

توسعه شبکه عصبی مصنوعی مبتنی بر الگوریتم ژنتیک به منظور پیش‌بینی آزمایش‌های PVT چاه‌های نفت در صنایع بالادستی

محسن اسلام نژاد^۱، حسین اکبری پور^۲ و محمدرضا امین ناصری^{*۲}

۱- گروه مهندسی فناوری و اطلاعات، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران

۲- بخش مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران

تاریخ پذیرش: ۹۳/۱۰/۲۱

تاریخ دریافت: ۹۲/۹/۱۸

چکیده

در مرحله صیانت از مخازن نفتی صنایع بالادستی، آزمایش‌های پیچیده‌ای موسوم به PVT برای شناسایی خواص سیالات مخزن انجام می‌گیرد. وجود مشکلاتی چون خطرات احتمالی، زمان‌بر بودن، دقیق نبودن نمونه‌ها و محدودیت‌های دما و فشار، باعث شده تا استفاده از روش‌های هوشمند در این حوزه گسترش یابد. در این پژوهش به منظور اجتناب از مشکلات مذکور و یافتن رابطه پیچیده و غیرخطی داده‌های آزمایش‌های PVT از شبکه عصبی مصنوعی بهره گرفته شده است. همچنین، از الگوریتم ژنتیک به منظور تعیین مقادیر بهینه پارامترهای مدل شبکه عصبی در فرآیند آموزش استفاده شده است. به منظور ارزیابی رویکرد توسعه یافته از مجموعه داده‌های چاه‌های نفتی جنوب ایران بهره گرفته شد و نتایج حاصل نشان می‌دهد که استفاده از شبکه عصبی مصنوعی مبتنی بر الگوریتم ژنتیک، برخلاف روش‌های کلاسیک، در زمان کمتر و با دقت بالایی خواص سیالات مخزن (ضریب حجمی سیال و فشار نقطه حباب) را پیش‌بینی می‌نماید. در نتیجه، کارشناسان و مدیران صنایع بالادستی مخازن نفتی ایران می‌توانند از شبکه عصبی پیشنهادی در راستای پیش‌بینی آزمایش‌های PVT بهره گیرند.

کلمات کلیدی: صنایع بالادستی نفت، صیانت از مخازن نفت، آزمایش‌های PVT، شبکه عصبی مصنوعی، الگوریتم ژنتیک

مقدمه

صنعت نفت با داشتن فعالیت‌ها و بخش‌های متنوع، از زمان جستجو برای اکتشاف نفت تا زمان تحویل نفت و فرآورده‌های آن به مصرف‌کننده، به دو بخش اصلی صنایع بالادستی و صنایع پایین‌دستی تقسیم می‌شود. صنایع بالادستی شامل اکتشاف، حفاری، استخراج و صیانت از مخازن است که کلیه این مراحل از اهمیت ویژه‌ای برخوردار است. صنایع

امروزه استفاده از روش‌های هوشمند در صنایع مختلف باعث بهبود عملکرد آنها شده است. صنعت نفت نیز از صنایع با قابلیت بالا در پیاده‌سازی روش‌های هوشمند به شمار می‌آید. به طور کلی

از روش‌های هوشمند، راهکار مناسبی برای حل مشکلات و رفع محدودیت‌ها در انجام آزمایش‌های PVT است [۲].

در سال‌های اخیر مهندسان نفت از قابلیت‌های شبکه عصبی مصنوعی در حل مسائل پیچیده و پر مخاطره صنعت نفت بهره گرفته‌اند [۴] که در این باره می‌توان به توصیف کاربردهای شبکه عصبی در مهندسی نفت، تکنیک شبکه‌های عصبی در پیش‌بینی تولید نفت و کاربرد شبکه‌های عصبی در پیش‌بینی تولید گاز طبیعی اشاره کرد [۵-۷]. همچنین، شبکه‌های عصبی مصنوعی به علت مزایایی چون سرعت و قابلیت یادگیری توانسته‌اند به صورت گسترده در تخمین ویژگی‌های فیزیکی و ترمودینامیکی مولفه‌های شیمیایی به کار روند [۸]. از جمله این موارد می‌توان به کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی ضریب تراکم‌پذیری (Z) [۸]^۱، فشار نقطه شبنم [۹]^۲، خواص مواد خالص و برش‌های نفتی [۱۰]^۳، نسبت ضریب فعالیت الکترولیت‌ها در محلول‌های آمینو اسید [۱۱]^۴، خواص ترمودینامیکی مبردها [۱۲-۱۳]^۵ و ضریب فعالیت هم‌فشار سیستم دوتایی [۱۴]^۶ اشاره کرد. در دهه‌های گذشته محققان تلاش کرده‌اند تا از شبکه‌های عصبی مصنوعی در پیش‌بینی خصوصیات سیال مخزن و آزمایش‌های PVT استفاده نمایند. برای مثال در سال ۱۹۹۷ غربی و الشرکاو تلاش کردند که با استفاده از مجموعه داده‌های مخازن نفت خام در منطقه خاورمیانه و توانمندی‌های شبکه عصبی مصنوعی، دو ویژگی سیال B_p و B_o ^۷ در آزمایش‌های PVT را پیش‌بینی نمایند [۱۵]. الشرکاو در سال ۱۹۹۸ از مدل شبکه عصبی RBF^۹

پایین‌دستی نیز شامل فعالیت‌هایی همچون پالایش، انتقال و فروش می‌شود. به‌کارگیری روش‌های هوشمند به منظور سهولت و افزایش دقت در فعالیت‌های متنوع صنایع بالادستی در دهه‌های اخیر رونق گرفته است.

یکی از مراحل مهم صنایع بالادستی، مرحله سیانت است که باعث افزایش بهره‌وری و طول عمر چاه می‌شود. سیانت از چاه‌های نفتی به معنی حفاظت و نگهداری از چاه نفت برای برداشت بیشتر از آن است. از دلایل اهمیت مرحله سیانت می‌توان به هزینه بالای حفر چاه جدید، زمان‌بر بودن آن و یا درصد پایین موفقیت حفر چاه اشاره کرد. شناخت خواص فیزیکی و شیمیایی نفت چاه‌ها برای سیانت از آنها با نمونه‌گیری دقیق از نفت مخازن و انجام آزمایش‌هایی به نام PVT ممکن می‌گردد [۱].

آزمایش‌های PVT را به طور خلاصه می‌توان انجام آزمایش‌های فشار، حجم و دمای متغیر بر روی سیال مخزن و مطالعه رفتار آن از لحاظ کلیه خواص ترمودینامیکی تعریف کرد. این آزمایش‌ها پرهزینه و حتی خطرناک هستند. گاهی نیز نمونه‌ها به علت مشکلات نمونه‌گیری و عدم دقت لازم، ارزش کافی ندارند و نمی‌توان به نتایج این آزمایش‌ها اعتماد کامل داشت. بنابراین، بدیهی است که هوشمندسازی این آزمایش‌ها مسأله مهم و کاربردی به شمار می‌آید [۲]. در تحقیقات انجام شده، پژوهشگران توانسته‌اند روابط ریاضی را بین نتایج آزمایش‌های PVT ارائه دهند. در واقع هر یک از این روابط تجربی سعی دارند تا فرمول‌ها و ضرایب جدیدی را برای شرایط مختلف ارائه نمایند [۳]. با این حال، وابستگی روابط به یک ناحیه و یا محدوده جغرافیایی خاص از بزرگ‌ترین معایب روابط ریاضی مذکور قلمداد می‌شود. در نتیجه استفاده از این روابط به منظور شناخت خواص فیزیکی مخازن نفتی ایران نتایج درستی به دنبال نخواهد داشت و تقریباً غیر کاربردی است. به نظر می‌رسد استفاده

1. Compressibility Factor (z)

2. Dew Point Pressure

3. Pure Substances and Petroleum Fraction's Properties

4. Amino Acids Solutions

5. Thermodynamic Properties of Refrigerants

6. Activity Coefficients of Isobaric Binary Systems

7. Bubble Point Pressure

8. Oil Formation Volume Factor at Bubble Point

9. Radial Basis Function

که درصد خطای نسبی در این مدل کمتر شده است [۲۰].

در سال ۲۰۰۴ عیسی و همکاران به منظور پیش‌بینی خواص سیال مخزن، دو مدل ۳ لایه و ۴ لایه شبکه عصبی مصنوعی توسعه دادند. در این پژوهش از داده‌های مخازن نفت در کالیفرنیا استفاده گردید و نتایج حکایت از میزان بسیار کم میانگین خطای مطلق داشت [۲۱]. در سال ۲۰۰۹ اوئل و همکاران، از قابلیت‌های شبکه عصبی در پیش‌بینی آزمایش‌های PVT با استفاده از مجموعه داده‌های مخازن نفتی در نیجریه بهره گرفتند [۲۲]. در سال ۲۰۱۱ اسدی ساقندی و طهماسبی تلاش کردند تا با استفاده از مجموعه داده‌هایی از مخازن نفت در مناطق مختلف نفتی ایران و شبکه‌های عصبی ویژگی‌های B_0 و P_b را در آزمایش‌های PVT را پیش‌بینی نمایند. نتایج پژوهش آنها، افزایش کارایی نسبت به روش‌های تجربی و شبکه‌های عصبی طراحی شده در پژوهش‌های قبلی را نشان می‌داد [۳].

به منظور پیش‌بینی چندین ویژگی سیال مخزن در آزمایش‌های PVT استفاده نمود که نتایج به‌دست آمده حکایت از کاهش قابل توجه خطا نسبت به روش‌های تجربی داشت [۱۶].

در سال ۱۹۹۹ وارتسیس و همکاران، از شبکه‌های عصبی مصنوعی در پیش‌بینی رفتار مخازن نفت و میعانات گاز استفاده کردند [۱۷]. در همان سال غربی و الشراوی، با استفاده از یک شبکه عصبی سه لایه پژوهش خود را ادامه دادند. با این تفاوت که مجموعه داده‌ها از مخازن نفتی در چند منطقه متفاوت از کل جهان جمع آوری شده بود و نتایج نسبت به مدل‌های قبلی دقت نسبتاً بیشتری داشت [۱۸]. در سال ۲۰۰۱ عثمان به منظور پیش‌بینی پارامتر B_0 از یک شبکه عصبی با معماری سه لایه استفاده نمود [۱۹]. در سال ۲۰۰۲ المرهون و همکاران، به منظور پیش‌بینی ویژگی سیال مخزن (P_b) از شبکه عصبی مصنوعی استفاده کردند. در این پژوهش از داده‌های مخازن نفت در عربستان سعودی استفاده گردید و نتایج حاصل از این پژوهش نشان می‌دهد

جدول ۱- مروری بر کاربرد شبکه عصبی مصنوعی در پیش‌بینی خواص سیالات مخازن نفتی در ادبیات

| مؤلفان | سال انتشار | نوع شبکه | توضیحات |
|---------------------------------|------------|-------------------|---|
| Gharbi and Elsharkawy [۱۵] | ۱۹۹۷ | شبکه ۴ لایه | استفاده از مجموعه داده‌های مخازن نفت خام در مناطق گوناگون از کل جهان و پیش‌بینی دو ویژگی سیال B_0 ، P_b |
| Elsharkawy [۱۶] | ۱۹۹۸ | شبکه از نوع RBF | پیش‌بینی چندین ویژگی سیال مانند B_0 ، μ_{od} |
| Varotsis and et al. [۱۷] | ۱۹۹۹ | - | استفاده از مجموعه داده‌های مخازن نفتی در مناطق مختلف جهان |
| Gharbi and Elsharkawy [۱۸] | ۱۹۹۹ | شبکه ۳ لایه | استفاده از مجموعه داده‌هایی از مخازن نفتی در منطقه خاورمیانه و پیش‌بینی دو ویژگی B_0 ، P_b سیال |
| Osman et al. [۱۹] | ۲۰۰۱ | شبکه ۳ لایه | استفاده از مجموعه داده‌های مخازن نفتی در مناطق مختلف جهان و پیش‌بینی ویژگی B_0 |
| Al-Marhoun and Osman [۲۰] | ۲۰۰۲ | - | استفاده از داده‌های مخازن نفت در عربستان سعودی و پیش‌بینی دو ویژگی B_0 ، P_b سیال |
| Eissa et al. [۲۱] | ۲۰۰۴ | دو مدل ۳ و ۴ لایه | استفاده از داده‌های مخازن نفت در کالیفرنیا و پیش‌بینی دو ویژگی B_0 ، P_b سیال |
| Omole et al. [۲۲] | ۲۰۰۹ | شبکه ۳ لایه | استفاده از مجموعه داده‌های مخازن نفتی در نیجریه و پیش‌بینی ویژگی μ_{od} |
| Asadisaghandi and Tahmasebi [۳] | ۲۰۱۱ | شبکه ۳ لایه | استفاده از مجموعه داده‌هایی از مخازن نفت در مناطق مختلف نفتی ایران و پیش‌بینی ویژگی‌های B_0 ، P_b |

روی فشار، حجم و دمای آنها صورت می‌پذیرد. در این آزمایش‌ها با ثابت نگه‌داشتن یک یا چند متغیر فیزیکی (مثل حجم و فشار) و تغییر یک یا چند متغیر دیگر (مانند دما) رفتار سیال مخزن نفت ارزیابی می‌شود. روابط تجربی عمدتاً به یک منطقه جغرافیایی خاص محدود است. از این رو مهندسان نفت به دنبال راهکار قابل قبولی هستند که بدون اتلاف وقت، هزینه و هر محدودیتی در دما و فشار بتواند خواص فیزیکی سیالات را محاسبه نماید. همین امر سبب ورود روش‌های جدید از جمله هوش مصنوعی به صنعت نفت شده است.

شبکه عصبی مبتنی بر الگوریتم ژنتیک به منظور پیش‌بینی آزمایش‌های PVT

در سال‌های اخیر از روش شبکه عصبی برای پیش‌بینی داده‌های PVT برای مخازن نفتی کشورهای تولیدکننده نفت در سراسر دنیا استفاده شده است. نتایج حاصل از مدل‌سازی شبکه‌های عصبی مصنوعی نشان می‌دهد که از روی یک مجموعه کامل داده‌های آزمایشگاهی PVT، تخمین ویژگی‌های سیالات مخزن نفتی امکان‌پذیر بوده و به مراتب از روش‌های سنتی معمول دقیق‌تر است. همچنین، قابلیت پردازش موازی شبکه‌های عصبی سبب می‌شود که رابطه پیچیده و غیرخطی موجود بین داده‌های PVT به راحتی محاسبه شود. با این حال، به دلیل نسبی بودن داده‌های PVT نمی‌توان از شبکه‌های عصبی موجود در مقالات برای مخازن نفتی ایران استفاده کرد [۲].

در این پژوهش به منظور پیش‌بینی خصوصیات سیالات مخزن به ویژه خصوصیت ضریب حجمی سیال، فشار نقطه حباب و شناسایی روابط پیچیده آزمایش‌های PVT از رویکرد شبکه‌های عصبی مصنوعی استفاده شده و با کاربرد الگوریتم ژنتیک، اوزان اتصالات شبکه عصبی بهینه شده است. بنابراین، در ابتدا سعی می‌شود مدل شبکه عصبی

با این حال، مقالات نسبتاً کمی در حوزه کاربردهای شبکه عصبی مصنوعی در پیش‌بینی آزمایش‌های PVT ارائه شده است [۸]. در جدول ۱ به کارگیری شبکه‌های عصبی مصنوعی در پژوهش‌های چند سال اخیر به منظور پیش‌بینی خواص سیال مخازن نفتی خلاصه شده است.

در این پژوهش به منظور پیش‌بینی خصوصیات سیالات مخزن به ویژه خصوصیات ضریب حجمی سیال مخزن (B_D)، فشار نقطه حباب (P_b) و شناسایی روابط پیچیده آزمایش‌های PVT، از شبکه‌های عصبی مصنوعی استفاده شده است. همچنین، از آنجایی که انتخاب مناسب اوزان اولیه، افزایش بازدهی و دقت شبکه عصبی را به دنبال دارد، از توانایی الگوریتم ژنتیک در تنظیم اوزان بهره گرفته می‌شود.

در ادامه این پژوهش هوشمندسازی آزمایش‌های PVT با استفاده از شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک پس از آن مورد بررسی قرار خواهد گرفت و در نهایت جزئیات پیاده‌سازی رویکرد پیشنهادی و تحلیل نتایج حاصل از آن ارائه می‌گردد.

آزمایش‌های PVT: بستری برای مهندسی مخازن نفت

صیانت از مخازن، عملیات تخصصی و پیچیده‌ای است که می‌توان آن را نگهداری و مراقبت از یک مخزن نفت به منظور استخراج صحیح تعریف کرد. هدف اصلی صیانت از مخازن حفظ آنها، کاهش ریسک مخزن، کاهش هزینه‌های تولید و حداکثر برداشت است. مهندسی مخزن، یکی از حوزه‌های فنی در صنایع بالادستی، به مطالعه اصول فنی، علمی و اجرایی در حفاری، نگهداری، استخراج از مخازن نفت و همچنین فعالیت‌های ترمیمی برای مخازن آسیب‌دیده می‌پردازد [۲۳]. فعالیت‌های مهندسی مخزن معمولاً بر مبنای نتایج آزمایش‌های گوناگون از جمله آزمایش‌های معروف و تخصصی PVT انجام می‌شود. این آزمایش‌ها جهت بررسی و مطالعه رفتار سیالات مخزن، با استفاده از اعمال تغییراتی

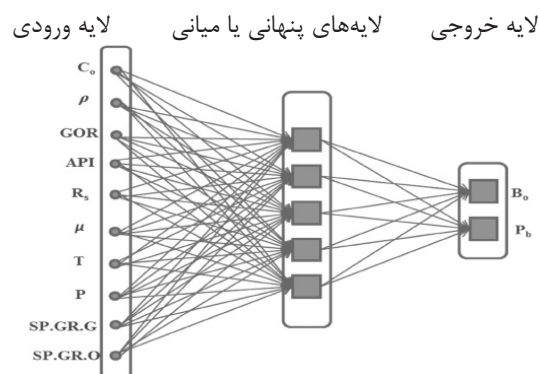
خوانده می‌شود.

شبکه عصبی مصنوعی پیشنهادی از نوع پیشرو^{۱۱} بوده و مطابق با شکل ۱ دارای ۱۰ نرون ورودی، ۵ نرون در لایه میانی و ۲ نرون خروجی است. هر یک از نرون‌های ورودی بر مبنای تجربیات متخصصان نفتی انتخاب شده است به طوری که به نتایج آزمایش‌های مبتنی بر ورودی‌های مذکور اعتماد بیشتری وجود دارد. در جدول ۲ نام، مقدار بیشینه و کمینه، میانگین و انحراف معیار هر یک از نرون‌های ورودی (تراکم‌پذیری، چگالی، نسبت گاز به نفت، چگالی نسبی نفت، میزان گاز محلول در نفت، گرانیوی، دما، فشار، وزن مخصوص گاز، وزن مخصوص نفت) برای مخازن نفتی جنوب ایران ارائه شده است.

مصنوعی به کار رفته در این پژوهش توصیف شود و سپس کاربرد الگوریتم ژنتیک در تنظیم اوزان شبکه عصبی به همراه جزییات کافی تبیین گردد.

مدل شبکه عصبی پیشنهادی

به منظور پیش‌بینی خواص سیال مخزن در این مقاله از شبکه‌های عصبی پرسپترون چند لایه استفاده شده است. در مواقعی که الگوهای آموزشی از دو طبقه خطی جداپذیر باشند، روش یادگیری پرسپترون پس از طی چند دوره همگرا می‌شود. ولی در عمل معمولاً نمی‌دانیم که آیا الگوها به صورت خطی جداپذیرند یا خیر. برای حل این مشکل، لایه (یا لایه‌هایی) بین لایه ورودی و خروجی اضافه می‌شوند که در این صورت پرسپترون، یک پرسپترون چند لایه (MLP)^{۱۰}



شکل ۱- مدل شبکه عصبی پیشنهادی جهت پیش‌بینی ضریب حجمی سیال و فشار نقطه حباب

جدول ۲- نرون‌های ورودی شبکه عصبی پیشنهادی به همراه مقادیر بیشینه، کمینه، میانگین و انحراف معیار

| نرون ورودی | نماد اختصاری | مقدار بیشینه | مقدار کمینه | میانگین | انحراف معیار |
|--|--------------|--------------|-------------|---------|--------------|
| ضریب تراکم‌پذیری | C_o | ۳۶/۹۶ | ۳/۸۰۴۹ | ۱۶/۱۳۵۵ | ۸/۱۴۱۴ |
| چگالی (kg/m^3) | ρ | ۰/۹۹۴۵ | ۰/۵۳۴۵ | ۰/۶۹۷۴ | ۰/۱۱۷۱ |
| نسبت گاز به نفت (Gallon/ Ounce) | GOR | ۱۹۹۸/۴ | ۶۶/۸۰۰ | ۱۰۲۲/۹ | ۶۲۷/۵۶ |
| چگالی نسبی نفت | API | ۳۴/۷۷ | ۷/۲۴ | ۲۷/۰۸۴۰ | ۷/۱۲۳۶ |
| میزان گاز محلول در نفت ($\text{cm}^3/\text{Gallon}$) | R_s | ۳۳۷۲/۱۶ | ۶۱ | ۸۱۴/۴۲ | ۴۶۱/۷۴ |
| گرانیوی (Poise) | μ | ۶/۰۲۳۰ | ۰/۱۹۶۰ | ۱/۲۱۴۸ | ۱/۳۲۲۳ |
| دما ($^{\circ}\text{C}$) | T | ۲۷۷ | ۱۳۹/۳ | ۲۲/۸۷۷ | ۴۴/۳۸۳ |
| فشار (P) | P | ۶۵۴۸ | ۸۱۳ | ۳۹۱۵/۶ | ۱۲۶۳/۷ |
| وزن مخصوص گاز (kg/m^3) | Sp.Gr.G | ۱/۳۱۰۳ | ۰/۷۸۸۳ | ۱/۰۲۹۵ | ۰/۱۳۳۴ |
| وزن مخصوص نفت (A.P.I) | Sp.Gr.O | ۰/۹۹۵۵ | ۰/۵۳۵۱ | ۰/۶۹۸۱ | ۰/۱۱۷۲ |

1. Multilayer Perceptron

2. Feed-Forward

شبکه (و یا معیارهای دیگر) داده‌ها به دو بخش آموزش و تست تقسیم می‌گردند. پس از مشورت با کارشناسان حوزه نفت، مقدار k در این پژوهش برابر با ۳ تنظیم گردید. در نتیجه ۱۱۷ سری از داده‌ها در راستای آموزش و ۵۹ سری از آنها جهت تست شبکه عصبی پیشنهادی به کار گرفته شد. فرآیند آموزش شبکه در هر دوره با تزریق یک سری از داده‌ها صورت گرفته و در آن مسیر رفت و برگشت طی می‌شود. در مسیر رفت، کمیت‌های ورودی شبکه وزن دار شده در توابع دینامیک نرون‌های مربوط به هر لایه قرار می‌گیرد. خروجی هر نرون مجدداً به عنوان بردار ورودی جدید به لایه بعدی تزریق شده و عملیات مشابهی روی هر یک از آنها صورت می‌پذیرد. خروجی آخرین لایه با خروجی واقعی شبکه مقایسه شده و اختلاف آنها به عنوان خطا در نظر گرفته می‌شود. در مسیر برگشت با توجه به خطای به دست آمده، وزن بردارها به نحوی تنظیم می‌شود که در مسیر رفت پیشرو خطای کمتر حاصل آید.

تنظیم اوزان شبکه عصبی مصنوعی پیشنهادی با استفاده از الگوریتم ژنتیک

یک شبکه عصبی مصنوعی دقیق، کارآمد و با قابلیت تعمیم‌پذیری بالا با انتخاب صحیح و مناسب متغیرهای ورودی (مانند اوزان اولیه)، تعداد لایه‌های میانی، تعداد نرون لایه‌های پنهان و انتخاب الگوریتم‌های مناسب آموزش شبکه، حاصل می‌شود. لذا با انتخاب بهینه این متغیرها، می‌توان انتظار داشت شبکه عصبی مصنوعی نتایج دقیق و درستی را به عنوان خروجی ارائه دهد.

ضریب حجمی سیال مخزن (B_o) و فشار نقطه حباب (P_b) صورت تابعی از مهم‌ترین خواص فیزیکی سیالات مخازن نفتی در قالب ۲ نرون خروجی معرفی شده است. در واقع شبکه عصبی پیشنهادی، پیش‌بینی مقدار خواص فیزیکی مذکور را به عنوان هدف دنبال می‌نماید. جدول ۳ نام، مقدار بیشینه و کمینه، میانگین و انحراف معیار نرون‌های خروجی را نشان می‌دهد.

شبکه عصبی نیز از طریق روش پس انتشار^۱ خطا آموزش داده شد. انتخاب داده‌های آموزشی مناسب در کیفیت نتایج شبکه عصبی بسیار حائز اهمیت است. زیرا اگر داده‌های آموزشی به میزان لازم متنوع نباشند، ممکن است شبکه در نقاط بهینه نسبی به دام افتد. از سوی دیگر، اگر حجم داده‌های انتخابی کم باشد، ممکن است فرآیند آموزش شبکه به خوبی صورت نگرفته و پاسخ شبکه صحیح نخواهد بود. در این مقاله از داده‌های کامل آزمایشگاهی ۲۲ حلقه چاه نفتی جنوب ایران بهره گرفته شده است به گونه‌ای که به ازای هر حلقه ۸ سری آزمایش صورت پذیرفته و مجموعاً ۱۷۶ سری آزمایش مستقل به منظور تست و آموزش شبکه عصبی مورد استفاده قرار گرفته است. به منظور انتخاب داده‌های آموزش و تست شبکه عصبی پیشنهادی، رویکرد ارزیابی متقابل k بخشی^۲ به کار گرفته شد. این رویکرد در هر تکرار، مجموعه داده‌ها را به k قسمت تصادفی تقسیم می‌نماید، به نحوی که در آن $k-1$ بخش از داده‌ها برای آموزش و یک قسمت نیز به منظور تست شبکه مورد استفاده قرار می‌گیرد. فرآیند مذکور k مرتبه تکرار می‌شود و با توجه به میانگین خطای پیش‌بینی

جدول ۳- نرون‌های خروجی شبکه عصبی پیشنهادی به همراه مقادیر بیشینه، کمینه، میانگین و انحراف معیار

| نرون خروجی | نماد اختصاری | مقدار بیشینه | مقدار کمینه | میانگین | انحراف معیار |
|--------------------------|--------------|--------------|-------------|---------|--------------|
| ضریب حجمی سیال (bbl/STB) | B_o | ۲/۳۹۴۷ | ۱/۰۳۹ | ۱/۶۶۵۶ | ۰/۴۱۳۷ |
| فشار نقطه حباب (psi) | B_p | ۴۵۹۰ | ۶۲۴ | ۲۹۸۳/۴ | ۱۲۰۱ |

1. Back Propagation
2. K-Flod Cross Validation

ورودی شبکه عصبی مورد استفاده قرار می‌گیرد. اوزان اولیه متناظر با ورودی‌های شبکه عصبی (کروموزم‌های الگوریتم ژنتیک) در تکرار نخست به صورت تصادفی انتخاب می‌شوند. همچنین، رابطه میانگین مجذور خطا^۱ به عنوان تابع برآزش هر کروموزم از الگوریتم ژنتیک قلمداد می‌گردد و از این رو به کارگیری عملگر تقاطع^۲ ممکن می‌شود. در پایان هر تکرار، ۱۰٪ از بهترین کروموزم‌ها به همراه ۹۰٪ کروموزم تولید شده تصادفی جدید، به نسل بعد منتقل می‌گردند. فرآیند مذکور تا رسیدن به شرایط توقف الگوریتم ادامه می‌یابد. در پایان بهترین کروموزم به عنوان اوزان اولیه به شبکه عصبی مصنوعی اعمال می‌شود.

عملگرهای تقاطع و جهش

به منظور تقاطع کروموزم‌های منتخب والد و تولید کروموزم‌های فرزند، از عملگر تقاطع یک نقطه‌ای^۳ استفاده شده است. عملگر تقاطع به منظور تولید نسل در هر تکرار مورد استفاده قرار می‌گیرد و هدف اصلی از به‌کارگیری این عملگر، تولید نسلی با برابری^۴ بهتر است، مشروط بر این که هر یک از فرزندان، مشخصه‌های مطلوب والدین خود را به ارث ببرند. در عملگر تقاطع یک نقطه‌ای، یک نقطه بر روی هر کروموزم انتخاب شده و فرزندان با ترکیب ژن‌های قبل و بعد نقطه تقاطع کروموزم والدین منتخب حاصل می‌گردند. همان‌گونه که در شکل ۴ مشاهده می‌شود، پس از اعمال عملگر تقاطع تک نقطه‌ای دو کروموزم والد، تبدیل به دو کروموزم فرزند می‌شوند. این عملگر در هر تکرار به تعداد نصف کروموزم‌های موجود صورت می‌پذیرد و در انتخاب کروموزم‌های والد از رویکرد چرخ رولت^۵ بهره گرفته می‌شود.

یکی از قابلیت‌های الگوریتم ژنتیک که به صورت ترکیبی با شبکه عصبی استفاده می‌شود، تنظیم اوزان اتصالات شبکه است. در ادامه، چگونگی بکارگیری الگوریتم ژنتیک به منظور تعیین اوزان شبکه عصبی توسعه یافته در این تحقیق تشریح می‌شود.

کدگذاری کروموزم‌ها

هر یک از کروموزم‌های الگوریتم ژنتیک از مجموع وزن‌ها و بایاس‌های متناظر با معماری شبکه عصبی تشکیل می‌شود. به عنوان مثال، شکل ۲ کروموزم حاصل از معماری یک شبکه با ۴ نرون ورودی، ۲ نرون در لایه میانی و یک نرون در لایه خروجی را نمایش می‌دهد. در این شبکه اوزانی که لایه اول و دوم را به یکدیگر متصل می‌نمایند با W_1^1 نمایش داده می‌شود و تعداد آنها برابر با ۸ است. همین طور اوزانی که لایه دوم و سوم را به یکدیگر متصل می‌کند با W_1^2 نمایش داده می‌شود که تعداد آنها برابر با ۲ است و در مجموع تعداد کل اوزان شبکه برابر با ۱۰ خواهد بود. از سوی دیگر تعداد ۲ بایاس برای دو عدد نرون لایه دوم در نظر گرفته می‌شود که با b_1^1 نمایش داده می‌شود و همچنین یک عدد بایاس با علامت b_1^2 برای یک عدد نرون در لایه سوم مشخص می‌شود. مجموع این بایاس‌ها برابر با ۳ عدد خواهد بود. در نتیجه طول کروموزم مورد نظر برابر با مجموع تعداد اوزان و بایاس‌های این شبکه و برابر با ۱۳ است. از همین رو، ۶۷ ژن برای هر کروموزم متناظر با شبکه عصبی شکل ۱ متصور است.

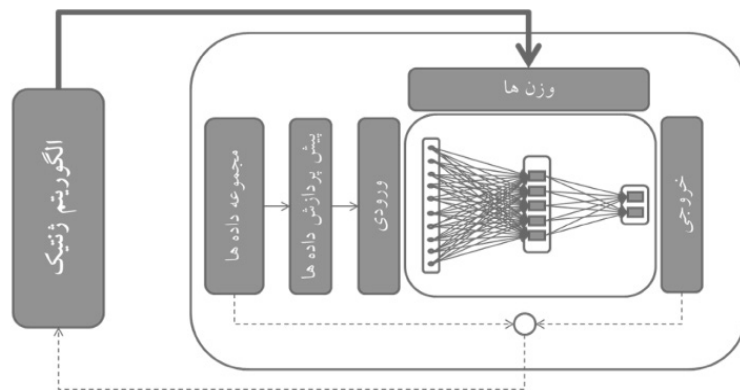
تابع برازندگی

شکل ۳ چگونگی تعامل شبکه عصبی و الگوریتم ژنتیک را نمایش می‌دهد. مطابق این شکل، پس از انجام فرآیند پیش پردازش، مجموعه داده‌ها به عنوان

| | | | | | | | | | | | | |
|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
| W_1^1 | W_2^1 | W_3^1 | W_4^1 | W_5^1 | W_6^1 | W_7^1 | W_8^1 | w_1^2 | w_2^2 | b_1^1 | b_2^1 | b_1^2 |
|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|

شکل ۲- نمایش کروموزم نمونه از معماری شبکه عصبی با ۴ نرون ورودی، ۲ نرون در لایه میانی و یک نرون در لایه خروجی

1. Mean Squared Error (MSE)
2. Crossover
3. Single-Point Crossover
4. Fitness
5. Roulette Wheel



شکل ۳- نحوه به‌کارگیری الگوریتم ژنتیک در تنظیم اوزان شبکه عصبی مصنوعی پیشنهادی

| والدین | | | | | | | | | | | | |
|--------|-------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| -۰.۵۷۹ | ۲.۴۵۶ | -۰.۵۲۳ | ۱.۶۰۲ | -۰.۲۶۸ | -۰.۳۰۶ | -۰.۱۸۶ | -۰.۷۱۵ | -۰.۳۹۱ | -۰.۴۵۴ | -۱.۱۲۹ | -۰.۳۰۸ | -۰.۱۹۵ |
| -۰.۶۵۱ | ۲.۳۱۴ | ۱.۳۸۱ | -۱.۷۵۳ | -۱.۹۲۷ | ۱.۱۷۳ | -۰.۰۴۲ | -۰.۰۸۷ | -۰.۵۹۸ | ۱.۹۲۵ | -۰.۷۱۵ | -۲.۳۱۳ | ۱.۳۸۱ |

↓

| فرزندان | | | | | | | | | | | | |
|---------|-------|--------|-------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| -۰.۵۷۹ | ۲.۴۵۶ | -۰.۵۲۳ | ۱.۶۰۲ | -۰.۲۶۸ | -۰.۳۰۶ | -۰.۱۸۶ | -۰.۰۸۷ | -۰.۵۹۸ | ۱.۹۲۵ | -۰.۷۱۵ | -۲.۳۱۳ | ۱.۳۸۱ |
| -۰.۵۷۹ | ۲.۴۵۶ | -۰.۵۲۳ | ۱.۶۰۲ | -۰.۲۶۸ | -۰.۳۰۶ | -۰.۱۸۶ | -۰.۷۱۵ | -۰.۳۹۱ | -۰.۴۵۴ | -۱.۱۲۹ | -۰.۳۰۸ | -۰.۱۹۵ |

شکل ۴- تبدیل دو کروموزوم والد به دو کروموزوم فرزند با استفاده از عملگر تقاطع

کدنویسی شده و نتایج محاسباتی آنها توسط سیستم یکسان با مشخصات پردازنده ۲/۲۷ گیگا هرتزی و رم ۴ گیگا بایتی با سیستم عامل ویندوز ۷ به‌دست آمده است. به منظور انتخاب پارامترهای الگوریتم ژنتیک همچون تعداد جمعیت اولیه، احتمال تقاطع و احتمال جهش، الگوریتم چندین بار اجرا شد. مطابق جدول ۴ نتایج حاصل از روش سعی و خطا نشان داد که بهترین خروجی الگوریتم ژنتیک با فرض جمعیت اولیه ۱۰۰ کروموزوم، احتمال تقاطع ۰/۸ و احتمال جهش ۰/۲ ممکن می‌گردد. در واقع به ازای پارامترهای مذکور، مقدار میانگین مطلق خطای نسبی^۲ برای هر دو مولفه خروجی شبکه عصبی پیشنهادی (ضریب حجمی سیال و فشار نقطه حباب) کمینه می‌گردد.

پس از به‌کارگیری عملگر تقاطع، جهت بررسی گسترده‌تر فضای جواب مساله، از عملگر جهش^۱ نیز استفاده می‌شود به‌طوری‌که در آن یک محل از هر کروموزوم به‌صورت تصادفی انتخاب شده و مقدار ژن متناظر با احتمال ۰/۵ به میزان ۱۰٪ افزایش (کاهش) می‌یابد.

شرط توقف

تعداد کل تکرار الگوریتم ژنتیک برابر با ۱۰۰ در نظر گرفته شده است و اگر بعد از ۳۰ تکرار بهبودی در مقادیر برازندگی به وجود نیاید، الگوریتم متوقف می‌شود.

نتایج محاسباتی

فرآیند آموزش و تست شبکه عصبی پیشنهادی و همچنین الگوریتم ژنتیک در نرم‌افزار MATLAB

1. Mutation

2. Absolute Average Relative Error (AARE)

جدول ۴- درصد خطای شبکه عصبی پیشنهادی به ازای پارامترهای مختلف الگوریتم ژنتیک

| تعداد جمعیت | احتمال تقاطع | احتمال جهش | درصد AARE برای ضرب حجمی | درصد AARE برای فشار نقطه حباب |
|-------------|--------------|------------|-------------------------|-------------------------------|
| ۵۰ | ۰/۶ | ۰/۴ | ۲/۴۰۹۵ | ۳/۴۳۵۲ |
| ۵۰ | ۰/۷ | ۰/۳ | ۱/۹۱۲۸ | ۵/۳۰۹۸ |
| ۵۰ | ۰/۸ | ۰/۲ | ۲/۱۲۸۱ | ۴/۶۰۹۴ |
| ۵۰ | ۰/۹ | ۰/۱ | ۱/۶۲۲ | ۲/۸۵۲۴ |
| ۱۰۰ | ۰/۶ | ۰/۴ | ۱/۸۵۴۴ | ۴/۶۹۶۵ |
| ۱۰۰ | ۰/۷ | ۰/۳ | ۱/۹۱۴۶ | ۶/۶۸۱۸ |
| ۱۰۰ | ۰/۸ | ۰/۲ | ۱/۴۳۷۹ | ۲/۵۳۲۵ |
| ۱۰۰ | ۰/۹ | ۰/۱ | ۱/۶۵۱۴ | ۳/۱۹۵۶ |
| ۱۵۰ | ۰/۶ | ۰/۴ | ۲/۱۱۴۲ | ۴/۶۵۳۲ |
| ۱۵۰ | ۰/۷ | ۰/۳ | ۱/۹۴۶۹ | ۵/۶۵۴۹ |
| ۱۵۰ | ۰/۸ | ۰/۲ | ۱/۷۵۶۱ | ۳/۵۷۸۷ |
| ۱۵۰ | ۰/۹ | ۰/۱ | ۱/۹۶۹۵ | ۴/۰۵۸۸ |

مشاهده می‌شود، مقدار پیش‌بینی شده بسیار نزدیک به مقدار واقعی P_b است. همچنین، مطابق با شکل ۱۰ معادله برازش برای پیش‌بینی مقدار P_b به صورت رابطه ۲ حاصل می‌شود:

$$Y=T-47 \quad (2)$$

ضریب همبستگی معادله فوق نزدیک به ۱ و برابر با ۰/۹۹۷ و شاخص میانگین مجذور خطا (MSE) برابر با ۰/۰۰۱ است. مقدار همبستگی بالا و میزان ناچیز خطا حکایت از دقت بالای نتایج پیش‌بینی فشار نقطه حباب دارد.

به منظور آنالیز دقیق‌تر، رویکرد پیشنهادی این پژوهش با سه روش کلاسیک موجود در مراجع مقایسه گردید. با فرض e به عنوان خطای نسبی پیش‌بینی، مطابق با روابط ۳-۶ شاخص‌هایی چون RMSE^۱، ARE^۲، AARE و ضریب همبستگی در پیش‌بینی ضریب حجمی سیال محاسبه گردید که مقادیر آن در جدول ۶ ارائه شده است (شاخص‌های مذکور در پیش‌بینی فشار نقطه حباب توسط رویکرد پیشنهادی این مقاله نیز محاسبه شده‌اند).

با تنظیم پارامترهای الگوریتم ژنتیک، اوزان اولیه شبکه عصبی مطابق جدول ۵ محاسبه می‌گردد و بدین طریق شبکه عصبی جهت پیش‌بینی (مرحله تست) مهیا می‌شود.

در شکل‌های ۵ و ۶ به ترتیب فرآیند آموزش و تست شبکه عصبی پیشنهادی برای نتایج ضریب حجمی سیال رسم شده است. همان‌طور که مشاهده می‌شود، مقدار پیش‌بینی شده به مقدار قابل توجهی مشابه با مقدار واقعی B_0 است. همچنین، مطابق با شکل ۷ معادله برازش برای پیش‌بینی مقدار B_0 به صورت رابطه ۱ حاصل می‌آید:

$$Y = 0.97 T + 0.054 \quad (1)$$

ضریب همبستگی معادله ۱ برابر با ۰/۹۹۷ و همچنین، شاخص میانگین مجذور خطا (MSE) برابر با ۰/۰۰۰۳۸ است. مقدار همبستگی بالا و میزان ناچیز خطا حکایت از دقت بالای نتایج پیش‌بینی ضریب حجمی سیال دارد.


در شکل‌های ۸ و ۹ به ترتیب نمودار دقت فرآیند آموزش و تست شبکه عصبی پیشنهادی را برای فشار نقطه حباب نشان می‌دهند. همان‌طور که

1. Root Mean Squared Error


2. Absolute Relative Error

جدول ۵- اوزان اولیه شبکه عصبی پیشنهادی بر طبق نتایج الگوریتم ژنتیک


| |
|--|
| بردار اوزان |
| $W_i^1 = [-0.160, 0.117, 0.119, 0.102, 0.176, 0.133, 0.186, 0.152, 0.11, 0.155, 0.122, 0.193, 0.139, -0.170, 0.153, 0.129, 0.160, 0.183, 0.120, 0.132, 0.136, 0.120, 0.133, 0.159, 0.128, 0.153, 0.121, -0.118, 0.132, 0.140, 0.183, 0.117, 0.147, 0.140, 0.171, 0.113, 0.145, 0.113, 0.145, -0.112, 0.167, 0.153, 0.127, 0.167, 0.127, 0.167, 0.153, 0.122, 0.154, -0.111, 0.172, 0.173]$ |
| $W_i^2 = [0.130, 0.174, 0.144, 0.148, 0.115, -0.116, 0.194, 0.122, 1, 0.155, 0.174, 0.158]$ |
| $b_i = [0.171, 0.167, 0.159, 0.119, 0.198, 0.185, 2.155]$ |



شکل ۵- نمودار دقت فرآیند آموزش شبکه برای ضریب حجمی سیال




شکل ۶- نمودار دقت فرآیند تست شبکه برای ضریب حجمی سیال




مقدار ضریب حجمی سیال مورد انتظار (T)


شکل ۷- نمودار برازش خروجی شبکه عصبی بر حسب مقدار واقعی ضریب حجمی سیال



شکل ۸- نمودار دقت فرآیند آموزش شبکه برای فشار نقطه حباب



شکل ۹- نمودار دقت فرآیند تست شبکه برای فشار نقطه حباب



مقدار فشار نقطه حباب مورد انتظار (psi)

شکل ۱۰- نمودار برازش خروجی شبکه عصبی بر حسب مقدار واقعی فشار نقطه حباب

جدول ۶- مقایسه رویکرد شبکه عصبی مبتنی بر الگوریتم ژنتیک با روش‌های کلاسیک موجود در مراجع

| روش مورد بررسی | ویژگی | MSE | RMSE | ARE | AARE | ضریب همبستگی |
|---|-------|---------|--------|---------|--------|--------------|
| روش پیشنهادی: شبکه عصبی مبتنی بر الگوریتم ژنتیک | B_0 | ۰/۰۰۰۳۸ | ۰/۰۱۹۷ | ۰/۰۰۰۲۱ | ۰/۰۱۴۶ | ۰/۹۹۷ |
| | P_b | ۰/۰۰۱۰۸ | ۰/۰۳۲۹ | ۰/۰۰۰۲۴ | ۰/۰۲۵۳ | ۰/۹۹۷ |
| روش کلاسیک [۲۴] | B_0 | ۰/۸۴۴ | ۰/۹۱۸۶ | ۰/۹۱۲ | ۰/۹۰۱۲ | ۰/۸۸۸ |
| روش کلاسیک [۲۵] | B_0 | ۰/۲۵۴ | ۰/۵۰۳۹ | ۰/۴۹۶۴ | ۰/۴۸۹۳ | ۰/۹۴۴ |
| روش کلاسیک [۲۳] | B_0 | ۰/۹۲۲ | ۰/۹۶۰۲ | ۰/۹۲۶۵ | ۰/۸۹۴۸ | ۰/۷۹۸ |

این امر جریان نفت به سمت چاه را نیز کندتر می‌نماید. مطابق شکل ۱۱ ب و با فرض ثابت بودن فشار، مشاهده می‌شود که افزایش دما در سیالات چند جزئی همچون نفت، فشار نقطه حباب را افزایش می‌دهد.

در شکل (۱۱ ج) و با فرض ثابت بودن دما، نمودار از سمت راست به چپ به شکل زیر قابل بررسی است:

با کاهش فشار اولیه مخزن، حجم نفت به خاطر انبساط آن افزایش می‌یابد. این امر به صورت افزایش ضریب حجمی سیال مشاهده می‌گردد، به طوری که افزایش حجم مذکور تا فشار نقطه حباب ادامه می‌یابد. در فشار نقطه حباب، نفت بیشترین انبساط خود را تجربه می‌نماید و ضریب حجمی سیال نیز به حداکثر مقدار خود خواهد رسید. با افت فشار به زیر نقطه حباب، حجم نفت و ضریب حجمی سیال به دلیل آزاد شدن گاز محلول کاهش یافته و رفته رفته به مقدار یک نزدیک می‌شود.

شکل (۱۱ د) نیز نشان می‌دهد که در یک دمای ثابت، افزایش فشار سبب افزایش فشار نقطه حباب سیال می‌شود. در جدول ۷ نیز تحلیل حساسیت بر روی شاخص‌های خطا و ضریب همبستگی در پیش‌بینی ضریب حجمی سیال و فشار نقطه حباب ارائه شده است.

در واقع به ازای تغییرات ۱۰٪ دما، ۱۵٪ فشار و همچنین ۲۰٪ چگالی، درصد تغییرات در ضرایب همبستگی و خطای پیش‌بینی محاسبه شده است. به عنوان مثال این نتایج بیان می‌دارد که افزایش ۱۰٪ در مقادیر دما (و ثابت ماندن سایر مولفه‌های ورودی شبکه عصبی پیشنهادی)، علاوه بر افزایش خطای پیش‌بینی ضریب حجمی سیال، ضریب همبستگی یک ۰/۱٪ کاهش می‌یابد.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (۳)$$

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n e_i^2 \right]^{\frac{1}{2}} \quad (۴)$$

$$ARE = \frac{1}{n} \sum_{i=1}^n e_i \quad (۵)$$

$$AARE \% = \frac{100}{n} \sum_{i=1}^n |e_i| \quad (۶)$$


نتایج محاسباتی شاخص‌های یاد شده نشان می‌دهد که روش پیشنهادی در مقایسه با سایر روش‌ها، از همبستگی بالاتر و خطای کمتری دارد. در نتیجه، شبکه عصبی مبتنی بر الگوریتم ژنتیک قادر به پیش‌بینی خصوصیات سیالات می‌باشد. همچنین، نتایج به دست آمده نشان می‌دهد شبکه عصبی پیشنهادی بر محدودیت روش‌های کلاسیک و همچنین محدودیت‌های انجام آزمایش‌های PVT فائق آمده و می‌تواند در صیانت از مخازن نفتی ایران راهگشا باشد.

تحلیل حساسیت روی متغیرهای خروجی شبکه عصبی مصنوعی پیشنهادی

در این بخش از مقاله، با فرض ثابت بودن دما (فشار) اثر تغییرات فشار (دما) بر خروجی‌های شبکه عصبی یعنی ضریب حجمی سیال و فشار نقطه حباب، تحلیل می‌گردد.

مطابق شکل ۱۱ الف، فشار ثابت در نظر گرفته می‌شود. دما نیز در مخزن نفتی مورد نظر مقداری تقریباً ثابت دارد و در نتیجه حجم سیال مخزن نیز ثابت خواهد بود. این در حالی است که با افزایش دما، حجم سیال موجود در سطح افزایش یافته و بر حسب معادلات ترمودینامیکی، ضریب حجمی سیال با افزایش روبه‌رو می‌شود.

رسیدن به نقطه فشار حباب سبب می‌شود تا درصدی از نفت به گاز تبدیل شود. همچنین،



شکل ۱۱- الف) تغییرات ضریب حجمی سیال به ازای افزایش دما، ب) تغییرات فشار نقطه حباب به ازای افزایش دما، ج) تغییرات ضریب حجمی سیال به ازای افزایش فشار، د) تغییرات فشار نقطه حباب به ازای افزایش فشار

جدول ۷- تحلیل حساسیت بر خطای پیش‌بینی و ضریب همبستگی به ازای تغییرات در دما، فشار و چگالی

| میزان تغییرات در دما، فشار و چگالی | ویژگی | درصد تغییرات MSE | درصد تغییرات RMSE | درصد تغییرات ARE | درصد تغییرات AARE | ضریب همبستگی |
|------------------------------------|-------|------------------|-------------------|------------------|-------------------|--------------|
| ۱۰٪ افزایش دما | B_0 | ۲/۵ | ۵/۲ | ۷/۴ | ۸/۶ | -۱/۰ |
| | P_b | ۱/۱۳۵ | ۴/۵۳ | ۳/۵۸ | ۷/۶۸ | -۲/۰ |
| ۱۰٪ کاهش دما | B_0 | -۴/۱۸ | -۶/۹ | -۷/۴ | -۳/۱ | -۱/۰ |
| | P_b | ۵/۴۳ | ۷/۱۹ | ۲۵ | ۴/۳۰ | -۱/۰ |
| ۱۵٪ افزایش فشار | B_0 | ۳/۹۷ | ۵/۳۹ | ۳/۵۲ | ۸/۵۶ | -۲/۰ |
| | P_b | ۱/۱۶۱ | ۳/۶۱ | ۵۰ | ۷/۵۵ | -۳/۰ |
| ۱۵٪ کاهش فشار | B_0 | ۵/۱۰ | ۶/۴۲ | ۶/۴۷ | ۱/۵۶ | -۴/۰ |
| | P_b | ۲/۵۹ | ۱/۲۶ | ۸/۲۰ | ۵/۲۳ | -۱/۰ |
| ۲۰٪ افزایش چگالی | B_0 | ۴/۱۸ | ۶/۸ | ۵/۹ | ۳/۱۲ | -۱/۰ |
| | P_b | ۴/۱۰ | ۸/۴۲ | ۵/۳۷ | ۷/۳۸ | -۲/۰ |
| ۲۰٪ کاهش چگالی | B_0 | -۴/۶۸ | -۶/۴۳ | -۳۸ | -۶/۳۷ | ۱/۰ |
| | P_b | ۰/۹۲ | ۶/۰ | -۱/۴ | -۷/۰ | ۰/۰ |

نتیجه‌گیری

ضریب حجمی سیال و فشار نقطه حباب (دو مورد از خصوصیات مهم سیال مخازن) به عنوان هدف پیش‌بینی شبکه انتخاب شدند. شبکه عصبی مصنوعی طراحی شده از نوع پیشرو با سه لایه بود

در این مقاله از شبکه عصبی مصنوعی مبتنی بر الگوریتم ژنتیک به منظور پیش‌بینی نتایج آزمایش‌های PVT بهره گرفته شد. در این راستا

بر مشکلات انجام آزمایش‌های PVT و همچنین محدودیت کاربرد منطقه‌ای روش‌های کلاسیک غلبه نماید. در نتیجه، شبکه پیشنهادی می‌تواند روشی کارا به منظور پیش‌بینی آزمایش‌های PVT مخازن نفتی ایران قلمداد گردد.

تشکر و قدردانی

تهیه‌کنندگان این پژوهش وظیفه خود می‌دانند که از هم‌فکری و راهنمایی‌های کلیه همکاران تشکر نمایند.

و به منظور آزمایش و تست آن از ۱۷۶ سری کامل داده‌های ۲۲ حلقه چاه نفت مناطق جنوب ایران استفاده گردید. به علاوه، جهت افزایش دقت و بازدهی بیشتر شبکه عصبی پیشنهادی از قابلیت‌های الگوریتم ژنتیک در بهینه‌سازی اوزان اولیه اتصالات بهره گرفته شده است. نتایج محاسباتی حکایت از توانایی شبکه عصبی پیشنهادی در پیش‌بینی خروجی‌های مدل با ضریب همبستگی بالا و خطای بسیار ناچیز دارد. این نتایج نشان می‌دهد که رویکرد پیشنهادی در مقایسه با روش‌های کلاسیک عملکرد بسیار بهتری داشته و توانسته است

مراجع

- [۱]. صیرفیان ع.، زمین‌شناسی نفت، نشر سمر، ۱۳۸۶.
- [۲]. علی مددی ا.، کاربرد سیستم‌های هوشمند در صنایع بالادستی صنعت نفت، پایان‌نامه کارشناسی ارشد، دانشگاه بوعلی سینا، ایران، ۱۳۹۱.
- [3]. Asadisaghanid J. and Tahmasebi P., "Comparative evaluation of back-propagation neural network learning algorithms and empirical correlations for prediction of oil PVT properties in Iran oilfields," *Petroleum Science and Engineering*, Vol. 78, pp. 464-475, 2011.
- [4]. Mohaghegh S. D., "Recent developments in application of artificial intelligence in petroleum engineering," *J. Pet. Technol.*, Vol. 78, pp. 86-91, 2005.
- [5]. Mohaghegh S. D., "Virtual intelligence applications in petroleum engineering: Part 2—evolutionary computing," *J. Pet. Technol.*, Vol. 52, pp. 40-46, 2000.
- [6]. Weiss W. W., Balch R. S., and Stubbs B. A., "How artificial intelligence methods can forecast oil production," *SPE/DOE Improved Oil Recovery Symposium*, Tulsa, 2002.
- [7]. Al-Fattah S. M. and Startzman R. A., "Predicting natural-gas production using artificial neural network," *SPE Hydrocarbon Economics and Evaluation Symposium*, Dallas, Texas, 2001.
- [8]. Moghadassi A. R., Parvaizian F., Hosseini S. M., and Fazlali A. R., "A new approach for estimation of PVT Properties of pure gazes based on artificial neural network model," *Brazilian Journal of chemical Egnieering*, Vol. 26, pp. 199-206, 2009.
- [9]. Zambrano G., "Development of neural network models for the prediction of dew point pressure of retrograde gases and saturated oil viscosity of black oil systems," *Masters thesis*, Texas A & M University, USA, 2002.
- [10]. Bozorgmehry R. B., Abdolahi F., and Moosavian M. A., "Characterization of basic properties for pure properties for pure substances and petroleum fractions by neural network," *Fluid phase equilibria*, Vol. 231, pp. 188-196, 2005.
- [11]. Dehghani M. R., Modarress H., and Bakhshi A., "Modeling and prediction of activity coefficient ratio of electrolytes in aqueous electrolyte solution containing amino acids using artificial neural network," *Fluid phase equilibria*, Vol. 244, pp. 153-159, 2006.

- [12]. Ganguly S., "Prediction of VLE data using radial basis function network," Computers and chemical engineering, Vol. 27, pp. 1445-1454, 2003.
- [13]. Sozen A., Arcakilioglu E., and Ozalp M., "Formulation based on artificial neural network of thermodynamic properties of ozone friendly refrigerant/absorbent couples," Applied thermal engineering, Vol. 25, pp. 1808-1820, 2005.
- [14]. Biglin M., "Isobaric vapor-liquid equilibrium calculations of binary systems using a neural network," J. Serb. Chem. Soc., Vol. 69, pp. 669-674, 2004.
- [15]. Gharbi R. B. and Elsharkawy A. M., "Neural-network model for estimating the PVT properties of Middle East crude oils," SPE Middle East Oil Show and Conference, Bahrain, 1997.
- [16]. Elsharkawy A. M., "Modeling the properties of crude oil and gas systems Using RBF network," SPE Asia Pacific Oil and Gas Conference, Perth, Australia, 1998.
- [17]. Varotsis N., Gaganis V., Nighswander J., and Guieze P., "A novel non-iterative method for the prediction of the PVT behavior of reservoir fluids," SPE Annual Technical Conference and Exhibition, Houston, Texas, 1999.
- [18]. Gharbi R. B. and Elsharkawy A. M., "Universal neural-network model for estimating the PVT properties of crude oils," SPE Asia Pacific Oil & Gas Conference, Kuala Lumpur, Malaysia, 1999.
- [19]. Osman E. A., Abdel-Wahhab O. A., and Al-Marhoun M. A., "Prediction of oil properties using neural networks," SPE Middle East Oil Show Conference, Bahrain, 2001.
- [20]. Al-Marhoun M. A. and Osman E. A., "Using artificial neural networks to develop new PVT correlations for saudi crude oils," Abu Dhabi, United Arab Emirates, 2002.
- [21]. Eissa M., Shokir El-M., Goda Hussam M., Fattah Khaled A., and Sayyoub Mohamed H., "Modeling approach for predicting PVT data," Engineering Journal of the University of Qatar, vol. 17, pp. 11-28, 2004.
- [22]. Omole O., Falode O. A., and Deng D. A., "Prediction of Nigerian crude oil viscosity using artificial neural network," Petroleum & Coal, Vol. 51, pp. 181-188, 2009.
- [23]. Ahmed T., "Hydrocarbon phase behavior," Vol. 7, Houston, TX: Gulf Publishing Company, 1989
- [24]. Vasquez A. and Beggs H. D., "Correlation for Fluid Physical Property Predictor," Journal of Petroleum Technology, Vol. 32, No 6, 1980.
- [25]. Petrosky G. E., Farshad F., "Pressure-volume-temperature correlations for gulf of mexico crude oils," SPE Res. Eval. & Eng., Vol. 1, No.5, pp. 416-420, 1998..