

## استفاده از شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی ژنتیک جهت تخمین نسبت گاز محلول به نفت در نقطه‌ی حباب مخازن نفتی جنوب غرب ایران

سید علیرضا طباطبایی نژاد<sup>۱</sup>، دانشگاه صنعتی سهند<sup>۲</sup>، محمد برجسته<sup>۳\*</sup>، مصیب کمری<sup>۴</sup>، شرکت ملی مناطق نفت‌خیز جنوب

### چکیده

هدف این پژوهش استفاده از توانایی هوش مصنوعی جهت تخمین خواص سیالات مخزن با دقت بیشتر نسبت به روش‌های تجربی است که کارآیی کمی دارند. بدین منظور پس از جمع‌آوری و سازمان‌دهی داده‌های مربوط به ۳۶ نمونه آزمایش PVT<sup>۲</sup> که طی ۵۶ سال تولید از مخزن انجام شده بود، جهت پیش‌بینی ضریب حجمی نفت سازندی، یک‌بار از شبکه‌ی عصبی مصنوعی و بار دیگر از تلفیقی از شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک استفاده گردید. از آنجا که  $R_{sb}$  تابعی از وزن مخصوص گاز، API نفت، دمای مخزن و فشار نقطه‌ی حباب است به‌عنوان داده‌های لایه‌ی ورودی استفاده شد. همان‌گونه که در ادامه مشاهده خواهد شد نتایج نشان می‌دهند که شبکه‌های عصبی نسبت به روابط تجربی که بر اساس داده‌های محلی خاص مناطق مختلف به‌دست آمده‌اند از دقت بسیار خوبی برای تخمین خواص سیالات مخزن برخوردارند. همچنین ترکیب شبکه‌ی عصبی مصنوعی با الگوریتم ژنتیک بسیار مفید بود؛ چراکه سبب افزایش بسیار زیاد سرعت همگرایی به سمت مدل دقیق و پایدار شبکه‌ی عصبی شد. شبکه‌ی عصبی مصنوعی طراحی شده میانگین انحراف نسبی حدود ۱/۸ درصدی را نشان می‌دهد.

### اطلاعات مقاله

تاریخ ارسال نویسنده: ۹۵/۳/۳

تاریخ ارسال به داور: ۹۵/۳/۲۰

تاریخ پذیرش داور: ۹۵/۴/۲۰

### واژگان کلیدی:

هوش مصنوعی، خواص سیالات مخزن، شبکه‌ی عصبی مصنوعی، الگوریتم ژنتیک، نسبت گاز محلول به نفت در نقطه‌ی حباب

### مقدمه

مخزن و وزن مخصوص نفت و گاز. مطالعه‌ی دقیق این روابط نشان می‌دهد که آنها دقت کافی جهت تعیین خواص نفت خام در میادین مختلف نفتی ندارند؛ چراکه معمولاً برای تولید این نوع روابط از داده‌های مناطق مشخصی استفاده شده است.

مطالعات چند سال اخیر نشان می‌دهد که برای پیش‌بینی خواص PVT، شبکه‌های عصبی مصنوعی از قابلیت بسیار خوبی برخوردارند. مثلاً در سال ۲۰۰۰ Al-Marhoun تعداد ۲۸۳ مجموعه داده از میادین مختلف عربستان جمع‌آوری کرد و برای تخمین  $P_b$  و  $B_{ob}$  در مخازن عربستان با استفاده از شبکه‌ی عصبی مصنوعی دو مدل ارائه کرد که دقت آنها برای تخمین  $B_{ob}$  بسیار بیشتر از روابط تجربی است. این مقاله ایده‌ی گسترش روابط بومی یا ناحیه‌ای برای تخمین خواص سیالات مخزن را نسبت به روابط تجربی جهانی تقویت می‌کند [۱]. قبل از این نیز Elsharkawy و Gharbi در ۱۹۹۷ مدل شبکه‌ی عصبی دیگری جهت تخمین خواص  $P_b$  و  $B_{ob}$  در مقیاس جهانی ارائه کرده بودند که در آن میانگین خطای تخمین  $P_b$  در فاز آموزش و آزمایش شبکه، پائین‌تر از روابط تجربی معمولی بود [۲].

اگرچه برای ایجاد این نوع شبکه‌ها نیز مثل روابط تجربی PVT از داده‌های مناطق خاصی استفاده می‌شود اما به‌دلیل آنکه ANN<sup>۶</sup> از روش‌های تجربی یا آماری متداول برای

خواص سیالات مخزن از متغیرهای بسیار مهم در محاسبات موازنه‌ی مواد، چاه‌آزمایی، تخمین مقدار نفت قابل‌برداشت و همچنین مدل‌سازی عددی مخزن است. اندازه‌گیری مستقیم این خواص در آزمایشگاه انجام می‌شود. اما از لحاظ محدودیت‌های موجود (هزینه‌ی زمان و فن‌آوری)، دسترسی همیشگی به آزمایشگاه مقدور نیست یا ممکن است حجم نمونه‌های اندازه‌گیری شده کافی نباشد؛ بنابراین روش‌های غیرمستقیم نیز در این خصوص کاربرد دارد. قبلاً از یک‌سری روابط تجربی جهت تخمین این خواص استفاده می‌شد که استفاده از این روابط سنتی غیربومی برای مخازن کشورمان چندان مناسب نیست. هدف این پژوهش، استفاده از روابط هوشمند با دقت بیشتر و به‌صورت بومی برای مخازن جنوب غرب ایران است. دو روش معمول قابل‌استفاده در هنگام عدم دسترسی به اندازه‌گیری‌های آزمایشگاهی برای تعیین خواص PVT نفت خام، عبارتند از معادله‌ی حالت EOS<sup>۵</sup> و روابط تجربی PVT. معادله‌ی حالت بر اساس آگاهی از جزئیات ترکیبات سیالات مخزن پایه‌گذاری می‌شود که تعیین این‌گونه کمیت‌ها بسیار گران و وقت‌گیر است. در حالی که روابط تجربی PVT بر اساس داده‌های حاصل از لایه‌های زمین که به‌راحتی اندازه‌گیری می‌شوند پایه‌گذاری شده‌اند. این داده‌ها عبارتند از فشار و دمای

\* نویسنده‌ی عهده‌دار مکاتبات (mohammad.barjaste@gmail.com)

### ج) رابطه‌ی Hanafy et.al

این رابطه‌ی تجربی، مربوط به نمونه‌های اخذ شده از خلیج سوئز و نواحی صحرای سیناست:

$$R_p = -49.069 + 0.312p$$

### د) رابطه‌ی Velarde et al

این رابطه‌ی تجربی، از ۲۰۹۷ نمونه‌ی مخلوط نفت و گاز اخذ شده است:

$$R_s = \left( \frac{P}{1091.47} \right)^{\frac{1}{535480}} + 0.740152 \frac{1}{\gamma_g^{-0.161488} \cdot 10^x}$$

$$x = 0.013098 \cdot T^{0.282372} - 8.2 \cdot 10^{-6} \cdot \gamma_o^{2.176124}$$

### ه) رابطه‌ی Vasquez & Beggs


این رابطه‌ی تجربی، مربوط به نمونه‌های اخذ شده از خلیج سوئز و نواحی صحرای سیناست:

۱ | ثابت‌های رابطه‌ی Beggs & vesquez

| Coefficient | $\gamma_o \leq 30^\circ \text{API}$ | $\gamma_o > 30^\circ \text{API}$ |
|-------------|-------------------------------------|----------------------------------|
| $C_1$       | $4/677 \times 10^{-4}$              | $4/670 \times 10^{-4}$           |
| $C_2$       | $1/751 \times 10^{-5}$              | $1/100 \times 10^{-5}$           |
| $C_3$       | $-1/811 \times 10^{-8}$             | $1/377 \times 10^{-9}$           |

$$R_s = c_1 \gamma_g P^{c_2} \exp\left(c_3 \left(\frac{\gamma_o}{T + 460}\right)\right)$$

در شبکه‌ی عصبی طراحی شده جهت تخمین  $R_{sb}$ ، از وزن مخصوص گاز، API نفت، دمای مخزن و فشار نقطه‌ی حباب



۱ | ساختار شبکه‌ی مصنوعی

محاسبات خود استفاده نمی‌کند فرآیند پیش‌بینی آن به یک یا چند میدان نفتی خاص محدود نمی‌شود. در این مطالعه با موضوع تخمین متغیرهای PVT سیالات نفتی توسط روش‌های هوشمند در یکی از مخازن جنوب غربی ایران تلاش شده با استفاده از ادغام دو روش شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک، شبکه‌ای را آموزش داد تا بتواند در ناحیه‌هایی که جهت شبیه‌سازی ستون چاه یا مخزن با کمبود اطلاعات مواجه هستیم، خواص سیالات مخزن را پیش‌بینی کند [۳].

### ۱- روش کار

در این مطالعه سعی شده جهت تخمین خواص سیالات مخزن با دقت زیاد، از توانایی و کاربرد هوش مصنوعی در حل مسائل پیچیده و غیرخطی بهره برد. بدین منظور جهت مقایسه با نتایج حاصل از روش‌های هوش مصنوعی و آزمایشگاه، روابط تجربی پرکاربرد ارائه شده است. در این نوشتار یکی از بزرگ‌ترین مخازن جنوب غرب کشور بررسی شد و داده‌های مربوط به ۳۶ نمونه آزمایش PVT طی ۵۶ سال تولید مخزن از پایگاه داده‌های مناطق نفت‌خیز جنوب جمع‌آوری و سازمان‌دهی گردید. از این داده‌ها جهت پیش‌بینی  $R_{sb}$  یک‌بار از طریق شبکه‌ی عصبی مصنوعی و مرتبه‌ی دیگر از طریق تلفیقی از شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک استفاده شد. در ادامه روابط تجربی به کار رفته ارائه گردیده است:

### الف) رابطه‌ی Petrosky & Farshad

این رابطه‌ی تجربی، مربوط به نمونه‌های اخذ شده از خلیج مکزیک است:

$$R_s = \left( \left( \frac{P}{112.727} + 12.34 \right) \cdot \gamma_g^{0.8439} \cdot 10^x \right)^{1.73184}$$

$$x = 7.916 \times 10^{-4} \cdot \gamma_o^{1.541} - 4.561 \times 10^{-5} T^{1.3911}$$

### ب) رابطه‌ی Glaso

این رابطه‌ی تجربی، مربوط به نمونه‌های اخذ شده از دریای شمال است:

$$R_s = \left( \frac{x \cdot \gamma_o^{0.989}}{T^{0.172}} \right)^{\frac{1}{0.816}} \cdot \gamma_g$$

که در آن:

$$\log(x) = \frac{-b + \sqrt{b^2 - 4ac}}{2a}$$

$$a = -0.30218$$

$$b = 1.7447 \quad c = 1.7669 - \log(p)$$

به صورت کلاسیک آموزش دیده و هم شبکه‌ی عصبی ترکیب شده با الگوریتم ژنتیک، نسبت به روابط تجربی جهانی عملکرد بسیار بهتری دارند؛ به طوری که میانگین انحراف خطای مدل‌های پیش‌بینی کننده توسط شبکه‌های عصبی حدود ۱/۹-۱ درصد است. در حالی که این مقدار برای روابط تجربی جهت پیش‌بینی  $R_{sb}$  حدود ۲۰-۱۱ درصد است. نتایج کلی به صورت میانگین مربعات خطای مطلق و ریشه‌ی آن برای روابط تجربی، شبکه‌ی عصبی مصنوعی و همچنین ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک در جدول ۲ ارائه شده است. مدل طراحی شده توسط شبکه‌های عصبی عملکرد بسیار خوبی داشت. لازم به ذکر است که در اجرای شبکه‌ی عصبی ترکیب شده با الگوریتم ژنتیک از ۸۰ درصد داده‌های آزمایشگاهی برای آموزش و از ۲۰ درصد برای آزمایش شبکه استفاده شد. همان گونه که در ادامه خواهیم دید برای ارزیابی عملکرد شبکه‌های عصبی مذکور از میانگین مربعات خطای مطلق (MSE) و ریشه‌ی میانگین مربعات خطای مطلق (RMSE) استفاده شد. در این مطالعه جهت پیش‌بینی خواص سیالات مخزن با تعداد محدودی داده‌های آزمایشگاهی مواجه بودیم و مقایسه‌ی MSE یا RMSE مدل‌های شبکه‌ی عصبی با مدل‌های حاصل از ترکیب الگوریتم ژنتیک و شبکه‌ی عصبی چندان صحیح نیست و نمی‌توان در مورد قدرت پایدار کنندگی که الگوریتم ژنتیک به شبکه‌ی عصبی می‌دهد قضاوت کرد. این توانایی الگوریتم ژنتیک زمانی بیشتر به چشم می‌خورد که با تعداد داده‌های بیشتری روبه‌رو هستیم. هر چند در این پژوهش حین اجرا این

به عنوان داده‌های لایه‌ی ورودی استفاده شد. شبکه‌ی پیش‌بینی کننده‌ی مذکور شامل یک لایه‌ی مخفی با پنج نورون است که تمامی آنها با تابع تانژانت سیگموئیدی تحریک می‌شوند. لایه‌ی خروجی یک نورون با تابع خطی خالص و یک خروجی  $R_{sb}$  دارد. ۶۰ درصد داده‌های آزمایشگاهی برای آموزش شبکه، ۲۰ درصد جهت اعتبارسنجی و ۲۰ درصد برای آزمایش شبکه‌های عصبی استفاده شد. شبکه‌ی طراحی شده با ساختاری که در شکل ۱- ارائه شده، نسبت به روابط تجربی عملکرد قابل قبول تری دارد [۴].

برای درک بهتر موضوع پس از نشان دادن نتایج حاصل از شبکه‌ی عصبی، برای مقایسه‌ی جواب‌های پیش‌بینی شده‌ی این دو روش با هم و بیان خطاهای هر یک از مقدار هدف، از روابط تجربی یعنی نتایج آزمایشگاهی استفاده گردید. برای ارزیابی عملکرد شبکه‌های عصبی مذکور از میانگین مربعات خطای مطلق (MSE) و ریشه‌ی میانگین مربعات خطای مطلق (RMSE) استفاده شد.

$$MSE = \frac{1}{n} \sum_{i=1}^n (TARGET - OUTPUT)^2$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (TARGET - OUTPUT)^2}$$

در ادامه‌ی این مطالعه تصمیم بر آن شد که برای تخمین  $R_{sb}$  از ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک استفاده گردد. بدین منظور جهت آموزش شبکه‌ی عصبی از الگوریتم ژنتیک که از الگوریتم‌های تکاملی (Evolution) به حساب می‌آید و قدرت بسیار زیادی جهت جستجوی جواب‌های قدرتمند و سازگار و ایجاد نسل‌های جدید از ترکیب نسل‌های کنونی دارد استفاده گردید. در این پژوهش برای تخمین بهترین وزن‌های لایه‌های مخفی و خروجی، از الگوریتم ژنتیک کمک گرفته شد که در همگرایی و تخمین دقیق مدل طراحی شده توسط شبکه‌ی عصبی نتایج بسیار خوبی داشت و به عبارت دیگر کنترل شبکه‌ی عصبی برای رسیدن به جوابی با دقت بیشتر و انحراف کمتر را بسیار ساده‌تر می‌کند؛ به طوری که از انحراف و تخمین خطای زیاد حتی در اجراهای مختلف جلوگیری می‌نماید. اما این در حالی است که شبکه‌ی عصبی به دلیل وجود انتخاب‌های تصادفی از نمونه برای رسیدن به جوابی با دقت مناسب، به تنهایی نیازمند اجراهای زیاد باشد. بنابراین این امر سبب می‌شود بتوان توسط الگوریتم ژنتیک به پایداری و مطمئن‌تر بودن شبکه‌ی عصبی کمک کرد [۵].

## ۲- بحث و نتایج

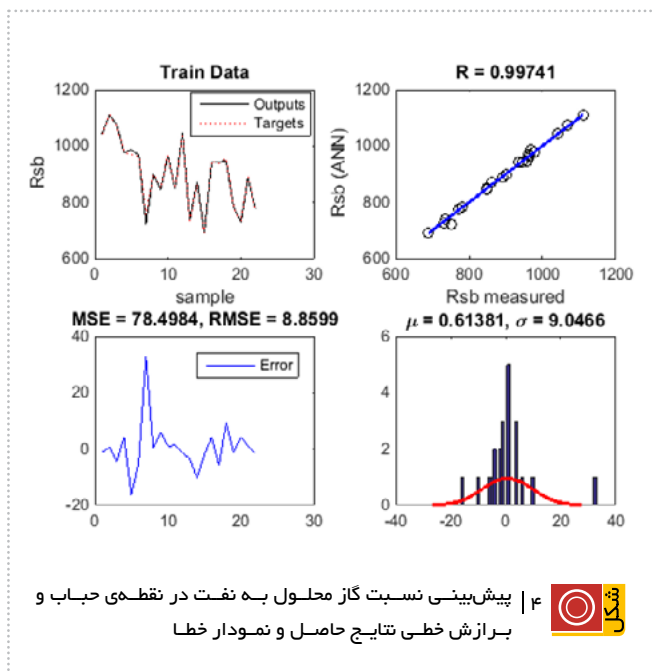
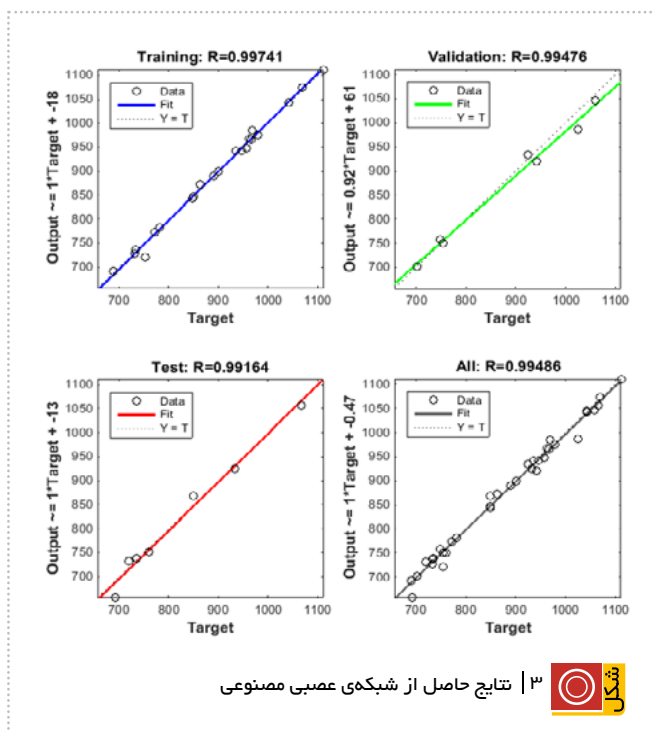
هر دو شبکه‌ی عصبی یعنی هم شبکه‌ی عصبی متداول که

جدول ۲ | نتایج میانگین مربعات خطای مطلق و ریشه‌ی آن برای نسبت گاز محلول به نفت در نقطه‌ی حباب

| رابطه             | میانگین مربعات خطای مطلق<br>MSE | ریشه‌ی میانگین مربعات خطای مطلق<br>RMSE | درصد میانگین مربعات خطای نسبی<br>٪ |
|-------------------|---------------------------------|---|------------------------------------|
| ANN               | ۷۸/۴۹                           | ۸۵/۸                                    | ۱                                  |
| AG+NNA            | ۳۱۷/۴۵                          | ۵۳/۱۷                                   | ۹/۱                                |
| Velardeetal       | ۸/۰۸۰۸ E3                       | ۸۹۳/۸۹                                  | ۲/۱۰                               |
| Petrosky& Farshad | ۱/۴۵۲۳ E4                       | ۵۱۱/۱۲۰                                 | ۶/۱۳                               |
| Vasquez&Beggs     | ۱/۷۹۰۹ E4                       | ۹۳۰/۱۳۱                                 | ۹/۱۴                               |
| Glaso et al       | ۲/۴۱۲۸ E4                       | ۳۳۰/۱۵۵                                 | ۶/۱۷                               |
| Hanafy et al      | ۲/۵۵۳۳ E4                       | ۷۸۹/۱۵۹                                 | ۱/۱۸                               |

۳۶ نمونه‌ی مطالعه شده ارائه گردیده است. همچنین توزیع نرمال خطا با میانگین تقریبی حدود صفر و دامنه‌ی خطای حدود ۰/۰۱ تأیید کننده‌ی عملکرد مناسب شبکه‌ی عصبی مصنوعی طراحی شده است.

**۲-۲- نسبت گاز محلول به نفت در نقطه‌ی حباب پیش‌بینی شده از طریق ادغام شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک**  
به‌طور کلی شبکه‌ی عصبی به دو صورت آموزش می‌بیند؛ روش اول



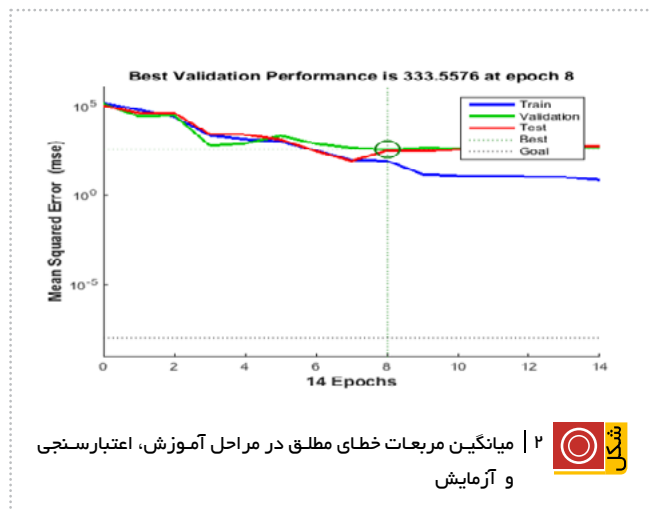
توانایی به‌وضوح مشاهده شد. با توجه به اینکه روش جفت‌گیری دو نقطه‌ای نسبت به سایر روش‌ها دقت بیشتری داشت در مدل ایجاد شده توسط ترکیب الگوریتم ژنتیک و شبکه‌ی عصبی مصنوعی برای پیش‌بینی نسبت گاز محلول به نفت در نقطه‌ی حباب، در مرحله‌ی تقاطع الگوریتم ژنتیک از این روش استفاده گردید.

**۲-۱- نسبت گاز محلول به نفت در نقطه‌ی حباب پیش‌بینی شده از طریق شبکه عصبی مصنوعی متداول**

در شکل ۲ عملکرد خوب و قابل اعتماد شبکه‌ی عصبی مصنوعی که توسط الگوریتم Levenberg-Marquardt آموزش دیده حین هر سه مرحله‌ی آموزش، اعتبارسنجی و آزمایش ارائه شده است. همان‌طور که در این شکل مشاهده می‌شود میانگین مربعات خطای مطلق در مرحله‌ی آموزش کمترین بوده و در مرحله‌ی آزمایش نیز روند کاهشی مناسبی داشته‌اند. این موضوع بیانگر عملکرد قابل اطمینان شبکه‌ی عصبی طراحی شده، جهت پیش‌بینی نسبت گاز محلول به نفت در نقطه‌ی حباب برای این مجموعه از داده‌ها و همچنین پیش‌بینی سایر نقاط در بخش‌های مختلف مخزن مورد مطالعه است. داده‌های ورودی در این بخش وزن مخصوص گاز، API نفت، دمای مخزن و فشار نقطه‌ی حباب است.

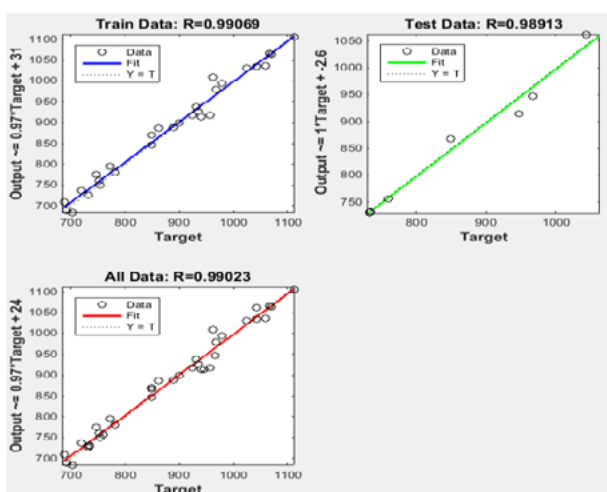
در شکل ۳ ضریب همبستگی برای هر یک از مراحل آموزشی، اعتبارسنجی و آزمایش و همچنین مقایسه‌ی خروجی شبکه با نتایج آزمایشگاه برای هر کدام از نمونه‌ها ارائه شده است. هر قدر خط ضریب همبستگی بر خط نقطه‌چین ( $Y=X$ ) منطبق‌تر باشد عملکرد شبکه‌ی عصبی بهتر خواهد بود.

در شکل ۴ مشاهده می‌شود که پیش‌بینی خروجی شبکه‌ی عصبی و نتایج آزمایشگاهی برای تمامی نمونه‌های آزمایش شده بسیار مناسب بوده است. در این شکل همچنین نمودار MSE و RMSE برای



الگوریتم ژنتیک و شبکه‌ی عصبی چندان صحیح نیست و نمی‌توان در مورد قدرت پایدار کنندگی که الگوریتم ژنتیک به شبکه عصبی می‌دهد قضاوت کرد. این توانایی الگوریتم ژنتیک زمانی بیشتر به چشم می‌خورد که با تعداد داده‌های بیشتری روبه‌رو هستیم. هرچند در این پژوهش توانایی مذکور حین اجرا به وضوح مشاهده است [۶].

در شکل ۸- نتایج پیش‌بینی نسبت گاز محلول به نفت در نقطه‌ی حباب جهت آموزش شبکه‌ی عصبی مصنوعی به هر دو روش کلاسیک و هوشمند و همچنین نتایج حاصل از تخمین توسط روابط تجربی ارائه شده است [۷].

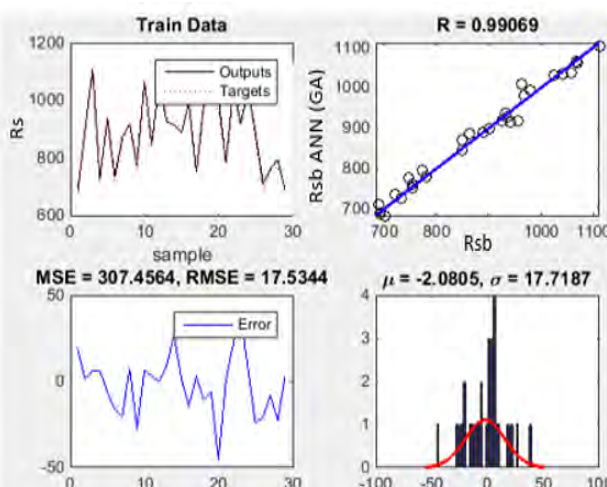


شکل ۶ | نتایج حاصل از ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک


استفاده از الگوریتم‌های کلاسیک مانند Levenberg-Marquardt است و روش دوم استفاده از الگوریتم‌های هوشمند نظیر الگوریتم ژنتیک مورچگان و ... در این قسمت جهت آموزش شبکه‌ی عصبی از الگوریتم ژنتیک استفاده شد.

لازم به ذکر است در طراحی این الگوریتم از جمعیت ۳۰۰ تایی و نسل‌های ۶۰ تایی استفاده گردید. همچنین نحوه‌ی انتخاب والدین در این روش به صورت رقابتی انجام شد. در ادامه‌ی کار جهت مرحله‌ی ادغام یا تقاطع از تابع دو نقطه‌ای استفاده گردید. در این مقاله الگوریتم ژنتیک جهت بهینه‌سازی وزن‌های شبکه‌ی عصبی برای رسیدن به مدلی با کمترین خطا کد نویسی شد. شایان ذکر است که داده‌های ورودی در این بخش نیز وزن مخصوص گاز، API نفت، دمای مخزن و فشار نقطه‌ی حباب است. در شکل ۵- نمودارهای مربوط به تابع هزینه که همان تابع خطای نسبی است ارائه شده‌اند. این نمودارها در ۶۰ نسل تولید شده به خوبی سیری نزولی را نشان می‌دهند که به سوی خطای کمتر و نسل‌های بهینه و پایدارتر سیر می‌کنند. در این شکل داده‌هایی که آموزش داده شده‌اند به خوبی نمایان و قابل مقایسه‌اند.

در شکل ۶- ضریب همبستگی برای هر یک از مراحل آموزشی و آزمایش و همچنین مقایسه‌ی خروجی شبکه با نتایج آزمایشگاه برای هر کدام از نمونه‌ها ارائه شده است. در این مطالعه جهت پیش‌بینی خواص سیالات مخزن، با تعداد محدودی داده‌های آزمایشگاهی مواجه بودیم. همان‌طور که در شکل ۷- مشاهده می‌شود مقایسه‌ی MSE یا RMSE مدل‌های شبکه‌ی عصبی با مدل‌های حاصل از ترکیب



شکل ۷ | میانگین مربعات خطای مطلق نتایج حاصل از ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک



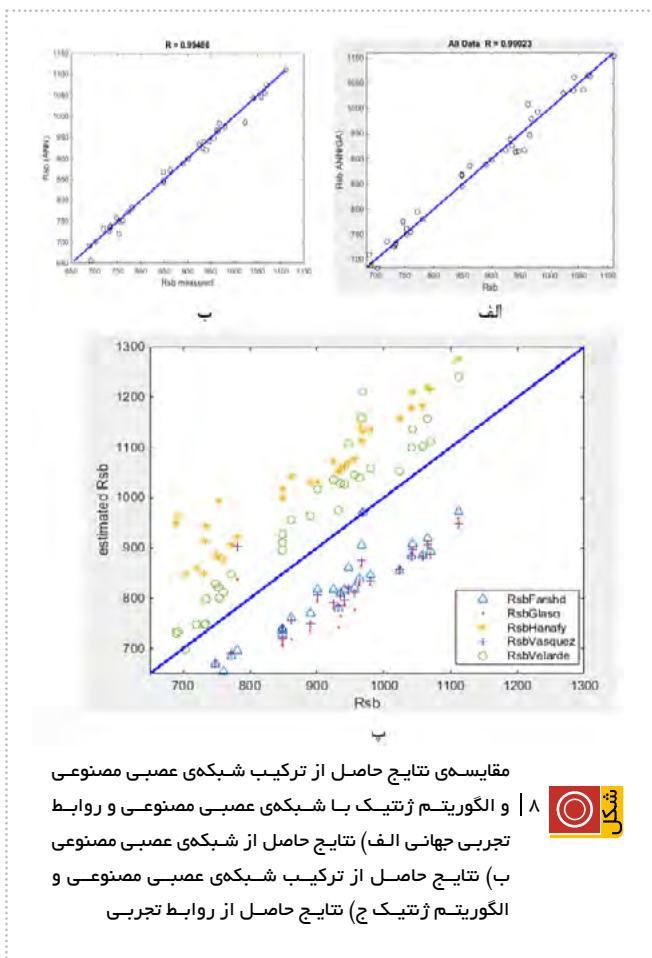
شکل ۵ | نمودارهای مربوط به تابع هزینه در مرحله‌ی آموزش



### نتیجه گیری

نتایج حاصل در تمامی مراحل نمایانگر برتری کامل مدل شبکه‌ی عصبی مصنوعی ارائه شده در تخمین خواص سیالات مخزن و ارائه‌ی بیشترین مقدار ضریب همبستگی نسبت به روابط تجربی معمول است. اما از آنجا که الگوریتم ژنتیک از جمله الگوریتم‌های جستجو و بهینه‌سازی هوشمند است در مدل پیش‌بینی شده توسط شبکه‌ی عصبی مصنوعی سبب همگرایی بسیار سریع‌تر به هدف (داده‌های آزمایشگاه) شد؛ به طوری که در حالتی که شبکه‌ی عصبی مصنوعی متداول وجود داشت، از انجام اجزای متعدد جلوگیری نمود. در این مطالعه در الگوریتم ژنتیک برای انتخاب والدین از روش رقابتی استفاده شد و نتایج زیر حاصل شد:

- زمانی که جمعیت انتخابی حدود ۱۰ برابر متغیرهای مجهول باشد جواب بهتری حاصل می‌گردد.
- زمانی که تعداد نسل‌های تولید شده ۲۰ درصد جمعیت انتخابی باشد الگوریتم با دقت خوبی عمل می‌کند.
- جهت تخمین نسبت گاز محلول به نفت در نقطه‌ی حباب، استفاده از توابع تقاطع<sup>۹</sup> یک نقطه‌ای در الگوریتم ژنتیک عملکرد بهتری خواهد داشت. ■



مقایسه‌ی نتایج حاصل از ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک با شبکه‌ی عصبی مصنوعی و روابط تجربی جهانی (الف) نتایج حاصل از شبکه‌ی عصبی مصنوعی (ب) نتایج حاصل از ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک (ج) نتایج حاصل از روابط تجربی



### پانویس‌ها

- |                                |  |                              |
|--------------------------------|--|------------------------------|
| 1. tabalireza@yahoo.com        | 4. Solution GasOil Ratio at bubble point | 7. Mean square error         |
| 2. mosayyeb.kamari@gmail.com   | 5. Equation Of State                     | 8. Root of mean square error |
| 3. Pressure-Volume-Temperature | 6. Artificial neural Network             | 9. Crossover                 |

### منابع

- [۱] M. A. Al-Marhoun, E. A. Osman, (2002), SPE, Using Artificial Neural Network to Develop New Correlation for Saudi Crude Oils, SPE, King Fahd University of petroleum & Mineral, Dhahran, Saudi Arabia.
- [2] Gharbi, Elsharkawy, (1999), Neural Network model for estimating the PVT properties of Middle East crude oil, 56850-PA SPE Journal Paper .
- [۳] احمد طاروق، قنبریان منیر، قاسمی صادق، ۱۳۸۹، مهندسی مخازن هیدروکربوری (کتاب جامع)، شرکت ملی نفت ایران
- [۴] عزیزی مهدی، ۱۳۹۱، شبکه‌ی عصبی، پایان‌نامه‌ی کارشناسی دانشگاه آزاد اسلامی
- [۵] علیرضا مهدی، ۱۳۸۶، مقدمه‌ای بر الگوریتم ژنتیک و کاربردهای آن، تهران: انتشارات ناقوس
- [۶] مسعود یانسولماز، استکی افسانه، ۱۳۸۶، طراحی جدول زمان‌بندی خودکار با استفاده از الگوریتم‌های ژنتیک، پایان‌نامه‌ی کارشناسی دانشگاه اصفهان
- [۷] وطنی علی، مخاطب سعید، ۱۳۸۴، اصول طراحی هیدرولیکی خطوط لوله‌های انتقال جریان‌های دوفازی، تهران، انتشارات جهاد دانشگاهی