

# ارائه ابزار گرافیکی به منظور پیش‌بینی نرخ نفوذ حفاری با استفاده از شبکه‌های هوشمند

سیدحسین مشعشعی<sup>۱</sup>، آرش ابراهیم آبادی<sup>۲\*</sup> و سید ابوالقاسم امامزاده<sup>۱</sup>  
 ۱- دانشکده مهندسی نفت، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران  
 ۲- گروه مهندسی معدن، واحد قائم شهر، دانشگاه آزاد اسلامی، قائم شهر، ایران

تاریخ دریافت: ۹۶/۶/۲۹ تاریخ پذیرش: ۹۷/۳/۱

## چکیده

پیش‌بینی نرخ نفوذ حفاری به دلیل نقش آن در به حداقل رساندن هزینه‌های حفاری برای بهینه‌سازی حفاری از اهمیت زیادی برخوردار است. تحلیل اطلاعات میدانی، عنصر اصلی کاهش هزینه و بهبود عملیات حفاری بوده و توسعه ابزارهای تحلیل اطلاعات میدانی و ارائه مدل‌های پیش‌بینی، یکی از راه‌های توسعه و بهبود عملیات حفاری به شمار می‌رود. هنگامی که یک سیستم حفاری مستقر شد، تنها تعداد پارامترهای محدودی هستند که قابل کنترل و تغییر هستند؛ لذا موفقیت‌آمیز بودن طرح‌های حفاری به میزان زیادی به پیش‌بینی عملکرد حفاری وابسته است. هدف اصلی انجام این تحقیق کاربرد شبکه‌های هوشمند و ارائه ابزارهایی گرافیکی برای پیش‌بینی نرخ نفوذ حفاری است که بدین منظور یک بانک اطلاعاتی از داده‌های میدانی از جمله عمق چاه، وزن روی مته، سرعت چرخش مته، فشار لوله حفاری، وزن روی قلاب و گشتاور از یکی از میادین جنوب کشور تهیه شد. در این تحقیق دو نوع مختلف و کاربردی از ابزار گرافیکی برای پیش‌بینی نرخ نفوذ حفاری و نیز محاسبه هزینه بر فوت، با استفاده از شبکه عصبی و عصبی فازی توسعه داده شد که ابزار اول در خصوص پیش‌بینی نرخ نفوذ حفاری و ابزار دوم به منظور ارزیابی اقتصادی عملکرد مته و محاسبه هزینه بر فوت ارائه شده است. نتایج تحلیل‌ها با استفاده از این ابزار گرافیکی نشان داد که رابطه خوبی با ضریب همبستگی ( $R^2=0/94$ ) برای پیش‌بینی نرخ نفوذ با استفاده از شبکه عصبی به دست می‌آید. در ادامه به جهت بهبود رابطه به دست آمده از روش شبکه عصبی فازی بهره گرفته شد. نتایج نشان داد که رابطه بسیار خوبی با دقت بالا با ضریب تعیین ( $R^2=0/99$ ) حاصل می‌شود که حاکی از بهبود دقت مدل پیش‌بینی با استفاده از روش عصبی فازی است.

**کلمات کلیدی:** نرخ نفوذ حفاری، پیش‌بینی، هزینه بر فوت، شبکه‌های هوشمند، شبکه عصبی فازی

## مقدمه

عملیات حفاری و به حداقل رساندن هزینه‌های حفاری دارد که در این راستا اطلاعات میدانی باید با دقت بالا برداشت و مورد تحلیل قرار گیرد که در این خصوص می‌توان از ابزارهای تحلیل اطلاعات بهره برد.

ارزیابی عملکرد حفاری نقش مهمی در بهره‌وری

وزن بر بیت، عمق و سرعت چرخشی که در طول عملیات حفاری ثبت شده است، استفاده می‌شود [۳]. بورگینه و یانگ روش رگرسیون چندگانه<sup>۱</sup> را برای به‌دست آوردن مجهولات استفاده کردند که این روش مجموعه‌ای از معادلات خطی را با تشکیل یک ماتریس رگرسیونی حل می‌کند [۴].

داشویسکی و همکاران از قدرت شبکه‌های عصبی (NN) برای مدل‌سازی 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 [۵]. مطهری و همکاران مدلی برای پیش‌بینی وزن روی مته بهینه، با تنظیم داده‌های عملکرد موتور با یک مدل نرخ نفوذ ارایه دادند [۶]. هانکین و همکاران روشی جهت پیش‌بینی بهینه تجهیزات و پارامترهای عملیاتی از طریق شبیه‌سازی عملیات حفاری در میدان لوزیانا ارایه دادند [۷].

ونگ و صالحی شبکه‌ای عصبی جهت پیش‌بینی بهینه هیدرولیک گل ارایه دادند. آن‌ها آنالیز حساسیت روی پارامترهای ورودی را جهت بررسی خروجی مدل مد نظر قرار دادند [۸]. مروجی و همکاران 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 با استفاده از داده‌های حفاری میدان واقعی مورد بررسی قرار دادند [۹].

عامر و همکاران استفاده از شبکه‌های عصبی مصنوعی (ANN) برای پیش‌بینی نرخ نفوذ حفاری (ROP) برای بهینه‌سازی انتخاب مته بررسی کرد [۱۰].

عباس خاکسار و همکاران برای بهینه‌سازی عملیات حفاری از شبکه‌های عصبی درک چند

با استفاده از مدل‌های پیش‌بینی عملکرد و نتایج حاصل از تحلیل‌های حاصل از برداشت‌های میدانی می‌توان دیدگاه بهتری از عملیات حفاری به‌دست آورد و با تغییر و اصلاح پارامترهای موثر، به نتایج بهتر و اثربخش‌تری دست یافت. در روند بهینه‌سازی عملیات حفاری عوامل مختلفی چون هزینه، ایمنی و تکمیل چاه دخالت دارند که در این بین، عامل اصلی نرخ نفوذ حفاری<sup>۱</sup> است. پیش‌بینی نرخ نفوذ حفاری عاملی کلیدی در موفقیت پروژه‌های حفاری بوده که به عواملی چون خواص سازند، رئولوژی گل، وزن روی مته، سرعت چرخش مته، نوع مته، انحراف چاه، هیدرولیک مته و غیره بستگی دارد [۱۱].

از عوامل مهم دیگر موثر در ارزیابی عملکرد حفاری، هزینه حفاری بازه حفر شده از یک چاه، در یک راندن مته، مجموع قیمت مته، هزینه تعویض مته و هزینه عملیاتی دکل حفاری برای مدت زمان حفاری آن بازه است. اگر هزینه راندن مته بر طول حفاری شده تقسیم شود، هزینه حفاری واحد طول بازه حفاری شده (معمولاً برحسب هزینه به‌ازای فوت<sup>۲</sup>) به‌دست می‌آید. هزینه حفاری واحد طول یک مته معین، در صورت انتخاب صحیح وزن روی مته و سرعت دوران، حداقل خواهد بود. همواره گران‌ترین و یا ارزان‌ترین مته، بهترین انتخاب نیست چون هزینه بر فوت بستگی به عوامل متعددی دارد که قیمت مته یکی از آنهاست. همچنین هزینه بر فوت ارتباط تنگاتنگی با نرخ نفوذ حفاری دارد [۱ و ۲].

در این تحقیق سعی می‌شود روابطی برای پیش‌بینی نرخ نفوذ و هزینه بر فوت ارائه شود که تأکید ویژه بر پارامتر مهم نرخ نفوذ خواهد بود. درخصوص پیش‌بینی نرخ نفوذ، مطالعات ارزشمندی انجام شده است. بیلگسو و همکاران یک روش جدید برای پیش‌بینی مقدار ROP در حین حفاری معرفی کردند. این روش از داده‌های اندازه‌گیری شده برای تعیین رابطه بین پارامترهای مختلف مانند نوع بیت،

1. Rate of Penetration (ROP)

2. Cost per Foot

3. Multiple Regression Technique

و پردازش تشکیل می‌شود. هر لایه شامل گروهی از سلول‌های عصبی (نورون) است که عموماً با کلیه نورون‌های لایه‌های دیگر در ارتباط هستند، مگر این که کاربر ارتباط بین نورون‌ها را محدود کند؛ ولی نورون‌های هر لایه با سایر نورون‌های همان لایه، ارتباطی ندارند. نورون کوچک‌ترین واحد پردازش‌گر اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. یک شبکه عصبی مجموعه‌ای از نورون‌هاست که با قرار گرفتن در لایه‌های مختلف، معماری خاصی را بر مبنای ارتباطات بین نورون‌ها در لایه‌های مختلف تشکیل می‌دهند. نورون می‌تواند یک تابع ریاضی غیرخطی باشد، در نتیجه یک شبکه عصبی که از اجتماع این نورون‌ها تشکیل می‌شود، نیز می‌تواند یک سامانه کاملاً پیچیده و غیرخطی باشد. در شبکه عصبی هر نورون به‌طور مستقل عمل می‌کند و رفتار کلی شبکه، برآیند رفتار نورون‌های متعدد است. به عبارت دیگر، نورون‌ها در یک روند همکاری، یکدیگر را تصحیح می‌کنند. در روش عصبی-فازی نیز برای هر یک از نورون‌ها و پارامترها وزن در نظر گرفته می‌شود [۲]. در ادامه مراحل و گام‌های مدل‌سازی با این روش‌های هوشمند برای میدان مورد مطالعه ارائه می‌شود.

### طراحی شبکه عصبی در میدان مورد مطالعه

#### دلیل استفاده از شبکه عصبی چند لایه (MLP)

با توجه به اینکه هدف از این تحقیق بررسی توانایی شبکه عصبی و عصبی-فازی در پیش‌بینی نرخ نفوذ حفاری بوده است، لذا استفاده از شبکه عصبی MLP به لحاظ امکانات کنترلی بهتر نظیر استفاده از توابع فعال‌ساز مختلف با لایه‌بندی‌های متفاوت که در اختیار کاربر قرار می‌دهد به‌عنوان کاندید انتخاب گردید.

لایه<sup>۱</sup> استفاده کردند. دو مدل با استفاده از شبکه‌های عصبی برای تعیین نوع مته و میزان نفوذ (ROP) توسعه داده شده است. سپس ورودی‌های مدل دوم توسط الگوریتم ژنتیک (GA) برای دسترسی به حداکثر میزان نفوذ بهینه‌سازی شده است. برای پیش‌بینی نوع مته و میزان نفوذ در مرحله آزمایش، ضرایب همبستگی به ترتیب برابر با ۰/۹۸ و ۰/۹۶ به‌دست آوردند [۱۱]. در این مقاله سعی شده است پس از معرفی روش‌های هوشمند در تحلیل نرخ نفوذ حفاری، با توجه به اهمیت و کاربردی بودن دو عامل نرخ نفوذ حفاری و هزینه بر فوت در عملکرد حفاری که در بالا اشاره شده است، ابزاری گرافیکی به صورت رابط گرافیکی کاربر GUI<sup>۲</sup> جهت پیش‌بینی نرخ نفوذ حفاری و هزینه بر فوت به صورت مجزا با استفاده از شبکه عصبی و عصبی-فازی طراحی و ساخته شود. این ابزار به صورت رابط کاربری آسان، به کاربر بدون نیاز به دانش برنامه‌نویسی کمک خواهد کرد با وارد کردن مقادیر ورودی: عمق چاه، وزن روی مته، سرعت چرخش مته، فشار لوله حفاری، وزن روی قلاب<sup>۳</sup>، گشتاور، بتواند خروجی نرخ نفوذ حفاری پیش‌بینی شده را به‌دست آورد. این در حالی است که در مقالات و پژوهش‌های قبلی تنها مبادرت به ارائه مدل پیش‌بینی نرخ نفوذ حفاری با استفاده از شبکه‌های هوشمند صورت گرفته است. در رابط گرافیکی دیگر نیز کاربر با وارد کردن مقادیر ورودی: هزینه مته، هزینه دکل، زمان چرخش، زمان متصل کردن و زمان بالا بردن لوله‌ها، خروجی هزینه بر فوت را محاسبه خواهد کرد. در این مقاله هر دو رابط گرافیکی به صورت مجزا در یک پنجره طراحی و ساخته خواهد شد، که قابلیت تبدیل به نرم‌افزار نیز خواهد داشت. در این مقاله با ارائه رابط گرافیکی، لازم به ذکر است که تعداد ۴۵۵ داده از عملکرد حفاری در یکی از میدانی نفتی ایران جمع‌آوری شده است.

### روش تحقیق

#### تحلیل عصبی و عصبی-فازی

یک شبکه عصبی مصنوعی، از سه لایه ورودی، خروجی

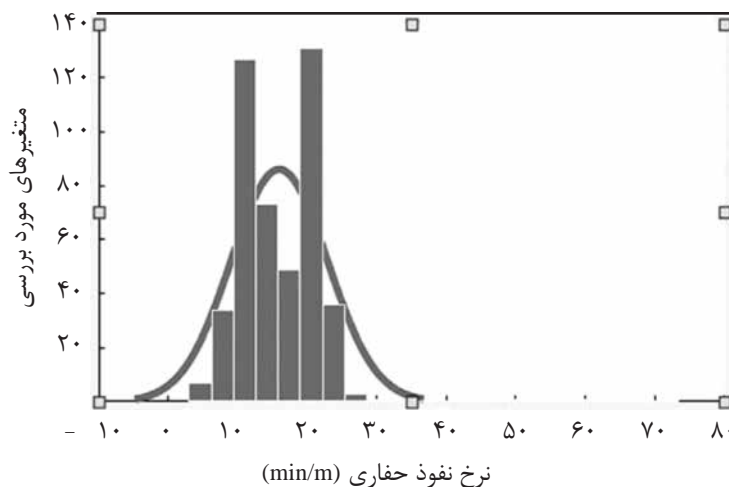
1. Multilayer Perceptron (MLP)  
2. Graphical User Interface  
3. Weight on Hookload (WHO)

۱۰ نورون در لایه دوم در نظر گرفته شد. با توجه به طراحی‌های بسیار دیگری که انجام گرفت، مشاهده شد که تفاوت چشم‌گیری با افزایش تعداد لایه‌های پنهان و تعداد نورون‌های هر لایه وجود ندارد. توابع تبدیل استفاده شده در این شبکه شامل توابع  $\text{tansig}$ ،  $\text{logsig}$  و  $\text{Purelin}$  است. از تابع  $\text{trainbr}$  نیز به جهت آموزش این شبکه استفاده شد. طرح کلی شبکه عصبی استفاده شده در شکل ۲ نشان داده شده است. همچنین میزان داده‌های مربوط به یادگیری<sup>۲</sup> و آزمون<sup>۳</sup> در جدول‌های ۲ و ۳ آورده شده است.

### طراحی شبکه عصبی فازی برای میدان مورد مطالعه

در این تحقیق به منظور تولید Fuzzy Interaction System از روش sub-Clustering استفاده گردید. طراحی عصبی-فازی با استفاده از نرم‌افزار متلب انجام پذیرفت. در طراحی شبکه عصبی فازی پس از وارد کردن داده‌های مذکور به‌عنوان داده‌های ورودی و نرخ نفوذ حفاری به‌عنوان داده خروجی، یک شبکه عصبی فازی را ایجاد می‌شود.

در طراحی شبکه عصبی ابتدا داده‌های بانک اطلاعاتی تهیه شده از میدان مورد مطالعه از جمله عمق چاه، وزن روی مته، سرعت چرخش مته، فشارلوله حفاری و گشتاور به‌عنوان داده‌های ورودی و نرخ نفوذ حفاری به‌عنوان داده خروجی وارد شد. برای انجام این کار ابتدا شناسایی و حذف داده‌های پرت باید انجام پذیرد. داده‌های فوق با توجه به امکان وجود خطا در حین عملیات و ثبت آنها در برخی موارد ممکن است نتایج غیر منطقی نشان دهند. اما با رسم نمودار نرخ نفوذ حفاری در مقابل متغیرهای مورد بررسی و مشاهده نحوه پراکندگی داده‌ها، ابتدا نمودار نحوه انتشار داده‌ها رسم می‌شود. سپس براساس نمودار توزیع نرمال، داده‌های پرت حذف می‌گردد. هیستوگرام<sup>۱</sup> داده‌های نرخ نفوذ حفاری در شکل ۱ به نمایش در آمده است. شایان ذکر است نمونه‌ای از داده‌های استفاده شده در جدول ۱ آورده شده است. لیست کامل داده‌ها در صورت نیاز قابل آرایه خواهد بود. در ادامه داده‌های اصلاح شده به‌صورت ورودی در دو محیط شبکه عصبی و عصبی-فازی بررسی می‌شود. در طراحی این شبکه عصبی، پس از تحلیل‌های گسترده و ارزیابی عملکرد شبکه، از ۲ لایه پنهان استفاده شده که ۲۰ نورون در لایه اول،




شکل ۱ هیستوگرام داده‌های نرخ نفوذ حفاری در برابر متغیرهای عمق چاه، وزن روی مته، سرعت چرخش مته، فشارلوله حفاری، وزن روی قلاب و گشتاور

1. Histogram
2. Train
3. Test

جدول ۱ داده‌های میدانی ورودی به شبکه عصبی

عمق چاه (ft)	وزن روی مته (klb)	وزن روی قلاب (klb)	سرعت چرخش مته (RPM)	گشتاور (Klb <sub>r</sub> .ft)	فشار لوله حفاری (Psi)	نرخ نفوذ حفاری (min/m)
۱۵۰۰	۶	۲۳۳	۲۱۳	۵	۲۰۵۸	۹
۱۵۰۱	۵	۲۳۴	۲۱۳	۵	۲۰۴۶	۸
۱۵۰۲	۵	۲۳۴	۲۱۳	۵	۲۰۵۳	۹
۱۵۰۳	۴	۲۳۵	۲۱۳	۵	۲۰۴۸	۸
۱۵۰۴	۵	۲۳۴	۲۱۳	۵	۲۰۵۹	۸
۱۵۰۵	۴	۲۳۵	۲۱۳	۵	۲۰۶۶	۹
۱۵۰۶	۴	۲۳۵	۲۱۳	۵	۲۰۵۲	۹
۱۵۰۷	۴	۲۳۵	۲۱۳	۵	۲۰۵۰	۹
۱۵۰۸	۴	۲۳۵	۲۱۳	۵	۲۰۶۷	۱۰
۱۵۰۹	۲	۲۳۷	۲۱۳	۵	۲۰۴۰	۱۰
۱۵۱۰	۳	۲۳۶	۲۱۳	۵	۲۰۵۷	۱۱
۱۵۱۱	۴	۲۳۵	۲۱۳	۵	۲۰۴۲	۹
۱۵۱۳	۷	۲۳۴	۱۴۱	۰	۲۱۲۹	۷
۱۵۱۴	۷	۲۲۹	۱۴۱	۰	۲۰۹۷	۵
۱۵۱۵	۵	۲۲۹	۱۴۱	۰	۲۰۸۹	۶
۱۵۱۶	۵	۲۲۹	۱۴۱	۰	۲۰۹۷	۷
۱۵۱۷	۶	۲۲۷	۱۴۱	۰	۲۱۲۶	۷
۱۵۱۸	۷	۲۲۴	۱۴۱	۰	۲۱۵۸	۹
۱۵۱۹	۹	۲۲۴	۱۴۱	۰	۲۱۵۹	۸
۱۵۲۰	۱	۲۳۵	۱۴۱	۰	۱۹۶۴	۱۰
۱۵۲۱	۱	۲۳۶	۱۴۱	۱	۱۹۶۲	۷
۱۵۲۲	۲	۲۳۲	۱۴۱	۱	۲۰۳۶	۱۱
۱۵۲۳	۳	۲۳۴	۱۴۱	۱	۲۰۰۳	۶
۱۵۲۴	۰	۲۴۲	۱۸۱	۴	۱۹۷۲	۸
۱۵۲۵	۱	۲۴۲	۱۸۱	۴	۱۹۸۳	۱۰
۱۵۲۶	۱	۲۴۲	۱۸۱	۴	۱۹۷۶	۱۰
۱۵۲۷	۱	۲۴۲	۱۸۱	۴	۱۹۷۸	۱۰
۱۵۲۸	۱	۲۴۲	۲۱۳	۴	۱۹۷۱	۱۰
۱۵۲۹	۱	۲۴۲	۲۱۳	۴	۱۹۷۷	۱۰



شکل ۲ نمایه‌ای از شبکه عصبی تولید شده جهت ساخت ابزار شبکه عصبی

جدول ۲ برخی داده‌های استفاده شده در شبکه عصبی جهت ساخت ابزار شبکه عصبی

تابع انتقال لایه اول	تابع انتقال لایه دوم	تابع انتقال لایه خروجی
Tansig	Logsig	Purelin

جدول ۳ میزان داده‌های تست و آموزش و تصدیق جهت ساخت ابزار شبکه عصبی

مقدار داده‌های آموزش	مقدار داده‌های تست
۸۰	۲۰

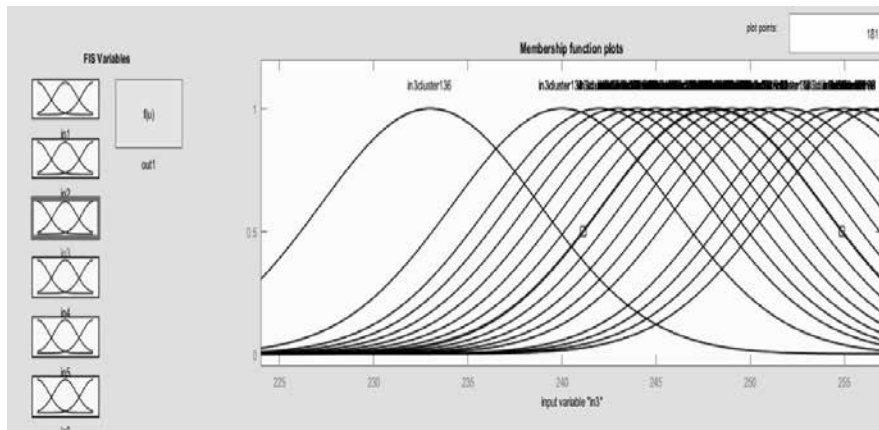
داده‌های اندازه‌گیری شده با داده‌ای تولیدی شبکه عصبی در نمودار کلی عدد  $R^2=0/93756$  را نشان می‌دهد. در مورد شبکه عصبی- فازی نیز، ابتدا نمودار داده‌های اندازه‌گیری شده با داده‌های هدف شبکه عصبی فازی (شکل ۶-الف) نشان داده شده است در ادامه نیز نمودار داده‌های پیش‌بینی شده شبکه عصبی- فازی که بر داده‌های اندازه‌گیری شده منطبق گردیده است (شکل ۶-ب). داده‌های اندازه‌گیری شده با داده‌های حاصل از شبکه عصبی- فازی به نحو قابل قبولی روی یکدیگر منطبق شده است. بررسی نمودار مقایسه‌ای نرخ نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی در شکل ۷-الف نشان داد که در آن  $R^2=0/8792$  است. نمودار مقایسه‌ای نرخ نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی- فازی در شکل ۷-ب نشان داده شد، که در آن  $R^2=0/8892$  است، که بیانگر این است که شبکه عصبی در ابتدا عملکرد مشابهی نسبت به شبکه عصبی فازی دارد.

که شامل ۱۳۶ تابع عضویت گوسی<sup>۱</sup> بوده که نمونه‌ای از آن در شکل ۳ آورده شده است. در این تحقیق پارامترهای تنظیم شامل Range Of Influence، Accept Ratio، Squash Factor و Reject Ratio هستند، که تأثیرگذارترین آنها Squash Factor است که پس از تحلیل عملکرد سیستم، در  $SQ=0/1$  بهترین نتیجه به دست آمد. شکل ۴ نمایه‌ای از شبکه عصبی- فازی تولید شده جهت ساخت ابزار شبکه عصبی- فازی است.

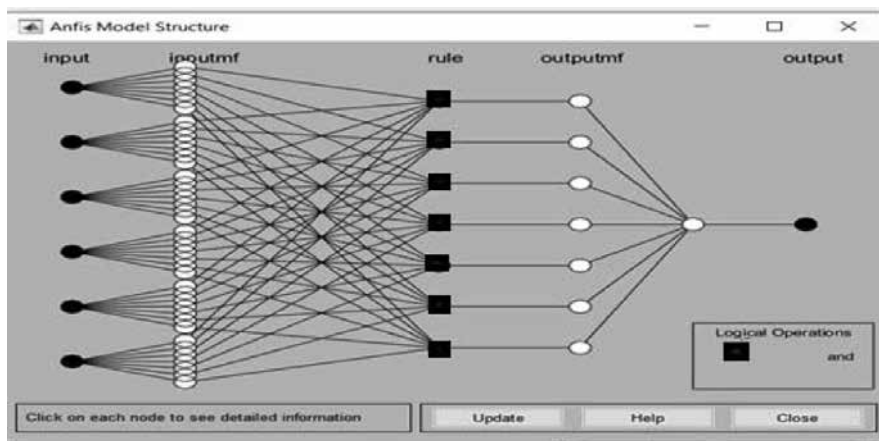
### تحلیل داده‌ها

با استفاده از شبکه عصبی که طراحی و ساخته شد، نمودارهای آموزش، تست و کلی در شکل ۵-الف، ب و ج نشان می‌دهد که مقایسه داده‌های اندازه‌گیری شده با داده‌های حاصل از شبکه عصبی به نحو قابل قبولی روی یک خط راست قرار گرفته است. شکل ۵-الف مقایسه داده‌های اندازه‌گیری شده با داده‌های تولیدی شبکه عصبی، در نمودار تست عدد  $R^2=0/81013$ ، شکل ۵-ب مقایسه داده‌های اندازه‌گیری شده با داده‌ای تولیدی شبکه عصبی در نمودار آموزش عدد  $R^2=0/99872$  و شکل ۵-ج مقایسه

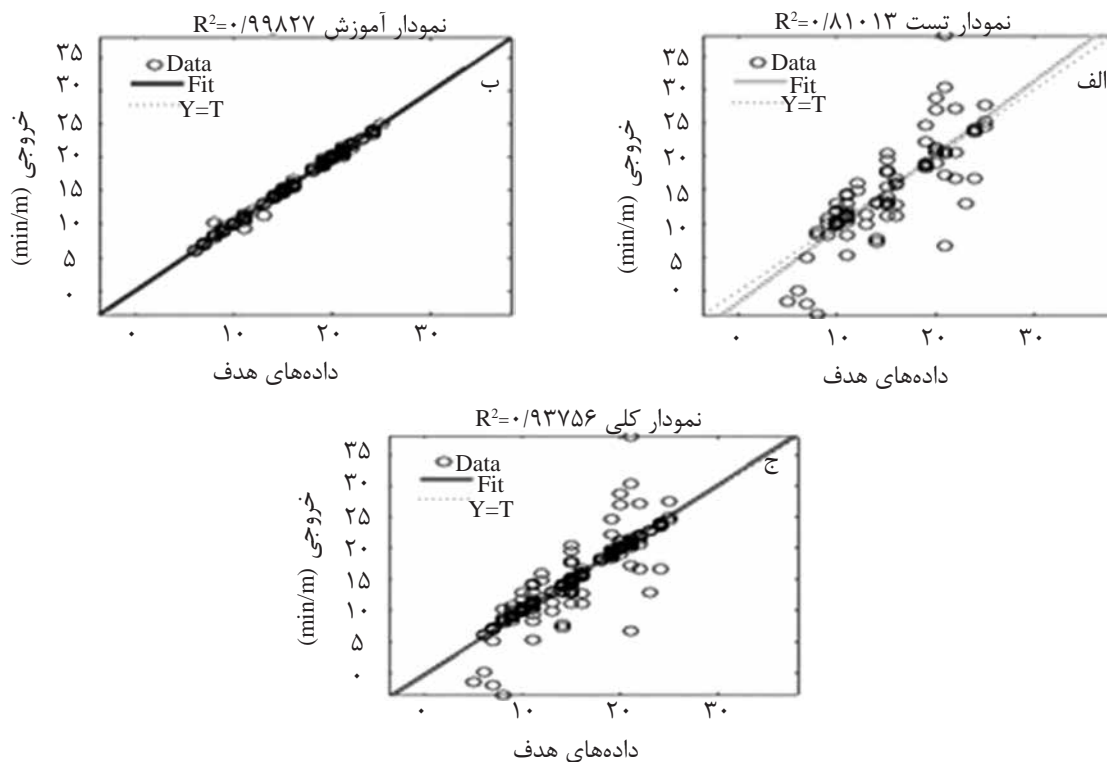
1. Gaussian Membership Function



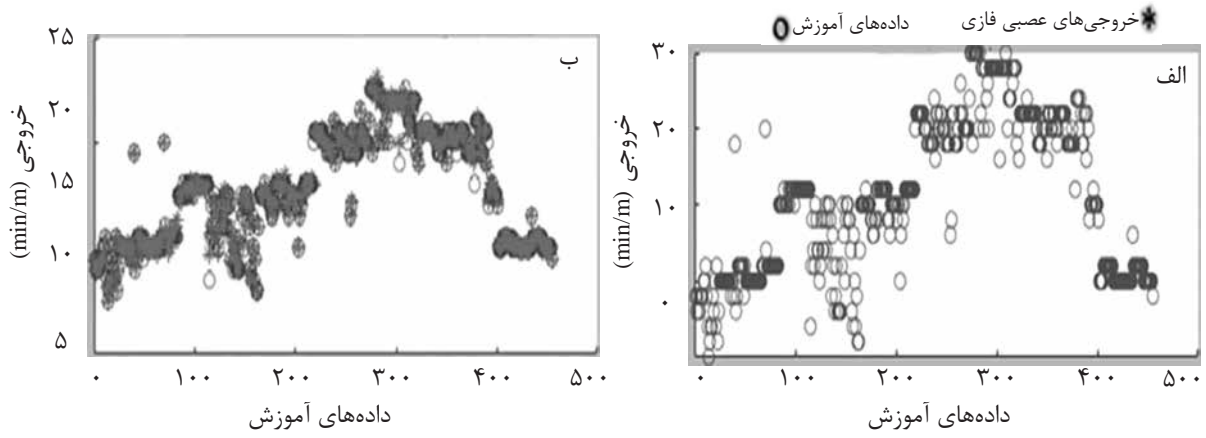
شکل ۳ نمونه‌ای از یک شبکه عصبی-فازی ایجاد شده



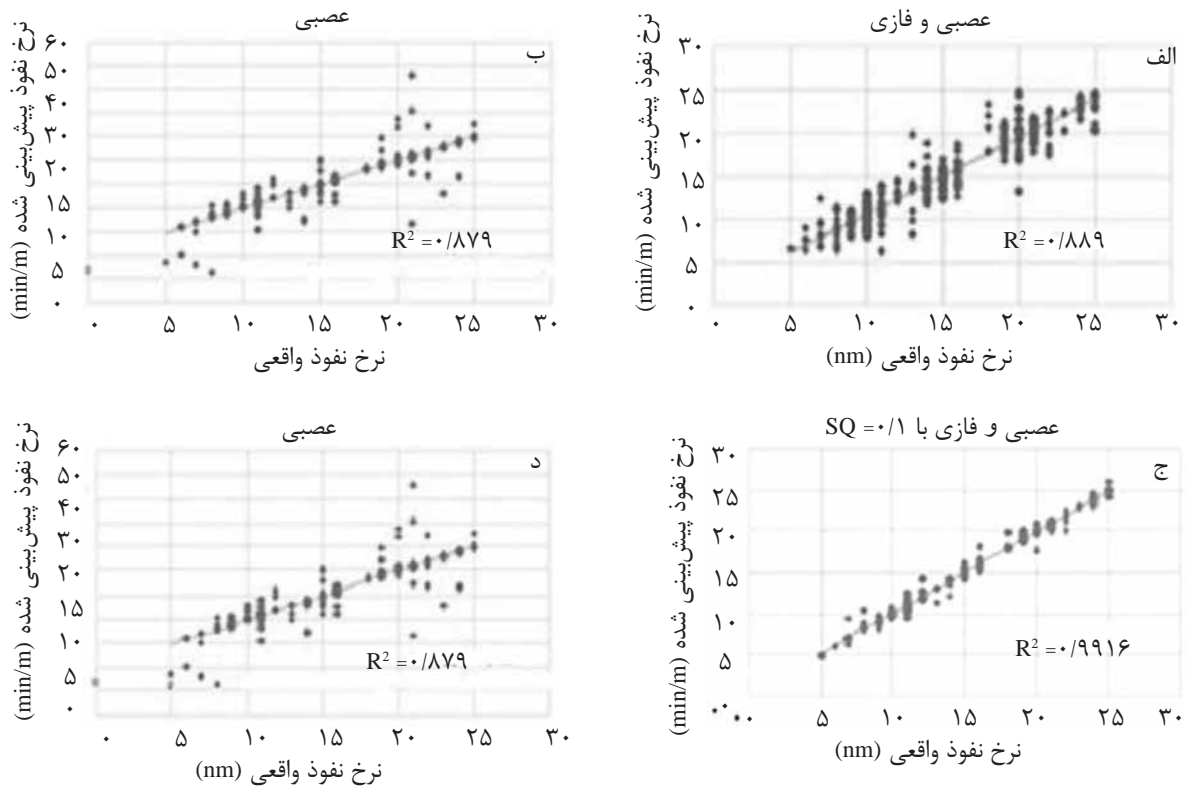
شکل ۴ نمایه‌ای از شبکه عصبی-فازی جهت ساخت شبکه عصبی فازی



شکل ۵ نمودار مقایسه داده‌های اندازه‌گیری شده با داده‌های هدف شبکه عصبی

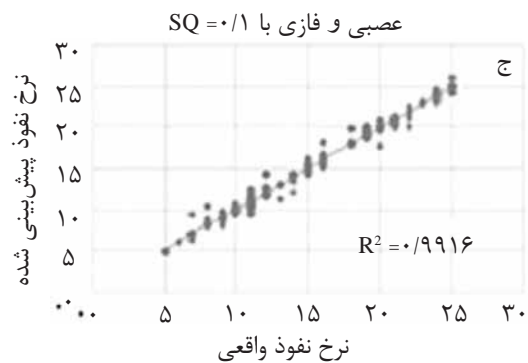
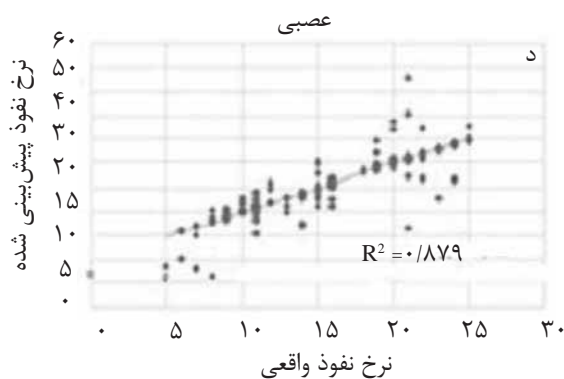




شکل ۶ نمودار تطبیقی داده های اندازه گیری شده با داده های هدف شبکه عصبی- فازی



شکل ۷ نمودار مقایسه ای نفوذ حفاری اندازه گیری شده نسبت به نرخ نفوذ حفاری پیش بینی شده از طریق شبکه عصبی و شبکه عصبی- فازی





شکل ۷ نمودار مقایسه‌ای نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی و شبکه عصبی-فازی

در Command تایپ کرده و سپس به طراحی آن پرداخت. نمونه صفحه طراحی شده در شکل ۸ آورده شده است. طراحی این صفحه بدون برنامه نویسی، کاربردی نداشته و در عمل بی‌فایده خواهد بود که در ادامه به توضیح آن پرداخته می‌شود:

با کلیک برروی هر کدام از المان‌های طراحی شده، پنجره‌ای با نام property inspector باز خواهد شد که در آن، هر کدام از خصوصیات المان طراحی شده باید تنظیم گردد که نمونه‌ای از آن در شکل ۹ آورده شده است. هر کدام از المان‌های طراحی شده، در script مربوطه دارای یک تابع فراخوان<sup>۱</sup> بوده که به‌عنوان نمونه، درخصوص عمق وارده توسط کاربر، script آن در زیر آورده شده است:

```
(function E Depth Callback (hObject, eventdata, handles)
(handles.Depth= str2double (get (hObject,String
guidata (hObject, handles)
```

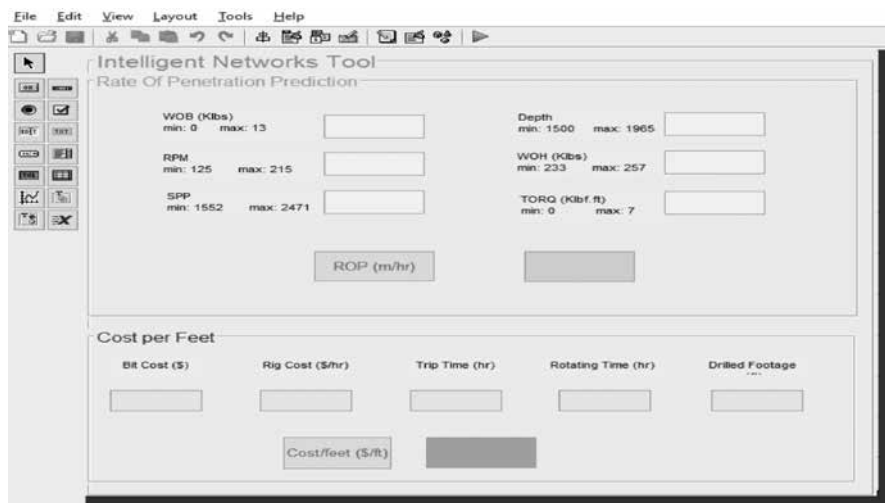
1. Callback Function

در ادامه در شبکه عصبی فازی با تغییر SQ از  $SQ = 1/25$  به  $SQ = 0.1$  رسید که نمودار مقایسه‌ای نرخ نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی در شکل ۷-ج نشان داده شد، که در آن  $R^2 = 0.879$  به‌دست آمده است. نمودار مقایسه‌ای نرخ نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی فازی در شکل ۷-د نشان داده شد، که در آن  $R^2 = 0.9916$  به‌دست آمده است. مقایسه عملکرد شبکه بیانگر عملکرد قابل قبول‌تر شبکه عصبی-فازی است.

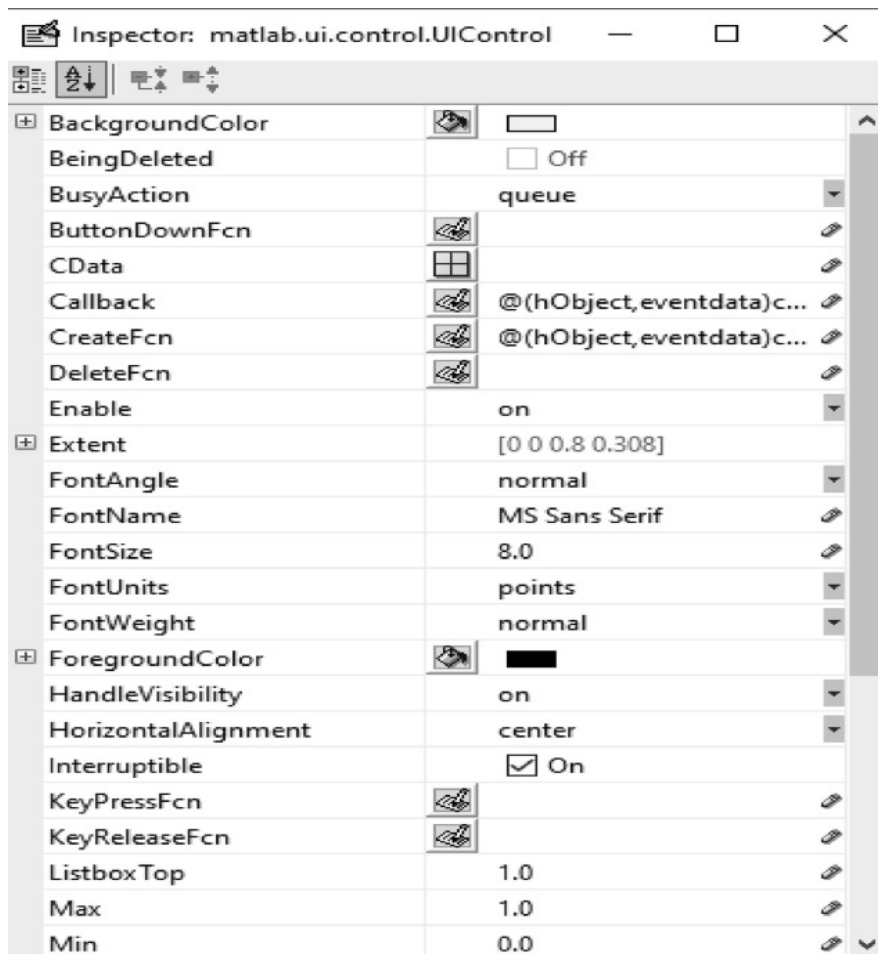
## طراحی و ساخت رابط‌های گرافیکی

### بخش اول- کد نویسی

به منظور ساخت ابزار گرافیکی، 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. برای فراخوانی این ماژول، کافیست واژه guide



شکل ۸ نمونه صفحه طراحی شده



شکل ۹ تنظیم خصوصیات امان طراحی شده

که در واقع همان نرخ نفوذ حفاری است محاسبه می‌گردد و با استفاده از عبارت: `set(handles.E);` به صورت یک رشته در `text box` نمایش داده خواهد شد. برای محاسبه میزان هزینه بر فوت نیز مراحل بالا در ذخیره میزان پارامترهای وارد شده توسط کاربر از همان مراحل توضیح شده در بالا استفاده خواهد شد با این تفاوت که برای محاسبه، با استفاده از کلید فشاری، به صورت زیر عمل خواهد شد.

```
function P C Callback (hObject, eventdata, handles)
handles.Cost per feet= (handles.Bit Cost+...
(handles.Rig Cost* (handles.trip time+ handles.Rotating time)))...
/handles.footage;
set(handles.E Cost per feet, 'String',handles. Cost per feet);
guidata (hObject, handles);
که در خصوص محاسبه هزینه بر فوت از رابطه ۱ استفاده گردید.
```

$$CT = (B + CR (t + T)) \div ^2 F \quad (1)$$

#### بخش دوم- اجرای برنامه

همان‌گونه که در بخش اول- کدنویسی اشاره شد، به منظور ساخت جعبه ابزار گرافیکی، از نرم‌افزار متلب<sup>۳</sup> استفاده می‌شود که نرم‌افزاری مخصوص طراحی رابط گرافیکی با استفاده از کدهای نوشته شده در قالب فایل‌های مورد استفاده متلب است. در پنل مخصوص نرخ نفوذ حفاری براساس جداول، داده‌های اندازه‌گیری شده ورودی که از طریق آن شبکه عصبی تولید شده است را به جهت داده ورودی کاربر تنظیم نموده و همچنین داده‌های ورودی که براساس آن ابزار شبکه عصبی فازی ساخته شده نیز به‌عنوان داده‌هایی که کاربر برای اجرای برنامه مورد نیاز است در نظر گرفته شده است.

در عبارت بالا، عدد وارد شده توسط کاربر به صورت یک عبارت `double` ذخیره شده که این عمل با استفاده از تبدیل عدد وارد شده (که توسط متلب به صورت عبارت رشته‌ای در نظر گرفته شده) با استفاده از تابع `str2double` انجام شده است. در آخر برای به روز رسانی داده‌ها و توابعی که به صورت یک `handle` و یا دستگیره به یکدیگر متصل هستند، از عبارت: `guidata(hObject, handles);` استفاده گردید. با استفاده از عبارات بالا، عدد وارد شده در `text box` مربوط به عمق، ذخیره شده که در مراحل بعدی استفاده گردد. به همین شکل برای دیگر پارامترها نیز این توابع فراخوان تعریف و کد نویسی می‌گردد که در ادامه بتوان از آن‌ها در شبکه عصبی- فازی طراحی شده از قبل استفاده کرد. دکمه فشاری<sup>۱</sup> که برای محاسبه نرخ نفوذ طراحی گردید دارای یک تابع فراخوان است که در زیر آورده شده و در ادامه به ذکر جزئیات آن خواهیم پرداخت.

```
function P-ROP-Callback (hObject, eventdata, handles)
Hfis2= readfis('Hfis2')
handles.Input=...
[handles.Depth...
handles.WOB ...
handles.WOH...
handles.RPM...
handles.TORQ...
handles.SPP];
handles.P-ROP= evalfis (handles.Input, Hfis2);
set(handles.E-Result,'String',handles.P-ROP);
guidata (hObject, handles);
عبارت Hfis2 = readfis('Hfis2') برای فراخوانی شبکه عصبی- فازی که از قبل طراحی شده است به کار رفته است. پس از آن، کلیه ورودی‌هایی که از قبل توسط کاربر ذخیره شده است در Input به صورت یک handle، ذخیره می‌گردد. با استفاده از تابع evalfis و داده‌های ذخیره شده در Input، میزان خروجی
```

1. Push Button

2. <http://www.drillingformulas.com/drilling-cost-per-foot/>

3. Matlab GUIDE

که با وارد کردن داده‌های مشخص شده در کادر نتیجه در کادر نارنجی رنگ به نمایش درآمده است. در بخش دوم، کاربر پس از وارد کردن مقادیر مورد نیاز که شامل هزینه مته، هزینه دکل، زمان چرخش، زمان متصل کردن و زمان بالا بردن لوله‌ها است، می‌تواند هزینه بر فوت که براساس فرمول‌های موجود محاسبه شده است را به راحتی در اختیار داشته باشد. در شکل ۱۰ در قسمت پایین، پانل مربوط به هزینه بر فوت قابل مشاهده است که با وارد کردن داده‌های مشخص شده در کادر نتیجه در کادر مقابل Cost/ Feet به نمایش درآمده است.

علاوه بر آن میزان هزینه بر فوت نیز به‌عنوان داده‌هایی که کاربر برای اجرای نرم‌افزار باید وارد کند در نظر گرفته شده است. در نهایت پس از طراحی شبکه‌های عصبی و عصبی فازی، رابط گرافیکی آن طراحی شد، که در شکل ۱۰ نشان داده شده است.

در بخش اول، کاربر پس از وارد کردن مقادیر مورد نیاز که شامل عمق چاه، وزن روی مته، سرعت چرخش مته، فشار لوله حفاری، گشتاور و وزن روی قلاب است، می‌تواند نرخ نفوذ حفاری را براساس داده‌ها و جداول منتشر شده و نتیجه حاصل از شبکه عصبی و عصبی- فازی در داخل کادر مقابل ROP مشاهده نماید. در شکل ۱۰ قسمت بالا پانل مربوط به پیش‌بینی نرخ نفوذ حفاری قابل مشاهده است

The screenshot displays the 'Intelligent Networks Tool' interface, divided into two main sections: 'Rate Of Penetration Prediction' and 'Cost per Feet'.

**Rate Of Penetration Prediction Section:**

- WOB (Klbs):** min: 0, max: 13, value: 2
- Depth:** min: 1500, max: 1965, value: 1735
- RPM:** min: 125, max: 215, value: 195
- WOH (Klbs):** min: 233, max: 257, value: 248
- SPP:** min: 1552, max: 2471, value: 1814
- TORQ (Klbf.ft):** min: 0, max: 7, value: 5
- ROP (m/hr):** 19.9656

**Cost per Feet Section:**

- Bit Cost (\$):** 1200
- Rig Cost (\$/hr):** 200
- Trip Time (hr):** 12
- Rotating Time (hr):** 12.5
- Drilled Footage (ft):** 240
- Cost/feet (\$/ft):** 25.4167

شکل ۱۰ پنجره اصلی رابط گرافیکی طراحی شده

## نتیجه گیری

حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی فازی در  $R^2=0/889$ ،  $SQ=1/25$  را نشان می‌دهد.

• نمودار مقایسه‌ای نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی فازی در  $R^2=0/9916$ ،  $SQ=0/1$  به‌دست آمد که با مقایسه شبکه عصبی و شبکه عصبی فازی با یکدیگر نشان داد که عملکرد شبکه عصبی فازی با نتیجه  $R^2=0/9916$  قابل قبول تر است.

• با استفاده از شبکه‌های عصبی طراحی شده، یک رابط گرافیکی شامل ۲ ابزار گرافیکی به منظور پیش‌بینی نرخ نفوذ حفاری و هزینه بر فوت در دو پانل مجزا طراحی شد که پانل اول برای پیش‌بینی نرخ نفوذ حفاری و پانل دوم به‌صورت محاسبه هزینه بر فوت است.

• در پانل اول، کاربر پس از وارد کردن داده‌های ورودی، می‌تواند با انتخاب شبکه عصبی یا عصبی فازی نرخ نفوذ حفاری را پیش‌بینی نماید و در پانل دوم، کاربر پس از ورود داده‌های مورد نظر می‌تواند نمودار هزینه بر فوت و پیش‌بینی نرخ نفوذ حفاری را مشاهده نماید.

در این پژوهش ابتدا یک بانک اطلاعاتی از عملکرد حفاری در یکی از میادین نفتی جنوب ایران تهیه شد و پس از آن با استفاده از روش‌های هوشمند مدل‌هایی برای پیش‌بینی نرخ نفوذ حفاری ارائه شد. نتایج به‌دست آمده از این تحقیق به‌صورت زیر است:

• یک شبکه عصبی چند لایه به منظور پیش‌بینی نرخ نفوذ حفاری با داده‌های میدانی عمق چاه، وزن روی مته، سرعت چرخش مته، فشار لوله حفاری، گشتاور و وزن روی قلاب با استفاده از تابع آموزش و توابع انتقال طراحی و ساخته شد.

• از هر دو شبکه عصبی و شبکه عصبی فازی نتایج قابل قبول و قابل اعتمادی به‌دست آمد.

• مقایسه داده‌های اندازه‌گیری شده با داده‌ای تولیدی شبکه عصبی، در نمودار آموزش عدد  $R^2=0/9987$ ، در نمودار تست عدد  $R^2=0/81013$  و در نمودار کلی عدد  $R^2=0/93756$  را به‌دست آمد.

• بررسی نمودار مقایسه‌ای نرخ نفوذ حفاری اندازه‌گیری شده نسبت به نرخ نفوذ حفاری پیش‌بینی شده از طریق شبکه عصبی  $R^2=0/879$  را نشان می‌دهد و نیز نمودار مقایسه‌ای نرخ نفوذ

## مراجع

- [۱]. بهاری ا.، و برادران سید ا.، "بهینه‌سازی هزینه‌های حفاری در میدان گازی خانگیران"، پایگاه مقالات فارسی مهندسی نفت، ۱۳۹۰.
- [2]. Fausett L., "Fundamentals of neural networks: architectures, algorithms, and applications," Prentice-Hall, Inc., Vol. 26, No. 11, pp. 59-68, 1994.
- [3]. Bilgesu H., Tetrick L.T., Altmis U., Mohaghegh S. and Ameri S., "A new approach for the prediction of rate of penetration (ROP) values," SPE Eastern Regional Meeting, Society of Petroleum Engineers, Vol. 32, No. 07, pp. 111-118, 1997.
- [4]. Bourgoyne Jr. A. and F. Young Jr., "A multiple regression approach to optimal drilling and abnormal pressure detection," Society of Petroleum Engineers Journal, Vol. 14, No. 04, pp. 371-384, 1974.
- [5]. Dashevskiy D., Dubinsky V. and Macpherson J. D., "Application of neural networks for predictive control in drilling dynamics," SPE Annual Technical Conference and Exhibition, SPE, Vol. 19, No. 04, pp. 36-43, 1999.

- [6] Motahhari H., Hareland G., Nygaard R. and Bond B., "Method of optimizing motor and bit performance for maximum ROP," Journal of Canadian Petroleum Technology, Vol. 48, No. 06, pp. 44-49, 2009.
- [7]. Hankins D., Salehi S. and Karbalaei Saleh F., "An Integrated Approach for Drilling Optimization Using Advanced Drilling Optimizer," Journal of Petroleum Engineering, Vol. 24, No. 05, pp. 54-61, 2015.
- [8]. Wang Y. and Salehi S., "Application of real-time field data to optimize drilling hydraulics using neural network approach," Journal of Energy Resources Technology, Vol. 137, No. 06, pp. 629-637, 2015.
- [9]. Moraveji M. K. and Naderi M., "Drilling rate of penetration prediction and optimization using response surface methodology and bat algorithm," Journal of Natural Gas Science and Engineering, Vol. 31, No. 07, pp. 829-841, 2016.
- [10]. Amer M. M., Dahab A. S. and Hashem El-Sayed A. A., "An ROP predictive model in Nile delta area using artificial neural networks," SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition, SPE, Vol.12, No.05, pp. 124-135, 2017
- [11]. Manshad A., Rostami H., Toreifi H. and Mohammadi A. H., "Optimization of drilling penetration rate in oil fields Using artificial intelligence technique," Nova Science Publishers, Vol. 18, No. 11, pp. 12-21, 2017.



## Petroleum Research

Petroleum Research 2018 (August-September), Vol. 28, No. 99. 41-44

DOI: 10.22078/pr.2018.2475.2146

# Presenting a Graphical Tool to Predict the Drilling Rate of Penetration through Intelligent Approaches

Seyed Hassan Mashashai<sup>1</sup>, Arash Ebrahimabadi<sup>2\*</sup> and Seyed Abolghasem Emamzadeh<sup>3</sup>

1. Faculty of Petroleum Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Department of Mining, Qaemshahr Branch, Islamic Azad University, Qaemshahr, Iran

3. Faculty of Petroleum Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

A.Ebrahimabadi@Qaemiau.ac.ir

DOI: 10.22078/pr.2018.3000.2395

Received: November/20/2017 Accepted: May/22/2018

## Abstract

The prediction of drilling rate is one of the important issue because of its role in minimizing drilling costs to optimize the drilling process. Field data analysis is a key element in reducing costs and improving drilling operations. Furthermore, developing field information analysis tools and providing prediction models are two alternatives to improve drilling operations. When a drilling system is deployed, there are only a few limited parameters which can be controlled and changed. In general, the main purpose of this research is to apply intelligent techniques and provide graphical tools for predicting drilling performance. For this purpose, a database of field data such as well depth, drill weight, drill speed, drill chuck, weight on the hook and the torque was established from one of the southern fields of Iran. In this research, two different types of graphical tools were proposed to predict the drilling rate of penetration as well as to calculate the cost per foot, using a fuzzy neural network and Neuro-fuzzy approaches. The goals of the economic evaluation are the drill performance and the cost-per-foot calculation. The results showed that a good correlation coefficient ( $R=0.94$ ) was obtained to predict the penetration rate using the neural network. In order to improve the findings, the fuzzy neural network method was applied. The results demonstrated that a very good relationship with high precision having a coefficient of determination ( $R^2=0.99$ ) was obtained and thereby it depicted a significant improvement in the accuracy of the prediction models.

**Keywords:** Drilling Rate, Prediction, Cost Per Foot, Neural Network, Fuzzy-neural Network, Graphical Software

## Introduction

Evaluation of drilling performance plays a major role in drilling operations productivity as well as drilling costs [1]. With respect to minimizing the costs, field data should be gathered and monitored precisely, leading to apply highly accurate data analysis tools. Using predictive models and results from field data analyses, it is possible to take effective measures in which the project could be managed appropriately to attain the most desirable and efficient results. Through the optimization process of the drilling operation, the parameter of the Rate of Penetration (ROP) is one of the most important factors. It directly contributes to the success of the project. This parameter is related to formation properties, fluid rheology, weight on bit, bit rotational speed, bit type, well deviation, bit hydraulic, etc.

Another essential parameter affecting the drilling effectiveness is the cost per foot of drilling. This is in association with whole drilling costs while it is close relation with bit price and rate of penetration. Some valuable attempts were made to present equations for predicting ROP and cost per foot of drilling [2-5].

This paper presents an approach to achieve predictive empirical models to evaluate drilling operation performance (rate of penetration and cost estimation) using neural networks and neuro-fuzzy methods in one of the Iranian oilfields. It finally results in a graphical tool provided by applying Graphical User Interface (GUI) tools in MATLAB software.

## Research Methods

Artificial neural networks (ANNs) or connectionist systems are computing systems vaguely inspired by the biological neural networks that constitute

animal brains [1]. Such systems “learn” to perform tasks by considering examples, generally without being programmed with any task-specific rules. For example, in image recognition, they might learn to identify images that contain cats by analyzing example images that have been manually labeled as “cat” or “no cat” and using the results to identify cats in other images. They do this without any prior knowledge about cats, e.g. that they have fur, tails, whiskers and cat-like faces. Instead, they automatically generate identifying characteristics from the learning material that they process.

An ANN is based on a collection of connected units or nodes called artificial neurons, which loosely model the neurons in a biological brain. Each connection, like the synapses in a biological brain, can transmit a signal from one artificial neuron to another. An artificial neuron that receives a signal can process it, and then signal additional artificial neurons can be connected to it.

In common ANN implementations, the signal at a connection between artificial neurons is a real number, and the output of each artificial neuron is computed by some non-linear function of the sum of its inputs. The connections between artificial neurons are called ‘edges’. Artificial neurons and edges typically have a weight that adjusts as learning proceeds. The weight increases or decreases the strength of the signal at a connection. Artificial neurons may have a threshold such that the signal is only sent if the aggregate signal crosses that threshold. Typically, artificial neurons are aggregated into layers. Different layers may perform different kinds of transformations on their inputs. Signals travel from the first layer (the input layer), to the last



layer (the output layer), possibly after traversing the layers multiple times.

The original goal of the ANN approach was to solve problems in the same way that a human brain would. However, over time, attention moved to performing specific tasks, leading to deviations from biology. ANNs have been used on a variety of tasks, including engineering problems such as petroleum engineering and drilling operations as it is used in this paper.

Neuro-fuzzy hybridization results in a hybrid intelligent system that synergizes these two techniques by combining the human-like reasoning style of fuzzy systems with the learning and connectionist structure of neural networks. Neuro-fuzzy hybridization is widely termed as the fuzzy neural network (FNN) or neuro-fuzzy system (NFS) in the literature. Neuro-fuzzy system (the more popular term is used henceforth) incorporates the human-like reasoning style of fuzzy systems through the use of fuzzy sets and a linguistic model consisting of a set of IF-THEN fuzzy rules. The main strength of neuro-fuzzy systems is that they are universal approximators with the ability to solicit interpretable IF-THEN rules.

The strength of neuro-fuzzy systems involves two

contradictory requirements in fuzzy modeling: interpretability versus accuracy. In practice, one of the two properties prevails. The neuro-fuzzy in fuzzy modeling research field is divided into two areas: linguistic fuzzy modeling that is focused on interpretability, mainly the Mamdani model; and precise fuzzy modeling that is focused on accuracy, mainly the Takagi-Sugeno-Kang (TSK) model.

### Modeling Approach and Results

Primarily, a database was compiled from field observation of drilling operation in one of the Iranian oilfields. The database was then analyzed via the neural network and neuro-fuzzy techniques. With that regard, MATLAB software was utilized.

By using Graphical User Interface (GUI) tool in software, a graphical tool was designed to evaluate the rate of penetration and cost estimation in a specified drilling project.

Figure 1, for instance, illustrates a neuro-fuzzy structure of the problem.

Figure 2 shows a snapshot of designed graphical tool using GUI in MATLAB software. Using this tool, a user can easily calculate ROP and cost per foot of drilling for each arbitrary drilling case.




Figure 1: A Schematic of a neuro-fuzzy structure of the problem.




Figure 2: An illustration of the designed graphical tool.

## Conclusions

Primarily, a database from drilling field data, in one of the southern Iranian oilfields, was established. The database was then analyzed through intelligent techniques to ultimately yield some equations and a graphical tool for calculating and predicting the rate of penetration and cost of drilling. The results showed a very good relation between measured and predicted ROP using the neural network and neuro-fuzzy approaches with  $R^2=0.879$  and  $R^2=0.889$ , respectively. Finally, a graphical tool using Graphical User Interface (GUI) in MATLAB software was provided to easily predict both ROP and cost per foot of drilling.

## References

- [1]. Bilgesu H., Tetrick L.T., Altmis U., Mohaghegh S. and Ameri S., "A new approach for the prediction of rate of penetration (ROP) values," SPE Eastern Regional Meeting, Society of Petroleum Engineers, Vol. 32, No. 07, pp. 111-118, 1997.
- [2]. Wang Y. and Salehi S., "Application of real-time

- field data to optimize drilling hydraulics using neural network approach," Journal of Energy Resources Technology, Vol. 137, No. 06, pp. 629-637, 2015.
- [2]. Moraveji M. K. and Naderi M., "Drilling rate of penetration prediction and optimization using response surface methodology and bat algorithm," Journal of Natural Gas Science and Engineering, Vol. 31, No. 07, pp. 829-841, 2016.
- [3]. Amer M. M., Dahab A. S. and Hashem El-Sayed A. A., "An ROP predictive model in Nile delta area using artificial neural networks," SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition, SPE, Vol.12, No.05, pp. 124-135, 2017
- [4]. Manshad A., Rostami H., Toreifi H. and Mohammadi A. H., "Optimization of drilling penetration rate in oil fields Using artificial intelligence technique," Nova Science Publishers, Vol. 18, No. 11, pp. 12-21, 2017.