

یک رهیافت جدید برای جایگاه یابی مسائل چند مدلی با استفاده از الگوریتم بهبود یافته جهش قورباغه

ایمان سیدی^۱، مليحه مغفوری فرسنگی^۲، محمد براتی^۱، حسین نظام آبادی پور^۳

۱- کارشناس ارشد مهندسی برق کنترل-دانشکده مهندسی -دانشگاه شهید باهنر کرمان

eiman.sayed@gmail.com, mbaratiz@gmail.com

۲- دانشیار بخش مهندسی دانشگاه شهید باهنر کرمان

mmaghfoori@uk.ac.ir

۳- دانشیار بخش مهندسی دانشگاه شهید باهنر کرمان

nezam@uk.ac.ir

چکیده: مسئله جایگاه یکی از روش‌های مهم برای بهینه‌سازی مسایل چند مدلی است. بیشتر روش‌های موجود در مسائل جایگاه نیاز به تعیین دقیقی از پارامترهای جایگاه به منظور عملکرد بهتر دارد. مشکل اصلی الگوریتم‌های ابتکاری در حل مسائل چند بعدی قدرت همگرایی آنها به یک جواب (عموماً بهینه فرا محلی) است. الگوریتم جهش قورباغه، از جمله الگوریتم‌های ابتکاری است که در سال‌های اخیر تا کنون نسخه‌ای از آن برای حل مسائل چند مدلی ارائه نشده است. در این مقاله نسخه‌ای از این الگوریتم برای حل مسائل چند مدلی با حفظ ساختارهای اساسی ارائه و با روش‌های مطرح مقایسه شده است. نتایج آزمایش‌ها روی توابع محک استاندارد توانایی الگوریتم پیشنهادی را تأیید می‌کند.

واژه‌های کلیدی: الگوریتم جهش قورباغه متعدد، بهینه‌های محلی، تابع قله-دره، روش‌های جایگاه یابی.

بسیاری از مسائل دنیای واقعی ذاتاً به صورت چند مدلی هستند به طوری که چندین نقطه بهینه برای حل آنها وجود دارد. برای حل مسائل بهینه‌سازی با چندین بهینه محلی و فرامحلی ممکن است به مشخص کردن مکان تمامی بهینه-ها نیاز باشد. در گذشته تکنیک‌های زیادی برای پیدا کردن این مکان‌ها ارائه و توسعه یافته‌اند. مسئله جایگاه یکی از روش‌های مهم برای بهینه‌سازی مسائل چند مدلی^۱ است. روش‌های جایگاه یابی حتی برای زمانی که هدف پیدا کردن یک نقطه بهینه فرامحلی است مؤثر واقع می‌شوند. از آنجایی که این روش‌ها به جستجوی موازی چندین بهینه در فضای مسئله می‌پردازنند، لذا الگوریتم کمتر، در بهینه-های محلی کمتر می‌گیرد. موفقیت الگوریتم‌های تکاملی در کاربردهای دنیای واقعی با استفاده از روش‌های جایگاه یابی همراه شده است [۱-۲۱]. همچنین برای حفظ کردن تنوع جمعیت در الگوریتم‌های تکاملی از روش‌های جایگاه

۱- مقدمه

در سال‌های اخیر الگوریتم‌های جستجوی تصادفی، از جمله الگوریتم‌های تکاملی، در حل بسیاری از مسائل دشوار بهینه سازی استفاده شده‌اند. شکل‌های استاندارد این الگوریتم‌ها معمولاً برای پیدا کردن یک بهینه فرامحلی (Global optimum) طراحی شده‌اند. با وجود این

^۱تاریخ ارسال مقاله: ۱۳۸۹/۱۱/۲۴

تاریخ پذیرش مقاله: ۱۳۹۰/۸/۱۸

نام نویسنده مسؤول: مليحه مغفوری
نشانی نویسنده مسؤول: ایران کرمان دانشگاه شهید باهنر
کرمان - بخش مهندسی برق

- ۱- نیازی به پارامترهای مربوط به جایگاه برای مشخص کردن فاصله بین دو نقطه بهینه یا تعدادی از بهینه‌ها نباشد.
- ۲- قادر به مشخص کردن چندین بهینه (بهینه محلی و فرامحلی) و حفظ کردن مکان بهینه جواب‌های پیدا شده تا پایان اجرای برنامه باشد.
- ۳- در مقایسه با روش‌هایی که همه نقاط جایگاه‌ها را ارائه می‌دهند دارای پیچیدگی محاسباتی کمتری باشد.
- سازماندهی مقاله به این طریق است که در بخش دوم الگوریتم جهش قورباغه متحرک بیان می‌شود و در بخش سوم الگوریتم جدید پیشنهادی این مقاله برای جایگاه یابی مسائل چند مدل بیان می‌گردد. در بخش چهارم نتایج حاصل از پیاده سازی الگوریتم پیشنهادی بر روی توابع محک استاندارد، تحلیل نتایج و مقایسه با بعضی از روش‌های موجود در حیطه مسائل مربوط به جایگاه ارائه و در بخش پنجم نتیجه گیری آورده شده است.

۲- الگوریتم جهش قورباغه

الگوریتم جهش قورباغه^{۱۱} یکی از الگوریتم‌های الهام گرفته از طبیعت است که توسط لنزی^{۱۲} و یوسف^{۱۳} توسعه داده شد. در این الگوریتم گروهی از قورباغه‌ها (مجموعه‌ای از جواب‌ها) به چندین زیر مجموعه^{۱۴} تقسیم می‌شوند، که هر قورباغه فرهنگ مختص به خود را دارد و می‌تواند از فرهنگ‌ها^{۱۵} یا ایده‌های قورباغه‌های دیگر در طول روند تکامل استفاده کند [۲۷-۲۲]. مراحل اجرای این الگوریتم در زیر توضیح داده شده است:

۱-۱- تولید جمعیت اولیه

همانند تمامی الگوریتم‌های شهودی^{۱۶} جمعیت اولیه (كورباغه‌ها) به صورت تصادفی^{۱۷} بین بازه مسئله با توجه به رابطه (۱) تولید می‌شود:

$$x_i = x_i^l + \text{rand} \times (x_i^h - x_i^l) \quad (1)$$

یابی استفاده شده است. برای معرفی این روش‌ها، می‌توان به روش ازدحامی^{۱۵}، روش ازدحامی قطعی^{۱۶}، روش شایستگی^{۱۷}، روش جایگاه یابی ترتیبی^{۱۸}، روش انتخاب رقابت محدود شده^{۱۹}، روش موازن سازی^{۲۰}، روش خوشبندی^{۱۱}، روش پاکسازی^۹، روش حفظ گونه^{۱۳}، اشاره کرد. عموماً پارامترهای جایگاه برای تعیین کردن فاصله بین دو بهینه نزدیک به هم استفاده می‌شوند. مثال مشخصی از این موضوع می‌توان به share^۵ در روش تسهیم شایستگی اشاره کرد [۷]. دیگر استفاده‌هایی که از پارامترهای جایگاه می‌شود، انتخاب CF در روش ازدحامی [۵]، مقدار W در روش انتخاب مسابقه‌ای محدود شده [۹] یا میانگین‌های دسته‌ها در روش خوشبندی است [۱۱ و ۷]. دلایل ارائه روش جدید در مقاله برای حل مسائل چند مدل به شرح زیر است:

۱- دشواری در حفظ کردن جواب‌های پیدا شده در یک بار اجرای مسئله: برای مثال، روش ازدحامی دی جانگ نمی‌تواند تمامی قله‌ها را در تکرارهای رو به جلو حفظ کند [۶]. یک الگوریتم جایگاه خوب باید قادر به حفظ کردن و نظم دادن به جواب‌های پیدا شده باشد.

۲- در روش‌های مرسوم جایگاه می‌توان مشاهده کرد که عمل همبری بین دو فرد شایسته از جمعیت در دو جایگاه متفاوت ممکن است باعث تولید یک نوزاد با شایستگی پایین تراز والد شود [۳].

۳- بعضی از روش‌های جایگاه فقط برای مشخص کردن تمام بهینه فرامحلی طراحی شده اند و از تعیین بهینه‌های محلی چشم پوشی شده است. برای مثال، در روش‌های جایگاه ترتیبی GA [۸]، پاکسازی [۱۲]، NichePSO [۱۳]، SPSO [۱۶] این امر اتفاق می‌افتد.

۴- پیچیدگی محاسبات بالا. بیشتر روش‌های مربوط به جایگاه به جز روش ازدحامی قطعی از این عیب رنج می‌برند. با این حال، بسیاری از محققین بر این عقیده هستند که روش ازدحامی قطعی به تعداد ارزیابی بالایی در پیدا کردن جواب نیاز دارد [۱۷] و از توزیع جمعیتی مناسبی برای پیدا کردن جایگاه‌ها برخوردار نیست [۱۸]. هدف این مقاله توسعه الگوریتم جایگاه با ارائه موارد زیر است:

Position change:

(۳)

$$D(i) = \text{rand}() \times (X_b - X_w)$$

که $\text{rand}()$ یک عدد تصادفی یکنواخت بین ۰ و ۱ است. موقعیت جدید قورباغه توسط رابطه (۴) به دست می‌آید که D_{\max} ماکریم تغییراتی است که در موقعیت قورباغه می‌توان اعمال کرد.

New Position:

$$X_w = \text{current position } X_w + D_i \quad D_{\max} \leq D_i \leq -D_{\max} \quad (4)$$

اگر این تغییر موقعیت، قورباغه‌ای با شایستگی بهتر تولید کرد این قورباغه جایگزین قورباغه بدتر می‌شود. در غیر این صورت، قورباغه با بهترین شایستگی در کل جمعیت (بهینه فرامحلی^{۱۸}) X_g جایگزین X_b در معادله (۳) شده و قورباغه جدیدی تولید می‌شود. اگر قورباغه‌ای با شایستگی بهتر تولید شود این قورباغه جایگزین قورباغه بدتر می‌شود. در غیر این صورت، قورباغه‌ای جدید به صورت تصادفی تولید و جایگزین بدترین قورباغه می‌گردد.

۴-۲- به هم آمیختن جمعیت^{۱۹}

پس از تکامل درونی چندین نسل، تمام مجموعه‌ها به هم آمیخته و بر اساس ارزش شایستگی آنها به صورت نزولی مرتب می‌شوند. سپس دوباره به چند زیر مجموعه تقسیم می‌گردند و روند تکامل در هر مجموعه تا زمانی که به معیار توقف برسد ادامه می‌یابد.

۵-۲- معايب الگوريتم

در الگوريتم‌های تکاملی که بر پایه جمعیت تصادفی هستند، عمدتاً دو جنبه باید بررسی شود: ۱- کاوش؛ ۲- بهره وری. کاوش به جستجوی بهتر فضای جستجو می‌باشد و بهره وری قادر به پیدا کردن بهینه بهتر حول بهترین جواب است. نکته مهم برای داشتن عملکرد مناسب، ایجاد مصالحه بین کاوش و بهره وری است. الگوريتم NFL ممکن است در بعضی از توابع بهینه سازی قادر به پیدا کردن بهینه فرامحلی نباشد و به رکود و افتادن

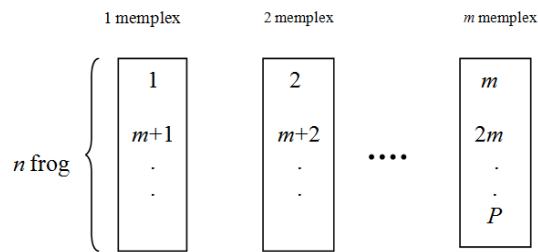
که در آن، x_i مقدار معادل هر عضو از جمعیت، x_i^h کران بالای متغیر x_i و rand یک مقدار تصادفی بین ۰ و ۱ است.

هر قورباغه نمایانگر یک راه حل قابل قبول در مسئله بهینه سازی است که دارای یک مقدار شایستگی است. قورباغه‌ها بر اساس شایستگی شان به صورت نزولی مرتب می‌شوند و بر اساس روندی خاص به زیر مجموعه‌های مختلف تقسیم می‌شوند که در بخش ۲-۲ توضیح داده شده است.

۲-۲- دسته بندی قورباغه‌ها

فرض کنید که جمعیت اولیه با P قورباغه تولید شده است. با توجه به شکل (۱)، P قورباغه به m مجموعه تقسیم می‌شوند. روند تقسیم بندی قورباغه‌ها بدین صورت است که قورباغه اول به مجموعه اول، قورباغه دوم به مجموعه دوم و قورباغه m به مجموعه m و قورباغه $m+1$ به مجموعه اول تعلق دارند. این روند به صورت مشابه تا قورباغه آخر تکرار می‌شود. هر مجموعه m شامل n قورباغه است به طوری که رابطه (۲) ارضاء می‌شود:

$$P = m \times n \quad (2)$$



شکل (۱): دسته بندی قورباغه‌ها به m زیر مجموعه

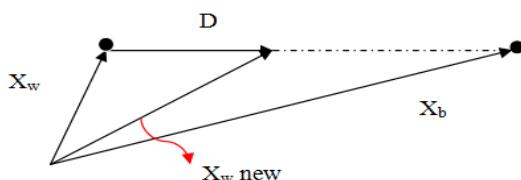
۳-۲- مراحل جستجوی محلی در الگوريتم NFL

در هر مجموعه موقعیت قورباغه i ، بر اساس اختلاف بین قورباغه بهتر (با بهترین شایستگی X_b) و قورباغه بدتر (با بدترین شایستگی X_w) با استفاده از معادله زیر به دست می‌آید:

بنابراین، روش پیشنهادی هان در بخش بعد توضیح داده می‌شود.

۷-۲- تصحیح کردن قانون پرش قورباغه با استفاده از روش پیشنهادی هان

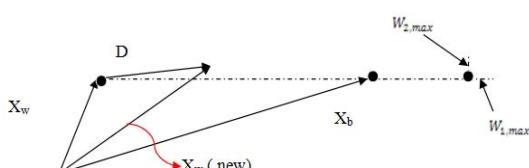
پس از ارائه نسخه ابتدایی لنزی و یوسف که در قسمت قبل بیان گردید، در سال ۲۰۰۸ مقاله‌ای با عنوان «بهبود دادن الگوریتم جستجوی قورباغه برای به دست آوردن ضرائب کترولر PID» توسط هان مطرح شد که به اصلاح قانون پرش قورباغه‌ها منجر گردید (رابطه (۳)). بدین گونه که به دلیل درک ناقص، قورباغه با شایستگی بدتر نمی‌تواند دقیقاً در موقعیت قورباغه بهتر قرار گیرد و این حرکت غیر دقیق، باعث می‌شود که قورباغه با شایستگی بدتر نتواند به طور مستقیم به موقعیت هدف پرش کند. این مورد در شکل (۲) برای یک مسئله دو بعدی نشان داده شده است.



شکل (۲): حرکت غیر دقیق قورباغه بدتر به سمت قورباغه

بهتر

با توجه به این عدم قطعیت، موقعیت قورباغه جدید با شایستگی کمتر لزوماً به مسیر مستقیمی که بین موقعیت جدیدش و موقعیت بهترین قورباغه است، محدود نمی‌شود. بنابراین قورباغه بدتر می‌تواند از روی خط مستقیم پرش کند. این ایده به یک قانون پرش جدید منتهی می‌شود که در شکل (۳) نشان داده شده است.



شکل (۳): پرش قورباغه بدتر از روی خط مستقیم

در بهینه محلی چهار شود. رکود الگوریتم SFL ممکن است به دو دلیل زیر باشد:

۱- در الگوریتم SFL، قورباغه‌ها متناسب با شایستگی شان به صورت نزولی مرتب و سپس همه جمعیت به چند زیر مجموعه تقسیم می‌گردند. این نوع دسته بندي نامتعادل است، زیرا عملکرد زیر مجموعه اول نسبت به زیر مجموعه‌های دیگر بهتر است. این توزیع نامتعادل قورباغه‌ها باعث ایجاد مشکلاتی در روند یادگیری می‌شود چون دیگر قورباغه‌های خوب در زیر مجموعه آخر وجود ندارند.

۲- چنانچه که ذکر شد در الگوریتم SFL موقعیت بدترین قورباغه با توجه به رابطه (۳) به دست می‌آید. قورباغه بدتر فقط از قورباغه بهتر تأثیر می‌پذیرد و قورباغه بهتر شانس کمتری برای یادگیری پیدا می‌کند مگر اینکه قورباغه‌های بهتر در طول تکامل تبدیل به قورباغه بدتر گردند. بنابراین این الگوریتم از مکانیزم یادگیری مناسبی برخوردار نیست.

تاکنون روش‌هایی توسط محققان برای بهبود الگوریتم SFL ارائه شده است. بخش بعدی به بیان این روش‌ها اختصاص می‌یابد و سپس الگوریتم پیشنهادی این مقاله ارائه می‌شود.

۶-۲- مروری بر کارهای انجام شده در بهبود الگوریتم SFL

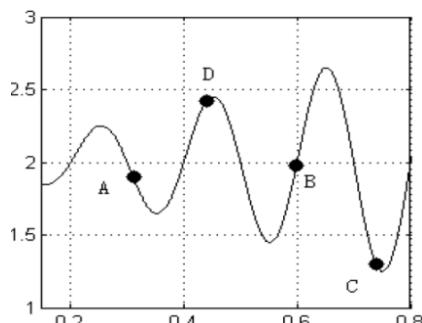
در سال ۲۰۰۷^{۲۰} و همکارانش الگوریتم ممتیک جدیدی از ترکیب الگوریتم‌های SFL و PSO ارائه دادند [۲۴]. سپس در سال ۲۰۰۸^{۲۱} لی و همکارانش مقاله‌ای با عنوان الگوریتم جهش قورباغه آشوبناک ارائه دادند [۲۵]. در [۲۶] از ایده ممتیک در بهبود SFL استفاده شد. در سال ۲۰۰۸^{۲۲}، هان^{۲۳} پرش غیر دقیق قورباغه‌ها را با اضافه کردن عبارت عدم قطعیت به رابطه (۳) اصلاح کرد و گامی جدید در بهبود این الگوریتم برداشت و مکانیزم یادگیری را تا حدی تصحیح کرد [۲۷]. از آنجایی که روش پیشنهادی در این مقاله بر اساس روش ارائه شده هان است،

۱-۳- دسته بندی قورباغه‌ها با استفاده از تابع قله-دره

به طور کلی، مشخص کردن شعاع همگرایی در روش‌های به دست آوردن جایگاه بسیار سخت است. بنابراین، اگر دو نقطه قله مربوط به تابع چند بعدی متعلق به فضای جستجو را داشته باشیم، دیگر به شعاع همگرایی نیازی نیست. این روش در ابتدا در سال ۱۹۹۹ توسط ارسام^۵ معرفی گردید [۲۱]. روش پیشنهادی ارسام در شکل (۴) نشان داده شده است.

```
Hill_valley(ip,iq,samples)
minfit=min(fitness(ip), fitness(iq))
for j=1 to samples.length
Calculate point iinterior on the line between the pints
ip and iq
If(minfit>fitness(iinterior))
    return 1
end if
end for
return 0
```

شکل (۴): شبیه کد تابع قله-دره



شکل (۵): ایده جدا سازی قله‌ها به وسیله تابع قله-دره

همان گونه ذکر شد، در الگوریتم SFL جمعیت مناسب با شایستگی مرتب می‌شود. در روش پیشنهادی، ابتدا دو قورباغه A و B در نظر گرفته، سپس قورباغه‌ای تصادفی بین A و B با نام D با توجه به رابطه (۹) تولید می‌شود.

$$D = A + \text{rand}() \times (B - A) \quad (9)$$

اگر مینیمم شایستگی A و B از شایستگی D بیشتر شد می‌توان این نتیجه را گرفت که A و B در قله‌های متفاوت هستند، در غیر این صورت، قورباغه B ام و قورباغه A ام مربوط به یک قله هستند و در یک زیر مجموعه قرار می‌-

قانون جدید پرس قورباغه پیشنهادی‌هان به صورت زیر است:

$$D = r \times c \times (X_b - X_w) + W \quad (5)$$

که مقدار W از رابطه (۶) تعیین می‌گردد:

$$W = [r_1 W_{1,\max}, r_2 W_{2,\max}, \dots, r_s W_{s,\max}]^T \quad (6)$$

که r یک مقدار تصادفی بین ۰ و ۱ است و c ثابتی است که مقداری بین ۱ و ۲ دارد و r_i ($1 \leq i \leq S$) یک عدد تصادفی بین -۱ و ۱ می‌باشد. ($1 \leq i \leq S$) بیشترین درک اجازه داده شده و عدم قطعیت در -1 -امین بعد از فضای جستجوست که به صورت رابطه زیر تعریف می‌شود:

$$V \quad (7)$$

برای هر متغیر مستقل S ، $0.1 \leq V \leq 0.2$. بازه مسئله در نظر گرفته می‌شود. در هر حال، اگر $|W_{\max}|$ بزرگ باشد، قانون جهش قورباغه مشخصه هدایتی خود را از دست می‌دهد.

سپس مقدار پرس جدید در رابطه (۵) به مقدار بدترین قورباغه طبق رابطه (۸) اضافه می‌شود:

$$X_w(\text{new}) = \begin{cases} X_w + D & \text{if } \|D\| \leq D_{\max} \\ X_w + \frac{D}{\sqrt{D^T D}} & \text{if } \|D\| > D_{\max} \end{cases} \quad (8)$$

بعیه الگوریتم همانند SFL استاندارد است. در قسمت بعد به بیان الگوریتم پیشنهادی این مقاله پرداخته می‌شود.

۳- معرفی الگوریتم جدید پیشنهادی این مقاله برای جایگاه یابی مسائل چند مدلی (NSFL^۳)

در این بخش ابتدا راهکاری برای دسته بندی قورباغه‌ها برای رفع نخستین عیوب الگوریتم SFL (بخش ۵-۲) ارائه می‌شود. سپس روش‌هان توسعه داده می‌شود و راه حلی برای رفع دومین عیوب الگوریتم SFL پیشنهاد می‌شود.

$$X_{\text{new worst}} = \text{current position } X_w + D \quad (11)$$

اگر این تغییر موقعیت، قورباغه‌ای با شایستگی بهتر تولید کرد این قورباغه جایگزین قورباغه بدتر می‌شود در غیر این صورت X_g جایگزین X_i می‌شود. X_g بیانگر بهترین قورباغه در کل مجموعه‌های است. اگر قورباغه بهتری تولید شد جایگزین بدترین قورباغه می‌گردد. در غیر این صورت، قورباغه‌ای به صورت تصادفی تولید و با توجه به رابطه زیر جایگزین بدترین قورباغه می‌گردد.

$$X_{\text{new worst}} = X_{\text{Low}} + \text{rand}() \times (X_{\text{hi}} - X_{\text{Low}}) \quad (12)$$

که $\text{rand}()$ یک عدد یکنواخت بین ۰ و ۱ است. اما الگوریتم پس از مدتی دچار رکود می‌گردد، چون یادگیری قورباغه بدتر از بهترین‌ها متوقف می‌شود. بنابراین، نیاز به حرکت دوباره قورباغه‌ها در جهت دیگر در فضای جستجو است. بنابراین، پس از آنکه یادگیری قورباغه بدتر از بهترین قورباغه در کل فضای جستجو پایان یافت از رابطه (۱۳) برای پرش قورباغه استفاده می‌شود.

$$D(i) = r \times c \times (X_g - X_i) + W \quad (13)$$

حال این پرش طبق رابطه (۱۴) به X_i اضافه می‌گردد و اگر شایستگی قورباغه تولید شده از i -امین قورباغه بهتر شد جایگزین قورباغه‌ای که دچار رکود شده است.

$$X_i(\text{new}) = \begin{cases} X_i + D & \text{if } \|D\| \leq D_{\max} \\ X_i + \frac{D}{\sqrt{D^T D}} & \text{if } \|D\| \geq D_{\max} \end{cases} \quad (14)$$

شایان ذکر است که بقیه الگوریتم همانند SFL استاندارد است. برتری روش پیشنهادی نسبت به الگوریتم هان در پیوست مقاله نشان داده شده است. در بخش بعد با پیاده سازی الگوریتم پیشنهادی بر روی توابع محک استاندارد، توانایی آن در پیدا کردن مکان تمامی جایگاه‌ها و رسیدن به جواب بهینه سنجیده می‌شود و با روش‌های مطرح در این زمینه مقایسه می‌شود.

گیرند. ممکن است قورباغه D در موقعیتی همانند شکل (۵) باشد.

همان طور که در شکل (۵) دیده می‌شود، مینیمم شایستگی A و B از D کمتر است و همچنان A و B در قله‌های متفاوت هستند. در صورت بروز چنین حالتی باید تعداد عددهای تصادفی بین A و B را زیاد در نظر گرفت تا شایستگی عدد تولید شده D از A و B کمتر شود. در اینجا این نکته قابل اهمیت است که در الگوریتم جهش قورباغه متحرک با توجه به مرتب کردن جمعیت قورباغه‌ها متناسب با شایستگی همیشه شایستگی قورباغه B از A کمتر است (مسئله بیشینه سازی). پس از دسته بندی قورباغه‌ها با توجه به جایگاه‌ها، بر روی هر کدام از مجموعه‌ها یک جستجوی محلی انجام می‌شود. در قسمت بعد با ارائه روشی جدید به بهبود الگوریتم هان پرداخته می‌شود که الگوریتم پیشنهادی بهتر از الگوریتم ارائه شده توسط هان عمل می‌نماید.

۲-۳- بهبود روش پیشنهادی هان

هر چند روش پیشنهادی هان تا حدودی الگوریتم SFL را بهبود بخشدید اما الگوریتم هنوز از مکانیزم یادگیری چندان موثری برخوردار نیست، از آنجایی که پرش مد نظر از اختلاف بین قورباغه‌های بهتر و بدتر حاصل می‌شود و از یادگیری بقیه قورباغه‌ها به نحوی جلوگیری می‌کند، بنابراین، در این مقاله، قانون پرش به صورت زیر تصحیح می‌شود؛ بدین گونه که پرش مورد نظر از اختلاف تک تک اعضا قورباغه‌ها در هر زیر مجموعه و بدترین عضو از همان مجموعه، به دست می‌آید:

$$D(i) = r \times c \times (X_i - X_{\text{worst}}) + W \quad (10)$$

که در آن $P=1:i$ و X هر عضو جمعیت یا قورباغه در هر مجموعه و X_{worst} بدترین عضو جمعیت در هر مجموعه است، i یک مقدار تصادفی بین ۰ و ۱ است و c ثابتی است که مقداری بین ۱ و ۲ دارد. سپس موقعیت جدید قورباغه توسط رابطه زیر به دست می‌آید:

$$\begin{aligned} F_5(x_1, x_2) = & 200 - (x_1^2 + x_2^2 \\ & - 11)^2 - (x_1 + x_2^2 \\ & - 7)^2 - 5 < x_1, x_2 \\ & < 5 \end{aligned} \quad (19)$$

تابع F_6 معروف به تابع فریبنده، توسط عمرانی^{۱۹} [۱۹] و عالمی^{۲۰} [۲۰] به کار گرفته شده است. این تابع در یک بعد و در فاصله $[0, 6]$ تعریف می‌شود و دارای دو بهینه مرزی است. این تابع دارای یک بهینه محلی در $x=3$ با مقادیر 0.6 و دو بهینه فرامحلی با مقادیر 1 در $x=0$ و $x=6$ است.

تابع F_7 توسط مایکولز^{۲۱} معرفی و توسط ژانگ استفاده شده است [۲۸]. این تابع در یک بعد در فاصله $[10, 10]$ تعریف می‌شود. این تابع 19 بهینه دارد که 3 تا از آنها بهینه‌های فرامحلی هستند. در این تابع تعداد بهینه‌ها افزایش یافته است تا الگوریتم پیشنهادی جهت یافتن تعداد بیشتر جایگاه‌ها محک رده شود. توابع F_6 و F_7 توسط روابط (۲۰) و (۲۱) تعریف می‌شوند.

$$F_6(x) = \begin{cases} -x+1 & \text{if } 0 \leq x < 1 \\ 0.4(x-1) & \text{if } 1 \leq x < 2 \\ 0.24x - 0.08 & \text{if } 2 \leq x < 3 \\ -0.24x + 1.36 & \text{if } 3 \leq x < 4 \\ -0.4x + 2 & \text{if } 4 \leq x < 5 \\ x-5 & \text{if } 5 \leq x \leq 6 \end{cases} \quad (20)$$

$$F_7(x) = \sum_{i=1}^5 i \cos[(i+1)x+i] \quad (21)$$

$$-10 \leq x \leq 10$$

شایان ذکر است که جمعیت اولیه برای توابع F_1 تا F_6 برابر 50 و برای تابع F_7 برابر 150 در نظر گرفته شده است. مقدار D_{\max} هم برای تمامی توابع برابر با 1 نهایت در نظر گرفته شده است.

در صد موفقیت برای حل مسائل چند مدلی به صورت نسبت تعداد بهینه‌های یافته شده توسط الگوریتم به کل بهینه‌های موجود در فضای مسئله در همه تکرارها تعریف می‌شود [۱]. جدول (۱) در صد موفقیت در یافتن نقاط بهینه طی 30 بار اجرای مستقل الگوریتم را با تعدادی از الگوریتم‌های دیگر مقایسه می‌کند. جدول (۲) خطا میانگین الگوریتم پیشنهادی را نشان می‌دهد. برای هر جواب، خطا میانگین به صورت میانگین فاصله اقلیدسی جواب پیدا شده توسط الگوریتم تا مکان بهینه واقعی تعريف می‌شود. این خطا طبق رابطه (۲۲) محاسبه می‌شود.

۴- آزمایش‌ها و نتایج و مقایسه با سایر

روش‌ها

در این قسمت نتایج حاصل از پیاده سازی الگوریتم پیشنهادی با چند روش دیگر ارائه شده در مقالات گوناگون، برای حل تعدادی از مسائل چند مدلی که در آنها هدف یافتن همه بهینه‌های محلی و فرامحلی است، ارائه شده است. توابع F_1 تا F_5 توسط گلدنبرگ^{۲۲} و ریچاردسون^{۲۳} معرفی شده‌اند. این توابع برای آزمودن الگوریتم جایگاه‌یابی توسط محققان مختلف استفاده شده‌اند [۱۷ و ۲۰]. این توابع توسط روابط (۱۵) تا (۲۱) تعریف می‌شوند. توابع F_1 تا F_4 در یک بعد تعریف شده و در بازه $[1, 10]$ دارای پنج نقطه بهینه است. تابع F_2 دارای پنج نقطه بهینه در مکان‌های $0.1, 0.3, 0.5, 0.7, 0.9$ است. برای تابع F_1 مقدار بهینه‌ها برابر 1 است، ولی برای تابع F_2 مقدار بهینه‌ها با یکدیگر متفاوت است. اما مکان بهینه‌ها در توابع F_3 و F_4 برابر $0.930, 0.450, 0.681$ و 0.079 است. برای تابع F_3 مقدار بهینه‌ها برابر 1 ، ولی برای تابع F_4 مقدار بهینه‌ها با یکدیگر متفاوت است. تابع F_5 به تابع هیملبلانو^{۲۴} مشهور است، در فضای دو بعدی تعریف می‌شود و در ناحیه تعریف شده چهار بهینه در نقاط $(-3.7790, -2.834), (-3.2804, -2.1304)$ و $(-1.8480, 3.5840)$ دارد.

$$F_1(x) = \sin^6(5\pi x) \quad 0 < x < 1 \quad (15)$$

$$F_2(x) = e^{2 \log(2) \times \left(\frac{x-0.1}{0.8}\right)^2} \sin^6(5\pi x) \quad (16)$$

$$0 < x < 1$$

$$F_3(x) = \sin^6\left(5\pi\left(x^{\frac{3}{4}} - 0.05\right)\right) \quad 0 < x < 1 \quad (17)$$

$$\begin{aligned} F_4(x) = & e^{2 \log(2) \times \left(\frac{x-0.08}{0.864}\right)^2} \sin^6\left(5\pi\left(x^{\frac{3}{4}}\right.\right. \\ & \left.\left. - 0.05\right)\right) \quad (18) \end{aligned}$$

$$0 < x < 1$$

نتایج جدول (۲) بیانگر آن است که کارایی الگوریتم پیشنهادی در مقایسه با الگوریتم‌های دیگر بهتر بوده است. به عبارت دیگر، الگوریتم پیشنهادی توانسته است در هر بار اجرای برنامه جایگاه نقاط بهینه را پیدا کند.

شود. در این رابطه N_i مکان واقعی بهینه \hat{N}_i مکان بهینه یافته شده توسط الگوریتم و M تعداد بهینه‌های یافت شده است [۲].

$$\text{Mean Error} = \frac{\sum_{i=1}^M \|N_i - \hat{N}_i\|}{M} \quad (22)$$

جدول (۱): درصد موفقیت الگوریتم پیشنهادی

[۲]Fitness sharing	Deterministic [۱۷]Crowding	[۱۸]GCPSO	[۲]NGSAV	NISFL	تابع
82.7	۱۰۰	۱۰۰	۱۰۰	۱۰۰	F1
68	93	93	۹۹.۳	۱۰۰	F2
80	90	۱۰۰	۱۰۰	۱۰۰	F3
66.7	90	93	۹۹.۳	۱۰۰	F4
53.3	90	۱۰۰	۱۰۰	۱۰۰	F5
63.7	-	-	۹۸.۸	۱۰۰	F6
32.3	-	-	۱۰۰	۱۰۰	F7

جدول (۲): بهترین جواب دیده شده در ۳۰ بار اجرای الگوریتم

Mean Error	Best_Niche				تابع
3.4e -5	0.9000	0.700	0.4995	0.2999	F1
1.1e -3	0.8976	0.6983	0.4983	0.2994	F2
1.6e -3	0.9338	0.6810	0.450	0.2466	F3
3.9e -4	0.9303	0.6791	0.4494	0.2462	F4
2.7e -3	-2.8056 2.1276	3.5843 1.8482	-3.7821 -3.2783	3.00 1.9993	F5
3.8e -3	6.00	2.999	-	0.000	F6
2.2e -2	-	-	-	-	F7

توانایی روش پیشنهادی، نتایج بهینه سازی چند تابع محک استاندارد با روش‌های مطرح در این زمینه مقایسه شده است. نتایج آزمایش‌ها بهبود کارایی روش پیشنهادی را تأیید می‌کند.

۵- نتیجه گیری

تاکنون برای حل مسائل چند مدلی به وسیله الگوریتم جهش قورباغه متحرک روشن ارائه نشده است. الگوریتم جهش قورباغه، از جمله الگوریتم‌های تکاملی است که می‌تواند در حل مسائل چند مدلی استفاده شود. در بهینه سازی مسائل چند مدلی، همیشه این سوال مطرح بوده است که یافتن تمامی نقاط بهینه بسیار دشوار است. همان طور که بیان شد، استفاده از پارامترهای جایگاه، از جمله پارامترهای شعاع همگرایی عملکرد بدی در مسائل مربوط به جایگاه دارد. با روش پیشنهادی علاوه بر بهبود الگوریتم NFL اقتباش شده از مقاله هان، می‌توان به روش تابع فله-دره قله‌ها را تشخیص داد و جمعیت را متناسب با قله‌ها در مجموعه‌های جداگانه دسته بندی کرد. برای ارزیابی

مراجع

- [۱] سجاد یزدانی، حسین نظام آبادی پور، (۱۳۸۸). «حل مسائل چند مدلی با استفاده از الگوریتم جستجوی گرانشی»، در پانزدهمین کنفرانس سالانه انجمن کامپیوتر ایران، مجموعه مقالات رایانش نرم.
- [۲] سجاد یزدانی، حسین نظام آبادی پور، (۱۳۸۹). «یک راه حل گرانشی جدید برای بهینه یابی مسائل چند

- [15] Li, X., "Adaptively choosing neighbourhood bests using species in a particle swarm optimizer for multimodal function optimization", in Proc. of Genetic and Evolutionary Computation Conference 2004(LNCS3102), K. Deb, Ed, pp. 105–116, 2004.
- [16] Parrott, D., Li, X., "Locating and tracking multiple dynamic optima by a particle swarm model using speciation", IEEE Trans. on Evol. Comput., vol. 10, no. 4, pp. 440–458, August 2006.
- [17] Brits, R., Negelbrecht, A., van den Bergh, F., "Locating multiple optima using particle swarm optimization", Applied Mathematics and Computation, vol. 189, pp. 1859–1883, 2007.
- [18] Sareni, B., Krahenbuhl, L., "Fitness sharing and niching methods revisited", IEEE Trans. on Evol. Comput., vol. 2, no. 3, pp. 97 – 106, Sep. 1998.
- [19] El Imrani, A., Bouroumi, A., Zine El Abidine, H., Limouri, M., Essaid, A., "A fuzzy clustering-based niching approach to multimodal function optimization", Cognitive System Research, vol 1, pp 119-133, 2000.
- [20] Alami, J., El Imrani, A., Bouroumi, A., "Multi-population cultural algorithm using fuzzy clustering", Applied Soft Computing ,vol. 7 ,pp. 506–519,2007.
- [21] R.K. Ursem, "Multinational evolutionary algorithms", in proceedings of congress of Evolutionary Computation (CEC-99), vol. 3, Washington, pp 1633–1640, 1999.
- [22] Eusuff, M., Lansey, K., Pasha, F., "Shuffled frog-leaping algorithm: a memetic meta-heuristic for discrete optimization", Engineering Optimization, vol. 38, No. 2, pp. 129-154, 2006.
- [23] Eusuff, M., Lansey, K., "Optimization of water distribution network design using the shuffled frog leaping algorithm", Journal of Water Resources Planning and Management, vol. 129, no. 2, pp. 210–25, 2003.
- [24] Zhen, Z., "A Novel Memetic Algorithm for Global Optimization Based on PSO and SFLA", ISICA, LNCS 4683, pp. 126–135, 2007.
- [25] Y. Li and et al, "The Chaos-based Shuffled Frog Leaping Algorithm and Its Application," Fourth International Conference on Natural Computation,pp.481-485,2008.
- [26] Ittipong, P., " solving non-linear continuous mathematical using shuffled frog leaping and memetic algorithm", Department of Computer Science and information technology, faculty of science, Naresuan university,2008.
- [27] Huynh, T.H., "A Modified Shuffled Frog Leaping Algorithm for Optimal Tuning of Multivariable PID Controllers", ICIT IEEE Industrial Technology ,2008 .
- [28] Zhang, J., "A novel adaptive sequential niche technique for multimodal function optimization", Neuro Computing,vol. 69, pp 2396-2401,2006.
- مدی» در هجدهمین کنفرانس مهندسی برق ایران مجموعه مقالات کامپیوتر.
- [3] Mahfoud, S. W., "Niching methods for genetic algorithms", Ph.D. dissertation, Urbana, IL, USA, 1995.
- [4] Horn, J., Nafpliotis, N., and Goldberg, D. E., "A Niched Pareto Genetic Algorithm for Multiobjective Optimization", in Proc. of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence, vol. 1. Piscataway, New Jersey: IEEE Service Center, pp. 82–87 ,1994.
- [5] De Jong, K. A., "An analysis of the behavior of a class of genetic adaptive systems", Ph.D. dissertation, University of Michigan, 1975.
- [6] Mahfoud, S. W., "Crowding and preselection revisited", in Parallel problem solving from nature 2, R. Manner and B. Manderick, Eds. Amsterdam: North-Holland, pp. 27–36, 1992.
- [7] Goldberg D. E., Richardson, J., "Genetic algorithms with sharing for multimodal function optimization", in Proc. of the Second International Conference on Genetic Algorithms, J. Grefenstette, Ed., pp. 41–49,1987.
- [8] Beasley, D., Bull, D. R., Martin, R. R., "A sequential niche technique for multimodal function optimization", Evolutionary Computation, vol. 1, no. 2, pp. 101–125, 1993.
- [9] Harik, G. R., "Finding multimodal solutions using restricted tournament selection", in Proc. of the Sixth International Conference on Genetic Algorithms, L. Eshelman, Ed. San Francisco, CA: Morgan Kaufmann, pp. 24–31,1995.
- [10] Bessaou, M., P'etrowski, A., and Siarry, P., "Island model cooperating with speciation for multimodal optimization", in Parallel Problem Solving from Nature - PPSN VI 6th International Conference, H.-P. S. et al., Ed. Paris, France: Springer Verlag, 16-20,2000.
- [11] Yin, X., Germay, N., "A fast genetic algorithm with sharing scheme using cluster analysis methods in multi-modal function optimization", in the International Conference on Artificial Neural Networks and Genetic Algorithms, pp. 450–457, 1993.
- [12] P'etrowski, A., "A clearing procedure as a niching method for genetic algorithms", in Proc. of the 3rd IEEE International Conference on Evolutionary Computation, pp. 798–803, 1996.
- [13] Li, J.P., Balazs, M. E., Parks, G. T., Clarkson, P. J., "A species conserving genetic algorithm for multimodal function optimization", Evol. Comput., vol. 10, no. 3, pp. 207–234, 2002.
- [14] Brits, A. E. R., van den Bergh, F., "A niching particle swarm optimizer", in Proc. of the 4th Asia-Pacific Conference on Simulated Evolution and Learning 2002(SEAL 2002), pp. 692–696, 2002.

پیوست ۱: نتایج روش هان با روش پیشنهادی روی توابع محک استاندارد در ادامه مقایسه شده است. نتایج آزمایش‌ها بهبود توانایی الگوریتم پیشنهادی و ضعف الگوریتم هان را تایید می‌کند. این نتایج نشان می‌دهد که الگوریتم هان از مکانیزم یادگیری مناسبی برخوردار نیست.

جدول ب-۱- توابع محک کمینه شونده چند مد و با بعد متغیر

Test Function	S
$F_1(X) = \sum_{i=1}^n x_i^2$	$[-100]^{10^n}$
$F_2(X) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10]^{10^n}$
$F_3(X) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$	$[-100]^{10^n}$
$F_4(X) = \max_i \{x_i 1 \leq i \leq n\}$	$[-100]^{10^n}$
$F_5(X) = \sum_{i=1}^{n-1} \left[100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	$[-30]^{10^n}$
$F_6(X) = \sum_{i=1}^n [(x_i + 0.5)]^2$	$[-100]^{10^n}$
$F_7(X) = \sum_{i=1}^n i x_i^4 + \text{random}[0,1)$	$[-1.28]^{1.28^n}$

جدول ب-۲- توابع چند مدی که با افزایش بعد، تعداد بهینه‌های آن افزایش می‌یابد.

Test Function	S
$F_8(X) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	$[-500]^{500^n}$
$F_9(X) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.125.12]^{n^n}$
$F_{10}(X) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	$[-323]^{2^n}$
$F_{11}(X) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$[-600]^{600^n}$
$F_{12}(x) = \frac{\pi}{n} \{ 10 \sin(\pi(x)_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi(x)_{i+1})] \\ + (y_n - 1)^2 \} + \sum_{i=1}^n u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4}$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	$[-505]^{n^n}$

$$\begin{aligned}
 F_{13}(X) = & 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] \right. \\
 & \left. + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)
 \end{aligned}$$

جدول پ- (۳): نتایج پیاده سازی الگوریتم هان و الگوریتم پیشنهادی روی توابع جداول (پ- ۱ و پ- ۲) میانگین بهترین جواب دیده شده (Mean_best)، بهترین جواب دیده شده (Best_answer)، بدترین جواب دیده شده (Worst_answer)، انحراف معیار (SD)، تعداد ارزیابی (evaluate) و تعداد تکرار ۵۰۰ با بعد ۳۰ با ۱۰ بار اجرای مستقل الگوریتم.

Function	الگوریتم هان					الگوریتم پیشنهادی				
	Mean_best	Best_answer	Worst_answer	SD	evaluate	Mean_best	Best_answer	Worst_answer	SD	evaluate
F1	5.9526e-05	2.6461e-05	7.2310e-05	3.177e-05	50000	0	0	0	0	35000
F2	0.0045	0.0024	0.0075	0.0018	50000	2.3207e-213	1.8278e-222	2.3188e-212	0	50000
F3	4.4987e-15	1.0080e-017	3.1450e-014	9.5e-15	50000	0	0	0	0	45000
F4	6.0352e-14	2.2777e-014	1.5774e-013	3.78e-14	50000	5.67393e-237	1.30685e-241	4.55618e-236	0	50000
F5	92.7849	26.2614	419.5713	117.7615	50000	0	0	0	0	4000
F6	0	0	0	0	8500	0	0	0	0	600
F7	0.0235	0.0038	0.1415	0.0419	50000	2.4646e-04	7.1464e-05	6.82636e-04	2.2e-04	50000
F8	7.6244e+03	9.2729e+03	7.0617e+003	688.4169	50000	1.25694e+04	1.25694e+04	1.25694e+04	0	1000
F9	46.1882	16.9143	70.6420	19.4128	50000	0	0	0	0	4000
F10	0.8419	0.0035	1.6484	0.7565	50000	0	0	0	0	35000
F11	0.0441	1.4482e-004	0.1058	0.0360	23000	0	0	0	0	3000
F12	1.0121	1.8416e-006	2.0943	1.6030	50000	1.57054e-32	1.57054e-32	1.57054e-32	2.88e-48	4000
F13	9.3631e-16	1.3934e-016	1.2814e-015	5.13e-16	50000	1.34978e-32	1.34978e-32	1.34978e-32	2.88e-48	4000

زیرنویس‌ها

¹ -Multimodal

² -Crowding

³ -Deterministic crowding

⁴ -Fitness sharing

⁵ -Sequential niche

⁶ - Restricted tournament selection

⁷ - parallelization

⁸ -Clustering

⁹ -Clearing

¹⁰ -Speciation

¹¹ Shuffled frog leaping (SFL)

¹² Lansey

¹³ -Eussuf

¹⁴ - Memplex

¹⁵ -Culture

¹⁶-Heuristic

¹⁷-random

¹⁸ Global best

¹⁹ Shuffled of population

²⁰ - Zhen

²¹ - Li

²² - Huynh

²³ New shuffled frog leaping (NSFL)

²⁴ -Hill- valley function

²⁵ -Ursem

²⁶ - Goldberg

²⁷ - Richardson

²⁸- Himmelblau

²⁹ - Imrani

³⁰ -Alami

³¹ - Michols