

مقاله پژوهشی

ارائه مدلی برای پیش‌بینی نرخ نفوذ حفاری در میدان نفتی شادگان با استفاده از شبکه عصبی مصنوعی

آرش ابراهیم آبادی*

دانشیار، گروه مهندسی نفت، معدن و مواد، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

دریافت مقاله: ۱۴۰۱/۰۳/۱۸ پذیرش مقاله: ۱۴۰۱/۰۶/۰۸

شناسه دیجیتال (DOI): 10.22107/jpg.2022.189126.1098

چکیده

واژگان کلیدی

امروزه در هر پروژه مباحث هزینه و زمان از اهمیت بالایی برخوردار می‌باشند، بنابراین در صنعت حفاری نیز که یکی از پرهزینه‌ترین صناعت‌ها به شمار می‌رود، باید اقداماتی مقتضی در خصوص صرفه‌جویی در زمان و هزینه صورت پذیرد. در عملیات حفاری، با انتخاب صحیح ابزار مورد استفاده و هم‌چنین پیش‌بینی دقیق و به موقع پارامترها و مشکلات احتمالی می‌توان این عملیات را در زمان و هزینه کمتر انجام داد. در این راستا یکی از موثرترین راهکارها تحلیل اطلاعات میدانی و به‌دنبال آن توسعه و بهبود ابزارهای این تحلیل‌ها می‌باشد. در صنعت حفاری برای شناسایی مشکل و بهبود عملکرد حفاری عموماً یا از آزمون‌های آزمایشگاهی و روابط تجربی استفاده می‌شود و یا از تجربیات گذشته بهره گرفته می‌شود. در این تحقیق سعی شد از روش‌های نوین و مدل‌سازی هوشمند برای پیش‌بینی نرخ نفوذ در عملیات حفاری استفاده شود که بدین منظور از روش شبکه عصبی مصنوعی استفاده شد. در این مقاله با استفاده از شبکه عصبی مصنوعی و داده‌های حفاری میدان نفتی شادگان (۴۰۰ داده) و در سازند آغاچاری اقدام به ساخت مدلی جهت پیش‌بینی نرخ نفوذ حفاری شد و سپس نتایج حاصل با نتایج بدست آمده از مدل‌سازی با رگرسیون چند متغیره مقایسه شد. برای ارزیابی خصوصیات اصلی مدل بدست آمده و صحت‌سنجی آن از داده‌های چاه‌های مجاور استفاده شد. نتایج تحقیق نشان داد که ضریب همبستگی برای شبکه عصبی ۰/۹۷ و ضریب تعیین آن ۰/۹۴ بدست آمد در حالی که در تحلیل آماری، مقدار ضریب همبستگی ۰/۹۴ و ضریب تعیین برابر با ۰/۸۹ می‌باشد که این امر دقت بالاتر مدل‌سازی با شبکه عصبی را نشان می‌دهد.

شبکه عصبی مصنوعی،
پیش‌بینی، نرخ نفوذ، ضریب
همبستگی، ضریب تعیین،
میدان نفتی شادگان

۱. پیش‌گفتار

که با توجه به وابسته بودن هزینه‌های عملیات حفاری به زمان، با کاهش زمان عملیات از طریق افزایش نرخ نفوذ مته می‌توان به میزان قابل توجهی در هزینه‌ها صرفه‌جویی نمود. استفاده از مدل‌های ریاضی تعیین نرخ نفوذ مته به‌منظور تعیین مقادیر بهینه پارامترهای حفاری و افزایش نرخ نفوذ مته با توجه به دسترس بودن اطلاعات از داده‌های چاه‌های مجاور، صرفه‌جویی قابل ملاحظه‌ای را در هزینه‌ها به دنبال داشته و با توجه به قابل استفاده بودن آن‌ها در حین عملیات و متناسب با محدودیت‌های احتمالی، کاربرد آن‌ها را بیش از پیش توجیه می‌کند. حال آنچه اهمیت دارد این است که بتوان بهترین

از حدود چهار دهه پیش لزوم بهینه‌سازی عملیات حفاری به طور جدی احساس و مدل‌هایی جهت برآورد سرعت حفاری ارائه گردید. در هریک از مدل‌های ارائه شده بسته به شرایط آزمایشگاهی و یا عملیاتی فقط بعضی از عوامل موثر بر نرخ حفاری به‌کار گرفته شده است، که خود به نوعی می‌تواند باعث بروز خطا گردد، از طرفی هم اجتناب از این امر امکان‌پذیر نیست [۱]. تحلیل اطلاعات میدانی به منظور رسیدن به مقادیر بهینه پارامترهای حفاری برای افزایش نرخ نفوذ مته همواره مورد نظر بوده است. اهمیت این موضوع در این است

* تهران، خیابان اشرفی اصفهانی، بالاتر از میدان پونک، بلوار امام حسن مجتبی (ع)، مجتمع دانشگاهی آیت الله هاشمی رفسنجانی، دانشکده مهندسی عمران و منابع زمین، گروه مهندسی نفت، معدن و مواد، a.abrahimabadi@iauctb.ac.ir

مروجی و همکاران در سال ۲۰۱۶ با جمع‌آوری داده‌های حفاری میدان‌های نفتی درباره پیش‌بینی نرخ نفوذ حفاری و بهینه‌سازی آن با استفاده از روش پاسخ سطحی و بت الگوریتم و تأثیر همزمان شش متغیر بر میزان نفوذ مطالعاتی انجام دادند و تأثیر این پارامترها را بر نرخ نفوذ بررسی نمودند [۸].

عامر و همکاران در سال ۲۰۱۷ از شبکه‌های عصبی مصنوعی (*Artificial Neural Network*) برای پیش‌بینی نرخ نفوذ حفاری (*Rate Of Penetration*) برای بهینه‌سازی انتخاب مته بهره‌گرفتند [۹].

خاکسار منشاد و همکاران در سال ۲۰۱۷ برای بهینه‌سازی عملیات حفاری از شبکه‌های عصبی درک چند لایه (*Multi-Layer Perceptron*) استفاده کردند. دو مدل با استفاده از شبکه‌های عصبی برای تعیین نوع مته و میزان نفوذ حفاری توسعه داده شد. سپس ورودی‌های مدل دوم توسط الگوریتم ژنتیک (*Genetic Algorithm*) برای دسترسی به حداکثر میزان نفوذ بهینه‌سازی شد. برای پیش‌بینی نوع مته و میزان نفوذ در مرحله آزمایش، ضرایب همبستگی را به ترتیب برابر با ۰/۹۸ و ۰/۹۶ بدست آوردند [۱۰].

در خصوص آخرین مطالعات در زمینه کاربرد شبکه عصبی در مهندسی حفاری نفت، پریانگا (*Priyanga*) و رولیاندی (*Ruliandi*) در سال ۲۰۱۸ از روش‌های نوین (اعمال دسته‌بندی و ایجاد الگوی تولید) در شبکه عصبی برای پیش‌بینی نرخ نفوذ حفاری استفاده نمودند. در تحلیل‌های ایشان، شبکه با انجام تمرین برای هر مجموعه داده‌ها و الگوی تولید با لایه‌های پنهان شروع می‌شود و سپس چندین مجموعه داده به صورت تصادفی انتخاب می‌شوند. به این ترتیب همراه با داده‌های آموزشی خوب و کافی و اندازه‌گیری مستقل برای اعتبار سنجی، از شبکه عصبی می‌تواند برای توسعه یک برنامه عملکرد خوب بهره‌برد و مدلی قابل قبول با قابلیت اعتماد بالا ارائه نمود [۱۱].

آسترینی (*Astrini*) و همکاران در سال ۲۰۱۹ نشان دادند در پیش‌بینی نرخ نفوذ حفاری پارامترهای عمق عمودی، وزن روی مته و نرخ چرخش مته بیشترین تأثیر را در پیش‌بینی نرخ نفوذ دارند. ایشان نشان دادند تنها با اندازه‌گیری و دخالت دادن این داده‌ها به عنوان ورودی و آموزش آن‌ها می‌توان نرخ نفوذ را به عنوان خروجی با دقتی بالا و قابل قبول پیش‌بینی کرد. نتایج تحقیق آن‌ها نشان داد نه تنها انتخاب پارامترها

مدل را در میدان مورد نظر تعیین نمود تا در حفاری چاه‌های بعدی از آن به منظور پیش‌بینی نرخ نفوذ مته استفاده نمود [۲].

افزایش و بهینه‌سازی سرعت حفاری به عوامل زیادی وابسته است که به دو دسته تقسیم می‌شوند. دسته اول شامل پارامترهای حفاری و دسته دوم پارامترهای سازند می‌باشند. گروه اول شامل وزن روی مته، گشتاور، سرعت چرخش و پارامترهای هیدرولیکی مانند میزان جریان، چگالی و رئولوژی مایع حفاری و دومین گروه شامل تنش‌های محلی، فشردگی سنگ، کانی‌شناسی و مایعات سازند می‌باشد بنابراین به منظور رسیدن به سرعت بهینه، یک تخمین خوب از پارامترهایی که اثر قابل توجه دارند ضروری است [۳].

عمده مطالعات پیشین بر مبنای پارامترهای حفاری - وزن روی مته، قطر مته و سرعت چرخش - انجام پذیرفته است. در خصوص دخالت دادن پارامترهای سازند نیز یلماز (*Yilmaz*) در سال ۲۰۰۲ با استفاده از مقاومت فشاری متوسط سازند، مدلی را توسعه داد اما فقط بر روی انتخاب مته کار کرد و بر روی ارزیابی دیگر مقادیر پارامترهای حفاری و چگونگی افزایش نرخ نفوذ حفاری نتیجه‌ای انجام نداد [۴].

بعدها عدالت‌خواه و همکاران در سال ۲۰۱۲ این مدل را توسعه داده و علاوه بر انتخاب مته، نرخ نفوذ حفاری را نیز بهینه کردند [۵]. شایان ذکر است که اکثر مطالعات بر اساس تحلیل‌های آماری بوده و کمتر از روش‌های هوشمند چون شبکه عصبی مصنوعی بهره‌گرفته شده است که جنبه نوآوری دارد. در این راستا انجام چنین تحقیقاتی در میدان نفتی شادگان برای اولین بار نیز بسیار حائز اهمیت است.

نوروزی و همکاران در سال ۱۳۹۳ با مطالعه بر عملکرد حفاری در یکی از چاه‌های میدان نفتی آزادگان نشان دادند پارامترهای ژئومکانیکی نقش به‌سزایی در پیش‌بینی نرخ نفوذ حفاری دارد و پیش‌بینی دقیق‌تری را بدست می‌دهد [۶].

مشعشعی و همکاران در سال ۱۳۹۷ با جمع‌آوری و تهیه یک بانک اطلاعاتی از داده‌های میدانی از جمله عمق چاه، وزن روی مته، سرعت چرخش مته، فشار لوله حفاری و وزن روی قلاب (*WOH-Weight On Hookload*) در یکی از میدانی جنوب ایران مبادرت به پیش‌بینی نرخ نفوذ حفاری با استفاده از روش‌های هوشمند نمودند و نهایتاً ابزاری گرافیکی بدین منظور توسعه دادند [۷].

که در این رابطه، ROP نرخ نفوذ حفاری، f_1 تا f_8 به ترتیب نشان دهنده‌ی تاثیر قدرت سازند، تراکم و فشردگی، اختلاف فشار، وزن روی مته، سرعت چرخش مته، فرسایش دندان‌ها و هیدرولیک مته می باشد که هر کدام دارای روابطی جهت محاسبه می‌باشند. اخیراً نیز مطالعات ارزنده‌ای با استفاده از روش‌های نوین در خصوص تعیین ضرایب ثابت این مدل ارائه شده است [۱۵].

۱.۲. مدل بایر (Bayer) و کالدر (Calder)

در سال ۱۹۶۷ این مدل بر اساس مطالعات تجربی در آمریکای شمالی ارائه گردید [۱۶]:

$$R = \frac{W RPM}{d \cdot 300} (61 - 28 \log \sigma) \quad (2)$$

در رابطه فوق، R : سرعت حفاری (ft/hr)، σ : مقاومت فشاری تک محوری سنگ، W : بار روی مته (1000 lbf)، d : قطر مته (in) و RPM : دور مته (rev/min) می‌باشند.

۲.۲. مدل وارن (Warren)

این مدل آزمایشگاهی در سال ۱۹۸۷ ارائه گردید و به شکل زیر می باشد [۱۷]:

$$\frac{S^2 d^3 a}{W^2 N} + \frac{b}{d_b N} + \frac{d \gamma c \mu}{F_{jm}} = \frac{1}{R} \quad (3)$$

که در آن R : نرخ حفاری (ft/hr)، a, b, c : ثابت بدون بعد، S : مقاومت حفاری (psi)، γ : وزن مخصوص سیال (بدون بعد)، d : قطر مته (in)، F_{jm} : نیروی ضربه تعدیل یافته جت (lbf)، N : سرعت دورانی مته (rev/min) و W : وزن روی مته (lbf) می‌باشند.

۳.۲. مدل کانینگهام (Cunningham)

این مدل در سال ۱۹۹۰ توسط آزمایشات انجام شده توسط کانینگهام بدست آمده است و ارتباط بین نرخ حفاری و بار روی مته، مقاومت فشاری سنگ، دور مته و اختلاف فشار بین ستون گل و سازند را نشان می‌دهد [۱۸]:

مهم است بلکه دامنه داده‌هایی که وارد شبکه می‌شوند هم مهم بوده همچنین داده‌هایی که پرت (داده‌های نویز) باید حذف شده و از ورود آنها به شبکه خودداری نمود [۱۲]. همچنین با توجه به اهمیت خصوصیات ژئومکانیکی سازند در ارزیابی عملکرد حفاری می‌توان برای انتخاب پارامترهای ژئومکانیکی موثر در مدل‌سازی‌ها از آخرین دستاوردها در زمینه مدل‌سازی‌های ژئومکانیکی بهره گرفت [۱۳]. در زمینه مدل‌های پیش‌بینی نرخ نفوذ حفاری در بخش بعدی اهم این مدل‌ها معرفی شده است.

در این تحقیق سعی شد اثر همزمان متغیرهای موثر بر نرخ نفوذ حفاری با استفاده از داده‌های حفاری میدان نفتی شادگان مورد بررسی قرار گیرد. این متغیرها عبارتند از: وزن روی مته، سرعت چرخش مته، وزن گل حفاری و گشتاور که در این تحقیق برای مدل‌سازی در نظر گرفته شده است. وجه تمایز در این تحلیل، انجام چنین مطالعه‌ای در میدان نفتی شادگان و نیز دخالت دادن پارامتر موثر گشتاور است که بدین منظور مدل‌سازی نرخ نفوذ حفاری با استفاده از شبکه‌های عصبی مصنوعی و با توجه به اثر همزمان متغیرهای ذکر شده انجام می‌پذیرد. در ادامه در ابتدا مدل‌های مهم پیش‌بینی نرخ نفوذ حفاری معرفی شده و سپس تحلیل آماری بر روی داده‌های حفاری میدان نفتی شادگان صورت گرفته و نهایتاً پس از حذف داده‌های پرت، مدل‌سازی با شبکه عصبی مصنوعی انجام و دقت این مدل برای میدان مزبور بررسی شده است.

۲. مدل‌های مهم پیش‌بینی نرخ نفوذ حفاری

مدل‌های ریاضی بسیاری برای برقراری رابطه‌ای بین این پارامترهای متغیر و نرخ نفوذ در سنگ وجود دارد. اکثر آنها ترکیبی از متغیرهای اولیه‌ی قابل کنترل و خصوصیات سازند هستند. متداول‌ترین رابطه برای مدل‌سازی چنین روابطی معادله‌ی بورگینه و یانگ خواهد بود. در زیر به ذکر روابط بورگینه و یانگ پرداخته می‌شود. این مدل در سال ۱۹۸۴ برای ایجاد رابطه بین نرخ در سنگ و عوامل متغیر اولیه از قبیل رسوب گذاری و مقاومت، فشار شکست، وزن روی مته، سرعت دورانی، هیدرولیک مته، فرسایش دندان‌های مته و ... معرفی شد [۱۴]. این مدل به صورت زیر است:

$$ROP = f_1 \times f_2 \times f_3 \times f_4 \times f_5 \times f_6 \times f_7 \times f_8 \quad (1)$$


خروجی سلول تبدیل می‌کند، تابع انتقال را تابع تحریک نیز می‌نامند. شبکه‌های عصبی ساختار لایه‌ای دارند. اولین لایه، لایه ورودی است و لایه آخر، لایه خروجی می‌باشد. داده‌ها در سلول‌های لایه ورودی جای می‌گیرند. لایه ورودی کار خاصی انجام نمی‌دهد و صرفاً داده‌های ورودی را در قسمت خروجی خود کپی می‌کند. پس از جمع‌آوری داده‌های مورد نیاز، اقدام به طراحی و تولید شبکه عصبی مورد نظر خواهد شد.

۴. میدان نفتی شادگان

میدان نفتی شادگان از میداین نفتی جنوب ایران است که در محدوده شهرستان شادگان، در استان خوزستان و در فاصله ۶۰ کیلومتری از جنوب غربی اهواز قرار دارد (شکل ۱). این میدان در سال ۱۳۴۷ کشف شد و بهره‌برداری از آن در سال ۱۳۶۷ آغاز گردید. میدان شادگان از میداین تحت مدیریت شرکت ملی مناطق نفت‌خیز جنوب است که عملیات تولید از آن، توسط شرکت بهره‌برداری نفت و گاز مارون انجام می‌شود [۲۰].

میدان نفتی شادگان دارای ۲۳ کیلومتر طول ۶ کیلومتر عرض می‌باشد و شامل مخازن نفتی آسماری و بنگستان است. در حال حاضر ظرفیت تولید نفت خام این میدان بطور میانگین معادل ۶۶ هزار بشکه در روز می‌باشد، که روزانه ۶۱ هزار بشکه از مخزن آسماری و ۵ هزار بشکه نفت از مخزن بنگستان استخراج می‌گردد.

از ابتدای زمان اکتشاف این مخزن تا اواخر سال ۱۳۶۷ با وجود عدم تولید نفت، هر دو مخزن فوقانی و تحتانی، افت فشار نسبتاً زیادی را نشان داده‌اند. چنین پدیده‌ای با توجه به عملکرد مخزن نشان دهنده ارتباط آبدۀ این مخزن با میداین همجوارش می‌باشد این پدیده با توجه به گسترش ماسه سنگ در این ناحیه توجیه‌پذیر است [۲۰].



شکل ۱. موقعیت جغرافیایی میدان نفتی شادگان

$$\frac{W^a N}{0.42\sigma^{1.5} + \Delta P^{0.75} \sqrt{N} \times W^a} = R \quad (۴)$$

که در رابطه فوق، R : نرخ حفاری (ft/hr)، N : سرعت دورانی (rpm)، W : بار روی مته (lb/in)، σ : مقاومت فشاری (lb/in)، ΔP : اختلاف فشار ستون گل و سازند (psi) و a : ضریب ثابت رابطه (۴) می‌باشند.

$$a = (0.178254 \ln \sigma + 1.09793) \quad (۵)$$

ضریب ثابت a نشان دهنده اثر بار روی مته بر سنگ‌های با مقاومت‌های مختلف است. به این معنی که هرچه مقاومت سنگ بیشتر باشد ضریب a و یا اثر بار روی مته بر سرعت حفاری بیشتر است.

۳. مبانی شبکه عصبی

شبکه‌های عصبی مصنوعی با الهام از ساختار مغز و عملکرد موازی آن به وجود آمده‌اند و تا به حال نتایج شگفت‌آوری به دنبال داشته‌اند. شبکه عصبی یک سیستم پویا و غیرخطی است که از تعداد زیادی واحد پردازش (نرون) و اتصالات بین واحدهای پردازش تشکیل می‌شود. شبکه عصبی برای حل مسائل سه مرحله را طی می‌کند [۱۹]:

الف) آموزش ($training$) ب) اعتبارسنجی ($validation$) ج) آزمایش ($testing$)

آموزش فرآیندی است که طی آن شبکه می‌آموزد تا الگوی موجود در ورودی را بشناسد، برای این منظور هر شبکه عصبی از مجموعه‌ای از قوانین یادگیری که نحوه یادگیری را تعریف می‌کند، استفاده می‌کند. اعتبارسنجی، توانایی شبکه است برای ارائه جواب قابل قبول در قبال ورودی‌هایی که در مجموعه آموزشی نبوده‌اند. استفاده از شبکه برای انجام عملکردی که برای آن طراحی شده است را آزمایش می‌گویند. شبکه عصبی از یک سری واحدهای ساختمانی اولیه تشکیل می‌شوند. این واحدهای ساختمانی را سلول عصبی، واحد پردازش یا گره می‌نامند. هر سلول دارای چندین ورودی است. بدنه سلول از دو بخش تشکیل شده است، تابع ترکیب که در اولین بخش قرار دارد، وظیفه تابع ترکیب این است که تمام ورودی‌ها را ترکیب و یک عدد تولید کند و بخش دوم سلول عصبی تابع انتقال نام دارد. تابع انتقال مقدار تابع ترکیب را به

۵. بانک اطلاعاتی داده‌ها جهت استفاده در

مدل‌سازی

به طور کلی عوامل موثر در سرعت حفاری را به سه بخش اصلی زیر می‌توان تقسیم‌بندی نمود [۲۱-۲۲]:

- خصوصیات مته و شرایط کاری آن
- خصوصیات سازند
- خصوصیات گل حفاری و هیدرولیک چاه

در این تحقیق سعی شد پارامترهایی که به عنوان ورودی برای مدل‌سازی در نظر گرفته شده، تمام دسته‌های بالا را شامل شود که از بین پارامترهای در دسترس وزن روی مته، نرخ چرخش مته، وزن گل حفاری و گشتاور در مدل‌سازی دخالت داده شده‌اند. همچنین از دیگر دلایل انتخاب این پارامترها این بوده که در تحلیل آماری بیشترین ضریب t را داشتند. این امر به همراه حذف داده‌های پرت موجب بالارفتن میزان دقت مدل شده و افزایش قابل توجه مقادیر ضریب همبستگی و ضریب تعیین را به دنبال دارد.

۱.۵. آمار توصیفی

آمار توصیفی داده‌های مورد استفاده در مدل‌سازی نرخ نفوذ در جدول ۱ نشان داده شده است. این بانک اطلاعاتی از عملیات حفاری در میدان نفتی شادگان و در سازند آغاچاری برای اعماق ۵۰۰ تا ۲۱۴۴ متری تهیه شده است.


۲.۵. بررسی آماری داده‌ها

جهت بررسی آماری داده‌ها، پس از ترسیم فراوان‌نما (هیستوگرام) مربوط به تک تک پارامترهای ورودی، هر کدام آنالیز شده و حداقل، حداکثر، میانگین، میانه، واریانس، چارک اول، چارک دوم، چارک سوم، انحراف معیار، چولگی و کشتاوری مشخص می‌گردد.

پس از ترسیم فراوان‌نما (هیستوگرام) و با استفاده از ضریب چولگی می‌توان دریافت که توزیع مورد بررسی تا چه حد فاقد تقارن می‌باشد. این موضوع برای هر بخش به صورت جداگانه مورد بررسی قرار گرفته است که در ادامه ارائه شده است.

جدول ۱. آمار توصیفی داده‌های استفاده شده در مدل‌سازی نرخ نفوذ حفاری


Range	Mode	Q (3)	Q (2)	Q (1)	Average	Median	St.Dev	Max.	Min.	واحد	پارامتر
۴۴/۵	۸/۶۰	۸	۱۰/۸۲	۱۷/۴۰	۱۳/۴	۱۰/۸	۷/۴۶	۴۵/۶	۱	klbf	WOB
۱۴۴	۱۶۹	۱۴۴	۱۶۱	۱۷۱	۱۵۸	۱۶۱	۱۸/۲۵	۲۰۱	۵۶	1/min	RPM
۷۵/۳۹	۷۳/۳۵	۶۵/۱۱	۷۴/۱۰	۹۵/۱۲	۷۹/۲۶	۷۴/۱۰	۱۲/۶۳	۱۴۰/۴۶	۶۵/۰۷	pcf	MW
۹۱۴۴	۶۸۰۰	۵۹۷۱	۷۰۷۲	۸۳۱۰	۷۱۸۳	۷۰۷۲	۱۵۶۸	۱۲۴۶۳	۳۳۱۹	lbfft	TORQUE
۴/۴۶	۲/۶۰	۲/۹۱	۴/۲	۶/۸۷	۵/۶	۴/۲	۴/۱۴	۴۶/۷	۰/۳	M/hr	ROP




شکل ۲. فراوان‌نمای مربوط به وزن گل حفاری

اولین قدم برای بررسی توزیع نرمال و چولگی، ترسیم هیستوگرام داده‌های ورودی می‌باشد که در شکل‌های ۲، ۳، ۴ و ۵ به ترتیب برای وزن گل حفاری، گشتاور، چرخش مته و وزن روی مته نشان داده شده است.


جدول ۲ نیز تعدادی از داده‌های واقعی و پارامترهای مورد استفاده در این تحقیق را نشان می‌دهد. همچنین شکل‌های ۶ تا ۱۰ تغییرات پارامترهای ورودی را نسبت به عمق نشان می‌دهند.




شکل ۶. تغییرات گشتاور بر اساس عمق




شکل ۳. فراوان‌نمای مربوط به گشتاور




شکل ۷. تغییرات نرخ نفوذ حفاری بر اساس عمق



شکل ۴. فراوان‌نمای مربوط به نرخ چرخش مته



شکل ۸. تغییرات نرخ چرخش مته بر اساس عمق




شکل ۵. فراوان‌نمای مربوط به وزن روی مته

جدول ۲. نمونه‌ای از پارامترهای ورودی و خروجی


نرخ نفوذ مته (m/hr)	وزن گل حفاری (pcf)	وزن روی مته (klbf)	سرعت چرخش مته (l/min)	گشتاور (lbf.ft)
۱۲/۰	۶۵/۰۷	۲۵/۲	۱۵۱	۶۴۰۰
۸/۹	۶۵/۰۸	۲۸/۷	۱۲۷	۶۰۰۰
۱۰/۸	۷۲/۲۴	۲۰/۷	۱۲۲	۵۷۱۷
۹/۰	۷۴/۱۰	۱۸/۳	۱۴۲	۷۲۸۹
۱۲/۴	۷۴/۲۳	۹/۱	۱۴۷	۸۲۴۵
۹/۳	۷۳/۳۵	۴/۷	۱۵۴	۷۳۴۴
۴/۰	۸۵/۰۳	۱۰/۶	۱۸۰	۸۱۸۸
۲/۶	۸۰/۲۲	۱۸/۸	۱۲۷	۹۵۴۴
۰/۸	۹۰/۰۳	۱۵	۱۲۰	۳۳۶۹
۳/۶	۸۹/۱۸	۷/۷	۱۲۵	۵۲۳۸
۲/۹	۹۵/۶۶	۸/۲	۱۶۸	۶۲۹۱

می‌باشد که معمولاً برای داده‌هایی مورد استفاده قرار می‌گیرد که سطح سنجش آن‌ها فاصله‌ای است. رگرسیون خطی به دو صورت رگرسیون خطی ساده و رگرسیون خطی چند متغیره مطرح می‌گردد. رگرسیون خطی ساده به پیش‌بینی مقدار یک متغیر وابسته بر اساس مقدار یک متغیر مستقل می‌پردازد. اما رگرسیون چند متغیره روشی است برای مشارکت جمعی و فردی دو یا چند متغیر مستقل در تغییرات یک متغیر وابسته. در مطالعات عوامل موثر بر سرعت حفاری باید گفت که هر متغیر ورودی به نوعی با چند متغیر دیگر در ارتباط می‌باشد. در نتیجه، برای حصول نتایج بهتر و صحیح تر به منظور تخمین سرعت حفاری، تحلیل‌های رگرسیون خطی چندمتغیره و غیرخطی برای برقراری نوعی ارتباط بین این متغیرها انجام پذیرفت [۲۳-۲۴]. برخی موارد رگرسیون خطی برای همه مسائل نمی‌تواند مناسب باشد، چرا که بعضی از اوقات پاسخ و متغیرهای رگرسیونی با تابع غیر خطی معلوم به هم مربوط می‌باشند. بدین جهت و به منظور حصول نتایج دقیق‌تر، تحلیل‌های غیرخطی نیز انجام پذیرفت که نتایج آن در جدول ۳ آورده شده است. همان‌گونه که در جدول ۳ نشان داده شده است، از آنجا که مدل خطی چند متغیره نسبت به مدل‌های دیگر ضرایب همبستگی و تعیین بالاتری را بدست می‌دهد این مدل‌سازی در دستور کار قرار گرفت.

با در اختیار داشتن داده‌های حفاری، در ابتدا تحلیل آماری صورت پذیرفت که ضریب همبستگی ۰/۹۴ حاکی از



شکل ۹. تغییرات وزن گل حفاری بر اساس عمق



شکل ۱۰. تغییرات وزن روی مته بر اساس عمق

۶. تحلیل رگرسیون

رگرسیون خطی چندگانه یکی از تکنیک‌های پیچیده آماری

که در آن ROP متغیر وابسته و WOB ، RPM ، MW و $TORQUE$ به عنوان متغیرهای مستقل در نظر گرفته شده‌اند. ضرایب بدست آمده از تحلیل رگرسیون در جدول‌های ۵ و ۶ آورده شده است.

قابل قبول بودن مدل‌سازی دارد. تعداد نمونه‌ها (داده‌ها) و ضریب همبستگی تحلیل رگرسیونی در جدول ۳ آورده شده است. در جدول ۴ نیز متغیرهای مستقل و وابسته نشان داده شده است.

همان‌گونه که اشاره شد، جدول ۵ پارامترهای مستقل و وابسته که در رگرسیون تاثیر داده شده اند را نشان می‌دهد

جدول ۳. نتایج رگرسیون خطی و غیرخطی

نوع رگرسیون	ضریب همبستگی	ضریب تعیین
غیرخطی نمایی (Exponential)	۰/۴۱	۰/۲۹
غیرخطی مکعبی (Cubic)	۰/۶۲	۰/۴۷
غیر خطی مربعی (Quadratic)	۰/۶۱	۰/۴۶
غیر خطی معکوس (Inverse)	۰/۵۳	۰/۲۶
غیر خطی لگاریتمی (Logarithmic)	۰/۴۱	۰/۳۰
خطی چند متغیره (Multiple Linear)	۰/۹۴	۰/۸۹

جدول ۴. ضرایب بدست آمده از جامعه آماری مختلف

ضریب همبستگی (R)	تعداد نمونه ها
۰/۹۴	۱۰۷

جدول ۵. متغیر های وابسته و مستقل

متغیر وابسته	متغیر های مستقل
ROP	$WOB, MW, RPM, TORQUE$

$$ROP = -10.266 - 0.038(Mw) - 0.001(Torque) + 0.075(RPM) + 0.499(WOB) \quad (6)$$

که در رابطه فوق، $Mw(pcf)$ وزن گل حفاری، RPM (1/min) : سرعت چرخش مته، $Torque$ (lbf.ft) : گشتاور و WOB (klbf) : وزن روی مته می‌باشد.

آماره t نیز اهمیت نسبی حضور هر متغیر مستقل در مدل را نشان می‌دهد. برای اینکه تشخیص داده شود که کدام متغیرها تاثیر آماری معنی داری بر متغیر وابسته داشته است، می‌توان به مقدار t رجوع نمود. معمولاً هرگاه قدر مطلق مقدار این آماره برای متغیری بزرگتر از عدد ۲/۳۳ باشد، سطح خطای آن نیز کوچک تر از ۰/۰۵ بوده و در نتیجه می‌توان گفت که متغیر مورد نظر تاثیر آماری معنی‌داری در تبیین تغییرات متغیر وابسته داشته است [۲۵]. با توجه به توضیحات بالا از آنجا که قدرمطلق WOB و RPM بیشتر از ۲/۳۳ می‌باشد، می‌توان نتیجه گرفت که این پارامترها تاثیر آماری معنی‌داری در تبیین تغییرات متغیر وابسته داشته‌اند.

β ضرایب رگرسیونی استاندارد شده، سهم نسبی هر متغیر مستقل در تبیین متغیر وابسته را نشان می‌دهد. باید توجه داشت که ضریب رگرسیونی استاندارد شده بر اساس مقادیر انحراف استاندارد سنجیده می‌شود. به عنوان مثال، ضریب بتای ۰/۷۷۳ نشان می‌دهد که تغییر یک انحراف استاندارد در متغیر مستقل باعث تغییر ۰/۷۷۳ انحراف استاندارد در متغیر وابسته می‌شود. بر اساس جدول ۶ معادله رگرسیونی حاصله به صورت زیر می‌باشد:

جدول ۶. نتایج حاصل از رگرسیون

شماره	ضریب همبستگی (Correlation Coefficient)	مجذور ضریب تعیین (Determination Coefficient)	ضریب تعیین تعدیل شده	خطای استاندارد برآورد	سطح معنی داری
۱	۰/۹۴	۰/۸۹	۰/۸۸	۱/۳۷	۰/۰۰۰

جدول ۷. ضرایب حاصل از رگرسیون و ضریب تاثیر هر یک از متغیرها

مدل	خطای استاندارد نشده B	خطای استاندارد برآورد	ضرایب استاندارد شده β	آماره t	سطح معنی داری
ثابت	-۱۰/۲۶۶	۱/۹۹۳		-۵/۱۵۱	۰/۰۰۰
MW	۰/۰۳۸	۰/۰۲۴	۰/۰۸۲	۱/۶۰۵	۰/۰۰۰
$TORQUE$	-۰/۰۰۱	۰/۰۰۰	-۰/۲۲۵	-۴/۴۴۲	۰/۰۰۰
RPM	۰/۰۷۵	۰/۰۱۶	۰/۲۷۰	-۴/۶۹۹	۰/۰۰۰
WOB	۰/۴۹۹	۰/۰۳۲	۰/۷۷۳	۱۵/۵۰۰	۰/۰۰۰

مطلوب مقایسه می‌گردد و بدین ترتیب راندمان شبکه آموزش دیده، محک زده می‌شود.

در این بخش، مهم‌ترین مسئله چگونگی انتخاب مجموعه داده‌های مربوط به سه بخش یاد شده است. در بیشتر شبکه‌های عصبی معمولاً از ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد باقیمانده برای تست شبکه استفاده می‌شوند. به طور کلی روش تقسیم این داده‌ها به یک دید خوب تحلیلی از چگونگی عملکرد شبکه و توزیع مناسب داده‌های هر چاه در هر کدام از مجموعه داده‌ها نیاز دارد [۲۱].

۲.۷. مدل‌سازی عصبی

پس از انجام مراحل قبل، داده‌ها برای مدل‌سازی آماده هستند. در این مرحله شبکه عصبی مناسب با توجه به مزیت‌ها و معایب آن و هدف از انجام کار در نظر گرفته می‌شود. در این مرحله نوع شبکه عصبی، ساختار و اجزاء آن انتخاب می‌شود. پس از انتخاب شبکه مورد نظر باید ساختار آن از جمله تعداد لایه‌های مخفی و تعداد نرون آن مشخص شود. همچنین شرط پایان مرحله آموزش نیز برای شبکه در این مرحله تعیین می‌شود. در این بخش از شبکه‌های عصبی مصنوعی و الگوریتم‌های بهینه‌سازی برای ایجاد مدل مناسب استفاده می‌شود.

۷. تحلیل عصبی

۱.۷. تقسیم‌بندی داده‌ها

بعد از جمع‌آوری و پردازش کامل داده‌ها، نوبت به مدل‌سازی با شبکه عصبی می‌رسد. به طور کلی داده‌های ورودی به شبکه‌های عصبی به سه بخش ذیل تقسیم می‌گردند:

- مجموعه داده‌های آموزش: از این مجموعه داده، برای ساخت شبکه عصبی استفاده می‌شود.

- مجموعه داده‌های اعتبارسنجی: در حین ساخت شبکه با داده‌های آموزش، ممکن است شبکه برای دستیابی به عملکرد بهتر مقادیر پارامتر هدف را حفظ کرده (به خاطر بسپارد) و خروجی خود را نزدیک به داده‌های واقعی کند. برای جلوگیری از پیش‌آمدن چنین اتفاقی، یک قسمت از داده‌ها با عنوان داده‌های اعتبارسنجی مشخص می‌شود که پس از آموزش شبکه در هر مرحله، شبکه با این داده‌ها تست می‌شود، تا میزان واقعی بودن خروجی شبکه مشخص شود و در صورت فراهم شدن شرط پایان (مناسب بودن میزان دقت شبکه) آموزش شبکه به پایان برسد.

- مجموعه داده‌های تست: پس از آن که شبکه توسط داده‌های آموزش تا رسیدن به حداقل خطا آموزش یافت، مابقی داده‌ها که در آموزش و اعتبارسنجی نقشی نداشته‌اند به عنوان ورودی به شبکه داده‌شده و پاسخ شبکه با پاسخ

۳.۷. معیارهای عملکرد

جهت بررسی عملکرد مدل‌ها و مقایسه نتایج، معیارهایی لازم است تا در تحقیق مورد استفاده قرار گیرد که از بین معیارهای مرسوم از ضریب همبستگی (R)، ضریب تعیین (R^2) و میانگین مربع خطا (MSE -Mean Square Error) استفاده گردید. مقدار R بیانگر ارتباط بین داده‌های واقعی و مدل بوده که مقدار آن بین منفی یک تا یک است؛ که مقدار منفی یک نشان دهنده رابطه معکوس و رابطه یک نشان دهنده رابطه مستقیم و مقدار صفر نشان دهنده عدم وجود رابطه بین داده‌ها می‌باشد. مقدار این متغیر از رابطه (۷) بدست می‌آید. R^2 مقدار ضریب رگرسیون به توان دو است. در صورتی که اختلاف زیادی بین داده‌های واقعی و مدل وجود داشته باشد، معیار ضریب رگرسیون به تنهایی نمی‌تواند بیانگر رابطه قوی بین داده‌ها باشد. بنابراین از معیار دیگری که بیانگر وضعیت اختلاف بین داده‌های واقعی و مدل است، استفاده می‌شود. بدین منظور معیار MSE مورد استفاده قرار گرفت. هر چه مقدار این معیار کمتر باشد نشان از دقت بالاتر مدل است. مقدار MSE به کمک رابطه (۸) محاسبه می‌شود [۲۵]:

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (7)$$

در معادله فوق X_i و Y_i هر یک از داده‌ها و \bar{x} و \bar{y} میانگین کل داده‌های پیش‌بینی شده و واقعی می‌باشند.


$$\varepsilon(n) = MSE = \frac{\sum_{i=1}^n (y_{pi} - y_{ti})^2}{n} \quad (8)$$

که در این رابطه، y_{pi} مقدار خروجی شبکه برای بردار داده i ام، y_{ti} مقدار واقعی داده برای بردار داده i ام و n تعداد کل داده‌های در دسترس است.

۴.۷. معماری شبکه عصبی

با توجه به دست‌بندی داده‌ها، مشخص است که شبکه عصبی مورد نظر دارای چهار پارامتر ورودی و یک پارامتر خروجی است. در این تحقیق، شبکه عصبی از نوع $Feed-Forward$


چند لایه ای انتخاب شده است. از دلایل این انتخاب می‌توان به کارایی بهتر در تخمین توابع اشاره کرد که همه ی کاربران برای تخمین توابع از این مورد استفاده کرده اند که نتایج قابل قبول و با قابلیت اعتماد بالاتری را نسبت به انواع دیگر بدست داده است. به منظور آموزش شبکه عصبی الگوریتم‌های متنوعی وجود دارد. پیشنهاد برنامه برای کارایی مورد نظر شبکه عصبی، الگوریتم $Back Propagation$ می‌باشد. بر اساس این الگوریتم توابع یادگیری $trainlm$ ، $trainbfg$ ، $trainrp$ ، $trainrg$ ، $trainscg$ و ... می‌توانند مورد استفاده قرار گیرند. در ادامه بر اساس نتایج به دست آمده از هر کدام از این توابع، بهترین گزینه انتخاب شده است که در این مورد بهترین نتیجه با استفاده از تابع یادگیری $trainlm$ حاصل شد که الگوریتم لونیبرگ - مارکاد (LMA -Levenberg-Marquardt) $Algorithm$ بین الگوریتم گاوس- نیوتون (GNA) و روش نزول گرادیانی را درون یابی می‌کند. LMA از GNA مقاومتر است یعنی این که در بسیاری مواقع، حتی اگر بسیار دورتر از کمینه نهایی شروع کرده باشد، جوابی را پیدا می‌کند. از سوی دیگر LMA پرفرمدارترین الگوریتم برازش خم است و کاربران کمی ممکن است به روش های دیگر برازش خم نیاز پیدا کنند. با استفاده از نتایج به دست آمده بهترین شبکه عصبی (شبکه‌ای که شیب خط رگرسیون تست آن بعد از آموزش به عدد یک نزدیک‌تر باشد، البته زمان مناسب آموزش و کم بودن میانگین مربعات خطا نیز می‌تواند در انتخاب شبکه بهینه موثر باشد) انتخاب شده است. بر اساس نتایج به دست آمده مشخص شد که نوع تابع یادگیری تاثیر بسیار زیادی بر بهتر شدن جواب‌های شبکه عصبی دارد. با توجه به جدول نتایج، بهترین تابع یادگیری تابع $trainlm$ می‌باشد، در مقابل نوع تابع انتقال تاثیر چندانی بر نتایج ندارد. با این حال به نظر می‌رسد که استفاده از تابع انتقال $tansig$ نتایج بهتری را به همراه دارد. برای معماری شبکه عصبی و بدست آوردن بهترین نتیجه به طرق مختلف شبکه مورد آزمایش سعی و خطا قرار گرفت تا از بین آن‌ها شبکه‌ای که بهترین نتایج را می‌دهد انتخاب گردد. شبکه‌ای که با این داده‌ها بهترین عملکرد را نشان داده است دو لایه بوده و دارای ۱۰ نرون در لایه پنهان است. تابع یادگیری این شبکه $trainlm$ و تابع انتقال آن در لایه اول از نوع $tansig$ و در لایه دوم از نوع $Purline$ بوده است که ساختار آن در شکل ۱۱ نشان داده شده است.



شکل ۱۱. ساختار شبکه عصبی

جدول ۸. بررسی ضریب همبستگی در شرایط مختلف

تعداد لایه	تعداد نرون ها	تابع انتقال	تابع یادگیری	ضریب همبستگی
۲	۵	Tansig	Trainlm	۰/۷۹
۲	۵	Tansig	Trainscg	۰/۷۵
۲	۱۰	Tansig	Trainlm	۰/۹۷
۲	۱۰	Tansig	Trainscg	۰/۸۷
۲	۱۴	Tansig	Trainlm	۰/۸۵
۲	۱۴	Tansig	Trainscg	۰/۸۴
۳	۱۰	Tansig	Trainlm	۰/۷۴
۳	۱۰	Tansig	Trainscg	۰/۷۲
۳	۱۴	Tansig	Trainlm	۰/۷۰
۳	۱۴	Tansig	Trainscg	۰/۶۹
۴	۱۰	Tansig	Trainlm	۰/۷۰
۴	۱۰	Tansig	Trainscg	۰/۶۹




شکل ۱۲. نمودار رگرسیونی برای چهار بخش مختلف

همان طور که اشاره شد، بارها شبکه مورد آموزش قرار گرفت که هرچند شبکه ضریب همبستگی مناسبی داشت، ولی بهبود نتایج نامطلوبی داشت و برای بهبود آن راههای مختلفی از قبیل نرمال کردن داده‌ها، حذف یکی از پارامترها و ... مورد آزمایش قرار گرفت تا بتوان نتیجه مطلوبی را برای تخمین این تابع بدست آورد. نتایج حاصل از آزمون سعی و خطا را در جدول ۸ نشان داده شده است.

۵.۷. تحلیل نمودارهای نقطه به نقطه

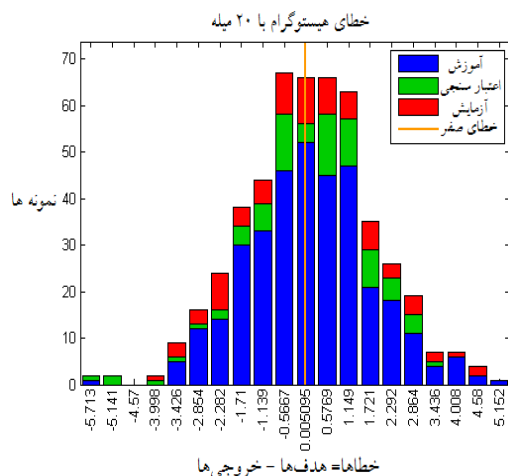
شکل ۱۲ ضریب همبستگی را در شبکه عصبی برای قسمت‌های مختلف از قبیل آموزش، ارزیابی و تست نشان می‌دهد که مقادیر نشان از قدرت بالای شبکه عصبی دارد.



شکل ۱۳. بهترین مرحله تکرار

۷.۷. خطای هیستوگرام

با توجه به شکل ۱۴ که میزان خطای هیستوگرام با ۲۰ میله (Bins or bars) برای هر سه مرحله یادگیری، اعتبار سنجی و تست را نشان می‌دهد. میزان خطا، با توجه به خطای صفر (Error Zero) (منظور اختلاف خطای تحلیل‌ها تا صفر نمودار که همان خط زرد در شکل است)، ۰/۰۰۵ بدست آمده است که بدلیل نزدیک بودن به صفر قابل قبول می‌باشد و از آنجا که از داده‌های واقعی استفاده شده است به مقدار صفر نمی‌رسد.



شکل ۱۴. خطای هیستوگرام با ۲۰ میله

با توجه به شکل بالا برای آموزش شبکه با رسم نقطه به نقطه ۷۰ درصد داده‌ها و رسم خط گذرنده از حداکثر نقاط، معادله (۹) با ضریب همبستگی ۰/۹۷۴۱ حاصل می‌شود:

$$output = 0.92 \times T_{\text{arget}} + 39 \quad (9)$$

و همچنین برای اعتبار سنجی شبکه با رسم نقطه به نقطه ۱۵ درصد داده‌ها و رسم خط گذرنده از حداکثر نقاط معادله زیر (معادله ۱۰) با ضریب همبستگی ۰/۹۶۰۵ بدست می‌آید:

$$output = 0.93 \times T_{\text{arget}} + 34 \quad (10)$$

برای آنالیز حساسیت سنجی شبکه با رسم نقطه به نقطه ۱۵ درصد داده‌ها و رسم خط گذرنده از حداکثر نقاط معادله (۱۱) با ضریب همبستگی ۰/۹۶۶۰ حاصل می‌شود.

$$output = 0.97 \times T_{\text{arget}} + 17 \quad (11)$$

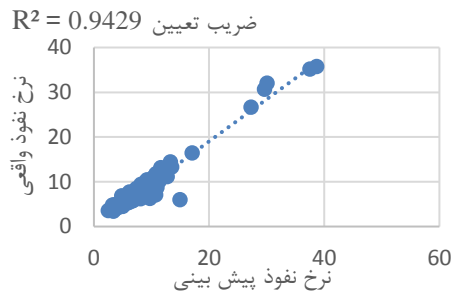
با توجه به معادلات بدست آمده و از مجموع همه ی داده‌های موجود نمودار نقطه‌ای تمامی داده‌ها (شکل ۷ پایین سمت راست) رسم می‌شود که ضریب همبستگی آن ۰/۹۷۰۶ می‌باشد و معادله بدست آمده از خط گذرنده از حداکثر نقاط به صورت زیر می‌باشد:

$$output = 0.93 \times T_{\text{arget}} + 34 \quad (12)$$


۶.۷. تکرار محاسبات (Epoch)

ایپوک به منزله‌ی تکرار محاسبات است که در شکل ۱۳ نشان داده شده است. برای تمام مراحل انجام شده، نمودار (شکل) زیر بیانگر تعداد تکرارهای صورت گرفته تا رسیدن به نتیجه مورد نظر است. در زیر مقادیر بدست آمده برای ایپوک ۱۳ یا به عبارتی دیگر در سیزدهمین مرحله تکرار نشان داده شده است.

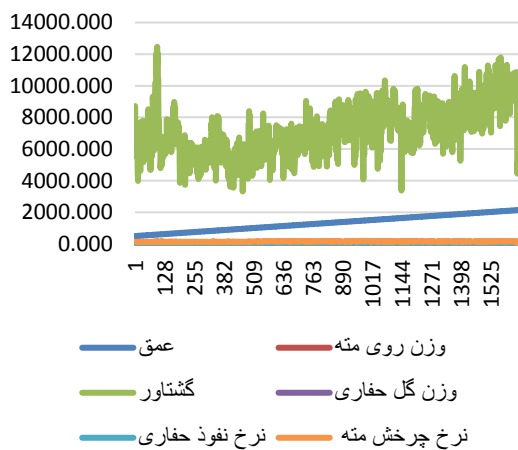
شبکه پس از حل معادلات و تکرارها، بهترین بازده خود در مراحل تکرار را ارائه می‌دهد که شکل زیر بیانگر همین موضوع می‌باشد. در این مرحله هرچه میانگین خطای مربع به صفر نزدیک‌تر باشد جواب بهتری حاصل شده است. در تکرار ۷ بهترین مقدار حاصل می‌شود.



شکل ۱۵. ضریب تعیین نرخ نفوذ واقعی بر حسب نرخ نفوذ محاسبه شده



شکل ۱۶. مقایسه مقادیر نرخ نفوذ پیش‌بینی شده با مقادیر واقعی



شکل ۱۷. نمودار تغییرات ورودی‌ها با خروجی

به منظور مقایسه مدل پیشنهادی با یکی از مدل‌های تجربی، مدل بایر و کالدر انتخاب شد. دلیل این انتخاب نیز مشابهت پارامترهای ورودی این مدل با مدل عصبی

پس از انجام محاسبات و بررسی نمودارهای بدست آمده که در شکل ۱۰ مشاهده می‌شود، در بسیاری از موارد نرخ نفوذ واقعی با نرخ نفوذ بدست آمده از شبکه عصبی اعدادی نزدیک به هم بوده‌اند، اما در موارد اندکی هم اختلافاتی وجود داشت. البته برای رفع این مشکل باید داده‌های ورودی به شبکه از چاه‌های مختلف و میدان‌های مختلف باشد (تعداد بیشتر داده) تا شبکه جامعیت بیشتری داشته باشد. نمونه‌ای از داده‌های استفاده شده در جدول ۹ آورده شده است.

جدول ۹. نمونه‌ای از داده‌ها برای ارزیابی شبکه عصبی

وزن گل حفاری [PCF]	وزن گشتاور [lbf.ft]	سرعت چرخش مته [1/min]	وزن روی مته [klbf]	نرخ نفوذ محاسبه شده [m/h]	نرخ نفوذ واقعی [m/h]
۶۵/۰۷	۸۴۴۸	۱۴۶	۳۰/۳	۷/۰۳	۷/۷۷
۷۴/۱۰	۶۱۷۴	۱۴۹	۷	۵/۹۳	۵/۳۴
۷۴/۱۰	۶۸۲۴	۱۶۰	۹/۲	۶/۹۰	۶/۵۵

ضریب تعیین بدست آمده با توجه به میزان نرخ نفوذ واقعی نسبت به نرخ نفوذ محاسبه شده برابر با ۰/۹۴ می‌باشد و این مقدار قابل قبول می‌باشد زیرا هر چه این ضریب به یک نزدیک‌تر باشد نشان از آن است که متغیرهای مستقل توانسته‌اند میزان زیادی از واریانس متغیر وابسته را تعیین کنند و بالعکس هرچه این ضریب به صفر نزدیک‌تر باشد دلالت بر نقش کمتر متغیرهای مستقل در تعیین واریانس متغیر وابسته دارد.

شکل‌های ۱۵ و ۱۶ به ترتیب نمودارهای ضریب تعیین و نرخ نفوذ واقعی بر حسب نرخ نفوذ محاسبه شده را نشان می‌دهند.

همان‌طور که در شکل ۱۶ مشاهده می‌شود، مقادیر نرخ نفوذ واقعی با رنگ قرمز و مقادیر نرخ نفوذ بدست آمده از شبکه عصبی با رنگ آبی رسم شده است. این مقادیر در بسیاری از موارد نزدیک به هم بوده و این نشان از قدرت و دقت شبکه عصبی مورد نظر می‌دهد. اما مواردی برای اختلاف هم وجود دارد که حکایت از نیاز شبکه به داده‌های اولیه بیشتر برای آموزش دارد. در ادامه، نمودار تغییرات پارامترهای ورودی با خروجی در شکل ۱۷ نشان داده شده است که بر اساس کلیه داده‌های بانک اطلاعاتی ترسیم شده است.

توجه می‌باشد در حالی که این اختلاف برای مدل پیشنهادی بسیار کمتر بوده و این امر خود دلیلی بر ضرورت و اهمیت تحقیق حاضر می‌باشد.

پیشنهادی بود. نتایج این مقایسه در جدول ۱۱ آورده شده است. نتایج این مقایسه نشان می‌دهد که میزان خطا و اختلاف مقادیر واقعی با مقادیر پیش‌بینی شده با مدل بایر و کالدر قابل

جدول ۱۱. نتایج مقایسه مقادیر واقعی با مقادیر پیش‌بینی شده حاصل از مدل سازی عصبی و مدل بایر و کالدر

نرخ نفوذ واقعی [m/h]	نرخ نفوذ پیش‌بینی شده با شبکه عصبی [m/h]	نرخ نفوذ محاسبه شده با استفاده از مدل بایر و کالدر [m/h]	وزن روی مته [klbf]	سرعت چرخش مته [1/min]	مقاومت فشاری تک محوره [1000bf]	قطر مته [in]
۱۶/۱۰	۱۳/۲۳	۱۱/۱۰	۱۹/۵	۱۳۰	۱۰۰۰	۱۷/۵
۱۲/۰۰	۱۰/۳۴	۱۰/۰۴	۱۸/۵	۱۲۴	۱۰۰۰	۱۷/۵
۱۲/۴۰	۱۰/۰۴	۱۵/۷۱	۲۶/۰	۱۳۸	۱۰۰۰	۱۷/۵
۵/۷۰	۱۰/۷۰	۱۳/۴۰	۲۳/۹۰	۱۲۸	۱۰۰۰	۱۷/۵
۷/۸۱	۸/۱۲	۶/۱۷	۹/۱۰	۱۵۵	۱۰۰۰	۱۷/۵
۲/۶۰	۴/۰۹	۷/۲۱	۹/۰۰	۱۸۳	۱۰۰۰	۱۷/۵
۷/۱۰	۶/۶۰	۴/۴۰	۶/۰۰	۱۷۰	۱۰۰۰	۱۷/۵

۸. نتیجه‌گیری

این تحقیق مدلی را برای پیش‌بینی نرخ نفوذ حفاری با استفاده از شبکه عصبی مصنوعی ارائه می‌دهد. بدین منظور در ابتدا یک بانک اطلاعاتی جامع از داده‌های میدانی و عملیات حفاری در میدان نفتی شادگان تهیه شد. سپس این اطلاعات با رویکرد شبکه عصبی مورد تحلیل قرار گرفت. نتایج کلی به دست آمده از این مدل‌سازی پیش‌بینی نرخ نفوذ حفاری در میدان نفتی شادگان با در نظر گرفتن پارامترهای وزن روی مته، نرخ چرخش مته، گشتاور و وزن گل حفاری با تعداد ۴۰۰ داده را به صورت زیر می‌توان خلاصه نمود:

۱- تحلیل‌های انجام شده نشان می‌دهد که شبکه‌های عصبی مصنوعی در مقایسه با روش‌های آماری هم‌چون رگرسیون چند متغیره در تخمین سرعت حفاری بسیار دقیق‌تر می‌باشند به طوری که ضریب تعیین در مدل‌سازی شبکه عصبی برابر با ۰/۹۴ و ضریب تعیین در مدل رگرسیونی برابر ۰/۸۹ می‌باشد. از آنجاکه رابطه بین پارامترهای حفاری غیر خطی می‌باشد می‌توان نتیجه گرفت که شبکه‌های عصبی در پیش‌بینی روابط غیر خطی کارایی خوبی دارند.

۲- مقدار R یا همان ضریب همبستگی در شبکه عصبی برای آموزش ۰/۹۷۴۱ و برای اعتبار سنجی ۰/۹۶۰۵ و برای تست

۰/۹۶۶۰ و برای حالت کل مجموعه ۰/۹۷۰۶ می‌باشد که نشان دهنده قدرت شبکه عصبی در تخمین توابع می‌باشد. علت بالا بودن ضریب‌ها به این دلیل است که داده‌هایی وارد مدل سازی شده است که هم بیشترین تاثیر را در نرخ نفوذ حفاری دارند و هم داده‌های پرت حذف شده‌اند.

۳- شبکه عصبی با داده‌های میدانی وزن روی مته، سرعت چرخش مته، گشتاور و وزن گل حفاری با استفاده از تابع آموزش و توابع انتقال طراحی و ساخته شد و خروجی که همان نرخ نفوذ حفاری می‌باشد پیش‌بینی شد که ضریب تعیین مقایسه بین مقادیر واقعی و پیش‌بینی $R^2 = 0/94$ بدست آمد که از نزدیکی مقادیر واقعی و پیش‌بینی شده و دقت بالای مدل پیش‌بینی با استفاده از شبکه عصبی مصنوعی حکایت دارد.

۴- میزان خطای هیستوگرام با ۲۰ میله با توجه به نمودار برابر با ۰/۰۰۵ می‌باشد. بدلیل اینکه از داده‌های واقعی استفاده شده این مقدار به صفر نمی‌رسد. کم بودن مقدار آن حاکی از خطای کم شبکه می‌باشد.

۵- تعداد ایپوک‌های صورت گرفته برای نتیجه گرفتن شبکه، ۱۳ می‌باشد که با توجه به میانگین خطای مربع در ایپوک ۷ بهترین نتیجه حاصل شده است.

[3] Al-Betairi E.A., Moussa M., & Al-Otaibi, S. (2005). Multiple regression approach to optimize drilling operations in the Arabian Gulf area. SPE Drilling Engineering, 3 (1), 83-88.

[4] Yilmaz, S., Demircioglu, C., & Akin, S. (2002). Application of artificial neural networks to optimum bit selection. Computers and Geosciences, 28, 261-269.

[5] Edalatkhah, S., Rasoul, R., & Hashemi, A. (2012). Bit selection optimization using artificial intelligence systems. Petroleum Science and Technology, 28 (18), 1946-1956.

[۶] نوروزی بزمین آبادی، س.؛ رمضان زاده، ا.؛ جلالی، س.م.؛؛ تخم‌چی، ب. (۱۳۹۳). مدل‌سازی نرخ نفوذ حفاری با استفاده از شبکه عصبی مصنوعی، مطالعه موردی در یکی از چاه‌های میدان نفتی آزادگان، کنفرانس ملی علوم معدنی، ساری.

[۷] مشعشعی، س.ح.؛ ابراهیم آبادی. آ.؛ امامزاده. ا.؛ (۱۳۹۷)، ارائه ابزار گرافیکی به منظور پیش‌بینی نرخ نفوذ حفاری با استفاده از شبکه‌های هوشمند، مجله علمی - پژوهشی پژوهش نفت، ۲۸ (۱۰۱)، ۱۱۲ - ۱۲۵.

[8] Moraveji, M.K., & Naderi., M. (2016). Drilling rate of penetration prediction and optimization using response surface methodology and bat algorithm. Journal of Natural Gas Science and Engineering, 31 (7), 829-841.

[9] Amer, M.M., Dahab, A.S., & Hashem El-Sayed, A.A. (2017). An ROP predictive model in Nile Delta area using artificial neural networks, SPE Kingdom of Saudi Arabia Annul Technical Symposium and Exhibition, SPE, 12 (5), 124-135.

[10] Khaksar Manshad, A., Rostami, H., Toreifi, H., & Mohammadi, A.H. (2017). Optimization of drilling penetration rate in oil fields using artificial intelligence technique, Nova Science Publishers, Inc., Chapter 13, 18 (11), 12-21.

[11] Priyanga, H.Y., & Ruliandi, D. (2018). Application of pattern recognition and classification using artificial neural network in geothermal operation. Forty-Third Workshop on Geothermal Reservoir Engineering, Stanford University, Stanford, California.

[12] Astrini, Y., Advarel, P., & Dorman P. (2019). Rate of penetration prediction using artificial neural network to predict ROP for nearby well in a geothermal Field, 44th workshop on geothermal reservoir engineering,

۶- نتایج مقایسه مدل پیشنهادی با مدل‌های تجربی نشان داد که میزان خطای این روابط با مقادیر واقعی و مقادیر محاسبه شده از مدل پیشنهادی زیاد می‌باشد. در این راستا، اختلاف کم مقادیر واقعی و پیش‌بینی شده با مدل عصبی پیشنهادی از دقت مدل پیشنهادی حکایت دارد.

۷- با این‌که نتایج حاصله و مدل ارائه شده از دقت و قابلیت اعتماد بالا برخوردار می‌باشد، پیشنهاد می‌شود از دیگر روش‌های هوشمند دیگر جهت اعتبار و صحت‌سنجی نتایج بهره گرفته شود.

۸- پیشنهاد می‌شود از مدل‌های هیبریدی شبکه عصبی و دیگر روش‌های نوین برای مدل‌سازی نرخ نفوذ حفاری بهره گرفته شود.

۹. فهرست نمادها

تمامی نمادهای مورد استفاده در متن مقاله، جداول و گزاره‌های ریاضی در جدول ۱۳ لیست شده است.

جدول ۱۳. فهرست نمادها

نماد	واحد	شرح
R	ft/hr	نرخ حفاری
a, b, c	بدون بعد	ثابت
S	psi	مقاومت حفاری
d	in	قطر مته
N	rev/min	سرعت دوران
W	lbf	وزن روی مته
γ	بدون بعد	وزن مخصوص سیال
F_{jm}	lbf	نیروی ضربه تعدیل یافته جت
σ	$1000 lb/in$	مقاومت فشاری سازند
ΔP	$1000 psi$	اختلاف فشار ستون گل و سازند
TVD	ft	عمق عمودی چاه

۱۰. مراجع

[1] Hapnes, M. (2014). Drilling in salt formation and rate of penetration modeling, Petroleum Geoscience and Engineering, Supervisor: John-Morten Godhavn, Norwegian University of Science and Technology (NTNU).

[2] Bourgoyne, A.T., Millheim, K.K., Chenevert, M.E., & Young, F.S. (2003). Applied drilling engineering, Ninth Edition, SPE, Richardson, 2, p. 232.

جامع کاربرد SPSS در تحقیقات پیمایشی، تهران: انتشارات متفکران.

Standford university, Standford, California SGP-TR-214, pp. 1-5.

[13] Tokhmechi, B. (2019). New approaches in 3D geomechanical earth modeling. *Journal of Petroleum Geomechanics*, 3 (1), 45-64.

[14] Burgoyne, D.J., & Young, T.C., (1984). Applying a genetic neuro-model reference adaptive controller in drilling optimization. *World Oil Magazine*, 228.

[15] Anemangely, A., Ramezanzadeh, A., & Tokhmechi B. (2017). Determination of constant coefficients of Bourgoyne and Young drilling rate model using a novel evolutionary algorithm. *Journal of Mining and Environment*, 8 (4), 693-702.

[۱۶] اصانلو، م؛ (۱۳۷۶). روش‌های حفاری. تهران: نشر صدا.

[17] Warren, T.M. (1987). Penetration rate Performance of roller cone bits. *SPE Drilling Engineering*, 9-18.

[18] Conningham, R.A. (1978). An empirical approach for relating drilling parameters. *Journal of Petroleum Technology*, 30 (7), 987-991.

[۱۹] کیا، س.م. (۱۳۹۵). شبکه‌های عصبی در متلب. تهران: خدمات نشر کیان رایانه سبز، خلیج فارس (زاینس).

[۲۰] امیری بختیار، ح؛ سجادی، ف؛ مرادی، ن. (۱۳۸۶). تطابق نموداری در بيو استراتیگرافی سازند آسماری در میدان نفتی اهواز. *مجله علوم دانشگاه تهران*، ۳۳ (۱)، ۱۰۶-۱۰۱.

[21] Beck, F.E., Powell, J.W., & Zamora, M. (1995). The effect of rheology on rate of penetration. In *SPE/IADC Drilling Conference*, Amsterdam.

[22] Kummen H.T., & Wold, A.A. (2015). The effect of cuttings on annular pressure loss, an analysis of field data in the North Sea. *Norwegian University of Science and Technology*.

[23] Eberhart, R.C., & Kennedy, J.M. (1995). A new optimizer using particle swarm theory, *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 39-43.

[24] Mohaghegh, S. (2000). Virtual-intelligence applications in petroleum engineering: part 1- artificial neural network. *Journal of Petroleum science and Engineering*, 52 (9), 64-73.

[۲۵] حبیب‌پور گنتابی، ک؛ صفری، ر. (۱۳۹۰). راهنمای