

## بهینه‌سازی مکان چاه‌های تزریق آب به همراه ارزیابی عدم قطعیت

حامد دارابی، محسن مسیحی\*<sup>+</sup>

تهران، دانشگاه صنعتی شریف، دانشکده مهندسی شیمی و نفت

**چکیده:** تعیین بهترین مکان برای حفر چاه‌های جدید یک مسئله پیچیده است که به ویژگی‌های سیال و مخزن، شرایط تجهیزات سطحی و چاه‌ها و معیارهای اقتصادی وابسته است. روش‌های گوناگونی برای حل این مسئله پیشنهاد شده است. در این میان، روش‌های بهینه‌سازی مستقیم که از شبیه‌سازی برای محاسبه تابع هدف استفاده می‌کنند، روش‌های به نسبت دقیقی هستند. ولی در بیشتر موردها به علت تعداد بالای شبیه‌سازی‌های مورد نیاز، این روش‌ها غیر عملی هستند. برای رفع این مشکلات، در این پژوهش از الگوریتم بهینه‌سازی هیبریدی (HGA) استفاده شده است. اساس این روش بر پایه‌ی الگوریتم ژنتیک است که با تابع‌های کمکی شبکه‌ی عصبی مصنوعی و الگوریتم پلی‌توپ ترکیب شده است. ترکیب الگوریتم ژنتیک با روش پلی‌توپ، سبب افزودن اثر پالایش موضعی شده و سرعت همگرایی را افزایش می‌دهد. همچنین با استفاده از شبکه‌ی عصبی مصنوعی می‌توان در طول اجرای برنامه، تابع نماینده شبیه‌ساز را تولید و کالیبره کرد. شایان ذکر است که در مسئله بهینه‌سازی مکان چاه‌ها، مدل عددی ساخته شده بر پایه داده‌های همراه با عدم قطعیت است. بنابراین در چنین شرایطی، یک جواب عمومی قطعی برای مسئله وجود نخواهد داشت. در این مطالعه، به منظور لحاظ کردن اثر عدم قطعیت موجود در داده‌ها بر روی تصمیم‌گیری، از سامانه استنتاج فازی استفاده شده است. خروجی این سامانه، میزان نامناسب بودن یک نقطه که برای حفر چاه جدید انتخاب شده است را با در نظر گرفتن اثرهای عدم قطعیت موجود در داده‌ها، دید مهندسی و ترجیح‌های تصمیم‌گیرنده تعیین می‌کند. در بیشتر مسئله‌های مهندسی، از جمله مسئله مکان‌یابی چاه، تابع هدف رایج در بهینه‌سازی، تابع سود به زمان حال بازگردانده شده (NPV) است. در این پژوهش، خروجی سامانه استنتاج فازی و NPV با هم ترکیب شده و یک تابع هدف جدید (NPV تصحیح شده یا CNPV) برای مسئله بهینه‌سازی مکان چاه‌ها ساخته شده است. در پایان عملکرد الگوریتم پیشنهاد شده برای مسئله مکان‌یابی چاه‌های تزریق آب در بخشی از یکی از مخازن غربی ایران بررسی شد. با توجه به نتیجه‌های به دست آمده از آزمایش‌های کنترل‌شده دیده شده که تعداد شبیه‌سازی‌های مورد نیاز برای یافتن مکان بهینه‌ی چاه‌ها در حالتی که از الگوریتم HGA استفاده شود تا حد زیادی کاهش می‌یابد. همچنین مکان و شدت جریان مناسب تزریق تا حداکثر چهار چاه تزریق آب در این مخزن با استفاده از الگوریتم پیشنهاد شده تعیین شد.

**واژه‌های کلیدی:** مکان‌یابی چاه، بهینه‌سازی، الگوریتم ژنتیک، روش پلی‌توپ، شبکه‌ی عصبی مصنوعی، تصمیم‌گیری، سامانه استنتاج فازی، ارزیابی عدم قطعیت.

**KEY WORDS:** Well placement, Optimization, Genetic algorithm, Polytope method, Artificial neural network, Decision, Fuzzy inference system, Uncertainty assessment.

+E-mail: masihi@sharif.edu

\*عهده دار مکاتبات

## مقدمه

برداشت بهینه و رسیدن به درآمد بیشتر با صرف کمترین هزینه، در برنامه‌ی توسعه‌ی مخازن، از هدف‌های اصلی در مدیریت مخازن می‌باشد. یکی از مهمترین برنامه‌های توسعه‌ی مخازن، یافتن نقطه‌های بهینه برای حفر چاه‌های جدید است. این چاه‌های جدید می‌توانند شامل چاه‌های توسعه‌ای جدید برای جارو کردن نفت‌های باقیمانده در مخزن، چاه‌های تزریق آب و گاز و حتی چاه‌های مورد استفاده در عملیات ازدیاد برداشت شوند. یافتن نقطه‌های بهینه برای حفر این چاه‌ها علاوه بر افزایش نرخ تولید، باعث افزایش میزان ضریب بازیافت مخازن نیز می‌شود.

انتخاب‌ها و تصمیم‌گیری‌ها در هر سطحی از فرایند توسعه‌ی مخزن انجام می‌گیرند. در بسیاری از حالت‌ها، انتخاب‌های بهینه وابسته به پارامترهایی هستند که به صورت غیرخطی به هم مرتبط شده‌اند که در نتیجه قضاوت درست مشکل می‌شود. در چنین حالت‌هایی استفاده از روش‌های بهینه‌سازی خودکار بسیار مفید می‌باشد. انتخاب‌های توسعه‌ای در موفقیت یا شکست یک پروژه تأثیر زیادی دارند و همچنین یک انتخاب بهتر، حتی اندکی بهتر، ممکن است ارزش اقتصادی یک پروژه را به مقدار زیادی افزایش دهد. بنابراین انتخاب‌ها می‌بایستی براساس دقیق‌ترین و مرتبط‌ترین ابزارهای قابل دسترس انجام گیرند. هر چند که اغلب چنین ابزارهایی از نظر محاسباتی گران و پرهزینه می‌باشند.

مسئله یافتن مکان بهینه جهت حفر چاه‌های تزریقی در یک پروژه‌ی تزریق آب را در نظر بگیرید؛ مدل‌های عددی در واقع پایه انتخاب‌ها می‌باشند. زیرا این مدل‌ها ابزارهای پیش‌بینی کننده‌ای هستند که ما را قادر می‌سازند تا رابطه‌های پیچیده‌ی بین پارامترهای گوناگون مانند ویژگی‌های سیال و مخزن، تجهیزات سرچاهی و معیارهای اقتصادی را محاسبه نمائیم. از طرف دیگر مدل‌های عددی استفاده شونده در صنعت نفت به‌طور عمومی دارای زمان پردازش بالا بوده و کویل کردن این مدل‌های عددی با یک بهینه‌ساز به صورت خودکار غیرعملی است. دو ایده برای عملی کردن این فرایند وجود دارد:

۱- کاهش تعداد شبیه‌سازهای مورد نیاز

۲- تخمین مدل عددی با یک ابزار ارزان‌تر و کم هزینه‌تر پژوهشگران بسیاری بر روی این روش‌ها تحقیق کرده‌اند.

کاهش تعداد محاسبات اولین ایده‌ای است که به ذهن می‌رسد، هر چند دقت زیادی برای اجتناب از انتخاب‌های شبه‌بهینه می‌بایستی انجام گیرد [۴-۱]. تخمین مدل کامل عددی ایده‌ی دیگری است که مورد توجه قرار دارد [۷-۵]. شایان گفتن است که انتخاب‌های انجام گرفته براساس ابزارهای تخمین ممکن است منجر به جواب بهینه نشود، مگر آنکه ابزار به کار برده شده بسیار دقیق و مناسب باشد. در این پژوهش یک راه حل مناسب برای حل مسئله مکان‌یابی پیشنهاد می‌شود که از هر دو روش بالا به صورت همزمان استفاده می‌کند.

## بخش نظری

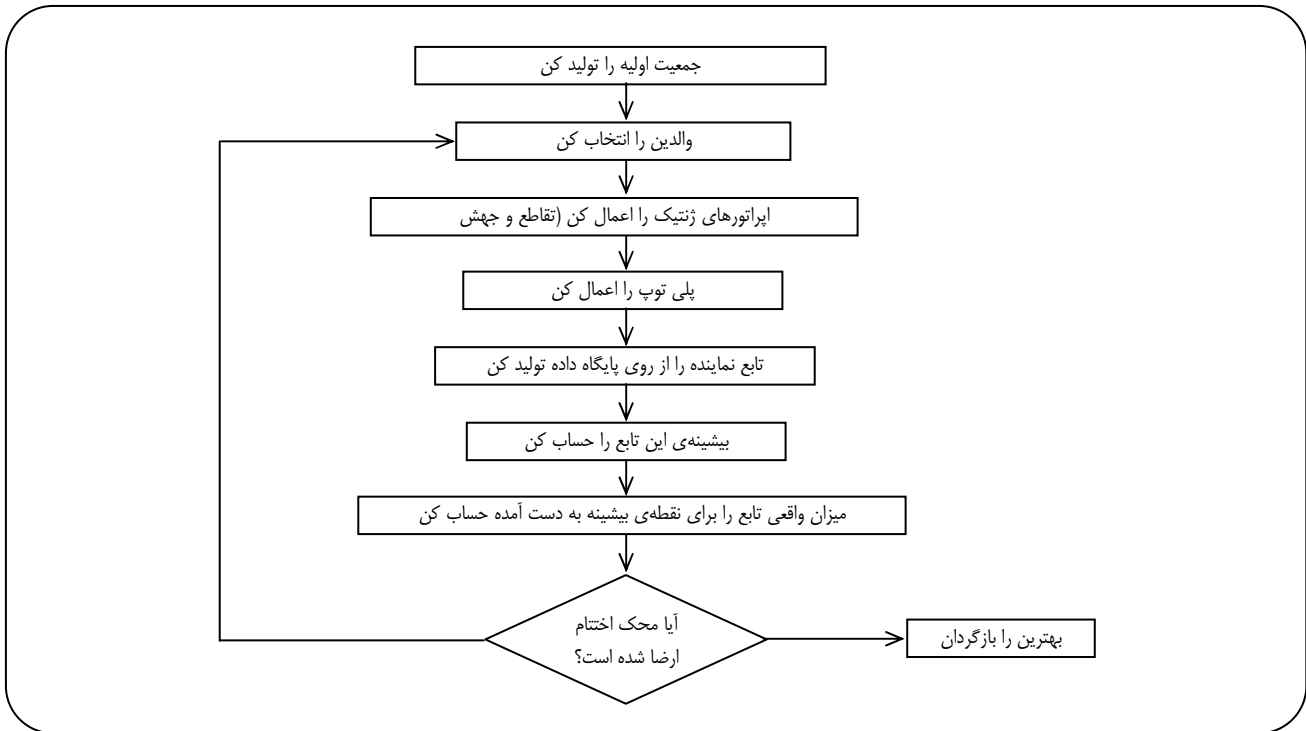
## الگوریتم بهینه‌سازی

برای مسئله‌ی مکان‌یابی چاه، الگوریتم ژنتیک<sup>(۱)</sup> به نظر روش مناسبی می‌رسد [۸]. با در نظر گرفتن مسایل توسعه مخزن، الگوریتم ژنتیک برتری‌های بسیار زیادی نسبت به روش‌های دیگر بهینه‌سازی دارد: اول اینکه پارامترهای ناپیوسته که اغلب در مسئله‌های مهندسی مخزن با آن روبرو هستیم به طور کاملاً ساده‌ای قابل استفاده هستند. پارامترهای پیوسته نیز به وسیله ناپیوسته کردن جزئی قابل استفاده می‌شوند. الگوریتم ژنتیک می‌تواند به طور همزمان با ساختارهای داده‌ای مختلف کار کند که این اجازه را به ما می‌دهد که تعریف مسئله را نیز بهینه کنیم. برای مثال، در مسئله مکان‌یابی چاه‌ها بوسیله‌ی الگوریتم ژنتیک، می‌توان تعداد چاه‌ها را نیز به عنوان متغیر مستقل در نظر گرفت. از آنجایی که الگوریتم ژنتیک براساس جمعیتی<sup>(۲)</sup> از جواب‌ها به طور همزمان کار می‌کند، موازی کردن الگوریتم ژنتیک بسیار آسان است. علاوه بر این برتری‌ها، همچنان که برنامه اجرا می‌شود می‌توان پارامترهای الگوریتم را با مسئله مطابقت داد و همچنین این الگوریتم به آسانی با الگوریتم‌های دیگر قابل ترکیب شدن می‌باشد. برخی از ویژگی‌های الگوریتم ژنتیک که این روش را پر قدرت و قوی می‌نمایند، باعث کند کردن و عدم دقت آن نیز می‌شوند. به‌طور عموم الگوریتم ژنتیک دارای پیشرفت اولیه‌ی بسیار مناسب برای یافتن جواب بهینه می‌باشد، ولی در یافتن جواب نهایی دارای مشکل می‌باشد. به خاطر این محدودیت‌ها در این پژوهش یک روش کمکی خاص به نام پلی‌توپ<sup>(۳)</sup> برای افزایش بازدهی بهینه‌سازی پیشنهاد شده است [۹]. با افزودن روش پلی‌توپ به الگوریتم ژنتیک

(۱) Genetic algorithm

(۲) Population

(۳) Polytope



شکل ۱- فلوجارت الگوریتم ژنتیک هیبریدی.

الگوریتم به دست آمده به عنوان الگوریتم ژنتیک هیبریدی (HGA) (۴) ارجاع داده می‌شود. فلوجارت الگوریتم ژنتیک هیبریدی در شکل ۱ نشان داده شده است.

#### هیبریدسازی الگوریتم ژنتیک و روش پلی‌توپ

اگر  $n$  برابر تعداد متغیرهای مستقل (ابعاد) مسئله باشد، پلی‌توپ توسط  $n+1$  فرد (۵) ساخته می‌شود. از روش پلی‌توپ برای تولید یک یا چند عضو از جمعیت موجود در هر نسل (۶) استفاده می‌شود. برای ساختن پلی‌توپ سه استراتژی مختلف در نظر گرفته شد که شرح داده شده است:

۱- ساختن پلی‌توپ از میان بهترین  $n+1$  فرد در نسل جاری (شکل ۲).

۲- ساختن پلی‌توپ از میان بهترین  $n+1$  فرد که از ابتدا تا نسل جاری وجود داشته‌اند (شکل ۳).

۳- ساختن پلی‌توپ از میان بهترین جواب که از ابتدا تا نسل جاری وجود داشته است و  $n$  نقطه نزدیک به آن (شکل ۴).

در واقع قابلیت پالایش موضعی (۱) به منظور حل این مشکل به این الگوریتم اضافه می‌شود.

ایده‌ی استفاده از یک تخمین ارزان‌تر مدل عددی با استفاده از روش تابع نماینده از مدل عددی (شبه‌ساز) قابل انجام می‌باشد. یک تابع نماینده از مدل عددی در تمام مرحله‌های جستجوی الگوریتم ژنتیک ساخته می‌شود. این روش برتری‌های زیادی نسبت به ساختن یک تابع نماینده با استفاده از شبیه‌سازی‌های عددی اولیه دارد. اول از همه اینکه، مشخص کردن تعداد شبیه‌سازی‌های مورد نیاز برای ایجاد یک تابع نماینده به اندازه کافی دقیق، همواره یک مبنای مشخص ندارد. همچنین، با کالیبره کردن تابع نماینده به صورت تکراری (۲)، بردار نامزد بعدی برای شبیه‌سازی شدن، وابسته به نتیجه‌های شبیه‌سازی مرحله قبل می‌باشد. این وابستگی به شبیه‌سازی‌های قبلی به الگوریتم اجازه می‌دهد تا خود را با ویژگی‌های مسئله همچنان که شبیه‌سازی جلو می‌رود وفق دهد. شبکه‌های عصبی مصنوعی RBF (۳) در این مطالعه به عنوان اساس ساخت تابع نماینده در نظر گرفته شده است [۱۰].

(۱) Local refinement

(۲) Iterative

(۳) Radial basis function

(۴) Hybrid Genetic Algorithm (HGA)

(۵) Individual

(۶) Generation

روش‌های یک و دو برای ساختن پلی‌توپ بیشتر شبیه عملگر جهش<sup>(۱)</sup> رفتار می‌کنند تا پالایش موضعی. همان‌طور که پیش‌تر اشاره شد، هدف از پلی‌توپ پالایش موضعی است و بدین منظور استراتژی آخر بهترین استراتژی است. اگر جوابی که پس از چند مرحله پلی‌توپ به دست می‌آید نسبت به جواب‌های موجود در نسل بهبود پیدا کند، آنگاه این جواب به دست آمده از پلی‌توپ به‌جای بدترین جواب جایگزین می‌شود و الگوریتم به کار خود ادامه می‌دهد. این نکته باید در نظر گرفته شود که فقط یک مرحله‌ی پلی‌توپ نیاز به تعداد زیادی (به تقریب یک تا سه مرتبه) محاسبه‌ی تابع هدف دارد. در نتیجه استفاده‌ی چند مرحله‌ی از پلی‌توپ، ممکن است سبب کاهش بازدهی عملکرد الگوریتم بهینه‌سازی شود.


### ساخت تابع نماینده‌ی شبیه‌ساز توسط شبکه عصبی RBF

برای ساختن تابع نماینده، ابتدا یک پایگاه داده از اطلاعات مورد نیاز از کل نقطه‌هایی که الگوریتم تا به حال ملاقات کرده، ساخته شده و هر جایی که تابع هدف جدیدی محاسبه می‌شود این پایگاه داده به‌روزرسانی می‌شود. از این پایگاه داده برای ساختن تابع نماینده استفاده می‌شود که در واقع جایگزینی برای محاسبه‌ی تابع هدف واقعی است.

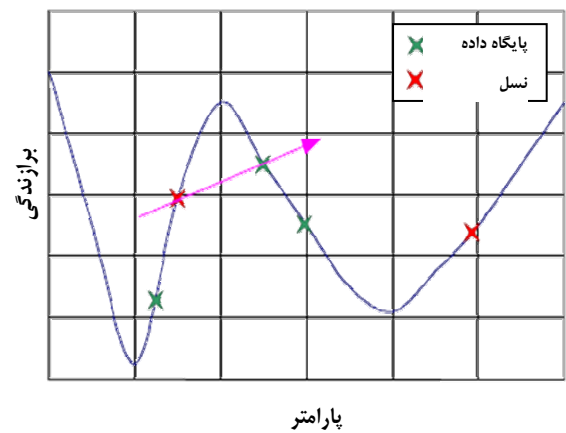
توسط این تابع نماینده مقدار تابع برای تمام نقاطی که مقدار تابع توسط شبیه‌سازی محاسبه نشده است، محاسبه می‌شود. نقطه بیشینه این تابع ساخته شده توسط تابع نماینده جستجو می‌شود. سپس مقدار تابع هدف واقعی توسط شبیه‌سازی برای این نقطه‌ی بیشینه محاسبه می‌شود. اگر این نقطه بهتر از بدترین نقطه‌ی موجود در نسل جاری باشد این نقطه به جای بدترین جواب جایگزین می‌شود. شاید به‌کارگیری تابع نماینده‌ی شبیه‌ساز نتواند خیلی بر روی بازدهی عملکرد الگوریتم بهینه‌سازی تأثیر داشته باشد، ولی باید توجه شود که استفاده از روش تابع نماینده تنها به یک محاسبه‌ی تابع واقعی در هر نسل نیاز دارد و عملیات پرهزینه‌ای نیست.

در مطالعه موردی که در این پروژه انجام شده و به شرح آن خواهیم پرداخت، پارامترهای زیر به عنوان ورودی‌های شبکه عصبی RBF در نظر گرفته شده‌است:


شاخص فاصله از مرزهای مخزن، شاخص فاصله از چاه‌های دیگر، شدت جریان تزریقی چاه‌ها، پارامتر عدم قطعیت، متوسط نفوذپذیری در ۲۵ بلوک اطراف چاه تزریق، متوسط تخلخل در ۲۵ بلوک اطراف چاه تزریق و متوسط اشباع آب در ۲۵ بلوک اطراف چاه تزریق.



شکل ۲- نمایش ساختن پلی‌توپ از میان بهترین فرد  $n+1$  فرد در نسل جاری برای مسئله‌ی یک بعدی.




شکل ۳- نمایش ساختن پلی‌توپ از میان بهترین فرد  $n+1$  فرد که از ابتدا تا نسل جاری وجود داشته‌اند برای مسئله‌ی یک بعدی.



شکل ۴- نمایش ساختن پلی‌توپ از میان بهترین جواب که از ابتدا تا نسل جاری وجود داشته و  $n$  نقطه نزدیک به آن برای مسئله‌ی یک بعدی.

(۱) Mutation



شکل ۵ - آنالیز گردش سرمایه در پروژه حفر چاه جدید.

با جواب وجود دارد. آنچه در این مطالعه انجام شده، آن است که با ارایه‌ی یک تابع هدف جدید بتوان به یک جواب دقیق‌تر دست یافت و میزان عدم قطعیت را تا حد امکان کاهش داد.

رسیدن به چنین تابع جدیدی، با استفاده از منطق فازی<sup>(۲)</sup> عملی می‌شود [۱۱]. به طوری که با استفاده از این روش پارامتری تعریف می‌شود که با اعمال این پارامتر بر روی تابع هدف که همان سود به زمان حال برگردانده شده است تابع جدید ساخته می‌شود. این تابع جدید به الگوریتم بهینه‌سازی داده می‌شود تا مکان بهینه برای حفر چاه‌ها انتخاب شود.

با استفاده از سامانه استنتاج فازی پارامتری تعریف می‌شود که میزان نامناسب بودن یک نقطه برای حفر چاه است. در این بحث این پارامتر را با  $r$  نمایش می‌دهیم. روش ساخت این پارامتر به این صورت است که با استفاده از قانون‌های زبانی سامانه فازی مواردی را که سبب عدم قطعیت تابع هدف می‌شوند در  $r$  گنجانده می‌شوند و با اعمال این پارامتر در تابع سود، تابع جدید ساخته می‌شود. با توجه به مطالب گفته شده تابع هدف جدید به صورت زیر در خواهد آمد:

$$f(p) = CNPV = -(1-r)NPV \quad (4)$$

عامل‌هایی که بر روی  $r$  تأثیرگذارند عبارتند از: عدم قطعیت در مدل عددی، ترجیح‌هایی را که انتخاب‌گر در مسئله اعمال می‌نماید و دید مهندسی در مورد تعیین نقطه‌ی بهینه.

تمامی این عامل‌ها توسط قانون‌های زبانی فازی در تعیین پارامتر  $r$  تأثیرگذارند. برای بیشتر روشن شدن مطلب عامل دوم را در نظر بگیرید.

(۱) Spread constant

تمام ورودی‌ها و خروجی شبکه‌ی عصبی در بازه  $[1,0]$  نرمالیزه شد. همچنین میزان ثابت گسترش<sup>(۱)</sup> برای شبکه‌ی عصبی RBF برابر با ۱ در نظر گرفته شد.

### محاسبه‌ی تابع هدف جهت انجام عملیات بهینه‌سازی

در یک پروژه‌ی تعیین محل مکان چاه‌ها، میزان درآمد‌ها، همان میزان تولید از چاه‌ها بوده و میزان هزینه‌ها مربوط به هزینه‌های حفاری، هزینه‌های مربوط به امکانات سرچاهی، هزینه‌های مربوط به دکل حفاری، هزینه‌های انتقال و... می‌باشد. بعد از محاسبه‌ی همه‌ی این مقادیر در بازه‌های زمانی مشخص، همه‌ی مقادیر به زمان حال برگردانده شده و تابع هدف اولیه که همان تابع سود به زمان حال برگردانده شده (NPV) است برای این مسئله ساخته می‌شود. در شکل ۵ نحوه توزیع هزینه‌ها و درآمد‌ها در طول پروژه نمایش داده شده است.

$$NPV = \sum_{j=1}^n (B_j - C_j)(1+i)^{-j} \quad (1)$$

حال اگر بازه‌های زمانی را بسیار کوچک در نظر بگیریم آنگاه  $n$  به سمت بینهایت میل کرده و مجموع بالا به انتگرال تبدیل می‌شود. تابع هدف اولیه برای مسئله‌ی مکان‌یابی چاه‌های تزریق آب که در این پژوهش استفاده شد به صورت زیر است:

$$f(p) = \text{Cost} - \int_0^T \left\{ \sum_{\text{prod.wells}} [c_w q_w^-(t) - c_{w,\text{diep}} q_w^-(t)] - \sum_{\text{inj.wells}} c_{w,\text{inj}} q_w^+(t) \right\} (1+r)^{-t} dt \quad (2)$$

شایان ذکر است که تابع بالا قرینه‌ی NPV است. انتخاب این تابع به این علت بوده است که الگوریتم بهینه‌سازی مورد نظر بر اساس کمینه‌سازی عمل می‌کند نه بر اساس بیشینه‌سازی.

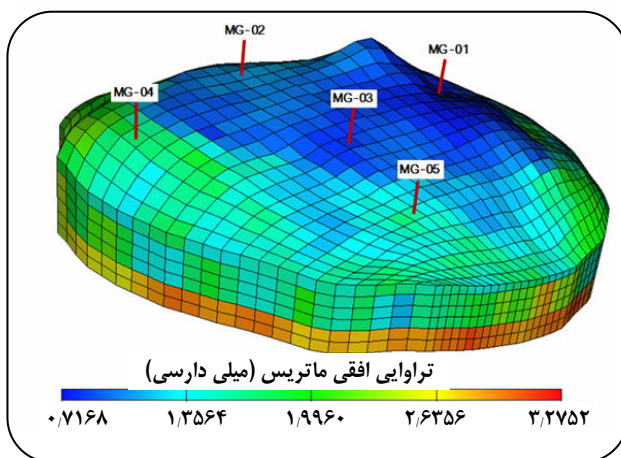
$$NPV = -f(p) \quad (3)$$

مشخص است که مدل عددی که مسئله‌ی تعیین مکان چاه به کمک آن حل می‌شود، وابسته به داده‌هایی است که ناقص بوده و پیش‌بینی مدل عددی با عدم قطعیت همراه است. بهینه‌سازی در چنین حالتی که عدم قطعیت وجود دارد، دارای پیچیدگی بسیاری است و یک جواب کلی مشخص وجود نخواهد داشت. با توجه به داده‌های موجود، آنچه انتظار می‌رود به دست آید یک انتخاب درست با توجه به ریسک و عدم قطعیتی است که همراه

(۲) Fuzzy logic

جدول ۱- داده‌های عمومی مخزن شبیه‌سازی شده.

ترکدار و اشباع	نوع مخزن
آب، نفت و گاز	فازهای موجود
۱ اکتبر ۱۹۹۹	شروع تولید
۹۰۰	عمق مبنا (ft)
۱۹۵۰	سطح تماس آب و نفت (ft)
۹۰۰	سطح تماس گاز و نفت (ft)
۴۱۰۰	فشار اولیه (psi)
۵	تعداد چاه‌های تولیدی



شکل ۶- شکل عمومی مخزن (توزیع نفوذپذیری).

فضای جستجو می‌شود و در نتیجه می‌توان برای هر مکان چاه ممکن شبیه‌سازی را انجام داد. این کار جامع برای این مسئله با اجرای شبیه‌سازی برای تمام حالت‌های ممکن که یک چاه تزریق می‌تواند اختیار کند، یعنی تمام بلوک‌های فعال در مدل شبیه‌سازی، انجام پذیرفت.

تعداد شبیه‌سازی‌های انجام شده در این مسئله برابر بوده است با:

$$750 = 30 \times (\text{تعداد بلوک‌ها در راستای } z) \times 25 \times (\text{تعداد بلوک‌ها در راستای } i)$$

پس از عملیات شبیه‌سازی، NPV معادل برای هر یک از حالت‌ها محاسبه شد، همچنین توسط سیستم فازی طراحی شده اثر عدم قطعیت در NPV محاسبه شده، داده شد و مقدار تابع هدف برای هر یک از حالت‌های ممکن محاسبه شد. فرایند تعیین آرایش چاه تزریقی در این مسئله در شکل ۷ نشان داده شده است.

برخی از ترجیح‌هایی که برای مکان حفر چاه‌های جدید در نظر گرفته می‌شود به این صورت است که این نقطه‌ها در درون دره‌ها یا بر روی کوه‌ها نباشد، یا اگر یک قسمت از مخزن زیر شهری واقع است نقطه‌های جدید نباید در زیر شهر قرار نگیرد. تأثیر این عامل‌ها با استفاده از قانون‌های فازی در  $r$  گنجانده شده و بر روی تابع هدف اعمال می‌شود. با توجه به معادله‌ی (۴) هر چه میزان  $r$  بیشتر باشد  $r-1$  میزان کمتری شده و میزان تابع هدف جدید مقدار کمتری خواهد شد و بر عکس.

برای مثال چند نمونه از قانون‌های فازی در زیر آمده است:

- اگر NPV بالا و فاصله از چاه‌ها زیاد و فاصله از مرزها زیاد باشد، آنگاه میزان  $r$  بسیار کم خواهد شد.
  - اگر NPV بالا و فاصله از چاه‌ها کم و ضخامت مخزن زیاد باشد، آنگاه میزان  $r$  متوسط خواهد شد.
  - اگر NPV کم و فاصله از چاه‌ها کم و میزان نفوذ پذیری کم و ضخامت مخزن کم باشد، آنگاه میزان  $r$  زیاد خواهد شد.
- حال پس از ساخته شدن تابع جدید این تابع به عنوان تابع هدف به بهینه‌ساز داده می‌شود تا نقاط بهینه محاسبه شوند.

### توصیف مسئله

در این پژوهش هدف نهایی بهینه کردن مکان چاه‌های تزریق آب است. برای شبیه‌سازی مخزن، از شبیه‌ساز Eclipse100 (شبیه‌ساز نفت سیاه) استفاده شده است. بهینه‌سازی و همچنین انجام عملیات مکان‌یابی در محیط نرم‌افزار MATLAB و از طریق ارتباط این نرم‌افزار با شبیه‌ساز Eclipse صورت می‌پذیرد. الگوریتم بهینه‌سازی مورد استفاده در این پروژه الگوریتم HGA است که در محیط نرم‌افزار MATLAB پیاده‌سازی شده است. برای انجام مطالعات، از داده‌های بخشی از یکی از مخازن غربی ایران استفاده شده است. مدل استفاده شده، در شکل ۶ نشان داده شده است. برخی از ویژگی‌های این مخزن در جدول‌های ۱ تا ۵ آورده شده است.

### نتیجه‌ها و بحث

#### آزمایش کنترل شده‌ی ۱

در ابتدا، الگوریتم HGA برای بهینه کردن مکان یک چاه تزریق آب با شدت جریان مشخص (STB/D) ۱۵۰۰۰ به کار گرفته شد. ثابت در نظر گرفتن شدت جریان تزریق موجب کوچک‌تر شدن

جدول ۲- مشخصات چاه‌های مخزن شبیه‌سازی شده.

نوع	بازه مشبک کاری (عمودی) <sup>(۱)</sup>		بازه مشبک کاری (اندازه‌گیری شده) <sup>(۲)</sup>		عمق کل <sup>(۳)</sup>		j	i	ارتفاع صفحه دوار <sup>(۴)</sup>	چاه
	تا	از	تا	از	(ftss)	(ftdd)				
	(ftss)	(ftss)	(ftdd)	(ftdd)					ft	
عمودی	۱۲۸۰	۱۱۳۵	۲۵۷۵	۲۴۳۰	۱۲۸۰	۲۵۷۵	۱۰	۲۱	۱۲۹۵	MG-۰۱
عمودی	۱۴۱۰	۱۱۶۰	۲۶۴۵	۲۳۹۵	۱۴۱۰	۲۶۴۵	۵	۱۲	۱۲۳۵	MG-۰۲
افقی	۱۱۷۰	۱۱۷۰	۲۹۳۰	۲۶۲۰	۱۶۸۰	۲۹۳۰	۱۳	۱۱،۱۲	۱۲۵۰	MG-۰۳
عمودی	۱۱۷۰	۱۱۳۵	۲۵۲۵	۲۴۱۰	۱۲۵۰	۲۵۲۵	۷	۴	۱۲۶۰	MG-۰۴
عمودی	۱۱۷۵	۱۱۴۰	۲۵۸۰	۲۴۶۰	۱۳۰۰	۲۵۸۰	۱۹	۱۰	۱۲۶۵	MG-۰۵

1) True Vertical Depth, 2) Measured Depth, 3) Total Depth, 4) Rotary table elevation (RTE)

جدول ۳- مسیر چاه MG-03.

توضیح	عمق واقعی	عمق اندازه‌گیری شده	y	x
	(ft)	(ft)	(ft)	(ft)
نقطه انحراف از عمود <sup>(۱)</sup>	۸۰۰	۸۰۰	۳۲۲۱۱۱۰	۷۱۵۷۱۸
	۹۲۰	۹۲۵	۳۲۲۱۱۱۰	۷۱۵۷۵۳
	۹۹۰	۱۰۱۰	۳۲۲۱۱۱۰	۷۱۵۸۰۱
	۱۰۰۵	۱۰۳۰	۳۲۲۱۱۱۰	۷۱۵۸۱۴
	۱۰۵۰	۱۰۹۰	۳۲۲۱۱۱۰	۷۱۵۸۵۴
	۱۱۴۰	۱۱۷۰	۳۲۲۱۱۱۰	۷۱۵۹۱۷
نقطه شروع طول افقی چاه	۱۱۷۰	۱۳۷۰	۳۲۲۱۱۱۰	۷۱۶۱۰۴
	۱۱۷۰	۱۶۸۰	۳۲۲۱۱۱۰	۷۱۶۴۱۴

(1) Kick of Point (KOP)

جدول ۴- خلاصه داده‌های PVT.

پارامتر	واحد	آزاد سازی جزئی
فشار نقطه حباب	psi	۳۰۵۷
چگالی نفت در شرایط استاندارد	g/cc	۰،۸۶۲۴
چگالی سیال مخزن در نقطه حباب	g/cc	۰،۷۰۴۸
نسبت گاز به نفت در شرایط استاندارد	SCF/STB	۸۵۰
ضریب انبساط حجمی نفت در نقطه حباب	rb/STB	۱،۴۵۳۴

جدول ۵ - ویژگی‌های آب و سنگ در فشار ۴۱۰۰ psi.

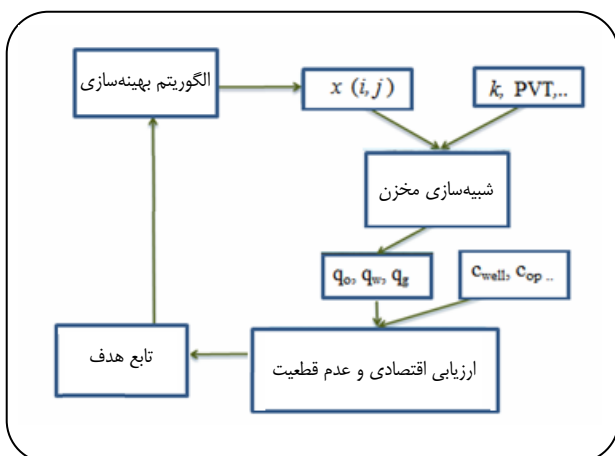
$P_{res}$	$B_w$	$C_w$	$\mu_w$	$C_{rock}$
psi	rb/STB	1/psi	cp	1/psi
۴۱۰۰	۱٫۰۱	$۲٫۱ \times ۱۰^{-۶}$	۰٫۹	$۱٫۲ \times ۱۰^{-۶}$

جدول ۶ - پارامترهایی که برای محاسبه NPV در نظر گرفته شده است.

مقدار	پارامتر
۱۰	نرخ کاهش ارزش پول، %
۲۵	قیمت نفت، \$/bbl
۳	قیمت گاز، \$/MSCF
۱	هزینه دفع آبهای تولیدی، \$/bbl
۴۰۰۰۰	هزینه عملیاتی، \$/day
۲۰۰۰۰۰۰	هزینه چاه، \$/well
۵۰۰۰۰۰۰	هزینه‌های سرمایه‌ای، \$

جدول ۷ - متوسط و انحراف معیار تعداد شبیه‌سازی‌ها و درصد موفقیت الگوریتم در یافتن نقطه بهینه: الگوریتم ژنتیک (GA)، الگوریتم پلی توپ (P)، شبکه‌ی عصبی (NN).

GA+P+NN	GA+P	GA	
۴۹	۵۱	۱۰۳	متوسط
۴۳٫۷	۴۴٫۴	۸۲٫۲	انحراف معیار
۹۵	۹۴	۸۴	درصد موفقیت



شکل ۷ - فرایند کلی تعیین آرایش چاه تزریقی.

همچنین پارامترهایی که برای محاسبه NPV در نظر گرفته شده است، در جدول ۶ آورده شده است.

پس از انجام تمامی ۷۵۰ شبیه‌سازی و محاسبه‌ی تابع هدف مربوط به این ۷۵۰ نقطه، تمامی داده‌ها در جدولی ذخیره شد. با نگاهی به جدول به‌طور کامل مشخص است که تابع هدف یک تابع نوسانی است. روش‌های بر پایه مشتق (کلاسیک) در رسیدن به نقطه‌ی بیشینه مطلق در این حالت با مشکل بسیاری مواجه‌اند و اغلب نمی‌توانند به این نقطه همگرا شوند. نقطه‌ی بیشینه مطلق در این مسئله در بلوک (۱۱،۹) واقع شده است.

این نکته قابل توجه است که بعضی از مکان‌های چاه تزریق سبب زیان‌دهی (CNPV مثبت) می‌شوند. داشتن چنین جدولی این امکان را فراهم می‌آورد که بتوانیم آنالیز حساسیت را بدون انجام شبیه‌سازی‌های بیشتر انجام دهیم. در واقع وقتی الگوریتم HGA اجرا می‌شود مقدار تابع هدف لازم در هر نقطه از روی جدولی که پیش از این تهیه شده خوانده می‌شود و نیازی به انجام شبیه‌سازی نیست. اگرچه مدل ما ساده است ولی این مدل به علت امکان‌پذیر بودن انجام شبیه‌سازی‌های کامل در ابتدا، این امکان را فراهم می‌کند تا بتوان عملکرد برنامه را با تنظیم پارامترهای آن تا حدود زیادی کنترل کرد. پس از ساخته شدن جدول تابع هدف توسط انجام شبیه‌سازی‌های جامع، الگوریتم بهینه‌سازی با آرایش‌های گوناگون برای این مسئله اجرا شده تا بتوان دید مناسبی نسبت به انتخاب روش بهینه‌سازی و پارامترهای این روش پیدا کرد. به این منظور برای هر حالت ۱۰۰ بار الگوریتم مربوطه اجرا شد و میانگین و انحراف معیار تعداد شبیه‌سازی‌های مورد نیاز برای رسیدن به جواب بهینه در هر حالت محاسبه شد.

زمان کل شبیه‌سازی ۱۷ سال بوده است که در واقع به میزان ۹ سال بعد از شروع تزریق شبیه‌سازی ادامه داشته است. از قانون‌های سرانگشتی برای مشخص کردن پارامترهای الگوریتم ژنتیک استفاده شد.

عملکرد ترکیب‌های مختلف از الگوریتم‌های ژنتیک و پلی توپ و شبکه‌ی عصبی RBF با هم مقایسه شده است. برای تمام این ترکیب‌ها حد بالای ۲۰۰ شبیه‌سازی و ۵۰ نسل انتخاب شده است. متوسط و انحراف معیار تعداد شبیه‌سازی‌هایی که برای رسیدن به نقطه بهینه مورد نیاز بوده، برای تمام حالات در جدول ۷ آورده شده است.

در بعضی از حالت‌های الگوریتم قادر نبوده است که در طول ۲۰۰ شبیه‌سازی و ۵۰ نسل به نقطه‌ی بهینه همگرا شود. به همین منظور



انجام شد و مدل جامع برای این آزمایش ساخته شد. تعداد شبیه‌سازی‌های انجام شده در این آزمایش برابر بوده است با:

$$30 \times (\text{تعداد بلوک در راستای } z) \times 25 (\text{تعداد بلوک در راستای } i) = 6000 = (\text{تعداد شدت جریان تزریق})$$

پس از به کار بردن اثر عدم قطعیت مقدار تابع هدف نیز در هر یک از این ۶۰۰۰ حالت محاسبه شد. سپس همانند آزمایش اول ترکیب‌های مختلف از الگوریتم‌های ذکر شده اجرا شد. در اینجا نیز برای هر حالت ۱۰۰ بار الگوریتم مربوطه اجرا شد و میانگین و انحراف معیار تعداد شبیه‌سازی‌های مورد نیاز برای رسیدن به جواب در هر حالت محاسبه شد. زمان کل شبیه‌سازی ۱۷ سال بوده است که در واقع به میزان ۹ سال پس از زمان شروع تزریق شبیه‌سازی ادامه داشته است. از قانون‌های سرانگشتی برای مشخص کردن پارامترهای الگوریتم ژنتیک استفاده شده است. برای تمام ترکیب‌های گوناگون، حد بالای ۳۰۰ شبیه‌سازی و ۱۰۰ نسل انتخاب شده است. متوسط و انحراف معیار تعداد شبیه‌سازی‌هایی که برای رسیدن به نقطه بهینه مورد نیاز بوده است برای تمام حالت‌ها و همچنین درصد موفقیت هر الگوریتم در جدول ۸ آورده شده است. با توجه به جدول ۸، نتیجه‌هایی که از این آزمایش به دست می‌آید منطبق با آزمایش اول است. در این آزمایش، همان‌طور که انتظار می‌رفت، شبکه عصبی اثر بیشتری بر روی بازدهی الگوریتم نسبت به آزمایش اول داشته است.

#### بهینه‌سازی مکان چند چاه تزریقی به همراه شدت جریان تزریق هر یک از چاه‌ها

آرایش مکانی و همچنین شدت جریان تزریق تا حداکثر چهار چاه توسط الگوریتم HGA بهینه‌سازی شد. در این حالت‌ها انجام شبیه‌سازی‌های جامع در ابتدا، به علت بزرگ بودن فضای جستجو (جدول ۹)، عملی نیست. همانند مسئله‌ی آزمایش دوم برای انجام عملیات بهینه‌سازی شدت جریان تزریق به ۷ بازه بین ۰ تا ۲۸۰۰۰ STB/D گسسته سازی شد که در واقع با دقت ۴۰۰۰ STB/D می‌توان شدت جریان تزریق را بهینه کرد. اندازه‌ی فضای جستجو که برای این مسئله‌ها در نظر گرفته شده، در جدول ۹ نشان داده شده است. همچنین برای تمام مسئله‌های حد بالای ۵۰۰ شبیه‌سازی انتخاب شده است. زمان کل شبیه‌سازی ۱۷ سال بوده که در واقع به میزان ۹ سال پس از زمان شروع تزریق شبیه‌سازی ادامه داشته است. نتیجه‌های به دست آمده در جدول ۱۰ نشان داده شده است. در این جدول آرایش مکانی چاه‌ها،

درصد موفقیت هر یک از الگوریتم‌ها برای رسیدن به جواب بهینه نیز در جدول ۷ آورده شده است. با توجه به جدول ۷ مشخص است که الگوریتم ژنتیک ساده به خوبی نتوانسته به جواب بهینه همگرا شود. ترکیب کردن روش پلی‌توپ و الگوریتم ژنتیک به میزان بسیار زیادی بازدهی جستجو را افزایش داده و به طور متوسط ۵۱ شبیه‌سازی برای رسیدن به نقطه بهینه مورد نیاز است. همچنین درصد شکست خوردن این الگوریتم نسبت به الگوریتم ژنتیک ساده بسیار کم بوده است و تنها در ۶ اجرا از ۱۰۰ اجرا این الگوریتم نتوانسته به جواب بهینه همگرا شود. همچنین به کارگیری شبکه عصبی RBF بازدهی الگوریتم را افزایش داده است ولی همان‌طور که مشخص است این افزایش بازدهی مانند حالت قبل (افزودن پلی‌توپ به الگوریتم بهینه‌سازی) چشمگیر نیست. تعداد متوسط شبیه‌سازی‌های مورد نیاز در این حالت ۴۹ و درصد موفقیت ۹۵ درصد است. درست است که در این مسئله شبکه‌ی عصبی RBF نتوانسته به میزان زیادی بازدهی الگوریتم را افزایش دهد، ولی اگر کمی عمیق‌تر به مسئله نگاه کنیم، این نکته قابل توجیه است. همان‌طور که روشن است، در نسل‌های اولیه وقتی که تعداد محدودی شبیه‌سازی انجام شده است، داده‌های کافی برای آموزش شبکه‌ی عصبی موجود نیست و انتظار نمی‌رود که شبکه بتواند تخمین درستی از تابع هدف داشته باشد، ولی با افزایش تعداد نسل‌ها و انجام شبیه‌سازی‌های بیشتر این مشکل تا حدودی برطرف می‌شود. در مسئله‌ای که در اینجا بررسی شده، الگوریتم پس از تعداد اندکی از نسل‌ها به جواب بهینه می‌رسد و تعداد شبیه‌سازی‌های مورد نیاز برای رسیدن به جواب بهینه اندک است. در واقع قبل از این که یک پایگاه داده مناسب برای آموزش شبکه عصبی ساخته شود، الگوریتم به جواب بهینه همگرا می‌شود. در نتیجه انتظار می‌رود که اگر مسئله ما پیچیده‌تر شود، سهم شبکه‌ی عصبی در بهبود بازدهی الگوریتم بیشتر خواهد بود. این مسئله در آزمایش بعدی که در ادامه توضیح داده خواهد شد نیز تا حدودی دیده می‌شود.

#### آزمایش کنترل شده‌ی ۲

در این آزمایش علاوه بر مکان چاه تزریق، شدت جریان تزریق نیز به عنوان متغیر مستقل در عملیات بهینه‌سازی در نظر گرفته شده است. برای انجام عملیات بهینه‌سازی شدت جریان تزریق به ۷ بازه بین ۰ تا ۲۸۰۰۰ STB/D گسسته‌سازی شد که در واقع با دقت ۴۰۰۰ STB/D می‌توان شدت جریان تزریق را بهینه کرد. در این آزمایش نیز همانند آزمایش اول برای تمام حالت‌های ممکن شبیه‌سازی

جدول ۸ - متوسط و انحراف معیار تعداد شبیه سازی‌ها و درصد موفقیت الگوریتم در یافتن نقطه‌ی بهینه: الگوریتم ژنتیک (GA)، الگوریتم پلی توپ (P)، شبکه‌ی عصبی (NN).

متوسط	GA	GA+P	GA+P+NN
۱۶۴	۱۰۹	۹۷	
۹۳٫۱	۵۷٫۱	۴۹٫۸	
۷۵	۹۰	۹۲	

جدول ۹ - اندازه‌ی فضای جستجو.

تعداد چاه‌های تزریق	اندازه فضای جستجو
۱	۶۰۰۰
۲	۳۶۰۰۰۰۰
۳	۲۱۶۰۰۰۰۰۰۰
۴	۱۳۹۶۰۰۰۰۰۰۰۰۰

جدول ۱۰ - تعداد چاه‌های تزریقی (ninj)، دبی تزریق بر واحد MSTB/D، تعداد شبیه سازی‌ها (nsim) و CNPV افزوده نسبت به حالت بدون تزریق بر واحد MM\$.

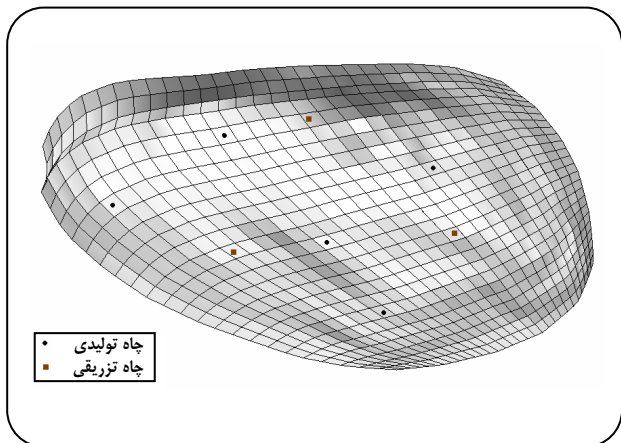
q <sub>4</sub>	(i <sub>4</sub> ,j <sub>4</sub> )	q <sub>3</sub>	(i <sub>3</sub> ,j <sub>3</sub> )	q <sub>2</sub>	(i <sub>2</sub> ,j <sub>2</sub> )	q <sub>1</sub>	(i <sub>1</sub> ,j <sub>1</sub> )	میزان افزایش CNPV	nsim	ninj
								۰	۱	حالت پایه
						۲۰	(۱۴،۸)	۱۰۲	۱۰۸	چاه ۱
				۲۴	(۱۴،۱۷)	۲۴	(۱۰،۶)	۱۶۹	۱۶۳	چاه ۲
		۱۶	(۱۵،۱۹)	۲۰	(۵،۱۶)	۲۰	(۱۲،۷)	۱۹۸	۱۹۸	چاه ۳
۲۰	(۱۶،۲۰)	۲۰	(۱۵،۸)	۲۸	(۶،۱۶)	۲۴	(۷،۷)	۱۹۳	۲۱۱	چاه ۴

### نتیجه‌گیری


یک روش ترکیبی (هیبریدی) از ترکیب الگوریتم ژنتیک، روش پلی توپ و تابع نماینده شبیه‌ساز ارایه شد. اجزای این روش هیبریدی ضعف‌های یکدیگر را جبران کرده و در نتیجه الگوریتم هیبریدی به دست آمده، عملکرد بسیار بهتری نسبت به هر یک از اجزا در حالت منفرد دارد.

از شبکه‌ی عصبی مصنوعی مبتنی بر توابع پایه شعاعی برای ساخت تابع نماینده شبیه‌ساز استفاده شد. از آنجا که تابع هدف نوسانی است و تعداد ابعاد مسئله می‌تواند بالا باشد، شبکه‌ی عصبی می‌تواند گزینه بسیار مناسبی باشد. مشکل اصلی که در استفاده از شبکه‌ی عصبی وجود دارد مشکل طراحی و آموزش آن است. همان‌طور که گفته شد تابع نماینده شبیه‌ساز در طول اجرای برنامه، تولید و کالیبره می‌شود. یعنی در طول اجرای برنامه، وقتی تعداد داده‌ها افزایش می‌یابد، باید داده‌های جدید به شبکه آموزش داده شوند و تابع هدف کالیبره شود. در چنین حالتی شبکه‌ی عصبی مصنوعی مبتنی بر توابع پایه شعاعی می‌تواند چاره‌ساز باشد.

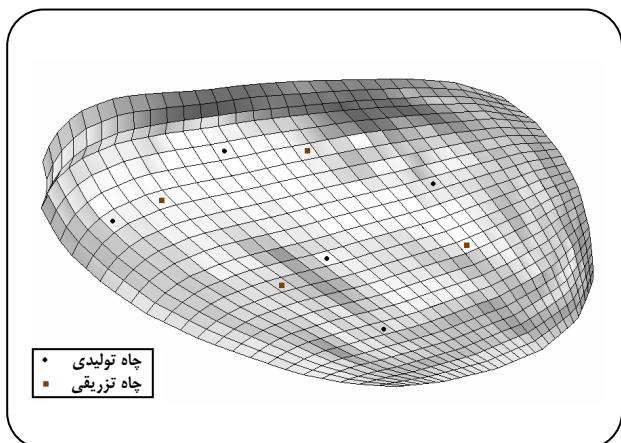
شدت جریان تزریق چاه‌ها و همچنین CNPV افزوده نسبت به حالت بدون تزریق که از این آزمایش به دست آمده، نشان داده شده است. مکان‌های چاه‌های تولیدی موجود و چاه‌های تزریق پیشنهاد شده توسط الگوریتم بهینه‌سازی در شکل‌های ۸ تا ۱۱ نشان داده شده است. از روی نتیجه‌های جدول ۱۰ مشخص است که در تمام حالت‌هایی که تزریق آب در این مخزن انجام گیرد سود می‌کنیم و حالت بهینه حالتی است که سه چاه تزریقی داشته باشیم. با توجه به شکل‌های ۸ تا ۱۱ به نظر می‌رسد که در تمام حالت‌ها یک مهندس مخزن، مخالفتی با مکان چاه‌ها و دبی تزریق هر یک از آن‌ها که توسط الگوریتم بهینه‌سازی پیشنهاد شده، نداشته باشد. اما این نکته باید در نظر گرفته شود که برخلاف یک انسان، عملیات بهینه‌سازی قادر است تمام اثرهایی را که ممکن است عوامل مختلف روی مسئله داشته باشند را لحاظ کند. بعضی از این عوامل عبارتند از: ویژگی‌های سنگ و سیال، فیزیک جریان در محیط متخلخل، پارامترهای اقتصادی و غیره. بیشتر این عامل‌ها، اثرهای ضمنی و غیرخطی بر روی تابع هدف دارند که تشخیص اثرهای آن‌ها توسط انسان امری دشوار به نظر می‌رسد.



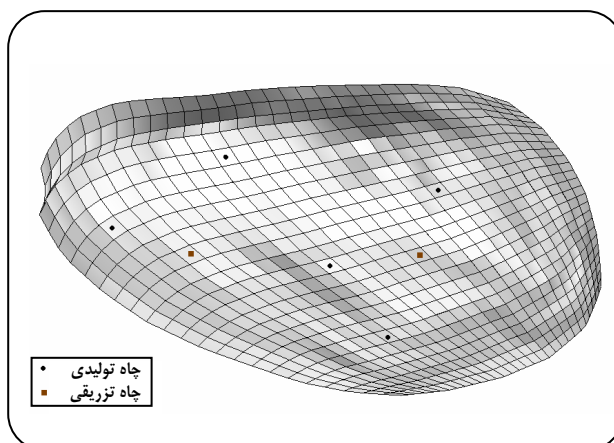
شکل ۱۰- مکان بهینه‌ی چاه‌ها برای مسئله‌ی مکان‌یابی سه چاه تزریق.



شکل ۸- مکان بهینه‌ی چاه برای مسئله‌ی مکان‌یابی یک چاه تزریق.



شکل ۱۱- مکان بهینه‌ی چاه‌ها برای مسئله‌ی مکان‌یابی چهار چاه تزریق.



شکل ۹- مکان بهینه‌ی چاه‌ها برای مسئله‌ی مکان‌یابی دو چاه تزریق.

برای رسیدن به نقطه‌ی بهینه را تا حد زیادی کاهش دهد. در آزمایش دوم که شدت جریان تزریق نیز جزء متغیرهای بهینه‌سازی مد نظر گرفته شد، این قضیه تأیید شد.

اگرچه در این پژوهش مسئله‌ی مکان‌یابی چاه مورد بررسی قرار گرفت، ولی باید در نظر داشت که بسیاری از مسئله‌های مهندسی نفت را می‌توان با ترکیب بهینه‌ساز و شبیه‌ساز حل نمود. تنها باید ابزار درست و مناسبی را برای الگوریتم بهینه‌سازی با توجه به فیزیک مسئله انتخاب کنیم. همچنین با اندکی تغییر در تابع هدف جدید پیشنهاد شده، می‌توان از این تابع در گستره‌ی بسیاری از مسئله‌های مهندسی بهره گرفت.

تاریخ دریافت: ۱۳۸۸، ۷، ۲۴ ؛ تاریخ پذیرش: ۱۳۸۹، ۴، ۲۸

طراحی این شبکه بسیار آسان است و عملیات آموزش آن نیز با مشکل زیادی مواجه نیست.

برای اینکه به مسئله با دید مهندسی بهتری نگاه شود، اثرهای نبود قطعیت در داده‌ها، ترجیح‌های تصمیم‌گیرنده و دید مهندسی نیز در انتخاب نقطه‌ی بهینه برای مکان چاه‌ها در نظر گرفته شد. به علت قابلیت‌های بسیار منطبق فازی، در این پروژه با استفاده از سیستم استنتاج فازی یک تابع هدف جدید برای مسئله مکان‌یابی چاه ارایه شد.

الگوریتم HGA برای مکان‌یابی چاه‌های تزریق در مخزن ذکر شده به کار گرفته شد. جواب‌های حاصل از HGA برای این مسئله جواب‌های بدیهی بودند. آزمایش اول که در آن هدف انتخاب مکان یک چاه تزریق با شدت جریان تزریقی ثابت بود، نشان داد که HGA قادر است که تعداد شبیه‌سازی‌های مورد نیاز

## مراجع

- [1] Rian D.T., Hage A., Automatic Optimization of Well Locations in a North Sea Fractured Chalk Reservoir Using a Front Tracking Reservoir Simulator, *SPE 28716*, Presented at the SPE International Petroleum & Exhibition of Mexico, Veracruz, Mexico, October 10-13, (1994).
- [2] Beckner B.L., Song X., Field Development Planning Using Simulated Annealing - Optimal Economic Well Scheduling and Placement, *SPE 30650*, Presented at the SPE Annual Technical Conference & Exhibition, Dallas, Texas, October 22-25, (1995).
- [3] Bittencourt A.C., Horne R.N., Reservoir Development and Design Optimization, *SPE 38895*, Presented at the SPE Annual Technical Conference & Exhibition, San Antonio, Texas, October 5-8, (1997).
- [4] Guyaguler B., Horne R., "Optimization of well placement," PhD thesis, University of Stanford, Technical Report, (2002).
- [5] Rogers L.L., Dowla F.U., Optimal Groundwater Remediation Using Artificial Neural Networks with Parallel Solute Transport, *Water Resources Research*, **30**(2), p 457 (1994).
- [6] Aanonsen S.I., Eide A.L., Holden L., Aasen J.O., Optimizing Reservoir Performance under Uncertainty with Application to Well Location, *SPE 30710*, Presented at the SPE Annual Technical Conference & Exhibition, Dallas, Texas, October 22-25, (1995).
- [7] Johnson V.M., Rogers L.L., Applying Soft Computing Methods to Improve the Computational Tractability of a Subsurface Simulation-Optimization Problem, *Journal of Petroleum Science and Engineering*, Special issue on Soft Computing, p. 153 (2001).
- [8] Goldberg D.E., "Genetic Algorithms in Search, Optimization, and Machine Learning," Addison-Wesley, Reading, MA, (1989).
- [9] Nelder J., Mead R., A Simplex Method for Function Minimization, *Computer Journal*, **7**, p 308 (1965).
- [10] Anderson J.A., "An Introduction to Neural Networks", MIT Press, Cambridge, MA, (1995).
- [11] Zadeh L.A., Fuzzy Sets, Information and Control, *World Scientific*, **8**, p. 338 (1965).