



بهینه سازی اثرگذاری سیال حفاری بر مبنای علم مکانیک سیالات در فرآیند حفاری چاه های یکی از میادین جنوب غرب ایران

مهدی منجزی^{۱*}، کورس نکوفار^۲، سید آرش سید شمس طالقانی^۳، مریم السادات قوامی^۴

۱- مهدی منجزی، کارشناس ارشد، واحد الکترونیکی دانشگاه آزاد اسلامی، تهران

۲- کورس نکوفار، استادیار، واحد الکترونیکی دانشگاه آزاد اسلامی، تهران

۳- سید آرش سید شمس طالقانی، استادیار، پژوهشگاه هوافضا، وزارت علوم، تحقیقات و فناوری، تهران

۴- مریم السادات قوامی، دانشجوی دکترای تخصصی، دانشگاه تربیت مدرس، تهران

*msghavami1990@gmail.com

چکیده

سرعت عملیات حفاری اثر مستقیمی بر روی هزینه های حفاری دارد و پارامترهای مختلفی از جمله خواص سیال حفاری و هیدرولیک مته بر روی آن مؤثر است. بنابراین استفاده از مدل هایی با در نظر گرفتن پارامترهای مختلف که دقت بالا داشته باشند اهمیت فراوانی دارد. از آنجاییکه ارتباط این پارامترها با یکدیگر پیچیده است نیاز به یک روش محاسباتی قابل اجرا دارد. شبکه عصبی مصنوعی یک روش محاسباتی نوین برای یادگیری است که برای پیش بینی پاسخ های خروجی سیستم های پیچیده استفاده می گردد. در این مقاله شبکه عصبی به منظور پیش بینی نرخ نفوذ مته با در نظرگیری پارامترهای سیال حفاری مورد استفاده قرار می گیرد و از مدل های هوش مصنوعی چندلایه و پایه شعاعی برای تشخیص و پیش بینی سرعت حفاری به عنوان پارامتر خروجی استفاده شده است.

اطلاعات مقاله

مقاله پژوهشی کامل

دریافت: ۲۵ مهر ۱۳۹۸

پذیرش: ۱۸ اسفند ۱۳۹۸

ارائه در سایت: ۱۰ اردیبهشت ۱۳۹۹

کلیدواژگان

سرعت عملیات حفاری

شبکه عصبی چندلایه

شبکه عصبی پایه شعاعی

Optimization of drilling fluid effectiveness based on fluid mechanics in well drilling process of one of the squares in the southwest of Iran

Mehdi Monjezi^{*1}, Kourose Nekoufar², Seyed Arash Seyed Shams Taleghani³, Maryam Sadat Ghavami⁴

1- Mehdi Monjezi, Master, Islamic Azad University Electronic Unit, Tehran

2- Kourose Nekoufar, Assistant Professor, Islamic Azad University Electronic Unit, Tehran

3- Seyed Arash Seyed Shams Taleghani, Assistant Professor, Aerospace Research Institute, Ministry of Science, Research and Technology,

4- Maryam Sadat Ghavami, PhD student, Tarbiat Modares University, Tehran

* Tehran msghavami1990@gmail.com

Article Information

Original Research Paper

Received 17 October 2019

Accepted 8 March 2020

Available Online 29 April 2020

Keywords

Speed of drilling operations

Multilayer neural network

Radial base neural network

ABSTRACT

The speed of drilling operations has a direct effect on drilling costs and various parameters such as drilling fluid properties and hydraulic drilling affect it. Therefore, it is very important to use models with different parameters that have high accuracy. Because the relationship between these parameters is complex, a computational method is needed. Artificial neural network is a new computational method for learning that is used to predict the output responses of complex systems. In this paper, the neural network is used to predict the drill penetration rate by considering the parameters of drilling fluid and multilayer artificial intelligence models and radial base are used to detect and predict drilling speed as output parameters.

Please cite this article using:

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Mehdi Monjezi, Kourose Nekoufar, Seyed Arash Seyed Shams Taleghani, Maryam Sadat Ghavami, Optimization of drilling fluid effectiveness based on fluid mechanics in well drilling process of one of the squares in the southwest of Iran

, Journal of Mechanical Engineering and Vibration, Vol. 11, No. 1, pp. 28-38, 2019-2020 (In Persian)

۱- مقدمه

یکی از مهمترین عوامل تعیین کننده میزان موفقیت یک عملیات حفاری، کنترل سیستم سیال حفاری مربوط به آن عملیات می باشد. اهمیت بهینه سازی اثر بخشی سیال حفاری در افزایش سرعت حفر چاه و در نتیجه کاهش هزینه های اقتصادی می باشد. از طرفی بهینه سازی سیال حفاری همیشه به معنی افزایش سرعت حفاری نیست زیرا برخی اوقات سرعت زیاد موجب کاهش شدید عمر مته می شود که خود اثر منفی بر روی عملیات حفاری دارد.

بنابراین انتخاب صحیح عوامل مؤثر بر نرخ نفوذ در سنگ سازند بر اساس پارامترهای مهم در سازند مورد نظر ضروری می باشد شبکه عصبی به منظور پیش بینی نرخ نفوذ مته با در نظرگیری پارامترهای سیال حفاری مورد استفاده قرار می گیرد. قطر چاه، سرعت تزریق گل، سرعت چرخش رشته حفاری، وزن روی مته، گشتاور، عمق، وزن گل، ویسکوزیته، نقطه واروی، ژل و میزان هرزروی سیال به عنوان پارامترهای ورودی و سرعت حفاری به عنوان پارامتر خروجی در نظر گرفته می شود.

تاکنون چندین مدل ریاضی به منظور پیش بینی شرایط مته حفاری بدون خارج کردن آن از ته چاه توسط محققین ارائه شده اند. گال و دز در سال ۱۹۶۰ یک مدل ریاضی را به منظور تعیین وزن روی مته و سرعت چرخش آن جهت افزایش بازدهی و کاهش هزینه های حفاری در سازندهای نرم ارائه نمودند [۱].

کانینگهام در سال ۱۹۶۰ نیز رابطه ای را جهت افزایش بازدهی مته ارائه نمود. عدم پیش بینی سریع فرسایش مته حفاری را می توان به عنوان اصلی ترین مشکل در رابطه ارائه شده توسط کانینگهام بیان نمود. بورگسی و لسو در سال ۱۹۸۵ رابطه ای را که برای سازندهای رسی قابل استفاده بود ارائه کردند [۲].

همچنین هاربرت در سال ۱۹۹۳ روشی را ارائه نمود که در شرایط تغییر ناگهانی وزن روی مته و تغییر لیتولوژی مناسب نمی باشد [۳].

روش دیگر ارائه شده توسط بورینگ و یانگ در سال ۲۰۰۳ نیز یکی دیگر از روابط تشریح شده جهت پیش بینی نرخ نفوذ مته و بهبود عملکرد آن می باشد. در میان تمامی روش های ارائه شده توسط محققین به منظور تخمین میزان نرخ نفوذ مته حفاری، روش بورینگ و یانگ به این دلیل که تقریباً تمام پارامترهای اصلی حفاری را در برمی گیرد، از برتری نسبی برخوردار می باشد. ایشان از روش رگرسیون چندگانه به منظور یافتن ضرایب

مجهول جهت تخمین میزان نرخ نفوذ مته حفاری استفاده نمودند [۴].

۲- مواد و روشها

۲-۱- مشخصه انرژی

مشخصه انرژی تئوری جدیدی نیست و از آن برای ارزیابی عملکرد مته استفاده می شده است. مشخصه انرژی ابزاری برای پیش بینی یا تجزیه و تحلیل عملکرد می باشد و مبتنی بر اصول اساسی مربوط به مقدار انرژی مورد نیاز برای از بین بردن یک واحد حجم سنگ و بهره وری از مته است.

بواسطه اعمال زیر در بهینه سازی نرخ نفوذ حفاری تاثیر گذار است :

۱. بهینه سازی پارامترهای حفاری جهت افزایش طول عمر مته
 ۲. افزایش سرعت نرخ نفوذ حفاری تا حداکثر توان سیستم صرف نظر از نوع مته
 ۳. دانستن زمانی که مته کارایی خود را از دست داده است
- بهینه سازی نرخ نفوذ حفاری با پیش بینی عملکرد مته با استفاده از ضریب انرژی مخصوص به عنوان یک تابع از مقاومت فشاری سنگ میسر می گردد [۵].
- در این روش ، نرخ نفوذ حفاری به شرح ذیل به دست می آید: [۶]

$$ROP = \frac{18\mu N}{d_B \left(\frac{CCS}{EFF_M \times WOB} - \frac{1}{A_B} \right)}$$

در این رابطه CCS مقاومت محوری تراکمی، A_B سطح مته، μ ضریب مخصوص اصطکاک لغزشی مته و EFF_M کارایی مکانیکی مته می باشد.

۲-۲- بهینه سازی

هدف از عملیات حفاری ، حفر ، ارزیابی و تکمیل چاه برای تولید کارآمد تولید نفت و گاز می باشد. سرعت حفاری و یا نرخ نفوذ مته به صورت مقدار متر از حفاری شده در واحد زمان تعریف می گردد. نرخ نفوذ مته تحت تاثیر تعداد زیادی از پارامترها، همانند نوع ، سایز، شرایط و IADC CODE مته، نوع سازند و لیتولوژی آن، نوع و خصوصیات گل حفاری (وزن و

یکی از اولین مدل های پیش بینی نرخ نفوذ مته در سازند توسط مارر ارائه شده است. این مدل فرض می کند که تمام کنده های حفاری از اطراف مته کنار می روند و مته همیشه در تماس کامل با سازند قرار دارد. این رابطه به صورت زیر بیان می شود: [۷].

فرمول ۲

$$ROP = k \frac{RPM \times W^2}{d_B \times S^2}$$

که در آن ROP سرعت حفاری، S توانایی حفاری سازند به صورت پایدار، W وزن روی مته، d_B سایز مته، و k یک ثابت است.

همچنین مارر پیشنهاد کرد که به دلیل کاهش سرعت حفاری به دلیل محدود شدن تماس بین مته و سازند در اثر حضور کنده های حفاری، رابطه بالا به صورت زیر اصلاح شود:

فرمول ۳

$$ROP = \frac{RPM^x \times W^y}{d_B^z}$$

که در آن پارامترها x ، y و z پارامترهای ثابتی هستند.

در سال ۱۹۷۸ مدل دیگری توسط کونینگ هام برای محاسبه سرعت حفاری به صورت زیر پیشنهاد شد: [۸].

فرمول ۴

$$ROP = \frac{RPM \times W^2}{0.424 \times S^{1.5} + \sqrt{RPM \times W^2 \times \Delta p}^{0.75}}$$

که در آن اختلاف فشار می باشد.

در سال ۱۹۸۱ وارن با استفاده از داده های آزمایشگاهی برای پیش بینی سرعت حفاری مدلی به صورت زیر ارائه داد:

فرمول ۵

$$ROP = \left(\frac{aS^2d_b^3}{RPM^b \times WOB^2} + \frac{c}{RPM \times d_b} \right)^{-1}$$

که در آن a ، b ، c پارامترهای ثابت هستند. این مدل با استفاده از مته هایی با اندازه ۶ تا ۱۲،۲۵ اینچ به دست آمده است. او در سال ۱۹۸۷ به منظور لحاظ کردن اثر ایجاد کنده های حفاری در اطراف مته رابطه خود را به صورت زیر اصلاح کرد:

فرمول ۶

گرانروی) فشار سازند، عمق حفاری، هیدرولیک حفاری، وزن روی مته، سرعت گردش مته و زاویه انحراف چاه می باشد.

تاثیر تعدادی از این پارامترها نسبت به زمان ثابت و تاثیر تعدادی از آنها نسبت به زمان متغیر و دینامیک میباشند. البته هیدرولیک حفاری که شامل دبی و فشار خروجی پمپ می گردد و گرانروی گل، تاثیر مستقیم بر سرعت حفاری ندارد بلکه نقش اصلی آن انتقال کنده های حفاری و خنک کردن مته می باشد؛ که در صورتی که در حالت بهینه نباشد نه تنها باعث کاهش سرعت حفاری می شود بلکه باعث مشکلات بسیار دیگری هم می گردد. پیش بینی نرخ نفوذ مته و یا به عبارت دیگر میزان سرعت حفاری، یکی از مهمترین چالش ها در عملیات حفاری می باشد و حداکثر شدن سرعت حفاری در شرایط ثابت و ایمن یکی از اولویت ها و اهداف اصلی عملیات حفاری می باشد که این مسئله باعث کاهش هزینه های عملیات حفاری و کاهش هزینه نهایی تمام شده چاه می گردد.

در صورتی که بتوان سرعت حفاری را پیش بینی و میزان و تاثیر عوامل موثر بر آن را مشخص کرد؛ میتوان به نتایج سودمندی دست پیدا کرد.

از جمله آن :

- پیش بینی میزان نرخ نفوذ مته و توانایی شبیه سازی عملیات حفاری به صورت مجازی

- تشخیص و تعیین میزان تاثیر عوامل موثر در نرخ نفوذ مته

- ارائه برنامه دقیق تر در هنگام طراحی چاه و در هنگام عملیات حفاری

- بهینه سازی سرعت حفاری در هنگام عملیات با توجه به تغییر پارامترهای موثر (سازند، لیتولوژی، هیدرولیک حفاری و ...) کمک به حفار و ناظر حفاری در زمان عملیات، برای تصمیم گیری صحیح تر در زمان مشاهده تغییرات زیاد در سرعت حفاری

- توانایی در تشخیص صحت گزارش های ارسالی از عملیات حفاری

-افزایش ایمنی در هنگام عملیات حفاری و بهینه سازی عملیات حفاری در سازندهای مشکل زا

-استفاده از روابط استاتیک و دینامیک در میان متغیرهای سیستم به منظور توصیف رفتار یک سیستم به شکل کیفی می باشد روش های شناسایی سیستم از این دسته هستند. در این روش میتوان به روش های خطی، غیرخطی، دینامیکی، استاتیکی شناسایی سیستم ها اشاره کرد


$$W_f = 1 - \frac{\Delta BG}{8}$$

$$S = S_0(1 + a_s P_e^b)$$

$$\Delta BG = W_c \sum_{i=1}^A W_i \times RPM \times S_i$$

$$ROP = W_f \left[f_c(P_e) \left(\frac{aS^2 d_B^3}{RPM \times W^2} + \frac{b}{RPM \times d_B} \right) + \frac{cd_B \rho \mu}{I_m} \right]^{-1}$$

این نکته باید مورد توجه قرار گیرد که افزایش پارامترهای حفاری همواره سبب افزایش سرعت حفاری نمی شود بلکه از یک محدوده به بعد تغییر پارامترها نه تنها باعث افزایش سرعت حفاری نمی شود بلکه با ایجاد مشکلاتی نظیر ایجاد ارتعاشات شدید در سیستم و تویی شدن مته و ساییده شدن بیشتر مته سبب کاهش سرعت حفاری نیز میشوند. به عنوان نمونه شکل زیر اثر وزن روی مته بر سرعت حفاری را نشان می دهد.



شکل (۱): نمودار سرعت حفاری بر حسب وزن روی مته و سرعت چرخش مته

در وزن های پایین، وزن روی مته اثر کمی بر سرعت حفاری دارد ناحیه (AB) در ناحیه دوم که ناحیه کارآمد یا پربازده نام دارد وزن روی مته و سرعت حفاری رابطه خطی با یکدیگر دارند و افزایش وزن روی مته سبب افزایش سرعت حفاری می شود. ناحیه (BC). نقطه C نقطه تقلا نام دارد که توسط گرنت بینگهام در سال ۱۹۵۰ معرفی شد. این نقطه حداکثر وزن روی مته و سرعت چرخش مته در ناحیه پربازده را نشان می دهد که اگر پارامترهای اعمال شده از این مقادیر فراتر روند

$$ROP = \left(\frac{aS^2 d_B^3}{RPM^b \times WOB^2} + \frac{b}{RPM \times d_B} + \frac{c \times d_B \times Y_f \times \mu}{F_{jm}} \right)^{-1}$$

که در آن چگالی ویژه سیال حفاری، مقدار ویسکوزیته پلاستیک و مقدار نیروی موثر می باشد. در سال ۱۹۸۶ مدل دیگری توسط والکر رابطه ای به صورت زیر برای محاسبه سرعت حفاری در سازند پیشنهاد داد: [۹].
فرمول ۷

$$ROP = 14 + 54W \times P_{hde} + 31\phi - 10d_{gran} - 16S + 46P_{hde}^2 - 3IW \times P_{hde}$$

که در آن فشار چاه، تخلخل و میانگین اندازه ذرات را نشان می دهد. برای ارائه این مدل سازندهایی از جنس ماسه، کربناته، شیل و بازالت مورد بررسی قرار گرفتند. از دیگر رابطه های محاسبه نرخ نفوذ مته، رابطه بینگهام به صورت زیر می باشد.
فرمول ۸

$$\frac{dD}{dt} = 60 \times a \left(\frac{W}{d_B} \right)^b \times N$$

که در آن سرعت حفاری، توانایی حفاری سازند به صورت پایدار، وزن روی مته، dB سایز مته، b وزن مته و N نرخ دوران مته است. در سال ۱۹۹۳ هیرلند و هوبروک با اصلاح مدل پیشنهادی وارن را به صورت زیر اصلاح کردند:
فرمول ۹

$$f_c(P_e) = c_c + a_c(P_e - 120)^{b_c}$$

$$ROP = \left[f_c(P_e) \left(\frac{aS^2 d_B^3}{RPM \times W^2} + \frac{b}{RPM \times d_B} \right) + \frac{cd_B \rho \mu}{I_m} \right]^{-1}$$

اما در این معادله تاثیر میزان فرسوده شدن مته در اثر حفاری در نظر گرفته نشده است. بنابراین هیرلند و هوبروک فرمول پیشنهادی خود را برای مد نظر قرار دادن اثرات فرسوده شدن مته به صورت زیر اصلاح کردند:
فرمول ۱۰

هیدرولیک توان خارج کردن همه خرده‌ها از زیر مته را ندارد در نتیجه مته دوباره اقدام به خرد کردن خرده‌های مرحله قبل می‌کند.

۲-۳- مروری بر روش های هوش مصنوعی

۱- یکی از جدیدترین مدل‌های حفاری، استفاده از شبکه‌های عصبی مصنوعی است. بیلگسو در سال ۲۰۰۰ از شبکه‌های عصبی مصنوعی برای انتخاب مته استفاده نمود. که در این مدل از پارامترهای حفاری استفاده و از پارامترهای سازند که نقش مهمی در انتخاب مته ایفا می‌کند، صرف نظر شد. یلماز با استفاده از متوسط استحکام فشاری سازند، این مدل را توسعه داد اما فقط بر روی انتخاب مته کارکرد و بر روی ارزیابی مقادیر بهینه پارامترهای حفاری و چگونگی افزایش نرخ نفوذ حفاری کاری انجام نداد.

۲- داشویسکی و همکاران از قدرت شبکه های عصبی برای مدل سازی رفتار دینامیکی سیستم حفاری غیرخطی، چند ورودی/ خروجی استفاده کردند و مدلی، همراه با کنترل کننده بهینه، که حفاری را با یک توصیه کافی در مورد اقدامات اصلاحی مناسب مورد نیاز برای آوردن سیستم به شرایط حفاری بهینه فراهم کردند. مطه‌ری و همکاران مدلی برای پیش بینی وزن مته بهینه، با تنظیم داده های عملکرد موتور با یک مدل نرخ نفوذ ارائه دادند. هانکین و همکاران روشی جهت پیش بینی بهینه تجهیزات و پارامترهای عملیاتی از طریق شبیه سازی عملیات حفاری در میدان لوزیانا ارائه دادند. ونگ و صالحی شبکه ای عصبی جهت پیش بینی بهینه هیدرولیک گل ارائه دادند. آنها آنالیز حساسیت روی پارامترهای ورودی را جهت بررسی خروجی مدل مد نظر قرار دادند. مروجی و همکاران درباره پیش بینی نرخ نفوذ حفاری و بهینه سازی آن با استفاده از روش پاسخ سطحی و بت الگوریتم و تأثیر همزمان شش متغیر بر میزان نفوذ با استفاده از داده‌های حفاری میدان واقعی مورد بررسی قرار دادند.

در یکی از کامل‌ترین کارهای انجام گرفته، شپین و همکاران در سال ۲۰۰۲ به بررسی میزان انباشتگی مایع در خطوط لوله دو فاز

افقی پرداخته‌اند. در این کار از ساختار شبکه MLP به عنوان یک ساختار متداول و کارا استفاده شده است [۱۰].

عامر و همکاران استفاده از شبکه‌های عصبی مصنوعی برای پیش بینی نرخ نفوذ حفاری برای بهینه سازی انتخاب مته بررسی کرد. عباس خاکسار و همکاران برای بهینه سازی عملیات حفاری از شبکه های عصبی درک چند لایه عصبی برای تعیین نوع مته و میزان نفوذ توسعه داده شده است، سپس ورودی های مدل دوم توسط الگوریتم ژنتیک برای دسترسی به حداکثر میزان نفوذ بهینه سازی شده است. برای پیش بینی نوع مته و میزان نفوذ در مرحله آزمایش، ضرایب همبستگی به ترتیب برابر با ۰/۹۸ و ۰/۹۶ به دست آوردند [۱۱].

۲-۴- کاربرد سیستم های هوشمند در صنایع نفت و گاز

شیوه‌های هوش مصنوعی هنگامی مورد استفاده قرار می‌گیرند که استفاده از شیوه‌های معمولی بسیار زمان‌بر باشد و یا با استفاده از این شیوه‌ها مسئله قابل حل نباشد. یکی از کاربردهای شبکه عصبی، استفاده از آن در تعیین پارامترهای خطوط لوله دو فاز است. میزان فشار ته چاهی، انباشتگی مایع و الگوی جریان سه پارامتری هستند که از این طریق مورد ارزیابی قرار گرفته‌اند. حرکت هم‌زمان مایع و گاز در کنار یکدیگر و لزوم تعیین پارامترهای دو فاز در حل مسائل مکانیک سیالاتی مانند افت فشار باعث ایجاد پیچیدگی مسئله می‌شود؛ لذا هر یک از پارامترهای فوق تابعی از خصوصیات دیگری مانند قطر لوله، ضخامت آن، دما، فشار، سرعت نفت و سرعت گاز و خصوصیات ترمودینامیکی سیالات خواهند بود.

کلید موفقیت در زمینه اکتشاف در سال ۱۹۹۰ و حتی بعدها، بدون شک در استفاده از کامپیوترها برای پردازش و تفسیر حجم عظیم داده های موجود از نقشه برداری سه بعدی لرزه‌ای بوده است. تکنیک‌های سه بعدی لرزه‌ای نقش مهمی را در توصیف مخزن بازی می‌کنند [۱۲].

این تکنیک‌ها به ویژه در دریای شمال به دلیل توانایی آن در تشخیص گسل‌های پیچیده، گودال‌ها و همچنین گنبد‌های نمکی، دارای اهمیت به سزایی است. از آنجایی که تکنیک‌های سه بعدی بازتاب لرزه‌ای بهتری نسبت به تکنیک‌های دو بعدی دارند، تغییرات محدوده نسبی می‌تواند برای تغییرات تخلخل و همچنین تشخیص وجود گاز تفسیر شوند. شبکه‌های عصبی نقشی حیاتی را در استفاده و تفسیر داده‌های زمین لرزه‌ای ایفا می‌کنند. فرآیند تفسیر زمان‌بر و پیچیده است؛ مخصوصاً زمانی که حجم زیادی از داده‌ها در دسترس

باشند. یک سیستم شبکه عصبی مناسب، برای تفسیر داده های زمین لرزه ای این فرآیند را به شدت تسریع می بخشد [۱۳].

۳-۱- شبکه عصبی پایه شعاعی

تعداد لایه های موجود در این نوع شبکه ها همانند شبکه های عصبی چند لایه سه لایه ورودی، میانی یا پنهان و خروجی می باشد. در این شبکه ها لایه میانی نمی تواند زیر لایه داشته باشد و فقط یک لایه ثابت می باشد.

در این شبکه ها دو پارامتر به نام های عدد گسترش (spread) و تعداد نورون های موجود در لایه میانی دقت مدل را به شدت تحت تاثیر قرار می دهند. به همین خاطر و به منظور اینکه مدلی با دقت قابل قبول ارائه دهیم باید مقادیر عددی این دو پارامتر را بهینه کنیم. در این تحقیق برای بهینه سازی این دو پارامتر از الگوریتم ازدحام ذرات استفاده شد.

با استفاده از این الگوریتم ابتدا جمعیتی شامل ۱۰۰ عضو از مقادیر این دو پارامتر انتخاب شدند. بر اساس این پارامترها ۱۰۰ مدل ساخته شد و دقت هر مدل از طریق محاسبه کمینه مربعات خطای آن مدل محاسبه شد. سپس با استفاده از عملگرهای مربوط به الگوریتم ازدحام ذرات، یک مجموعه ۱۰۰ عضوی جدید از این پارامترها بر اساس بهترین جوابهای جمعیت قبلی ساخته شد. این فرآیند توسط الگوریتم ازدحام ذرات آنقدر ادامه می یابد تا جواب های بهینه تعیین شوند.


در شکل (۳) کمترین مقدار کمینه مربعات خطا را در برابر تکرارهای الگوریتم ازدحام ذرات نشان می دهد. همان گونه که از این شکل مشخص است پس از ۳۰ تکرار مقدار کمینه مربعات خطا ثابت می شود و دیگر تغییر نمی کند که نشان می دهد که الگوریتم به مقادیر کمینه پارامترها همگرا شده است. مقادیر بهینه پارامتر گسترش و بیشینه نورون های لایه میانی به ترتیب ۰,۷۸ و ۴۱ به دست آمد. با استفاده از این دو پارامتر مدل پایه شعاعی برای پیش بینی داده ها ساخته شد و دقت آن با سایر مدل ها مورد مقایسه قرار گرفت.

۳- روش اجرای تحقیق و ساخت مدل

این مدل دارای سه لایه می باشد که لایه میانی یا لایه پنهان می تواند یک یا چند زیرلایه داشته باشد. اما طبق کارها و تحقیقات انجام گرفته اثبات شده است که انتخاب یک زیرلایه برای لایه میانی برای پیش بینی داده ها با دقت قابل قبول کافی می باشد. در این تحقیق نیز برای پیش بینی داده ها از یک لایه میانی استفاده شد. در لایه میانی از تابع تانژانتی و در لایه خروجی از تابع خطی استفاده شد.

در این شبکه ها تعداد نورون های درون لایه میانی یک پارامتر مهم در میزان دقت مدل می باشد. در این پروژه تعداد نورون های لایه میانی از ۴ نورون تا ۲۵ نورون تغییر داده شد و در هر حالت دقت شبکه ها مورد بررسی قرار گرفت. دقت شبکه ها از طریق محاسبه کمینه مربعات خطا بین داده های اصلی و داده های پیش بینی شده توسط مدل برای بخش های آموزش، تست و کل داده ها محاسبه شد.

شکل (۲) نمودار مربعات کمینه خطا را برای داده های آموزش، تست و کل داده ها بر حسب تعداد نورون های لایه میانی نشان می دهد. همان گونه که در این شکل مشخص است کمترین میزان مقادیر کمینه مربعات خطا در تعداد نورون های برابر با ۲۲ اتفاق می افتد که نشان می دهد شبکه با این تعداد نورون در لایه میانی بالاترین دقت را دارا می باشد. بنابراین این مدل برای پیش بینی داده ها و مقایسه با سایر مدل ها انتخاب شد.



شکل (۲) : تغییر کمینه مربعات خطا بر حسب تعداد نورون های لایه ورودی برای داده های تست، آموزش و کل داده ها

جدول (۱) اطلاعات آماری داده های استفاده شده برای مقایسه مدل های ساخته (۱)

پارامتر	نوع پارامتر	کمینه	میانگین	بیشینه
قطر چاه (اینچ)	ورودی	۶,۱۳	۲۰,۵۸	۳۲,۰۰
سرعت تزریق گل (بشکه بر دقیقه)	ورودی	۲۰۰,۰۰	۷۷۶,۶۷	۱۱۰۰,۰۰
سرعت چرخش رشته حفاری (دور بر دقیقه)	ورودی	۴۰,۰۰	۱۲۳,۵۴	۲۰۰,۰۰
وزن روی مته (کیلو پوند)	ورودی	۲,۵۰	۲۱,۴۶	۷۰,۰۰
گشتاور (کیلو فوت در پوند)	ورودی	۱,۵۰	۶,۹۳	۱۵,۰۰
عمق (متر)	ورودی	۴۳,۰۰	۴۸۷۳,۷۲	۱۵۴۲۲,۵
وزن گل (پوند بر فوت مکعب)	ورودی	۶۲,۴۰	۸۸,۵۳	۱۳۸,۰۰
ویسکوزیته قیف (ثانیه)	ورودی	۲۶,۰۰	۳۹,۶۸	۶۰,۰۰
ویسکوزیته پلاستیک (سنٹی پویز)	ورودی	۴,۰۰	۱۵,۷۵	۴۱,۰۰
نقطه واروی (پوند بر ۱۰۰ فوت مربع)	ورودی	۰,۰۰	۱۵,۳۰	۲۶,۰۰
نسبت ژل ۱۰ ثانیه بر ۱۰ دقیقه	ورودی	۰,۴۰	۰,۶۸	۰,۸۸
هرزروی سیال (سی سی در ۳۰ دقیقه)	ورودی	۱,۶۰	۱۴,۴۱	۴۸,۰۰
سرعت حفاری (متر بر ساعت)	خروجی	۰,۰۲	۳,۰۲	۲۳,۳۲

در تحقیق حاضر از ۳۱۱ داده سرعت حفاری یکی از میادین ایران استفاده شد و مقادیر سرعت حفاری بر اساس این داده ها و با استفاده از الگوریتم های هوش مصنوعی پیش بینی شدند. به منظور پیش بینی مقدار سرعت حفاری با استفاده از داده های میدانی از چند پارامتر ورودی شامل عمق (متر)، قطر چاه (اینچ)، سرعت تزریق گل (بشکه بر دقیقه)، سرعت چرخش رشته حفاری (دور در دقیقه)، وزن روی مته (کیلو پوند)، گشتاور (کیلو فوت در پوند)، وزن گل (پوند بر فوت مکعب)، ویسکوزیته قیف (ثانیه)، ویسکوزیته پلاستیک (سنٹی پویز)، نقطه واروی (پوند بر ۱۰۰ فوت مربع)، نسبت ژل ۱۰ ثانیه بر ۱۰ دقیقه و هرزروی سیال (سی سی در ۳۰ دقیقه) استفاده شد. همچنین مقدار سرعت حفاری (متر بر ساعت) نیز به عنوان پارامتر خروجی مدل ها در نظر گرفته شد. پارامترهای آماری مربوط به داده های مورد استفاده در جدول (۱) آورده شده است. این پارامترهای آماری شامل بیشینه مقدار داده، کمترین مقدار داده و میانگین داده مورد استفاده می باشد. به منظور ساخت مدل های مختلف ابتدا کل داده ها به دو زیر مجموعه داده های آموزش و داده های تست تقسیم شدند. برای قسمت آموزش از ۸۰ درصد داده ها و برای بخش تست از ۲۰ درصد باقی مانده داده ها استفاده شد. تعداد داده های مربوط به بخش های آموزش و تست و کل داده ها در جدول (۲) نمایش داده شده است.


جدول (۲): تعداد داده های استفاده شده برای مدل سازی و صحت آزمایی مدل های ساخته شده

نوع داده ها	تعداد
آموزش	۱۸۵
تست	۴۶
تعداد کل داده ها	۲۳۱

۵- بررسی دقت مدل های مختلف

در این پروژه برای مدل سازی سرعت حفاری از دو مدل به نام های شبکه عصبی چند لایه (MLP) و شبکه عصبی پایه شعاعی (RBF) استفاده شد. در ادامه با استفاده از روش های مختلف به بررسی دقت هر مدل در مقایسه با سایر مدل ها برای پیش بینی داده ها پرداخته می شود.

۵-۱ شبکه عصبی چند لایه



شکل (۳) : عملکرد الگوریتم ازدحام ذرات برای بهینه سازی پارامترهای شبکه RBF

۴- تجزیه و تحلیل داده ها

$$\%AARD = \frac{100}{N} \sum_{i=1}^N \left| \frac{(\lambda_{Pred}(i) - \lambda_{Exp}(i))}{\lambda_{Exp}(i)} \right|$$

فرمول ۱۲

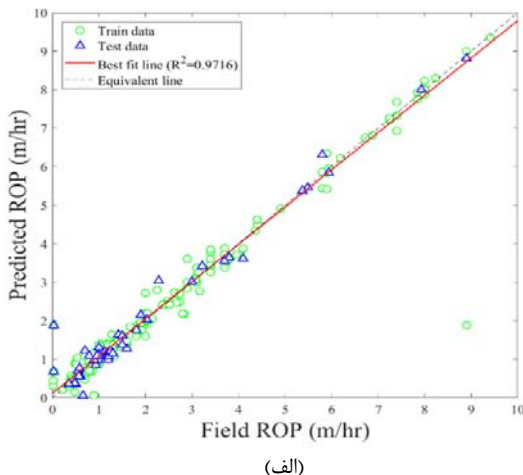
$$RMSE = \left(\frac{\sum_{i=1}^N (\lambda_{Pred}(i) - \lambda_{Exp}(i))^2}{N} \right)^{0.5}$$

در این روابط مقدار پیش بینی شده سرعت حفاری توسط مدل، مقدار اصلی سرعت حفاری و N تعداد داده ها را نمایش می دهد.

۵-۲- شبکه عصبی پایه شعاعی

همانگونه که قبلاً اشاره شد این مدل دارای دو پارامتر بیشینه تعداد نورون ها و عدد گسترش می باشد که با استفاده از الگوریتم ازدحام ذرات مقادیر بهینه آنها ۴۱ و ۰/۷۸ به دست آمد. با استفاده از این دو مقدار مدل بر اساس داده های آموزش، آموزش داده شده و ساخته شد و با استفاده از داده های تست پیش بینی های این مدل مورد بررسی قرار گرفت.

کراس پلات مربوط به این مدل در شکل (۴) نمایش داده شده است. بر اساس این شکل مقدار ضریب همبستگی این مدل برابر با ۰/۹۷۹۵ می باشد که مقدار بالایی می باشد و نشان می دهد که مدل دارای دقت قابل قبولی است. همچنین این مدل دارای ضریب همبستگی بالاتری نسبت به مدل MLP می باشد که این نشان می دهد که دقت مدل RBF از مدل MLP در پیش بینی داده های سرعت حفاری بالاتر می باشد. شکل (۵) نیز نمودار خطای نسبی مدل RBF این مدل را نشان می دهد.



پس از تعیین تعداد نورون های لایه ورودی، به منظور ساخت این مدل از داده های آموزش استفاده شد و پس از ساخت مدل عملکرد و دقت آن با استفاده از داده های تست مورد بررسی و ارزیابی بیشتر قرار گرفت. کراس پلات داده های پیش بینی شده سرعت حفاری در برابر مقادیر اصلی در شکل (۵-۱) (الف) نمایش داده شده است.

ضریب همبستگی مربوط به این مدل برابر ۰/۹۷۱۶ می باشد که به دلیل اینکه این مقدار به عدد ۱ که بیشترین مقدار برای ضریب همبستگی می باشد، خیلی نزدیک است، می توان نتیجه گرفت که این مدل دقت قابل قبولی برای پیش بینی داده های سرعت حفاری دارد.

توزیع فشرده داده ها در اطراف خط نیمساز ربع اول و سوم یا همان خط $Y=X$ نیز نشان می دهد که مدل برای پیش بینی دقیق داده های سرعت حفاری دقت مناسبی دارد. نمودار درصد خطای نسبی داده های پیش بینی شده به وسیله مدل در برابر داده های سرعت حفاری اصلی در شکل (۵-۱) (ب) نمایش داده شده است.

در این شکل خطای نسبی توسط رابطه زیر محاسبه شده است:
فرمول ۱۰

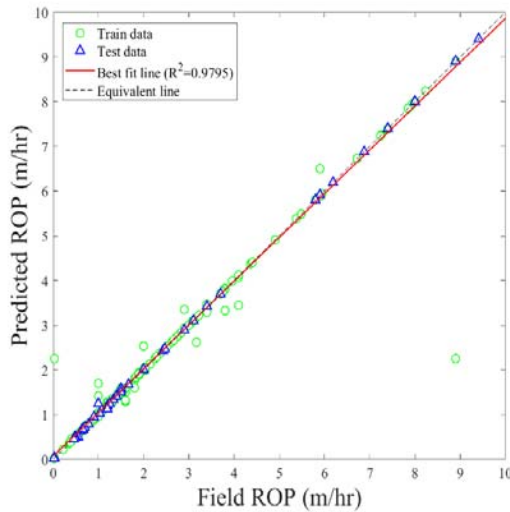
$$RE = 100 \times \frac{(\lambda_{Pred}(i) - \lambda_{Exp}(i))}{\lambda_{Exp}(i)}$$

در این روابط مقدار پیش بینی شده سرعت حفاری توسط مدل، مقدار اصلی سرعت حفاری و RE مقدار خطای نسبی را مشخص می کند. با توجه به این شکل مدل بیشتر داده ها را با خطایی کمتر از $\pm 15\%$ درصد پیش بینی کرده است که نشان می دهد مدل قادر است داده ها را با خطای قابل قبول و دقت مناسب پیش بینی کند.


پارامترهای آماری مربوط به این مدل نیز در جدول (۵-۲) نمایش داده شده است. این پارامترهای آماری عبارتند از ضریب همبستگی (R^2)، میانگین خطای نسبی (AARD) و جذر کمینه مربعات خطا (RMSE) که برای محاسبه این پارامترها از روابط زیر استفاده می کنیم:

فرمول ۱۱

$$R^2 = 1 - \frac{\sum_{i=1}^N (\lambda_{Pred}(i) - \lambda_{Exp}(i))^2}{\sum_{i=1}^N (\lambda_{Pred}(i) - \bar{\lambda}_{Exp})^2}$$




(الف)



(ب)

شکل (۴) : (الف) نمودار متقاطع نشان دهنده ضریب همبستگی بین سرعت حفاری و سرعت حفاری پیش بینی شده توسط شبکه MLP برای داده های آموزش و تست. (ب) نمودار نشان دهنده خطای نسبی برای داده های آموزش و تست مربوط به شبکه طراحی شده MLP.



(ب)

شکل (۵) : (الف) نمودار متقاطع نشان دهنده ضریب همبستگی بین سرعت حفاری میدانی و سرعت حفاری پیش بینی شده توسط شبکه RBF (ب) نمودار نشان دهنده خطای نسبی برای داده های آموزش و تست مربوط به شبکه طراحی شده RBF

جدول (۳) : پارامترهای آماری مربوط به شبکه عصبی MLP

نوع داده	ضریب همبستگی (R^2)	درصد میانگین خطای نسبی (AARD)	جذر کمینه مربعات خطا (RMSE)
داده های آموزش	۰/۹۸۳۹	۱۳/۷۵	۰/۲۵۸
داده های تست	۰/۹۵۶۰	۱۲/۲۱	۰/۴۰۱
کل داده ها	۰/۹۷۱۶	۱۲/۵۱	۰/۳۷۶

بر اساس شکل (۵) (ب) بیشترین میزان خطای نسبی مدل برابر با ۴۵ درصد می باشد و بیشتر داده ها دارای خطای نسبی بین منفی ۱۰ درصد و مثبت ۱۰ درصد می باشند که نشان می دهد مدل دارای دقت بالایی می باشد. همچنین مقادیر پارامترهای آماری این مدل در جدول (۵-۲) خلاصه شده اند.

جدول (۴) : پارامترهای آماری مربوط به شبکه عصبی RBF

نوع داده	ضریب همبستگی (R^2)	درصد میانگین خطای نسبی (AARD)	جذر کمینه مربعات خطا (RMSE)
داده های آموزش	۰/۹۸۹۵	۸/۴۶	۰/۲۰۰۴
داده های تست	۰/۹۶۴۱	۱۲/۱۶	۰/۲۰۱۳
کل داده ها	۰/۹۷۹۵	۹/۴۲	۰/۲۰۰۶

۶- بحث و نتیجه گیری

یکی از مهم ترین پارامترها در فرآیند حفاری، سرعت حفاری می باشد. با توجه به هزینه بالای حفاری چاه ها، ساخت مدل های دقیق و موثر برای پیش بینی و بهینه سازی این پارامتر یعنی سرعت حفاری بسیار حائز اهمیت است. در این تحقیق، سرعت حفاری نسبی حاصل از اطلاعات میدانی توسط شبکه های هوشمند مدل سازی شد و نتایج مطلوبی به دست آمد. نتایج حاصل از شبیه های هوشمند به کار گرفته شده در این تحقیق در جدول (۵) آمده است. در این جدول در ستون اول مدل های به کار رفته مشخص شده است. در ستون دوم نوع داده های مربوط به مدل آورده شده است که همانگونه که قبلاً در بخش ایجاد مدل ها اشاره شد، این داده ها به سه دسته آموزش، تست و کل داده ها تقسیم می شوند. در ستون های سوم تا ششم نیز پارامترهای آماری به ترتیب R^2 ، AARD و RMSE آورده شده اند. همانگونه که در این جدول مشخص است، مدل RBF نسبت به مدل MLP دارای مقادیر R^2 بیشتر و مقادیر AARD و RMSE کم تر می باشد. این نشان می دهد که مدل RBF نسبت به مدل MLP دقیق تر است و دقت بالاتری دارد.

جدول (۵) : پارامتر های آماری تخمین گر های مختلف سرعت حفاری.

نوع شبکه	نوع داده	R^2	AARD	RMSE
MLP	داده های آموزش	۰/۹۸۳۹	۱۳/۷۵	۰/۲۵۸
	داده های تست	۰/۹۵۶۰	۱۲/۲۱	۰/۴۰۱
	کل داده ها	۰/۹۷۱۶	۱۲/۵۱	۰/۳۷۶
RBF	داده های آموزش	۰/۹۸۹۵	۸/۴۶	۰/۲۰۰۴
	داده های تست	۰/۹۶۴۱	۱۲/۱۶	۰/۲۰۱۳
	کل داده ها	۰/۹۷۹۵	۹/۴۲	۰/۲۰۰۶

همان طور که در جدول (۵) نشان داده شده است، RBF به دلیل دارا بودن مقدار بالاتر R^2 و مقدار پایین تر AARD نسبت به شبکه MLP دقیق تر است.

۶-۱- نتایج

۵-۳- حساسیت سنجی

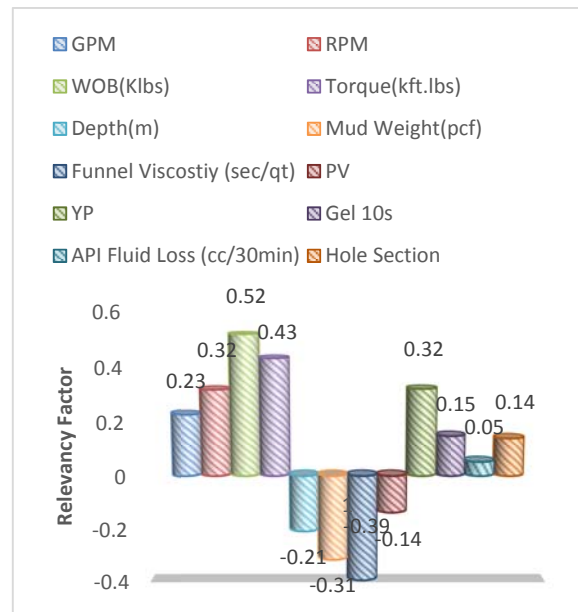
در این تحقیق به منظور بررسی تاثیر پارامترهای مختلف بر میزان سرعت حفاری از آنالیز حساسیت سنجی به روش پیرسون استفاده شد.

مطابق شکل (۶) آنالیز رابطه بین پارامترهای ورودی و پارامتر خروجی مدل مشخص شده که در بهینه سازی فرآیند حفاری و انتخاب بهینه پارامترهای حفاری و سیال بسیار پر کاربرد است.

در این روش رابطه بین پارامترهای ورودی و خروجی از طریق پارامتری به نام پارامتر ارتباط مشخص می شود. این پارامتر مقداری بین -۱ تا ۱ را شامل می شود. مقادیر منفی بیانگر این است که بین پارامتر ورودی و خروجی یک ارتباط معکوس وجود دارد. به عبارت دیگر افزایش پارامتر ورودی باعث کاهش در پارامتر خروجی می شود.

مقادیر مثبت این پارامتر به معنی وجود ارتباط مستقیم بین پارامتر ورودی و خروجی می باشد. به عبارت دیگر با افزایش پارامتر ورودی، پارامتر خروجی نیز افزایش می یابد.

هر چه مقدار این پارامتر بیشتر باشد به معنای این است که تاثیر پارامتر ورودی بر پارامتر خروجی نیز بیشتر است. نمودار مقدار پارامتر ارتباط برای ورودی های مختلف به منظور پیش بینی سرعت حفاری با استفاده از مدل RBF به عنوان مدل دقیق تر در شکل زیر نمایش داده شده است.



شکل (۶) : حساسیت سنجی پارامترهای مختلف موثر بر سرعت حفاری

- of a residential HVAC system. Energy and Buildings, 2017. 141: p. 96-113.
- [5] Afram, A., et al., Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system. Energy and Buildings, 2017. 141: p. 96-113.
- [6] Parali, L., et al., The artificial neural network modelling of the piezoelectric actuator vibrations using laser displacement sensor. Journal of Electrical Engineering, 2017. 68(5): p. 371-377.
- [7] Chen, W., H.R. Pourghasemi, and Z. Zhao, A GIS-based comparative study of Dempster-Shafer, logistic regression and artificial neural network models for landslide susceptibility mapping. Geocarto international, 2017. 32(4): p. 367-385.
- [8] Zhang, Z., Artificial neural network, in Multivariate Time Series Analysis in Climate and Environmental Research. 2018, Springer. p. 1-35.
- [9] Cortes, C., et al., Adanet: Adaptive structural learning of artificial neural networks. arXiv preprint arXiv:1607.01097, 2016.
- [10] Turing, A., Intelligent machinery. B. Jack Copeland, 1953: p. 395.
- [11] Rosenblatt, F., Perceptions and the theory of brain mechanisms. 1962
- [12] Widrow, B. and M.E. Hoff, Adaptive switching circuits. 1960, STANFORD UNIV CA STANFORD ELECTRONICS LABS.
- [13] Kohonen, T., Correlation matrix memories. IEEE transactions on computers, 1972. 100(4): p. 353-359.
- [14] Grossberg, S., Nonlinear neural networks: Principles, mechanisms, and architectures. Neural networks, 1988. 1(1): p. 17-61.

- مدل های هوش مصنوعی قادرند که ارتباط و الگوی میان پارامترهای ورودی و خروجی را که روابط کاملاً غیرخطی دارند به خوبی تشخیص داده و پیش بینی دقیقی از مقادیر خروجی ارائه دهند. همان گونه در تحقیق حاضر نشان داده شد؛ با وجود اینکه رابطه بین میزان سرعت حفاری و سایر اطلاعات یک میدان کاملاً غیرخطی است؛ اما مدل های هوش مصنوعی RBF و MLP قادرند به خوبی این ارتباط غیرخطی را تشخیص داده و پیش بینی هایی با مقادیر R^2 بالا و مقادیر AARD و RMSE پایین ارائه دهند.
- مقادیر پارامترهای آماری ضریب همبستگی، میانگین خطای نسبی و جذر کمینه مربعات خطا برای مدل MLP به ترتیب برابر با ۰/۹۷۱۶، ۱۲/۵۱ و ۰/۴۰۱ به دست آمد. مقادیر این پارامترها برای مدل RBF به ترتیب برابر ۰/۹۷۹۵، ۹/۴۲ و ۰/۲۰۰۶ به دست آمد.
- با توجه به پارامترهای آماری اگرچه مدل های مختلف دقت قابل قبولی برای پیش بینی داده های سرعت حفاری حاصل از اطلاعات میدانی ارائه می دهند، می توان نتیجه گرفت.
- مدل RBF به دلیل مقدار R^2 بالاتر و مقادیر AARD و RMSE پایین تر نسبت به مدل MLP دقیق تر است.

۷- منابع و مراجع

- [1] Mohaghegh, S., Virtual-Intelligence Applications in Petroleum Engineering: Part 1 Artificial Neural Networks. Journal of Petroleum Technology, 2000. 52(9): p. 64-73
- [2] Hertz, J.A., A.S. Krogh, and R.G. Palmer, Introduction to the theory of neural computation. Vol. 1. 1991, Addison-Wesley Publishing Company: Westview press.
- [3] Pchelintseva, S.V., et al. Recognition and classification of oscillatory patterns of electric brain activity using artificial neural network approach. in Dynamics and Fluctuations in Biomedical Photonics XIV. 2017. International Society for Optics and Photonics.
- [4] Afram, A., et al., Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study