

# گسسته‌سازی تطبیقی احتمالاتی برای حل مسائل بهینه‌سازی پیوسته با استفاده از الگوریتم ژنتیک – کاربرد در بهینه‌سازی سازه

علی رحمانی فیروزجائی<sup>۱\*</sup>، محمدهادی افشار<sup>۲</sup>

۱- دانشجوی دکترای عمران، دانشگاه علم و صنعت ایران

۲- دانشیار دانشکده عمران، دانشگاه علم و صنعت ایران

\*تهران، صندوق پستی ۱۶۳-۱۶۷۶۵

ARahmani@IUST.ac.ir

(دریافت مقاله: آذر ۱۳۸۵، پذیرش مقاله: خرداد ۱۳۸۶)

**چکیده-** در این تحقیق از الگوریتم ژنتیک برای بهینه‌سازی صفحات استفاده شده است. از آنجاکه الگوریتم ژنتیک در اساس برای بهینه‌سازی مسائل گسسته ابداع شده، برای حل مسائل پیوسته، به روشی برای گسسته‌سازی فضای جستجو نیاز است. در این مقاله روش جدیدی برای گسسته‌سازی فضای جستجوی پیوسته ارائه شده که در آن تدقیق گسسته‌سازی به‌طور خودکار انجام می‌شود. روش پیشنهادی امکان رسیدن به جوابهای بهتر را با صرف هزینه‌های محاسباتی بیشتر فراهم می‌نماید. با به‌کارگیری روش گسسته‌سازی ارائه شده و الگوریتم ژنتیک، مسأله بهینه‌سازی برای گروهی از توابع شناخته شده در این زمینه تحقیقاتی حل و نتایج به‌دست آمده ارائه شده است. تأثیر پارامترهای روش، با ارائه جداول و نمودارهایی بررسی شده و در نهایت طرح بهینه صفحه تنش مسطح ارائه و نتایج به‌دست آمده از روش ارائه شده، با نتایج روشهای دیگر مقایسه شده است.

**کلید واژگان:** بهینه‌سازی، گسسته‌سازی تطبیقی احتمالاتی، الگوریتم ژنتیک، بهینه‌سازی سازه‌ها، صفحات.

## ۱- مقدمه

طراحی بهینه سازه عبارت است از انتخاب متغیرهای طراحی به‌نحوی که وزن یا قیمت سازه به کمترین مقدار ممکن برسد و در عین حال قیدهای تنش و تغییر مکان ارضا شود. متغیرهایی طراحی مسائل بهینه‌سازی سازه می‌توانند متغیرهایی پیوسته یا گسسته باشند. در مسائل بهینه‌سازی سازه براساس روشهای برنامه‌ریزی ریاضی، تحقیقات متعددی انجام شده است [۱-۴]. با

توجه به اینکه روشهای برنامه‌ریزی ریاضی برای متغیرهای پیوسته توسعه یافته‌اند، لذا در تحقیقات انجام شده برای متغیرهای گسسته، در نظر گرفتن تمهیداتی لازم می‌نمورد. مقاله هانسن و واندرپلاتس [۵] و همچنین مقاله سلاجقه و واندرپلاتس [۶] در زمینه بهینه‌سازی سازه‌ها با متغیرهای گسسته اندازه و شکل با به‌کارگیری روشهای برنامه‌ریزی ریاضی، نمونه‌ای از این تحقیقات را نشان می‌دهند.

جمعیت فوق، تعدادی از افراد به‌عنوان والد مناسب به‌منظور تولید نسل بعدی انتخاب می‌شوند. انتخاب جمعیت جدید با توجه به تابع هدف محاسبه شده برای هر یک از کروموزم‌ها در کنار یک فرایند احتمالاتی انجام می‌شود، به‌نحوی که کروموزم‌های با تابع هدف مناسب‌تر، احتمال انتخاب بیشتری خواهند داشت. در میان روشهای انتخاب، می‌توان روش چرخ گردونه<sup>۷</sup> و روش رقابتی<sup>۸</sup> را نام برد [۸]. در فرایند تولید مثل، بخشهایی از اطلاعات ژنتیکی دو فرد والد با هم معاوضه می‌شود که این عملیات از طریق عملگر ریاضی تقاطع<sup>۹</sup> انجام می‌شود. برای جلوگیری از همگرایی زودرس<sup>۱۰</sup>، عملگر جهش<sup>۱۱</sup> اعمال می‌شود. این عملگر برخی از ژن‌های افراد حاصل از تقاطع را به‌طور تصادفی تغییر می‌دهد. هر دو عملگر تقاطع و جهش معمولاً به‌روش احتمالی اعمال می‌شوند [۹].

افراد نسل جدید جایگزین نسل قبلی می‌شوند و محاسبات فوق تا حصول به همگرایی ادامه می‌یابد. معیار همگرایی را می‌توان کل تعداد نسل‌های ایجاد شده یا تعداد نسل‌های متوالی که در آن مقدار تابع هدف بهینه تغییر نکرده است، تعریف کرد. روند بهینه‌سازی با الگوریتم ژنتیک در شکل ۱ ارائه شده است. به‌منظور بهبود کیفیت الگوریتم ژنتیک، گونه‌های جدیدتری از آن ارائه شده است که در میان آنها می‌توان به الگوریتم‌های ترکیبی<sup>۱۲</sup> اشاره کرد. در روشهای ترکیبی معمولاً سعی بر آن است تا با ترکیب الگوریتم ژنتیک و روشهای دیگر بهینه‌سازی، مزایای دو روش را حفظ کرده و معایب آنها را از بین ببرند یا به حداقل برسانند [۱۰-۱۳].

روشهای برنامه‌ریزی ریاضی معمولاً براساس مشتقات تابع عمل می‌کنند و به‌همین دلیل برای مسائلی که در آنها تعداد بهینه‌های موضعی زیاد باشند، در یافتن نقطه بهینه کلی کارایی کمتری دارند و این هنگامی که فضای جستجو بزرگ باشد، بیشتر نمایان خواهد شد. در چند دهه اخیر با الگو گرفتن از طبیعت، گونه‌ای از روشهای بهینه‌سازی توسعه یافته که براساس تکامل یک جمعیت اولیه، جواب بهینه را جستجو می‌کنند و در یافتن بهینه کلی، بسیار کارآمدتر از روشهای مبتنی بر مشتقات<sup>۱</sup> عمل می‌کنند.

امروز روشهای بهینه‌سازی تکاملی توسعه چشمگیری یافته‌اند. در این گروه می‌توان الگوریتم ژنتیک<sup>۲</sup> (GA)، جامعه مورچگان<sup>۳</sup> (ACO)، راهبردهای تکاملی<sup>۴</sup> (ES) و شبیه‌سازی بازپخت<sup>۵</sup> (SA) را نام برد [۷]. برخی از روشهای فوق مانند راهبردهای تکاملی و شبیه‌سازی بازپخت، برای یافتن مقادیر بهینه متغیرهای پیوسته و گروه دیگر برای متغیرهای گسسته کاربرد دارند. در صورت استفاده از روش گسسته برای حل مسأله‌ای با متغیرهای پیوسته، گسسته‌سازی فضای جستجو اجتناب‌ناپذیر است.

## ۲- الگوریتم ژنتیک

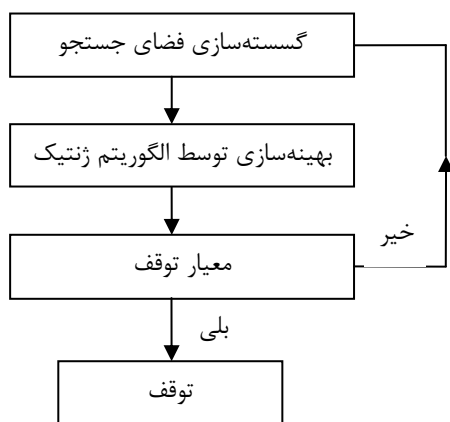
الگوریتم ژنتیک یکی از روشهای تکاملی است که در سالهای اخیر توسعه خوبی یافته است. فرایند بهینه‌سازی در این روش بر تکامل طبیعی استوار است. در الگوریتم ژنتیک، جمعیت<sup>۶</sup> اولیه‌ای از جوابها به‌طور تصادفی انتخاب و کدگذاری می‌شود. ارزیابی هر یک از افراد (کروموزم‌ها) در این جمعیت براساس تابع هدف انجام شده و سپس از میان

7. Roulette Wheel Selection  
8. Tournament Selection  
9. Crossover  
10. Premature Convergence  
11. Mutation  
12. Hybrid GA

1. Gradient Based  
2. Genetic Algorithm  
3. Ant Colony Optimization  
4. Evolution Strategy  
5. Simulated Annealing  
6. Population

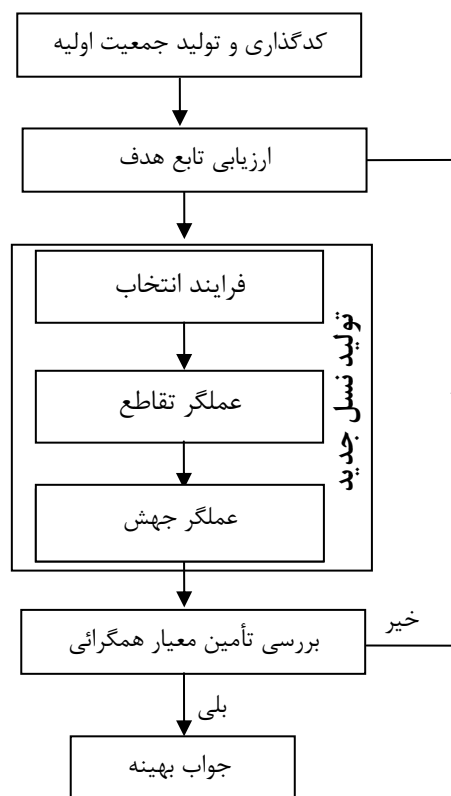
تقسیم می‌شود. در روش دوم زیر دامنه به‌نحوی تعیین می‌شود که فراوانی داده‌ها در هر بازه برابر مقدار معینی (که کاربر مشخص می‌کند) باشد. در روش سوم زیر دامنه به‌طور تصادفی تعیین می‌شود. در تمامی روشهای فوق در روند گسسته‌سازی، از اطلاعات مربوط به اندازه تابع استفاده نمی‌شود، لذا آنها را در گروه روشهای گسسته‌سازی بدون نظارت<sup>۵</sup> قرار می‌دهند [۱۵].

روشهای فوق در مسائل ساده‌ای با بازه‌های کوچک جوابهای مناسبی را به‌دست می‌دهد؛ اما هنگامی که فضای جستجو به‌طور قابل ملاحظه‌ای بزرگ و تابع دارای بهینه‌های موضعی<sup>۶</sup> متعددی باشد، به‌منظور رسیدن به جوابهای مناسب‌تر، استفاده از روشهای فوق به‌صورت تکراری با بازه‌های گسسته‌سازی که به‌تدریج تدقیق می‌شوند، لازم به‌نظر می‌رسد. روند بهینه‌سازی در این شرایط در شکل ۲ نشان داده شده است.



شکل ۲ روش بهینه‌سازی مسائل پیوسته با GA

در مقابل روشهای گسسته‌سازی بدون نظارت، روش‌هایی وجود دارند که در روند گسسته‌سازی از اطلاعات مربوط به اندازه تابع مورد بررسی استفاده می‌کنند. این گروه، روشهای



شکل ۱ روندنمای بهینه‌سازی در الگوریتم ژنتیک

### ۳- مرور روشهای گسسته‌سازی

گسسته‌سازی، نگاهی از فضای پیوسته به فضای گسسته است که در آن، فضای جستجو به تعداد محدودی بازه تقسیم می‌شود. تحقیقات زیادی در زمینه گسسته‌سازی انجام شده است. در میان اولین و ساده‌ترین روشها می‌توان گسسته‌سازی با پهنای مساوی<sup>۱</sup> و گسسته‌سازی با فراوانی یکسان<sup>۲</sup> و همچنین گسسته‌سازی تصادفی<sup>۳</sup> را نام برد [۱۴]. در روش اول با در نظر گرفتن حد بالا و پایین دامنه، محدوده به زیر دامنه‌هایی با پهنای مشخص (که کاربر مشخص می‌کند)

1. Equal Width Discretization
2. Equal Frequency Discretization
3. Random Discretization
4. User - Defined

5. Unsupervised Discretization Method
6. Local Optimum

گسسته‌سازی می‌کند. چمیلسکی (Chmielewski) روشی را پیشنهاد کرده که روش‌های محلی را به روش‌هایی کلی تبدیل می‌کند [۲۷].

تفاوت روش‌های گسسته‌سازی تجزیه‌کننده و ترکیب‌کننده در راهبرد جستجو است. در روش‌های تجزیه‌کننده، دامنه‌های بزرگتر به زیر دامنه‌هایی تبدیل می‌شوند؛ در حالی که در روش‌های ترکیب‌کننده، دو یا چند زیر دامنه ترکیب شده و دامنه بزرگتری را ایجاد می‌کنند. روش‌های ChiMerge و StatDisc و Khlops جزو این دسته محسوب می‌شوند.

در صورتی که تعداد بازه‌ها از پیش تعیین شده باشد، روش مستقیم نامیده می‌شود. برای مثال روش گسسته‌سازی با پهنای مساوی و فراوانی یکسان جزو این دسته‌اند اما در روش‌های گسسته‌سازی تدریجی، روند با گسسته‌سازی ساده‌ای شروع شده و به تدریج گسسته‌سازی دقیق می‌شود.

#### ۴- روش گسسته‌سازی تطبیقی احتمالاتی<sup>۱۰</sup>

در بهینه‌سازی مسائل پیوسته توسط روش‌های بهینه‌سازی گسسته، برای رسیدن به جواب‌های مناسب، گسسته‌سازی دامنه و استفاده از نوعی روند تکرار برای تدقیق گسسته‌سازی لازم است. در روش ارائه شده تدقیق گسسته‌سازی به‌طور خودکار<sup>۱۱</sup> انجام می‌شود. برای تشریح، روش به سه قسمت مجزا تفکیک می‌شود:

##### ۴-۱- گسسته‌سازی اولیه

در این قسمت فضای جستجو به تعداد  $nc$  فضای گسسته تبدیل می‌شود که هر فضای جستجوی گسسته، شامل  $ns$  بازه است. گسسته‌سازی اولیه به‌طور تصادفی انجام می‌شود:

گسسته‌سازی با نظارت<sup>۱</sup> نامیده می‌شوند. روش‌های گسسته‌سازی با نظارت به دو گروه مهم: الگوریتم‌های مبتنی بر آمار و الگوریتم‌های مبتنی بر بی‌نظمی (آنتروپی) تقسیم می‌شوند [۱۶]. در میان الگوریتم‌های مبتنی بر آمار می‌توان [۱۷] ChiMerge و [۱۸] Chi2 و [۱۹] Modified Chi2 و [۲۰] StatDisc و [۲۱] Khlops را نام برد. در میان الگوریتم‌های مبتنی بر بی‌نظمی می‌توان الگوریتم حداکثر بی‌نظمی (Maximum Entropy) [۲۲] و [۲۳] D2 و [۲۴] Entropy-MDLC را نام برد.

علاوه بر تقسیم‌بندی فوق روش‌های گسسته‌سازی را می‌توان به صورت دینامیک<sup>۲</sup> یا استاتیک<sup>۳</sup>، محلی<sup>۴</sup> یا کلی<sup>۵</sup>، تجزیه‌کننده<sup>۶</sup> یا ترکیب‌کننده<sup>۷</sup> و مستقیم<sup>۸</sup> یا تدریجی<sup>۹</sup> طبقه‌بندی کرد [۲۵].

در گسسته‌سازی استاتیک، تعداد بازه‌های گسسته‌سازی از پیش تعیین شده و در حین فرایند ثابت می‌ماند در حالی که در روش‌های دینامیک این مقدار به‌صورت پویا تعیین می‌شود. بنابر این روش‌های پهنای مساوی، فراوانی یکسان، روش‌های مبتنی بر آنتروپی، ChiMerge و مانند آن جزو روش‌های استاتیک هستند. تفاوت روش‌های استاتیک و دینامیک در مقاله دوارتی (Dougherty) تبیین شده است [۲۶].

روش‌های محلی و کلی در تعداد مشخصه‌هایی که گسسته‌سازی می‌شوند تفاوت دارند. روش‌های محلی محدود به گسسته‌سازی یک مشخصه هستند در حالی که روش‌های گسسته‌سازی کلی، تمامی مشخصه‌ها را به‌طور همزمان

1. Supervised Discretization Method
2. Dynamic
3. Static
4. Local
5. Global
6. Splitting
7. Merging
8. Direct
9. Incremental

10. Stochastic Adaptive Discretization Method  
11. Self Adaptivity

$$\sigma_i^* = \sqrt{\frac{\sum_{j=1}^{nc} (x_i^{*j} - \bar{x}_i^*)^2}{nc-1}}, \quad i = 1, 2, \dots, n \quad (4)$$

گسسته‌سازی در این مرحله با استفاده از اطلاعات به‌دست آمده از روابط (۲) تا (۴) به روش زیر انجام می‌شود:

$$S_{i,j}^k = \bar{x}_i^* + N(0, \sigma_i^*), \quad \begin{cases} i = 1, 2, \dots, n \\ j = 1, 2, \dots, ns \\ k = 1, 2, \dots, nc \end{cases} \quad (5)$$

با  $N(0, \sigma_i^*)$  عددی تصادفی با توزیع گوس (نرمال) با میانگین صفر و انحراف معیار  $\sigma_i^*$  است. بدین ترتیب امکان تدقیق در گسسته‌سازی فراهم می‌شود.

#### ۴-۳- معیار توقف

پس از انجام تکرارهای متوالی، به تدریج، مقادیر بهینه به‌دست آمده از مجموعه‌های متفاوت گسسته‌سازی شده، به سمت جواب واحدی همگرا می‌شوند و در این شرایط، انحراف معیار محاسبه شده از رابطه (۴) به سمت صفر میل می‌کند. بنابراین شرط زیر را می‌توان به‌عنوان معیار توقف روش در نظر گرفت:

$$\sigma_i^* \leq \varepsilon, \quad i = 1, 2, \dots, n \quad (6)$$

که  $\varepsilon$  عدد مثبت کوچکی در نظر گرفته می‌شود. روند کلی بهینه‌سازی به روش ارائه شده، در نمودار جریان شکل ۳ نمایش داده شده است.

#### ۵- مثالهای عددی

در این بخش به منظور ارزیابی روش حاضر، از چند تابع ریاضی که در [۲۸] ارائه شده و همچنین از یک مسأله سازه‌ای از [۲۹] استفاده می‌شود.

$$S_{i,j}^k = x_i^L + (x_i^U - x_i^L) \times \text{Ran}(0,1), \quad \begin{cases} i = 1, 2, \dots, n \\ j = 1, 2, \dots, ns \\ k = 1, 2, \dots, nc \end{cases} \quad (1)$$

که  $S$  مجموعه مقادیر گسسته‌سازی شده برای هر متغیر و برای هر مجموعه گسسته‌سازی شده،  $x_i^U$  و  $x_i^L$  به ترتیب حد پایین و بالای متغیر طراحی نام و  $n$  تعداد متغیرهای طراحی است.  $ns$  و  $nc$  به ترتیب تعداد مجموعه‌های گسسته‌سازی شده مورد نظر و تعداد تقسیمات (بازه‌های) لازم برای گسسته‌سازی هر دامنه است که جزو پارامترهای روش بوده و توسط کاربر تعیین می‌شوند،  $\text{Ran}(0,1)$  عددی تصادفی بین صفر و یک با توزیع یکنواخت است.

با در نظر گرفتن هر مجموعه گسسته‌سازی شده و با به‌کارگیری یک روش بهینه‌سازی گسسته (در این تحقیق الگوریتم ژنتیک) جوابهای بهینه‌ای برای آن مجموعه گسسته‌سازی شده به‌دست خواهد آمد:

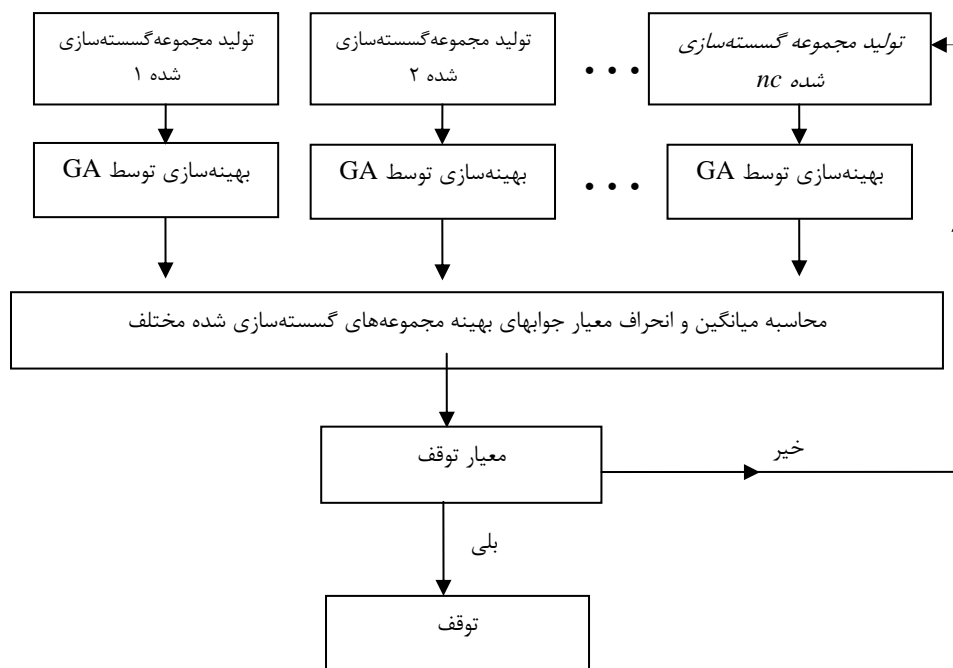
$$X^{*i} = (x_1^{*i}, x_2^{*i}, \dots, x_n^{*i})^T, \quad i = 1, 2, \dots, nc \quad (2)$$

$X^{*i}$  بردار مقادیر بهینه متغیرهای طراحی مربوط به مجموعه گسسته‌سازی شده نام است.

#### ۴-۲- گسسته‌سازی میانی

جوابهای بهینه به‌دست آمده برای مجموعه‌های گسسته‌سازی شده متفاوت، لزوماً یکسان نیستند. میانگین و انحراف معیار جوابهای بهینه مربوط به مجموعه‌های متفاوت گسسته‌سازی شده، برای هر متغیر طراحی از رابطه زیر محاسبه می‌شود:

$$\bar{x}_i^* = \frac{1}{nc} \sum_{j=1}^{nc} x_i^{*j}, \quad i = 1, 2, \dots, n \quad (3)$$



شکل ۳ نمودار جریان روش بهینه‌سازی ارائه شده برای مسائل پیوسته با GA

۱-۵- بهینه‌سازی توابع ریاضی

الف) تابع لوی شماره ۳ (Levy No.۳):

$$f(x) = \sum_{i=1}^n [i \cos((i-1)x_i + i)] \sum_{j=1}^n [j \cos((j+1)x_j + j)] \quad (7)$$

$$-1.0 \leq x_i \leq 1.0, \quad i = 1, 2$$

تابع فوق حدود ۷۶۰ بهینه موضعی دارد و ۱۸ بهینه آن حداقل مقدار تابع هدف را دارند و مقدار حداقل تابع برابر ۱۷۶,۵۴۲- است.

ب) تابع لوی شماره ۵ (Levy No.۵):

$$f(x) = \sum_{i=1}^n [i \cos((i-1)x_i + i)] \sum_{j=1}^n [j \cos((j+1)x_j + j)] \quad (8)$$

$$+ (x_1 + 1/42013)^2 + (x_2 + 0/80032)^2$$

$$-1.0 \leq x_i \leq 1.0, \quad i = 1, 2$$

این تابع حدود ۷۶۰ بهینه موضعی و فقط یک بهینه سراسری به مختصات  $(1/42013, 1/80032)^T$  دارد. مقدار بهینه سراسری این تابع برابر ۱۷۶/۱۳۷۵- است.

ج) تابع لوی شماره ۸ (Levy No.۸):

$$f(x) = \sin^2(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 \left[ 1 + 0.5 \sin^2(\pi y_i + 1) \right] \quad (9)$$

$$+ (y_n - 1)^2$$

$$y_i = 1 + \frac{x_i - 1}{4}$$

$$-1.0 \leq x_i \leq 1.0, \quad i = 1, 2, \dots, n$$

به‌ازای  $n=3$  دارای حدود ۱۲۵ بهینه موضعی و یک بهینه سراسری در نقطه  $(1,1,1)^T$  و مقدار تابع در نقطه بهینه برابر صفر است.

د) تابع فرودنستاین - روث (Freudenstein-Roth):

سراسری را تعیین کرد. جدولهای ۱ تا ۴ میانگین تعداد محاسبه تابع<sup>۱</sup> را برای توابع مختلف به ازای  $ns=50$  و  $nc$ های مختلف نشان می‌دهد. نتایج مربوط به روش گسسته‌سازی با بازه‌های مساوی با عنوان EIW نشان داده شده است.

جدول ۱ اطلاعات مربوط به  $nc=2$

میانگین تعداد محاسبات تابع	میانگین مقدار تابع	درصد موفقیت	مقدار بهینه سراسری
۱۱۳۹۵	-۱۷۲/۹۴۶	۸۰	-۱۷۶/۵۴
۶۴۱۶	-۱۵۷/۶۰۱	۶۰	-۱۷۶/۱۳۷
۵۰۰۶	۰/۰۰	۱۰۰	۰/۰۰
۵۹۲۷	۵/۸۶۶	۸۰	۳/۰۰
۷۲۷۷	۱/۲۳	۸۰	۰/۰۰

جدول ۲ اطلاعات مربوط به  $nc=3$

میانگین تعداد محاسبات تابع	میانگین مقدار تابع	درصد موفقیت	مقدار بهینه سراسری
۳۹۱۵۶	-۱۷۶/۰۷	۹۰	-۱۷۶/۵۴
۱۲۳۳۸	-۱۷۶/۱۳۷	۱۰۰	-۱۷۶/۱۳۷
۶۴۰۳	۰/۰۰	۱۰۰	۰/۰۰
۱۰۲۴۷	۳/۰۰	۱۰۰	۳/۰۰
۸۹۲۷	۰/۰۰	۱۰۰	۰/۰۰

جدول ۳ اطلاعات مربوط به  $nc=5$

میانگین تعداد محاسبات تابع	میانگین مقدار تابع	درصد موفقیت	مقدار بهینه سراسری
۱۲۵۹۸۱	-۱۷۶/۵۴	۱۰۰	-۱۷۶/۵۴
۲۳۲۸۸	-۱۷۶/۱۳۷	۱۰۰	-۱۷۶/۱۳۷
۱۱۶۲۱	۰/۰۰	۱۰۰	۰/۰۰
۱۸۵۰۴	۳/۰۰	۱۰۰	۳/۰۰
۱۷۶۲۶	۰/۰۰	۱۰۰	۰/۰۰

$$f(x) = [-13 + x_1 + ((5 - x_1)x_1 - 2)x_1]^2 + (-29 + x_1 + ((x_1 + 1)x_1 - 14)x_1)^2 \quad (10)$$

$$-10 \leq x_i \leq 10, \quad i=1,2$$

دارای بهینه سراسری  $(5,4)^T$  با مقدار تابع هدف برابر صفر است.

تابع گلدستین - پرایس (Goldstein-Price):

$$f(x) = |1 + (x_1 + x_2 + 1)(19 - 14x_1 + 3x_1^2 - 14x_2 + 7x_1x_2 + 3x_2^2)| + |30 + (2x_1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 + 48x_2 - 37x_1x_2 + 27x_2^2)| \quad (11)$$

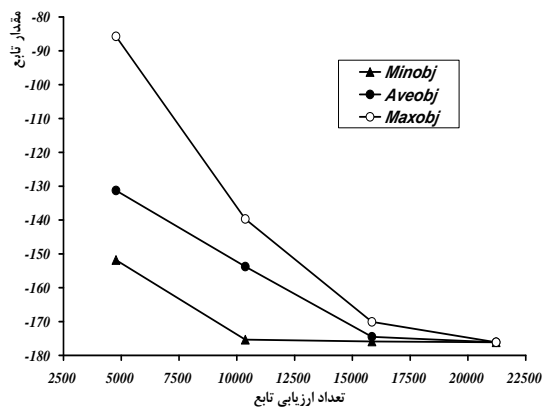
$$-10 \leq x_i \leq 10, \quad i=1,2$$

این تابع نیز فقط یک بهینه سراسری به مختصات  $(-1, -1)^T$  دارد و مقدار تابع در این نقطه برابر ۳ است.

در این تحقیق به منظور ارزیابی روش فوق و بررسی تأثیر پارامترهای موجود،  $nc \in \{2, 3, 5\}$  و  $ns \in \{5, 10, 15, 20, 25\}$  در نظر گرفته شده است. تعداد جمعیت در فرایند بهینه‌سازی الگوریتم ژنتیک برابر ۱۰۰، احتمال تقاطع برابر ۱ و احتمال جهش برابر ۰/۰۲ در نظر گرفته شده است. معیار همگرایی الگوریتم ژنتیک، حداکثر ۱۰۰۰۰ نسل یا ۱۰۰ نسل متوالی بدون تغییر در مقدار بهینه فرض شده است.

از آنجاکه طبیعت الگوریتم ژنتیک و همچنین روش گسسته‌سازی ارائه شده تصادفی است، بنابراین طبیعی است در صورتی که این مسأله چندین بار حل شود، تعداد ارزیابی تابع هدف به منظور رسیدن به جواب نهایی لزوماً یکسان نیست. با در نظر گرفتن میانگین تعداد محاسبه تابع می‌توان ملاک مناسبی را برای هزینه محاسباتی بهینه‌سازی ارائه کرد. در این تحقیق میانگین تعداد محاسبه تابع هدف با ۱۰ بار حل هر مسأله محاسبه شده است. به همین ترتیب با در نظر گرفتن ۱۰ بار حل هر مسأله و تعیین تعداد دفعاتی که جواب بهینه سراسری محاسبه شده، می‌توان درصد موفقیت در یافتن جواب بهینه

محروم است. به‌ازای  $ns$ ‌های متفاوت، نتایج همین روند را تأیید می‌کند. شکل ۴ روند رسیدن به جواب بهینه را برای تابع لوی شماره ۵ با  $nc=5$  و  $ns=250$  نشان می‌دهد.



شکل ۴ روند رسیدن به جواب بهینه

در این نمودار  $maxobj$  مقدار بیشینه پاسخ بهینه محاسبه شده توسط مجموعه‌های گسسته‌سازی شده در تکرار است.  $aveobj$  مقدار میانگین پاسخ بهینه محاسبه شده توسط مجموعه‌های گسسته‌سازی شده در تکرار است.  $minobj$  مقدار کمینه پاسخ بهینه محاسبه شده توسط مجموعه‌های گسسته‌سازی شده به‌عبارتی بهینه حاصل از روش است. روی محور افقی تعداد ارزیابی تابع هدف نشان داده شده است.

### ۲-۵- بهینه‌سازی صفحه تنش مسطح<sup>۱</sup>

بهینه‌سازی صفحه‌ای مطابق شکل ۵ را با دو متغیر طراحی شکل<sup>۲</sup> در نظر می‌گیریم به‌طوری که وزن سازه کمترین مقدار ممکن را داشته باشد. سه بار منفرد  $F_1$  و  $F_2$  و  $F_3$  به صفحه اعمال می‌شود و صفحه در قسمت تحتانی گیردار شده است. ضریب پواسون مصالح صفحه برابر  $0.15$  و

جدول ۴ اطلاعات مربوط به روش گسسته‌سازی با بازه‌های مساوی (EIW)

مقدار بهینه سراسری	درصد موفقیت	میانگین مقدار تابع	میانگین تعداد محاسبات تابع	لوی شماره
-۱۷۶/۵۴	۶۰	-۱۶۱/۰۳	۳۲۷۴	۳
-۱۷۶/۱۳۷	۵۰	-۱۵۳/۲۴	۳۶۴۰	۵
۰/۰۰	۱۰۰	۰/۰۰	۲۷۳۴	۸
۳/۰۰	۶۰	۱۶/۵۰	۳۶۱۶	گلدستین - پرایس
۰/۰۰	۰	۱۵/۱۴	۳۲۶۵	فروندنستاین - روث

بررسی اطلاعات این جدولها نشان می‌دهد که افزایش تعداد مجموعه‌های گسسته‌سازی شده، تأثیر مثبت قابل ملاحظه‌ای بر رسیدن به جواب بهینه سراسری دارد. به‌عنوان نمونه درصد موفقیت و میانگین تعداد محاسبات تابع و همچنین میانگین زمان محاسبات برای رایانه‌ای با پردازشگر پنتیوم ۴ با فرکانس  $1/86$  GHz در بهینه‌سازی تابع لوی شماره ۵ با روش گسسته‌سازی با بازه‌های یکسان (EIW) و روش حاضر با تعداد مجموعه‌های گسسته‌سازی شده ۲ و ۵ در جدول ۵ ارائه شده است.

جدول ۵ مقایسه روش گسسته‌سازی با بازه‌های یکسان (EIW) و روش حاضر برای تابع لوی شماره ۵ با تعداد متفاوت مجموعه‌های گسسته‌سازی شده

nc=۵	nc=۳	Nc=۲	EIW	
۱۰۰	۱۰۰	۶۰	۵۰	درصد موفقیت
۲۳۲۸۸	۱۲۳۳۸	۶۴۱۶	۳۶۴۰	میانگین تعداد محاسبات تابع
۱۰/۴	۵/۵	۲/۹	۱/۶	میانگین زمان بهینه‌سازی (ثانیه)

بنابراین به‌منظور تأمین جوابهای مناسب‌تر، تعداد مجموعه‌های گسسته‌سازی شده را می‌توان افزایش داد. روش گسسته‌سازی با بازه‌های یکسان (EIW) از این امکان

1. Plane Stress  
2. Shape Design Variables



برابر صفر در نظر گرفته می‌شود. این سازه توسط برنامه کامپیوتری و به صورت تنش مسطح تحلیل شده است. در روند بهینه‌سازی با در نظر گرفتن  $n_c = 2$  و  $n_s = 25$ ، نتایج حاصل از روش بهینه‌سازی حاضر با روشهای مبتنی بر مفاهیم تقریب‌سازی ارائه شده در [۲۳] در جدول ۶ مقایسه شده است.

جدول ۶ مقایسه روشهای تقریب‌سازی با روش جدید


روش حاضر	تقریب دو نقطه‌ای با $p$ ثابت	تقریب خطی	
۰/۳۵	۰/۳۴	۰/۳۴	$x_1$ (m)
۰/۲۱	۰/۲۶	۰/۲۶	$x_2$ (m)
۱۹۳/۲۵	۱۹۶/۴۴	۱۹۶/۴۴	وزن بهینه (kg)

### ۶- نتیجه‌گیری

در بهینه‌سازی مسائل پیوسته با استفاده از روشهایی که در اساس برای مسائل گسسته ارائه شده‌اند، به‌کارگیری روشهای گسسته‌سازی اجتناب‌ناپذیر است. در بسیاری از پژوهشهای مهندسی از روش گسسته‌سازی با بازه‌های مساوی به این منظور استفاده شده که در آن برای رسیدن به جواب بهینه سراسری یا جوابهای محلی، ابزاری در دست نیست. به بیان دیگر در این روش با افزایش تعداد بازه‌های گسسته‌سازی، تضمینی برای بهتر شدن جوابها وجود ندارد. به‌منظور بر طرف ساختن این معضل روش گسسته‌سازی تطبیقی احتمالاتی ارائه شده که برای تعداد معینی از بازه‌های گسسته‌سازی و تعداد معینی از مجموعه‌های گسسته‌سازی شده، امکان رسیدن به جوابهای بهتر با صرف هزینه محاسباتی بیشتر فراهم می‌شود.

با توجه به نتایج مسائل مطرح شده و مطالب ارائه شده و مقایسه جوابهای بهینه روش حاضر با روشهای گذشته، این

مدول الاستیسیته برابر  $(kg/m^2) \times 10^9 \times 2$  و وزن واحد حجم برابر  $(kg/m^2) \times 2400$  است. ضخامت صفحه  $(cm) \times 10$ ، تنش مجاز فشاری  $(kg/m^2) \times 10^9 \times 7$  و تنش مجاز کششی  $(kg/m^2) \times 10^4 \times 7$  در نظر گرفته می‌شود.



شکل ۵ صفحه و بارگذاری آن

مسئله بهینه‌سازی صفحه تنش مسطح فوق به شکل زیر

توصیف می‌شود:

$$\begin{aligned} \text{Min } & W(x_1) \\ \text{subject to:} & \\ & \frac{\sigma_i}{\sigma_{pi}} - 1 \leq 0, \quad i = 1, m \end{aligned} \quad (12)$$

که در آن  $W$  وزن صفحه، تابعی از متغیر طراحی اول بوده و  $m$  تعداد قیود تنش و  $\sigma_i$  و  $\sigma_{pi}$  به ترتیب تنش و تنش مجاز قید نام است. در این تحقیق با به‌کارگیری روش توابع جریمه، مسئله مقید فوق به صورت مسئله‌ای نامقید مطابق رابطه زیر درآمده و سپس بهینه‌سازی شده است.

$$\text{Min } W'(x_1, x_2) = W(x_1, x_2) + \sum_{i=1}^m \alpha_i \left( \frac{\sigma_i}{\sigma_{pi}} - 1 \right)^2 \quad (13)$$

در رابطه فوق  $\alpha_i$  ضریب جریمه‌ای<sup>۱</sup> است که برای قیود ارضا نشده مقداری بزرگ<sup>۲</sup> و برای قیدهای ارضا شده

#### 1. Penalty Factor

۲. در این تحقیق ضریب پنالتی برابر ۱۰۰۰ در نظر گرفته شده است.

- [6] Salajegheh E., Vanderplaats G.; "Optimum design of trusses with discrete sizing and shape variables", *Structural Optimization*; Vol. 6, 1993, pp. 79-85.
- [7] Back T.; "Evolutionary Algorithms in Theory and Practice", Oxford University Press, New York, 1996.
- [8] Goldberg DE.; "Genetic algorithms in search, optimization and machine learning". Reading, MA: Addison-Wesley, 1989.
- [9] Afshar M. H., Marino M. A.; "A convergent genetic algorithm for pipe network optimization", *Scientia Iranica*; Vol. 12, No. 4, 2005, pp. 392-401.
- [10] Yeh I. C.; "Hybrid genetic algorithms for optimization of truss structures", *Computer-Aided Civil and Infrastructure Engineering*; Vol. 14, No. 3, 1999, pp. 199-206.
- [11] Chan, C. M., Liu, P. and Wong, K. M.; "Optimization of large scale tall buildings using hybrid genetic algorithms", *Proc. 5th World Congress on Structural and Multidisciplinary Optimization*; Italy, 2003.
- [12] Chan C. M., Wong K. M.; "An Efficient Hybrid Genetic Algorithm for Structural Form and Element Sizing Design Optimization of Tall Steel Frameworks", *Proc. 6th World Congress of Structural*

روش، روشی کارآمد، مطلوب و بسیار مناسب برای یافتن بهینه سراسری است. به بیان دیگر در این روش می‌توان به‌منظور تأمین جوابهای مناسب‌تر، تعداد مجموعه‌های گسسته‌سازی شده را اضافه کرد؛ در حالی که روشهای مبتنی بر مفاهیم تقریب‌سازی و روش گسسته‌سازی با پهنای مساوی، از این امکان محروم هستند.

## ۷- منابع

- [1] Fadel G. M., Riley M. F., J. F. M. Barthelemy; "Two-Point Exponential Approximation Method for Structural Optimization", *Structural Optimization*; Vol. 2, 1990, pp. 117-124.
- [2] Wang L. P., Grandhi R. V.; "Efficient Safety Index Calculation for Structural Reliability Analysis", *Computers and Structures*; Vol. 52, 1994, pp. 103-111.
- [3] Wang L. P., Grandhi R. V.; "Improved Two-Point Function Approximations for Design Optimization", *AIAA Journal*; Vol. 33, 1995, pp. 1720-1727.
- [4] Salajegheh E.; "Optimum design of plate structures using three-point approximation"; *Structural Optimization*; Vol. 13, 1997, pp. 142-147.
- [5] Hansen S., Vanderplaats G.; "Approximation method for configuration optimization of trusses", *AIAA Journal*; Vol. 28, pp. 161-168, 1990.

- Trans. Knowledge and Data Eng.; Vol. 14, No. 3, 2002, pp. 666-670.
- [20] Richeldi M., Rossotto M.; “Class-Driven Statistical Discretization of Continuous Attributes (extended abstract)”, Machine Learning: ECLM-95 (Proc. European Conf. Machine Learning, 1995), N. Lavrac and S. Wrobel, eds., 1995, pp. 335-338.
- [21] Boulle M., “Khiops: A Statistical Discretization Method of Continuous Attributes”, Machine Learning; Vol. 55, 2004, pp. 53-59.
- [22] Wong A. K. C., Chiu D. K. Y.; “Synthesizing Statistical Knowledge from Incomplete Mixed-Mode Data”, IEEE Trans. Pattern Analysis and Machine Intelligence; Vol. 9, 1987, pp. 796-805.
- [23] Catlett J., “On Changing Continuous Attributes into Ordered Discrete Attributes”, Machine Learning-EWSL-91, Proc. European Working Session on Learning, 1991, pp. 164-178.
- [24] Fayyad U. M., Irani K. B.; “Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning”, Proc. 13th Int’l Joint Conf. Artificial Intelligence, 1993, pp. 1022-1027.
- [25] Liu H., Hussain F., Tan C. L., Dash M., “Discretization: An Enabling Technique”, and Multidisciplinary Optimization; Brazil, 2005.
- [13] Konak A., Bartolacci M. R.; “Designing survivable resilient networks: A stochastic hybrid genetic algorithm approach”; the international Journal of management science, Vol. 35, 2007, pp. 645 – 658
- [14] Aguilar–Ruiz j., Bacardit j., Divina f.; “Experimental Evaluation of Discretization Schemes for Rule Induction”, GECCO 2004, Deb K., et al. (Eds.), 2004, pp. 828–839.
- [15] Kurgan L. A., “CAIM Discretization Algorithm”, IEEE Trans. Knowledge and Data Eng.; Vol. 16, No. 2, 2004, pp. 145-153.
- [16] Liu X.; “A Discretization Algorithm Based on a Heterogeneity Criterion”, IEEE Trans. Knowledge and Data Eng.; Vol. 17, No. 9, 2005, pp. 1166-1173.
- [17] Kerber R., “ChiMerge: Discretization of Numeric Attributes”, Proc. 10th Int’l Conf. Artificial Intelligence (AAAI-91), 1992, pp. 123-128.
- [18] Liu H., Setiono R., “Feature Selection via Discretization”, IEEE Trans. Knowledge and Data Eng.; Vol. 9, No. 4, 1997, pp. 642-645.
- [19] Tay F. E. H., Shen L. X.; “A Modified Chi2 Algorithm for Discretization”, IEEE

[28] Parsopoulos K. E., Vrahatis M. N., "Recent Approaches to Global Optimization Problems through Particle Swarm Optimization", *J. Natural Computing*; Vol. 1, 2002, pp. 235-306.

[۲۹] سلاجقه عیسی و رحمانی فیروزجائی علی، «بهینه‌سازی صفحات با محدودیت تنش و تغییر مکان»، کنفرانس بین‌المللی مکانیک، دانشگاه علم و صنعت ایران، ۱۳۷۷، صص ۱۰۴۳-۱۰۳۵.

*Data Mining and Knowledge Discovery*; Vol. 6, 2002, pp. 393-423.

[26] Dougherty J., Kohavi R., Sahami M.; "Supervised and Unsupervised Discretization of Continuous Features", *Proc. 12<sup>th</sup> Int'l Conf. Machine Learning*, 1995, pp. 194-202.

[27] Chmielewski M. R., Grzymala-Busse J. W.; "Global Discretization of Continuous Attributes as Preprocessing for Machine Learning", *Int'l J. Approximate Reasoning*, Vol. 5, 1996, pp. 319-331.