

# طراحی شبکه عصبی برای بهینه‌سازی اندازه سطح مقطع شیرهای درون چاهی با اندازه‌ی ثابت در چاه هوشمند با الگوریتم پرندگان

مرتضی حسن آبادی\*<sup>+</sup>

تهران، دانشگاه صنعتی امیرکبیر، دانشکده ریاضی و علوم کامپیوتر

سید مهدیا مطهری، مهدی ندری پری

تهران، پژوهشگاه صنعت نفت، پژوهشکده مطالعات مخازن و توسعه میادین

**چکیده:** بهینه‌سازی تولید نفت از میدان‌های هیدروکربوری یکی از دغدغه‌های اصلی مدیریت مخازن نفت است. در این راستا از فناوری چاه هوشمند که در دهه‌ی اخیر توسعه یافته، استفاده می‌شود. از جمله چالش‌های مهم این فناوری، تنظیم بهینه شیرهای کنترلی ثابت در طول عمر چاه هوشمند است. به دست آوردن وضعیت بهینه این شیرها با استفاده از نرم‌افزار شبیه‌ساز مخزن، نیازمند تعداد بسیار زیاد اجرای شبیه‌سازی است که با توجه به محدودیت‌های زمان و هزینه غیرممکن است. از این رو باید به دنبال روشی برای جایگزینی نرم‌افزار شبیه‌ساز مخزن و ارزیابی الگوریتم بهینه‌سازی مناسب بود. در این مقاله با جایگزینی روش شبکه عصبی مصنوعی با نرم‌افزار شبیه‌ساز مخزن، مقادیر تولید نفت و آب محاسبه شده و بهینه‌سازی تنظیمات شیرهای کنترلی ثابت برای بیشینه کردن تولید نفت و کمینه کردن تولید آب با الگوریتم پرندگان (PSO) انجام می‌شود، که سرانجام میزان تولید نفت به اندازه ۵۵٪ نسبت به روش متداول افزایش می‌یابد به بیان دیگر، میزان نفت تجمعی از ۳.۵ میلیون بشکه به ۶ میلیون بشکه و ضریب بازیافت آن از ۶٪ به ۹.۵٪ در طول عمر چاه افزایش می‌یابد.

**واژه‌های کلیدی:** الگوریتم پرندگان (PSO)، بهینه‌سازی، چاه هوشمند، روش شبکه عصبی مصنوعی، شیرهای کنترلی درون چاهی.

**KEY WORDS:** Particle Swarm Optimization (PSO), Optimization, Smart well, Artificial Neural Network (ANN), Inflow Control Valve (ICV).

## مقدمه

طبیعت بسیار ناهمگن مخازن نفتی زیرزمینی منجر به رفتاری متفاوت در تولید نفت در دوره‌های زمانی گوناگون می‌شود. برای کنترل بهینه تولید از فناوری چاه هوشمند استفاده می‌شود. چاه هوشمند مجهز به حسگرهای درون چاهی برای اندازه‌گیری دما، فشار و نرخ تولید است. همچنین شیرهای کنترلی درون چاهی ثابت<sup>(۱)</sup> (ICD)، میزان تولید نفت در طول عمر چاه هوشمند را

\*E-mail: hassanabadimorteza@gmail.com , M\_hassanabadi@aut.ac.ir

\*عده دار مکاتبات

(۱) Inflow Control Device (ICD)

## بخش نظری

## بیان مسأله و مدل ریاضی

تولید نفت از مخازن نفتی با عدم قطعیت همراه است که به‌طور عمده ناشی از نبود شناخت کامل از وضعیت مخزن به دلیل ناهمگونی‌های آن می‌باشد. از این‌رو برنامه‌ریزی تولید همواره با مشکلات بسیاری روبرو بوده است. یکی از روش‌های مؤثر برای برخورد با این عدم قطعیت و مدیریت آن، استفاده از فناوری چاه هوشمند است. شیرهای کنترلی درون چاهی یکی از عملگرهای این فناوری است که بهینه‌سازی تولید نفت نیازمند به‌دست آوردن تنظیمات بهینه برای این شیرها است. به‌کارگیری الگوریتم‌های بهینه‌سازی برای تعیین تنظیمات‌های این شیرها نیازمند حل معادله‌های دیفرانسیل با مشتقات جزئی<sup>(۸)</sup> است که ساختاری غیرخطی دارند. حل این معادله‌ها در شرایط مخزن حتی با استفاده از نرم افزارهای شبیه‌ساز مخزن، زمان‌بر و پرهزینه است. از این‌رو باید به دنبال راه‌حلی بود که با کاهش زمان، خطای کم و رعایت قیدهای حاکم بر مسأله، از جمله میزان تولید نفت صیانتی و محدودیت‌های سطح الارضی فرآورش نفت از آب با توجه به پارامتر برش آب، بتوان بهترین تنظیمات تولید را برای ICDها در طول عمر چاه هوشمند به‌دست آورد.

در ادامه مقاله، یک مدل ریاضی برای تنظیمات بهین ICDها در طول عمر چاه با هدف رسیدن به خروجی بیشینه در تولید نفت و کمینه در تولید آب ارایه شده است. در بخش سوم روش پیاده‌سازی و حل مدل ریاضی بر مبنای روش شبکه عصبی مصنوعی<sup>(۱۰)</sup> در سه قسمت روش‌های طرح آزمایش و طراحی شبکه عصبی و الگوریتم بهینه‌ساز پرندگان بیان شده است، در بخش چهارم مدل ریاضی ارایه شده با روش شبکه عصبی بر روی یک مخزن مشخص پیاده‌سازی شده و با الگوریتم پرندگان (PSO)<sup>(۱۱)</sup> بهینه شده است. در بخش پایانی مقایسه نتیجه‌های روش کنترل هوشمند با روش متداول<sup>(۱۲)</sup>، ارایه شده است.

برای تعیین و تنظیم بهین عملکرد شیرهای کنترلی در چاه هوشمند از یک مدل ریاضی استفاده می‌شود. در این مدل سعی می‌شود با رعایت ضوابط مربوطه، سطح دلخواه بودن خروجی هر شیر کنترلی

با توجه به ویژگی‌های مخزنی تنظیم می‌کنند. شیرهای کنترلی از نظر توانمندی در کنترل سیال، دارای بی‌نهایت<sup>(۱)</sup> (بی‌بسته) حالت می‌باشد. به‌طوری که تنظیمات بهینه به‌دست آمده به‌عنوان تنظیمات شیرهای کنترلی در طول عمر چاه هوشمند به صورت ثابت قرار داده می‌شود. در این مقاله چگونگی تنظیم بهینه شیرهای کنترلی در یک چاه افقی با روش شبکه عصبی مصنوعی<sup>(۲)</sup> (ANN) و الگوریتم بهینه‌ساز پرندگان<sup>(۳)</sup> (PSO) مورد مطالعه و بررسی قرار می‌گیرد. دلیل اصلی برای به‌کارگیری این روش، سرعت بالا (کاهش زمان) در تخمین تابع تقریب (متا مدل) با کمترین خطا نسبت به تابع هدف است. برتری‌های استفاده از ICDها در چاه‌های نفتی در مقایسه با روش متداول<sup>(۴)</sup> (غیر کنترلی) بسیار زیاد است. در این زمینه می‌توان به افزایش تولید نفت، کاهش تولید آب، افزایش ضریب بازیافت<sup>(۵)</sup> و کاهش هزینه‌های تولید اشاره کرد [۴-۱].

اولین عملیات کنترل هوشمند در آگوست ۱۹۹۷ میلادی در دریای شمال انجام شد. تا کنون در بیش از ۳۰۰ مورد از مخازن زیر زمینی نفتی سامانه کنترل هوشمند نصب شده است. این عملیات زمینه‌ی اصلی بهینه‌سازی در چاه‌های هوشمند را با شیرهای کنترلی هوشمند<sup>(۶)</sup> فراهم کرده است [۱]. در سال ۲۰۰۲ میلادی بهینه‌سازی شیرهای کنترلی برای اولین بار با روش گرادینان مزدوج<sup>(۷)</sup> مورد بررسی قرار گرفت [۲]. این روش برای بهینه‌سازی تنظیمات شیرهای کنترلی تا سال ۲۰۱۱ میلادی در بیشتر پژوهش‌ها مورد توجه بوده است [۵-۱۱]. در سال ۲۰۰۶ میلادی از روش شبکه عصبی برای تعیین بهترین مکان چاه‌های هوشمند استفاده شده است [۱۲]. در سال ۲۰۰۸ میلادی الگوریتمی برای بهینه‌سازی تولید نفت مخازن با به‌کارگیری چاه هوشمند ارایه شد. برای حل مدل ریاضی آن، با هدف بهینه‌سازی تنظیمات شیرهای کنترلی، از روش چند مرحله‌ای شبه نیوتنی<sup>(۸)</sup> استفاده شده است [۱۳]. در سال ۲۰۰۹ میلادی از الگوریتم ژنتیک برای بهینه‌سازی تنظیمات شیرهای کنترلی در چاه‌های هوشمند استفاده شده است [۱۴].

(۱) Infinite

(۲) Artificial Neural Network (ANN)

(۳) Particle Swarm Optimization (PSO)

(۴) Conventional

(۵) Recovery factor

(۶) Intelligent Control Valves (ICVs)

(۷) Conjugate gradient

(۸) Multi-Step Quasi-Newton (SSMQN) method

(۹) Partial Differential Equation (PDE)

(۱۰) Artificial Neural Network (NN)

(۱۱) Particles Swarm Optimization (PSO)

(۱۲) Conventional

$$\nabla \cdot \left[ \left( \frac{\rho_w k k_{rw}}{\mu_w} \right) (\nabla p_w - \rho_w g \nabla e_z) \right] = \phi \frac{\partial (\rho_w S_w)}{\partial t} \quad (9)$$

$$S_w + S_o = 1 \quad (10)$$

$$q_o = f(s_o) \quad (11)$$

$$q_w = f(s_w) \quad (12)$$

جریان سیال آب و نفت در محیط متخلخل مخزن به شکل معادله‌های دیفرانسیل با مشتقات جزئی در معادلات (۸) و (۹) داده شده است. از حل معادله‌های (۸) و (۹) در هر نوع مخزنی و در هر فاصله زمانی چگونگی میزان اشباع سیال نفت و آب به دست می‌آید. نرخ جریان سیال نفت و آب تابعی از میزان اشباع نفت و آب در محیط متخلخل مخزن است که در معادله‌های (۱۰) تا (۱۲) داده شده است. این معادله‌ها در شرایطی حاکم است که فرض شود ICDها در چاه نصب نشده باشند. برای ارزیابی اثر میزان باز و بسته بودن شیرها، به بیان دیگر به دست آوردن بهترین تنظیمات برای شیرها در طول عمر چاه هوشمند، از معادله‌های دیگری باید استفاده کرد. با تغییر تنظیمات شیرهای کنترلی در عمل سطح مقطع عبور سیال از مخزن به درون چاه تغییر می‌کند. این تغییر سطح مقطع منجر به ایجاد افت فشار اضافی بر سیال می‌شود که در معادله (۱۳) داده شده است. بر اساس این معادله، افت فشار کل ناشی از عبور سیال از شیرهای کنترلی برابر با افت فشار ناشی از اصطکاک سیال با لوله جداری به اضافه افت فشار ناشی از عبور سیال از سطح مقطع شیرهای کنترلی است. میزان افت فشار سیال، ناشی از عبور از سطح مقطع شیر کنترلی از معادله (۱۴) به دست می‌آید [۱۵].

$$\Delta P_t = \Delta P_c + \Delta P_f \quad (13)$$

$$\Delta P_c = C_u \rho \frac{V_c^2}{2C_v} \quad (14)$$

معادله (۱۴) نشان می‌دهد که تغییر افت فشار سیال، ناشی از عبور از سطح مقطع شیر کنترلی ( $\Delta P_c$ ) فقط به سرعت سیال ( $V_c$ ) بستگی دارد.

$$V_c = \frac{q_t}{A_c} \quad (15)$$

معادله (۱۵) ارتباط نرخ جریان سیال با سطح مقطع شیرهای کنترلی را نشان می‌دهد. سطح مقطع شیرهای کنترلی ( $A_c$ ) با سرعت سیال ( $V_c$ ) رابطه عکس و با جریان سیال رابطه مستقیم دارد. سطح مقطع  $A_c$  را می‌توان با معادله (۱۶) محاسبه کرد.

در بازه‌ی طول عمر چاه چنان تعیین شود که در مجموع تولید بیشینه نفت به دست آید. در این مدل ریاضی فرض شده است که چاه مورد مطالعه دارای  $N$  عدد ICD است. هدف، بیشینه کردن تولید نفت تجمعی و کمینه کردن تولید آب تجمعی با تنظیم بهینه شیرهای کنترلی است. منظور از تولید تجمعی، مجموع تولید از زمان شروع تا پایان افق زمانی است.

$$Z = \text{MAX} \quad (N_p - W_p) \quad (1)$$

$$N_p = \sum_{i=1}^N q_{t_i} (1 - w_{c_i}) \quad (2)$$

$$W_p = \sum_{i=1}^N q_{t_i} w_{c_i} \quad (3)$$

معادله (۱) تابع هدف را در قالب تفاضل تولید نفت و آب تجمعی نشان می‌دهد. میزان نفت و آب تجمعی از تمامی شیرهای کنترلی به ترتیب از معادله‌های (۲) و (۳) به دست می‌آید. شمارنده  $i$  نشان دهنده تعداد ICDها است. این معادله‌ها نشان می‌دهند که میزان تولید نفت و آب تجمعی تابعی از نرخ تولید سیال ( $q_{t_i}$  با واحد بشکه در روز) و برش آب ( $w_c$  با واحد درصد) است.

$$q_{t_i} = q_{o_i} + q_{w_i} \quad (4)$$

$$w_c = \sum_{i=1}^N q_{w_i} / \sum_{i=1}^N q_{t_i} \quad (5)$$

معادله (۴) ارتباط نرخ جریان سیال نفت ( $q_{o_i}$ ) و نرخ جریان سیال آب ( $q_{w_i}$ ) با نرخ تولید کل سیال ( $q_{t_i}$ ) را نشان می‌دهد. معادله (۵) درصد برش آب ( $W_c$ ) را به صورت نسبت نرخ جریان سیال آب ( $q_{w_i}$ ) به نرخ جریان تولید کل سیال ( $q_{t_i}$ ) را بیان می‌کند.

$$\sum_{i=1}^N q_{o_i} \leq q_o \quad (6)$$

$$W_c \leq W_{c_0} \quad (7)$$

تابع هدف باید با توجه به محدودیت‌های (۶) و (۷) بیشینه شود. معادله (۶) تضمین می‌کند که مجموع نفت تولیدی از شیرهای کنترلی کمتر یا مساوی مقدار ثابت  $q_o$  (بشکه در روز) باشد. معادله (۷) درصد برش آب در سیال تولید شده از چاه مجهز به شیرهای کنترلی را به مقدار ثابت  $W_{c_0}$  (درصد) محدود می‌کند.

$$\nabla \cdot \left[ \left( \frac{\rho_o k k_{ro}}{\mu_o} \right) (\nabla p_o - \rho_o g \nabla e_z) \right] = \phi \frac{\partial (\rho_o S_o)}{\partial t} \quad (8)$$

قرار بگیرد. برای رفع این عیب‌ها باید شبکه‌هایی با تعداد نورون‌ها و لایه‌های گوناگون را بارها آموزش داد [۱۶].

ساختار شبکه عصبی، متغیرهایی مانند تعداد لایه در یک شبکه، تابع تبدیل هر لایه، تعداد نورون‌ها در هر لایه و اتصالات بین نورون‌ها را تعریف می‌کند. اجزای تشکیل دهنده یک شبکه عصبی متشکل شده از نورون مصنوعی و لایه‌ها است. نورون‌های مصنوعی مهمترین عنصر یک شبکه عصبی مصنوعی است و به عنوان پرسپترون یا عنصر پردازشگر<sup>(۲)</sup> نیز شناخته می‌شود. نورون‌ها در قالب لایه‌ها<sup>(۳)</sup> سازماندهی می‌شوند. یک شبکه عصبی مصنوعی از سه نوع لایه ورودی، پنهان و خروجی تشکیل شده است که هر لایه مسئول یک کار ویژه است. مدل ریاضی نورون‌ها (سلول عصبی) از دو بخش اساسی تابع ترکیب<sup>(۴)</sup> و تابع تحریک<sup>(۵)</sup> تشکیل شده است [۱۷].

#### الگوریتم یادگیری

قانون یا الگوریتم یادگیری<sup>(۶)</sup> به معنی روش اصلاح مقدارهای وزن‌ها به شبکه است. هدف قانون یادگیری، آموزش شبکه برای انجام یک کار ویژه است. انواع گوناگونی از الگوریتم‌های یادگیری را می‌توان به الگوریتم یادگیری نظارتی (با سرپرست)، الگوریتم یادگیری تقویت یافته یا تشدید و الگوریتم یادگیری غیر نظارتی (بدون سرپرست) تقسیم کرد [۱۸].

#### انتخاب نمونه‌های آموزشی

مجموعه آموزشی در برگیرنده داده‌های ورودی و خروجی مطلوب متناظر با آنهاست. انتخاب یک مجموعه آموزشی مناسب، از اهمیت زیادی برخوردار است و باید دامنه گسترده‌ای از این داده‌ها را در برگیرد. زیرا کیفیت جواب نهایی شبکه، به مثال‌های آموزشی به کار رفته در مرحله آموزش وابسته است. مهمترین شرط لازم برای مجموعه آموزشی این است که همه دامنه مقدارهای ورودی‌ها را پوشش دهد. به بیان دیگر، مجموعه آموزشی باید از همه دامنه مقدارهای متغیرهای پیوسته و گسسته انتخاب شود [۱۹].

اعتبارسنجی تابع تقریب (متا مدل) طراحی شده از روش شبکه عصبی مصنوعی تحلیل و تجزیه فاکتورها در تابع تقریب به دست آمده از روش شبکه عصبی، با کمک نمودارهای برازش در داده‌های آموزش<sup>(۷)</sup>،

$$0 \leq A_C = \frac{A_{choke}}{A_{Total}} \leq 1 \quad (16)$$

در معادله (۱۶)  $A_{total}$  سطح مقطع شیرهای کنترلی در حالت کاملاً باز است و  $A_{choke}$  سطح مقطع شیرهای کنترلی است که به عنوان متغیر باید تنظیم شوند [۱۵، ۱۳]. فرض کنید  $T$  مدت زمان تولید باشد و از طرفی چاه مورد مطالعه دارای  $N$  عدد ICD است که برای تنظیم بهینه‌ی تولید در طول عمر چاه بی‌نهایت حالت متفاوت برای مدل ریاضی است. بنابراین در این مطالعه سعی شده است با بررسی کمترین ترکیب‌های ممکن با روش‌های طرح آزمایش، نمونه‌های<sup>(۱)</sup> مناسبی برای آموزش شبکه عصبی انتخاب شود. با طراحی این شبکه عصبی، بهینه‌سازی تنظیمات شیرهای کنترلی ثابت با هدف بیشینه کردن تولید نفت و کمینه کردن تولید آب ناخواسته با الگوریتم پرندگان (PSO) انجام می‌شود.

#### روش حل مسأله

در این بخش، روش حل مسأله تنظیم بهینه اندازه شیرهای کنترلی ثابت در چاه هوشمند متشکل از طراحی شبکه‌های عصبی به عنوان جایگزینی از شبیه‌ساز و الگوریتم بهینه‌ساز پرندگان (PSO) و روش طرح آزمایش سطح رویه پاسخ از نوع طرح مرکب مرکزی برای انتخاب نمونه‌های آزمایشی آمده است. شمای گرافیکی روش حل مسأله در شکل ۱ نشان داده شده است.

#### طراحی ساختار شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی نوعی شبیه‌سازی ساختار مغز انسان در قالب یک سامانه مصنوعی هستند که از تعداد به نسبت زیادی از عضوهای پردازشگر (نورون‌های مصنوعی) تشکیل شده‌اند و به طور خاص و منظمی (یعنی بین هر دو لایه یک گراف کامل وجود دارد) طراحی شده‌اند. روش شبکه‌های عصبی نیز همانند همه روش‌ها دارای کاستی‌ها و عیب‌هایی می‌باشند. از جمله مهمترین آنها نیاز به مجموعه‌ای از داده‌ها برای آموزش و نیز آزمودن شبکه، ارایه ندادن توضیح و چگونگی رسیدن به پاسخ، امکان ارایه یک جواب زودرس و نامناسب، یعنی؛ تابع آموزش تخمین زده شده در کمترین محلی

(۱) Samples

(۲) Processing element

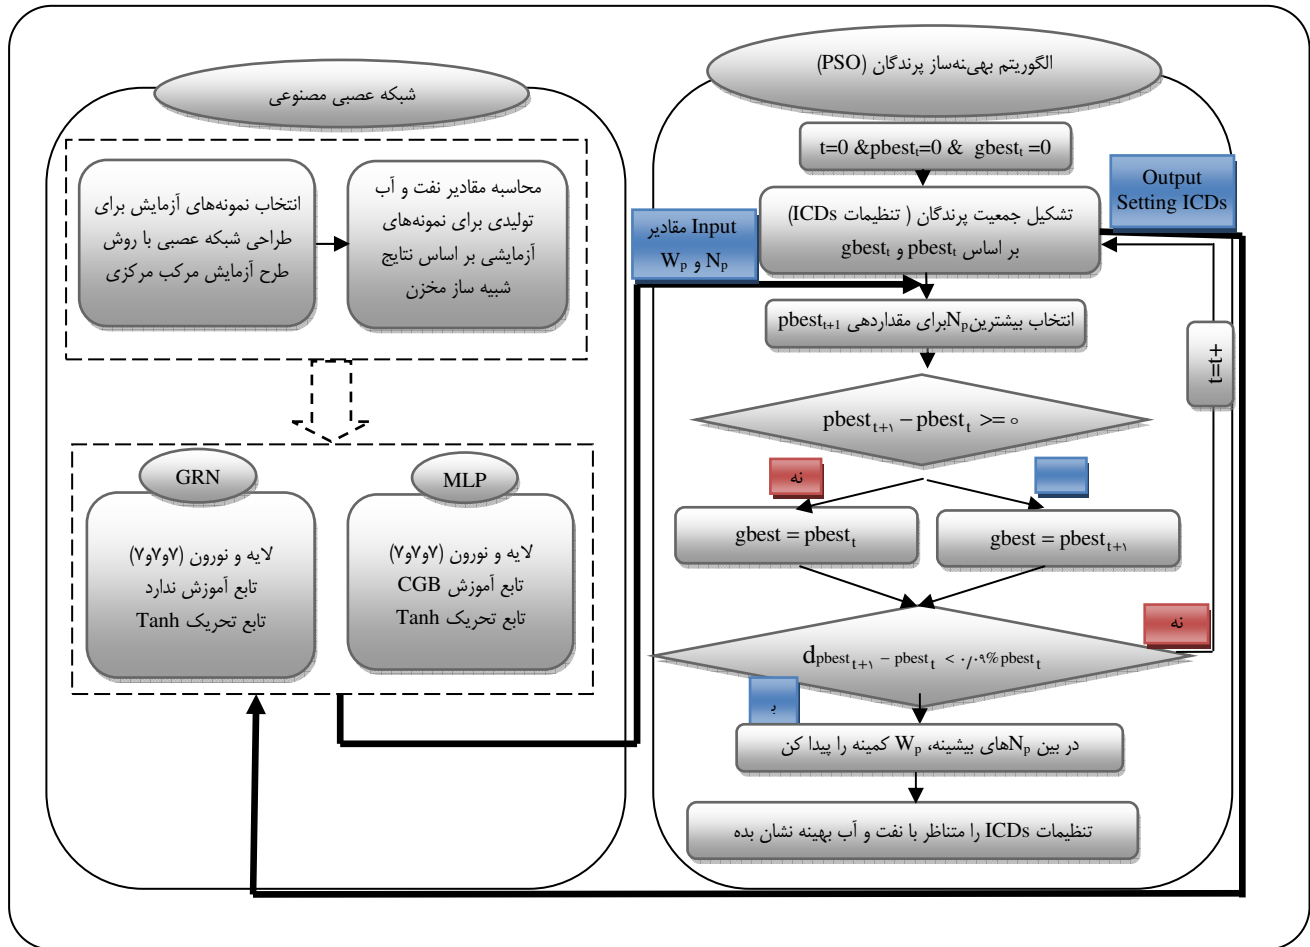
(۳) Layers

(۴) Integration function

(۵) Activation function

(۶) Learning algorithm

(۷) Training



شکل ۱- شمای گرافیکی روش حل مسئله.

$$MSE = \frac{\sum_{i=1}^n (O_i - T_i)^2}{n} \quad (17)$$

در معادله (۱۷)  $O_i$  خروجی‌های دلخواه (هدف) و  $T_i$  خروجی‌های شبکه عصبی برای داده‌های آموزش،  $i$  و  $n$  تعداد داده‌های مجموعه آموزش می‌باشند. در کل بهترین نتیجه از یک شبکه عصبی باید دارای کمترین میانگین مربعات خطا باشد.

**روش طرح آزمایش سطح روبه پاسخ برای انتخاب نمونه‌های آموزشی در طراحی شبکه عصبی مصنوعی**

طرح آزمایش<sup>(۵)</sup> به سلسله آزمون‌هایی گفته می‌شود که بتوانند عامل‌های مؤثر بر یک فرآیند و میزان تأثیر آنها را مشخص کنند.

اعتبارسنجی<sup>(۱)</sup> و آزمون<sup>(۳)</sup> انجام می‌شود. به طور معمول تعداد داده‌های آموزش ۸۰٪ و داده‌های آزمون و اعتبار به ترتیب ۱۵٪ و ۵٪ از مجموع داده‌ها است. برای بررسی دقت شبکه عصبی طراحی شده، از نمودار خط برازش پاسخ‌ها استفاده می‌شود. برآورد نزدیک به یک ضریب همبستگی<sup>(۳)</sup> ( $R=1$ ) از خط برازش، نشان دهنده دقت بالای تابع تقریب زده شده توسط شبکه عصبی آموزش دیده است (یعنی؛ باید داده‌های پاسخ روی خط برازشی و یا در امتداد آن باشند).

روش دیگر، محاسبه خطای داده‌ها برای تخمین تابع تقریب مناسب با دقت بالا در شبکه عصبی، روش میانگین مربعات خطا<sup>(۴)</sup> است که به صورت معادله (۱۷) به‌دست می‌آید.

(۱) Validation

(۲) Test

(۳) Coefficient of correlation

(۴) Mean Square Error (MSE)

(۵) Design Of Experimental (DOE)

هر شیر کنترلی در این بازه پیوسته وجود دارد، که با روش CCD به پنج وضعیت به صورت جدول ۱ تبدیل شده است. حال فضای پیوسته هر شیر به یک فضای گسسته که بهترین حالات ممکن برای به دست آوردن نمونه‌های آموزشی و همچنین در برگزیده فضای پیوسته برای ICD هاست، تبدیل شده است. با توجه به فرض مسأله، با داشتن N عدد ICD و با روش CCD بی‌نهایت حالت به  $5^N$  وضعیت متفاوت برای انتخاب نمونه‌های آموزشی در شبکه عصبی تبدیل شده است.

#### ارایه الگوریتم بهینه‌ساز پرندگان (PSO)

الگوریتم PSO به تقلید از پرواز دسته جمعی پرندگان شکل گرفته است. این الگوریتم یک روش هوش گروهی برای حل مسأله‌های بهینه‌سازی سراسری است. در PSO هر نامزد راه حل، موقعیت خود را در فضای جستجو با توجه به تجربیات خود و تجربیات کل گروه راه حل‌های نامزد، تغییر می‌دهد. PSO شامل اجزایی است که به طور مرتب دانش خود را از فضای جستجو اصلاح می‌کنند. اجزاء در PSO با بردار موقعیت و سرعتشان متمایز می‌شوند و جستجو با جذب اجزا به سوی مکان‌هایی با راه حل‌های بهین، انجام شود. در نسخه‌ی اصلی PSO، هر جزء با دو اجبار حرکت می‌کند، یکی جذب با بهترین حالتی که جزء تاکنون داشته و دیگری جذب با بهترین موقعیتی که توسط گروه کسب شده است.

در PSO هر جواب یک پرده در فضای جستجو است که آن را (فرد یا جزء<sup>(۸)</sup>) می‌نامند. به عبارت دیگر، یک جزء نقطه‌ای در فضای جستجو چند بعدی است که در آن فضا به جستجوی موقعیت بهینه پرداخته می‌شود. در ابتدا PSO توسط یک گروه از اجزا که به طور تصادفی تولید شده‌اند مقداردهی می‌شود و جستجو برای پیدا کردن پاسخ بهینه آغاز می‌شود. در هر تکرار از الگوریتم، هر جزء موقعیت بعدی خود در فضای جستجو را با توجه به دو مقدار تغییر می‌دهد؛ یکی بهترین موقعیتی است که خود تاکنون داشته است (pbest) و دیگری بهترین موقعیتی که تاکنون توسط کل اجزای گروه به وجود آمده است (gbest). هر جزء از معادله‌های (۱۸) و (۱۹) برای تعیین موقعیت بعدی خود استفاده می‌کند:

کاربردهای این روش را می‌توان در تعیین پارامترهای مؤثر بر فرایند، تعیین شرایط بهین، اصلاح فرایند با توجه به نتیجه‌های به دست آمده از شرایط امکان پذیر، تعیین شرایط مقاوم و کاهش تغییرپذیری پاسخ فرایند، بیان کرد [۲۰، ۲۱].

انواع طرح آزمایش را می‌توان به دو روش فاکتوریل کامل<sup>(۱)</sup> و فاکتوریل جزئی<sup>(۲)</sup> (کسری) تقسیم کرد. روش سطح رویه پاسخ<sup>(۳)</sup> (RSM)، جزء روش‌های فاکتوریل جزئی است که در این مطالعه مورد توجه و استفاده قرار گرفته است [۲۲]. روش RSM مجموعه‌ای از روش‌های ریاضی و آماری برای مدل‌سازی و تجزیه مسأله است. از این روش زمانی استفاده می‌شود که پاسخ مسأله (هدف) تحت تأثیر چندین عامل مستقل (ورودی) قرار دارد و هدف، بهینه‌سازی این پاسخ است. در این روش چگونگی روابط بین یک یا چند پاسخ با استفاده از تأثیر عوامل مستقل اندازه گیری می‌شود.

سه طرح مرکب مرکزی<sup>(۴)</sup>، مکعب بنکن<sup>(۵)</sup> و دهلرت<sup>(۶)</sup> در برآزش مدل اولیه در روش RSM به کار می‌رود. هر سه روش بر پایه ترکیبی از طرح‌های فاکتوریل کامل و فاکتوریل جزئی ساخته شده‌اند. در این بین، روش طرح مرکب مرکزی بهترین روش برای ارایه مدل ریاضی در RSM است [۲۳].

طرح مرکب مرکزی (CCD) دارای مشخصه‌های زیر می‌باشد:

- ۱- هر متغیر در چهار سطح تغییر می‌کند.
  - ۲- به طور معمول کمتر از طرح‌های مکعب بنکن است.
  - ۳- بر پایه فاکتوریل دوسطحی و فاکتوریل کسری بنا شده است.
  - ۴- می‌توان آن در مرحله‌های فاکتوریل دوسطحی + نقاط مرکزی + نقاط محوری اجرا کرد.
  - ۵- دوران پذیر است.
  - ۶-  $2k$  - نقطه فاکتوریل +  $n_c$  نقطه مرکزی +  $2k$  نقطه محوری و ستاره‌ای.
- نقطه‌های محوری، نقطه‌هایی بر روی محور هستند که از مرکز به فاصله  $\alpha$  است

با کمک روش CCD می‌توان نمونه‌های آموزشی بهتر و جامع‌تری برای آموزش شبکه عصبی انتخاب کرد.

اندازه سطح مقطع<sup>(۷)</sup> شیرهای کنترلی ثابت بین صفر تا ۰/۰۲۲ فوت مربع است یعنی؛ تعداد بی‌نهایت وضعیت برای تنظیم

(۱) General factorial design

(۲) fractional factorials design

(۳) Response Surface Method (RSM)

(۴) Central Composite Design (CCD)

(۵) Box-Behnken Design (BBD)

(۶) Doehlert design

(۷) Cross section

(۸) Particle

و حالت تعادلی بین توانایی الگوریتم در جستجو به صورت محلی و سراسری ایجاد نماید [۲۴].

شیوه‌ی عملکرد PSO همانند الگوریتم ژنتیک (GA) است که در هر دو الگوریتم ابتکاری، جمعیت اولیه را به‌طور تصادفی مقداردهی می‌کنند، از یک تابع برازش (در این مطالعه از روش شبکه عصبی استفاده شده است) برای محاسبه مقدارهای تابع هدف استفاده می‌کنند، روش PSO توانایی ایجاد تعادل بین جستجوهای محلی و سراسری را دارد. برتری PSO نسبت به GA انتخاب پارامترهای کم، پیاده‌سازی آسان و کم هزینه است [۲۵].

ویژگی‌های الگوریتم PSO را می‌توان بی تفاوت بودن نسبت به مقایسه کردن در طراحی متغیرها، اجرا و پیاده‌سازی آسان، انجام کارهای موازی برای پروژه‌های هم‌زمان، الگوریتمی با پارامترهای خیلی کم، جستجوی سراسری<sup>(۱)</sup> بسیار کارآمد است [۲۶].

### پیاده‌سازی روش حل مسأله - بررسی موردی

در این قسمت روش حل مسأله بر روی مخزنی با ویژگی‌های زیر به کار گرفته شده است. این روش بر روی یک چاه افقی در مخزن نفتی پیاده‌سازی و تحلیل و بررسی شده است. نتیجه‌ی استفاده از این روش با کمک الگوریتم بهینه‌ساز PSO، منجر به ارایه بهترین اندازه برای شیرهای کنترلی ثابت با هدف تولید نفت بیشینه و آب کمینه از مخزن شده است.

### مشخصات مخزن

میدان مورد مطالعه در این مقاله یک مخزن طاق‌دیس می‌تقارن ماسه سنگی ناهمگون با کانال پرتخلخل و تراوایی بالا است. این مخزن دارای ابعاد ۴×۴ کیلومتر مربع و ضخامت ۵۰ متر است. این مخزن کلاهیگازی ندارد و دارای آبدهی قوی است. ویژگی‌های مخزن مورد مطالعه در جدول‌های ۲ و ۳ ارایه شده است.

شکل ۲ نمای سه بعدی از چاه هوشمند مجهز به شیرهای کنترلی را به صورت گرافیکی نشان می‌دهد. مهمترین مشخصه مخزن میزان تراوایی و تخلخل آن است، که میزان تراوایی در سه بعد فضای مخزنی بر روی محور X در شکل (۳-ا)، بر روی محور Y در شکل (۳-ب) و بر روی محور Z در شکل (۳-ج) و میزان تخلخل در شکل ۴ داده شده است. همچنین ویژگی‌های عددی این دو مشخصه در جدول ۳ توصیف شده است.

### جدول ۱- وضعیت پنجگانه سطح مقطع در ICD.

حالت سطح مقطع (s) ICV	سطح مقطع Ft
۱	به طور کامل بسته
۲	$0.3 \times 0.22$
۳	$0.5 \times 0.22$
۴	$0.8 \times 0.22$
۵	کاملاً باز $1 \times 0.22$

### جدول ۲- خصوصیات مدل مخزن مورد مطالعه.

کانال ماسه‌ی	نوع محیط متخلخل مخزن
۸۳	تعداد گریدها در جهت X (Nx)
۷۳	تعداد گریدها در جهت Y (Ny)
۲۰	تعداد گریدها در جهت Z (Nz)
۱۲۱۱۸۰	تعداد کل گریدهای مخزن
۱۰۰	اندازه گرید در جهت X (ft)
۱۰۰	اندازه گرید در جهت Y (ft)
۸	اندازه گرید در جهت Z (ft)

### جدول ۳- مشخصات مخزن مورد مطالعه.

کانال ماسه‌ی	نوع محیط متخلخل مخزن
۸۳	تعداد گریدها در جهت X (Nx)
۷۳	تعداد گریدها در جهت Y (Ny)
۲۰	تعداد گریدها در جهت Z (Nz)
۱۲۱۱۸۰	تعداد کل گریدهای مخزن
۱۰۰	اندازه گرید در جهت X (ft)
۱۰۰	اندازه گرید در جهت Y (ft)
۸	اندازه گرید در جهت Z (ft)

$$V_{t+1} = W_t \cdot V_t + c_1 \cdot \text{rand}() (pbest - present_t) + c_2 \cdot \text{rand}() (gbest - present_t) \quad (18)$$

$$present_{t+1} = present_t + V_{t+1} \quad (19)$$

در رابطه (۱۸)  $c_1$  و  $c_2$  پارامترهای یادگیری هستند.  $\text{rand}()$  تابعی برای تولید عددهای تصادفی در بازه [۰ و ۱] است.  $present_t$  موقعیت فعلی و  $V_t$  سرعت حرکت جزء می‌باشد.  $W_t$  یک پارامتر کنترلی است که سرعت فعلی را به سرعت بعدی  $V_{t+1}$  کنترل می‌کند


(۱) Global search

جدول ۳- ویژگی‌های مخزن مورد مطالعه.

۱۷۰	دمای مخزن (F)	۱/۱۱۲	ضریب حجمی سازند (Rbbl/stb)
۳/۸	ویسکوزیته نفت (cp)	۰/۱۷۲	نسبت گاز به نفت (mcf/STB)
۱۲	متوسط تخلخل ماتریس (%)	-۱۱۸۰۸	عمق مینا (ftss)
۶۴	درصد متوسط اشباع نفت (%)	۵۰۰۰	فشار متوسط مخزن در عمق مینا (psi)
$۵ \times 10^{-6}$	تراکم‌پذیری سنگ مخزن (l/psi)	۵۳	دانسیته نفت ( $lb/ft^3$ )
۱۷	متوسط تراوایی در افق (md)	-۱۱۸۰۸	عمق تماس آب - نفت (ftss)
۳/۵	متوسط تراوایی در قائم (md)	۳۵	API

در این مقاله برداشت از مخزن نفت با یک چاه هوشمند در یک افق زمانی ده ساله مورد مطالعه قرار گرفته است. برای پیاده‌سازی مدل ریاضی چاه هوشمند، قیدهای (۶) و (۷) با شرط‌های زیر لحاظ شده است.

میزان برش آب مجاز کمتر یا مساوی ۶۰ درصد و مجموع کل بیشینه جریان نفت تولیدی از شیرهای کنترلی برابر با ۳۰۰۰ بشکه در روز است. میزان برش آب با توجه به محدودیت تأسیسات سطح‌الارضی جداسازی آب از نفت، و محدودیت تولید روزانه نفت بر اساس مطالعات و تحلیل نفت موجود در مخزن، توسط کارشناسان تعیین شده است.



شکل ۲- نمایش سه بعدی مخزن و چاه افقی هوشمند مجهز به سه شیر کنترلی.

**نتیجه‌های به دست آمده از پیاده‌سازی شبکه عصبی مصنوعی بر روی مدل ریاضی**  
 شبکه عصبی پیاده‌سازی شده در این مسأله با استفاده از طرح مرکب مرکزی (CCD)، تعداد بی نهایت حالت برای انتخاب نمونه‌های آموزش برای سه ICD پیوسته را به ۱۲۵ آزمایش کاهش داده است. در این مقاله برای حل مدل ریاضی از دو شبکه عصبی چند لایه ایپرسپترون<sup>(۴)</sup> (MLP) از نوع شبکه‌های عصبی با اتصالات درونی پیش‌خور<sup>(۵)</sup> که با الگوریتم پس انتشار<sup>(۶)</sup> آموزش داده می‌شوند و شبکه عصبی برازش تعمیم داده شده<sup>(۷)</sup> (GRNN) شامل یک لایه پایه شعاعی<sup>(۸)</sup> و یک لایه خطی ویژه استفاده شده است. شکل ۵ الگوریتم پس انتشار خطا را در یک شبکه عصبی MLP نمایش داده است. این شبکه از الگوریتم آموزش گرادیان مزدوج پاول/ بل<sup>(۹)</sup> استفاده کرده است [۲۷].

این مخزن، دارای یک چاه نفتی افقی است. بخش افقی این چاه به طول ۱۴۰۰ متر، مجهز به سه ICD است، فاصله‌ی شیرها از یکدیگر حدود ۴۰۰ متر است. شیر کنترلی اول در پاشنه<sup>(۱)</sup>، شیر کنترلی دوم در وسط<sup>(۲)</sup> و شیر کنترلی سوم در پنجه<sup>(۳)</sup> چاه نصب شده است. برای شیرهای کنترلی پنج حالت متفاوت مطابق با جدول ۱ در نظر گرفته شده است. سطح مقطع هر شیر کنترلی در بازه (۰.۰۲۲ و ۰) بر حسب فوت مربع است یعنی؛ حالت به طور کامل باز شیر کنترلی  $0.022 \text{ ft}^2$  و حالت به طور کامل بسته آن صفر فوت مربع است (برای راحتی در محاسبه‌ها حالت به طور کامل باز را معادل ۱ و بقیه حالت‌ها نسبت به بازه (۰ و ۱) در نظر گرفته شده است).

(۱) Heel

(۲) Middle

(۳) Toe

(۴) Multilayer perceptron (MLP)

(۵) Feed forward


(۶) Backpropagation

(۷) Generalized regression neural network (GRNN)


(۸) Radial basis

(۹) Conjugate Gradient with Powell / Beale Restarts

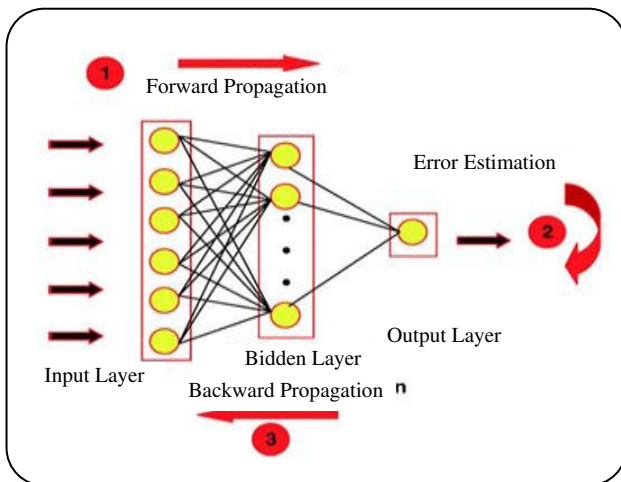




شکل ۴- مقطع عرضی توزیع تخلخل مخزن.




شکل ۳-a- مقطع عرضی توزیع تراوایی مخزن (روی محور X).




شکل ۵- شبکه عصبی MLP با الگوریتم پس انتشار خطا با یک لایه میانی.

برای رسیدن به بهترین شبکه عصبی و همچنین الگوریتم آموزش با دو شرط اعتبارسنجی کمترین میانگین مربعات خطا در محاسبه MSE و دیگری بهترین خط برازش از پاسخ‌های نفت و آب تجمعی برای نمونه‌های آموزش، استفاده شده است. برای یافتن شبکه عصبی مناسب، شبکه‌های عصبی گوناگون همراه با الگوریتم‌های آموزشی متفاوت بررسی شده است. از شبکه‌های مورد بررسی قرار گرفته شده، شبکه‌ی تابعی پایه شعاعی<sup>(۱)</sup> و از الگوریتم‌های آموزشی گرادیان مزدوج فلچر-پاول<sup>(۲)</sup>، گرادیان مزدوج پلاک - لیبیر<sup>(۳)</sup>، گرادیان مزدوج مدرج<sup>(۴)</sup> و روش CGB با لایه‌های میانی (پنهان) متفاوت استفاده شده است.



شکل ۳-b- مقطع عرضی توزیع تراوایی مخزن (روی محور Y).



شکل ۳-c- مقطع عرضی توزیع تراوایی مخزن (روی محور Z).

(۱) Radial Basis Function (RBF)

(۲) Fletcher-Powell Conjugate Gradient (CGF)

(۳) Polak-Ribière Conjugate Gradient (CGP)

(۴) Scaled Conjugate Gradient (SCG)

جدول ۴- طراحی شبکه عصبی MLP با لایه‌ها و نورون‌های گوناگون.

تعداد شبکه عصبی	تعداد نورون‌ها و لایه‌های پنهان	اعتبار سنجی خطا با MSE
۱	۱۰	$۳,۵۶ \times ۱۰^{-۲}$
۲	۱۲	$۷,۷۹ \times ۱۰^{-۱}$
۳	(۵, ۵)	$۲,۷۳ \times ۱۰^{-۱}$
۴	(۷, ۵)	$۱,۱۷ \times ۱۰^{-۱}$
۵	(۷, ۷)	$۲,۴۷ \times ۱۰^{-۳}$
۶	(۱۰, ۵)	$۲,۹۸ \times ۱۰^{-۳}$
۷	(۵, ۱۰, ۵)	$۳,۵ \times ۱۰^{-۳}$
۸	(۱۰, ۱۰, ۵)	$۱,۳۳ \times ۱۰^{-۳}$
۹	(۷, ۷, ۷)	$۴ \times ۱۰^{-۴}$
۱۰	(۵, ۱۰, ۱۰, ۵)	$۲,۲ \times ۱۰^{-۱}$

محاسبه شده از شبیه‌ساز مخزن است که با کمک روش CCD، شبکه عصبی MLP و GRNN با ۱۲۵ نمونه، آموزش داده است. همچنین نوع آموزش شبکه عصبی از نوع یادگیری نظارتی بوده و معیار پایان دادن یادگیری روش اعتبارسنجی متقاطع<sup>(۳)</sup> است.

#### اعتبار سنجی تابع تقریب حاصل از شبکه عصبی مصنوعی MLP و GRNN

در شکل ۶ که نمودار برازش پاسخ‌های نفت و آب در روش MLP نمایش داده شده است، تمامی پاسخ‌ها برای تمامی نمودارهای آموزش، اعتبار سنجی و آزمون در این شبکه عصبی دارای دقتی بیش از ۰/۹۹۵ (نزدیک به ضریب همبستگی یک  $(R^2=1)$ ) می‌باشند. این برآورد نشان دهنده دقت بالای تابع تقریب زده شده، توسط شبکه عصبی آموزش دیده بالا می‌باشد.

شکل ۷ میزان خطای داده‌های آموزش و آزمون را با روش میانگین مربعات خطا (MSE) در شبکه عصبی MLP با الگوریتم آموزش CGB نمایش می‌دهد.

پایین‌ترین میزان خطای محاسبه شده در روش شبکه عصبی MLP با الگوریتم آموزش CGB برابر  $۴ \times ۱۰^{-۴}$  برای نمونه‌ای انتخابی نرمال‌سازی شده است. به‌طور همانند و حتی با دقت بالاتری شبکه عصبی GRNN دارای خطای  $MSE \times ۱۰^{-۶}$  است. همچنین نمودارهای برازش برای پاسخ‌های روش GRNN برابر با دقت ۰/۹۹۹۸ می‌باشد که این میزان دقت با خطای پایین

برای یافتن شبکه عصبی همراه با محاسبه الگوریتم آموزش مناسب، باید تعداد لایه‌های میانی و تعداد نورون‌های هر لایه به صورت بهینه انتخاب شود. جدول ۴ بیانگر چگونگی یافتن بهترین تعداد لایه با نورون‌ها در الگوریتم‌های آزمایشی مورد استفاده است.

سرانجام بهترین نتیجه در خروجی‌ها در شبکه MLP، با الگوریتم آموزش CGB و با تعداد سه لایه میانی که هریک دارای ۷ نورون به صورت (۷ و ۷ و ۷) است، به‌دست آمد. علت انتخاب این الگوریتم آموزش کمترین مقدار خطا در میزان MSE و بهترین خط برازش برای پاسخ‌های نفت و آب است که در جدول ۴ و شکل ۶ نشان داده شده است. شایان گفتن است که شبکه عصبی GRNN نیز در مقایسه با روش MLP علاوه بر خطای کمتر در محاسبه MSE، دارای دقت بالاتری در خط برازشی پاسخ‌ها است که در جدول ۵ نشان داده شده است.

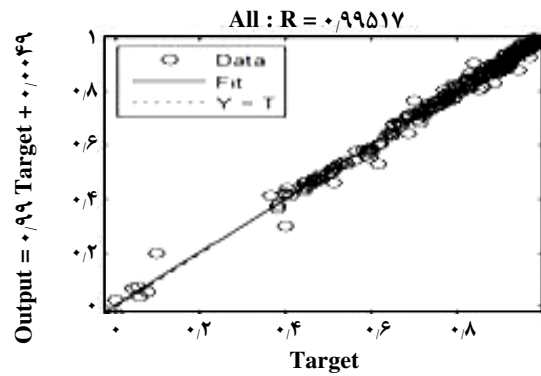
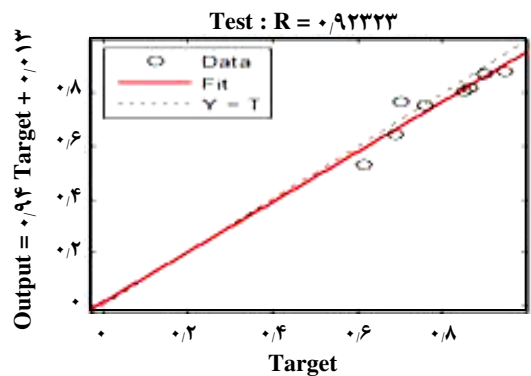

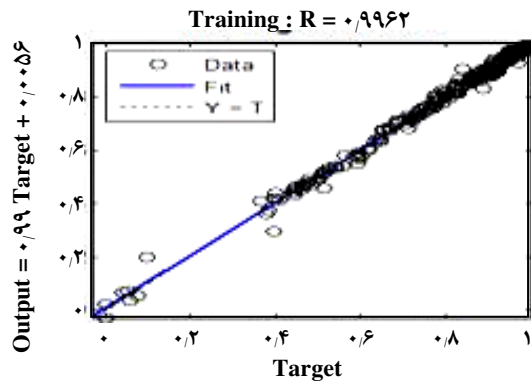
در تمامی این موردها تابع انتقال، تابع تانژانت هایپربولیک بوده که در انتخاب نوع شبکه و هم در انتخاب الگوریتم‌های آموزشی، مورد استفاده قرار گرفته است. علاوه بر این تابع، تابع سیگموئید دو سویه نیز مورد بررسی قرار گرفته شده که نتیجه‌های آن تا حدی قابل قبول می‌باشد، ولی دقت بالا و سرعت همگرایی نتیجه‌های تابع تانژانت هایپربولیک باعث شده تا از این تابع انتقال در تابع آموزش شبکه عصبی استفاده شود.

در این مقاله ورودی‌های<sup>(۱)</sup> شبکه عصبی تنظیمات سه ICD با سطح مقطع پیوسته و خروجی‌های<sup>(۲)</sup> آن، نفت و آب تجمعی

(۱) Input

(۳) Cross validation

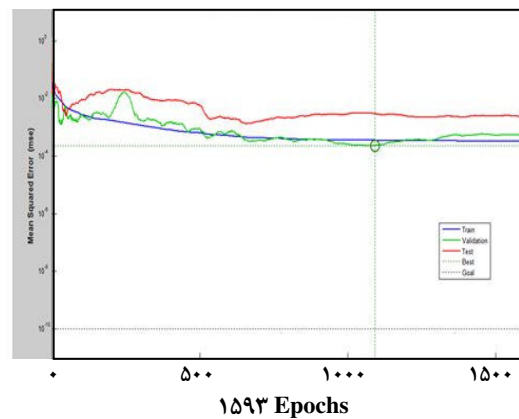
(۲) Output



شکل ۶ - نمودار برازش پاسخ های نفت و آب برای اعتبار سنجی متا مدل به دست آمده از ANN<sub>MLP</sub>.

#### الگوریتم بهینه سازی پرندگان (PSO)

بعد از اعتبار سنجی تابع تقریب طراحی شده در شبکه عصبی، الگوریتم بهینه‌سازی PSO با هدف به دست آوردن بهترین تنظیمات برای سه شیر کنترلی بر روی شبکه عصبی پیاده‌سازی می‌شود. با توجه به نوع تعریف تابع هدف در مدل ریاضی مسأله، با یک مدل ریاضی دو هدفه و غیرخطی روبرو هستیم که هدف‌های آن هر یک دارای یک ارزش و درجه اهمیتی می باشند. در نتیجه با الگوریتم بهینه‌ساز PSO بدون در نظر گرفتن وزن برای پاسخ‌های مسأله، تابع هدف را بهینه می کنیم. برای بهینه‌سازی تابع تقریب طراحی شده برای مدل ریاضی با الگوریتم بهینه‌ساز PSO از شبکه عصبی MLP از شمای عملیاتی در شکل ۱ استفاده می کنیم. نتیجه بهینه به دست آمده برای سه ICD به صورت بردار سه تایی  $(ICD1, ICD2, ICD3) = (0.2, 0.2, 1)$  با شبکه‌ی MLP است. جواب به دست آمده از این تنظیمات برای نفت و آب تجمی به ترتیب ۶/۱۵ و ۷ میلیون بشکه در پایان دوره ۱۰ ساله است که خطای آن با شبیه ساز مخزن در حدود ۳ درصد می باشد.





شکل ۷ - بهترین عملکرد داده‌ها در میانگین مربعات خطا (MSE) در حالت کلی.

برای داده‌های آموزش و برای داده‌های تست در شکل‌های ۸ و ۹ و جدول ۵ نمایش داده شده اند. این میزان دقت در این شبکه نشان‌دهنده آموزش خوب و همگرایی بالای داده‌های تست به داده‌های آموزش می باشد.

جدول ۵ - مقایسه دو روش طراحی شبکه عصبی.

شبکه عصبی	مقدار MSE	ضریب همبستگی $R^2$	ضریب بازیافت	بهترین تنظیمات	میزان تولید نفت تجمعی MMBbl	میزان خطا با شبیه‌ساز
MLP	$4 \times 10^{-4}$	۰.۹۹۵	%۹.۵	(۰.۲ و ۰.۲)	۶.۱۵	%۳
GRNN	$10^{-6}$	۰.۹۹۹۸	%۹.۵	(۱ و ۰.۵۴)	۶.۰۲۷	%۱

شکل ۹ - نمودار برازش پاسخ‌های تست نفت و آب برای اعتبارسنجی متا مدل حاصل از ANN<sub>GRNN</sub>.شکل ۸ - نمودار برازش پاسخ‌های آموزش نفت و آب برای اعتبارسنجی متا مدل حاصل از ANN<sub>GRNN</sub>.

مقایسه نرخ تولید نفت و برش آب مجاز در دو روش متداول و روش کنترل هوشمند، در شکل‌های ۱۱ و ۱۲ نشان می‌دهند که تولید نفت در کنترل هوشمند تا ده سال ادامه داشته و چاه همچنان به تولید ادامه داده است در حالی که در روش متداول تولید نفت در همان پنج سال اول پایان می‌یابد. علت این رخداد، عدم کنترل بر تولید سیال است که منجر به افزایش برش آب فراتر از حد مجاز شده و باعث بسته شدن چاه شده است. ضریب بازیافت تولید نفت که نشان دهنده میزان موفقیت در برداشت نفت از کل نفت موجود در مخزن است، در روش متداول ۶٪ و روش شبکه عصبی مصنوعی ۹.۵٪ رسیده است. برای پیاده‌سازی و توسعه روش‌های شبکه عصبی از نرم افزار MATLAB استفاده شده است.

### نتیجه گیری

در این مقاله تلاش برای توسعه طراحی معماری روش شبکه‌های عصبی با استفاده از روش طرح مرکب مرکزی بود که بهینه‌سازی تابع تقریب ایجاد شده با الگوریتم بهینه ساز پرندگان (PSO) صورت گرفته است. نتیجه‌های زیر از به‌کارگیری این روش

به همین صورت نتیجه بهینه به‌دست آمده برای سه ICD به صورت بردار سه تایی  $(ICD1, ICD2, ICD3) = (1, 0.54, 1)$  با شبکه‌ی GRNN است. جواب بهین به دست آمده از این تنظیمات برای نفت و آب تجمعی به ترتیب ۶/۰۲۷ و ۷/۱۰۵ میلیون بشکه در پایان دوره ۱۰ ساله است که خطای آن با شبیه ساز مخزن کمتر از ۱ درصد می‌باشد. این مقدار خطا نشان دهنده نزدیک بودن تابع تقریب به‌دست آمده از شبکه عصبی به جواب بهینه مسأله است. با مقایسه روش شبکه عصبی با روش متداول در تولید نفت تجمعی این نتیجه به‌دست می‌آید که میزان نفت تجمعی در روش شبکه عصبی به اندازه ۵۵٪ نسبت به حالت متداول افزایش داشته است. این مقایسه در تولید نفت و آب در شکل ۱۲ نمایش داده شده است.

### مقایسه عملکرد روش متداول با روش کنترل هوشمند

با مقایسه روش شبکه عصبی با روش متداول در تولید نفت تجمعی این نتیجه به‌دست می‌آید که میزان نفت تجمعی در روش شبکه عصبی به اندازه ۵۵٪ نسبت به حالت متداول افزایش داشته است. این مقایسه در تولید نفت و آب در شکل ۱۰ نمایش داده شده است.

$N_p$	نفت تجمعی، میزان نفت از زمان برداشت تا آخرین تولید، bbl	در تولید نفت تجمعی در یک چاه افقی به دست آمده است: • افزایش قابل توجه تولید نفت در حالت کنترل هوشمند نسبت به حالت متداول
$W_p$	آب تجمعی، میزان آب از زمان برداشت تا آخرین تولید، bbl	• افزایش دوره زمانی تولید از مخزن نفتی در حالت کنترل هوشمند نسبت به حالت متداول
$q_{oi}$	نرخ جریان نفت خارج شده از هر شیر کنترلی، bbl/day	• افزایش قابل توجه ضریب بازیافت مخزن در حالت کنترل هوشمند نسبت به حالت متداول
$W_{ci}$	نرخ جریان آب خارج شده از هر شیر کنترلی، bbl/day	• کاهش قابل توجه زمان محاسبه با به کارگیری روش شبکه عصبی نسبت به روش متداول
$\Delta P_f$	افت فشار ناشی از اصطکاک جریان بر روی لوله، Psi	• تناسب عملکرد شیرهای کنترلی با ناهمگونی‌های مخزن
$L$	طول هر قسمت از لوله ما بین شیرهای کنترلی، متر	
$D$	قطر هر لوله، in	
$f$	ضریب اصطکاک	
$\rho_m$	چگالی سیال (نفت و آب)	
$\rho$	چگالی، $lb_m/ft^3$	
$K$	تراوایی مطلق	
$K_w$	تراوایی مؤثر آب	
$K_o$	تراوایی مؤثر نفت	
$K_{rw}$	تراوایی نسبی آب، md	
$e_z$	بردار نقطه ای در جهت جاذبه	
$S_w$	میزان اشباع آب	
$S_o$	میزان اشباع نفت	
$g$	گرانش زمین، $9.8$	

### قدردانی

نویسندگان بدین وسیله از آقای دکتر مهدی قطعی بابت کمک و راهنمایی‌های ایشان در آشنایی با نوار ابزار شبکه عصبی در نرم افزار MATLAB و پژوهشگاه صنعت نفت بابت ایجاد محیطی آموزشی و در اختیار قراردادن نرم‌افزارهای شبیه‌ساز مخزن و همچنین از آقایان امیر عباس عسگری و امیر جهان بخش قدردانی می‌نمایند.

### نمادها

نشان دهنده تعداد شیرهای کنترلی است،  $I \in N$   
 $I, i \in I$   
 $t$  دفعات به روز رسانی چاه هوشمند

### پارامترهای مدل ریاضی

$W_c$  میزان برش آب بر حسب درصد  
 $q_o$  حداکثر نفت قابل تولید، bbl/day

### متغیرهای مدل ریاضی

$q_t$  نرخ جریان کل سیال، bbl/day

تاریخ دریافت: ۱۳۸۸، ۱۲، ۲۷ ؛ تاریخ پذیرش: ۱۳۸۹، ۹، ۲۲

### مراجع

- [1] Gao c., Ranjeswaran T., Surtin U., Nakagawa E., "A Literature Review on Smart-Well Technology," in *SPE*, Oklahoma, March-April (2007).
- [2] Oberwinker C., Stundener M., Team D., "From Real Time Data to Production Optimization," in *SPE*, March (2004).

- [3] Naus M.M.J.J., Dolle N., Jansen J., "Optimization of Commingled Production Using Infinitely Variable Inflow Control Valves," in *SPE*, Houston, (2005).
- [4] Yeten B., Brouwer D.R., Durlofsky L.J., Aziz K., Decision Analysis Under Uncertainty for Smart Well Deployment, *Journal of petroleum Science & Engineering*, **43**, p. 183 (2004).
- [5] Yeten B., Durlofsky L.J., Khalid A., "Optimization of Smart Well Control," in *SPE*, Alberta, November (2002).
- [6] Aitokhuehi I., Durlofsky L.J., Optimization the Performance of Smart Well in Complex Reservoirs Using Continuously Updated Geological Models, *Petroleum Science & Engineering*, **48**(3-4), p. 254 (2005).
- [7] Taware S., Sharme M., Alhuthali A.H., Gupta A.D., "Optimization Water flood Management Under Geological Uncertainty Using Accelerated Production Strategy," in *SPE*, Florence, (2010).
- [8] Alhuthali A.H., Gupta A.D., Yeten B., Fontanilla J.P., "Field Applications of Waterflood Optimization via Optimal Rate Control with Smart Well," in *SPE*, Woodlands, (2009).
- [9] Van Essen G.M., Jansen J.D., Brouwer D.R., Douma S.G., Zandvliet M.J., Rollett K.I., Harris D.P., "Optimization of Smart Wells in the St. Joseph Field," in *SPE*, Jakarta, (2009).
- [10] Alhuthali A.H., Gupta A.D., Yeten B., Fontanilla J.P., "Optimal Rate Under Geologic Uncertainty," in *SPE*, Oklahoma, (2008).
- [11] Shuai Y., White C.D., Zhang H., Sun T., "Using Multiscale Regularization to Obtain Realistic Optimal Control Strategies," in *SPE*, Woodlands, (2011).
- [12] Moreno J.C. et al., "Optimization Workflow for Designing Complex Wells," in *SPE*, Vienna, (2006).
- [13] Meun P., Tondel P., Godhavn J.M., Aamo O.M., "Optimization of Smart well Production Through Nonlinear Model Predictive Control," in *SPE*, Amsterdam, (2008).
- [14] Al-Ghreeb Z.M., "Monitoring and Control of Smart Wells," in *Monitoring and Control of Smart Wells*.: Copy by Zeid Al-Ghreeb , (2009).
- [15] Conejeros R., Lenoach B., Model-Based Optimal of Dual Completion Wells, *Petroleum Science & Engineering*, **42**(1), p. 1 (2004).
- [16] Harrison S.J., Marshall R.F., "Optimization and Training of Feedforward Neural Network by GAs," in *Proceeding of IEE Second International Conference on Artificial Neural Networks*, pp. 39-43 (1991).
- [۱۷] کمالی، محمد رضا؛ علی مددی، فاطمه؛ فخری، امین؛ کاربرد روش‌های هوشمند در مهندسی نفت و علوم زمین ایران، تهران، پژوهشگاه صنعت نفت، (۱۳۹۰).
- [18] Graudenz S., Bornholdt D., General Asymmetric Neural Networks and Structure Design by Genetic Algorithms, *Neural Netw*, **5**, p. 327 (1992).
- [19] Moselhi T., Fazio O., Hegazy P., Developing Practical Neural Network Applications Using Back-Propagation, *Microcomput. Civ. Eng*, **9**, p. 145 (1994).

- [20] Anderson M.J., Whitcomb P.J., "DOE Simplified", INC, (2000).
- [21] Beielstein T.B., Chiarandini M., Paquete L., Preuss M., "Experimental Methods for the Analysis of Optimization Algorithms", Berlin: Springer, (2010).
- [22] Montgomery D.C., "Design and Analysis of Experimental", John Wiley & Sons, (2001).
- [23] Aggarwal A., Singh H., Kumar P., Singh M., Optimization Power Consumption for CNC Turned Parts Using Response Surface Methodology and Taguchi Techniqu-A Comparative Analysis, *Material Processing Technology*, **200**(1-3), p. 373 (2008).
- [24] Kennedy Clerc, "The Particle Swarm Explosion, Stability and Convergence in a Multideimentional Complex Space," *IEEE, Vol. on Evolutionary Computation*, **6**(1), p. 58 (2002).
- [25] Eberhart J., Kennedy R., "Particle Swarm Optimization," in *Proceedings IEEE International Conference on Neural Networks*, (1995).

[۲۶] شالکف، رابرت جی؛ مترجم: جوراییان، محمود؛ شبکه های عصبی مصنوعی، دانشگاه شهید چمران اهواز،

(۱۳۸۴).