

ارزیابی عملکرد شبکه‌های عصبی مصنوعی تلفیق شده با الگوریتم‌های فراابتکاری وال و مورچگان در تخمین نرخ نفوذ حفاری و مقایسه با شبکه‌های عصبی ساده و مدل‌های ریاضی

مرسوم

احسان برنجکار^{۱*}

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۳۹۸/۱۱/۲۶ پذیرش مقاله: ۱۴۰۰/۰۱/۱۵	
واژگان کلیدی: نرخ نفوذ حفاری، مدل بورگوان و یانگ، مدل بینگهام، الگوریتم وال، الگوریتم کلونی مورچگان، شبکه عصبی پرسپترون چند لایه.	تخمین نرخ نفوذ (ROP) در یک فرایند حفاری از آن جهت که سبب انتخاب بهینه پارامترهای حفاری و کاهش هزینه‌های مصرفی عملیات می‌شود بسیار حائز اهمیت است. هدف اصلی از این مقاله، مدلسازی و تخمین ROP با استفاده از شبکه‌های عصبی پرسپترون چند لایه بهینه شده با الگوریتم وال (WOA-MLPNN)، شبکه‌های عصبی بهینه شده با الگوریتم مورچگان (ACO-MLPNN)، شبکه‌های عصبی پس انتشار خطا (BP-MLPNN) و دو مدل ریاضی شامل مدل بورگوان و یانگ (BYM) و مدل بینگهام می‌باشد. داده‌های مورد نیاز برای توسعه مدل‌ها، از واحد نمودارگیری گل و گزارشات پایانی سه چاه حفاری شده در یک میدان نفتی واقع در جنوب غربی ایران جمع‌آوری شده است، که نخست به منظور حذف نقاط خارج از محدوده و کاهش نویز پیش پردازش شدند. در ادامه، از اطلاعات مقطع ۱۲،۲۵ اینچ دو حلقه چاه که شامل یک توالی مشابه از سازنده‌های حفاری شده می‌باشند به منظور آموزش و آزمایش مدل‌ها استفاده گردید و سپس مدل‌های تولید شده توسط اطلاعات چاه سوم مورد اعتبار سنجی قرار گرفتند. در پایان، عملکرد مدل‌ها بوسیله شاخص‌های آماری و ابزارهای گرافیکی مختلفی مورد ارزیابی قرار گرفت. نتایج این مطالعه نشان داد که روش‌های آموزش ماشین نسبت به مدل‌های ریاضی مرسوم بسیار دقیقتر می‌باشند. همچنین، بررسی‌های بیشتر ثابت کرد که مدل WOA-MLPNN با مقادیر AAPRE برابر ۳،۱۹، ۵،۴۸ و ۹،۳۱ به ترتیب برای سه بخش آموزش، آزمایش و اعتبار سنجی بالاترین عملکرد را نسبت به سایر مدل‌ها دارا می‌باشد.

۱- مقدمه

نفوذ ممکن است سبب بوجود آوردن مشکلاتی همچون گیر کردن لوله‌ها، تمیز شدن نامناسب چاه و فرسایش سریع مته شود، که مزیت‌های یک حفاری سریعتر را خنثی میکند. لذا دستیابی به یک مقدار بهینه برای نرخ نفوذ بسیار ضروری است [۳]. پارامترهای تأثیر گذار بر نرخ نفوذ را میتوان به دو زیر گروه متغیرهای قابل کنترل و متغیرهای غیر قابل کنترل تقسیم نمود. متغیرهای قابل کنترل، به عنوان پارامترهایی شناخته میشوند که می‌توان آنها را در

نرخ نفوذ (ROP)، یک فاکتور مؤثر در بهینه سازی فرایند حفاری می‌باشد که با تخمین هر چه دقیق تر آن می‌توان علاوه بر مدیریت هزینه های مصرفی و انتخاب مته بهینه، برنامه ریزی بهتری از چاه‌های آینده داشت [۱]. موفقیت هر عملیات حفاری در پروژه‌های نفت و گاز تابعی از سه معیار افزایش سرعت حفاری یا میزان نفوذ، کاهش هزینه کلی و حفظ ایمنی می‌باشد [۲]. همچنین افزایش بیش از حد نرخ

* پست الکترونیک نویسنده مسئول: ebrenjkar@gmail.com

۱. فارغ التحصیل کارشناسی ارشد مهندسی نفت، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران

ورودی شامل عمق^۳(ft)، قطر مته^۴(in)، میزان فرسایش مته (%)، هیدرولیک مته حفاری^۵(lbf)، سرعت چرخش مته^۶(rpm)، وزن روی مته^۷(klbf)، وزن روی قلاب^۸(klbf)، گشتاور^۹(lbf.ft)، فشار منفذی سازند (ppg)، چگالی گل در حال گردش^{۱۰}(ppg) و ساعات کار مته^{۱۱}(hr) میباشد. پیش از فرایند مدلسازی، داده‌های جمع‌آوری شده به منظور حذف نقاط دور افتاده و کاهش نویز مورد بررسی قرار گرفتند. در ادامه، داده‌های جمع‌آوری شده از چاه شماره ۱ و چاه شماره ۲ با یکدیگر ترکیب شدند تا یک مجموعه داده بزرگتر را تشکیل دهند. سپس این مجموعه داده به طور تصادفی به دو زیر مجموعه آموزش (۷۰ درصد) و مجموعه آزمایش (۳۰ درصد) تقسیم گردید. از مجموعه داده‌های آموزش با ۷۷۸ نقطه داده برای توسعه مدلها و از مجموعه داده آزمایش با ۳۳۵ نقطه داده برای ارزیابی عملکرد تقریب مدلها استفاده گردید. پس از توسعه مدلها، به منظور اعتبار سنجی و ارزیابی مدلها به صورت میدانی، از آنها برای تخمین نرخ نفوذ در چاه شماره ۳ با ۳۶۲ نقطه داده استفاده گردید. در پایان، ارزیابی خطا در سه بخش آموزش، آزمون و اعتبار سنجی مدلها توسط شاخص‌های اماری مختلفی مورد بررسی قرار گرفت که شامل میانگین درصد نسبی خطای مطلق (AAPRE)، میانگین مربعات خطا (RMSE)، ضریب همبستگی (R^2) و ضریب رگرسیون (R) می‌باشد. نتایج این مطالعه می‌تواند در برنامه‌ریزی و بهینه‌سازی فرایند حفاری چاه‌های آینده مورد توجه قرار گیرد.

۲- مروری بر ادبیات تحقیق

عبدالجبار و همکاران [۹]، یک مدل ریاضی جدید را برای تخمین ROP ارائه کردند که در آن از پارامترهای عملیات حفاری و خصوصیات سیال حفاری استفاده شده بود. نتایج مطالعه آنها نشان داد که مدل توسعه داده شده دارای دقت مناسبی در تخمین ROP می‌باشد. آنها همچنین نتیجه‌گیری کردند که ROP به شدت وابسته به پارامترهایی نظیر وزن روی مته، سرعت چرخش، گشتاور، هیدرولیک حفاری، ویزکوزیته پلاستیک و دانسیته گل حفاری می‌باشد. ویکتورسکی و همکاران [۱۰]، مدل

حین عملیات حفاری تغییر داد، در حالی که متغیرهای غیر قابل کنترل به عنوان پارامترهایی شناخته می‌شوند که از جانب محیط تحمیل شده و اساساً تغییر آنها از نظر اقتصادی و عملیاتی امکانپذیر نیست [۴]. هر یک از مدل‌های ارائه شده در پیشینه تحقیق، تعداد مشخصی از پارامترهای حفاری را به عنوان ورودی در نظر می‌گیرند. با این حال وزن روی مته، سرعت چرخش و سایز مته معمولاً در اکثر مدلها وجود دارند [۵].

در دهه‌های اخیر روابط ریاضی متعددی توسط محققین مختلف ارائه شده، که ارتباط میان نرخ نفوذ و متغیرهای مختلف را بیان می‌کنند. به دلیل تعداد زیاد متغیرهای مؤثر بر نرخ نفوذ و همچنین ارتباط پیچیده میان این متغیرها با یکدیگر، دستیابی به مدلی با دقت بالاتر برای تخمین نرخ نفوذ، سبب بوجود آمدن یک زمینه چالش بر انگیز تحقیقاتی در سالهای اخیر شده است. از جمله مدل‌های نرخ نفوذ پیشین میتوان به مدل گیل و وود [۶]، مدل بینگهام [۷] و مدل بورگوان و یانگ [۸] اشاره نمود، که مدل بورگوان و یانگ یکی از جامع‌ترین و قابل قبول‌ترین مدل‌های ریاضی در ادبیات تحقیق است. ثوابت مدل‌های ریاضی، از یک میدان به میدانی دیگر متفاوت است و تأثیر برخی از پارامترها نظیر وزن روی مته و سرعت چرخش بر روی نرخ نفوذ به صورت خطی فرض شده است. به دلیل این محدودیت‌ها و همچنین دقت پایین مدل‌های ریاضی، مدل‌های مبتنی بر هوش محاسباتی^۱ می‌توانند به عنوان یک جایگزین مناسب در تخمین نرخ نفوذ به شمار آیند [۱].

هدف اصلی از این مطالعه، مدلسازی و تخمین ROP با استفاده از شبکه‌های عصبی پرسپترون چند لایه بهینه شده با الگوریتم وال (WOA-MLPNN)، شبکه‌های عصبی پرسپترون چند لایه بهینه شده با الگوریتم مورچگان (ACO-MLPNN)، شبکه‌های عصبی پرسپترون چند لایه پس انتشار خطا (BP-MLPNN) و دو مدل ریاضی شامل مدل بورگوان و یانگ (BYM) و مدل بینگهام می‌باشد. به منظور توسعه مدل‌های تخمین گر نرخ نفوذ، از داده‌های واحد نمودارگیری گل^۲ و گزارش نهایی سه چاه حفاری شده واقع در جنوب غربی ایران، استفاده شده است. متغیرهای

⁷ Weight on the bit

⁸ Hook load

⁹ Torque

¹⁰ Equivalent circulating density (ECD)

¹¹ Bit working hour

¹ Computational intelligence (CI)

² Mud logging unit (MLU)

³ Depth

⁴ Bit size

⁵ Bit hydraulic

⁶ Bit rotational speed

شبکه‌های عصبی مصنوعی برای پیش‌بینی میزان نفوذ با استفاده از داده‌های سطحی پرداختند. داده‌های مورد استفاده برای ساخت مدل شبکه‌های عصبی مصنوعی از سه چاه حفاری شده استخراج گردید. در ادامه، از داده‌های ۲ چاه برای آموزش و آزمون مدلها استفاده گردید و سپس مدل موردنظر با استفاده از داده‌های چاه شماره ۳ مورد اعتبار سنجی قرار گرفت. گن و همکاران [۱۷]، از فیلتر تبدیل موجک برای کاهش نویز داده‌ها استفاده کردند و در مرحله بعد ورودی‌های مدل را با استفاده از روش اطلاعات متقابل^۷ تعیین نمودند. پس از توسعه مدل‌های مختلف آموزش ماشین و اعتبار سنجی آنها بوسیله داده‌های سایر چاه‌ها، ثابت گردید که ترکیب الگوریتم خفاش (BA)^۸ و روش رگرسیون بردار پشتیبان، بالاترین دقت پیش‌بینی را جهت تقریب نرخ نفوذ ارائه می‌کند. اشرفی و همکاران [۱۸]، از مجموعه داده‌های پتروفیزیکی و داده‌های حفاری استخراج شده از یک چاه عمودی در میدان نفتی مارون، برای مدلسازی و تخمین نرخ نفوذ حفاری استفاده کردند. آنها نویز کلی داده‌های جمع‌آوری شده را با اجرای فیلتر هموارسازی ساویتزکی گولی کاهش دادند و سپس از یک روش انتخاب ویژگی و ویژگی‌ها با استفاده از الگوریتم ژنتیک برای انتخاب ویژگی‌های مؤثر و همچنین کاهش تعداد ورودی‌ها استفاده کردند. بر اساس نتایج مطالعه آنها ثابت گردید که مدل شبکه‌های عصبی ترکیب شده با الگوریتم ازدحام ذرات (PSO-MLPNN) دارای بالاترین دقت در تخمین نرخ نفوذ حفاری می‌باشد.

۳- کلیات تحقیق

۳-۱- شبکه عصبی پرسپترون چند لایه (MLPNN)
شبکه عصبی پرسپترون چند لایه، یک سیستم پردازش اطلاعات است که سعی دارد از ویژگی‌های سیستم عصبی انسان تقلید کند و یک مدل رایانه‌ای را بوجود آورد که از طریق آن می‌توان الگوهای موجود در داده‌ها را پیدا کرده و همبستگی میان متغیرها را بدست آورد [۱۹]. یک شبکه عصبی از تعداد زیادی واحدهای پردازشگر به نام نورون تشکیل شده که از طریق برخی اتصالات وزن دار به یکدیگر متصل شده‌اند و بدین وسیله امکان آموزش شبکه فراهم

بورگوان و یانگ را به منظور به حساب آوردن نرخ تغییر زاویه چاه^۱ و چگالی گل در حال چرخش اصلاح کردند و ثابت کردند که مدل جدید بدست آمده دارای دقت بالاتری نسبت به مدل کلاسیک می‌باشد. درویش و همکاران [۱۱]، مدل بورگوان و یانگ را به کار گرفتند تا مقایسه پارامترهای حفاری قابل کنترل را با استفاده از داده‌های ۲۳ چاه حفاری شده در شمال عراق بهینه‌سازی کنند. آنها همچنین به لزوم حذف نویز و همگنی سازند از طریق روش خوشه بندی^۲ و میانگین گیری^۳ اشاره کردند. انه منگلی و همکاران [۱۲]، از الگوریتم بهینه سازی فاخته (COA) برای تعیین ضرایب مدل بورگوان و یانگ استفاده کردند. آنها برای رسیدن به این هدف، داده‌های مربوط به دو چاه حفاری شده در یک میدان نفتی واقع در جنوب غربی ایران را جمع آوری کردند و پس از محاسبه ثوابت مدل به طور جداگانه برای یکی از چاه‌ها، از آن ثوابت برای تخمین میزان نرخ نفوذ حفاری در چاه دیگر با همان سازندها استفاده کردند. در پایان، نتایج بدست آمده با سایر الگوریتم‌ها نظیر ازدحام ذرات (PSO) و الگوریتم ژنتیک (GA) مقایسه گردید و ثابت شد که COA دارای سرعت بیشتری در همگرایی بوده و خطای برآورد کمتری را نتیجه می‌دهد. به دلیل وجود محدودیت و همچنین پیچیدگی ارتباط میان متغیرهای اثرگذار بر ROP، تاکنون مدل‌های ریاضی ارائه شده در پیشینه تحقیق قادر به تخمین مناسب نرخ نفوذ نبودند [۱۳].

یوسفی و همکاران [۱۴]، از روش ماشین یادگیری افراطی (ELM)^۴ برای تخمین نرخ نفوذ استفاده کردند و نتایج بدست آمده را با مدل‌های تجربی مقایسه نمودند. نتایج مطالعه آنها ثابت کرد که مدل ELM ترکیب شده با الگوریتم وال (WOA) بالاترین دقت را در تقریب نرخ نفوذ دارا می‌باشد. ایوب و همکاران [۱۵]، به بررسی تخمین نرخ نفوذ از طریق روش شبکه‌های عصبی فازی (ANFIS)^۵ پرداختند و نتایج بدست آمده را با مدل‌های مرسوم مقایسه کردند. احمد و همکاران [۱۵]، به مقایسه روش ماشین بردار پشتیبان (SVM)^۶ و مدل نرخ نفوذ بورگوان و یانگ پرداختند و توانستند با استفاده از روش SVM به دقت مناسبی از تقریب ROP دست یابند. عبد و الجبار و همکاران [۱۶]، در مطالعه خود به پیاده‌سازی یک روش

^۵ Adaptive neural fuzzy inference systems (ANFIS)

^۶ Support vector machine

^۷ Mutual information

^۸ Bat algorithm (BA)

^۱ Dog leg severity (DLS)

^۲ Clustering

^۳ Averaging

^۴ Extreme learning machine

خروجی محاسبه می‌گردد. به روزرسانی وزن‌ها و بایاس‌های شبکه تازمانی که شرایط توقف محقق شده و خطای میان مقادیر واقعی و خروجی به مقدار قابل قبولی برسد ادامه می‌یابد. نحوه به‌روزرسانی وزن‌های شبکه در رابطه (۳) ارائه شده است.

$$W_{ij(t+1)} = W_{ij}(t) + \eta \frac{\partial f(e)}{\partial W_{ij}} \quad (3)$$

در جایی که، W_{ij} پارامتر وزن شماره i را در لایه j نشان می‌دهد، t تکرار آموزش، $\partial f(e)$ تابع خطا و η نرخ یادگیری می‌باشد [۲۲]. در شبکه‌های عصبی مصنوعی، کاهش خطا بسیار اهمیت دارد. خطا می‌تواند به صورت مقدار مطلق اختلاف میان مقادیر واقعی و تخمین زده شده و یا به صورت مقدار میانگین مربعات خطا تعریف شود. کاهش مقدار خطای شبکه و دستیابی به شبکه‌ای با حد اقل خطا، هدف از یک فرآیند آموزشی می‌باشد که بوسیله یک الگوریتم بهینه‌سازی و با تنظیم وزن‌ها و بایاس‌های شبکه محقق می‌شود [۲۱].

۲-۳- مدل‌های نرخ نفوذ ریاضی

مدل نرخ نفوذ بورگوان و یانگ (BYM) [۸]، یکی از کاملترین مدل‌های ریاضی برای پیش‌بینی نرخ نفوذ می‌باشد که مقبولیت بالایی در صنعت حفاری بدست آورده است. این مدل به صورت حاصل ضرب هشت تابع مستقل می‌باشد که هر یک از این توابع برای تعیین اثر پارامترهای مختلف بر روی نرخ نفوذ در نظر گرفته شده‌اند. رابطه کلی این مدل به صورت زیر می‌باشد:


$$R = f_1 \times f_2 \times f_3 \times f_4 \times f_5 \times f_6 \times f_7 \times f_8 \quad (4)$$

که در این رابطه، f_1 تأثیر مقاومت سازند، f_2 تأثیر عمق و فشردگی سازند، f_3 تأثیر فشار منغذی سازند، f_4 تأثیر فشار تفاضلی سازند و چاه، f_5 تأثیر وزن روی مته و قطر مته، f_6 تأثیر سرعت چرخش مته، f_7 تأثیر میزان فرسایش دندان‌های مته و f_8 تأثیر هیدرولیک حفاری را بر روی نرخ نفوذ تعریف می‌کند [۱۱]. هر یک از این توابع، به صورت روابط (۵) تا (۱۲) تعریف شده‌اند.

$$f_1 = e^{(2.303 \times a_1)} \quad (5)$$

$$f_2 = e^{2.303 \times a_2 (10000 - D)} \quad (6)$$

می‌آید [۲۰]. شبکه‌های عصبی پرسپترون چند لایه (MLPNN)، یکی از انواع شبکه‌های عصبی پیشخور است که از سه لایه ورودی، میانی و خروجی تشکیل شده است. در شکل (۱)، ساختار یک شبکه عصبی MLP نمایش داده شده است.



شکل ۱- ساختار یک شبکه عصبی MLP سه لایه

رابطه ریاضی یک شبکه عصبی MLP شامل n ورودی و k نورون در لایه پنهان را می‌توان به صورت رابطه (۱) نوشت.

$$y = f^o \left(\omega^o + \sum_{i=1}^k \omega_j^o f^h \left(\omega_j^h + \sum_{i=1}^n \omega_{ji}^h x_i \right) \right) \quad (1)$$

که در این عبارت، f^o تابع فعال ساز در لایه خروجی، f^h تابع فعال ساز در هر یک از نورون‌های لایه مخفی، ω^b مقدار بایاس اضافه شده به لایه پنهان می‌باشد. در شبکه‌های عصبی پرسپترون چند لایه، نخست هر یک از ورودی‌ها در مقادیری وزن مشخصی ضرب می‌شوند و سپس برای انجام محاسبات اصلی به لایه میانی منتقل می‌شوند. در لایه میانی، نورون‌هایی با توابع غیر خطی مستقر هستند که پس از جمع نمودن مقادیر وزن دار شده ورودی‌ها، این مقادیر را به یک بازه مشخص انتقال می‌دهند. تابع فعال‌سازی سیگموئید^۱ (رابطه ۲) یکی از انواع توابع پرکاربرد در شبکه‌های عصبی می‌باشد [۲۱].

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

برای آموزش و به‌روزرسانی وزن‌های شبکه، از روش آموزش با نظارت استفاده می‌شود. در روش آموزش با نظارت، نخست مقادیر وزن‌های شبکه به‌صورت تصادفی انتخاب شده و در ادامه برای هر یک از ورودی‌های شبکه، مقدار

^۱ Sigmoid function

k ثابت نشان دهنده سهولت حفاری سازند و a ثابت وزن روی مته می‌باشد [۵]. k و a ثوابت بدون بعد برازش مدل هستند که بایستی برای هر سازند و یا یک مقطع مشخص از چاه، بوسیله مجموعه داده‌های آموزشی و به طوری که بهترین برازش بر روی داده‌های میدانی بوجود آید، محاسبه شوند [۲۳].

۳-۳- الگوریتم بهینه سازی وال (WOA)

این الگوریتم یک فرآیند بهینه‌سازی فرا ابتکاری است که از نهنگ‌های گوژپشت الهام گرفته شده و در سال ۲۰۱۶ توسط میرجلیلی و لوییس [۲۴]، ارائه گردیده است. در حقیقت، این روش یک نوع الگوریتم مبتنی بر جمعیت است که بر پایه الگوی منحصر به فرد والها برای صید بیشتر ماهی‌ها می‌باشد. جالب ترین نکته در مورد شکار والها، روش خاص آنها می‌باشد که به نام حباب تور^۱ شناخته می‌شود. در روش حباب تور، والها به دور دسته‌ای از ماهی‌ها می‌چرخند و حباب‌های متمایز را تولید می‌کنند که از طریق آن ماهی‌ها را در دام می‌اندازند و سبب می‌شوند تا ماهی‌ها به سطح دریا فرار کنند. سپس به سمت ماهی‌ها نزدیک می‌شوند و آنها را شکار می‌کنند [۲۵].

محاصره طعمه در بهترین موقعیت، مرحله اولیه شکار طعمه است. نهنگ‌های گوژپشت برای موقعیت مناسب طعمه را نگاه می‌کنند و موقعیت‌های خود را بر اساس یک راه حل بهینه برای شکار ماهی‌ها انتخاب می‌کنند. این راه‌حل را می‌توان با معادلات (۱۴) و (۱۵) بیان نمود:

$$\vec{D} = \left| \vec{C}\vec{X}^* - \vec{X}(t) \right| \quad (14)$$

$$\vec{A} = 2a\vec{r} - \quad (15)$$

در جایی که \vec{X} و \vec{X}^* دو بردار موقعیت هستند و \vec{X} نشان دهنده راه حل بهینه بدست آمده در هر لحظه می‌باشد و t بیانگر تکرار حال حاضر می‌باشد. علاوه بر این، \vec{A} و \vec{D} بردارهای ضریب هستند که به صورت زیر تعریف می‌شوند:

$$\vec{A} = 2a\vec{r} - \vec{a} \quad (16)$$

$$\vec{C} = 2\vec{r} \quad (17)$$

در جایی که، a یک متغیر کاهنده خطی است و r یک بردار مشتمل بر مقادیر تصادفی بین ۰ و ۱ می‌باشد.

$$f_3 = e^{(2.303 \times a_3 \times D^{0.69} (g_p - 9))} \quad (7)$$

$$f_4 = e^{(2.303 \times a_4 \times D (g_p - \rho_c))} \quad (8)$$

$$f_5 = \left[\frac{\left(\frac{W}{d_b} \right) - \left(\frac{W}{d_b} \right)_t}{4 - \left(\frac{W}{d_b} \right)_t} \right]^{a_5} \quad (9)$$

$$f_6 = (N / 60)^{a_6} \quad (10)$$

$$f_7 = e^{-a_7 \times h} \quad (11)$$

$$f_8 = (F_j / 1000)^{a_8} \quad (12)$$

که در این روابط، D عمق حفاری (ft)، d_b قطر مته (in)، g_p گرادیان فشار منفذی سازند (lb/gal)، h مقدار فرسایش دندان‌های مته (%)، ρ_c چگالی گل حفاری (lb/gal)، N سرعت دوران مته (rpm)، WOB وزن روی مته ($klbf$)، $\left(\frac{W}{d_b} \right)_t$ وزن آستانه روی مته که پس از آن حفاری سازند شروع می‌شود ($klbf$) و a_1, \dots, a_8 نیز ثوابت میدانی مدل هستند که بایستی بوسیله روش‌هایی نظیر حد اقل مربعات رگرسیون چند گانه و یا الگوریتم‌های جمعیت مه‌ور، برای هر سازند و یا گروهی از سازندها محاسبه شوند. عملکرد این مدل، وابسته به تنظیم ثوابت بر اساس خصوصیات میدانی است. بنابراین بدیهی است که بدست آوردن مقادیر مناسب برای این ثوابت، تأثیر به‌سزایی بر عملکرد تقریب مدل داشته باشد [۱۲].

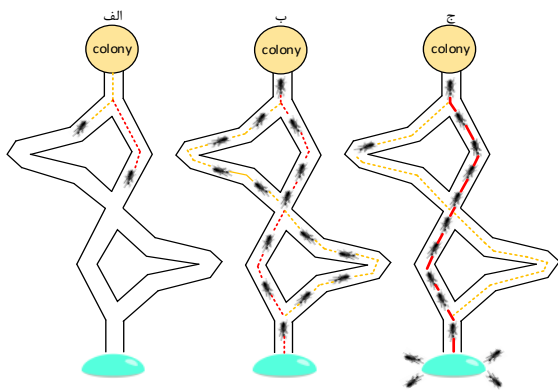
بینگهام [۷]، در سال ۱۹۶۵ یک مدل ریاضی نرخ نفوذ را ارائه نمود که از سه متغیر وزن روی مته، قطر مته و سرعت چرخش برای تخمین ROP استفاده می‌نماید. در استفاده از این مدل محدودیتی در خصوص نوع مته مطرح نشده است. رابطه این مدل به صورت رابطه زیر می‌باشد:

$$R = k \left(\frac{W}{d} \right)^a . N \quad (13)$$

در جایی که، R نرخ نفوذ (ft/hr)، W وزن روی مته (klb)، d قطر مته (in)، N سرعت چرخش (RPM)،

¹ Bubble-net

منبع غذایی الهام گرفته شده است [۲۹]. در ابتدا جستجوی مورچه‌ها برای پیدا کردن غذا به صورت تصادفی می‌باشد. اما وقتی مورچه‌ای یک منبع غذایی را پیدا می‌کند، هنگام بازگشت به کلونی مقدار مشخصی فرومون را در مسیر ترشح کرده تا سایر مورچه‌ها بتوانند با ردگیری آن، به سوی منبع غذایی یافت شده هدایت شوند. این فرومون‌ها پایدار نیستند و بعد از مدتی تبخیر می‌شوند تا جستجو برای بهترین مسیر همواره ادامه داشته باشد [۳۰]. در شکل ۲، می‌توان یک نقشه کلی از رفتار طبیعی مورچه‌ها را برای پیدا کردن غذا مشاهده نمود. خطوط قرمز رنگ، نشان دهنده میزان فرومون ترشح شده توسط مورچه‌ها می‌باشد که غلظت آن به کیفیت منبع غذایی و فاصله آن تا کلونی بستگی دارد.



شکل ۲- رفتار طبیعی مورچه‌ها برای پیدا کردن منبع غذایی. (الف): شروع جستجوی تصادفی، ب: یافتن اولین مسیر میان منبع غذایی و کلونی، ج: تقویت نزدیک ترین مسیر به منبع غذایی با ترشح فرومون بیشتر توسط سایر مورچه‌ها)

الگوریتم ACO اولیه، برای استفاده در مسائل گسسته طراحی شده بود و به منظور تعمیم این الگوریتم به مسائل پیوسته بایستی اصلاحاتی بر روی آن انجام می‌شد. سوشا و دریگو در سال ۲۰۰۸ [۳۱]، از جمله کسانی بودند که این الگوریتم را برای کاربرد در فضای پیوسته ارائه کردند. این الگوریتم، بیشترین مطابقت را با الگوریتم ACO فضای گسسته داشت، به طوری که می‌توانست بدون تغییرات اساسی در مفهوم الگوریتم اولیه، بهینه سازی مسائل پیوسته را انجام دهد. به منظور پیوسته‌سازی فضا در متغیرهای تصمیم، در این الگوریتم از یک تابع چگالی به نام (PDF) به جای تابع گسسته استفاده شده است. این تابع متشکل از مجموعه‌ای از توابع کرنل گوسی می‌باشد که از مجموعه وزنی چندین تابع گوسی منفرد بوجود آمده است. برای متغیر i -ام، یک تابع کرنل گوسی $G^i(x)$ را میتوان

در گام بعد وال‌های گوژپشت به سمت طعمه حمله می‌کنند که این مرحله محاصره طعمه‌ها کوچکتر شده و بر اساس این مکانیزم مقادیر \vec{A} و \vec{a} در دو رابطه قبل کاهش پیدا می‌کنند. بردار \vec{A} شامل مقادیر تصادفی در بازه $[-a, a]$ را شامل می‌شود و از مقدار ۲ به ۰ کاهش پیدا می‌کند. موقعیت جدید را می‌توان با استفاده از موقعیت‌های بهینه و فعلی به دست آورد. در ادامه، موقعیت مارپیچی به روز رسانی می‌شود. در صورتی (X, Y) و (X^*, Y^*) نشان دهنده موقعیت وال و طعمه باشد و \vec{D}' فاصله میان آنها باشد، حرکت مارپیچ نهنگ‌ها را میتوان به صورت زیر نوشت:

$$\vec{X}(t+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) \quad (18)$$

در جایی که $\vec{D}' = |\vec{X}^*(t) - \vec{X}(t)|$ یک متغیر ثابت، l یک متغیر تصادفی میان $[-1, 1]$ و b یک ثابت می‌باشد. یک مدل ریاضی برای به‌روز رسانی موقعیت وال‌ها در فرآیند بهینه‌سازی مورد نیاز است، زیرا آن‌ها به سمت طعمه در دو مکانیسم کوچک کردن دایره و حرکت در مسیر مارپیچ عمل می‌کنند. به روز رسانی موقعیت وال‌ها به صورت زیر ارائه شده است:

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - \vec{A}\vec{D} & \text{if } p < 0.5 \\ \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) & \text{if } p \geq 0.5 \end{cases} \quad (19)$$

در جایی که p یک مقدار تصادفی با رنجی میان ۰ تا ۱ می‌باشد. گام آخر این الگوریتم، جستجو برای طعمه (فاز اکتشافی) می‌باشد که بر اساس آن، یک جستجوی جهانی انجام می‌شود. این مکانیزم وقتی استفاده می‌شود، \vec{A} دارای یک مقدار تصادفی بزرگتر از ۱ یا کمتر از -۱ می‌باشد. جستجوی طعمه را می‌توان با معادلات زیر الگو گرفت:

$$\vec{D} = |\vec{C}\vec{X}_{rand} - \vec{X}| \quad (20)$$

$$\vec{X}(t+1) = \vec{X}_{rand} - \vec{A}\vec{D} \quad (21)$$

در جایی که بردار موقعیت \vec{X}_{rand} به صورتی تصادفی از وال‌های میان جمعیت تولید شده انتخاب می‌شود [۲۶ و ۲۷].

۳-۴ الگوریتم کلونی مورچگان (ACO)

الگوریتم بهینه‌سازی کلونی مورچگان (ACO)، یکی از روش‌های حل مسائل بهینه‌سازی با رویکرد جمعی می‌باشد که در سال ۱۹۹۶، توسط دریگو و همکارانش [۲۸]، مطرح گردید. ACO از هوش جمعی و همکاری دسته جمعی میان مورچگان برای یافتن کوتاه‌ترین مسیر از کلونی تا

در این رابطه، $\xi > 0$ یک پارامتر مشابه نرخ تبخیر فرومون در فضای گسسته می‌باشد که در نظر گرفتن مقادیر پایین برای آن، سرعت همگرایی الگوریتم را افزایش می‌دهد. در ادامه برای تولید جواب جدید بر اساس جواب S_l ، یک عدد تصادفی نرمال با میانگین S_l^i و انحراف معیار σ_l^i برای متغیر تصمیم i -ام تولید می‌شود. پس از تولید یک جواب برای همه متغیرهای تصمیم که حاصل انتخاب یکی از مورچه‌ها می‌باشد، برای هر مورچه جواب جدیدی تولید شده و به آرشو اضافه می‌گردد. در ادامه کل جوابها مرتب شده و پس از ذخیره سازی k جواب برتر، مابقی حذف می‌شوند. این مراحل تا محقق شدن شرایط خاتمه تکرار می‌شود [۳۲].

۵-۳- الگوریتم پس انتشار خطا (BP)

الگوریتم پس انتشار خطا، یک روش آموزشی تحت نظارت شبکه‌های عصبی مصنوعی است. در این روش، ابتدا یک مجموعه داده مورد پردازش قرار گرفته و عملکرد خطا در هر نرون ارزیابی می‌شود تا از این طریق بتوان وزن‌های شبکه را به گونه‌ای اصلاح نمود که با دریافت ورودی‌های دلخواه، مقادیر خروجی مطلوب را نگاشت نماید. وزن‌های به‌دست آمده که حداقل عملکرد خطا را ارائه می‌دهند، راه‌حل مطلوب مسئله یادگیری است [۲۱]. الگوریتم پس انتشار یکی از پرکاربردترین روش‌های آموزش با نظارت می‌باشد که امروزه بسیار در آموزش شبکه‌های عصبی مورد استفاده قرار می‌گیرد [۳۳]. عملکرد این الگوریتم برای تنظیم وزن‌های شبکه اینگونه است که در هر تکرار، داده‌های ورودی به شبکه وارد شده و خروجی‌های متناظر با داده‌های ورودی بدست می‌آید. پس از بدست آمدن خروجی‌ها، اختلاف آنها در مقایسه با مقدار واقعی محاسبه شده و در طول شبکه به عقب منتشر می‌شود تا وزن‌ها و بایاس‌های شبکه در جهت کاهش خطا به‌روز رسانی شوند. الگوریتم در هر تکرار، تلاش می‌کند تا با تغییر اوزان شبکه، خطا را تا زمانی که شرایط توقف حاصل شود، کاهش دهد [۳۴].

۴- جمع آوری داده‌های میدانی

فراهم آوردن داده‌های مناسب یکی از بخش‌های مهم در توسعه مدل‌های مبتنی بر آموزش ماشین می‌باشد، به طوری که فراهم کردن داده‌های با کیفیت بالا و با تعداد نمونه‌های

مطابق با رابطه (۲۲) تعریف نمود:

$$G^i(x) = \sum_{l=1}^k \omega_l g_l^i(x) = \dots \quad (22)$$

به منظور تعریف این رابطه بایستی سه پارامتر ω و σ^i و ∞^i مشخص شوند. در الگوریتم ACO پیوسته، ابتدا مجموعه‌ای از جوابها تولید شده و در یک آرشو قرار داده می‌شوند. در صورتی که n متغیر تصمیم وجود داشته باشد، تعداد جواب‌های ذخیره شده در آرشو برابر k می‌باشد. همچنین l -امین جواب ذخیره شده، با S_l مشخص می‌شود که نشان دهنده ردیف آن جواب در آرشو می‌باشد. سپس جوابهای موجود مورد ارزیابی قرار گرفته و به صورت نزولی مرتب می‌شوند و برای هر کدام یک وزن (ω) در نظر گرفته می‌شود. مقادیر این وزن‌ها از طریق رابطه (۲۳) قابل محاسبه می‌باشند.

$$\omega_l = \frac{1}{qk\sqrt{2\pi}} e^{-\frac{(l-1)^2}{2q^2k^2}} \quad (23)$$

در جایی که، $q > 0$ یک پارامتر تنظیمی می‌باشد که مشابه فشار انتخاب عمل می‌کند. انتخاب مقادیر پایین برای q ، شانس انتخاب راه‌حل‌های ضعیف‌تر را کاهش داده و الگوریتم را به سوی یک بهینه محلی سوق می‌دهد. پارامتر ∞^i ، برای جواب l و متغیر تصمیم i -ام در آرشو جوابها، برابر با S_l^i می‌باشد. احتمال انتخاب یک جواب توسط یک مورچه بر اساس وزن آن، توسط رابطه زیر تعریف می‌شود:

$$P_l = \frac{\omega_l}{\sum_{j=1}^k \omega_j} \quad \forall l=1\dots k \quad (24)$$

در جایی که، ω_l وزن تابع گوسی جواب l -ام می‌باشد. سپس یک جواب جدید با استفاده از تابع گوسی که دارای میانگین $\mu = S_l^i$ و انحراف معیار σ می‌باشد، تولید می‌شود. انحراف معیار در هر مرحله، که نشان دهنده میانگین فاصله میان راه حل انتخابی S_l با سایر راه‌حل‌ها می‌باشد، از رابطه زیر محاسبه می‌شود:

$$\sigma^i = \xi \sum_{e=1}^k \frac{|s_e^i - s_l^i|}{k-1} \quad i=1,2,\dots,n \quad (25)$$

¹ Back Propagation Algorithm (BP)

استفاده گردید و همچنین برای توسعه مدل‌های ریاضی، ورودی‌ها بر اساس روابط ارائه شده در ادبیات تحقیق انتخاب شدند.

داده‌های جمع آوری شده نخست با هدف بهبود کیفیت و حذف نقاط دور افتاده، مورد پیش پردازش قرار گرفتند. در ادامه، از داده‌های حفره ۱۲،۲۵ اینچی چاه اول و دوم که مجموعاً شامل ۱۱۱۳ نقطه داده می‌باشد برای آموزش و آزمایش مدل‌ها استفاده گردید. سپس، از داده‌های چاه سوم با ۳۶۲ نقطه داده استفاده گردید تا مدل‌های توسعه یافته مورد اعتبار سنجی قرار گیرند. اطلاعات آماری مجموعه داده‌های مورد استفاده برای توسعه و اعتبار سنجی مدل‌های مورد مطالعه، در جدول ۱ و ۲ ارائه شده است.

بیشتر منجر به تولید مدل‌هایی با قابلیت اعتماد بالاتر می‌گردد [۳۵]. در این مطالعه، داده‌های مورد نیاز برای توسعه مدل‌ها از واحد نمودارگیری گل و گزارشات نهایی سه چاه حفاری شده واقع در جنوب غربی ایران جمع آوری شده است. داده‌های جمع آوری شده شامل ۱۱ متغیر مستقل و یک متغیر وابسته (ROP) می‌باشد. متغیرهای ورودی شامل عمق (ft)، قطر مته (in)، میزان فرسایش مته (%)، هیدرولیک مته حفاری (lbf)، سرعت چرخش مته (rpm)، وزن روی مته (klbf)، وزن روی قلاب (klbf)، گشتاور (lbf.ft)، فشار منفذی سازند (ppg)، چگالی گل در حال گردش (ppg) و ساعات کار مته (hr) هستند. از تمام این متغیرها برای توسعه مدل‌های مبتنی بر آموزش ماشین

جدول ۱- مشخصات متغیرهای موجود در مجموعه داده مدلسازی و آزمایش مدل‌ها (۱۱۱۳ نقطه داده)

پارامتر	واحد	حد اقل	حد اکثر	میانگین
عمق	ft	۵۲۸،۵۵۹	۵۰۷۵،۴۵۹	۳۱۳۳،۰۱۴
قطر مته	in	۱۲،۲۵	۱۲،۲۵	۱۲،۲۵
میزان فرسایش مته	%	۰	۰،۶۵	۰،۴۸۲
هیدرولیک حفاری	lbf	۶۸۷،۴۹۶	۲۱۳۶،۹۲۴	۱۶۹۳،۲۷۷
سرعت دوران مته	rpm	۸۷،۳۱۹	۲۰۹،۸۰۷	۱۷۶،۵۳۱
وزن روی مته	klbf	۵،۰۲۵	۳۰،۶۹۵	۱۴،۳۲۵
وزن روی قلاب	klbf	۸۵،۴۷۸	۱۷۹،۷۰۹	۱۴۷،۳۲۰
گشتاور	lbf.ft	۱۴۲۵۰،۰۶۳	۵۵۰۷۹،۰۹۱	۳۶۳۵۰،۹۱۵
فشار منفذی سازند	ppg	۷،۶۹	۱۶،۳۲۵	۹،۳۲۸
چگالی گل حفاری	ppg	۷،۸۱۵	۱۸،۶۰۲	۱۵،۷۰۱
ساعات کار مته	hr	۱۶۰	۲۷۲	۲۲۴،۱۹۲
نرخ نفوذ حفاری	ft/hr	۷،۰۱۶	۴۱،۶۸۴	۲۱،۱۵۷

جدول ۲- مشخصات متغیرهای موجود در مجموعه داده اعتبار سنجی (۳۶۲ نقطه داده)

پارامتر	واحد	حد اقل	حد اکثر	میانگین
عمق	ft	۴۱۰،۱۳۸	۴۸۹۵،۱۲۵	۲۶۱۷،۵۸۹
قطر مته	in	۱۲،۲۵	۱۲،۲۵	۱۲،۲۵
میزان فرسایش مته	%	۰	۰،۷۵۱	۰،۵۶۲
هیدرولیک حفاری	lbf	۵۴۲،۱۳۵	۲۰۳۱،۲۶۹	۱۷۸۱،۸۶۲
سرعت دوران مته	rpm	۸۱،۳۲۶	۱۹۶،۷۱۷	۱۷۷،۳۴۳
وزن روی مته	klbf	۳،۱۳۳	۳۳،۱۳۵	۱۶،۸۶۸
وزن روی قلاب	klbf	۷۹،۳۲۶	۱۸۷،۶۹۷	۱۴۲،۳۵۷
گشتاور	lbf.ft	۱۳۱۰۰،۲۹۴	۵۷۳۲۵،۲۷۷	۳۴۸۶۴،۹۳۶
فشار منفذی سازند	ppg	۷،۶۹	۱۶،۳۲۵	۹،۳۲۸
چگالی گل حفاری	ppg	۸،۴۵۶	۱۸،۰۲۳	۱۶،۱۲۶
ساعات کار مته	hr	۱۴۸	۲۵۴	۱۹۵،۶۲۳
نرخ نفوذ حفاری	ft/hr	۵،۱۵۵	۴۵،۱۵۸	۲۲،۷۸۹

۲-۵- توسعه مدل های ریاضی

برازش یا منطبق کردن مدل های ریاضی بر روی داده های میدانی بوسیله تنظیم ثوابت این مدل ها صورت می گیرد. تنظیم این ثوابت، از طریق روش هایی مانند تجزیه و تحلیل رگرسیون چندگانه و یا الگوریتم های فرا ابتکاری قابل انجام است. ایده استفاده از آنالیز رگرسیون برای تعیین ثوابت مدل های حفاری، نخستین بار توسط گراهام و مونچ [۳۷]، مطرح گردید. همچنین بورگوان و یانگ [۸]، روش رگرسیون چندگانه را برای تعیین ثوابت نامشخص مدل خود پیشنهاد کردند. ثابت شده که استفاده از روش رگرسیون چندگانه برای محاسبه ثوابت مدل، منجر به تولید مقادیر خارج از محدوده شده و در نهایت دستیابی به مقادیر بهینه را تضمین نمی کند. از سوی دیگر، در صورتی که ثوابت بدست آمده از این روش در مدلها لحاظ شوند، منجر به تولید مقادیری با روند خطی و با خطای بسیار بالا می گردد [۱۲].

جدول ۳- پارامترهای تنظیمی الگوریتم های WOA و ACO برای بهینه سازی شبکه های عصبی MLP

الگوریتم	پارامتر	مقدار
ACO	سایز آرشیو	۸۰
	فشار انتخاب	۰.۶
	نرخ انحراف	۱
	جمعیت	۸۰
	تعداد تکرار	۵۰۰
WOA	p	۰.۵۲
	l	۰.۳۵
	جمعیت	۵۰
	تعداد تکرار	۵۰۰

به دلیل ناهمگن بودن سازندهای حفاری شده، استفاده از ثوابت یکسان برای کل چاه امکانپذیر نیست. بنابراین می-بایست بازه هایی از چاه را که دارای سازندهای تقریباً یکسان می باشند، جداگانه مدلسازی نمود [۱۲ و ۳۸]. بر اساس مطالعه پیشینه تحقیق، برای هشت ثابت مدل BYM بازه هایی مطابق با جدول ۴ ارائه شده که از طریق آنها میتوان همگرایی الگوریتم و دستیابی به نتایج قابل اطمینان از مدل را تضمین نمود. به منظور محاسبه ثوابت میدانی مدل BYM و ارزیابی دقت مدل با استفاده از این ثوابت، داده های چاه اول و دوم به دو زیر مجموعه داده های آموزش

همچنین به منظور بهبود کارایی شبکه و حذف تأثیر ابعاد پارامترهای ورودی بر نتایج، لازم است تا هر یک از ورودی ها در بازه ای مشخص نرمال شوند. از رابطه (۲۶)، به منظور نرمال سازی داده ها در بازه ۰ و ۱ استفاده می شود.

$$x_i = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (26)$$

که در این رابطه، x_i مقدار نرمال شده، X مقدار واقعی، X_{min} کمترین مقدار و X_{max} بیشترین مقدار از پارامتر مورد نظر می باشد [۳۶].

۵- مدلسازی و تخمین نرخ نفوذ

۱-۵- توسعه مدل شبکه های عصبی

داده های جمع آوری شده از سه چاه مورد مطالعه، پس از پیش پردازش به منظور حذف نقاط دور افتاده و کاهش نویز، به طور تصادفی به دو زیر مجموعه آموزش (۷۰ درصد) و مجموعه آزمایش (۳۰ درصد) تقسیم شدند. از مجموعه داده های آموزش با ۷۷۸ نقطه داده برای توسعه مدلها و از مجموعه داده آزمایش با ۳۳۵ نقطه داده برای ارزیابی عملکرد تقریب مدلها استفاده گردید.

تعداد بهینه لایه های پنهان، نورون ها و نوع تابع فعال سازی نیز با یک رویکرد سعی و خطی و بر اساس میزان خطای آموزش و آزمایش مدل تعیین گردید تا از بوجود آمدن بیش برازش^۱ جلوگیری به عمل آید. پس از بررسی ساختارهای مختلف، در نهایت یک ساختار سه لایه ای متشکل از یک لایه ورودی، یک لایه پنهان با ۱۸ نورون حاوی تابع فعال ساز سیگموئید و یک لایه پایانی با تابع خطی (Purelin)، مطلوبترین عملکرد را در بخش آموزش و آزمایش مدل MLPNN نمایش داد. پس از پایه ریزی مناسب ترین ساختار شبکه های عصبی در نرم افزار متلب، با استفاده از سه الگوریتم WOA، ACO و BP شبکه آموزش داده شد. در جدول ۳، مقادیر تنظیمی دو الگوریتم فراابتکاری WOA و ACO برای بهینه سازی شبکه های عصبی MLP ارائه شده است. لازم به ذکر است که الگوریتم BP نیز بر اساس تنظیمات پیش فرض نرم افزار متلب با تابع لونیبرگ مارکواردت ("trainlm") و تعداد تکرار ۲۰۰ عدد در نظر گرفته شده است. در شکل (۳)، فلوچارت نحوه توسعه مدل های مورد مطالعه، به طور خلاصه شرح داده شده است.

^۱ Over-fitting

جدول ۵ ارائه شده است.

جدول ۵- پارامترهای تنظیمی الگوریتم WOA و ACO برای بهینه‌سازی مدل‌های ریاضی نرخ نفوذ

الگوریتم	پارامتر	مقدار
ACO	سایز آرشیو	۶۰
	فشار انتخاب	۰,۵
	نرخ انحراف	۱
	تعداد تکرار	۲۰۰
	جمعیت	۸۰
WOA	p	۰,۶۸
	l	۰,۳۵
	تعداد تکرار	۲۰۰
	جمعیت	۸۰

پس از محاسبه ثوابت مدل BYM بوسیله هر یک از الگوریتم‌های مورد مطالعه و مجموعه داده آموزش، از این ثوابت برای تخمین نرخ نفوذ در مجموعه داده‌های آزمون استفاده گردید. در نهایت مدل بهینه تولید شده، بوسیله مجموعه داده اعتبارسنجی (چهار شماره ۳) مورد ارزیابی قرار گرفت. در شکل (۳)، فلوجارت فریند مدلسازی و تخمین نرخ نفوذ بوسیله ترکیب مدل BYM با دو الگوریتم فرا ابتکاری مذکور نمایش داده شده است. همچنین در جدول ۶، ثوابت محاسبه شده توسط هر الگوریتم گزارش شده است. لازم به ذکر است که فرایند برنامه نویسی این روشها، در نرم افزار متلب نسخه ۲۰۱۸ انجام شده است.

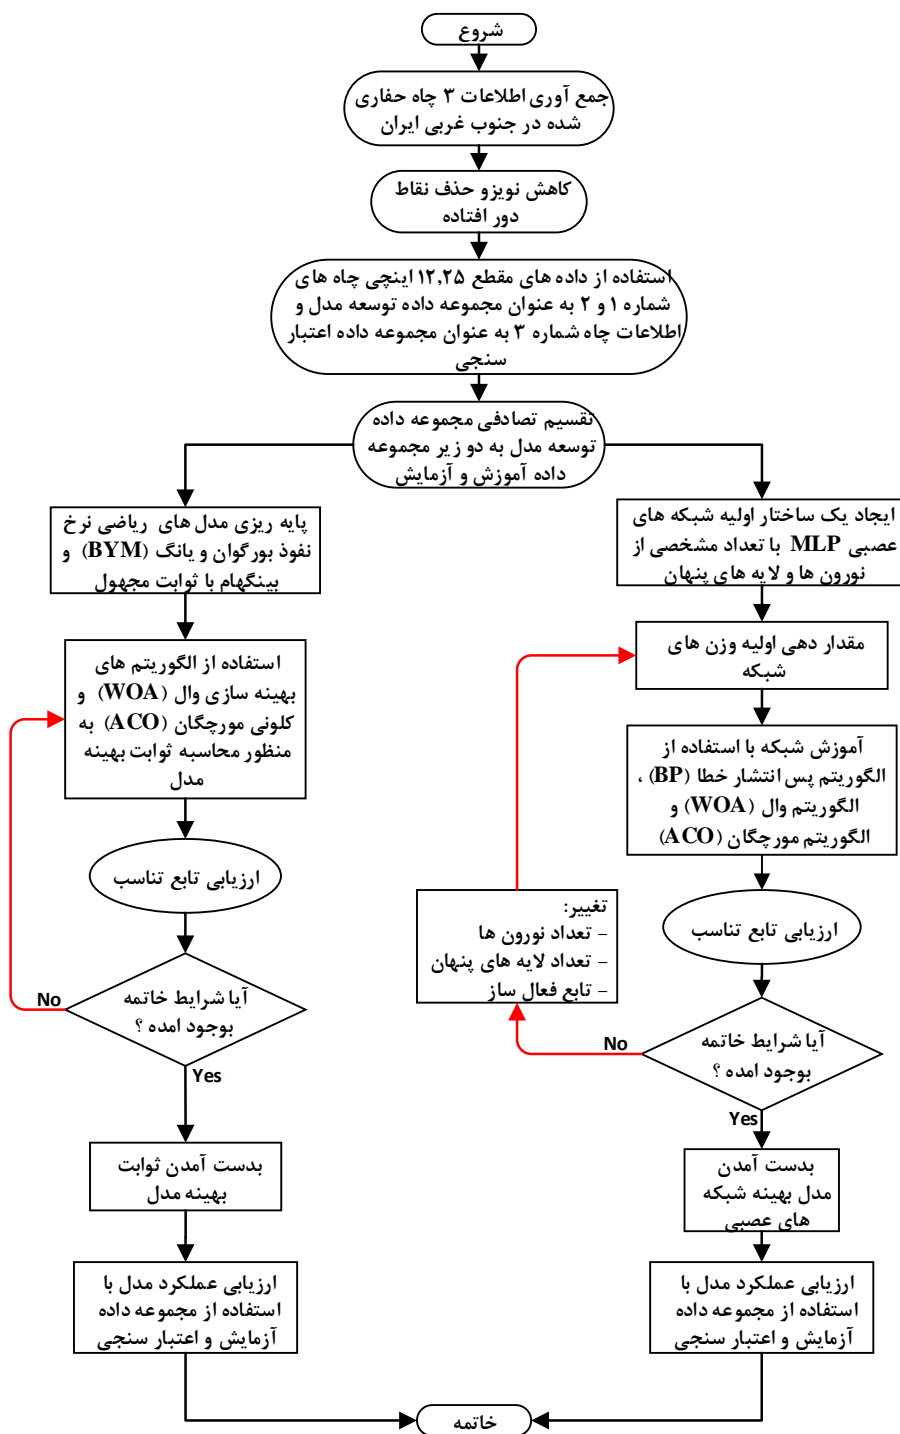
بر اساس نتایج بدست آمده در جدول ۶، مشاهده می‌شود که هر دو الگوریتم توانسته‌اند ثوابت مدل BYM را مطابق با بازه‌های ارائه شده در جدول ۴، بدست آورند. با این حال تصادفی سازی و ایجاد تنوع در پاسخهای مسئله، یکی از مشخصه‌های اصلی الگوریتم‌های فرا ابتکاری می‌باشد که ممکن است سبب محاسبه برخی ثوابت در خارج از محدوده تعیین شده شود. مشابه مدل نرخ نفوذ بورگوان و یانگ، از دو الگوریتم ACO و WOA برای محاسبه ثوابت بهینه مدل بینگهام نیز استفاده شد و تنظیمات الگوریتم‌ها مشابه بخش پیشین لحاظ گردید. پس از ۲۰۰ تکرار، مقادیر بهینه ثوابت مدل بینگهام محاسبه شدند که این مقادیر در جدول ۷ ارائه شده است. پس از محاسبه ثوابت بهینه مدل بینگهام با استفاده از دو الگوریتم ACO و WOA، از مدل‌های تولید شده برای تخمین نرخ نفوذ در مجموعه داده‌های آزمایش و اعتبارسنجی استفاده گردید.

با ۷۰ درصد و داده‌های آزمون با ۳۰ درصد تقسیم شدند. بر این اساس می‌توان مدل BYM را در یک مرحله بر روی داده‌ها منطبق کرد و در گام بعد بوسیله داده‌هایی که در بخش قبل استفاده نشده‌اند، مورد ارزیابی قرار داد.

جدول ۴- بازه‌های ثوابت مدل بورگوان و یانگ [۱۲]

ثابت مدل	حد اقل	حد اکثر
a_1	۰,۵	۱,۹
a_2	۰,۰۰۰۰۱	۰,۰۰۰۰۵
a_3	۰,۰۰۰۰۱	۰,۰۰۰۰۹
a_4	۰,۰۰۰۰۱	۰,۰۰۰۰۱
a_5	۰,۵	۲
a_6	۰,۴	۱
a_7	۰,۳	۱,۵
a_8	۰,۳	۰,۶

در این مطالعه، از دو الگوریتم کلونی مورچگان (ACO) و الگوریتم وال (WOA) برای یافتن ثوابت مدل BYM استفاده گردید. در فرایند آموزش مدلها بوسیله الگوریتم‌های جمعیت‌مهور، تلاش می‌گردد تا در هر تکرار از الگوریتم ثوابت مدل به گونه‌ای تنظیم شوند که مقدار خطای تقریب به حداقل برسد. بر همین اساس، ابتدا جمعیت هر نسل از الگوریتم به صورت تصادفی در بازه‌های مشخصی مقداردهی اولیه می‌شوند و نرخ خطا با استفاده از داده‌های آموزشی محاسبه می‌گردد. در ادامه، ثوابت مدل یا مشخصه‌های تنظیمی اثر گذار بر نگاشت داده‌های ورودی به روز رسانی می‌شوند و این فرآیند تا زمانی ادامه می‌یابد که شرایط خاتمه حاصل شود و یا حداقل خطای مجاز بدست آید [۳۹]. در حقیقت برای منطبق کردن مدل بر روی داده‌های میدانی، ثوابت مدل به عنوان ابعاد هر یک از اعضای جمعیت در نظر گرفته می‌شوند تا سپس با در نظر گرفتن خطای تقریب (MSE) به عنوان تابع هدف، الگوریتم ثوابت مذکور را به گونه‌ای تغییر دهد که کمترین مقدار خطا حاصل شود [۴۰]. یکی از مهمترین اقدامات مهم در استفاده از الگوریتم‌های فرا ابتکاری، تنظیم پارامترهای الگوریتم می‌باشد. بنابراین لازم است تا بر اساس پیچیدگی و ابعاد مسئله، مقادیر مناسبی برای این پارامترها تعیین شود تا الگوریتم به صورت کار آمد پاسخ بهینه مسئله مورد نظر را پیدا کند [۴۱]. همچنین می‌توان مقادیر این پارامترها را بر اساس پیشینه تحقیق تعیین نمود [۴۲]. مقادیر در نظر گرفته شده برای این پارامترهای تنظیمی در



شکل ۳- فلوچارت مدلسازی و تخمین نرخ نفوذ حفاری بوسیله روشهای مود مطالعه

۶- بحث و بررسی نتایج

مهمترین مواردی که بهره‌گیری از الگوریتم ACO را در این مطالعه دو چندان کرده است، کشف سریع جوابهای مناسب، عدم همگرایی زودرس الگوریتم به یک بهینه محلی و کشف جوابهای قابل قبول در مراحل اولیه جستجو می‌باشد [۳۱]. الگوریتم WOA نیز از آن جهت در این مطالعه مورد توجه قرار گرفت که دارای توانایی یافتن راه حل بهینه در محدوده فضای جستجو بوده و با بهره‌گیری

مسئله تخمین نرخ نفوذ، یکی از موضوعات مهم برای بهینه سازی فرایند حفاری می‌باشد که طیف وسیعی از محققین را در این حوزه به چالش کشیده است. در این مطالعه تلاش گردید تا از طریق داده‌های واحد نمودارگیری گل و بهره‌گیری از مدل‌های ریاضی و مدل‌های مبتنی بر آموزش ماشین، به تخمین این فاکتور کلیدی پرداخته شود. از جمله

$$R^2 = 1 - \frac{\sum_{i=1}^n \left((ROP)_{field} - (ROP)_{predict} \right)^2}{\sum_{i=1}^n \left((ROP)_{field} - \left(\frac{1}{n} \sum_{i=1}^n (ROP)_{field} \right) \right)^2} \quad (29)$$

نتایج بدست آمده از این ارزیابی برای سه بخش آموزش، آزمون و اعتبار سنجی، در جدول ۸ گزارش شده است.

جدول ۸- جزئیات آماری نتایج بدست آمده از مدل‌های توسعه داده شده در این مطالعه

روش‌ها	مجموعه داده	MSE	R ²	AAPRE
WOA-MLPNN	آموزش	۱,۴۴۰	۰,۹۷۶	۳,۱۹۷
	آزمون	۱,۹۶۵	۰,۹۵۶	۵,۴۸۲
	اعتبار سنجی	۵,۳۴۵	۰,۸۷۳	۹,۳۱۰
ACO-MLPNN	آموزش	۴,۸۸۱	۰,۹۱۸	۷,۵۵۸
	آزمون	۴,۵۶۷	۰,۸۹۶	۷,۵۴۰
	اعتبار سنجی	۹,۲۰۵	۰,۸۴۷	۱۰,۹۳۲
BP-MLPNN	آموزش	۶,۱۱۵	۰,۸۹۹	۸,۳۷۱
	آزمون	۶,۰۲۲	۰,۸۶۶	۹,۰۳۷
	اعتبار سنجی	۱۰,۸۶۴	۰,۸۲۲	۱۳,۱۱۴
WOA-BYM	آموزش	۲۴,۶۱۴	۰,۵۸۶	۲۰,۴۷۱
	آزمون	۱۹,۹۹۵	۰,۵۵۰	۱۸,۵۱۶
	اعتبار سنجی	۳۱,۱۳۴	۰,۴۸۸	۲۳,۴۷۲
ACO-BYM	آموزش	۲۸,۲۷۰	۰,۵۲۰	۲۱,۹۰۶
	آزمون	۲۱,۹۲۰	۰,۵۰۷	۱۹,۲۳۰
	اعتبار سنجی	۳۸,۱۲۵	۰,۴۲۶	۲۴,۸۶۴
WOA-Bingham	آموزش	۳۵,۵۵	۰,۴۰۱	۲۵,۰۲۹
	آزمون	۲۷,۸۱۲	۰,۳۷۷	۲۲,۱۴۹
	اعتبار سنجی	۴۶,۲۸۷	۰,۲۹۵	۲۵,۲۸۳
ACO-Bingham	آموزش	۳۹,۲۹۸	۰,۴۰۰	۲۴,۹۶۸
	آزمون	۳۴,۲۳۷	۰,۳۵۳	۲۲,۷۶۱
	اعتبار سنجی	۴۵,۶۱۳	۰,۳۲۰	۲۳,۹۸۱

هرچه مقادیر AAPRE و RMSE برای یک مدل کوچک‌تر باشند، می‌توان اینگونه استنباط کرد که مدل مورد نظر دارای دقت بالاتری در تقریب می‌باشد. مقادیر AAPRE یک مقدار مطلق از APRE را محاسبه کرده که از طریق آن می‌توان عملکرد مدل را به خوبی آنالیز کرد. همچنین از

از تکنیک انطباقی در جهت همگرایی سریع و دارا بودن رفتار تصادفی برای بهبود راه حل‌های مسئله، حل مسائل چالش بر انگیز و دارای فضای جستجوی ناشناخته را با عملکرد قابل قبولی تضمین می‌نماید [۴۳].

جدول ۶- ثوابت بهینه محاسبه شده مدل بورگوان و یانگ (BYM) با استفاده از الگوریتم‌های WOA و ACO

ثوابت	مقدار	
	WOA- BYM	ACO- BYM
a _۱	۰,۰۷۳	۰,۳۷۶
a _۲	۰,۰۰۰۱۴۶	۰,۰۰۰۱۲۱
a _۳	۰,۰۰۰۱۵۲	۱,۵۱۸ × 10 ⁻⁵
a _۴	-2,764 × 10 ⁻⁵	-۹,۸۴۱ × 10 ⁻⁵
a _۵	-۰,۲۰۱	-۰,۱۷۳
a _۶	۰,۰۴۳	-۰,۵۷۷
a _۷	-۰,۲۶۳	۳,۰۰۷
a _۸	-۰,۴۲۴	۰,۳۹۲

جدول ۷- ثوابت بهینه محاسبه شده مدل بینگهام با استفاده از الگوریتم‌های WOA و ACO

ثوابت	مقدار	
	WOA- BYM	ACO- BYM
a	۰,۱۲۶	۰,۱۱۸
k	-۰,۰۱۲۸	-۰,۰۱۳۵

نتایج حاصل شده از مدل‌ها در غالب شاخص‌های آماری و ابزارهای گرافیکی که در ادامه این بخش ارائه می‌شوند نیز خود گویای عملکرد بسیار قابل قبول این دو الگوریتم می‌باشند. همچنین در بخش بعد، عملکرد تقریب هر یک از مدل‌های توسعه داده شده در این مطالعه، با روش‌های جدید ارائه شده در سایر مطالعات مقایسه شده است تا بتوان به یک دید کلی نسبت به نتایج دست یافت.

به منظور تجزیه و تحلیل خطای مدل‌ها، از سه معیار آماری حد اقل مربعات خطا (MSE)، درصد میانگین مطلق خطای نسبی (AAPRE) و ضریب تعیین (R²) استفاده گردید. این معیارهای آماری، به صورت روابط (۲۷) تا (۲۹) تعریف شده اند.

$$MSE = \frac{1}{n} \sum_{i=1}^n \left((ROP)_{field} - (ROP)_{predict} \right)^2 \quad (27)$$

$$AAPRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(ROP)_{field} - (ROP)_{predict}}{(ROP)_{field}} \right| \times 100 \quad (28)$$

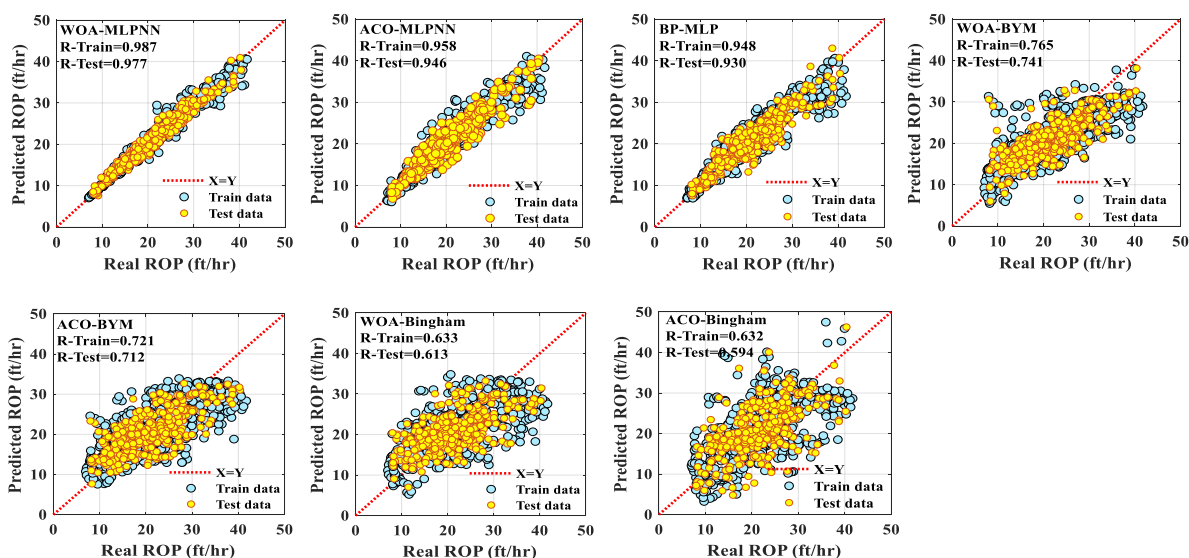
و ACO را در بهینه‌سازی مدل شبکه‌های عصبی MLP و دو مدل ریاضی، نمایش می‌دهد. در ادامه به منظور مقایسه میان مدل‌ها در یک نگاه کلی‌تر، در شکل (۹) مقادیر AAPRE محاسبه شده از مدلها، برای سه مجموعه داده آموزش، آزمون و اعتبار سنجی با یکدیگر مقایسه گردید. AAPRE یک شاخص بسیار مهم می‌باشد که از طریق آن

میتوان عملکرد مدل‌ها را به خوبی ارزیابی کرد [۴۴]. بر اساس نتایج بدست آمده ثابت گردید که مدل‌های آموزش ماشین عملکرد مناسبتری را در تخمین ROP در مقایسه با مدل‌های پیشین ریاضی ارائه می‌کنند. با این حال روش شبکه عصبی بهینه شده با الگوریتم وال (WOA-MLPNN)، بالاترین دقت را با مقادیر AAPRE برابر ۵,۴۸۲ و ۹,۳۱۰ به ترتیب برای دو بخش آزمایش و اعتبار سنجی میدانی ارائه کرده است. همچنین، روش ACO-Binham، ضعیف‌ترین نتایج را در دو بخش آزمایش و اعتبار سنجی میدانی با مقادیر AAPRE برابر ۲۲,۷۶۱ و ۲۳,۹۸۱ نمایش داد. دلیل دقت پایین مدل‌های ریاضی را میتوان به فرض کردن تأثیر خطی برخی متغیرهای ورودی بر ROP مرتبط دانست. از طرف دیگر، مدل‌های ریاضی، چاه را در یک شرایط تمیز سازی ثابت در نظر می‌گیرند که این مسئله می‌تواند در سرعت‌های بالای حفاری سبب ایجاد خطا در تقریب ROP شود. بنابر این میتوان اذعان داشت که مدل‌های ریاضی نرخ نفوذ را در محدوده‌هایی به خوبی تخمین می‌زنند که دخالت سایر عوامل کاهش دهنده نرخ نفوذ هنوز شدت نیافته است.

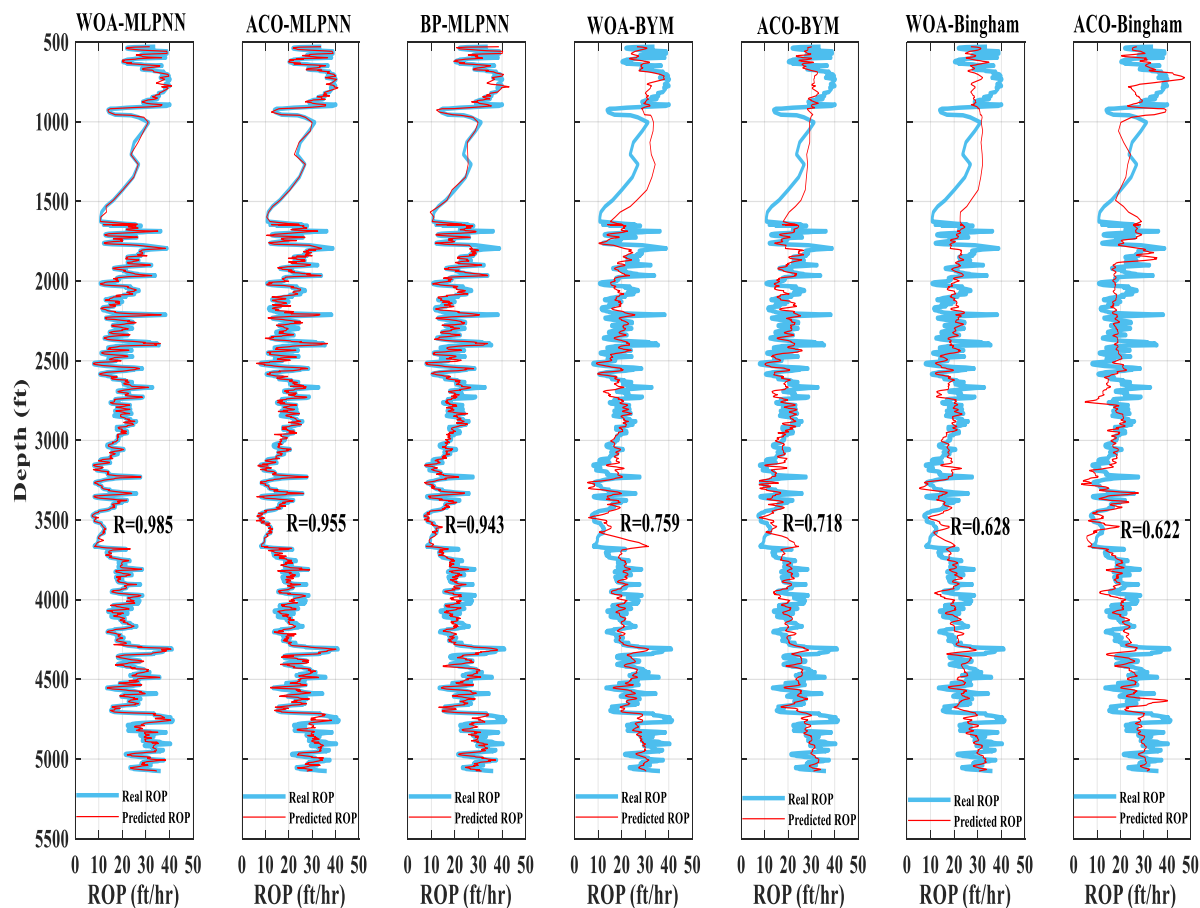
طریق R^2 ، میتوان مشخص نمود که چند درصد از خروجی‌های مدل توسط خط برازش شده بر روی نقاط قابل تعریف هستند و هر چه این شاخص به مقدار یک نزدیک‌تر باشد، بازگو کننده این است که مدل عملکرد خوبی در تقریب دارا می‌باشد. شکل (۴)، برازش منحنی مقادیر واقعی نرخ نفوذ در مقابل مقادیر خروجی از مدلها را برای دو بخش آموزش و آزمون نمایش می‌دهد و شکل (۵) نیز، نشان دهنده مقایسه میان مقادیر واقعی نرخ نفوذ و مقادیر خروجی از مدلها برای مجموعه داده کل می‌باشد.

پس از توسعه مدل‌های مبتنی بر آموزش ماشین و مدل‌های ریاضی، از آنها برای تقریب نرخ نفوذ بوسیله مجموعه داده اعتبار سنجی استفاده گردید. اعتبار سنجی مدل‌ها، این امکان را به ما می‌دهد تا مدل‌های توسعه داده شده را به صورت میدانی و بوسیله داده‌های یک چاه دیگر مورد ارزیابی قرار دهیم تا به یک قطعیت در خصوص عملکرد صحیح مدلها دست پیدا نماییم. شکل (۶)، نشان دهنده مقادیر واقعی نرخ نفوذ در مقابل مقادیل تخمین زده شده توسط مدلها می‌باشد و شکل (۷)، مقایسه مقادیر نرخ نفوذ واقعی با مقادیر تخمین زده شده برای بخش اعتبار سنجی مدل را نمایش می‌دهد.

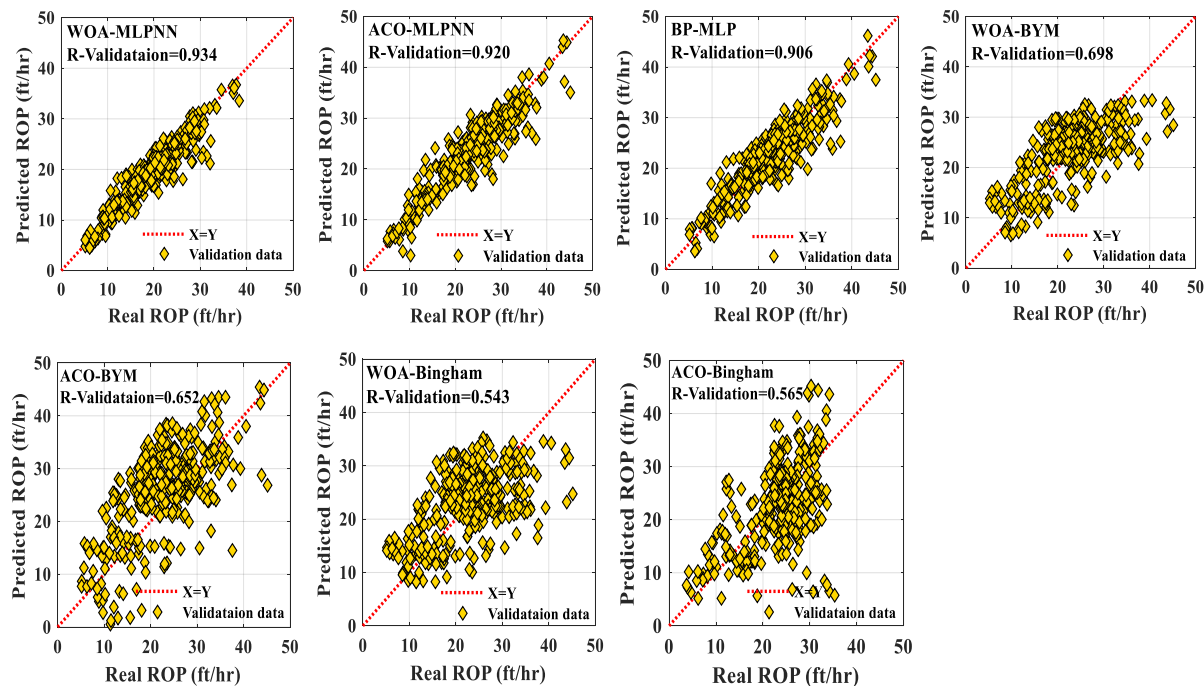
همچنین، یکی دیگر از نمودارهای مناسب به منظور بررسی عملکرد الگوریتم‌های بهینه‌ساز، نمودار مقادیر خطا در مقابل تعداد تکرار می‌باشد که از طریق آن می‌توان نحوه عملکرد مدل را در همگرایی به یک مقدار بهینه مورد بررسی قرار داد. شکل (۸)، همگرایی الگوریتم‌های WOA



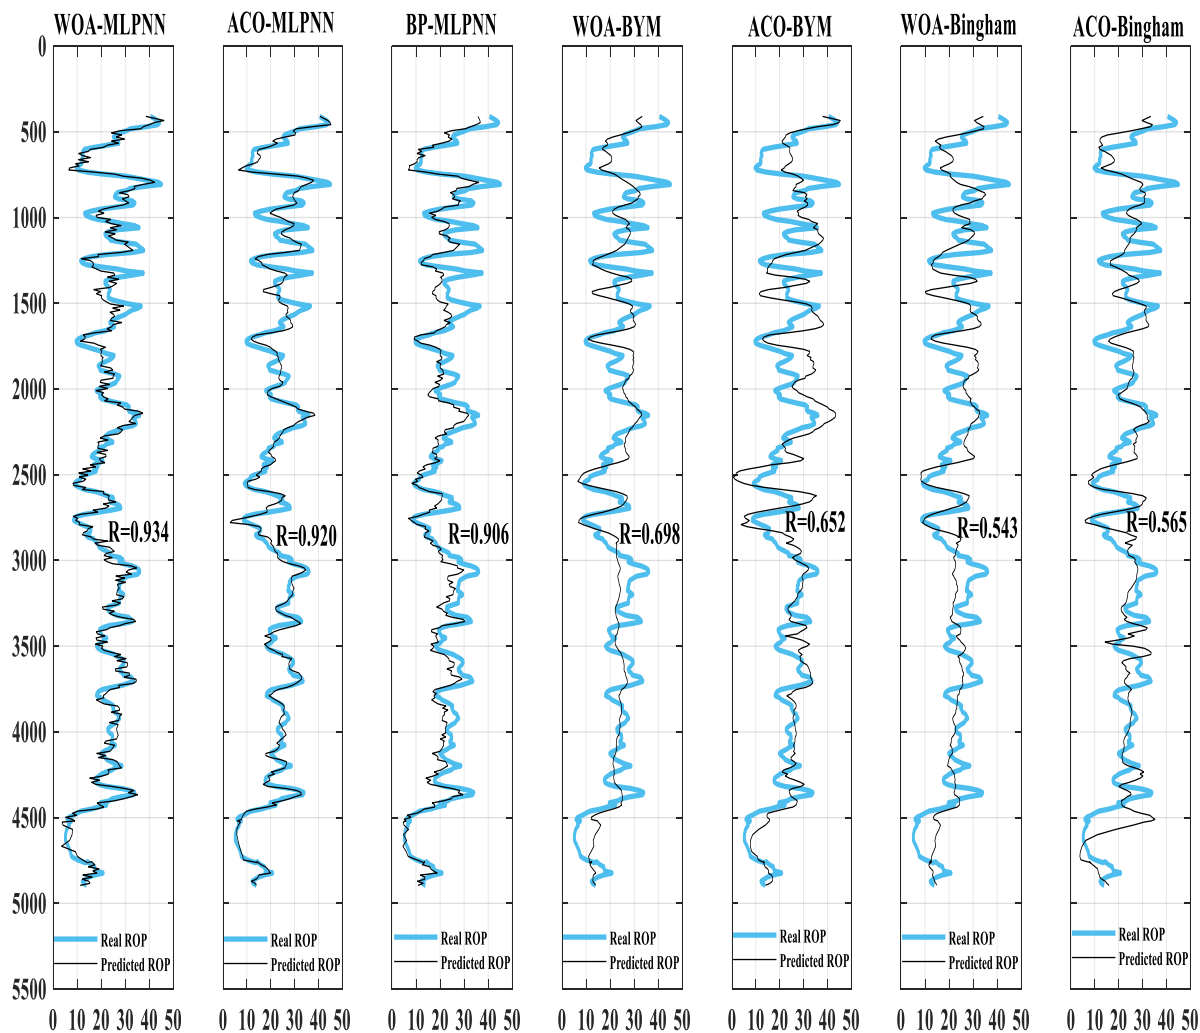
شکل ۴- نمایش همبستگی میان نرخ نفوذ واقعی و نرخ نفوذ پیش‌بینی شده برای مجموعه داده‌های آموزش (۷۷۸ نقطه داده) و آزمایش (۳۳۵ نقطه داده)



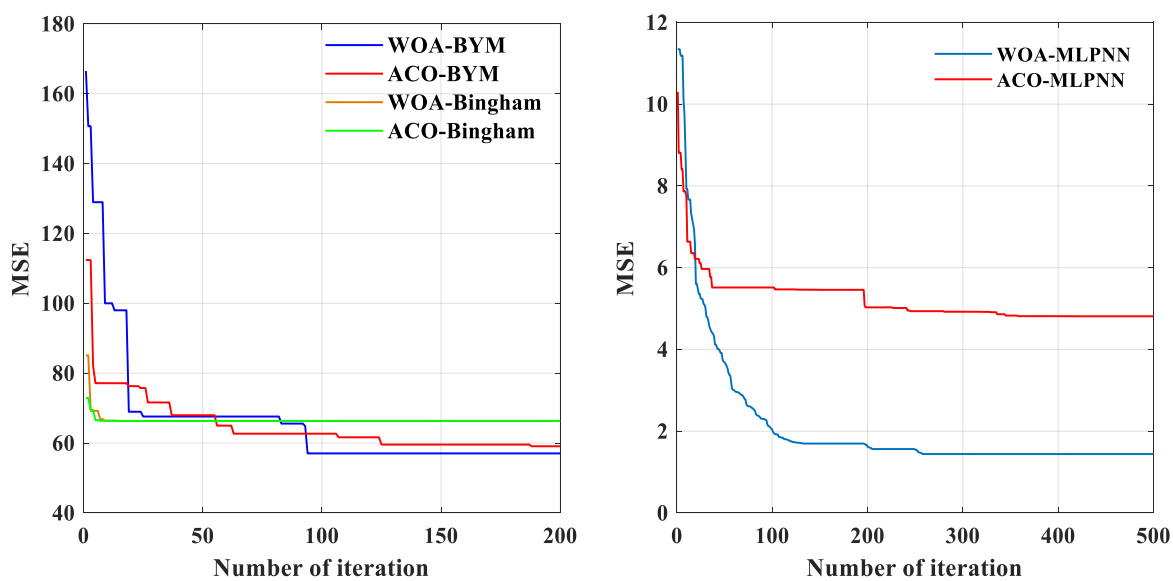
شکل ۵- مقایسه نرخ نفوذ واقعی و نرخ نفوذ پیش‌بینی شده توسط مدل‌های توسعه داده شده در این مطالعه برای مجموعه داده کل (۱۱۱۳ نقطه داده)




شکل ۶- نمایش همبستگی میان نرخ نفوذ واقعی و نرخ نفوذ پیش‌بینی شده برای مجموعه داده اعتبار سنجی (۳۶۲ نقطه داده)



شکل ۷- مقایسه نرخ نفوذ واقعی و نرخ نفوذ پیش بینی شده توسط مدل های توسعه داده شده در این مطالعه برای مجموعه داده اعتبار سنجی (۳۶۲ نقطه داده)



شکل ۸- مقایسه همگرایی الگوریتم های WOA و ACO در بهینه سازی مدل های مورد مطالعه



شکل ۹- مقایسه مقدار میانگین درصد نسبی خطای مطلق (AAPRE) مدل‌های توسعه داده شده در این مطالعه

۷- مقایسه دقت مدلها با روش‌های جدید ارائه شده در سایر مطالعات

هدف از ارائه این بخش، مقایسه عملکرد مدل‌های توسعه داده شده در این مطالعه با روش‌های مورد استفاده در سایر مطالعات می‌باشد، تا از این طریق بتوان دقت عملکرد تقریب هر یک از مدلها را در سطح گسترده‌تری مورد ارزیابی قرار داد و به یک نتیجه‌گیری کاملتر دست یافت. برای این منظور، نخست اطلاعات قابل مقایسه نظیر تعداد نقاط داده استفاده شده، تعداد متغیرهای ورودی و ضریب همبستگی مدل‌های به کار رفته از جدیدترین مطالعات منتشر شده با موضوع تخمین نرخ نفوذ حفاری استخراج گردید و در ادامه مورد ارزیابی قرار گرفت. این اطلاعات برای مراجع مورد بررسی به طور خلاصه در جدول ۹، لیست شده‌اند.

بر اساس اطلاعات جدول ۹، دو مدل WOA-ELM و PSO-ELM ارائه شده توسط یوسفی و همکاران [۱۴]، بیشترین دقت تقریب نرخ نفوذ حفاری را با ضریب همبستگی ۰,۹۹۳ ارائه کرده‌اند. همچنین، مدل SVM ارائه شده توسط احمد و همکاران [۱۵]، از جمله دقیق ترین مدلها با ضریب همبستگی ۰,۹۸۰ می‌باشد، که رتبه سوم را در این مقایسه به دست آورده است. ضعیف‌ترین نتایج نیز مربوط به روش Simple-RBF ارائه شده توسط اشرفی و همکاران (۲۰۱۹) [۱۸]، با ضریب همبستگی ۰,۶۵۷ می‌باشد. لازم به ذکر است که تعداد نقاط داده مورد استفاده، برای افزایش درجه اطمینان نتایج حاصل شده


بسیار حائز اهمیت می‌باشد. بر این اساس می‌توان اذعان داشت که در مطالعه یوسفی و همکاران [۱۴]، علاوه بر دستیابی به دقت قابل قبول، از تعداد نقاط داده قابل قبولی برای توسعه مدلها استفاده شده است. در ادامه با شرکت دادن روش‌های توسعه داده شده در این مطالعه می‌توان نتیجه‌گیری کرد که مدل WOA-MLPNN با اختلاف بسیار ناچیزی نسبت به سه روش برتر ذکر شده، رتبه چهارم را در این مقایسه با ضریب همبستگی ۰,۹۵۶ به دست می‌آورد که نشان دهنده عملکرد و جایگاه مناسب این مدل می‌باشد. همچنین، در این مطالعه اعتبار سنجی میدانی مدلها توسط یک مجموعه داده متفاوت انجام گردید تا به اطمینان بیشتری از نتایج دست یافت. این در حالی است که در بسیاری از مطالعات انجام شده در پیشینه تحقیق اعتبار سنجی میدانی مدلها چندان مورد توجه قرار نگرفته است. در شکل (۱۰)، ضریب همبستگی مدل‌های توسعه داده شده در این مطالعه و مدل‌های ارائه شده در سایر مقالات با یکدیگر مقایسه شده‌اند تا از این طریق بتوان به یک دید کلی از دقت و عملکرد مدلها دست یافت. بررسی‌های دقیق-تر در این بخش از مطالعه نشان داد که استفاده از الگوریتم‌های فرا ابتکاری در ترکیب با مدل‌های آموزش ماشین می‌تواند عملکرد رضایت بخش‌تری را در مقایسه با روش‌های مرسوم ریاضی ارائه نماید. با توجه به مزیت‌های دو الگوریتم WOA و ACO که در بخش پیشین به برخی از آنها اشاره گردید و همچنین نتایج مطلوب بدست آمده از الگوریتم

توجه قرار نگرفته است. از این رو استفاده از این الگوریتم‌ها به منظور توسعه مدل‌های تخمین‌گر نرخ نفوذ و مقایسه آنها با سایر روش‌های استفاده شده در ادبیات تحقیق دارای نتایج ارزشمندی می‌باشد که در این مطالعه به منظور دستیابی به آنها تلاش گردید.

WOA در مطالعه یوسفی و همکاران [۱۴]، می‌توان ترکیب آنها را با سایر روش‌های آموزش ماشینی و مدل‌های ریاضی تأیید نمود. از سوی دیگر، ترکیب الگوریتم‌های WOA و ACO با مدل MLPNN و سایر مدل‌های ریاضی در جهت تخمین نرخ نفوذ حفاری تا کنون در مطالعات پیشین مورد

جدول ۹- مشخصات روش‌های مورد استفاده در سایر مقالات

تعداد ورودی های مدل	تعداد نقاط داده	ضریب همبستگی مدل	روش	مرجع
۱۰	۴۰۰	۰٫۹۵۶	SVM	احمد و همکاران (۲۰۱۸) [۱۵]
۲۴	۱۲۳۵۵	۰٫۸۸۰	BP-ANN	عباس و همکاران (۲۰۱۸) [۳]
۵	۱۱۹۰۰	۰٫۹۲	BP-ANN	عبد الجبار و همکاران (۲۰۲۰) [۱۶]
۵	۶۲۵	۰٫۹۲۱	PSO-MLP	انه منگلی و همکاران (۲۰۱۸) [۴۵]
		۰٫۷۶۹	PSO-MLP	
۸	۱۰۰۰	۰٫۸۷۰	PSO-MLP	اشرفی و همکاران (۲۰۱۹) [۱۸]
		۰٫۷۹۷	GA-MLP	
		۰٫۷۲۲	ICA-MLP	
		۰٫۷۲۳	BBO-MLP	
		۰٫۶۸۸	Simple-MLP	
		۰٫۷۷۰	PSO-RBF	
		۰٫۷۷۷	GA-RBF	
		۰٫۷۳۹	ICA-RBF	
		۰٫۷۳۵	BBO-RBF	
		۰٫۶۵۷	Simple-RBF	
۵	۳۵۶۱	۰٫۹۹۳	WOA-ELM	یوسفی و همکاران (۲۰۲۰) [۱۴]
		۰٫۹۹۳	PSO-ELM	
۵	۵۰۴	۰٫۹۸۰	BP-ANFIS	ایوب و همکاران (۲۰۱۷) [۵]
۸	۴۸۷۴	۰٫۹۲۰	SaDE-ANN	الکاتانی و همکاران (۲۰۱۹) [۴۶]
۸	۳۱۸۰	۰٫۸۹۳	LM-ANN	ژاو و همکاران (۲۰۱۹) [۴۷]
		۰٫۸۴۶	SCG-ANN	
		۰٫۸۴۰	OSS-ANN	



شکل ۱۰- مقایسه میان مقادیر همبستگی مدل‌های نرخ نفوذ توسعه داده شده در این مطالعه و سایر مطالعات

۸- خلاصه و نتیجه گیری

بهینه‌سازی فرایند حفاری مستقیماً با افزایش نرخ نفوذ ارتباط دارد، چرا که می‌توان از این طریق سرعت حفاری را تا حد مجازی افزایش داده و در هزینه‌های مصرفی صرفه جویی نمود. بهینه‌سازی فرایند حفاری نیازمند درک ارتباط میان پارامترهای مختلف مؤثر بر فرایند حفاری می‌باشد، به طوری که تخمین هر چه بهتر فاکتور نرخ نفوذ می‌تواند برنامه‌ریزی بهتری را برای چاههای آینده به ارمغان آورد. در این مطالعه به منظور مدلسازی و تخمین نرخ نفوذ، از شبکه‌های عصبی بهینه شده با الگوریتم وال (WAO-MLPNN)، شبکه‌های عصبی بهینه شده با الگوریتم مورچگان (ACO-MLPNN)، شبکه‌های عصبی پس انتشار خطا (BP-MLPNN) و دو مدل ریاضی شامل مدل بورگوان و یانگ (BYM) و مدل بینگهام استفاده گردید. داده‌های مورد نیاز، از واحد نمودارگیری گل و گزارش نهایی ۳ چاه حفاری شده واقع در جنوب غربی ایران جمع آوری شده است. این داده‌ها پس از حذف نقاط خارج از محدوده و کاهش نویز، بر اساس قطر مته و نوع سازند طبقه بندی شده و در ادامه، از اطلاعات حفره ۱۲،۲۵ اینچی چاه‌های شماره ۱ و ۲ استفاده گردید تا مدلها توسعه و سپس ارزیابی شوند. در پایان مدل‌های توسعه داده شده توسط داده‌های یک چاه دیگر (چاه شماره ۳) مورد اعتبار سنجی قرار گرفتند. بررسی‌های انجام شده در این مطالعه، نتایج زیر را به همراه داشت:

۱- پیش پردازش داده‌ها یکی از مهمترین اقداماتی است که بایستی قبل از فرایند مدلسازی انجام گیرد تا درجه اطمینان نتایج افزایش یابد و فرایند آموزش مدل‌ها با عملکرد مطلوب‌تری انجام شود. یک جنبه مهم مرتبط

- با داده که بر روی عملکرد یادگیری ماشین تأثیر می‌گذارد، تعداد نقاط داده می‌باشد. فرایند آموزش ماشین‌ها تا زمانی که با داده‌های حجیم و گسترده مواجه نشوند، نوید بهبودی را نخواهند داد. در حالی که اگر داده‌های حجیم در دسترس باشند می‌توان انتظار داشت که الگوهای بهتری کشف شوند و پیش-بینی‌های دقیق تری از متغیر هدف صورت پذیرد.
- ۲- تحلیل گروهی مدل‌ها و مقایسه مدل‌های توسعه داده شده با مدل‌های منتشر شده در ادبیات تحقیق نشان داد که مدل‌های مبتنی بر آموزش ماشین عملکرد بهتری را نسبت به مدل‌های مرسوم ریاضی دارا هستند. همچنین بر اساس آنالیزهای آماری و گرافیکی، ثابت گردید که مدل WAO-MLPNN دارای بالاترین دقت در تخمین نرخ نفوذ می‌باشد.
- ۳- ترکیب شبکه‌های عصبی با الگوریتم‌های فرا ابتکاری نوین، امکان کشف الگوهای پیچیده در داده‌ها را امکان پذیر می‌نماید. همچنین ترکیب شبکه‌های عصبی با الگوریتم‌های فرا ابتکاری، نوید دستیابی به نتایج بهتری را در مقایسه با شبکه‌های عصبی ساده می‌دهد.
- ۴- از بهترین مزایای استفاده از الگوریتم‌های ACO و WAO میتوان به کشف سریع جوابهای مناسب، محاسبات توزیع شده، یافتن پاسخ‌های بهینه در محدوده فضای جستجو و بهره‌گیری از همگرایی سریع اشاره کرد. علاوه بر موارد مذکور، عدم استفاده از این دو الگوریتم جهت توسعه مدل‌های تخمینگر نرخ نفوذ و همچنین نتایج مطلوب بدست آمده از آنها در مطالعات انجام شده در ادبیات تحقیق سبب گردید تا استفاده از این دو الگوریتم جهت مدلسازی و تقریب نرخ نفوذ مورد تأیید قرار گیرد.

مراجع

- [1] M. M. Amer, A. S. Dahab, and A.A. H. El-Sayed, "An ROP Predictive Model in Nile Delta Area Using Artificial Neural Networks", Society of Petroleum Engineers, June 2017.
- [2] S. Z. Lashari, A. Takbiri-Borujeni, E. Fathi, T. Sun, R. Rahmani, and M. Khazaeli, "Drilling performance monitoring and optimization: a data-driven approach", Journal of Petroleum Exploration and Production Technology, Vol. 9, No. 4, December 2019, pp. 2747-2756.
- [3] A. K. Abbas, S. Rushdi, and M. Alsaba, "Modeling Rate of Penetration for Deviated Wells Using Artificial Neural Network", Abu Dhabi International Petroleum Exhibition and Conference, November 2018.
- [4] A. K. Abbas, S. Rushdi, M. Alsaba, and M. F. Al Dushaishi, "Drilling Rate of Penetration Prediction of High-Angled Wells Using Artificial Neural Networks", Journal of Energy Resources Technology, Vol. 141, No. 11, May 2019, p. 112904.

- [5] M. Ayoub, G. Shien, D. Diab, and Q. Ahmed, "Modeling of drilling rate of penetration using adaptive neuro-fuzzy inference system", *International Journal of Applied Engineering Research*, Vol. 12, 2017, pp. 12880-12891.
- [6] E. M. Galle and H. B. Woods, "Best Constant Weight and Rotary Speed for rotary Rock Bits", *Drilling and Production Practice*. American Petroleum Institute, p. 26, 1963, Accessed: June 2019.
- [7] M. G. Bingham, "A new approach to interpreting rock drillability", *Petroleum Pub. Co.*, 1965.
- [8] A. T. Bourgoynne and F. S. Young, "A Multiple Regression Approach to Optimal Drilling and Abnormal Pressure Detection", *Society of Petroleum Engineers*, Vol. 14, No. 04, August 1974, pp. 371-384.
- [9] A. A. Jabbar, S. Elkhatny, M. Mahmoud, K. Abdelgawad, and A. Al-Majed, "A Robust Rate of Penetration Model for Carbonate Formation", *Journal of Energy Resources Technology*, Vol. 141, No. 4, November 2018.
- [10] E. Wiktorski, A. Kuznetsov, and D. Sui, "ROP Optimization and Modeling in Directional Drilling Process", *SPE Bergen One Day Seminar*, April 2017.
- [11] A. K. Darwesh, T. M. Rasmussen, and N. Al, "Controllable drilling parameter optimization for roller cone and polycrystalline diamond bits", *Journal of Petroleum Exploration and Production Technology*, Vol. 10, No. 4, 2020, pp. 1657-1674.
- [12] M. Anemangely, A. Ramezanzadeh, and B. Tokhmechi, "Determination of constant coefficients of Bourgoynne and Young drilling rate model using a novel evolutionary algorithm", *Journal of Mining and Environment*, Vol. 8, No. 4, 2017, pp. 693-702.
- [13] Y. Li and R. Samuel, "Prediction of Penetration Rate Ahead of the Bit through Real-Time Updated Machine Learning Models", *SPE/IADC International Drilling Conference and Exhibition*, Mar. 2019.
- [14] M. R. Youcefi, A. Hadjadj, A. Bentriou, and F. S. Boukredera, "Rate of penetration modeling using hybridization extreme learning machine and whale optimization algorithm", *Earth Science Informatics*, 2020.
- [15] A. Ahmed s, S. Elkhatny, A. Abdulraheem, M. Mahmoud, A. Z. Ali, and I. M. Mohamed, "Prediction of Rate of Penetration of Deep and Tight Formation Using Support Vector Machine", *Society of Petroleum Engineers*, August 2018.
- [16] A. Al-Abduljabbar, H. Gamal, and S. Elkhatny, "Application of artificial neural network to predict the rate of penetration for S-shape well profile", *Arabian Journal of Geosciences*, Vol. 13, No. 16, 2020.
- [17] C. Gan et al., "Prediction of drilling rate of penetration (ROP) using hybrid support vector regression: A case study on the Shennongjia area, Central China", *Journal of Petroleum Science and Engineering*, Vol. 181, October 2019.
- [18] S. B. Ashrafi, M. Anemangely, M. Sabah, and M. J. Ameri, "Application of hybrid artificial neural networks for predicting rate of penetration (ROP): A case study from Marun oil field", *Journal of Petroleum Science and Engineering*, Vol. 175, December 2018, pp. 604-623.
- [19] K. Al-Azani, S. Elkhatny, A. Ali, E. Ramadan, and A. Abdulraheem, "Cutting concentration prediction in horizontal and deviated wells using artificial intelligence techniques", *Journal of Petroleum Exploration and Production Technology*, Vol. 9, No. 4, December 2019, pp. 2769-2779.
- [20] حدیث بی باک، جهانگیر خزایی و حسین مویدی، "پیش بینی طرح اختلاط بهینه برای بهسازی خاک رس نرم با استفاده از شبکه های عصبی مصنوعی"، *نشریه مدل سازی در مهندسی*، دوره ۱۷، شماره ۵۷، تابستان ۱۳۹۸، صفحه ۱۳-۱.
- [21] D. Toghraie, N. Sina, N. A. Jolfaei, M. Hajian, and M. Afrand, "Designing an Artificial Neural Network (ANN) to predict the viscosity of Silver/Ethylene glycol nanofluid at different temperatures and volume fraction of nanoparticles", *Physica A: Statistical Mechanics and its Applications*, Vol. 534, p. 122142, Nov. 2019.
- [22] N. F. Hordri, S. S. Yuhani, S. M. Shamsuddin, and A. Ali, "Hybrid Biogeography Based Optimization-Multilayer Perceptron for Application in Intelligent Medical Diagnosis", *Advanced Science Letters*, Vol. 23, No. 6, June 2017, pp. 5304-5308.
- [23] C. Soares and K. Gray, "Real-time predictive capabilities of analytical and machine learning rate of penetration (ROP) models", *Journal of Petroleum Science and Engineering*, Vol. 172, January 2019, pp. 934-959.
- [24] S. Mirjalili and A. Lewis, "The Whale Optimization Algorithm", *Advances in Engineering Software*, Vol. 95, 2016, pp. 51-67.
- [25] A. Heydari, D. Astiaso Garcia, F. Keynia, F. Bisegna, and L. De Santoli, "Hybrid intelligent strategy for multifactor influenced electrical energy consumption forecasting", *Energy Sources, Part B: Economics, Planning*,

and Policy, Vol. 14, No. 10-12, December 2019, pp. 341-358.

[26] W. Chen et al., "Spatial Prediction of Landslide Susceptibility Using GIS-Based Data Mining Techniques of ANFIS with Whale Optimization Algorithm (WOA) and Grey Wolf Optimizer (GWO)", Applied Sciences, Vol. 9, No. 18, September 2019, p. 3755.

[27] D. Tien Bui, M. M. Abdullahi, S. Ghareh, H. Moayedi, and H. Nguyen, "Fine-tuning of neural computing using whale optimization algorithm for predicting compressive strength of concrete", Engineering with Computers, August 2019.

[28] M. Dorigo, V. Maniezzo, and A. Coloni, "Ant system: optimization by a colony of cooperating agents", IEEE Transactions on Systems, Vol. 26, No. 1, 1996, pp. 29-41.

[۲۹] امیر سقط فروش، مسعود منجزی و جعفر خادمی حمیدی، "بهینه سازی عملیات انفجار با استفاده از روش ترکیبی عصبی-مورچگان (مطالعه موردی: معدن سنگ آهن دلکن)", نشریه مدل سازی در مهندسی، دوره ۱۵، شماره ۴۸، بهار ۱۳۹۶، صفحه ۲۶۹-۲۵۹.

[30] P. Li, H. Nie, L. Qiu, and R. Wang, "Energy optimization of ant colony algorithm in wireless sensor network", International Journal of Distributed Sensor Networks, Vol. 13, No. 4, April 2017.

[31] K. Socha and M. Dorigo, "Ant colony optimization for continuous domains", European Journal of Operational Research, Vol. 185, No. 3, March 2008, pp. 1155-1173.

[32] D. Zhao et al., "Chaotic random spare ant colony optimization for multi-threshold image segmentation of 2D Kapur entropy", Knowledge-Based Systems, October 2020.

[۳۳] نوید فریدونی مهر و فواد نظری، "تحلیل پارامتری و بهینه سازی سیکل تبریداجکتوری فوق بحرانی همراه با سیال عامل های مختلف به کمک شبکه عصبی مصنوعی و الگوریتم بهینه سازی پرندگان"، نشریه مدل سازی در مهندسی، دوره ۱۵، شماره ۵۰، پاییز ۱۳۹۶، صفحه ۱۳۳-۱۲۲.

[34] M. Puig-Arnavat and J. C. Bruno, "Artificial Neural Networks for Thermochemical Conversion of Biomass", Recent Advances in Thermo-Chemical Conversion of Biomass, 2015, pp. 133-156.

[35] M. Ahmadi and Z. Chen, "Machine learning-based models for predicting permeability impairment due to scale deposition", Journal of Petroleum Exploration and Production Technology, Vol. 10, No. 7, October 2020, pp. 2873-2884.

[۳۶] حامد نوذری و فاطمه توکلی، "پیش بینی جریان با استفاده از مدل ماشین بردار پشتیبان بر مبنای سری های زمانی دبیو بارش در ایستگاه های بالادست (مطالعه موردی: ایستگاه هیدرومتری تله زنگ)", نشریه مدل سازی در مهندسی، دوره ۱۶، شماره ۵۴، پاییز ۱۳۹۷، صفحه ۱۰۴-۹۶.

[37] J. W. Graham and N. L. Muench, "Analytical determination of optimum bit weight and rotary speed combinations", Society of Petroleum Engineers, 1959.

[38] T. Miyora, M. P. Jónsson, and S. Þórhallsson, "Modelling of geothermal drilling parameters—a case study of well MW-17 in Menengai Kenya", GRC Trans, 2015.

[39] F. Ecer, S. Ardabili, S. S. Band, and A. Mosavi, "Training multilayer perceptron with genetic algorithms and particle swarm optimization for modeling stock price index prediction", Entropy, Vol. 22, N0. 11, pp. 1–20.

[40] Z. Hu, Y. Zhang, and L. Yao, "Radial Basis Function Neural Network with Particle Swarm Optimization Algorithms for Regional Logistics Demand Prediction", Discrete Dynamics in Nature and Society, Vol. 2014, pp. 1–13, 2014.

[41] O. Kramer, "Genetic Algorithm Essentials", Springer International Publishing, Vol. 679, 2017.

[42] K. Bamdad, M. E. Cholette, L. Guan, and J. Bell, "Ant colony algorithm for building energy optimisation problems and comparison with benchmark algorithms", Energy and Buildings, Vol. 154, pp. 404–414, 2017.

[43] J. Nasiri, F. M. Khiyabani, and A. Yoshise, "A whale optimization algorithm (WOA) approach for clustering", Cogent Mathematics & Statistics, Vol. 5, No. 1, p. 1483565, 2018.

[44] A. Karkevandi-Talkhoonchek, S. Hajirezaie, A. Hemmati-Sarapardeh, M. M. Husein, K. Karan, and M. Sharifi, "Application of adaptive neuro fuzzy interface system optimized with evolutionary algorithms for modeling CO2-crude oil minimum miscibility pressure", Fuel, Vol. 205, October 2017, pp. 34-45.

[45] M. Anemangely, A. Ramezanzadeh, B. Tokhmechi, A. Molaghab, and A. Mohammadian, "Drilling rate

prediction from petrophysical logs and mud logging data using an optimized multilayer perceptron neural network”, *Journal of Geophysics and Engineering*, Vol. 15, No. 4, pp. 1146–1159, Aug. 2018.

[46] S. Elkatatny, “Development of a new rate of penetration model using self-adaptive differential evolution-artificial neural network”, *Arabian Journal of Geosciences*, Vol. 12, No. 2, 2019.

[47] Y. Zhao, A. Noorbakhsh, M. Koopialipour, A. Azizi, and M. M. Tahir, “A new methodology for optimization and prediction of rate of penetration during drilling operations”, *Engineering with Computers* volume, pp. 1–9, Jan. 2019.