

مدل سازی افزایش سرعت و نرخ نفوذ حفاری در سنگ با کمک شبکه فازی

عصبی

محراب عزیزی^۱، روناک پروانه^۲، ناصر عبادتی^{۳*}

^۱ گروه مهندسی نفت، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران

^۲ انستیتو مهندسی نفت، دانشکده مهندسی شیمی، دانشگاه تهران، تهران، ایران

^۳ گروه زمین شناسی، واحد اسلام شهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران

* مسئول مکاتبات: ebadati@yahoo.com

چکیده

بر اساس داده‌های میدانی، روش‌های مختلفی برای کاهش هزینه حفاری چاه‌ها وجود دارد. یکی از این روش‌ها بهینه‌سازی پارامترهای حفاری برای به دست آوردن حداکثر نرخ نفوذ (ROP) موجود است. پارامترهای بسیار زیادی بر روی ROP تاثیر می‌گذارند. هدف اصلی انجام این تحقیق کاربرد شبکه‌های هوشمند برای نرخ نفوذ حفاری است که بدین منظور داده‌های ورودی چاه اعم از عمق حفاری، مدت زمان عملیات حفاری، سرعت گردش مته، وزن روی مته، وزن و حجم گل حفاری به عنوان داده ورودی و نرخ نفوذ حفاری به عنوان داده خروجی از یکی از میدانی واقع در خلیج فارس تهیه شد. ۷۰ درصد داده‌ها برای آموزش شبکه، ۱۵ درصد داده‌ها برای اعتبار سنجی و ۱۵ درصد داده‌ها برای آنالیز حساسیت اختصاص داده شده است. طبق نتایج به دست آمده مشخص شد که با استفاده از این ابزار رابطه خوبی با ضریب همبستگی کل (۰/۹۶) برای پیش بینی نرخ نفوذ با استفاده از شبکه عصبی به دست می‌آید که این نشان‌دهنده این است که مدل از اعتبار خوبی برخوردار است. همچنین با استفاده از تکرار محاسبات در تکرار ۱۲ بهترین مقدار به دست آمد که این مقدار برابر ۱۴/۲۴ درصد می‌باشد.

کلیدواژه: شبکه عصبی، نرخ نفوذ در سنگ، وزن روی مته، بهینه سازی، سرعت دورانی رشته حفاری

مقدمه

بخش عمده سرمایه‌گذاری چاه مربوط به عملیات حفاری می‌باشد. بنابراین، بهینه‌سازی نرخ نفوذ (ROP)^۱ یک جنبه کلیدی برای کاهش هزینه کل چاه است. چالش‌های مدل‌سازی ROP از این واقعیت ناشی می‌شوند که ROP توسط بسیاری از عوامل مرتبط به هم نشات می‌گیرد، که استنتاج اثر متقابل هر پارامتر جداگانه را بسیار دشوار می‌کند (Lukawski.,2014; Wardlaw et al.,1961). بنابراین، عملیات حفاری نیاز به نظارت منظم دارد تا هزینه‌های حفاری به حداقل برسد. هزینه حفاری رابطه مستقیمی با

نرخ نفوذ (ROP) حفاری دارد. از این رو، با دستیابی به نرخ قابل قبولی از ROP که منجر به بهینه سازی فرآیند حفاری و در نتیجه به حداقل رساندن هزینه حفاری می‌شود، کل پارامترهایی که بر ROP تاثیر می‌گذارند باید در طول عملیات حفاری بهینه شوند (Abdel Azim al.,2020). عوامل متعددی اعم از عوامل قابل کنترل و عوامل محیطی در میزان نرخ نفوذ مته تاثیرگذار می‌باشند که در جدول ۱ گزارش شده است.

¹ Rate of Penetration

جدول ۱: عوامل موثر در نرخ نفوذ در سنگ (Eren.2010)

عوامل محیطی	عوامل قابل کنترل
نوع سازند	وضعیت فرسایش روی مته
خصوصیات سازند	وزن روی مته
نوع سیال حفاری	طراحی و سایز مته
چگالی سیال حفاری	سرعت چرخشی مته
خصوصیات دیگر سیال حفاری	دبی جریان
فشار ته چاه سیال حفاری	قدرت هیدرولیکی مته

$$f_1 = e^{a_1}$$

$$f_2 = e^{a_2(1000 - TVD)}$$

$$f_3 = e^{a_3 D^{0.69} (MW - 67.41)}$$

$$f_4 = e^{a_3 TVD(EMW_{Pore} - ECD)}$$

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

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

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

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

مدل بینگهام^۲

مدل بینگهام یک مدل ساده است که اصلاحی از مدل Maurer (یک مدل تجربی که برای مقادیر کم وزن روی مته و سرعت چرخش قابل استفاده است) می باشد. این مدل عمق حفاری را نادیده می گیرد بنابراین ضریب خطای بالایی و کاربرد کمتری دارد (Bourgoyne et al., 1986).

$$R = K \left(\frac{W}{d_b} \right)^{a_5} N^e \quad (2)$$

مدل‌های ریاضی بسیاری برای برقراری رابطه‌ی بین پارامترهای متغیر و نرخ نفوذ در سنگ وجود دارد. اکثر آن‌ها ترکیبی از متغیرهای اولیه‌ی قابل کنترل و خصوصیات سازند هستند (باغبانی و همکاران، ۱۳۹۲). این متغیرها قابل کنترل عبارتند از وزن روی مته، وزن گل، سرعت جریان پمپ و فشار پمپ که در ادامه به بررسی خلاصه از مدل‌ها ریاضی برای بررسی نرخ نفوذ و سرعت حفاری پرداخته می شود.

مدل بورگین-یانگ^۱

از میان تمامی مدل‌های حفاری معرفی شده، مدل بورگین-یانگ بر همه مدل‌ها برتری دارد، زیرا تقریباً تمامی پارامترهای سازند و متغیرهای حفاری را در برمی گیرد. در این مدل تابع نرخ نفوذ را بر اساس هشت پارامتر، استحکام سازند، فشردگی و تراکم، تأثیر اختلاف فشار گل حفاری و سازند، وزن روی مته و سرعت چرخش مته، فرسایش دندان‌ها و هیدرولیک مته بیان کرده‌اند (Bataee et al., 2014).

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

¹ Bourgoyne & Young

² Bingham model

مدل وارن^۱

وارن یک مدل پرکاربرد برای سازندهای نرم را ارائه می‌دهد. این مدل نرخ نفوذ حفاری را به سرعت چرخش، استحکام سنگ، وزن روی مته و سایز مته مرتبط می‌کند (Bourgoyne et al., 1986 ; Nygaard et al. 2007).

$$R = \left(\frac{a S^2 d_b^3}{N W^2} + \frac{c}{N d_b} \right)^{-1} \quad (3)$$

امروزه شبکه‌های عصبی مصنوعی در دهه اخیر، موارد کاربرد فراوانی را در رشته‌های مختلف علوم برای مطالعه و بررسی عواملی همچون طبیعت داده‌ها، بهینه‌سازی، تخمین توابع و بسیاری دیگر از موارد به خود اختصاص داده‌اند. روش‌های قدیمی از الگوریتم ساده برای حل مسئله استفاده می‌کنند، در حالیکه روش شبکه فازی عصبی از فرایند فراگیری نمونه‌ها استفاده می‌کند (درویش زاده، ۱۳۸۰). در حال حاضر این روش در بخش‌های مختلفی از مهندسی نفت مانند توصیف خواص مخزن، بهره برداری و تحلیل نتایج نمودارگیری چاه و چاه آزمایشی مورد استفاده قرار گرفته است. طراحی شبکه عصبی پس انتشار شبکه‌های عصبی مصنوعی اخیراً توجه محققین را به خود جلب کرده و مشکلات پیچیده را در زمینه‌های مختلف کاربرد از جمله صنعت نفت را با موفقیت حل کرده‌اند. اساس شبکه‌های عصبی مصنوعی توانایی آن‌ها را در یادگیری و تعمیم رفتار یک سیستم با استفاده از مجموعه‌ای از وزن‌های اتصال است.

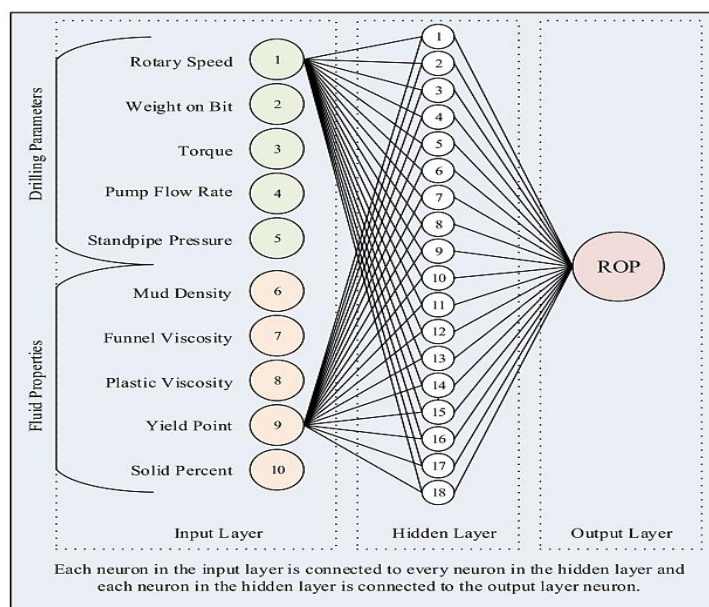
شبکه عصبی مصنوعی (ANN)^۲ به عنوان تقلید از سیستم عصبی بیولوژیکی تعریف می‌شود. شبکه فازی عصبی برای حل چالش‌های محاسباتی که تکنیک‌های محاسبات خطی قادر به رسیدگی نیستند استفاده شده است. ساختار این شبکه با تعداد لایه‌ها نشان داده می‌شود و هر لایه دارای یک عنصر اساسی است که نورون نامیده می‌شود. نورون‌ها به عنوان عناصر اصلی پردازش یک سیستم ANN عمل

می‌کنند. حداقل تعداد برای ساخت ANN سه لایه است که لایه ورودی، پنهان و خروجی است. توابع انتقال اساساً برای پیوند دادن لایه‌های ANN و الگوریتم‌های مناسب برای آموزش داده استفاده می‌شوند. علاوه بر آن، ثابت‌هایی که به عنوان وزن مدل شناخته می‌شوند، نورون‌های هر لایه را با نورون‌های لایه بعدی پیوند می‌دهند. بهینه‌سازی برای تعداد نورون‌ها مورد نیاز است، زیرا افزایش تعداد نورون‌ها ممکن است باعث برآزش بیش از حد شود و بر عملکرد پیش‌بینی تأثیر منفی بگذارد. با این حال، کاهش تعداد نورون‌ها ممکن است منجر به عدم تناسب شود. در مرحله آموزش، پس انتشار خطاها و پردازش داده‌ها از لایه ورودی تا لایه خروجی اعمال می‌شود. پس از آن، پارامترهای خروجی برآورد شده با خروجی‌های واقعی مقایسه می‌شوند. برای یک مدل ANN کارآمد، وزن‌های هر لایه به خروجی‌های تخمین زده شده با حداقل خطا به روز می‌شوند.

به طور معمول، ANN شامل یک لایه ورودی، تعداد لایه‌های پنهان (لایه‌های میانی) و یک لایه خروجی است. لایه ورودی اطلاعات را دریافت می‌کند، لایه‌های پنهان رابطه‌ای بین پارامترها ایجاد می‌کنند و سپس لایه خروجی نتایج را تشکیل می‌دهد. بهینه‌سازی برای انتخاب تعداد مناسب لایه‌ها و نورون‌ها مورد نیاز است، زیرا انتخاب بسیاری از نورون‌ها منجر به برآزش بیش از حد و انتخاب چند نورون منجر به عدم برآزش می‌شود. افزایش اندازه مدل با افزایش تعداد لایه‌های پنهان و نورون‌ها منجر به افزایش زمان محاسباتی می‌شود و منجر به به خاطر سپردن، که خطا را در طول آموزش مدل کاهش می‌دهد، در حالی که خطا در طول آزمایش داده‌های دیده نشده بالا باقی می‌ماند. شکل ۱ معماری ANN مورد استفاده را نشان می‌دهد (Ahmed et al., 2019).

¹ Warren model

² Artificial Neural Network



شکل ۱: معماری محاسبه سرعت نرخ نفوذ به روش شبکه فازی عصبی (Ahmed et al., 2019).

۲۰۱۸ به روش شبکه فازی عصبی نرخ نفوذ را بررسی کردند. آن‌ها با استفاده از ۱۰ داده ورودی که پارامترهای مکانیکی حفاری و خواص سیال را نشان می‌دهد، یک مدل نرخ نفوذ با خطای ۲۸۳ درصد ایجاد کردند (Ahmad el al., 2018). موسی و همکاران (۲۰۱۸) رویکرد جدیدی را برای تعیین نفوذپذیری مخزن با استفاده از داده‌های ثبت چاه ارائه کردند. چندین تکنیک هوش مصنوعی برای ارائه مدل نفوذپذیری استفاده شد. آن‌ها اشاره کردند که معادلات توسعه یافته دقیق هستند و از مدل‌های نفوذپذیری فعلی بهتر عمل می‌کنند (Mousa et al., 2018). هادی و همکاران در سال ۲۰۱۹ با استفاده از شبکه فازی عصبی به ضریب همبستگی بالای ۰/۹۶ دست یافتند. آن‌ها با توجه به پارامترهای ورودی، نتایج به دست آمده نشان دادند که عمق حفاری، وزن روی مته و سرعت چرخش مته بیشترین تأثیر را بر روی شرایط تخمینی نرخ نفوذ حفاری داشتند و به دنبال آن نرخ جریان پمپ، گشتاور حفاری و استحکام سنگ کاهش یافت (Hadi et al., 2019). عبدالجبار و همکاران در مطالعه دیر در سال ۲۰۲۰ از شبکه فازی

طبق نمودار شکل ۱ مدل ROP ساخته شده توسط احمد و همکاران شامل ۱۰ پارامتر ورودی (خواص سیال و پارامترهای حفاری) می‌باشد. مدل ANN از ۱۸ نورون و یک لایه پنهان تشکیل شده است. معمولاً سه فرآیند مختلف در ایجاد مدل ANN اعمال می‌شود که این فرآیند شامل آموزش^۱، اعتبارسنجی^۲ و آزمایش^۳ می‌باشد. در سال‌های اخیر مطالعاتی در زمینه بهینه سازی نرخ نفوذ حفاری به کمک شبکه فازی عصبی مورد بررسی قرار گرفته است که در ادامه به مختصری از آن پرداخته می‌شود.

نلس و همکاران (۲۰۱۸) به مقایسه کلی مدل‌های ایجاد شده برای سرعت حفاری در یکی از میدین خلیج فارس پرداختند. آن‌ها ذکر کردند که معادله‌های سرعت حفاری بدست آمده در این مقاله در چندین فواصل عمقی بر اساس دو مدل یانگ-بورگین و وارن می‌باشد بعد از مقایسه این مدل‌ها به ایجاد یک مدل جدید با استفاده از شبکه های عصبی پرداختند. آنها تصریح کردند که نتیجه این کار کاهش زمان و هزینه در حفاری چاه‌های جدید بوده است (Nelles et al., 2018). احمد و همکاران در سال

¹ Training

² Validation

³ Test

حفاری بازی کرده است. بسیاری از محققان به طور مستمر برای بهینه‌سازی نرخ نفوذ کار کرده‌اند. هدف اصلی این مطالعه بهبود بیشتر پیش‌بینی ROP با استفاده از محاسبه ضرایب همبستگی در میدان ابوذر واقع در خلیج فارس با استفاده از شبکه‌های عصبی مصنوعی است. در واقع در این مقاله به بررسی نحوه عملکرد هوش مصنوعی در محاسبه ROP نسبت به روابط ریاضی پرداخته می‌شود.

روش تحقیق

هدف اصلی این مطالعه بهبود بیشتر پیش‌بینی ROP با استفاده از محاسبه ضرایب همبستگی در میدان ابوذر واقع در خلیج فارس با استفاده از شبکه‌های عصبی مصنوعی است. میدان ابوذر در خلیج فارس در ۷۴ کیلومتری غرب جزیره خارگ و بین میدان نفتی نوروز و سروش قرار دارد (شکل ۲). مشخصات چینه شناسی سازند ابوذر مطابق جدول ۲ می‌باشد (NIOC Company, 2002). داده‌های مورد استفاده در این پروژه از گزارش‌های روزانه^۱ مربوط به چاه‌های میدان ابوذر واقع در خلیج فارس استخراج شده‌اند که حدود ۲۵۰۰ گزارش عملیات حفاری می‌باشد. اولین چاه اکتشافی در این میدان در سال ۱۹۵۹ حفر شد. چاه‌های اکتشافی دیگر از A₂ تا A₉ طی سال‌های ۱۹۶۰ تا ۱۹۷۰ حفر شدند که تولید نفت در این میدان در سال ۱۳۵۵ آغاز گردید. مخزن اصلی این میدان سازند آسماری است. بسترهای انیدریت به عنوان سنگ کلاهدک آسماری می‌باشد. مخزن ماسه سنگی تجمیع نشده با تخلخل^۲ متوسط ۳۵ درصد و نفوذپذیری^۳ بالا در حدود ۲ تا ۳ داری عضو غار نامیده می‌شود که مخزن اصلی در میدان است. برای جلوگیری از خطا در یادداشت داده‌های میدان، پس از استخراج داده‌ها تمام داده مورد بازبینی قرار گرفت تا در صورت وجود اشتباه اصلاح گردد (NIOC Company, 2002).


عصبی همراه با تکامل دیفرانسیل خود تطبیقی برای پیش‌بینی نرخ نفوذ در مخازن کربناته افقی استفاده کردند. با استفاده از شش ورودی که پارامترهای مکانیکی حفاری و خواص پتروفیزیکی تشکیل، مانند اشعه گاما، مقاومت و چگالی ظاهری را به هم متصل می‌کردند، پس از ساخت مدل به ضریب همبستگی قوی ۰/۹۶ و درصد خطای ۵/۱۲ درصد دست یافتند. آن‌ها با استفاده از چاه دیگری با داده‌های نادیده، مقادیر نرخ نفوذ حفاری و درصد خطا را به ترتیب ۰/۹۵ و ۵/۸ درصد به دست آوردند (Al-AbdulJabbar et al., 2020). موران و همکاران در سال ۲۰۲۱ از ANN برای مطالعه داده‌های حفاری قدیمی استفاده کرد و پیش‌بینی نرخ نفوذ حفاری را بهبود بخشید. آن‌ها از شش پارامتر ورودی شامل نرخ نفوذ حفاری، وزن روی مته و وزن گل مقاومت سنگ، سایش و نوع سنگ استفاده کردند. موران به ضریب همبستگی ۰/۸ دست یافتند (Moran et al. 2021). جهانبخشی و همکاران ۲۰۲۱ از شبکه فازی عصبی برای پیش‌بینی نرخ نفوذ حفاری بر اساس داده‌های چاه افست استفاده کردند. او از تعداد زیادی پارامتر ورودی، ۲۱ مورد استفاده کرد که شامل سرعت چرخشی، وزن روی بیت، فشار پمپ، تراکم گردش معادل، نوع گل، نقطه تسلیم، ویسکوزیته پلاستیک، pH گل، درصد جامد، استحکام ژل ۱۰ دقیقه، قدرت ژل ۱۰ ثانیه، سایدگی مته، نوع مته، توان هیدرولیکی مته، چگالی سنگ، تخلخل، نفوذپذیری، مته‌پذیری سازند، فشار دیفرانسیل و عمق چاه است. آن‌ها ۷۰ درصد از داده‌ها را برای آموزش مدل، ۱۵ درصد برای اعتبارسنجی مدل و ۱۵ درصد برای آزمایش مدل ترتیب دادند. آن‌ها ضریب همبستگی ۰/۹۱ و میانگین مربعات خطای ۰/۱۵ را برای داده‌های تست به دست آوردند (Jahanbakhshi et al., 2021).

در طول سال‌ها، پیش‌بینی نرخ نفوذ به دلیل تأثیر آن بر بهینه‌سازی پارامترهای مختلف که مربوط به صرفه جویی قابل توجه در هزینه است، یک قانون کلیدی برای مهندسان

¹ Daily Drilling Reports

² Porosity

³ Permeability



شکل ۲: موقعیت میدان ابوزر در حوزه خلیج فارس (ژئوسیستم جی سون)

جدول ۲: اطلاعات مربوط به چینه شناسی میدان مورد مطالعه (NIOC Company, 2002)

جنس	ضخامت (متر)	عمق از سطح دریا (متر)	لایه
سنگ رس، انیدریت شیل و دولومیت بین لایه‌ای	۲۰۹	۶۱۲	سازند گچساران
انیدریت و شیل	۶	۸۲۱	پوش سنگ اول
دولومیت نفتی و متخلخل، شیل بین لایه‌ای	۲۴	۸۲۷	بخش A (آسماری فوقانی)
انیدریت و شیل	۵	۸۵۱	بخش B (پوش سنگ غار)
ماسه سنگ، شیل و دولومیت‌های بین لایه‌ای	۸۴	۸۵۶	بخش C (ماسه سنگ غار)
دولومیت و شیل و رس بین لایه‌ای	۲۱	۹۴۰	بخش E (آسماری تحتانی)

سازند
آسماری

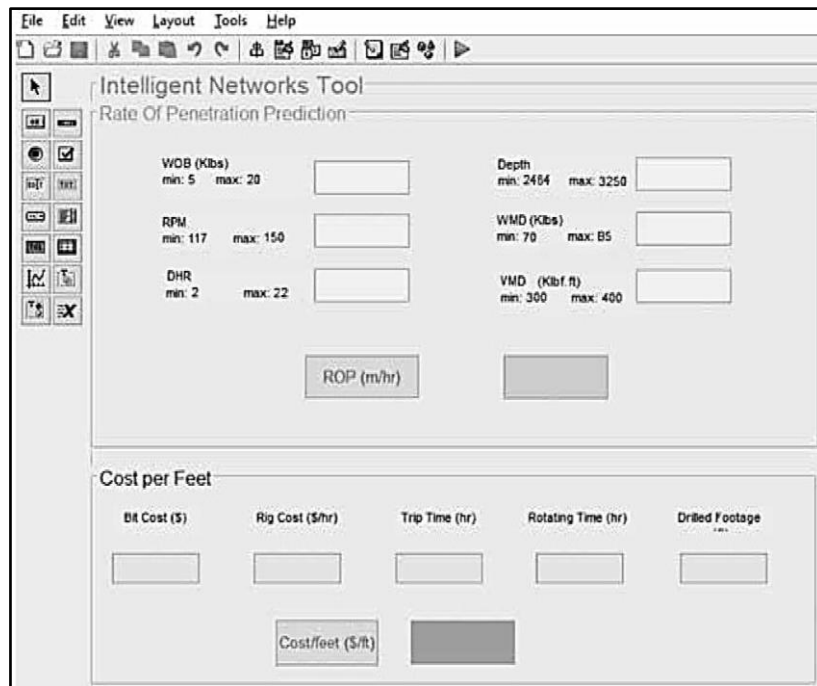
لوله‌ها است، می‌توان هزینه بر فوت که براساس فرمول ۴ موجود محاسبه شده است را به راحتی محاسبه کرد.

$$\frac{\$}{ft} = \frac{c_b + c_r(t_b + t_c + t_r)}{\Delta D} \quad (4)$$

در این فرمول، C_b قیمت مته (دلار)، C_r هزینه ثابت عملیاتی دکل حفاری (دلار بر ساعت)، t_b زمان راندن مته (ساعت)، t_c زمان اتصال (ساعت)، t_r زمان بالا و پایین کردن رشته حفاری (ساعت) و ΔD متراژ حفاری (فوت) است. اما، آنالیز هزینه مقیاس ایده‌آلی برای انتخاب مته نیست، زیرا صرفاً معرف یک محاسبه اقتصادی است و بر پایه پارامترهای واقعی حفاری نمی‌باشد. بنابراین این معیار در کنار سایر روش‌هایی که پارامترهای دیگر را در بردارد به کار می‌رود (خاکی، ۱۳۸۴).

طراحی سرعت حفاری با کمک شبکه فازی عصبی

برای طراحی آزمایش‌های بدست آمده می‌بایست مدلی را طراحی کرد که به کمک آن بتوان سرعت حفاری برای آزمایشات طراحی شده را پیش بینی کرد. در این پروژه از نرم‌افزار متلب که نرم‌افزاری مخصوص طراحی رابط گرافیکی با استفاده از کدهای نوشته شده در قالب فایل‌های مورد استفاده، از ماژول GUIDE استفاده گردید. شکل ۳ نمونه صفحه طراحی شده را نشان می‌دهد. طبق این شکل واضح است در بخش اول، پس از وارد کردن مقادیر داده‌های ورودی می‌توان نرخ نفوذ حفاری را براساس داده‌ها و جداول منتشر شده در داخل کادر مقابل ROP مشاهده نماید. در بخش دوم، پس از وارد کردن مقادیر مورد نیاز که شامل هزینه مته، هزینه دکل، زمان چرخش، زمان متصل کردن و زمان بالا بردن



شکل ۳: نمونه شکل طراحی شده جهت محاسبه نرخ نفوذ حفاری

صورت عدد نمی‌باشد، این ورودی ابتدا به وسیله کد گذاری به عدد تبدیل شده و سپس به عنوان ورودی برای شبکه تعریف می‌گردند. در غیر این صورت شبکه قادر به شناسایی ورودی نمی‌باشد. در این پژوهش عمق حفاری،

معرفی و نمایش ورودی و خروجی‌ها

در زمان کار با روش‌هایی هوش مصنوعی باید توجه داشت این شبکه‌ها اعداد را به عنوان پارامتر ورودی شناسایی می‌کنند و در صورت وجود ورودی که به

است که کمترین مقدار نرخ نفوذ در عمق ۸۹۱.۵ متری مربوط به سازند آسماری پیش بینی شده است. بدیهی است جنس سازند در این عمق حفاری بیشتر از جنس دولومیت می‌باشد. همچنین بیشترین میزان نرخ نفوذ حفاری در عمق ۷۵۱ متری بدست آمده است که این عمق مربوط به سازند گچساران است که جنس این سازند در این عمق حفاری عمدتاً شیل است.

مدت زمان عملیات حفاری، سرعت گردش مته، وزن روی مته، و حجم گل حفاری به عنوان داده ورودی و نرخ نفوذ حفاری به عنوان داده خروجی می‌باشد. جدول ۳ تعدادی از داده‌های واقعی و پارامترهای مورد استفاده در این پروژه را نشان می‌دهد. طبق جدول ۳ نرخ نفوذ حفاری بین ۵ تا ۱۲.۵ متر/ساعت پیش بینی شده

جدول ۳: داده‌های میدانی ورودی به شبکه فازی عصبی

عمق چاه (m)	ساعت حفاری	سرعت چرخش مته RPM	وزن روی مته (Klb)	وزن گل حفاری (pcf)	حجم گل پمپاژ شده	نرخ نفوذ حفاری (m/hr)
۷۵۱	۱۲	۱۵۰	۱۵-۲۰	۷۰	۳۰۰	۱۲.۵
۷۵۶	۱۲	۱۵۰	۱۵-۲۰	۷۰	۳۰۰	۹
۷۶۲	۲	۱۵۰	۲۰	۷۰	۳۰۰	۸
۷۶۸	۱۱	۱۵۰	۲۰	۷۰	۳۰۰	۷
۷۹۸.۵	۱۰	۱۵۰	۲۰	۸۵	۴۰۰	۹
۸۰۲	۲۲	۱۵۰	۲۰	۸۵	۴۰۰	۱۰
۸۱۷	۲۱	۱۵۰	۵	۸۵	۴۰۰	۱۰
۸۲۶	۲۲	۱۱۷	۵	۸۵	۴۰۰	۱۱
۸۷۹	۱۰	۱۱۷	۵	۸۵	۴۰۰	۷
۸۹۱.۵	۵	۱۱۷	۵	۸۵	۴۰۰	۵
۹۱۷.۵	۲۲	۱۱۷	۱۰	۸۵	۴۰۰	۶
۹۴۰	۲۲	۱۱۷	۱۰	۸۵	۴۰۰	۷
۹۴۵	۱۶	۱۱۷	۱۰	۸۵	۴۰۰	۷
۹۵۲.۵	۳	۱۱۷	۱۰	۸۵	۴۰۰	۹
۹۷۳.۸	۲۲	۱۱۷	۵	۸۵	۴۰۰	۹
۹۷۶	۲۲	۱۱۷	۵	۸۵	۴۰۰	۸
۹۹۱	۲۲	۱۱۷	۵-۱۰	۸۵	۴۰۰	۱۰



شکل ۴: نمودار نرخ نفوذ بر حسب عمق حفاری در سازندهای مختلف میدان ابوذر

این مقدار اختلاف بین داده‌های واقعی با داده‌های پیش بینی شده به توان ۲ است. در تحلیل نمودارهای بدست آمده برای هر مرحله، هرچه مقدار خطا به ۱ نزدیک‌تر باشد، نتیجه‌ی بهتری از شبکه به دست خواهد آمد.


از آن‌جا که هدف این پروژه توانایی شبکه فازی عصبی در بهینه‌سازی نرخ نفوذ حفاری است، لذا در ابتدا داده‌های میدان مورد مطالعه تهیه شده شامل عمق حفاری، مدت زمان عملیات حفاری، سرعت گردش مته، وزن روی مته، وزن و حجم گل حفاری را به عنوان داده ورودی و نرخ نفوذ حفاری را به عنوان داده خروجی وارد شد. اولین گام در طراحی شبکه فازی عصبی حذف داده‌های پرت می‌باشد. زیرا این داده‌ها باعث امکان وجود خطا می‌شود و نتایج غیر منطقی را نشان می‌دهد. پس با رسم نمودار نرخ نفوذ حفاری در مقابل متغیرها می‌توان داده‌های پرت را حذف نمود. شکل ۵ هیستوگرام^۱ داده‌ها را نشان می‌دهد.

نمودار شکل ۴ نرخ نفوذ حفاری بر حسب عمق حفاری را در سازندهای مختلف نشان می‌دهد. طبق نمودار شکل ۴ واضح است که با تغییر سازند گچساران به پوش سنگ اول نرخ نفوذ افزایش یافته است که علت این امر تغییر یافتن جنس سازند از شیل و دولومیت بین لایه‌ای به شیل و انیدریت می‌تواند باشد.

طراحی شبکه در میدان مورد مطالعه

شبکه عصبی داده‌ها را به سه قسمت آموزش، اعتبار سنجیو آنالیز حساسیت تقسیم می‌نماید. ۷۰ درصد داده‌ها برای آموزش شبکه اختصاص می‌یابد. ۱۵ درصد داده‌ها برای اعتبار سنجی شبکه و ۱۵ درصد برای آنالیز حساسیت اختصاص داده می‌شود. آنالیز حساسی شبکه به منظور جلوگیری از تنبلی شبکه انجام می‌پذیرد. در آخر در مجموع تمامی داده‌ها در نمودار کلی ترسیم خواهد شد. در این مقاله از روش مربع خطا (RSquare) استفاده شده است.

^۱ Histogram



شکل ۵: هیستوگرام داده‌های نرخ نفوذ حفاری در برابر عمق حفاری، مدت زمان عملیات حفاری، سرعت گردش مته، وزن روی مته، وزن و حجم گل حفاری

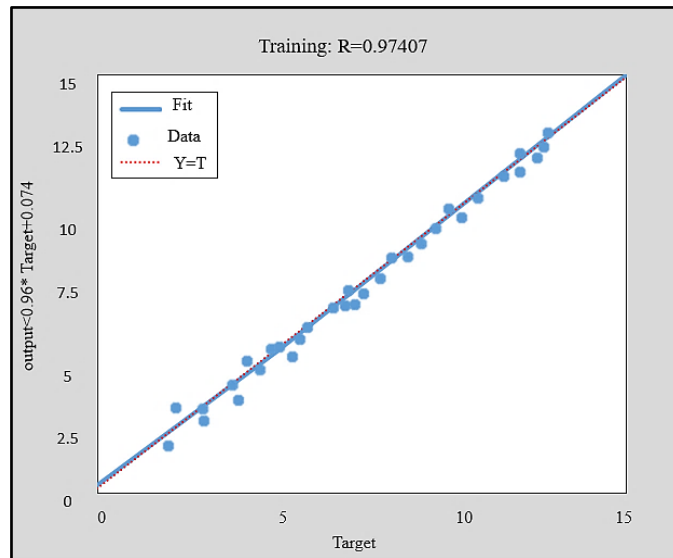
نتایج و بحث

با رسم نقطه به نقطه ۷۰ درصد داده‌ها و رسم خط گذرنده معادله ۵ به دست آمده است. طبق فرمول ۵ ضریب همبستگی برای داده‌های آموزش برابر ۰/۹۷ می‌باشد. شکل ۶ ضریب همبستگی داده آموزش را نشان می‌دهد.

با استفاده از شبکه عصبی طراحی شده به کمک نرم افزار متلب، نمودار آموزش، اعتبار سنجی، حساسیت و کلی در شکل ۶، ۷، ۸ و ۹ نشان داده شده است. برای آموزش شبکه

$$\text{Output} = 0.96 * \text{Target} + 0.074 \quad (5)$$

$$R = 0.97$$



نمودار ۶: نمودار نقطه به نقطه داده‌ها برای آموزش شبکه

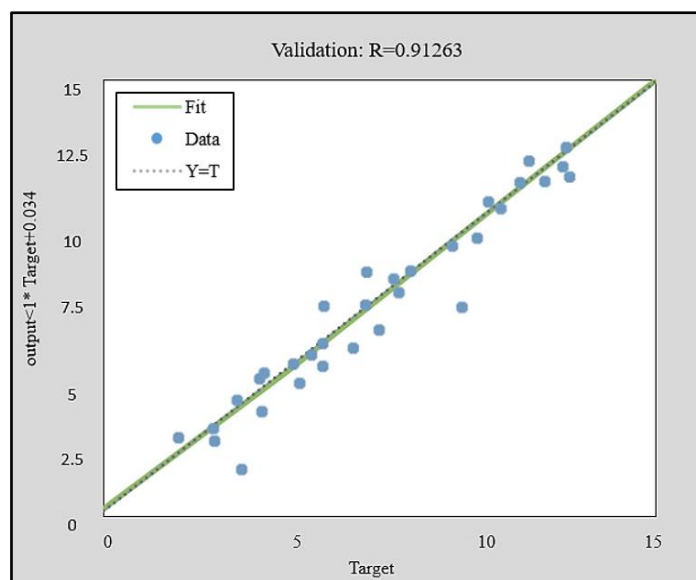
سنجی شبکه نشان می‌دهد.

$$\text{Output} = 1 * \text{Target} + 0.034 \quad (6)$$

$$R = 0.91$$

برای اعتبار سنجی شبکه با رسم نقطه به نقطه ۱۵ درصد داده و خط گذرنده معادله ۶ به دست می‌آید.

معادله زیر و شکل ۷ ضریب همبستگی ۰/۹۱ را برای اعتبار




نمودار ۷: نمودار نقطه به نقطه داده‌ها برای اعتبار سنجی شبکه

برای حساسیت سنجی شبکه با رسم نقطه به نقطه ۱۵ درصد داده و خط گذرنده معادله ۷ به دست می‌آید. معادله زیر و شکل ۸ ضریب همبستگی ۰/۹۲ را برای حساسیت سنجی شبکه نشان می‌دهد.

$$\text{Output} = 1 * \text{Target} + 0.014 \quad (7)$$

$$R = 0.92$$




نمودار ۸: نمودار نقطه به نقطه داده‌ها برای حساسیت سنجی شبکه

با توجه به معادلات به دست آمده و رسم نمودار نقطه‌ای کلی، ضریب همبستگی برابر با ۰/۹۶ به دست آمد.

$$\text{Output} = 1 * \text{Target} + 0.015 \quad (8)$$

$$R = 0.96$$

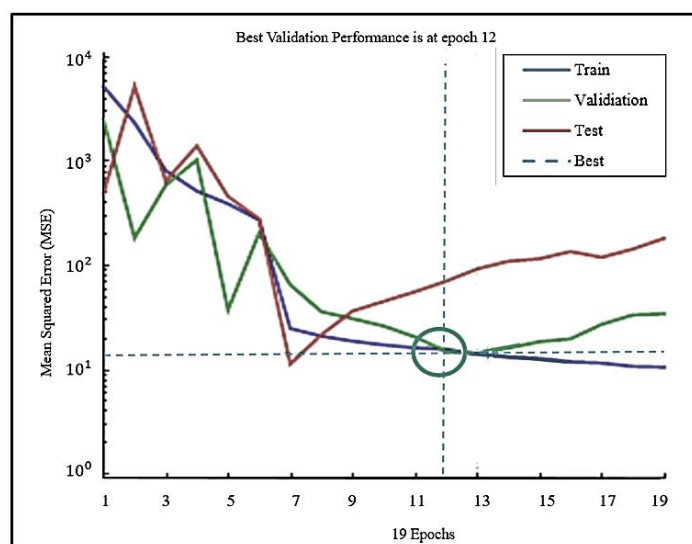


شکل ۹: نمودار نقطه به نقطه داده‌ها برای کل شبکه

نزدیک‌تر باشد به منزله پاسخ بهتر می‌باشد. میانگین مربعات خطا (MSE) به عنوان تابع عملکرد برای ارزیابی استحکام مدل ساخته شده در هر تکرار استفاده می‌شود. شکل ۱۰ خطاهای آموزش، اعتبارسنجی و آزمایش را برای سیستم شبکه‌های عصبی مصنوعی انتخابی نهایی در طول فرآیند آموزش نشان می‌دهد. همانطور که شکل ۱۰ نشان می‌دهد، هنگامی که شبکه عصبی با داده‌های آموزشی آموزش داده می‌شود، خطا کاهش می‌یابد. با توجه به روند منحنی زیر، در تکرار ۱۲ بهترین مقدار به دست آمد که برابر ۱۴/۲۴ است.

تکرار محاسبات (Epoch)

ایپوک به منزله تکرار محاسبات است. برای تمامی مراحل انجام شده، نمودار ۱۰ بیانگر تعداد تکرارهای صورت گرفته می‌باشد. در این پژوهش مقادیر به دست آمده در نوزدهمین مرحله تکرار نشان داده شده است. به عبارت دیگر شبکه پس از حل مدل ایجاد شده داده خروجی را به صورت نمودار ارائه می‌دهد. نمودار شکل ۱۰ بیانگر این هستند که پس از ۱۹ مرحله تکرار جواب به دست آمده است. شبکه پس از حل معادله‌ها و تکرارها، بهترین بازه را ارائه خواهد داد. در واقع هر چه میانگین خطای مربعات به صفر




شکل ۱۰: خطاهای آموزش و اعتبارسنجی و آزمایش مدل شبکه عصبی مصنوعی

روش رگرسیون چند متغیره خطی

در شکل ۱۱ نرخ نفوذ حفاری اندازه گیری شده نسبت به نرخ نفوذ حفاری پیش بینی شده نشان داده شده است که در آن $R^2=0/96$ به دست آمده است. با توجه به اینکه ضریب همبستگی به عدد ۱ خیلی نزدیک است پس این مدل همچنین توانایی خوبی در تخمین ROP را نشان می دهد.

$$Y=0.9435X+8.5453 \quad (9)$$

$$R^2=0.96$$



شکل ۱۱: رابطه بین ROP پیش بینی شده و اندازه گیری شده به کمک شبکه فازی عصبی

(۲) ضریب همبستگی که برای داده‌ها در بخش‌های مختلف با استفاده از روش حداقل مربعات به دست آمد، برای آموزش شبکه برابر با $0/97$ برای اعتبار سنجی شبکه برابر است با $0/91$ برای آنالیز حساسیت سنجی شبکه برابر است با $0/92$ و برای مجموع داده‌ها برابر است با $0/96$ است.

(۳) از آنجا که ضریب همبستگی به ۱ نزدیک است، پس این شبکه قابل اعتماد بوده و برای حفاری‌های آینده در میدان مورد مطالعه بسیار کاربرد خواهد داشت.

(۴) با این روش خطای انسانی کم شده و بهترین مقدار پارامترهای حفاری را در زمان حفاری چاه‌های نفت اعمال می‌شود.

(۵) با استفاده از شبکه عصبی طراحی شده در پانل اول، پس از وارد کردن داده‌های ورودی، می‌توان

همانطور که شکل ۱۰ نشان می‌دهد، هنگامی که شبکه عصبی با داده‌های آموزشی، آموزش داده می‌شود، خطا نسبت اعتبار سنجی و حساسیت سنجی کمتر است. در واقع شبکه پس از آموزش اطلاعات کافی در مورد ویژگی‌های مدل دارد و می‌تواند راه حل‌های قابل قبولی برای داده‌های مشابه ارائه دهد. نتایج نشان می‌دهد که مدل‌های شبکه عصبی مصنوعی به طور رضایت‌بخشی در تخمین ROP موفق بوده‌اند.

نتیجه گیری

در این پژوهش ابتدا یک بانک اطلاعاتی از عملکرد حفاری در میدان نفتی ابوذر واقع در خلیج فارس تهیه شد و پس از آن با استفاده از روش‌های هوشمند مدل‌هایی برای پیش‌بینی نرخ نفوذ حفاری ارائه شد. نتایج به دست آمده از این تحقیق به صورت زیر است:

(۱) کمترین مقدار نرخ نفوذ در عمق 891.5 متری مربوط به سازند آسماری پیش بینی شده است. بدیهی است جنس سازند در این عمق حفاری بیشتر از جنس دولومیت می‌باشد. همچنین بیشترین میزان نرخ نفوذ حفاری در عمق 751 متری بدست آمده است که این عمق مربوط به سازند گچساران است که جنس این سازند در این عمق حفاری عمدتاً شیل است.

A. (2019). New artificial neural networks model for predicting rate of penetration in deep shale formation. *Sustainability*, 11(22), 6527.

Bataee, M., Kamyab, M., & Ashena, R. (2010). International Oil and Gas Conference and Exhibition in China.

Bourgoyne, A. T., Millheim, K. K., Chenevert, M. E., Young Jr., F. S., "Applied Drilling Engineering (SPE Textbook Series, Vol. 2)," Society of Petroleum Engineers, ISBN-13: 978.

Eren, T., 2010. Real Time Optimization of Drilling Parameters During Drilling Operations. PhD Thesis, Middle East Technical University, Turkey.

Hadi, F., Altaie, H., & AlKamil, E. (2019, November). Modeling rate of penetration using artificial intelligent system and multiple regression analysis. In Abu Dhabi International Petroleum Exhibition & Conference.

Jahanbakhshi, R.; Keshavarzi, R.; Jafarnezhad, A. Real-time Prediction of Rate of Penetration during Drilling Operation in Oil and Gas Wells. In Proceedings of the ARMA-2012-244 Was Presented at 46th U.S. Rock Mechanics Geomechanics Symposium, Chicago, IL, USA, 24–27 June 2012.

Lukawski, M.Z.; Anderson, B.J.; Augustine, C.; Capuano, L.E.; Beckers, K.F.; Livesay, B.; Tester, J.W. Cost analysis of oil, gas, and geothermal well drilling. *J. Pet. Sci. Eng.* 2014, 118.

Mousa, T., Elkatatny, S.M., Mahmoud, M.A., and Abdurraheem, A. 2018. Improved Permeability Correlations from Well Log Data using Artificial Intelligence Approaches. *Journal of Energy Resources Technology*.

Moran, D.P.; Ibrahim, H.F.; Purwanto, A.; Osmond, J. Sophisticated ROP Prediction Technology Based on Neural Network Delivers Accurate Results Sophisticated ROP. In Proceedings of the SPE-132010-MS Was Presented at IADC/SPE Asia Pacific Drilling Technology Conference and Exhibition, Ho Chi Minh City, Vietnam, 1–3 November 2010.

Nelles O., Ernst S., and Isermann R., 2018, "Neural network models for identification of nonlinear dynamic systems", Adzeti, Germany.

Nygaard, R., Hareland, G., Latin American & Caribbean Petroleum Engineering Conference Buenos Aires, Argentina, ISBN : 978-1-55563-185-7 (2007).

Wardlaw, H. Simplified Analysis Aids in Optimizing Drilling Factors for Minimum Cost. *J. Pet. Technol.* 1961, 13, 475–482.

با انتخاب شبکه فازی عصبی نرخ نفوذ حفاری را پیش‌بینی نماید و در پانل دوم، پس از ورود داده‌های مورد نظر می‌توان نمودار هزینه بر فوت و پیش‌بینی نرخ نفوذ حفاری را مشاهده کرد که این موضوع برای حفاری‌های آینده می‌تواند خیلی مفید باشد.

(۶) با روش تکرار محاسبات مشخص شد، در تکرار ۱۲ بهترین مقدار به دست آمد که این مقدار برابر ۱۴/۲۴ است.

(۷) نمودار مقایسه‌ای نرخ نفوذ اندازه‌گیری شده نسبت به نرخ نفوذ پیش‌بینی شده با شبکه فازی عصبی نشان داد این مدل با ضریب رگرسیون ۰/۹۶ قابل قبول است.

منابع

باغبانی، مرادزاده، نخعی، روکی، (۱۳۹۲)، "تخمین سرعت

حفاری با سیال کف با استفاده از شبکه عصبی مصنوعی

رگرسیون عمومی"، دومین همایش علمی مهندسی مخازن

هیدروکربوری، علوم و صنایع مرتبط، تهران،

<https://civilica.com/doc/200249>

شرکت نفت مرکزی ایران، (۱۳۸۳) "گزارشات تکمیلی

حفاری"، آرشیو اداره حفاری.

درویش زاده، ع، (۱۳۸۰) "زمین شناسی ایران"، مؤسسه

انتشارات امیر کبیر، تهران.

Abdel Azim, R. (2020). Application of artificial neural network in optimizing the drilling rate of penetration of western desert Egyptian wells. *SN Applied Sciences*, 2(7), 1177.

Ahmed, A.; Elkatatny, S.; Ali, A.; Mahmoud, M.; Abdurraheem, A. New Model for Pore Pressure Prediction While Drilling Using Artificial Neural Networks. *Arabian J. Sci. Eng.* 2018, 44, 6079–6088

Al-AbdulJabbar, A., Elkatatny, S., Abdulhamid Mahmoud, A., Moussa, T., Al-Shehri, D., Abughaban, M., & Al-Yami, A. (2020). Prediction of the rate of penetration while drilling horizontal carbonate reservoirs using the self-adaptive artificial neural networks technique. *Sustainability*, 12(4), 1376.

Ahmed, A., Ali, A., Elkatatny, S., & Abdurraheem,

Artificial Neural Networks Models for Rate of Penetration Prediction in Rock Drilling

Mehrab Azizi¹, Ronak Parvaneh², Naser Ebadati^{3*}

¹Department of Petroleum Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

²Institute of Petroleum Engineering, School of Chemical Engineering, University of Tehran, Iran

³Department of Geology, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran

*Corresponding Author: ebadati@yahoo.com

Abstract

Based on field data, there are various methods to reduce the cost of drilling wells. One of these methods is to optimize the drilling parameters to obtain the maximum rate of penetration (ROP). Many parameters affect ROP. The main purpose of this research is the use of smart networks for the penetration rate of drilling, for this purpose, well input data including drilling depth, duration of the drilling operation, speed of rotation of the drill, weight on the drill, weight and volume of drilling mud as input data. And the drilling penetration rate was prepared as output data from one of the fields located in the Persian Gulf. 70% of data is allocated for network training, 15% of data for validation and 15% of data for sensitivity analysis. According to the obtained results, it was found that using this tool, a good relationship with the total regression coefficient (0.96) is obtained for predicting the penetration rate using a neural network. Also, by repeating the calculations in repetition 12, the best value was obtained, which is equal to 14.24.

Keywords: Neural network, Rock penetration rate, Drill weight, Optimization, Drilling rotation speed