

Increasing Computational Efficiency of Inverse Transient Analysis for Leak Detection using GA-Kriging Surrogate Model

S. Sarkamaryan¹, A. Haghighi², S. M. Ashrafi³, H. Mohammad Vali Samani⁴

1. PhD Student, Dept. of Civil Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran
(Corresponding Author) saeid.sarkamaryan@gmail.com
2. Assoc. Prof., Dept. of Civil Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran
3. Assist. Prof., Dept. of Civil Engineering, Faculty of Engineering Shahid Chamran University of Ahvaz, Ahvaz, Iran
4. Prof., Dept. of Civil Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

(Received Jan. 18, 2019 Accepted Aug. 15, 2019)

To cite this article:

Sarkamaryan, S., Haghighi, A., Ashrafi, S. M., Mohammad Vali Samani, H. 2020. "Increasing computational efficiency of inverse transient analysis for leak detection using GA-Kriging surrogate model" Journal of Water and Wastewater, 31(3), 1-11. Doi: 10.22093/wwj.2019.168274.2812 (In Persian)

Abstract

The inverse transient analysis (ITA) method is amongst the successful leak detection methods in water distribution networks. However, determining the unknown leakage parameters such as number, location, and area of leakages is computationally time-consuming and costly due to applying metaheuristic algorithms, like the genetic algorithm (GA). This study aimed to present a novel approach to resolve this issue in order to enhance the accuracy and speed of the ITA method while maintaining its computational structure. In this research, surrogate models were incorporated in the optimization process of the ITA method. Mimicking the behavior of the objective function, surrogate models attempt to represent the most similar behavior at a low computational cost. In this regard, a new optimization algorithm based on the Kriging surrogate model, called GA-Kriging was proposed. In this algorithm, according to the structural characteristics of the Kriging surrogate model, an EI index was presented to modify the offspring selection scheme in GA. In order to evaluate the GA-Kriging algorithm and compare its performance with the conventional GA, a reference water distribution network was considered for leak detection. The accuracy and computational efficiency of the results in the GA-Kriging algorithm were 52% and 75% higher than those of the conventional GA, respectively. The present study concluded that appropriate incorporation of surrogate models in the optimization process can make the computations more intelligent, reduce repeated computations and, ultimately, increase computational efficiency.

Keywords: Inverse Transient Analysis, Leak Detection, Computational Efficiency, Surrogate Model.

مجله آب و فاضلاب، دوره ۳۱، شماره ۳، صفحه: ۱۱-۱

افزایش راندمان محاسباتی روش نشت یابی تحلیل معکوس جریان گذرا با استفاده از مدل جایگزین کریجینگ

سعید سرکمریان^۱، علی حقیقی^۲، سید محمد اشرفی^۳ و حسین محمد ولی سامانی^۴۱- دانشجوی دکترا، گروه عمران، دانشکده مهندسی، دانشگاه شهید چمران، اهواز، ایران
(نویسنده مسئول) saeid.sarkamaryan@gmail.com

۲- دانشیار، گروه عمران، دانشکده مهندسی، دانشگاه شهید چمران، اهواز، ایران

۳- استادیار، گروه عمران، دانشکده مهندسی، دانشگاه شهید چمران، اهواز، ایران

۴- استاد، گروه عمران، دانشکده مهندسی دانشگاه شهید چمران، اهواز، ایران

(دریافت ۹۷/۱۰/۲۸ پذیرش ۹۸/۵/۲۴)

برای ارجاع به این مقاله به صورت زیر اقدام فرمایید:

سرکمریان، س.، حقیقی، ع.، اشرفی، س.م.، محمدولی سامانی، ح.، ۱۳۹۹. "افزایش راندمان محاسباتی روش نشت یابی تحلیل معکوس جریان گذرا با استفاده از مدل جایگزین کریجینگ" مجله آب و فاضلاب، ۳۱(۳)، ۱۱-۱. Doi: 10.22093/wwj.2019.168274.2812

چکیده

روش تحلیل معکوس جریان گذرا (ITA)، یکی از روش‌های موفق در زمینه شناسایی نشت در شبکه‌های آبرسانی است. با این وجود دستیابی به پارامترهای مجهول نشت مانند تعداد، مکان و مساحت نشت‌ها در این روش به دلیل استفاده از الگوریتم‌های فراکوشی مانند الگوریتم ژنتیک (GA) نیازمند صرف هزینه و زمان محاسباتی زیادی است. هدف از این پژوهش ارائه راهکاری است که با حفظ ساختار محاسبات ITA، دقت و سرعت دسترسی به نتایج نیز افزایش یابد. در این پژوهش راهکار استفاده از مدل‌های جایگزین در فرایند بهینه‌سازی روش ITA مطرح شد. این مدل‌ها با تقلید از رفتار تابع هدف اصلی، تلاش می‌کنند با هزینه محاسباتی اندک، تا حد امکان بیشترین شباهت رفتاری را نسبت آن داشته باشند. در همین راستا الگوریتم بهینه‌سازی جدیدی بر پایه مدل جایگزین کریجینگ تحت عنوان الگوریتم GA-Kriging معرفی شد. در این الگوریتم با استفاده از ویژگی ساختاری مدل جایگزین کریجینگ و ارائه شاخصی به نام EI اصلاحاتی در انتخاب فرزندان الگوریتم GA انجام شد. به منظور ارزیابی الگوریتم GA-Kriging و مقایسه عملکرد آن با الگوریتم GA، از یک شبکه آبرسانی مرجع با هدف یافتن نشت استفاده شد. نتایج نشان داد که الگوریتم GA-Kriging با ۵۲ درصد دقت بیشتر نتایج به دست آمده و صرفه‌جویی زمان محاسباتی به اندازه ۷۵ درصد، نسبت به الگوریتم GA کارایی محاسباتی بیشتری دارد. این پژوهش نشان داد که استفاده مناسب از مدل‌های جایگزین در فرایند بهینه‌سازی می‌تواند سبب هوشمندتر شدن محاسبات، کاهش محاسبات تکراری و در نهایت، افزایش کارایی محاسباتی شود.

واژه‌های کلیدی: تحلیل معکوس جریان گذرا، تعیین نشت، راندمان محاسباتی، مدل جایگزین

۱- مقدمه

سیال از خطوط لوله علاوه بر خسارات اقتصادی و فنی، می‌تواند خطرات بهداشتی و محیط زیستی جبران‌ناپذیری نیز در پی

در ارزیابی شبکه‌های آبرسانی، تعیین میزان هدر رفت آب از اهمیت بسیاری برخوردار است. این امر به دلیل آن است که نشت

استفاده از این روش، زیاد باشد. یک نمونه از راهکارهایی که با استفاده از آن، هزینه محاسباتی کاهش داده می‌شود، استفاده از مدل‌های جایگزین است. این مدل‌ها با تقلید از رفتار شبیه‌ساز اصلی تلاش می‌کنند تا حد امکان بیشترین شباهت رفتاری را نسبت آن به وجود بیاورند. این مدل‌ها با کمک اطلاعاتی که در روند فرایند بهینه‌سازی در فضای جست‌وجو به دست می‌آورند مسیر فرایند بهینه‌سازی را به گونه‌ای هدایت می‌کنند که در نهایت باعث کاهش تعداد ارزیابی‌های تابع هدف اصلی مسئله می‌شود. در واقع با استفاده از این مدل‌ها، در حل مسائل بهینه‌سازی از محاسبات تکراری به خصوص در روش‌های استوکاستیک³ اجتناب می‌شود. مدل‌های جایگزین می‌توانند تقریباً در تمام عملگرهای الگوریتم‌های تکاملی مانند ازدواج و جهش و ارزیابی‌ها جایگزین تابع هدف اصلی مسئله شوند (Jin, 2011).

از متداول‌ترین مدل‌های جایگزین، به مدل شبکه عصبی مصنوعی⁴، مدل‌های توابع پایه شعاعی⁵، مدل کریجینگ⁶ و روش ماشین‌های بردار پشتیبان⁷ اشاره می‌شود (Hwang and Martins, 2018) با توجه به هزینه محاسباتی کم و سرعت زیاد اجرای آن‌ها در سال‌های اخیر استفاده از این روش‌ها در زمینه حل مسائل بهینه‌سازی در حال افزایش است.

چین و همکاران پیشنهاد استفاده از مدل جایگزین را در کنار تابع هدف اصلی در طول الگوریتم بهینه‌سازی مطرح کردند. روش پیشنهادی در دو حالت مبتنی بر اعضای جمعیت⁸ در یک نسل و مبتنی بر تمام اعضای یک نسل⁹ مطرح شد و توانست تعداد ارزیابی‌های تابع هدف را در مقایسه با GA کاهش دهد (Jin et al., 2002).

ژو و همکاران پیشنهاد استفاده از مدل‌های جایگزین را درون GA به صورت روش سلسله مراتبی¹⁰ مطرح کردند. این روش از دو مدل جایگزین سراسری و مدل جایگزین محلی در حل مسئله بهینه‌سازی بهره گرفت (Zhou et al., 2004).

داشته باشد (Weil, 1993). در سال‌های اخیر پژوهش‌های بسیاری در خصوص جلوگیری از هدر رفت بیشتر آب، انجام شده و روش‌های مختلفی به منظور شناسایی نشت معرفی شده است. از میان روش‌های معرفی شده، روش تحلیل معکوس جریان گذرا¹ یکی از روش‌های موفق در زمینه شناسایی نشت در خطوط لوله تحت فشار است (Covas and Ramos, 2001). در این روش با ایجاد تغییر در شرایط مرزی خطوط لوله همچون باز و بسته کردن شیر در قسمتی از شبکه آبرسانی، جریان گذرا (غیر ماندگار) در سیستم به وجود می‌آید که نتیجه آن به وجود آمدن امواج فشاری رفت و برگشتی در طول خطوط لوله خواهد بود. این امواج در هنگام حرکت در خطوط لوله تحت تأثیر شرایط مرزی سیستم، از جمله نشت‌های موجود خواهند گرفت. به این ترتیب با ثبت مقدار تغییرات فشار نسبت به زمان و تحلیل آن‌ها، اطلاعات منعکس شده از سیستم، از جمله تعیین پارامترهای نشت شامل تعداد، محل و اندازه نشت‌ها به دست می‌آید. دستیابی به شاخص‌های مجهول نشت در روش ITA، به صورت معکوس انجام می‌شود. روش کار در حالت معکوس به این ترتیب است که با در دست داشتن مقدار اندازه‌گیری‌های خروجی سیستم همچون فشار توسط فشارسنج‌ها و توسعه مدل عددی برای حل سیستم، سعی می‌شود تا مقدار فشار محاسباتی به مقدار فشار اندازه‌گیری شده نزدیک شوند. برای این منظور یک تابع هدف تعریف می‌شود که این تابع هدف، اختلاف بین مقدار فشار محاسباتی و مشاهداتی است. برای تعیین شاخص‌های مجهول، باید میزان اختلاف مقدار محاسبه شده توسط مدل هیدرولیکی، با مقدار برداشت شده از شبکه توسط یک الگوریتم بهینه‌سازی مانند الگوریتم ژنتیک² کمینه شود. این روش توسط پژوهشگران بسیاری مورد ارزیابی قرار گرفته و نتایج موفقیت‌آمیزی نیز به دست آمده است. (Liggett and Chen, 1994, Vitkovský et al., 2000, Kapelan et al., 2003, Shamloo and Haghghi, 2009, Shamloo and Haghghi, 2010, Haghghi et al., 2012a, Haghghi and Ramos, 2012b, Keramat et al., 2017)

با وجود موفقیت روش ITA، یافتن پارامترهای نشت در این روش به دلیل استفاده از الگوریتم‌های فراکاوشی نیازمند محاسبه تعداد زیاد تابع هدف است. این امر سبب می‌شود هزینه محاسباتی

¹ Inverse Transient Analysis (ITA)

² Genetic Algorithm (GA)

³ Stochastic Method
⁴ Artificial Neural Network (ANN)
⁵ Radian Basis Function (RBF)
⁶ Kriging
⁷ Support Vector Machine (SVM)
⁸ Individual based
⁹ Generation based
¹⁰ Hierarchical

بیشتر مسائل مهندسی این معادلات به ترتیب به صورت زیر نوشته می شوند (Chaudhry, 2014)

$$\frac{\partial H}{\partial t} + \frac{a^2}{gA} \frac{\partial Q}{\partial x} = 0 \quad (1)$$

$$\frac{\partial Q}{\partial t} + gA \frac{\partial H}{\partial x} + \frac{f|Q|Q}{2DA} = 0 \quad (2)$$

که در معادلات بالا

x مختصات در راستای محور لوله، t زمان، a سرعت موج، D قطر لوله، A مساحت لوله، g شتاب گرانش، f ضریب اصطکاک داریسی-وایسباخ، H هد پیزومتریک لحظه‌ای و Q دبی لحظه‌ای است.

حل این معادلات با استفاده از روش عددی^۴ انجام می‌شود. به منظور مدل‌سازی نشت، میزان جریان خروجی از محل نشت به صورت معادله روزه در نظر گرفته شد (Chaudhry, 2014)

$$Q_{lk} = A_e \sqrt{2g(H_1 - Z_1)} \quad (3)$$

که در آن

Q_{lk} دبی خروجی ناشی از نشت، A_e سطح مقطع منفذ نشت، H_1 تراز پیزومتریک و Z_1 تراز ارتفاعی محل نشت نسبت به سطح مبنا است.

۲-۲- تعریف مسئله بهینه‌سازی

همان‌طور که عنوان شد دستیابی به پارامترهای مجهول نشت در روش ITA به صورت معکوس انجام می‌شود. به منظور دستیابی به مقدار مجهول، شامل سطح مقطع منفذ نشت، تابع هدفی به صورت مجذور مربع اختلاف بین پارامترهای مشاهداتی و محاسباتی مانند معادله ۴ تعریف می‌شود

$$\text{Min } C(A_{e1}, A_{e2}, A_{e3}, \dots, A_{en}) = \sqrt{\sum_{i=1}^{MS} \sum_{j=1}^N (H_{ij} - H'_{ij})^2} \quad (4)$$

Subject to: $0 \leq A_{e2} \leq A_{emax}$

⁴ Method Of Characteristic (MOC)

شی و رشید، روش استفاده از مدل جایگزین سازگار شونده^۱ را در الگوریتم ژنتیک مطرح کردند. در این روش مدل جایگزین در کنار مدل اصلی به منظور محاسبه برازندگی اعضا (کاندیدها) قرار گرفت (Shi and Rasheed, 2008).

در پژوهش یو و همکاران الگوریتم بهینه‌سازی ذرات سلسله مراتبی^۲ با استفاده از مدل جایگزین به منظور کاهش هزینه محاسبات پیشنهاد شد. روش کار در این الگوریتم به این صورت بود که ابتدا از روش یادگیری اجتماعی^۳ به منظور دستیابی به پاسخ بهینه مدل جایگزین RBF استفاده شد. پس از آن در اطراف بهینه یافت شده تصحیح تقریبی به منظور یافتن پاسخ بهینه‌تر انجام شد. الگوریتم پیشنهادی برای چندین تابع تست در نظر گرفته شد و توانست مقدار قابل توجهی از حجم محاسبات را کاهش دهد (Yu et al., 2018).

دو مسئله اساسی که در هنگام استفاده از مدل‌های جایگزین باید مورد توجه قرار گیرد شامل انتخاب نوع مدل جایگزین و نحوه به‌کارگیری مدل جایگزین در فرایند بهینه‌سازی است. مدل جایگزین مورد استفاده در این پژوهش مدل کریجینگ است. علت این انتخاب، ویژگی منحصر به فرد مدل کریجینگ در محاسبه میزان واریانس مقدار پیش‌بینی شده است. از این ویژگی، در هوشمندسازی مسیر جست‌وجوی بهینه‌سازی استفاده می‌شود. در واقع ایده و نوآوری این پژوهش، به‌کارگیری این ویژگی مدل جایگزین کریجینگ در GA با هدف افزایش راندمان محاسباتی است. از آن جایی که هدف، بررسی عملکرد استفاده از مدل‌های جایگزین در فرایند بهینه‌سازی روش ITA است، از یک شبکه آبرسانی با هدف یافتن پارامترهای نشت استفاده شد. مقایسه نتایج حاصل از روش دارای مدل جایگزین و روش متداول ITA به تشخیص توانایی عملکردی روش معرفی شده کمک می‌کند.

۲- مواد و روش‌ها

۲-۱- معادلات حاکم

معادلات حاکم بر جریان گذرا در خطوط لوله تحت فشار، شامل معادلات بقای جرم (معادله ۱) و مومنوم (معادله ۲) هستند. در

¹ Adaptive

² Surrogate Hierarchical Particle Swarm Optimization (SHPSO)

³ Social Learning (SL)

که در آن

C تابع هدف، H_{ij} مقدار محاسبه شده، H'_{ij} مقدار مشاهده شده هدف فشار در سایت i و زمان j، MS تعداد مکان‌های اندازه‌گیری و N تعداد گام‌های زمانی در زمان مدل‌سازی جریان گذرا هستند. پس از مدل‌سازی هیدرولیکی، نوبت ساخت مدل جایگزین و انتخاب روش مدیریت مناسب به منظور دستیابی به حل بهینه سراسری است.

که در آن

$r(x) = \{R(x, x^1), \dots, R(x, x^n)\}$ و $1 = \{1, 1, \dots, 1\}^T$ است. در مدل کریجینگ، میزان واریانس مقدار پیش‌بینی شده (میانگین مربع خطا برای مقادیر پیش‌بینی شده) محاسبه می‌شود. این مقدار، بر اساس معادله ۹ به دست می‌آید

$$s^2(x) = \sigma^2 \left[1 - rR^{-1}r + \frac{(1 - 1^T R^{-1} r)^2}{1^T R^{-1} r} \right] \quad (9)$$

۲-۳- مدل کریجینگ

در مدل کریجینگ مقدار تخمینی $\hat{y}(x)$ به صورت معادله ۵ بیان می‌شود (Zhou et al., 2004)

$$\hat{y}(x) = \beta + Z(x) \quad (5)$$

که در آن

β بیان‌کننده یک مقدار ثابت، $Z(x)$ یک تابع تصادفی گوسی با میانگین صفر، واریانس σ^2 و همچنین کواریانس، غیر صفر است که به صورت معادله ۶ بیان می‌شود

$$\text{cov}[Z(x) Z(x')] = \sigma^2 R(x, x') \quad (6)$$

که در آن

$R(x, x')$ یک تابع همبستگی است که تنها به فاصله اقلیدسی بین دو بردار x و x' بستگی دارد و می‌تواند به صورت توابع مختلف بیان شود که از متداول‌ترین این توابع، تابع همبستگی گاوسی^۱ است که بر اساس معادله ۷ بیان می‌شود

$$R(x, x') = \exp\left(-\sum_{k=1}^m \theta_k |x_k - x'_k|^{c_k}\right) \quad (7)$$

که در آن

θ_k و c_k به عنوان ضرایب مجهول مدل کریجینگ شناخته می‌شوند که حدود تغییرات آن به صورت $0 \leq \theta_k \leq \infty$ و $1 \leq c_k \leq 2$ است و در نهایت باید محاسبه شوند. مقدار پیش‌بینی شده توسط مدل کریجینگ، بر اساس معادله ۸ بیان می‌شود

$$\hat{y}(x) = \hat{\beta} + r^T R^{-1} (y - 1\hat{\beta}) \quad (8)$$

¹ Gaussian Correlation Function

۲-۴- معرفی شاخص پیشرفت مورد انتظار^۲

لازمه عملکرد مناسب یک الگوریتم بهینه‌سازی، ایجاد تعادل بین دو فاکتور مهم اکتشاف^۳ و استخراج^۴ است. قابلیت اکتشاف، مسئول ایجاد تنوع و پاسخ‌های جدید است و در مقابل، قابلیت استخراج، مسئول ایجاد تغییرات جزئی و بهبود موضعی پاسخ‌هایی است که قبلاً یافت شده‌اند. همان‌طور که پیش‌تر بیان شد یکی از ویژگی‌های منحصر به فرد مدل کریجینگ، تعیین میزان واریانس مقدار پیش‌بینی شده است. از این ویژگی، به منظور تعیین مقدار EI استفاده می‌شود. مقدار EI در هر نقطه به صورت معادله ۱۰ تعریف می‌شود (Viana et al., 2013)

$$(10)$$

$$EI(x) = (y_{PBS} - \hat{y}(x)) \times \phi\left(\frac{y_{PBS} - \hat{y}(x)}{s(x)}\right) + s(x) \times \varphi\left(\frac{y_{PBS} - \hat{y}(x)}{s(x)}\right)$$

که در آن

ϕ برابر با تابع توزیع تجمعی^۵ و φ تابع چگالی احتمال^۶ در توزیع نرمال تعریف می‌شود. y_{PBS} کمترین مقدار تابع هدف در مجموعه داده‌ها، $\hat{y}(x)$ پیش‌بینی انجام شده توسط مدل کریجینگ و $s(x)$ انحراف معیار نمونه‌های پیش‌بینی شده است.

جونز و همکاران نشان دادند که میزان EI در قسمت‌های دارای بیشترین میزان انحراف معیار (مناطق از فضای جست‌وجو که کمتر

² Expected Improvement (EI)

³ Exploration

⁴ Exploitation

⁵ Cumulative Density Function (CDF)

⁶ Probability Density Function (PDF)

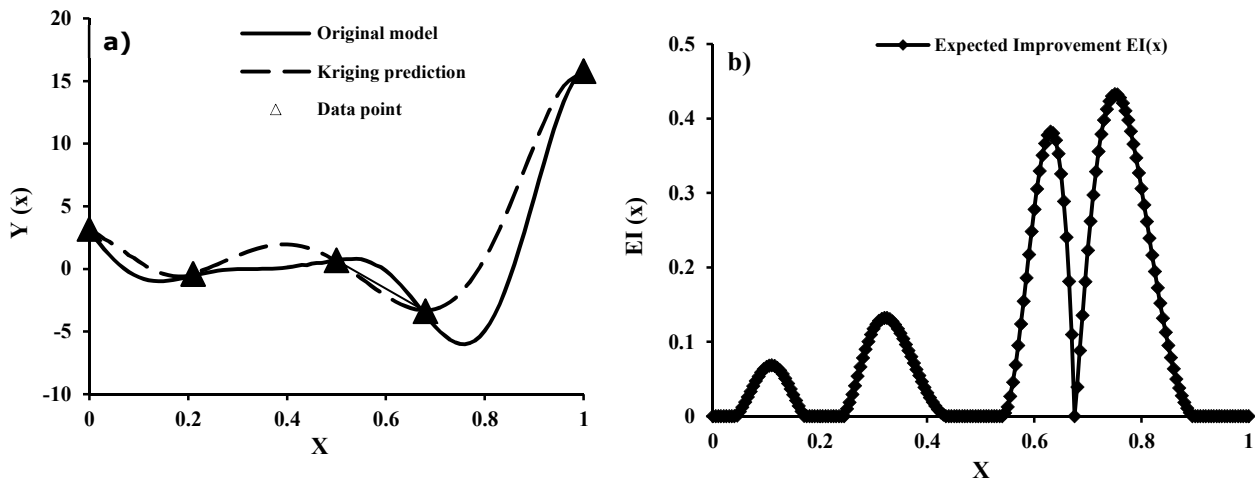


Fig. 1. a) Calculation of the prediction values for different points of the math function $y(x) = (6x-2)^2 \sin(12x-4)$
 b) Calculation of the $EI(x)$ values for different points

شکل ۱-ا) محاسبه مقدار پیش‌بینی برای نقاط مختلف تابع ریاضی، $y(x) = (6x-2)^2 \sin(12x-4)$ (ب) محاسبه مقدار $EI(x)$ برای نقاط مختلف

را در استفاده از دو بخش اکتشاف و استخراج همراهی کند. با توجه به اینکه استفاده از پارامتر EI می‌تواند مسیر بهینه‌سازی را هوشمندتر سازد، راهکار به کار گرفته شده در این پژوهش استفاده از پارامتر EI در انتخاب فرزندان حاصل از ازدواج و جهش است که در قالب ژنتیک الگوریتم-کریجینگ^۱ بیان می‌شود. ساختار اصلی تشکیل دهنده الگوریتم GA-Kriging همانند الگوریتم متداول GA است. تفاوت دو الگوریتم در تعداد فرزندان تولید شده و نحوه گزینش فرزندان است. در صورتی که تعداد فرزندان تولید شده با استفاده از عملگرهای تقاطع و جهش در الگوریتم GA برابر با λ در نظر گرفته شود، در الگوریتم GA-Kriging تعداد فرزندان برابر با λ' که $\lambda' > \lambda$ است. پارامتری است که مقدار آن باید توسط کاربر مشخص شود. نحوه گزینش فرزندان و انتقال آن‌ها به نسل بعد در الگوریتم GA فقط بر اساس میزان تابع هدف اصلی انجام می‌شود. این در حالی است که در الگوریتم GA-Kriging، میزان EI محاسبه شده نیز علاوه بر میزان تابع هدف در انتخاب فرزندان تأثیر دارد. روند کلی روش الگوریتم GA-Kriging مطابق شکل ۲ است.

۳- نتایج و بحث

در این قسمت روش محاسباتی پیشنهادی بر روی یک نمونه شبکه آبرسانی مرجع مورد بررسی قرار گرفت. این شبکه در ابتدا توسط

بررسی شده) و نقاط نزدیک به بهترین پاسخ یافته شده، دارای بیشترین مقدار است (Jones et al., 1998). در نتیجه با جست‌وجو در نقاطی که میزان پارامتر EI دارای بیشترین مقدار است به گونه‌ای، دو بخش مهم الگوریتم بهینه‌سازی یعنی بخش‌های اکتشاف و استخراج پوشش داده می‌شود. به‌عنوان نمونه در شکل ۱-ا مقدار یک تابع ریاضی در نقاط $[0, 0.21, 0.5, 0.68, 1]$ مشخص شده است. با استفاده از این نقاط، مدل کریجینگ آموزش دید و برای سایر نقاط، مقدار پیش‌بینی و میزان انحراف معیار محاسبه شد. پس از آن، با استفاده از معادله ۱۰ برای نقاط مختلف میزان EI محاسبه شد. با مشاهده نتایج به‌دست آمده در شکل ۱-ب مشخص شد که میزان EI در نقاط جست‌وجو نشده (ناحیه بین نقاط محاسباتی) و همچنین اطراف محل بهترین پاسخ یافت شده (۰/۶۸) دارای بیشترین مقدار است. در نتیجه جست‌وجو در نقاطی که دارای بیشترین مقدار پارامتر EI هستند، سبب می‌شود تا از یک طرف، مناطق کمتر بررسی شده، پوشش داده شوند و از طرف دیگر، با جست‌وجو در نقاط نزدیک به بهترین پاسخ یافت شده، پاسخ‌های بهینه‌تر حاصل شوند.

۴-۲- الگوریتم بهینه‌سازی مدل جایگزین

همان‌طور که در بخش‌های قبل بیان شد استفاده از نقاطی که دارای بیشترین میزان پارامتر EI هستند می‌تواند الگوریتم بهینه‌سازی

¹ Genetic Algorithm-Kriging (GA-Kriging)

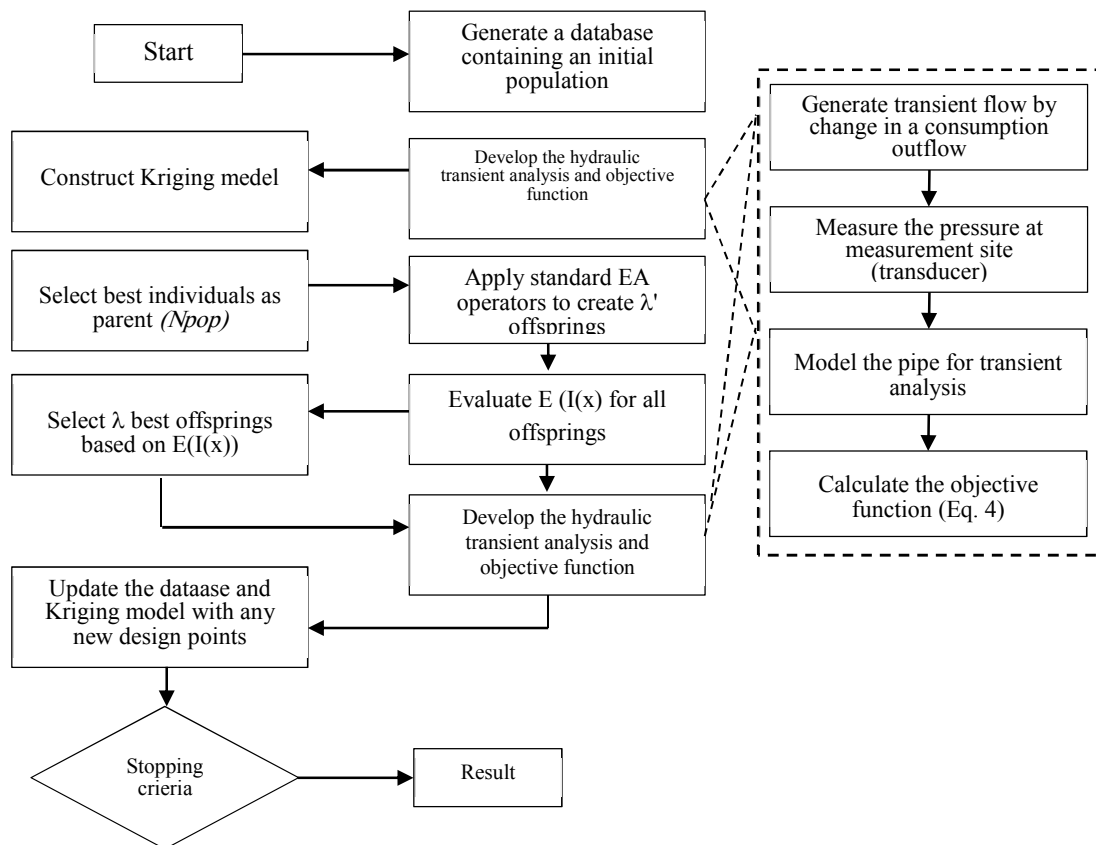


Fig. 2. Flowchart of GA-Kriging method
 شکل ۲- روند نمای روش GA-Kriging

پودار و لیگت معرفی شد و تاکنون توسط پژوهشگران بسیاری مورد ارزیابی قرار گرفته است (Pudar and Liggett, 1992). شبکه مورد بررسی از ۱۱ خط لوله و ۷ گره اصلی مطابق شکل ۳ تشکیل شده است. تغذیه این شبکه توسط یک مخزن با هد پیزومتریک ۳۰ متری در گره شماره ۱ و دبی ورودی با نرخ ثابت ۲۰ لیتر در ثانیه در گره شماره ۷ انجام می‌شود. از طرفی گره شماره ۴ با نرخ خروجی آب ۵۸ لیتر در ثانیه در شبکه یک گره با مصرف ثابت است. تمامی خطوط لوله دارای طول یکسان ۷۶۲ متر و قطر یکسان ۲۵۴ میلی‌متر هستند. میزان سرعت موج در تمامی لوله‌ها برابر ۱۳۱۶ متر در ثانیه تعیین شد. مشخصات خطوط لوله به کار گرفته‌شده در شکل ۳ به همراه مقدار ضرایب افت داری-ویسباخ مشخص شده است. به منظور ایجاد جریان گذرا با توجه به پژوهش شاملو و همکاران میزان جریان خروجی از گره شماره ۴ از ۵۹ لیتر در ثانیه به ۲۸ لیتر در ثانیه در مدت زمان ۱۰ ثانیه کاهش پیدا کرد و مجدداً در همین مدت زمان به ۵۹ لیتر در ثانیه افزایش پیدا کرد

(Shamloo et al., 2010). به منظور حل مسئله و یافتن میزان محل و تعداد نشت در شبکه تمام گره‌ها به جز گره مخزن به عنوان پتانسیل محل وجود نشت انتخاب شدند. در نتیجه تعداد متغیرهای تصمیم حل مسئله برابر با ۶ عدد بود. حدود تغییرات متغیرهای تصمیم‌گیری (سطح مقطع منفذ نشت) برای تمامی گره‌ها $0 \leq A_e (\text{cm}^2) \leq 10$ در نظر گرفته شد.

شبکه مورد نظر به صورت عددی مطابق روش محاسباتی MOC به همراه مدل‌سازی شرایط مرزی در نرم‌افزار MATLAB شبیه‌سازی شد. تابع هدف مشابه با معادله ۴ و سایت برداشت پاسخ، جریان گذرای ایجاد شده در گره شماره ۴ انتخاب شد.

تنظیم پارامترهای موجود در الگوریتم‌های بهینه‌سازی مانند نرخ جهش الگوریتم ژنتیک، نقش مهمی را در نتیجه نهایی به دست آمده از این الگوریتم‌ها ایفا می‌کنند. به منظور تنظیم این پارامترها از روش آنالیز حساسیت استفاده شد. به این منظور مقادیر مختلفی برای هر پارامتر در نظر گرفته شد و میزان تابع هدف به ازای آن‌ها

عملکرد روش‌های بهینه‌سازی مورد استفاده در این پژوهش مقدار مربوط به کمینه تابع هدف به دست آمده، میزان خطای حاصل از مقدار مجهول به دست آمده با مقدار واقعی و سرعت همگرایی تابع هدف مشخص بررسی شدند. در همین راستا هرکدام از روش‌های مورد استفاده در این پژوهش ۱۰ مرتبه مورد ارزیابی قرار گرفتند. شرط توقف برای هر الگوریتم تعداد ۳۰۰۰ مرتبه ارزیابی تابع هدف^۱ قرار داده شد.

نتایج حاصل از ده مرتبه ارزیابی تابع هدف شبکه آبرسانی برای هر دو الگوریتم GA و GA-Kriging در شکل ۴ نشان داده شده است. مطابق شکل ۴، مقایسه نتایج حاصل از دو الگوریتم GA و GA-Kriging نشان می‌دهد که در تمام ارزیابی‌ها، الگوریتم GA-Kriging توانسته به مقدار تابع هدف کمتری نسبت به الگوریتم GA دست پیدا کند. این امر نشان داد که در صورتی که شرط توقف میزان محدود تابع هدف قرار داده شود، الگوریتم GA-Kriging عملکرد برتری نسبت به الگوریتم GA دارد. به منظور مقایسه دقیق‌تر نتایج، مقدار مربوط به میانگین، بهترین، بدترین و انحراف معیار مقادیر تابع هدف به دست آمده در میان ۱۰ مرتبه ارزیابی تابع هدف بررسی شدند (جدول ۲).

پارامتر مهم مورد بررسی در این نتایج، مقدار میانگین بود. مقدار میانگین نتایج حاصل از ۱۰ مرتبه ارزیابی تابع هدف، برای الگوریتم GA-Kriging برابر با ۰/۶۵ و برای الگوریتم GA برابر

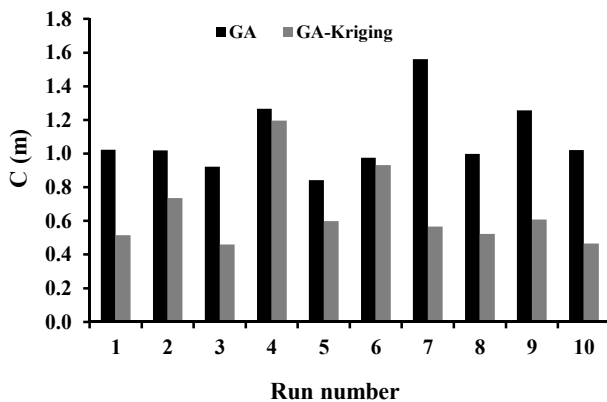


Fig. 4. The results of 10 times evaluation of the objective function of the water supply network for both GA and GA-Kriging algorithms

شکل ۴- نتایج حاصل از ده مرتبه ارزیابی تابع هدف شبکه آبرسانی برای هر دو الگوریتم GA و GA-Kriging

¹ Number of Function Evaluation (NFE)




Fig. 3. Configuration of reference water network (Pudar and Liggett, 1992)

شکل ۳- پیکربندی شبکه آبرسانی (Pudar and Liggett, 1992)

محاسبه شد. بهترین مقدار برای هر پارامتر زمانی است که تابع هدف در ازای آن کمینه شود. مقدار پارامترهای به دست آمده برای هر الگوریتم در جدول ۱ نشان داده شده است.

جدول ۱- مقدار پارامترهای مربوط به الگوریتم‌های مختلف

Table 1. The values for the parameter of different algorithms

Initial population	Population	Crossover probability	Mutation rate	λ'
300	40	0.5	0.05	$2 \times \lambda$

مقدار به دست آمده برای پارامترهای جمعیت اولیه، جمعیت تکاملی، نرخ تقاطع و نرخ جهش در هر دو الگوریتم GA و GA-Kriging مشترک هستند. پارامتر λ' مربوط به الگوریتم GA-Kriging است و بیان می‌کند که بهترین پاسخ الگوریتم GA-Kriging در حل مسئله نشت‌یابی زمانی است که مقدار آن دو، برابر فرزندان تولید شده در الگوریتم GA باشد. به منظور مقایسه

جدول ۳- نتایج نشت بهترین عملکرد الگوریتم‌های مختلف در گره‌های مختلف

Table 3. Leakage results for the best performance of different algorithms in different nodes

Node	True Ae (cm ²)	Approach	
		GA-Kriging	GA
2	1	0.76	0.58
3	0	0.01	0.08
4	0	0.02	0.07
5	0	0.01	0.05
6	0	0.03	0.01
7	0	0.01	0.05
Overall absolute differences (cm ²)		0.32	0.68




Fig. 5. Minimization process of the objective function for the reference water supply network vs. the NFE

شکل ۵- روند کمینه‌سازی تابع هدف شبکه آبرسانی مرجع در مقابل NFE

کند. به منظور ایجاد مقایسه عددی سرعت همگرایی در میان الگوریتم‌های استفاده شده تعداد ارزیابی‌ها و زمان رسیدن به یک مقدار مشخص تابع هدف، به عنوان معیار عملکردی در نظر گرفته شدند. سیستم مورد استفاده در این پژوهش شامل یک PC با پردازنده core i7 CPU 2.4 GHz و RAM 8 GB بود. به منظور در نظر گرفتن یک معیار با هدف مقایسه عملکرد دو الگوریتم، پاسخ نهایی به دست آمده توسط الگوریتم GA را به عنوان ملاک ارزیابی در نظر گرفته شد. زمان محاسباتی برای الگوریتم GA به منظور رسیدن به پاسخ نهایی ۱/۰۸ نزدیک به ۲/۷۸ ساعت ثبت شد. این در حالی است که الگوریتم GA-Kriging پس از محاسبه ۷۲۱ مرتبه ارزیابی تابع هدف و زمان محاسباتی ۰/۶۷ ساعت به این

جدول ۲- نتایج آماری حاصل از ۱۰ مرتبه ارزیابی تابع هدف شبکه آبرسانی

Table 2. The statistical results of 10 times evaluation of objective function for water supply network

Cost function	Approach	Mean	Best	Worst	Std.
C (m)	GA-Kriging	0.65	0.38	1.19	0.23
	GA	1.08	0.84	1.56	0.20

با ۱/۰۸ به دست آمد. مقایسه این دو مقدار کاهش ۳۹ درصد میزان تابع هدف را در الگوریتم GA-Kriging نسبت به الگوریتم GA نشان داد. مقایسه مقدار بهترین و بدترین عملکرد در میان ده مرتبه ارزیابی نیز برتری محاسباتی الگوریتم GA-Kriging را نسبت به الگوریتم GA نشان داد. معیار دیگری مورد بررسی میزان انحراف معیار است که از آن می‌توان به منظور مقایسه میزان ثبات در نتایج استفاده کرد. در این شاخص الگوریتم GA توانست با مقدار کمتر به دست آمده نشان دهد که دارای ثبات بیشتری در نتایج است.

به منظور بررسی میزان توانایی هر یک از الگوریتم‌ها در یافتن پارامترهای مجهول نشت، نتایج حاصل از بهترین عملکرد هر یک از الگوریتم‌ها در جدول ۳ نشان داده شده است. نتایج حاصل از دو الگوریتم نشان داد که بیشترین میزان سطح مقطع منفذ نشت در گره شماره ۲ است. این بدان معنی است که در هر دو الگوریتم محل اصلی نشت به درستی شناسایی شده است. در ردیف انتهایی جدول ۳ میزان مجموع خطای نتایج سطح مقطع منفذ نشت به دست آمده نسبت به مقدار واقعی محاسبه شد. این میزان خطا برای هر دو الگوریتم GA-Kriging و الگوریتم GA به ترتیب برابر با ۰/۳۲ و ۰/۶۸ به دست آمد. مقایسه این مقدار نشان داد که الگوریتم GA-Kriging دارای خطای محاسباتی کمتری به اندازه ۵۲ درصد نسبت به الگوریتم GA است.

معیار دیگر بررسی عملکرد الگوریتم‌های بهینه‌سازی سرعت کاهش میزان تابع هدف است. به این منظور از روند کاهش میانگین ۱۰ مرتبه ارزیابی مطابق شکل ۵ استفاده شد. به منظور درک بهتر روند کاهش تابع هدف، محور قائم مربوط به میزان تابع هدف در شکل ۵ در مقیاس لگاریتمی قرار داده شد. مقایسه روند کاهش تابع هدف در شکل ۵ نشان می‌دهد که الگوریتم GA-Kriging محاسبات هوشمندانه‌تری نسبت به الگوریتم GA داشته و توانسته است در ازای مقادیر تابع هدف یکسان به نتایج بهتری دست پیدا

افزایش کارایی روند بهینه‌سازی در روش ITA بود. از روش پیشنهادی به منظور یافتن نشت در یک شبکه آبرسانی مرجع استفاده شد. نتایج حاصل از الگوریتم پیشنهادی GA-Kriging و الگوریتم متداول GA مورد مقایسه قرار گرفتند. مقایسه و بررسی نتایج در دو بخش دقت نتایج نشت به دست آمده و سرعت کاهش تابع هدف انجام شد. در بخش دقت نتایج به دست آمده، میزان سطح مقطع منفذ نشت به دست آمده در روش GA-Kriging نسبت به الگوریتم GA به مقادیر واقعی نزدیک‌تر بود. در بخش سرعت کاهش میزان تابع هدف نیز الگوریتم GA-Kriging نسبت به الگوریتم GA از سرعت بیشتری برخوردار بود. پژوهش حاضر نشان داد که با استفاده مناسب از مدل‌های جایگزین می‌توان در حل فرایند بهینه‌سازی مسئله ITA از محاسبات تکراری به‌خصوص در روش‌های استوکاستیک اجتناب کرد و کارایی محاسباتی را افزایش داد. با توجه به موفقیت استفاده از مدل جایگزین کریجینگ و شاخص EI در حل مسئله ITA در پژوهش‌های آتی استفاده از سایر مدل‌های جایگزین و طراحی الگوریتم بهینه‌سازی جدید به منظور بررسی عملکرد آن‌ها پیشنهاد می‌شود.

۵- قدردانی

نویسندگان مقاله از حمایت‌های همه جانبه گروه عمران دانشگاه شهید چمران اهواز کمال تقدیر و تشکر را دارند.

مقدار دست یافت. مقایسه زمان محاسباتی نشان داد که روش GA-Kriging نزدیک به ۲/۱۱ ساعت و یا ۷۵ درصد صرفه‌جویی محاسباتی نسبت به الگوریتم GA داشت. این امر، برتری محاسباتی روش GA-Kriging را در سرعت کاهش میزان تابع هدف نشان داد. علت افزایش راندمان محاسباتی این روش را می‌توان در انتخاب هوشمندانه‌تر فرزندان عنوان کرد که شانس ایجاد پاسخ‌های بهتر را افزایش می‌دهد.

۴- نتیجه‌گیری

استفاده از مدل‌های جایگزین در حل مسائل بهینه‌سازی، سبب کاهش هزینه محاسباتی می‌شود، به این صورت که به جای اجرای تابع هزینه بر اصلی می‌توان یک مدل با بار محاسباتی کم با همان رفتار جایگزین شود. این مدل‌ها با کمک اطلاعاتی که در روند فرایند بهینه‌سازی در فضای جست‌وجو به دست می‌آورند، مسیر فرایند بهینه‌سازی را به گونه‌ای هدایت می‌کنند که در نهایت سبب کاهش تعداد ارزیابی‌های تابع هدف اصلی مسئله خواهند شد. انتخاب نوع و نحوه مدیریت مدل جایگزین در نتایج به دست آمده بسیار مؤثر خواهد بود. در این پژوهش سعی شد تا با استفاده از اصلاح انتخاب فرزندان در جمعیت الگوریتم ژنتیک با استفاده از ویژگی ساختاری مدل جایگزین کریجینگ و محاسبه پارامتر EI، راندمان محاسباتی افزایش یابد. از آنجایی که هدف از این پژوهش

References

- Chaudhry, M. H. 2014. *Transient flow equations*, Springer, New York, USA.
- Covas, D. & Ramos, H. 2001. Hydraulic transients used for leakage detection in water distribution systems. *Proceeding 4th International Conference on Water Pipeline Systems*, United Kingdom.
- Haghighi, A., Covas, D. & Ramos, H. 2012a. Direct backward transient analysis for leak detection in pressurized pipelines: from theory to real application. *Journal of Water Supply: Research Technology-Aqua*, 61, 189-200.
- Haghighi, A. & Ramos, H. M. 2012b. Detection of leakage freshwater and friction factor calibration in drinking networks using central force optimization. *Water Resources Management*, 26, 2347-2363.
- Hwang, J. T. & Martins, J. 2018. A fast-prediction surrogate model for large datasets. *Journal of Aerospace Science Technology*, 75, 74-87.
- Jin, Y. 2011. Surrogate-assisted evolutionary computation: recent advances and future challenges. *Journal of Swarm Evolutionary Computation*, 1, 61-70.
- Jin, Y., Olhofer, M. & Sendhoff, B. 2002. A framework for evolutionary optimization with approximate fitness functions. *Journal of IEEE Transactions on Evolutionary Computation*, 6, 481-494.

- Jones, D. R., Schonlau, M. & Welch, W. J. 1998. Efficient global optimization of expensive black-box functions. *Journal of Global Optimization*, 13, 455-492.
- Kapelan, Z. S., Savic, D. A. & Walters, G. A. 2003. A hybrid inverse transient model for leakage detection and roughness calibration in pipe networks. *Journal of Hydraulic Research*, 41, 481-492.
- Keramat, A., Ghidaoui, M. & Wang, X. 2017. Inverse transient analysis for pipeline leak detection in a noisy environment. *37th IAHR World Congress*, Kuala Lumpur, Malasia.
- Liggett, J. A. & Chen, L. C. 1994. Inverse transient analysis in pipe networks. *Journal of Hydraulic Engineering*, 120, 934-955.
- Pudar, R. S. & Liggett, J. A. 1992. Leaks in pipe networks. *Journal of Hydraulic Engineering*, 118, 1031-1046.
- Shamloo, H. & Haghghi, A. 2009. Leak detection in pipelines by inverse backward transient analysis. *Journal of Hydraulic Research*, 47 (3), 311-318.
- Shamloo, H. & Haghghi, A. 2010. Optimum leak detection and calibration of pipe networks by inverse transient analysis. *Journal of Hydraulic Research*, 48 (3), 371-376.
- Shi, L. & Rasheed, K. 2008. ASAGA: an adaptive surrogate-assisted genetic algorithm. *Proceedings of the 10th Annual Conference on Genetic and Evolutionary Computation*, ACM, New York. 1049-1056.
- Viana, F. A., Haftka, R. T. & Watson, L. T. 2013. Efficient global optimization algorithm assisted by multiple surrogate techniques. *Journal of Global Optimization*, 56, 669-689.
- Vítkovský, J. P., Simpson, A. R., Lambert, M. F. & Management 2000. Leak detection and calibration using transients and genetic algorithms. *Journal of Water Resources Planning*, 126, 262-265.
- Weil, G. J. 1993. Non contact, remote sensing of buried water pipeline leaks using infrared thermography. *Water Management in the '90s: a Time for Innovation*, ASCE, USA.
- Yu, H., Tan, Y., Zeng, J., Sun, C. & Jin, Y. 2018. Surrogate-assisted hierarchical particle swarm optimization. *Journal of Information Sciences*, 454, 59-72.
- Zhou, Z., Ong, Y. S. & Nair, P. B. 2004. Hierarchical surrogate-assisted evolutionary optimization framework. *Institute of Electrical and Electronics Engineers*, 2, 1586-1593.