

# طراحی نمونه برداری چند هدفه برای واسنجی مدل شبکه توزیع آب با استفاده از الگوریتم ژنتیک و شبکه عصبی

عبدالله اردشیر<sup>۲</sup>

کوروش بهزادیان<sup>۱</sup>

(دریافت ۸۶/۲۱ پذیرش ۸۶/۱۱/۱)

## چکیده

در این مقاله یک مدل بهینه سازی چندهدفه نوین برای انتخاب نقاط بهینه در شبکه توزیع آب به منظور نصب ابزارهای اندازه گیری فشار ارائه می شود. داده های فشارسنجی جمع آوری شده در نقاط منتخب (بهینه) می تواند بعداً برای واسنجی مدل مورد استفاده قرار گیرد. توابع هدف، افزایش دقت پیش بینی مدل واسنجی شده و کاهش هزینه کل نمونه برداری می باشند. به منظور کاهش زمان اجرا، مدل بهینه سازی چندهدفه با تلفیقی از الگوریتم ژنتیک و شبکه عصبی سازگار توسعه یافته است. شبکه عصبی پس از پیشرفت چند نسل اولیه الگوریتم ژنتیک به صورت اولیه آموزش دیده و پس از تولید تعداد مشخصی از جوابهای تحلیل شده با مدل کامل به صورت دوره ای در طی الگوریتم ژنتیک آموزش مجدد داده می شود تا به روز گردد. شبکه عصبی آموزش دیده در طی پیشرفت الگوریتم ژنتیک جایگزین محاسبه تابع هدف بخشی از کروموزوم های یک نسل می گردد. استفاده از حافظه نهانی سبب جلوگیری از ارزیابی تابع هدف جوابهای تکراری در طی الگوریتم می شود. جواب مدل بهینه سازی به صورت مجموعه نقاط غیرپست (رویه بهینه پارتو) نسبت به دو تابع هدف به دست می آید. نتایج نشان می دهد تلفیق شبکه های عصبی مصنوعی در مدل بهینه سازی الگوریتم ژنتیک برای برآورد تابع هدف بخشی از جوابها، کاهش چشمگیری در زمان اجرا دارد و می تواند در کاهش زمان اجرای مدل های بهینه سازی با زمان اجرای طولانی بسیار نویدبخش باشد.

**واژه های کلیدی:** طراحی نمونه برداری، شبکه های توزیع آب، واسنجی، الگوریتم ژنتیک، شبکه عصبی.

## Multiobjective Sampling Design for Calibration of Water Distribution Network Model Using Genetic Algorithm and Neural Network

Kourosh Behzadian<sup>1</sup>

Abdollah Ardeshir<sup>2</sup>

(Received Apr. 10, 2007 Accepted Jan. 21, 2008)

### Abstract

In this paper, a novel multiobjective optimization model is presented for selecting optimal locations in the water distribution network (WDN) with the aim of installing pressure loggers. The pressure data collected at optimal locations will be used later on in the calibration of the proposed WDN model. Objective functions consist of maximization of calibrated model prediction accuracy and minimization of the total cost for sampling design. In order to decrease the model run time, an optimization model has been developed using multiobjective genetic algorithm and adaptive neural network (MOGA-ANN). Neural networks (NNs) are initially trained after a number of initial GA generations and periodically retrained and updated after generation of a specified number of full model-analyzed solutions. Trained NNs are replaced with the fitness evaluation of some chromosomes within the GA progress. Using cache prevents objective function evaluation of repetitive chromosomes within GA. Optimal solutions are obtained through pareto-optimal front with respect to the two objective

1. PhD Candidate of Hydraulic Engineering, Department of Civil and Environmental Engineering, Amir Kabir University of Technology, kouroshbehzadian@yahoo.com

2. Assistant Professor, Department of Civil & Environmental Engineering, Amir Kabir University of Technology

۱- کاندیدای دکترای مهندسی آب دانشگاه صنعتی امیرکبیر،

kouroshbehzadian@yahoo.com

۲- استادیار دانشکده عمران و محیط زیست دانشگاه صنعتی امیرکبیر

functions. Results show that jointing NNs in MOGA for approximating portions of chromosomes' fitness in each generation leads to considerable savings in model run time and can be promising for reducing run-time in optimization models with significant computational effort.

**Keywords:** Sampling Design, Water Distribution Network, Calibration, Genetic Algorithm, Neural Network.

## ۱- مقدمه

از آنجایی که دقت واسنجی یک مدل شبکه آبرسانی از لحاظ فنی و اقتصادی بستگی بسیار زیادی به نوع، نحوه، کیفیت و کمیت اطلاعات مورد نظر برای واسنجی مدل دارد، لذا ضروری است نقاطی به عنوان ایستگاههای نمونه برداری انتخاب شود که توجیه مناسبی از لحاظ فنی و اقتصادی داشته باشند. در سالهای اخیر نیز این مسئله توجه محققین شبکه‌های آبرسانی را به خود جلب کرده است [۱]. در طراحی نمونه برداری، مجموعه‌ای از نقاط شبکه آبرسانی برای نصب ابزارهای اندازه‌گیری فشار و جریان انتخاب می‌شوند که پس از اندازه‌گیری، اطلاعات جمع‌آوری شده می‌تواند به منظور واسنجی مدل مورد استفاده قرار گیرد [۲].

در زمینه طراحی نقاط نمونه برداری در شبکه‌های توزیع آب در سالهای اخیر تحقیقات متعددی توسط محققین مختلف انجام گرفته است [۱، ۲، ۳ و ۴]. در عموم روشها، حساسیت نقاط اندازه‌گیری نسبت به پارامترهای واسنجی به‌عنوان معیار انتخاب نقاط بهینه در نظر گرفته می‌شود. بوش و اُبر<sup>۱</sup> در سال ۱۹۹۸ سه روش نسبتاً ساده ولی مؤثر را بر اساس حساسیت نقاط برای طراحی نمونه برداری نقاط پایش پیشنهاد دادند [۴]. این روشها عبارت بودند از: (الف) حداکثر مجموع حساسیت‌ها؛ (ب) مجموع وزنی حساسیت‌ها و (ج) حداکثر نمودن حداقل حساسیت‌ها. جواب مدل‌های مذکور به صورت رتبه‌بندی نقاط برتر می‌باشد. بدین معنی که در هر مرتبه انتخاب نقاط برتر، یک نقطه بهینه (برتر) انتخاب می‌شود و به مجموعه نقاط منتخب قبلی اضافه می‌گردد تا اینکه رتبه‌بندی برای کلیه نقاط انجام شود. این روش با وجود کاربردی بودن، دارای عیب بزرگ عدم تأثیر هم‌زمانی یک مجموعه نقاط انتخابی به صورت با هم در انتخاب نقاط بهینه می‌باشد.

لسنی<sup>۲</sup> و همکاران در سال ۲۰۰۱ یک فرآیند سه مرحله‌ای را برای واسنجی مدل و انتخاب نقاط پایش ارائه دادند که عبارت است از برآورد پارامتر، ارزیابی واسنجی و طراحی نقاط پایش. در گام اول، واسنجی مدل انجام می‌گیرد. در گام دوم ارزیابی واسنجی با استفاده از عدم قطعیت‌های پیش‌بینی محاسبه می‌شود. سپس در گام سوم با توجه به عدم قطعیت‌های موجود، مجموعه نقاط اضافی و همچنین شرایط جدید که می‌تواند موجب بهبود برآورد پارامترها

شود طراحی و انتخاب می‌شوند [۵]. در این رویکرد اگرچه مسئله به صورت جامع مورد بررسی قرار می‌گیرد، اما نیازمند عمل برداشت داده‌ها و اندازه‌گیری در نقاط پایش می‌باشد و عملاً انتخاب پایش پیش از انجام برداشت نمونه برداری نهایی امکان‌پذیر نمی‌باشد.

در یکی از آخرین تحقیقات انجام شده توسط کاپلان<sup>۳</sup> و همکاران در سال ۲۰۰۳ یک مدل الگوریتم ژنتیک چندهدفه برای طراحی نمونه برداری به منظور واسنجی مدل شبکه آبرسانی توسعه داده شد [۳]. در این مدل توابع هدف عبارت بودند از کاهش هزینه نمونه برداری و کاهش عدم قطعیت مدل. برای در نظر گرفتن تابع هدف عدم قطعیت، سه نوع تابع هدف بررسی شد که عبارت‌اند از (الف) حداکثر نمودن ماتریس حساسیت پیش‌بینی مدل نسبت به پارامترهای مدل؛ (ب) حداقل نمودن عدم قطعیت پارامترهای مدل و (ج) حداکثر نمودن دقت پیش‌بینی‌های مدل. آنها نهایتاً به این نتیجه رسیدند که تابع هدف حداکثر نمودن دقت پیش‌بینی فشار مدل واسنجی شده بهتر می‌تواند نشان‌دهنده عدم قطعیت در مدل واسنجی شده باشد. علی‌رغم کامل بودن مدل چند هدفه مذکور، پارامترهای واسنجی مسئله که شامل ضرایب زبری لوله‌ها و نیازهای آبی می‌باشند در این مدل به صورت ثابت در نظر گرفته شده بود. در حالی که در زمان طراحی نقاط نمونه برداری با هدف واسنجی مدل این پارامترها به صورت قطعی مشخص نمی‌باشند.

برای کاهش زمان اجرای مدل، در سالهای اخیر روشهای تغییر یافته<sup>۴</sup> مورد توجه خاصی قرار گرفته‌اند. البته کاربرد این روشها در مدل‌های شبکه‌های آبرسانی چندان فراوان نمی‌باشد. برد<sup>۵</sup> و همکاران در سال ۲۰۰۵ یک مدل تغییر یافته شبکه عصبی برای طراحی بهینه شبکه‌های توزیع آب ارائه نمودند که شبکه عصبی پس از آموزش با تعداد زیادی داده‌های آموزشی در مدل الگوریتم ژنتیک جایگزین بخش شبیه‌سازی مدل که قبلاً توسط نرم افزار EPANET انجام می‌گرفته است می‌شود [۶]. شبکه عصبی مذکور پیش از ورود به مدل بهینه‌سازی، آموزش داده می‌شود که با توجه به عدم آموزش مجدد آن، امکان بروز خطا در طی نسل‌های آینده مدل بهینه‌سازی وجود خواهد داشت. ین و مینسکر<sup>۶</sup> نیز در سال ۲۰۰۶ برای کاهش زمان محاسباتی یک مدل الگوریتم ژنتیک تک هدفه-

<sup>3</sup> Kapelan

<sup>4</sup> Metamodel

<sup>5</sup> Broad

<sup>6</sup> Yan and Minsker

<sup>1</sup> Bush and Uber

<sup>2</sup> Lansley

چنانچه در  $N$  نقطه از شبکه آبرسانی،  $N$  دستگاه فشارسنج با انحراف معیار خطای اندازه‌گیری مشخص  $\sigma_y$  اندازه‌گیری فشار را انجام دهند، عدم قطعیت پارامترهای مدل که به صورت ماتریس کواریانس پارامترهای مدل بیان می‌شود به صورت زیر قابل تعریف می‌باشد [۸]:

$$\text{Cov}_a = \sigma_y^2 \cdot (J^T J)^{-1} \quad (1)$$

که در آن

$J$  ماتریس ژاکوبین مشتقات  $\partial y_i / \partial a_k$  بردار متغیرهای پیش‌بینی در نقاط اندازه‌گیری مورد نظر،  $a$  بردار پارامترهای واسنجی مورد نظر،  $N_0$  تعداد داده‌های اندازه‌گیری در بازه زمانی و مکانی مطابق با نقاط اندازه‌گیری مورد نظر (چنانچه در  $N$  نقطه  $t$  مرتبه در طی شبیه‌سازی دوره گسترش یافته اندازه‌گیری انجام شود خواهیم داشت:  $N_0 = N \times t$ ) و  $N_a$  تعداد پارامترهای واسنجی می‌باشد. میزان انحراف معیار خطای دستگاههای اندازه‌گیری ( $\sigma_y$ ) برابر  $0.1$  متر فرض می‌شود. به بیان دیگر هر یک از عناصر ماتریس ژاکوبین برابر مشتقات جزئی متغیرهای پیش‌بینی نسبت پارامترهای مدل می‌باشد. همچنین عناصر قطری ماتریس  $\text{Cov}_a$  نشان‌دهنده واریانس پارامترهای مدل می‌باشند.

عدم قطعیت متغیرهای پیش‌بینی مدل بر اساس انتشار عدم قطعیت پارامترهای مدل برآورد می‌شوند. بدین ترتیب ماتریس پیش‌بینی کواریانس مدل با توجه به ماتریس کواریانس پارامترها به صورت زیر برآورد می‌شود [۸]:

$$\text{Cov}_z = J_z \cdot \text{Cov}_a J_z^T \quad (2)$$

که در آن

$J_z$  ماتریس ژاکوبین مشتقات  $\partial z_i / \partial a_k$  بردار متغیرهای پیش‌بینی مدل در کلیه نقاط با پتانسیل نصب فشارسنج و  $N_z$  تعداد داده‌های اندازه‌گیری در بازه زمانی و مکانی مطابق کلیه نقاط با پتانسیل نصب فشارسنج می‌باشد. مقادیر عناصر قطری ماتریس  $\text{Cov}_z$  نیز نشان‌دهنده واریانس متغیرهای پیش‌بینی فشار می‌باشند که به نوعی عدم قطعیت متغیرهای پیش‌بینی فشار را نشان می‌دهند. عدم قطعیت پیش‌بینی مدل واسنجی شده به صورت میانگین انحراف معیار متغیرهای پیش‌بینی یعنی مجذور عناصر قطری ماتریس  $\text{Cov}_z$ ، به صورت رابطه زیر تعریف می‌گردد:

$$F_1 = \frac{1}{N_z} \sum_{i=1}^{N_z} \text{Cov}_{z,ii}^{1/2} \quad (3)$$

در این صورت برای هر مجموعه‌ای از نقاط اندازه‌گیری، ماتریس‌های ژاکوبین  $J$  مختلفی تولید می‌شود و بنابراین مقادیر متفاوتی برای  $\text{Cov}_z$  و  $\text{Cov}_a$  به دست می‌آید که به ترتیب

شبکه عصبی را برای طراحی بهینه پایش به منظور کاهش آلودگی آبهای زیرزمینی ارائه دادند. مدل بهینه‌سازی توسعه یافته به صورت تک هدفه با حداقل‌سازی هزینه می‌باشد. شبکه عصبی برای جایگزینی از مدل شبیه‌سازی طولانی مدت آب زیرزمینی کمک می‌گیرد و همچنین به صورت متوالی در داخل حلقه بهینه‌سازی الگوریتم ژنتیک آموزش می‌بیند و به روز می‌شود [۷].

در این مقاله با بهره‌گیری از روش ارائه شده توسط یین و مینسکر یک مدل الگوریتم ژنتیک چندهدفه-شبکه عصبی سازگار<sup>۱</sup> برای طراحی نمونه‌برداری شبکه آبرسانی با هدف واسنجی مدل توسعه می‌یابد. شبکه عصبی پس از پیشرفت چند نسل الگوریتم ژنتیک به صورت اولیه آموزش دیده و در طی پیشرفت الگوریتم ژنتیک به صورت دوره‌ای مجدداً آموزش می‌بیند و به روز می‌شود تا جایگزین محاسبه تابع هدف بخشی از کروموزوم‌های یک نسل گردد. اهداف مدل الگوریتم ژنتیک دوهدفه عبارت‌اند از (الف) حداکثر نمودن دقت نسبی پیش‌بینی فشار مدل واسنجی شده؛ (ب) حداقل نمودن کل هزینه نمونه‌برداری یا تعداد نقاط نمونه‌برداری. همچنین به منظور در نظر گرفتن خطا در برآورد اولیه پارامترهای واسنجی مدل، این پارامترها در مدل پیشنهادی به صورت غیرقطعی و احتمالاتی لحاظ می‌شوند. پس از انتخاب نقاط نمونه‌برداری، دستگاههای فشارسنج در آنها نصب و برداشت داده‌های فشارسنجی انجام خواهد شد که می‌تواند برای واسنجی مدل مورد استفاده قرار گیرد.

## ۲- روش تحقیق

### ۲-۱- بهینه‌سازی در طراحی نمونه برداری

برای مدل‌سازی طراحی نمونه‌برداری با هدف واسنجی مدل فرضیات زیر در نظر گرفته شده است. نوع متغیرهای نمونه‌برداری می‌تواند فشار گرهی، جریان (سرعت) لوله یا هر دو باشد که در اینجا تنها فشار گرهی به عنوان متغیر نمونه‌برداری فرض شده است. نوع پارامتر واسنجی می‌تواند نیازهای آبی، ضرایب زبری لوله‌ها یا ترکیبی از هر دو باشد که هر دو نوع پارامتر در اینجا در نظر گرفته شده است. زمان پایش نیز به صورت شبیه‌سازی دوره‌گسترش یافته روزانه می‌باشد.

اندازه‌گیری دقت پیش‌بینی مدل واسنجی شده وابسته به عدم قطعیت پارامترهای مدل می‌باشد که آن نیز وابسته به میزان خطای اندازه‌گیری در نقاط پایش می‌باشد. بنابراین نقاط اندازه‌گیری که کمترین عدم قطعیت را روی پارامترها و پیش‌بینی‌های مدل ایجاد کنند بهترین نقاط نمونه‌برداری می‌باشند [۵]. بر اساس این معیار

<sup>1</sup>Multi Objective Genetic Algorithm Artificial Neural Network (MOGA-ANN)

بتانسیل نصب فشارسنج در شبکه کمتر باشد ( $N_{max} \leq N_{ml}$ ). از طرف دیگر حداکثر تعداد دستگاههای قابل نصب، شاخص بودجه نمونه برداری را نیز نشان می دهد.

## ۲-۲- الگوریتم پیشنهادی

روندنمای الگوریتم پیشنهادی در شکل ۱ دیده می شود. این الگوریتم ترکیبی از الگوریتم ژنتیک چندهدفه و شبکه عصبی مصنوعی و حافظه نهانی می باشد. در این تحقیق از الگوریتم ژنتیک چندهدفه NSGA-II<sup>۳</sup> که توسط دب<sup>۴</sup> و همکاران در سال ۲۰۰۲ توسعه یافته است استفاده می شود [۱۱]. در الگوریتم پیشنهادی، ابتدا نسل اولیه ای از کروموزومها به صورت تصادفی ایجاد می گردد. کروموزومها که هر یک نشان دهنده یک پتانسیل جواب در الگوریتم ژنتیک هستند متشکل از مجموعه ای از ژن ها می باشند. در مدل بهینه سازی مذکور این ژن ها در یک کروموزوم (جواب)، مجموعه نقاط پیشنهادی (انتخابی) برای نمونه برداری در شبکه توزیع می باشند. بنابراین هر یک از ژن ها یک نقطه نمونه برداری را نشان می دهد.

در مرحله بعدی توابع هدف کروموزومهای نسل اولیه با استفاده از مدل کامل محاسبه و با توجه به قوانین پستی پارتو، برازش آنها تعیین می شود که در الگوریتم ژنتیک چندهدفه برازش کروموزومها بر اساس رتبه بندی آنها در رویه های غیرپست انجام می شود. برای کاهش محاسبات زمان بر محاسبه تابع هدف با مدل کامل که شامل محاسبات ماتریس ژاکوبین، ماتریس واریانس-کواریانس پارامترها و پیش بینی ها می باشد، در مدل پیشنهادی از شبکه عصبی مصنوعی استفاده می شود. شبکه های عصبی مصنوعی می توانند پس از آموزش جایگزین این محاسبات زمان گیر برای بخشی از کروموزومهای یک نسل شوند.

حلقه اصلی الگوریتم با ایجاد کروموزومهای اولاد و اعمال عملگرهای ژنتیکی بر روی آنها در گام سوم شروع می شود. تعداد کافی داده های آموزشی به منظور استفاده از شبکه عصبی برای برآورد (پیش بینی) توابع هدف ضروری است. به منظور تأمین آنها، در تعداد مشخصی از نسلهای اولیه الگوریتم ژنتیک، محاسبه توابع هدف و ارزیابی برازش فقط با استفاده از مدل کامل و بدون کمک شبکه عصبی انجام می شود (گامهای ۵ و ۶ در روندنما). در همین حال همواره از حافظه نهانی به منظور بازیابی توابع هدف کروموزومهای تکراری و عدم محاسبه مجدد آنها در وهله اول و سپس برای ذخیره کروموزومهای ارزیابی شده جدید استفاده می شود. پس از جمع آوری تعداد کافی داده های آموزشی در نسلهای

نشان دهنده عدم قطعیت پارامترها و پیش بینی ها برای آن مجموعه نقاط مشاهداتی می باشد. از آنجا که تابع هدف اول بر اساس دقت متغیرهای پیش بینی می باشد و همچنین با توجه به ترجیح استفاده از مقادیر بی بعد در مدل سازی، دقت نسبی متغیرهای پیش بینی به صورت زیر ارائه می شود [۳]:

$$f_1 = \frac{F_{1,ml}}{F_1} \quad (4)$$

که در آن

$F_{1,ml}$  مقدار عدم قطعیت مدل برای مطلوب ترین حالتی است که در آن، کلیه نقاط با پتانسیل اندازه گیری پایش می شوند. محدوده تغییرات رابطه ۴ بین صفر و یک خواهد بود که حالت ۱ مربوط به دقیق ترین حالت اندازه گیری یعنی پایش کلیه نقاط است.

همچنین برای در نظر گرفتن خطا در برآورد اولیه پارامترهای واسنجی در مدل سازی، از تابع برازش پارازیت دار<sup>۱</sup> استفاده می شود [۹ و ۱۰]. با توجه به در نظر گرفتن یک تابع چگالی احتمالی<sup>۲</sup> خاص برای پارامترهای دارای خطا در برآورد، برای هر یک از پارامترها به تعداد مشخصی نمونه گیری تصادفی می شود. سپس بر اساس هر مجموعه از پارامترهای نمونه گیری شده تابع هدف متناظر محاسبه و با میانگین گیری از آنها، تابع هدف دقت پیش بینی مدل واسنجی شده یا "تابع هدف با مدل کامل" محاسبه می شود که به صورت زیر است:

$$\text{Max } f_1 = \frac{1}{N_k} \sum_{j=1}^{N_k} \frac{F_{1,ml}}{F_1} \quad (5)$$

که در آن

$N_k$ ، برابر تعداد نمونه گیری ها می باشد که در این مقاله بر اساس تحلیل حساسیت ۵۰۰ نمونه کفایت می نماید. به منظور در نظر گرفتن خطا در برآورد اولیه پارامترهای مدل، پارامترهای ضرایب زبری لوله ها به صورت تابع چگالی احتمال با توزیع یکنواخت و ضریب تغییرات  $CV=0/3$  و پارامترهای نیاز آبی گرهها با توزیع نرمال و ضریب تغییرات  $CV=0/2$  فرض می شوند.

تابع هدف دوم هزینه نمونه برداری می باشد که در اینجا از تعداد دستگاههای فشارسنج به عنوان شاخص هزینه نمونه برداری استفاده می شود که با محدودیت مربوطه به صورت زیر قابل ارائه است:

$$\text{Min } F_2 = N \quad (6)$$

$$N_{\min} \leq N \leq N_{\max} \quad (7)$$

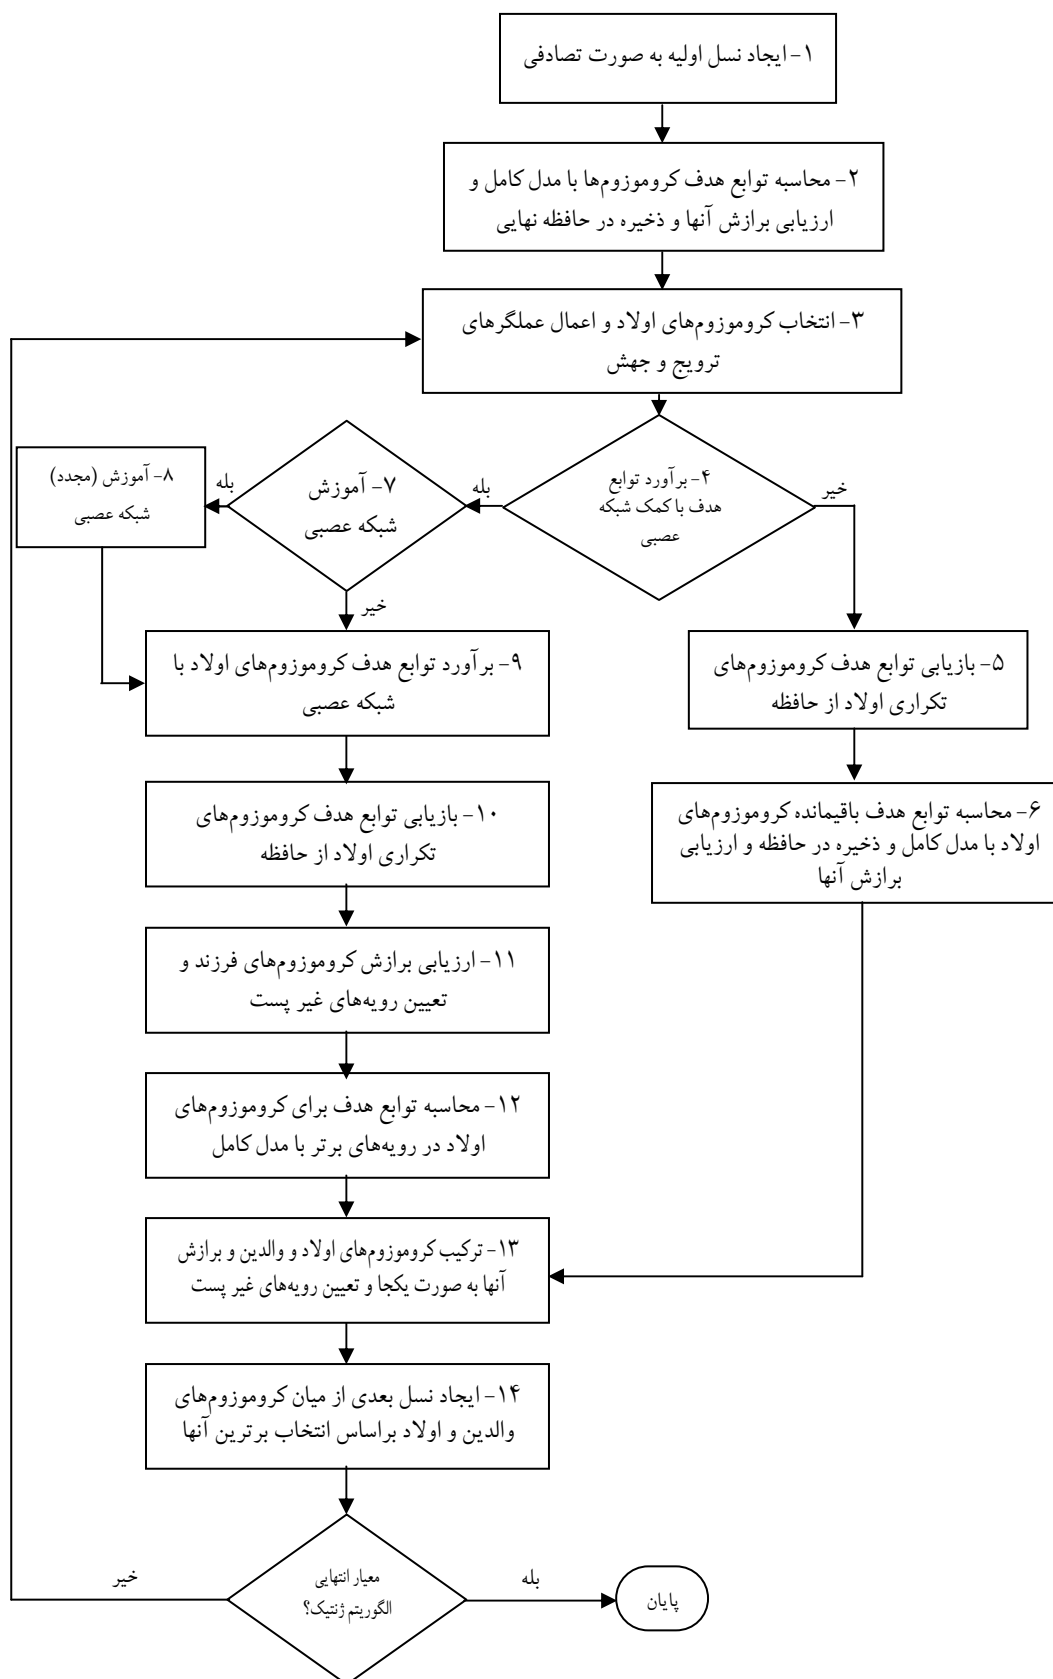
که  $N$ ، تعداد دستگاههای فشارسنج قابل نصب را نشان می دهد. حداکثر تعداد دستگاههای فشارسنج قابل نصب باید از تعداد نقاط با

<sup>3</sup> Nondominated Sorting Genetic Algorithm II

<sup>4</sup> Deb

<sup>1</sup> Noisy Fitness Function

<sup>2</sup> Probability Density Function (PDF)



شکل ۱- روندنمای الگوریتم ژنتیک چند هدفه و شبکه عصبی

اولیه، ابتدا شبکه عصبی آموزش داده می‌شود (گام ۷ روندنما) و از آن به بعد، برآورد توابع هدف با کمک شبکه عصبی نیز انجام می‌شود (گامهای ۹ الی ۱۲ روندنما). لازم به ذکر است که داده‌های آموزشی در واقع کروموزوم‌ها و توابع هدف آنها که با استفاده از مدل کامل برآورد شده‌اند می‌باشد. همچنین برای جمع‌آوری داده‌های آموزشی شبکه عصبی، هر چه تعداد نسلهای اولیه بیشتر باشد، تعداد داده‌های آموزشی بیشتر می‌شود که برای آموزش شبکه عصبی مناسب‌تر است. اما از طرف دیگر به دست آمدن این داده‌ها به زمان اجرای بیشتری نیازمند است. بنابراین تعداد نسلهای اولیه باید مسامحه‌ای از هر دو معیار مربوطه باشد. این تعداد بر اساس تحلیل حساسیت تعیین می‌شود که در بخش نتایج بیان خواهد شد. پس از گذشت تعداد مشخصی از نسلها و تأمین تعداد کافی داده‌های آموزشی، توابع هدف با کمک شبکه عصبی، حافظه نهانی و مدل کامل، توأم برآورد می‌شوند (گامهای ۷ الی ۱۳ روندنما). در این گامها، ابتدا شبکه عصبی با داده‌های آموزشی برای اولین بار آموزش داده می‌شود (گام ۸ روندنما). برآورد توابع هدف کروموزوم‌های اولاد در این مرحله ابتدا با کمک شبکه عصبی به سرعت انجام می‌گیرد (گام ۹ روندنما). سپس در گام دهم هر یک از کروموزوم‌های اولاد با کروموزوم‌های موجود در حافظه به صورت یک به یک مقایسه می‌شوند و در صورت یافتن "مشابهت ژنتیکی" بین دو کروموزوم اولاد و حافظه (دو کروموزوم که کلیه ژن‌های آنها با هم یکی و برابر باشند)، مقادیر واقعی توابع هدف کروموزوم اولاد (که توسط تابع هدف با مدل کامل محاسبه شده است) از حافظه نهانی بازیابی و جایگزین مقادیر برآورد شده شبکه عصبی می‌شوند. سپس برآزش کروموزوم‌های اولاد با توجه به قوانین پست‌شدگی پارتو تعیین می‌شود. با در نظر گرفتن تقریبی بودن برآوردهای توابع هدف توسط شبکه عصبی و احتمال گمراهی در یافتن جواب بهینه طی فرآیند بهینه‌سازی، پس از تعیین برآزش کروموزوم‌های اولاد و تعیین رویه‌های غیرپست، توابع هدف کلیه کروموزوم‌های موجود در رویه‌های غیرپست برتر که دارای توابع هدف برآورد شده توسط شبکه عصبی می‌باشند مجدداً در گام دوازدهم توسط تابع هدف با مدل کامل محاسبه می‌شوند تا کلیه کروموزوم‌های (جوابها) موجود در رویه غیرپست برتر توسط تابع هدف با مدل کامل محاسبه شده باشند و بدین ترتیب عدم انحراف احتمالی جواب بهینه تضمین شود.

در گام سیزدهم الگوریتم به منظور تولید نسل بعدی، کروموزوم‌های اولاد و والدین با هم ترکیب می‌شوند و مجدداً برآزش همگی آنها با هم انجام می‌شود و بدین ترتیب کروموزوم‌های رتبه‌بندی شده در رویه‌های غیرپست تقسیم بندی می‌گردند. آنگاه کروموزوم‌های برترین رویه‌های غیرپست به نسل بعدی منتقل

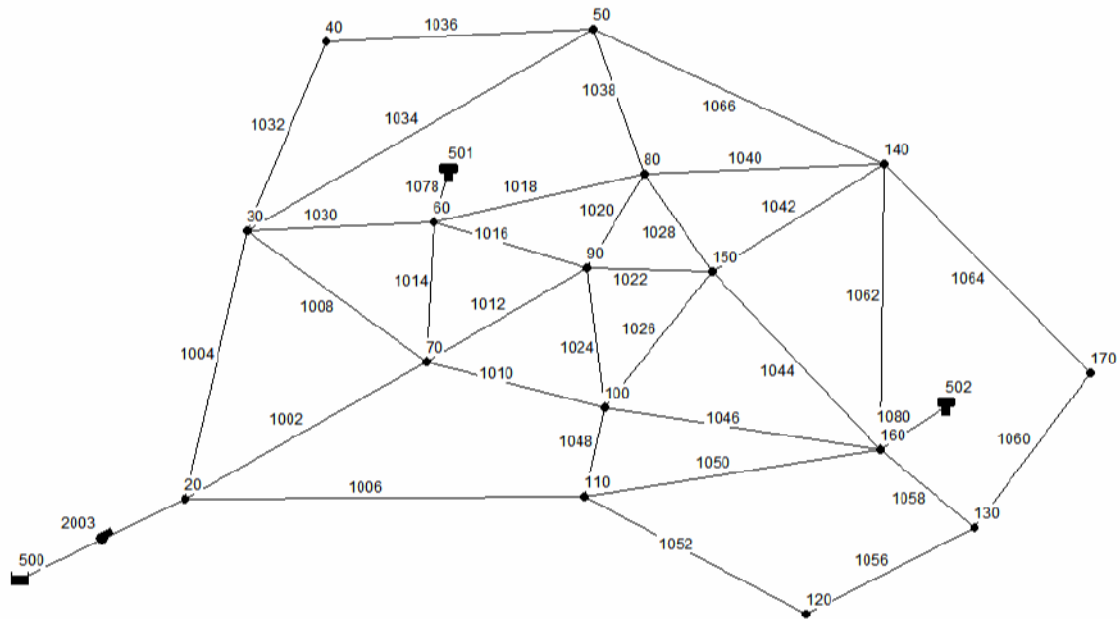
می‌شوند تا مجموعه کروموزوم‌های والدین نسل بعد را تشکیل دهند.

از آنجا که شبکه عصبی با داده‌های آموزشی تولید شده در نسلهای اولیه آموزش دیده است، در طی پیشرفت الگوریتم ژنتیک با پیدایش جوابهای جدید در طی نسلهای بعدی، لازم است شبکه عصبی مجدداً با داده‌های آموزشی جدید آموزش داده شود تا در برآورد جوابهای جدید خطای کمتری وجود داشته باشد. از اینرو شبکه عصبی پس از جمع‌آوری تعداد مشخصی از داده‌های آموزشی به صورت دوره‌ای آموزش داده می‌شود. این شبکه عصبی دارای دو لایه شامل یک لایه مخفی و یک لایه خروجی و همچنین ورودی داده‌ها می‌باشد. ورودی شبکه عصبی شماره گرهای نصب دستگاههای فشارسنج به صورت اعداد صحیح و تعداد ورودی‌ها برابر حداکثر تعداد دستگاههای قابل نصب است. لایه خروجی دارای یک نرون می‌باشد که برابر مقدار تابع هدف اول یعنی دقت نسبی پیش‌بینی‌های فشار در شبکه است. تعداد نرون‌های لایه مخفی پس از انجام تحلیل حساسیت برابر ۲۰ نرون تعیین شد.

### ۳- نتایج و بحث

الگوریتم پیشنهادی، روی یک شبکه توزیع شناخته شده در مقالات به نام مدل Anytown آزمایش شده است [۳، ۱۲ و ۱۳]. شکل ۲ شبکه مذکور را نشان می‌دهد که شامل یک مخزن زمینی با بلندای ثابت و دو مخزن هوایی می‌باشند. طراحی نمونه‌برداری با توجه به پارامترهای واسنجی ضرایب زبری هیزن-ویلیامز لوله‌ها (۵ ضریب گروه‌بندی شده) و نیازهای آبی گر‌ها (۴ نیاز آبی) انجام می‌شود که در مجموع تعداد پارامترها برابر  $N_a = 9$  می‌باشد. کلیه گرهای موجود در شبکه به استثناء گرهای مربوط به مخازن ثابت و هوایی به عنوان گرهایی با پتانسیل نصب فشارسنج در نظر گرفته شدند ( $N_{ml} = 16$ ). ماتریس ژاکوبین کامل  $J_{ml}$  با استفاده از پارامترها و نقاط با پتانسیل نصب فشارسنج با ابعاد  $N_a = 9$  ستون و  $N_O = 128$  ردیف (۱۶ گر مکانی برای ۸ حالت نیاز آبی مختلف زمانی) قابل محاسبه می‌باشد.

از آنجا که برای رسیدن به "جواب معین" در مدل بهینه‌سازی باید مجموع تعداد اندازه‌گیری‌های مکانی و زمانی از مجموع تعداد پارامترهای واسنجی بیشتر باشند و با توجه به اینکه مجموع تعداد پارامترها  $N_a = 9$  و همچنین ۸ حالت نیاز آبی در شبانه‌روز (یعنی امکان ۸ مرتبه اندازه‌گیری زمانی برای هر فشارسنج)، امکان نصب یک فشارسنج در شبکه برای رسیدن به "جواب بهینه معین" وجود ندارد. بنابراین حداقل ۲ فشارسنج به عنوان حداقل تعداد فشارسنج‌های لازم برای نصب، به مدل معرفی می‌شود ( $N_{min} = 2$ ).




شکل ۲- جانمایی شبکه توزیع آب مورد مطالعه

از نقاط روی این رویه غیرپست مجموعه محل‌های بهینه نصب فشارسنج وجود دارد که جزئیات آن در جدول ۱ ارائه شده است. بدین ترتیب تصمیم‌گیرنده می‌تواند تعداد و محل مناسب فشارسنج‌های مورد نیاز را تعیین نماید که به چند روش زیر قابل انجام می‌باشد: (الف) با توجه به حداکثر بودجه در اختیار؛ (ب) با توجه به حداقل دقت پیش‌بینی مورد نیاز؛ (ج) با توجه به نقطه‌ای روی منحنی که به ازای افزایش تعداد نقاط نمونه‌برداری افزایش چشمگیری در دقت پیش‌بینی به وجود نمی‌آید.

با دقت در روند رویه غیرپست شکل ۳ مشاهده می‌شود که با افزایش تعداد نقاط بهینه پایش فشار به بیش از ۶ یا ۷ نقطه بهبود محسوسی در دقت نسبی پیش‌بینی مدل یا عدم قطعیت پیش‌بینی حاصل نمی‌گردد. بنابراین این نقاط با توجه به یکی از معیارهای انتخاب می‌توانند به عنوان نقاط اقتصادی نمونه‌برداری معرفی شوند که حدود ۴۰ درصد مجموعه نقاط با پتانسیل نصب فشارسنج در شبکه را نشان می‌دهد. همچنین با حداقل ۲ نقطه بهینه فشارسنج، می‌توان تا حد عدم قطعیت ۰/۱۳ متر برای پیش‌بینی مدل دست یافت. اگرچه در این حالت تنها حدود ۱۹ درصد از حداکثر دقت پیش‌بینی فشار حاصل می‌گردد. با این وجود در زمانهایی که این مقدار دقت کفایت نماید می‌تواند به عنوان یک نقطه اقتصادی مطرح باشد.

پارامترهای الگوریتم ژنتیک پس از انجام تحلیل حساسیت بدین صورت به دست آمد که احتمال جهش  $(P_m) 0/25$ ، احتمال تزویج  $(P_c) 0/90$ ، تعداد جمعیت افراد هر نسل برابر ۵۰ کروموزوم و تعداد نسل‌های مورد نیاز برای رسیدن به جواب بهینه برابر ۵۰۰ نسل تعیین گردید. در بخش تنظیمات شبکه عصبی از سریع‌ترین روش آموزش شبکه عصبی یعنی *Levenberg-Marquardt backpropagation* استفاده گردید [۱۴ و ۱۵]. کمترین تعداد نسل‌های اولیه مورد نیاز برای جمع‌آوری داده‌های آموزشی شبکه عصبی که در آنها توابع هدف صرفاً با استفاده از مدل کامل محاسبه می‌شود، بر اساس تحلیل حساسیت ذکر شده در بخش الگوریتم پیشنهادی، برابر ۵ نسل به دست آمد، به نحوی که در کمتر از این تعداد، شبکه عصبی آموزش دیده دارای دقت کافی برای پیش‌بینی توابع هدف نبود. بنابراین از نسل ۶ الی ۵۰۰ برآورد توابع هدف با کمک شبکه عصبی و مدل کامل، توأمآ انجام می‌شود (گام‌های ۷ الی ۱۲ در روند نما). همچنین تعداد داده‌های آموزشی لازم برای آموزش مجدد (دوره‌ای) شبکه عصبی پس از تحلیل حساسیت برابر ۱۰۰۰ داده آموزشی تعیین شد.

جواب مدل بهینه‌سازی به صورت رویه غیرپست بهینه پارتو در شکل ۳ نشان داده شده است. در این شکل رویه غیرپست بهینه برای هر دو نوع تابع هدف دقت نسبی پیش‌بینی مدل واسنجی شده در برابر تابع هدف هزینه نمونه‌برداری ترسیم شده است. برای هر یک



شکل ۳- رویه غیرپست بهینه مدل الگوریتم ژنتیک چند هدفه

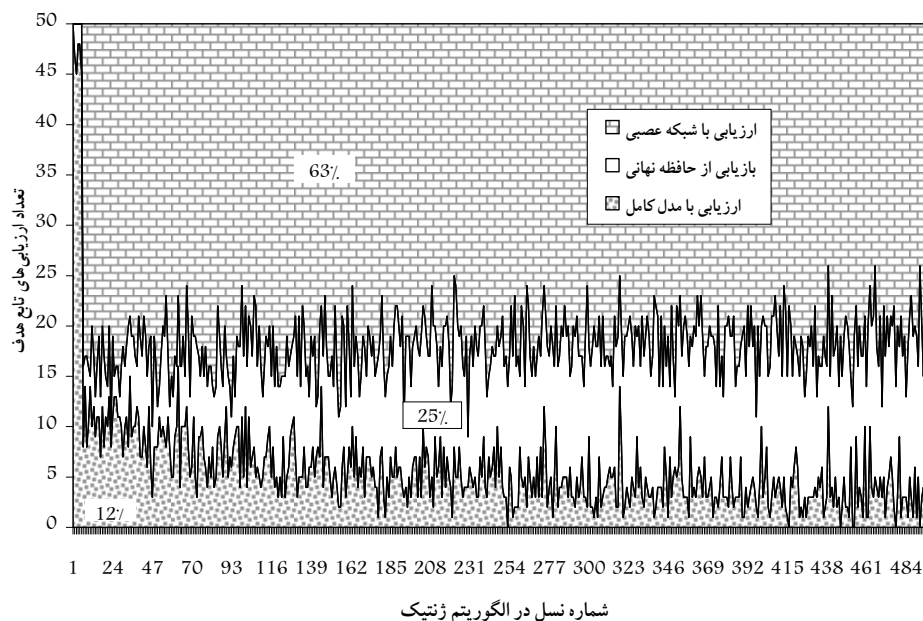
درصد کروموزوم‌ها در طی فرآیند الگوریتم ژنتیک در نسل‌های مختلف، تابع هدف توسط مدل کامل محاسبه می‌شود. در ۵ نسل اولیه بیشتر ارزیابی‌ها توسط مدل کامل انجام شده است زیرا داده‌های آموزشی مورد نیاز برای آموزش شبکه عصبی جمع‌آوری

در شکل ۴ مقایسه تعداد ارزیابی‌های تابع هدف کروموزوم‌ها با روش مدل کامل، بازیابی از حافظه نهانی و تقریب شبکه عصبی در بین کروموزوم‌های هر نسل و در طی نسل‌های مختلف الگوریتم ژنتیک نمایش داده می‌شود. بر اساس این شکل، تنها برای ۱۲

جدول ۱- مجموعه جوابهای غیرپست پارتو مدل الگوریتم ژنتیک چند هدفه- شبکه عصبی شامل نقاط بهینه محل نصب فشارسنج؛ عدد "۱" یعنی در آن گره فشارسنج نصب گردد و علامت "-" یعنی در آن گره فشارسنج نصب نشود.

شماره گره																تعداد نقاط	
۱۷۰	۱۶۰	۱۵۰	۱۴۰	۱۳۰	۱۲۰	۱۱۰	۱۰۰	۹۰	۸۰	۷۰	۶۰	۵۰	۴۰	۳۰	۲۰	دقت نسبی	پایش
																$f_1$ پیش‌بینی	$F_2$
-	-	-	-	-	۱	-	-	۱	-	-	-	-	-	-	-	۰/۱۸۷۸	۲
-	-	-	-	-	۱	-	۱	-	-	-	۱	-	-	-	-	۰/۳۰۴۷	۳
۱	-	-	-	-	۱	-	۱	۱	-	-	-	-	-	-	-	۰/۴۳۵۳	۴
۱	-	-	-	-	۱	۱	-	۱	-	-	۱	-	-	-	-	۰/۵۶۶۲	۵
۱	-	-	-	-	۱	۱	۱	۱	-	-	۱	-	-	-	-	۰/۶۷۰۹	۶
۱	۱	-	-	-	۱	۱	۱	۱	-	-	۱	-	-	-	-	۰/۷۴۲۲	۷
۱	۱	-	-	-	۱	۱	۱	۱	۱	-	۱	-	-	-	-	۰/۷۸۴۰	۸
۱	۱	-	-	۱	۱	۱	۱	۱	-	۱	۱	-	-	-	-	۰/۸۲۳۷	۹
۱	۱	-	-	۱	۱	۱	۱	۱	۱	۱	۱	-	-	-	-	۰/۸۶۴۱	۱۰
۱	۱	۱	-	۱	۱	۱	۱	۱	۱	۱	۱	-	-	-	-	۰/۸۹۵۵	۱۱
۱	۱	۱	-	۱	۱	۱	۱	۱	۱	۱	۱	-	۱	-	-	۰/۹۲۳۹	۱۲
۱	۱	۱	-	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	-	-	۰/۹۵۰۱	۱۳
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	-	-	۰/۹۷۲۴	۱۴
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	-	۰/۹۸۷۲	۱۵
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱/۰۰۰	۱۶





شکل ۴- مقایسه تعداد ارزیابی‌های تابع هدف کروموزوم‌ها در مدل MOGA-ANN

جدول ۲- مقایسه زمان اجرا و تعداد محاسبه تابع هدف با مدل کامل

نوع مدل	زمان (دقیقه)	تعداد محاسبه تابع هدف با مدل کامل
مدل الگوریتم ژنتیک چند هدفه	۸۰	۲۵۰۰۰
مدل الگوریتم ژنتیک چند هدفه-شبکه عصبی	۹	۲۹۳۶

#### ۴- نتیجه‌گیری

الگوریتم پیشنهادی MOGA-ANN به خوبی موفق به کاهش زمان اجرای مسئله طراحی نمونه‌برداری چند هدفه شده است. حافظه نهانی جهت بازیابی جوابهای تکراری در طی پیشرفت الگوریتم و برآورد تابع هدف بخشی از کروموزوم‌های هر نسل توسط شبکه عصبی مصنوعی از جمله روشهای مؤثر به کار رفته می‌باشند. جواب مدل بهینه‌سازی به صورت مجموعه نقاط غیرپیست یا رویه بهینه پارتو نسبت به دو تابع هدف به دست می‌آید. منحنی توازن حاصله معیاری ایده‌آل را برای انتخاب تعداد و محل مناسب نقاط نمونه‌برداری با توجه به میزان دقت پیشنهاد می‌دهد.

روش پیشنهادی در مقایسه با روش استاندارد الگوریتم ژنتیک چند هدفه کاهش چشمگیری در زمان محاسبه جواب نهایی تولید نموده است. نتایج نشان می‌دهد تلفیق شبکه‌های عصبی مصنوعی در مدل بهینه‌سازی الگوریتم ژنتیک برای برآورد تابع هدف بخشی از جوابها، کاهش چشمگیری در زمان اجرا دارد و می‌تواند در کاهش زمان اجرای مدل‌های بهینه‌سازی با زمان اجرای طولانی بسیار نوید بخش باشد.

می‌شده است. پس از آن در طی نسلهای بعدی تأثیر ارزیابی با مدل کامل به تدریج کاهش پیدا کرده است و سهم دو بخش دیگر بیشتر شده. درصد بازیابی تابع هدف از حافظه نهانی ۲۵ درصد کل ارزیابی‌ها می‌باشد که البته این مقدار به شدت وابسته به احتمال جهش در الگوریتم ژنتیک می‌باشد و با کاهش احتمال جهش، این درصد افزایش و برعکس با افزایش احتمال جهش، درصد بازیابی از حافظه نهانی کاهش می‌یابد. علت این وابستگی، احتمال تولید ژن‌های جدید می‌باشد که قبلاً در حافظه نهانی سیستم وجود نداشته‌اند.

جدول ۲ مقایسه زمانی اجرا و تعداد محاسبه تابع هدف با مدل کامل بین الگوریتم MOGA توسعه داده شده توسط کاپلان و همکاران در سال ۲۰۰۳ و الگوریتم پیشنهادی MOGA-ANN را برای مطالعه موردی نشان می‌دهد. بر این اساس، زمان اجرای الگوریتم پیشنهادی در عین دستیابی به جواب بهینه حدود ۹ برابر سریع‌تر از روش قبلی می‌باشد.

- 1- De Schaetzen, W. (2000). "Optimal calibration and sampling design for hydraulic network models." PhD. thesis, School of Engineering and Computer Science, Univ. of Exeter, Exeter, U.K.
- 2- Kapelan, Z. S. (2002). "Calibration of WDS hydraulic models." PhD. thesis, School of Engineering and Computer Science, Univ. of Exeter, Exeter, U.K.
- 3- Kapelan, Z. S., Savic, D. A., and Walters, G. A. (2003). "Multi-objective sampling design for water distribution model calibration." *Journal of Water Resources Planning and Management*, 129(6), 466-479.
- 4- Bush, C. A., and Uber, J. G. (1998). "Sampling design methods for water distribution model calibration." *Journal of Water Resources Planning and Management*, 124(6), 334-344.
- 5- Lansley, K. E., El-Shorbagy, W., Ahmed, I., Araujo, J., and Haan, C. T. (2001). "Calibration assessment and data collection for water distribution networks." *J. Hydraul. Eng.*, 127(4), 270-279.
- 6- Broad, D. R., Dandy, G. C., and Maier, H. R. (2005), "Water distribution system optimization using metamodels." *Journal of Water Resources Planning and Management*, 131(3), 172-180.
- 7- Yan, S., and Minsker, B. (2006). "Optimal groundwater remediation design using an adaptive neural network genetic algorithm." *Water Resour. Res.*, 42(5).
- 8- Kapelan, Z. S., Savic, D. A., and Walters, G. A. (2005). "Optimal sampling design methodologies for water distribution model calibration." *Journal of Hydraulic Engineering*, 131(3), 190-200.
- 9- Wu, J. C., Zheng, C. C., and Zheng, L. C. (2006). "A comparative study of Monte Carlo simple genetic algorithm and noisy genetic algorithm for cost-effective sampling network design under uncertainty." *Advance in Water Resources*, 29(1), 899-911.
- 10- Gopalakrishnan, G., Minsker, B. S., and Goldberg, D. (2001). "Optimal sampling in a noisy genetic algorithm for risk-based remediation design." Phelps, D., and Sehlke, G., eds., *Bridging the gap: meeting the world's water and environmental resources challenges. Proc. World Water and Environmental Resources Congress*, Washington, D.C.
- 11- Deb, K., Pratap, A., Agarwal, S., and Meyarivan, T. (2002). "A fast and elitist multiobjective genetic algorithm: NSGA-II." *IEEE Trans. Evol. Comput.*, 6(4), 182-197.
- 12- Ferreri, G. B., Napoli, E., and Tumbiolo, A. (1994). "Calibration of roughness in water distribution networks." *Proc. 2nd International Conference on Water Pipeline Systems*, Edinburgh, UK, D. S. Miller, ed., vol. 1, 379-396.
- 13- Ormsbee, L. E. (1989). "Implicit network calibration." *Journal of Water Resources Planning and Management*, 115(2), 243-257.
- 14- MATLAB 7.2 (2006). The Math works Inc.
- 15- Lingireddy, S., and Ormsbee, L. E. (1998). "Neural networks in optimal calibration of water distribution systems." *Artificial Neural Networks for Civil Engineers: Advanced Features and Applications*, I. Flood and N. Kartam, eds., ASCE, Reston, VA., 53-76.