuro-fuzzy inference system (ANFIS), (c) the hybrid genetic algorithm-artificial neural network (GA-ANN) model, and (d) the hybrid particle swarm optimization-artificial neural network (PSO-ANN) model.



شکل ۸- مقایسه تراوایی مغزه اندازه‌گیری شده (Real) و مقادیر تخمین زده شده (Predicted) توسط روش‌های هوش مصنوعی شامل: (a) شبکه عصبی مصنوعی (ANN)، (b) سیستم تطبیقی استنتاجی عصبی - فازی (ANFIS)، (c) مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی (GA-ANN) و (d) مدل ترکیبی الگوریتم ازدحام ذرات- شبکه عصبی (PSO-ANN).

Fig. 8. The comparison of the measured core permeability (real) and the values (predicted) estimated using the artificial intelligence methods including (a) the artificial neural network (ANN), (b) the adaptive neuro-fuzzy inference system (ANFIS), (c) the hybrid genetic algorithm-artificial neural network (GA-ANN) model, and (d) the hybrid particle swarm optimization-artificial neural network (PSO-ANN) model.



شکل ۹- مقایسه تخلخل مغزه اندازه‌گیری شده (Real) و مقادیر تخمین زده شده (Predicted) توسط روش‌های هوش مصنوعی شامل (a) شبکه عصبی مصنوعی (ANN)، (b) سیستم تطبیقی استنتاجی عصبی - فازی (ANFIS)، (c) مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی (GA-ANN) و (d) مدل ترکیبی الگوریتم ازدحام ذرات- شبکه عصبی (PSO-ANN).

Fig. 9. The comparison of the measured core porosity (real) and the values (predicted) estimated using the artificial intelligence methods including (a) the artificial neural network (ANN), (b) the adaptive neuro-fuzzy inference system (ANFIS), (c) the hybrid genetic algorithm-artificial neural network (GA-ANN) model, and (d) the hybrid particle swarm optimization-artificial neural network (PSO-ANN) model.

جدول ۱- مقایسه ی مجموع مربعات خطا (MSE) و ضریب تطابق مربوط به داده‌های آموزشی و آزمایشی برای مدل‌های هوشمند شبکه عصبی، سیستم تطبیقی استنتاج نروفازی، سیستم ترکیبی الگوریتم ژنتیک - شبکه عصبی و مدل ترکیبی ازدحام ذرات - شبکه عصبی.

Table 1. Statistical comparison of artificial neural network (ANN) results with the adaptive neuro-fuzzy inference system (ANFIS), the hybrid genetic algorithm-artificial neural network (GA-ANN), and the hybrid Particle Swarm Optimization-Artificial Neural Network model (PSO-ANN).

Target log	Method	Training result		Testing result	
		R	MSE	R	MSE
Shear wave velocity	ANN	0.9697	0.0116	0.9673	0.0267
	ANFIS	0.9661	0.0130	0.9610	0.0286
	GA-ANN	0.9777	0.0096	0.9743	0.0204
	PSO-ANN	0.9804	0.0084	0.9789	0.0190
Permeability	ANN	0.8951	0.0215	0.7311	0.0301
	ANFIS	0.9108	0.0153	0.7303	0.0293
	GA-ANFIS	0.9012	0.0170	0.7289	0.0300
	PSO-ANN	0.9179	0.0135	0.7581	0.0281
Porosity	ANN	0.9701	0.0133	0.9398	0.0197
	ANFIS	0.9631	0.0242	0.9287	0.0223
	GA-ANFIS	0.9711	0.0124	0.9490	0.0154
	PSO-ANN	0.9846	0.0093	0.9734	0.0141

منابع

- Anselmetti, F.S., Eberli, G.P., 1993. Controls on sonic velocity in carbonates. *Pure and Applied Geophysics* 141(2-4), 287-323.
- Bastos, A.C., Dillon, L.D., Vasquez, G.F., Soares, J.A., 1998. Core-derived acoustic, porosity & permeability correlations for computation pseudo-logs. Geological Society, London, Special Publications, 136(1), 141-146.
- Brocher, T.M., 2005. Empirical relations between elastic wavespeeds and density in the Earth's crust. *Bulletin of the Seismological Society of America* 95(6), 2081-2092.
- Chau, K.W., 2007. Application of a PSO-based neural network in analysis of outcomes of construction claims. *Automation in Construction* 16(5), 642-646.
- Dhanarajan, G., Mandal, M., Sen, R., 2014. A combined artificial neural network modeling-particle swarm optimization strategy for improved production of marine bacterial lipopeptide from food waste. *Biochemical Engineering Journal* 84, 59-65.
- Domenico, S.N., 1984. Rock lithology and porosity determination from shear and compressional wave velocity. *Geophysics* 49(8), 1188-1195.
- Eberhart-Phillips, D., Han, D.H., Zoback, M.D., 1989. Empirical relationships among seismic velocity, effective pressure, porosity, and clay content in sandstone. *Geophysics* 54(1), 82-89.
- Eberhart, R.C., Kennedy, J., 1995. A new optimizer using particle swarm theory. In *Proceedings of the sixth international symposium on micro machine and human science*. New York, NY, pp. 39-43.
- Garat, J., Krief, M., Stellingwerf, J., Ventre, J., 1990. A petrophysical interpretation using the velocities of P and S waves (full-waveform sonic). *The Log Analyst* 31(06).
- Gardner, G.H.F., Gardner, L.W., Gregory, A.R., 1974. Formation velocity and density-the diagnostic basics for stratigraphic traps. *Geophysics* 39(6), 770-780.
- Grimaldi, E.M., Grimaccia, F., Mussetta, M., Zich, R.E., 2004. PSO as an effective learning algorithm for neural network

- applications. In *Computational Electromagnetics and Its Applications, 2004. Proceedings. ICCEA 2004. 2004 3rd International Conference on IEEE*, pp. 557–560.
- Huang, W., Zhou, L., Qian, J., Ma, L., 2005. FIR frequency sampling filters design based on adaptive particle swarm optimization algorithm. In *Advances in Natural Computation*. Springer, pp. 289–298.
- Jamialahmadi, M., Javadpour, F.G., 2000. Relationship of permeability, porosity and depth using an artificial neural network. *Journal of Petroleum Science and Engineering* 26(1), 235–239.
- Kadkhodaie-Ilkhchi, A., Rezaee, M.R., Rahimpour-Bonab, H., Chehrazi, A., 2009. Petrophysical data prediction from seismic attributes using committee fuzzy inference system. *Computers & Geosciences* 35(12), 2314–2330.
- Kadkhodaie- Ilkhchi, A., Amini, A., 2009. A fuzzy logic approach to estimating hydraulic flow units from well log data: A case study from the Ahwaz oilfield, south Iran. *Journal of Petroleum Geology* 32(1), 67–78.
- Karimi, H., Yousefi, F., 2012. Application of artificial neural network–genetic algorithm (ANN–GA) to correlation of density in nanofluids. *Fluid Phase Equilibria* 336, 79–83.
- Kennedy, J., Kennedy, J.F., Eberhart, R.C., Shi, Y., 2001. *Swarm intelligence*, Morgan Kaufmann.
- Labani, M.M., Kadkhodaie-Ilkhchi, A., Salahshoor, K., 2010. Estimation of NMR log parameters from conventional well log data using a committee machine with intelligent systems: A case study from the Iranian part of the South Pars gas field, Persian Gulf Basin. *Journal of Petroleum Science and Engineering* 72(1), 175–185.
- Lim, J.S., 2005. Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea. *Journal of Petroleum Science and Engineering* 49(3), 182–192.
- Lin, X., Sun, J., Palade, V., Fang, W., Wu, X., Xu, W., 2012. Training ANFIS parameters with a quantum-behaved particle swarm optimization algorithm. In *Advances in Swarm Intelligence*, Springer, pp. 148–155.
- Meulenkamp, F., Grima, M.A., 1999. Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness. *International Journal of Rock Mechanics and Mining Sciences* 36(1), 29–39.
- Moradi, M., Tokhmechi, B., Masoudi, P., 2017. Inversion of well logs into rock types, lithofacies and environmental facies, using pattern recognition, a case study of carbonate Sarvak Formation. *Carbonates and Evaporites*, 1–13.
- Murphy, W., Reischer, A., Hsu, K., 1993. Modulus decomposition of compressional and shear velocities in sand bodies. *Geophysics* 58(2), 227–239.
- Nawi, N.M., Ransing, M.R., Ransing, R.S., 2006. An Improved Learning Algorithm based on the Conjugate Gradient Method for Back Propagation Neural Networks. *Proc of World Academy of Science, Eng, and Technology*, 14.
- Nikravesh, M., Aminzadeh, F., 2001. Mining and fusion of petroleum data with fuzzy logic and neural network agents. *Journal of Petroleum Science and Engineering* 29(3), 221–238.
- Nikravesh, M., Zadeh, L.A., Aminzadeh, F., 2003. *Soft computing and intelligent data analysis in oil exploration*, Elsevier.
- Rini, D. P., Shamsuddin, S. M., Yuhani, S.S., 2016. Particle swarm optimization for ANFIS interpretability and accuracy. *Soft Computing* 20(1), 251–262.
- Sfidari, E., Amini, A., Kadkhodaie, A., Ahmadi, B., 2012. Electrofacies clustering and a hybrid intelligent based method for porosity and permeability prediction in the South Pars Gas Field, Persian Gulf. *Geopersia* 2(2), 11–23.
- Tabatabaei, S.M.E., Kadkhodaie-Ilkhchi, A., Hosseini, Z., Moghaddam, A.A., 2015. A hybrid stochastic-gradient optimization to estimating total organic carbon from petrophysical data: A case study from the Ahwaz oilfield, SW Iran. *Journal of Petroleum Science and Engineering* 127, 35–43.
- Tokhmechi, B., Rasouli, V., Azizi, H., Rabiei, M., 2018. Hybrid clustering-estimation for characterization of thin bed heterogeneous reservoirs. *Carbonates and Evaporites*, 1–13.
- Von Altrock, C., 1995. *Fuzzy logic and neurofuzzy applications explained*. Prentice-Hall, Inc.
- Zahmatkesh, I., Soleimani, B., Kadkhodaie, A., Golalzadeh, A., Abdollahi, A.M., 2017. Estimation of DSI log parameters from conventional well log data using a hybrid particle swarm optimization–adaptive neuro-fuzzy inference system. *Journal of Petroleum Science and Engineering* 157, 842–859.