

## تخمین نرخ نفوذ حفاری بر اساس خواص مکانیکی سنگ، سیال حفاری و پارامترهای حفاری با استفاده از شبکه عصبی مصنوعی در میدان نفتی مارون مسعود راه نما اصفهانی؛ مهدی نظری صارم

### چکیده

نرخ نفوذ حفاری یکی از مهمترین پارامترها در بهینه سازی و کاهش هزینه های عملیات حفاری است. به منظور تخمین نرخ نفوذ حفاری با دقت بسیار بالا، در این پژوهش از روش های متداول هوش مصنوعی استفاده شده است. بدین منظور داده های حفاری لایه ی مخزنی یکی از چاه های میدان نفتی مارون شامل پارامترهای عملیات حفاری، خواص سیال حفاری و خواص مکانیکی سنگ که با استفاده از نمودارگیری سیال حفاری و نمودارهای پتروفیزیک استخراج شده، گردآوری شده است. ۸ پارامتر ورودی شامل وزن روی مته، سرعت چرخش مته، فشار پمپ، وزن مخصوص سیال، ویسکوزیته پلاستیک سیال، نقطه تسلیم سیال، حجم شیل، تخلخل، مقاومت فشارشی تک محوره، مدول یانگ و چقرمگی به عنوان موثرترین پارامترها ی ورودی بر تخمین نرخ نفوذ حفاری انتخاب شده اند. با استفاده از این پارامترها، دو مدل شبکه عصبی مصنوعی MLP-BP و MLP-PSO به منظور تخمین نرخ نفوذ حفاری توسعه یافته اند و عملکرد آنها با یکدیگر مقایسه شده است. بررسی ها نشان می دهد که مدل شبکه عصبی مصنوعی آموزش داده شده با استفاده از الگوریتم تجمع ذرات PSO عملکرد بسیار بالاتری نسبت به مدل دیگر در تخمین نرخ نفوذ حفاری دارد که بیانگر قدرت این الگوریتم در بهینه سازی پارامترهای شبکه عصبی مصنوعی است. در ادامه عملکرد این مدل شبکه عصبی مصنوعی با مدل های تجربی متداول در تخمین نرخ نفوذ حفاری مقایسه شده است که نتایج نشان می دهد عملکرد شبکه عصبی مصنوعی در تخمین داده های واقعی حفاری نسبت به مدل های تجربی متداول بسیار بهتر است. مدل های تجربی علاوه بر نیاز به زمان بیشتر برای محاسبه پارامترهای تجربی آنها، دقت بسیار پایین تری نیز در تخمین نرخ نفوذ حفاری دارند.

کلید واژه ها: نرخ نفوذ حفاری، شبکه عصبی مصنوعی، الگوریتم تجمع ذرات

## Prediction of drilling rate of penetration based on rock mechanics properties, drilling fluid and drilling parameters using artificial neural networks in Maroun oilfield

### Abstract

Drilling rate of penetration is one of the most important parameters in optimization and cost reduction of drilling operation. In order to predict the rate of penetration with high precision, artificial intelligence methods are used in this paper. Drilling data of reservoir zone in one of the Maroun oilfield wells consisting of drilling operation parameters, drilling fluids properties, and rock mechanics properties, extracted from mud logging and petrophysics logs, is collected. 8 input parameters such as weight on bit, bit rpm, pump pressure, fluid specific gravity, fluid plastic viscosity, fluid yield point, shale volume, porosity, unconfined compressive strength, Young modulus and toughness are chosen as the most effective parameters on rate of penetration. Using these parameters, two artificial neural network models MLP-PSO and MLP-BP were developed to predict rate of penetration and their performances are evaluated. This study shows that artificial neural network trained by particle swarm optimization have better performance than other models in predicting rate of penetration. The performance of this model is compared with empirical models and the results show the superior performance of artificial neural network models over these models in predicting rate of penetration. Besides requiring more calculation time, these empirical models show lower precision in predicting drilling rate of penetration.

**Keywords:** drilling rate of penetration, Artificial neural networks, Particle swarm optimization

## ۱. مقدمه

برای مدلسازی نرخ نفوذ حفاری و ساییدگی مته در سازند های مختلف و پارامتر های عملیاتی مختلف استفاده کرده است. وی با استفاده از ۵۰۰ داده حاوی ۸ پارامتر ورودی شامل سرعت چرخش مته، وزن روی مته، گشتاور، دبی جریان سیال، زمان چرخش، ساییدگی مته، زبری سازند و قابلیت حفاری سازند به مدلسازی پرداخته است. این مدل با استفاده از ۹۰٪ داده ها آموزش داده شده و با استفاده از ۱۰٪ باقی مانده تست شده است. دقت این مدل در تخمین نرخ نفوذ حفاری در بازه ۰/۹۰۲ تا ۰/۹۸۲ گزارش شده است. [1]

Arabjamaloei و Shadizadeh (۲۰۱۱) نیز از یک مدل شبکه عصبی مصنوعی برای تخمین نرخ نفوذ حفاری استفاده کرده اند. در این مدل از ۳۳۰ داده و ۱۰ پارامتر ورودی استفاده شده است. ورودی های این مدل شامل سرعت چرخش مته، وزن روی مته، نرخ گردش سیال، وزن سیال، ویسکوزیته، عمق، سایز مته، مدت زمان استفاده از مته، بازده مته و فشار دالیز بوده است. دقت این مدل برابر با ۰/۹۴۰۲ برای داده های آموزش شبکه و برای داده های تست ۰/۷۴۰۱ گزارش شده است. [2]

Bataee و همکاران (۲۰۱۱) نیز برای بهبود پارامتر های حفاری از شبکه عصبی مصنوعی برای تخمین نرخ نفوذ حفاری استفاده کرده است. وی از ۱۸۰ داده با ۵ پارامتر ورودی استفاده کرده که شامل سرعت چرخش مته، وزن روی مته، وزن سیال، عمق و قطر مته بوده است. ۶۰٪ این داده ها به عنوان داده های آموزش شبکه، ۲۰٪ برای صحت سنجی و ۲۰٪ برای تست مدل استفاده شده است. [3]

Jahanbakhshi و همکاران نیز از داده های حفاری برای تخمین نرخ نفوذ حفاری استفاده کرده است. در این مطالعه تعداد زیادی داده به عنوان ورودی انتخاب شده است. این ۲۱ داده ورودی شامل سرعت گردش مته، وزن روی مته، فشار پمپ، چگالی معادل گردش سیال، نوع سیال، نقطه تسلیم سیال، ویسکوزیته پلاستیک، PH سیال، درصد جامدات، مقاومت ده دقیقه ای ژل سیال، مقاومت ده ثانیه ای ژل سیال، ساییدگی مته، نوع مته، توان هیدرولیکی مته، چگالی سنگ، تخلخل، تراوایی، قابلیت حفاری شونده سازند، اختلاف فشار چاه و سازند، عمق حفره و سایز حفره است. در ساخت این مدل از ۷۰٪ داده ها برای آموزش شبکه، ۱۵٪ برای راستی آزمایی و ۱۵٪ آن برای تست مدل استفاده شده است. دقت این مدل ۰/۹۱۶ و خطای جذر مجموع مربعات آن (RMSE) برای داده های تست ۰/۰۱۵ گزارش شده است. [4]

همواره حفاری چاه های نفتی به خصوص چاه های فرا ساحلی به عنوان پرهزینه ترین مرحله ی توسعه میادین شناخته می شود. بخشی از این هزینه ها مربوط به تجهیزات و دارایی های مورد نیاز حفاری است و بخش اعظم آن به زمان انجام عملیات حفاری بستگی دارد. در نتیجه نیاز است که عملیات حفاری از لحاظ زمانی بهینه سازی شود. نرخ نفوذ حفاری که به طور مستقیم چگونگی پیشرفت عملیات حفاری را نشان می دهد، بیانگر زمان مورد نیاز برای حفاری طول معینی از یک چاه است. برای بهینه سازی عملیات حفاری، انتخاب بهینه ی پارامتر های موثر در آن قبل از شروع عملیات حفاری از اهمیت ویژه ای برخوردار است. بررسی تاثیر این پارامتر ها که شامل وزن روی مته، سرعت چرخش مته و غیره است، بر نرخ نفوذ حفاری مهمترین بخش در بهینه سازی عملیات حفاری به شمار می آید. چرا که برای فرموله و مدل سازی بهینه سازی حفاری نیاز است که یک مدل تخمینی دقیق توسعه یابد. این مدل ها با هدف دستیابی به پارامتر های موثر مانند مته حفاری، سرعت چرخش و وزن روی مته و اهمیت تاثیر آنها در عملیات حفاری توسعه می یابند که تاثیر همه ی آنها در نرخ نفوذ حفاری دیده می شود. پارامتر های زیادی همچون خواص سازند، خواص سیال حفاری، هیدرولیک و پارامتر های مکانیکی بر نرخ نفوذ حفاری تاثیر گذارند. این پارامتر ها به دو دسته قابل کنترل و محیطی تقسیم می شوند. عوامل محیطی به شرایط حفاری همچون جنس و خصوصیات سازند که تغییر آنها دشوار است، اطلاق می شود. در مقابل عوامل قابل کنترل عواملی هستند که امکان تغییر آنها وجود دارد، از جمله سرعت چرخش مته، وزن روی مته و پارامتر های هیدرولیکی. با این حال ارتباط بین این پارامتر ها و نرخ نفوذ حفاری به طور دقیق مشخص نشده و به دلیل غیر خطی بودن این روابط تخمین نرخ نفوذ حفاری با استفاده از این پارامتر ها بسیار دشوار است. البته تاثیر این پارامتر ها بر سرعت حفاری با استفاده از روابط مختلف غیر خطی، مختلط و استوکستیک می تواند مدل شود.

در دهه های گذشته، محققان بسیاری تلاش هایی بر توسعه مدل های مختلف برای تخمین نرخ نفوذ حفاری انجام داده اند. این مدل ها که عمدتاً بر پایه ی فیزیک حفاری توسعه یافته اند محدودیت های بسیاری از جمله نیاز به داده های کمی ( خصوصیات مته، خصوصیات سیال حفاری، طراحی مته و ...)، استفاده از ضرایب تجربی و وابستگی شدید به لیتولوژی ( به دلیل وابستگی ضرایب تجربی به لیتولوژی) داشته که باعث بلا استفاده شدن آنها در تخمین نرخ نفوذ حفاری می شود. در نتیجه روش های دیگری برای تخمین نرخ نفوذ با حداقل خطا بایستی در نظر گرفته شود. مطالعات بسیاری در زمینه ی حفاری از روش های مختلف هوش مصنوعی استفاده کرده اند.

Bilgesu و همکاران (۱۹۹۷) از شبکه های عصبی مصنوعی

کند. Maurer مدلی تجربی برای مته های کاجی بر اساس سرعت چرخش مته، وزن روی مته، سختی سنگ و سایز مته ارائه کرده است. این مدل بر اساس مشاهده ی حجم خرده های ایجاد شده زیر مته توسعه یافته است. [7]

$$ROP = K \frac{NW^2}{db^2 S^2} \quad (1)$$

که در این رابطه  $k$  ثابت حفاری سنگ،  $N$  سرعت چرخش مته بر حسب RPM،  $W$  وزن روی مته بر حسب Klb،  $db$  قطر مته بر حسب اینچ و  $S$  مقاومت فشاری سنگ بر حسب KPa است.

Bingham نیز با ساده سازی مدل Maurer مدل منحصر به فرد خود را ارائه کرد. در این مدل پارامتر  $a_5$  به عنوان ثابت توانی بر پایه داده های آزمایشگاهی اضافه شده است. [8]

$$ROP = K \left( \frac{W}{db} \right)^{a_5} \quad (2)$$

Young و Bourgoyne یکی از مهمترین مدل های تخمین نرخ نفوذ حفاری را با استفاده از رگرسیون چندگانه پارامترهای حفاری ارائه کرده اند. [9]

$$ROP = f_1 \times f_2 \times f_3 \times f_4 \times f_5 \times f_6 \times f_7 \times f_8 \quad (3)$$

$$f_1 = e^{a_1} \quad (4)$$

$$f_2 = e^{a_2(10000-TVD)}$$

$$f_3 = e^{a_3 TVD^{0.69} (EMW_{pore}-67.41)}$$

$$f_4 = e^{a_4 TVD(EMW_{pore}-ECD)}$$

$$f_5 = \left( \frac{\left( \frac{w}{db} \right) - \left( \frac{w}{db} \right)_t}{4 - \left( \frac{w}{db} \right)_t} \right)^{a_5}$$

$$f_6 = \left( \frac{N}{60} \right)^{a_6}$$

$$f_7 = e^{a_7 h}$$

$$f_8 = \left( \frac{F_j}{1000} \right)^{a_8}$$

در این مدل TVD عمق عمودی واقعی بر حسب فوت،  $EMW_{pore}$  وزن سیال معادل حفره بر حسب pcf،  $db$  قطر مته،  $f_1$  سختی چگالی معدل گردش سیال،  $W$  وزن مته،  $f_2$  سایز مته،  $f_3$  اثر تراکمی،  $f_4$  اثر فراتعادلی،  $f_5$  و  $f_6$  سرعت چرخش مته و اثر وزن مته،  $f_7$  ساییدگی دندان مته و  $f_8$  اثر هیدرولیکی مته است. ثوابت  $a_1$  تا  $a_8$  نیز بر اساس داده های حفاری موجود محاسبه می شوند.

## ۲-۲. شبکه های عصبی مصنوعی

شبکه های عصبی مصنوعی به طور کلی شامل لایه ی ورودی،

Manshad و همکاران از شبکه عصبی مصنوعی چندلایه ای برای تخمین نرخ نفوذ حفاری استفاده کرده است. در این مطالعه از الگوریتم ژنتیک برای انتخاب پارامترهای ورودی استفاده شده است. با استفاده از ۳۳۲ داده و ده پارامتر ورودی شامل سرعت گردش مته، وزن روی مته، نرخ جریان سیال، ویسکوزیته ی پلاستیک، سطح جریان، فشار پمپ، عمق، سایز مته، بازه ی حفاری و مقاومت فشاری تک محوره است. در این مدل ۷۰ درصد داده ها برای آموزش مدل و ۳۰ درصد باقی مانده آن به ۱۵ درصد برای تست و ۱۵ درصد برای راستی آزمایی تقسیم شده است. این مدل دقت ۰/۹۵۷ برای داده های آموزش و ۰/۹۶۲ برای داده های تست داشته است. [5]

Elkatanty و همکاران با استفاده از پارامترهای خواص سیال حفاری و پارامترهای مکانیکی حفاری مدل شبکه عصبی مصنوعی برای تخمین نرخ نفوذ حفاری توسعه داده است. در این مطالعه از ۳۳۳۳ داده شامل هفت پارامتر ورودی شامل سرعت چرخش مته، وزن روی مته، دبی جریان سیال، فشار پمپ، گشتاور، چگالی سیال حفاری و ویسکوزیته ی پلاستیکی استفاده شده است. با استفاده از ۷۰ درصد داده ها این مدل آموزش داده شده است و با ۳۰ درصد باقی مانده آنها مدل تست شده است. دقت این مدل برای داده های آموزشی ۰/۹۹۷ و برای داده های تست ۰/۹۹۳ و همچنین خطای آن برای داده های آموزشی ۳/۹۸ و برای داده های تست ۵/۶ گزارش شده است. [6]

Zhang و همکاران نتایج حاصل از مدل شبکه عصبی مصنوعی و یادگیری ماشین در تخمین نرخ نفوذ حفاری را مقایسه کرده است. در این مطالعه از ۵۰۰۰ داده شامل ۱۱ پارامتر ورودی شامل سرعت چرخش مته، وزن روی مته، فشار پمپ، وزن سیال، ویسکوزیته سیال، زبری سازند، مقاومت فشاری تک محوره، ساییدگی مته، نوع مته و سایز مته استفاده شده است. ۷۵٪ این داده ها برای آموزش مدل و ۲۵٪ آنها برای تست مدل بکار گرفته شده است. دقت این مدل برابر ۰/۹۱ برای داده های آموزشی و ۰/۹ برای داده های تست گزارش شده است ضمن اینکه خطای جذر مجموع مربعات این مدل (RMSE) ۱/۵۱ و ۳/۵۶ به ترتیب برای تخمین داده های آموزشی و تست تعیین شده است.

## ۲. روش تحقیق

### ۲-۱. روابط تجربی تخمین نرخ نفوذ حفاری

طی سالیان گذشته، روابط تجربی مختلفی ارائه شده است که نرخ نفوذ حفاری را با استفاده از پارامترهای مختلف محاسبه می

تعداد بهینه آن شناسایی و مورد استفاده قرار گیرد. در هر نرون ورودی های آن در یک وزن ضرب شده و در آخر با یک مقدار ثابت بایاس جمع می شود. در نهایت مجموع آنها وارد تابعی به عنوان تابع فعال سازی می شود و خروجی این تابع به عنوان خروجی نرون در نظر گرفته می شود و خروجی های هر لایه نیز به عنوان ورودی های لایه ی بعدی مورد استفاده قرار میگیرند. خروجی شبکه عصبی MLP به صورت زیر تعریف می شود.

$$P_{jk} = F_k \left( \sum_{i=1}^{N_{k-1}} W_{ijk} P_{i(k-1)} + B_{ik} \right) \quad (5)$$

که در این رابطه  $P_{jk}$  و  $B_{ik}$  به ترتیب خروجی نرون  $j$  از لایه  $k$  ی و بایاس نرون  $j$  در لایه  $k$  ی هستند.  $W_{ijk}$  ضرایب تصادفی برای مرحله  $k$  ی اول فرآیند یادگیری است.  $F_k$  تابع فعال سازی است که انواع مختلفی از جمله تابع Identity، تابع Binary Step، تابع Sigmoid، تابع Gaussian و تابع خطی دارد. تابع Rectified Linear (ReLU) به عنوان تابع فعالسازی در این مدل استفاده شده است. این تابع از پر کاربرد ترین توابع فعالسازی است که در مسائل تخمینی شبکه های عصبی مصنوعی مورد استفاده قرار میگیرد.

$$ReLU = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (6)$$

این تابع اگر چه ساختار خطی دارد ولی با غیر فعال کردن خروجی نرون های کوچکتر و مساوی صفر باعث ایجاد ساختار غیر خطی در مدل می شود. [10]

#### ۲-۴ آموزش شبکه عصبی مصنوعی

مدل شبکه عصبی مصنوعی با استفاده از داده های آموزش توسط الگوریتم های بهینه سازی مقادیر نهایی وزن و بایاس ها را شناسایی کرده و از آنها برای تخمین پارامتر هدف استفاده می کند.

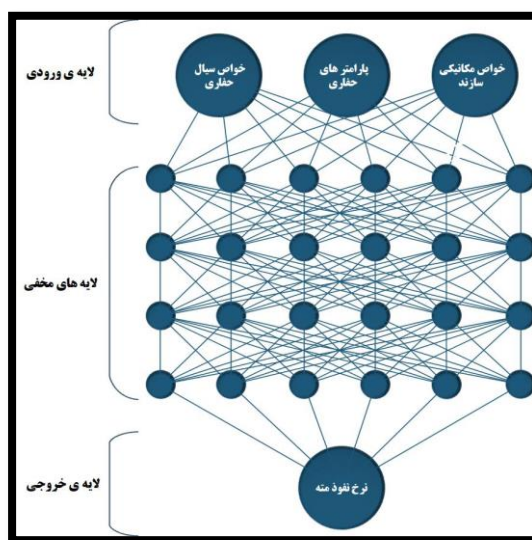
##### ۲-۴-۱ الگوریتم Back Propagation

برای بهینه سازی الگوریتم بازگشت به عقب Back-propagation یکی از متداولترین روش های مورد استفاده در شبکه های MLP است. در این روش یک تابع هزینه تعریف شده و مقدار آن برای تمام وزن های شبکه عصبی محاسبه می شود و سپس از روش های گرادیان کاهشی برای پیدا کردن مجموعه وزن های بهینه استفاده می شود. روش گرادیان های کاهشی با حرکت در خلاف جهت گرادیان و تکرار آن تابع هزینه را به حداقل می رساند.

##### ۲-۴-۲ الگوریتم Particle Swarm Optimization

یکی دیگر از روش های بهینه سازی شبکه عصبی مصنوعی،

تعدادی لایه مخفی و یک لایه ی خروجی هستند. لایه ی ورودی داده های ورودی مسئله را دریافت می کند، لایه میانی یا مخفی ارتباط بین پارامتر ها را توسعه می دهد و لایه ی خروجی نتایج را تشکیل می دهد. برای انتخاب تعداد مناسب لایه ها و نرون های تشکیل دهنده ی هر لایه، بایستی بهینه ترین مقدار انتخاب شود چرا که استفاده از تعداد نرون بیش از اندازه موجب بیش برآزش مدل و تعداد کم آن موجب کم برآزش آن می شود. افزایش سایز مدل از طریق افزایش تعداد لایه های مخفی و نرون های تشکیل دهنده ی آن نیز باعث افزایش زمان و حجم محاسبات شده که این امر خطا را هنگام آموزش مدل کاهش می دهد ولی در مقابل خطای مدل برای تخمین داده های تست افزایش می یابد. آموزش بیش از اندازه مدل نیز خود باعث بیش برآزش آن می شود. شماتیکی از یک مدل شبکه عصبی مصنوعی در شکل ۱ مشاهده می شود که سه دسته پارامتر ورودی تحت عنوان خواص مکانیکی سازند، پارامتر های حفاری و خواص سیال حفاری به عنوان ورودی این مدل و نرخ نفوذ حفاری به عنوان خروجی این مدل انتخاب شده است.



شکل (۱). شماتیک مدل شبکه عصبی مصنوعی

#### ۲-۳ شبکه عصبی چندلایه (MLP)

شبکه عصبی چندلایه یکی از متداولترین و کاربردی ترین انواع شبکه های عصبی در حوزه هوش مصنوعی است. این نوع شبکه در تخمین مقادیر با همبستگی های غیر خطی عملکرد قابل قبولی دارد. ساختار MLP از سه بخش تشکیل شده است. لایه ی ورودی، لایه ی مخفی و لایه ی خروجی. از طریق لایه ی مخفی یا میانی ارتباطی بین لایه ی ورودی و لایه ی خروجی ایجاد می شود. تعداد نرون های ورودی در لایه ی ورودی و خروجی با تعداد پارامتر های ورودی و خروجی برابر است ولی تعداد نرون های لایه ی میانی میتواند متفاوت باشد و بایستی

در جدول ۱ اطلاعات آماری داده های ورودی به همراه نرخ نفوذ حفاری آمده است. کمینه، بیشینه، میانگین و انحراف معیار در این جدول مشاهده می شود.

جدول (۱). خلاصه ای از اطلاعات آماری داده های ورودی مدل

پارامتر	واحد	کمینه	بیشینه	میانگین	انحراف معیار
وزن روی مته	klbs	۱۶/۱۷۴	۳۱/۵	۲۵/۵۳	۲/۱۹
سرعت گردش مته	rpm	۷۷/۱۲۴	۱۹۸/۷	۱۳۲/۷۳	۴۰/۹۷
فشار پمپ	Psi	۳۶۰/۵۵	۵۲۶/۲۹	۴۷۷/۸۴	۳۳/۰۸
وزن مخصوص سیال	PCF	۵۹	۶۰	۵۹/۶۱	۰/۴۸۷
پلاستیک ویسکوزیته سیال	Cp	۵	۱۹	۱۵/۰۳	۴/۸۷
نقطه تسلیم سیال	Lb/100ft <sup>2</sup>	۳	۹	۷/۰۹	۲/۱۷
حجم شیل	-	۰/۰۱	۱	۰/۲۹۳	۰/۱۶۶
تخلخل	-	۰/۰۰۰۷	۰/۳۰۱	۰/۰۹۷۵	۰/۰۶
مقاومت فشارشی تک محوری	GPa	۲/۵۹۵	۲۷/۰۲	۱۲/۷۱۹۱	۲/۸۱
مدول یانگ	GPa	۱۱/۶۳	۱۲۱/۱	۵۷	۱۲/۶۲
شاخص چقرمگی	GPa	۱۹۴/۷۲	۲۱۲/۳۶	۲۰۶/۳۰۲	۱/۹۷
نرخ نفوذ مته	m/hour	۲/۲۴	۷/۶۷	۵/۰۲	۱/۱۲۲

عدم قطعیت بالا در داده های واقعی میداین به ویژه در داده های حفاری بسیار رایج است. به همین خاطر داده ها با خطای بالا از داده های مورد استفاده در این مدل خارج شده اند. خطای اندازه گیری نیز یکی از اصلی ترین دلایل وجود خطا در داده ها است. در بیشتر مسائل یادگیری عمیق ماشین وجود خطا در داده ها بر سرعت و نتایج یادگیری مدل تاثیر منفی بسزایی دارد. در مطالعات قبلی آمده است که وجود خطا در داده ها تعادل بین پارامتر

الگوریتم بهینه سازی ازدحام ذرات PSO است. PSO یک روش غیرقطعی برای بهینه سازی تابع مطرح شده که از حرکت دسته جمعی پرندگان که به دنبال غذا هستند، الهام گرفته شده است. تنها یک تکه غذا در فضای مورد جستجو وجود دارد. هر ذره یک مقدار شایستگی دارد که توسط یک تابع شایستگی محاسبه می شود. هر چه ذره در فضای جستجو به هدف (غذا) در مدل حرکت پرندگان) نزدیکتر باشد، شایستگی بیشتری دارد. همچنین هر ذره دارای یک سرعت است که هدایت حرکت ذره را بر عهده دارد. هر ذره با دنبال کردن ذرات بهینه در حالت فعلی، به حرکت خود در فضای مسئله ادامه می دهد.

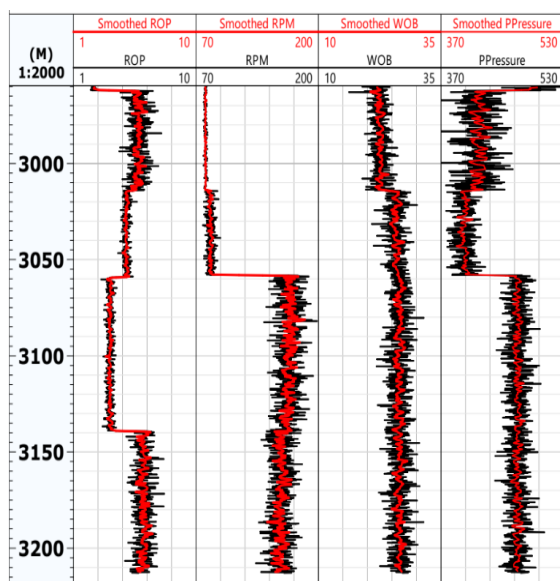
$$v_{id}^{t+1} = w.v_{id}^t + C_1.rand(0,1).(p_{id}^t - x_{id}^t) + C_2.rand(0,1).(p_{gd}^t - x_{id}^t) \quad (7)$$

در روابط بالا  $v_{id}^t$  و  $x_{id}^t$  سرعت ذرات و مکان ذرات،  $i$  شناسه ذرات،  $d$  بعد در فضای جستجو و  $t$  مرتبه تکرار است.  $P_i$  بیانگر بهترین مکان ذره  $i$  و  $P_g$  بیانگر بهترین مکان همسایه های ذره  $i$  است.  $C_1$  و  $C_2$  سرعت حرکت به سمت بهینه ترین ذره تجمع و  $W$  وزن است. وزن های بالاتر بیانگر بزرگتر بودن سایز هر قدم در افزایش رفتار اکتشافی است. به منظور بالا بودن رفتار اکتشافی در ابتدای بهینه سازی  $damping\ ratio$  تعریف شده و در مقادیر وزن در هر دوره ضرب می شود. [11]

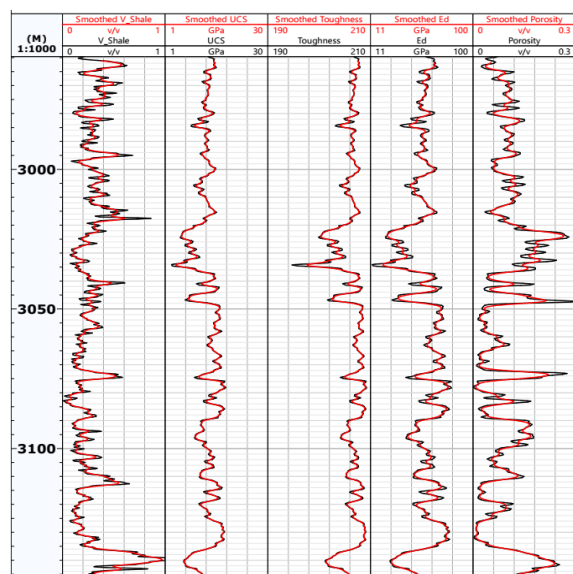
## ۵-۲. تشریح داده ها

در این مطالعه مدل شبکه عصبی مصنوعی با استفاده از داده های مربوط به یکی از چاه های میدان نفتی مارون واقع در جنوب غربی ایران آموزش داده و تست شده است. داده های این چاه از ۱۷۱۵ داده حفاری مربوط به ناحیه ی مخزنی این چاه از عمق ۲۹۶۰ متر تا ۳۲۱۲ متر که در مخزن آسماری واقع شده، تشکیل شده است. داده های موجود از دو منبع شامل داده های نمودارگیری (پتروفیزیک) و نمودارگیری گل استخراج شده اند. از طرفی به دلیل تفاوت سرعت اندازه گیری دو منبع استفاده شده برای استخراج داده ها، با بکارگیری روش ارتقا مقیاس این مشکل حل شده است. داده های مکانیکی حفاری این چاه شامل: وزن روی مته WOB، سرعت چرخش مته RPM و فشار پمپ ها است. خواص سیال حفاری شامل وزن سیال، ویسکوزیته ی پلاستیک و نقطه ی تسلیم است. حجم شیل، تخلخل، مقاومت فشارشی تک محوره، مدول یانگ و چقرمگی سنگ نیز به عنوان خواص سازند انتخاب شده اند.

## ۶-۲. مطالعه آماری داده ها



شکل (۲). داده های حفاری قبل و بعد از کاهش نوسانات



شکل (۳). داده های پتروفیزیک قبل و بعد از کاهش نوسانات

## ۲-۷. انتخاب پارامتر های ورودی ها

انتخاب پارامترهای ورودی فرآیندی است که طی آن پارامتر های موثرتر بر نرخ نفوذ حفاری از میان پارامتر های موجود به عنوان ورودی مدل انتخاب می شوند. از مهمترین فواید آن، کاهش زمان آموزش مدل، تحلیل آسانتر مدل و کاهش بیش برآزش مدل می باشد. از ضریب همبستگی بین پارامتر های ورودی و نرخ نفوذ حفاری می توان به عنوان شاخصی برای بررسی میزان تاثیر پارامتر های مختلف بر نرخ نفوذ حفاری استفاده کرد که این ضریب برای هر پارامتر در جدول ۲ آمده است.

های ورودی را از بین برده و در نتیجه باعث کاهش عملکرد توابع تخمین مورد استفاده در مدل می شود. عوامل محیطی نیز مخصوصا در داده های پتروفیزیک می تواند باعث خطا در داده ها شود. تشخیص علل ایجاد خطا در داده ها در مواجهه با آنها می تواند بسیار تاثیر گذار باشد. تعویض تجهیزات حفاری، لرزش رشته حفاری، شستشوی ستون چاه و جابجایی در انتقال اعماق در لاگ های مختلف می توانند از عوامل ایجاد خطا در داده های حفاری شناخته می شوند. برای کاهش خطای داده ها از روش های مختلفی برای کاهش خطا استفاده می شود. در این پژوهش از روش Savitzky-Golay (SG) به عنوان یکی از رایج ترین روش های کاهش خطای داده های پتروفیزیک، استفاده شده است. در این روش تاثیر نوسانات بر روی داده ها با استفاده از یک تابع چند جمله ای با استفاده از جایگزینی داده های اولیه با داده های با نوسان کمتر نوسان داده ها کاهش پیدا می کند. این تابع چند جمله ای مرتبه ای  $n$  بر تعدادی از نقاط که کمترین خطای جذر میانگین مربعات را در یک بازه داشته است، تطبیق داده می شود. تعداد نقاط در این بازه بایستی فرد و یا کمتر از مرتبه ی تابع چندجمله ای باشد. افزایش مرتبه ی تابع چندجمله ای و یا کاهش تعداد نقاط بازه جزییات داده را بیشتر نمایان کرده و نوسانات موجود در داده را کمتر کاهش می دهد. در مقابل افزایش تعداد نقاط و کاهش مرتبه ی تابع چند جمله ای نوسان داده ها را کاهش می دهد ولی باعث از دست رفتن تعدادی از داده ها می شود. در نتیجه تعیین مرتبه و تعداد نقاط بهینه ی تابع چند جمله ای از اهمیت ویژه ای برخوردار است. برای بدست آوردن مقدار بهینه ی مرتبه ی تابع و تعداد نقاط، داده های حفاری و پتروفیزیک در بازه ی حفاری مورد نظر بررسی شده اند. بر اساس نتایج بدست آمده مرتبه ی بهینه تابع چند جمله ای برای داده های حفاری ۵ و برای داده های پتروفیزیک ۳ بدست آمده است. همچنین تعداد نقاط بهینه برای داده های حفاری و پتروفیزیک به ترتیب ۱۳ و ۸ تعیین شده است. داده های حفاری و پتروفیزیک در شکل ۲ و ۳ قبل و پس از کاهش نوسانات آمده است.

جدول بالا نشان می‌دهد که در انتخاب پارامتر های ورودی مقدار بهینه ای وجود دارد که پس از آن با کاهش پارامتر های ورودی خطای مدل افزایش می یابد. با توجه به جدول بالا استفاده از ۸ پارامتر ورودی شامل وزن روی مته، سرعت گردش مته، فشار پمپ، وزن مخصوص سیال، ویسکوزیته پلاستیک سیال، نقطه تسلیم سیال، حجم شیل، تخلخل، مقاومت فشاری تک محوره، مدول یانگ و چقرمگی کمترین خطا (۰/۱۸۹۶) را در میان موارد دیگر در تخمین نرخ نفوذ حفاری داشته است. بنابراین این ۸ پارامتر به عنوان پارامتر های ورودی برای توسعه مدل استفاده شده اند. اختلاف زیاد مرتبه اعداد مورد استفاده در پارامتر های ورودی می تواند بر فرآیند آموزش شبکه عصبی تاثیر منفی داشته باشد، بنابراین به منظور بهبود عملکرد مدل داده های ورودی پیش از شروع فرآیند آموزش مدل، با استفاده از رابطه ی زیر نرمال سازی شده اند.

$$x_i^n = 2 \times \frac{x_i - x_{min}}{x_{max} - x_{min}} - 1 \quad (7)$$

در رابطه بالا  $i$  بیانگر تعداد پارامترها و  $x_{min}$  و  $x_{max}$  به ترتیب مقدار بیشینه و کمینه ی پارامتر  $x_i$  است.

از میان الگوریتم های آموزشی *back propagation*، الگوریتم *Levenberg-Marquardt* به عنوان الگوریتم آموزش شبکه عصبی مصنوعی *MLP* انتخاب شده است. در مطالعات پیشین نشان داده شده که استفاده از الگوریتم *LM* در تخمین مسایل مهندسی نسبت به الگوریتم های دیگر کارایی بهتری داشته است (Yetilmezsoy ۲۰۱۱).

تعداد لایه های میانی یکی از مهمترین عوامل اثرگذار بر سرعت و دقت مدل شبکه عصبی مصنوعی است. بر اساس مطالعات پیشین تاکید شده است که در مسائل پیچیده استفاده از بیش از دو لایه در دقت مدل تاثیر بسزایی دارد (Ramchoun ۲۰۱۶). برای تعیین تعداد بهینه ی آن چندین مدل شبکه مصنوعی که هر لایه ی آن شامل ۲۰ نرون است اجرا شده است. با افزایش تعداد لایه ها همانطور که در شکل ۴ مشاهده می شود، در ابتدا دقت مدل در تخمین نرخ نفوذ حفاری افزایش داشته ولی استفاده ی بیش از دو لایه ی میانی باعث کاهش دقت مدل شده است. بنابراین در مدل ساخته شده از دو لایه میانی به عنوان بهینه ترین تعداد لایه استفاده شده است.

علامت اختصاری	پارامتر ورودی	ضریب همبستگی
D <sub>1</sub>	وزن روی مته WOB	-۰/۱۶۷
D <sub>2</sub>	سرعت چرخش مته	۰/۳۲۶
D <sub>3</sub>	فشار پمپ	-۰/۱۹
M <sub>1</sub>	وزن مخصوص سیال	-۰/۱۸۴۴
M <sub>2</sub>	پلاستیک ویسکوزیته سیال	۰/۱۹۰۲۲
M <sub>3</sub>	نقطه تسلیم سیال	۰/۲۶۷
P <sub>1</sub>	حجم شیل	۰/۳۴۳۷
P <sub>2</sub>	تخلخل	۰/۶۳۴
P <sub>3</sub>	مقاومت فشاری تک محوری	۰/۲۵۳۷
P <sub>4</sub>	مدول یانگ	۰/۳۶۴۵
P <sub>5</sub>	شاخص چقرمگی	-۰/۲۰۷۳

برای انتخاب بهینه ی ورودی ها چندین مدل چندلایه برای تخمین نرخ نفوذ حفاری اجرا شده و در هر اجرا، تاثیر مجزای هر پارامتر در تخمین نرخ نفوذ مته با ثابت نگه داشتن بقیه ی پارامتر ها بررسی شده است. مدل استفاده شده، متشکل از دو لایه ی میانی شامل ۲۰ نرون در هر لایه است. در هر اجرا یکی از پارامتر ها در ورودی حذف شده و مدل ۱۰ مرتبه با استفاده از ۷۰ درصد داده ها آموزش داده شده و با ۳۰ درصد داده ها تست شده است و خطای جذر میانگین مربعات آن محاسبه شده است. آن پارامتر ورودی که حذف آن باعث کاهش خطای مدل در تخمین نرخ نفوذ شده در مرحله بعدی از ورودی ها حذف شده و مراحل بالا بار دیگر تکرار شده است. این فرآیند تا جای ادامه داده شده است که پس از حذف پارامتر ورودی خطای مدل افزایش یافته است. خلاصه ای از نتایج فرآیند انتخاب پارامتر های ورودی در جدول ۳ آمده است.

جدول (۳). نتایج فرآیند انتخاب پارامتر های ورودی

پارامتر های ورودی	MSE
D <sub>1</sub> , D <sub>2</sub> , D <sub>3</sub> , M <sub>1</sub> , M <sub>2</sub> , M <sub>3</sub> , P <sub>1</sub> , P <sub>2</sub> , P <sub>3</sub> , P <sub>4</sub> , P <sub>5</sub>	۰/۲۲۳۹
D <sub>1</sub> , D <sub>2</sub> , D <sub>3</sub> , M <sub>1</sub> , M <sub>2</sub> , P <sub>1</sub> , P <sub>2</sub> , P <sub>3</sub> , P <sub>4</sub> , P <sub>5</sub>	۰/۲۱۳۰
D <sub>1</sub> , D <sub>2</sub> , M <sub>1</sub> , M <sub>2</sub> , P <sub>1</sub> , P <sub>2</sub> , P <sub>3</sub> , P <sub>4</sub> , P <sub>5</sub>	۰/۱۹۵۱
D <sub>1</sub> , D <sub>2</sub> , M <sub>1</sub> , M <sub>2</sub> , P <sub>1</sub> , P <sub>2</sub> , P <sub>3</sub> , P <sub>5</sub>	۰/۱۸۹۴
D <sub>1</sub> , D <sub>2</sub> , M <sub>1</sub> , P <sub>1</sub> , P <sub>2</sub> , P <sub>3</sub> , P <sub>5</sub>	۰/۱۹۸۸
D <sub>1</sub> , D <sub>2</sub> , M <sub>1</sub> , P <sub>2</sub> , P <sub>3</sub> , P <sub>5</sub>	۰/۲۰۰۱
D <sub>1</sub> , D <sub>2</sub> , M <sub>1</sub> , P <sub>3</sub> , P <sub>5</sub>	۰/۴۵۱۰

پاسخ های مسئله ی بهینه سازی است و تعداد ستون های آن برابر با مجموع وزن و بایاس ها است. پس از ساخت این ماتریس برای مدل، اعضای آن بر اساس تابع هزینه تعریف شده رتبه بندی می شوند. در مرحله بعدی، ماتریس جدیدی شامل عملی ترین پاسخ های مسئله (وزن ها و بایاس ها) با استفاده از عملگر های مشخص، ساخته میشود.

تعداد لایه ها و نرون های و توابع مربوطه برای هر دو الگوریتم یکسان در نظر گرفته شده است. مقادیر بهینه پارامتر های مورد استفاده در مدل PSO در جدول ۵ آمده است.

جدول (۶). پارامتر های بهینه مورد استفاده در الگوریتم PSO

۰/۵	ثابت شناختی
۲/۵	ثابت اجتماع
۵	وزن اینرسی
۰/۶	نسبت میرایی وزن اینرسی

بیشینه تعداد تکرار برای آموزش هر دو مدل MLP-BP و MLP-PSO، ۵۰۰ تکرار در نظر گرفته شده است.


### ۳. نتایج و بحث

در این بخش عملکرد مدل های توسعه داده شده در تخمین نرخ نفوذ حفاری مورد بررسی قرار گرفته و با مدل های متداول تجربی موجود مقایسه شده است. پارامترهای آماری فراوانی برای بررسی کمی عملکرد مدل توسعه داده شده، وجود دارد که از میان آن خطای جذر میانگین مربعات (RMSE) و ضریب رگرسیون (R2) در این مطالعه استفاده شده است.

$$RMSE = \left( \frac{1}{P} \sum_{r=1}^P (y_r - z_r)^2 \right)^{\frac{1}{2}} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{r=1}^P (y_r - z_r)^2}{\sum_{r=1}^P (y_r - y_{r,mean})^2} \quad (9)$$

در این روابط، z خروجی مدل، y مقدار واقعی پارامتر خروجی و P تعداد نقاط داده های موجود است. کاهش مقدار RMSE و افزایش R2 بیانگر افزایش دقت مدل در تخمین نرخ نفوذ حفاری است. در جدول ۶ مقادیر R2 و RMSE برای مدل های توسعه یافته آمده است. بر اساس نتایج این جدول، مدل MLP-PSO، R2 بالاتر و RMSE کمتر نسبت به مدل MLP-BP داشته که بیانگر عملکرد بهتر آن در تخمین نرخ نفوذ حفاری است. یکی از معایب مدل MLP-BP در بهینه سازی همگرایی این مدل به کمینه های محلی در کمینه سازی تابع هزینه است که پایین بودن مقادیر R2 و بالا بودن RMSE بیانگر این مهم در حین آموزش مدل است.



شکل (۴). دقت مدل بر حسب تعداد لایه های میانی

تعداد نرون های هر لایه نیز از اهمیت زیادی برخوردار است. تعداد بهینه نرون های هر لایه بسته به مسائل مختلف می تواند متفاوت باشد. استفاده از تعداد نرون های بیش از اندازه می تواند موجب بیش برآزش مدل شود. به همین خاطر با بررسی حالت های مختلف نیاز است که تعداد بهینه نرون در هر لایه مشخص شود. بدین منظور مدل برای حالت های مختلف اجرا شده است. در حالتی که لایه ی اول ۲۰ نرون و لایه ی دوم ۱۵ نرون داشته، مدل کمترین خطا و بیشترین دقت را از خود نشان داده است.

با توجه به نتایج حاصل شده، استفاده از دو لایه میانی که هر کدام به ترتیب شامل ۲۰ و ۱۵ نرون است، به عنوان بهینه ترین حالت که کمترین مقدار خطا نسبت به حالت های دیگر داشته است، برای ساخت مدل استفاده شده است. خلاصه مدل توسعه داده شده در جدول ۵ آمده است.

جدول (۴). خلاصه مشخصات مدل توسعه یافته

Multi_layer perceptron	نوع شبکه
Levenberg-Marquardt	الگوریتم یادگیری
۴	تعداد لایه
۲۰	تعداد نرون های لایه اول میانی
ReLU	تابع فعالسازی لایه اول میانی
۱۵	تعداد نرون های لایه دوم میانی
ReLU	تابع فعالسازی لایه دوم میانی
۱	تعداد نرون لایه خروجی
Linear	تابع فعالسازی لایه خروجی

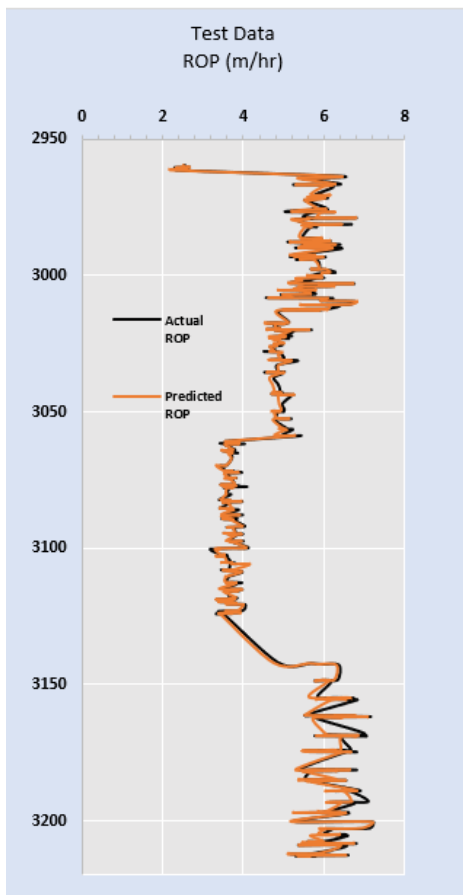
همانطور که قبلا اشاره شد، هر MLP شامل چندین وزن و بایاس است که بایستی طی فرآیند یادگیری مدل بهینه سازی شوند. در الگوریتم PSO یک ماتریس شامل وزن ها و بایاس به طور تصادفی انتخاب می شود. این ماتریس با عنوان ماتریس ازدحام swarm شناخته می شود. هر ردیف این ماتریس شامل



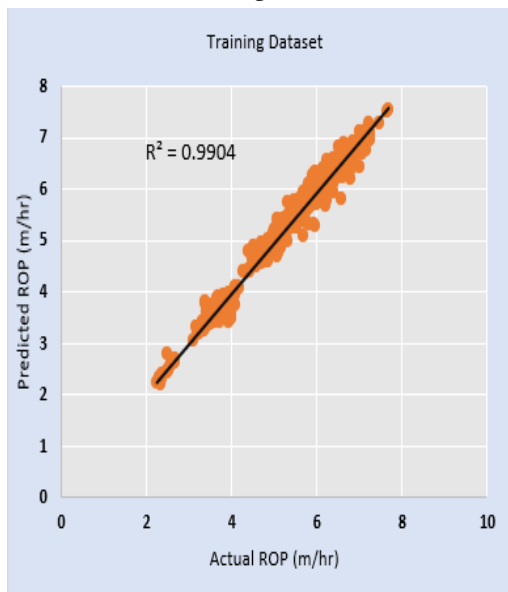
جدول (۷). مقایسه عملکرد دو مدل در تخمین نرخ نفوذ حفاری

مدل	داده	RMSE	R2
MLP-BP	آموزش	۰/۰۰۹۳	۰/۹۴۰۲
	تست	۰/۰۱۰۳	۰/۹۳۲۵
MLP-PSO	آموزش	۰/۰۰۴۱	۰/۹۹۴۴
	تست	۰/۰۰۶۳	۰/۹۸۴۸

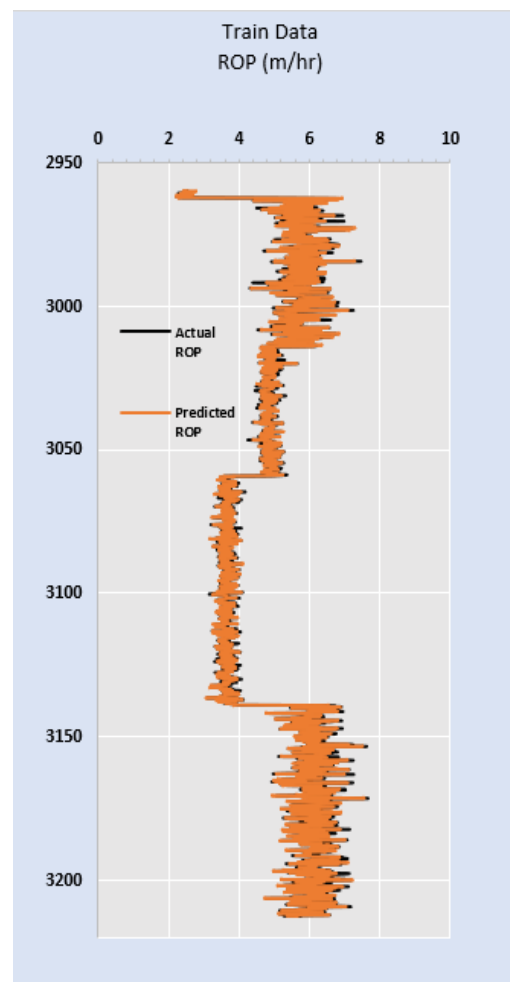
عملکرد مدل MLP-PSO در تخمین نرخ نفوذ حفاری برای ۷۰ درصد داده ها به عنوان داده های آموزش و ۳۰ درصد داده ها به عنوان داده های تست در شکل ۵ تا ۸ آمده است.



شکل (۶). عملکرد مدل MLP-PSO در تخمین نرخ نفوذ حفاری برای داده های تست



شکل (۷). مقادیر  $R^2$  برای نرخ نفوذ حفاری تخمین زده شده بر حسب داده های حفاری واقعی آموزش

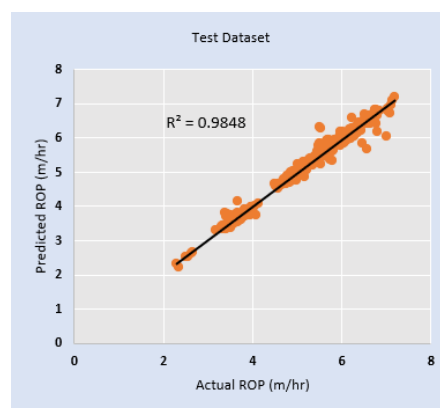


شکل (۵). عملکرد مدل MLP-PSO در تخمین نرخ نفوذ حفاری برای داده های آموزش

#### ۴. نتیجه گیری

برای تخمین نرخ نفوذ حفاری داده های یکی از چاه های میدان نفتی مارون با استفاده از نمودارگیری سیال حفاری و نمودار های پتروفیزیک گردآوری شده است. در ابتدا با استفاده از روش Savitzky-Golay نوسانات داده ها جهت افزایش دقت مدل کاهش یافته است. در مرحله بعد، ۸ پارامتر ورودی شامل وزن روی مته، سرعت گردش مته، فشار پمپ، وزن مخصوص سیال، ویسکوزیته پلاستیک سیال، نقطه تسلیم سیال، حجم شیل، تخلخل، مقاومت فشارشی تک محوره، مدول یانگ و چقرمگی به عنوان موثرترین پارامتر های ورودی بر تخمین نرخ نفوذ حفاری انتخاب شده اند. با استفاده از این پارامتر های ورودی دو مدل شبکه عصبی مصنوعی MLP-BP و MLP-PSO به منظور نرخ نفوذ حفاری توسعه یافته اند و نتایج آن با توجه به خطا و دقت آنها با یکدیگر مقایسه شده اند. در آخر نیز عملکرد مدل MLP-PSO به عنوان مدلی که بالاترین دقت را تخمین نرخ نفوذ حفاری داشته با سه مدل تجربی متداول مقایسه شده است. دستاورد های اصلی این پژوهش در ادامه خلاصه شده است:

- از میان پارامتر های عملیات حفاری، وزن روی مته، سرعت چرخش مته و فشار پمپ، از میان خواص سیال حفاری وزن مخصوص سیال، ویسکوزیته ی پلاستیک سیال، نقطه تسلیم سیال و از میان خواص سازند تخلخل، مقاومت فشارشی تک محوره، مدول یانگ و چقرمگی سنگ بیشترین تاثیر بر تخمین نرخ نفوذ حفاری را دارند.
- مدل شبکه عصبی مصنوعی آموزش داده شده با الگوریتم تجمع ذرات PSO عملکرد بسیار بالاتری نسبت مدل های دیگر در تخمین نرخ نفوذ حفاری از خود نشان داده که بیانگر قدرت این الگوریتم در بهینه سازی پارامتر های شبکه عصبی مصنوعی است.
- عملکرد الگوریتم های Back Propagation در تخمین نرخ نفوذ حفاری به دلیل استفاده از مقادیر کمینه محلی در کمینه سازی تابع هزینه، با خطای بیشتر و دقت کمتری نسبت به الگوریتم PSO مواجه شده است.
- کاهش نوسان داده ها و نرمال سازی داده های ورودی مدل شبکه عصبی مصنوعی بر افزایش دقت مدل در تخمین نرخ نفوذ حفاری بسیار موثر است.



شکل (۸). مقادیر  $R^2$  برای نرخ نفوذ حفاری تخمین زده شده بر حسب داده های حفاری واقعی تست

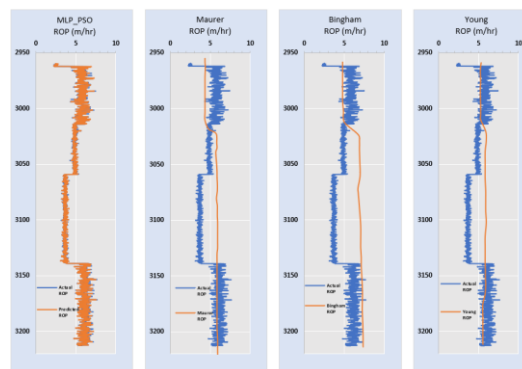
برای راستی آزمایی بیشتری این مدل توسعه داده شده، عملکرد آن با سه مدل متداول تجربی مقایسه شده است. مدل بینگهام مدلی تجربی است که دو پارامتر  $k$  قابلیت حفاری و  $a_5$  وزن مته با استفاده از آنالیز رگرسیون به ترتیب  $0.0437$  و  $0.0001$  بدست آمده است. همانند مدل بینگهام برای مدل ماورر نیز با استفاده از آنالیز رگرسیون ثابت  $k$  برابر با  $64695629$  محاسبه شده است.

جدول (۸). مقایسه خطا و دقت مدل شبکه عصبی مصنوعی

توسعه یافته با مدل های تجربی در تخمین نرخ نفوذ حفاری

مدل	$R^2$	RMSE
MLP-PSO	۰/۹۹۱۳	۰/۰۰۵۰۱
Maurer	۰/۲۰۵۴	۱/۰۱۳
Bingham	۰/۱۱۲۲	۱/۵۱۷
Young	۰/۳۵۷۸	۰/۹۸۷۴

از میان مدل های تجربی مدل بینگهام کمترین دقت و مدل یانگ بیشترین دقت در تخمین نرخ نفوذ حفاری را از میان دیگر مدل های تجربی داشته است. با این حال دقت مدل یانگ نسبت به مدل شبکه عصبی مصنوعی بسیار پایینتر است. عملکرد این ۴ مدل در تخمین نرخ نفوذ حفاری در شکل ۹ آمده است.



شکل (۹). عملکرد مدل های تجربی و مدل شبکه عصبی مصنوعی در تخمین نرخ نفوذ حفاری

- مدل سازی نرخ نفوذ حفاری با استفاده از شبکه عصبی مصنوعی نسبت به مدل های تجربی متداول در تخمین نرخ نفوذ حفاری داده های واقعی گزارش شده از میادین نفتی، عملکرد بسیار بهتری خواهد داشت. مدل های تجربی علاوه بر نیاز به زمان بیشتر برای محاسبه پارامترهای تجربی آنها، دقت بسیار پایینی نیز در تخمین نرخ نفوذ حفاری دارند.

## ۵. مراجع

- [1] Bilgesu, H. I., et al. "A new approach for the prediction of rate of penetration (ROP) values." SPE Eastern Regional Meeting. Society of Petroleum Engineers, 1997.
- [2] Arabjamaloei, R., and S. Shadizadeh. "Modeling and optimizing rate of penetration using intelligent systems in an Iranian southern oil field (Ahwaz oil field)." *Petroleum Science and Technology* 29.16 (2011): 1637-1648.
- [3] Bataee, M., and S. Mohseni. "Application of artificial intelligent systems in rop optimization: A case study." SPE middle east unconventional gas conference and exhibition. Society of Petroleum Engineers, 2011.
- [4] Jahanbakhshi, R., R. Keshavarzi, and A. Jafarnejhad. "Real-time prediction of rate of penetration during drilling operation in oil and gas wells." 46th US Rock Mechanics/Geomechanics Symposium. American Rock Mechanics Association, 2012.
- [5] Manshad, Abbas, et al. "Optimization of drilling penetration rate in oil fields Using artificial intelligence technique." *Heavy Oil: Characteristics, Production and Emerging Technologies*; Nova Science Publishers: Hauppauge, NY, USA (2017): 255-269.
- [6] Elkatatny, S. M., et al. "Optimization of rate of penetration using artificial intelligent techniques." 51st US Rock Mechanics/Geomechanics Symposium. American Rock Mechanics Association, 2017.
- [7] Maurer, W. C. "The" perfect-cleaning" theory of rotary drilling." *Journal of Petroleum Technology* 14.11 (1962): 1-270.
- [8] Bingham, Grant. "A new approach to interpreting rock drillability." *TECHNICAL MANUAL REPRINT, OIL AND GAS JOURNAL*, 1965. 93 P. (1965).
- [9] Bourgoyne Jr, Adam T., and F. S. Young Jr. "A multiple regression approach to optimal drilling and abnormal pressure detection." *Society of Petroleum Engineers Journal* 14.04 (1974): 371-384.
- [10] Moghadassi, Abdolreza, Fahime Parvizian, and S. Hosseini. "A new approach based on artificial neural networks for prediction of high-pressure vapor-liquid equilibrium." *Australian Journal of Basic and Applied Sciences* 3.3 (2009): 1851-1862.
- [11] Fausett, Laurene V. *Fundamentals of neural networks: architectures, algorithms and applications*. Pearson Education India, 2006.