

بهینه‌سازی چندمدى با الگوريتم جستجوی گرانشی به همراه تکنيک loop in Loop و نخبه‌گرائي k-means

محمد نورمحمدی زرده‌سوار، شهرام گلزاری، امين موسوي

چكيده

بشر برای حل مسائل خود، همواره به دنبال راه حلی بوده که هزینه کمتری داشته باشد. از اين رو مسائل بهينه‌سازی، توجه محققان را به خود جلب نموده‌اند. از مهم‌ترین روش‌های برخورد با اين مسائل، الگوريتم‌های تکاملی هستند که بيشتر آن‌ها از طبيعت الهام گرفته شده‌اند. الگوريتم جستجوی گرانشی يکی از الگوريتم‌های تکاملی می‌باشد که در برخورد با مسائل تکمدي کاراچي خود را نشان داده است. برای موفقیت اين الگوريتم در مسائل چندمدى، آن را با يکی از تکنيک‌های جايگاه‌يابي به نام K-means و تکنيک نخبه‌گرائي جدید loop in Loop ترکيب نموده‌ایم. كاراچي اين الگوريتم ترکيبی در بخش نتایج آزمایشگاهی مشاهده می‌شود.

كلمات کليدي

جستجوی گرانشی، چند مدي، جايگاه‌يابي، K-means

در طول تاریخ سعی بر این بوده است که نسل‌های جدید، نسبت به نسل‌های گذشته قوی‌تر باشند. در گیاهان و حیوانات هم با اصلاح نژاد سعی در ایجاد نسل‌های بعدی قوی‌تر شده است. این ایده به درون الگوريتم‌های مکافهه‌ای تحت عنوان نخبه‌گرائي رخنه نموده و باعث تسریع همگرائي اين-گونه الگوريتم‌ها گردیده است. [5] SPSO، [4] CBN، [3] NichePSO، [7] r2PSO-lhc، [7] r3PSO، [6] MGPSO Deterministic Crowding، [8] FER-PSO، [7] r3PSO-lhc [9] و [10] (SN) Sequential Niche (DC) [11] برخی از الگوريتم‌های مطرح برای حل مسائل چند مدي می‌باشند. اکثر اين الگوريتم‌ها، به پارامترها بسيار وابسته می‌باشند. در اين پژوهش سعی گردیده با حذف اين پارامترها و بالا بردن دقت در ارزیابي‌های كمتر، الگوريتمي موفق ارائه شود. در ادامه مفاهيم پايه به همراه الگوريتم پيشنهادي تشریح و نتایج قابل قبولی گزارش گردیده است.

۱ - مقدمه

بهينه‌سازی يک مسئله، يافتني بهترین جواب یا جواب‌ها در بين تمامي راه حل‌هاي ممکن برای آن مسئله می‌باشد. مسائلی که به دنبال چندين راه حل بهينه‌هاست، مسائل چندمدي^۱ ناميده شده و در مقابل آن مسائل تکمدي^۲ که فقط به دنبال يافتني تک جواب هستند وجود دارند. در دهه‌های اخير، توجه بيشتری به الگوريتم‌های تکاملی برخلاف عملکرد مناسب در برخورد با مسائل تکمدي، الگوريتم‌های تکاملی چندان موفق نبوده‌اند. از اين رو تکنيک‌های جايگاه‌يابي^۳ در مسائل چندمدي چندان موفق نبوده‌اند. از جايگاه‌يابي^۴ بهره‌مند شده است. جهت كمک به الگوريتم‌های تکاملی در مسائل چندمدي ارائه گردیدند. يکی از الگوريتم‌های تکاملی کارا جهت يافتني بهينه‌ها، الگوريتم جستجوی گرانشی^۵ است. در اين پژوهش، از الگوريتم جستجوی گرانشی به همراه تکنيک جايگاه‌يابي K-means و تکنيک جدید نخبه‌گرائي^۶ به نام loop in Loop برای حل مسائل چندمدي استفاده گردیده است. از دلائل انتخاب الگوريتم جستجوی گرانشی، يافتني بهينه‌های موجود با تكرار^۷ كمتر و فرار از بهينه‌های محلی و همچنين واستگى كمتر به پارامترها می‌باشد. از ميان تکنيک‌های خوشبندی^۸، K-means به دليل سادگي، موثر بودن و پيچيدگي زمانی کم برای تقسيم جمعيت اصلی به زير جمعيتيها برگزیده شده است؛ به اين ترتيب كه اعضاء هر زير جمعيت، همديگر را در يافتني بهينه‌ها ياري می‌رسانند.

۲ - مفاهيم پايه

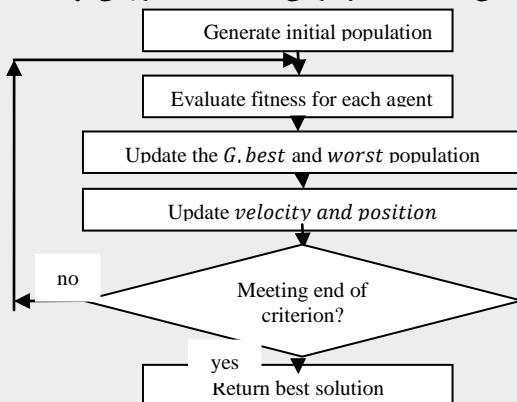
۲-۱- الگوريتم جستجوی گرانشی

الگوريتم جستجوی گرانشی توسط راشدی و همكارانش بر اساس قانون گرانش نيوتن، ارائه گردید. در الگوريتم جستجوی گرانشی، عامل‌ها به صورت اجسامي هستند که يكديگر را با نيزوی گرانشی جذب می‌نمایند و اين نيزرو

فلوچارت الگوریتم جستجوی گرانشی در شکل (۱) نشان داده شده است.

۲- جایگاه یابی

در طبیعت همه جانداران به دنبال یافتن منابع غذایی می‌باشند. هر جاندار در نزدیک منابع غذایی خود زندگی می‌کند. از این رو طبیعت تقسیم‌بندی می‌شود. معمولاً در هر قسمت جانورانی از یک گونه وجود دارند که برای یافتن منابع غذایی با یکدیگر رقابت می‌کنند. از این فعل و انفعال طبیعت، مفهوم جایگاه‌یابی به ذهن محققان خطور کرد و از آن به عنوان راهی برای غلبه بر مسائل چند-مدى استفاده گردید. یکی از روش‌های مطرح جایگاه‌یابی، خوش‌بندی داده‌ها با الگوریتم K-means می‌باشد. در این روش به تعداد خوش‌بندی که می‌خواهیم تشکیل دهیم، دانه تصادفی تعیین می‌کنیم. هر عضو از جمعیت به نزدیکترین دانه اختصاص می‌یابد. حال وقتی اعضاء هر خوش‌بندی شد دانه‌های هر خوش بزرگی خودش به مرکز خوش بندی منتقل می‌شوند و این کار تا هنگامی که دانه‌ها تغییر حرکتی نداشته باشند تکرار می‌شود.



شکل (۱) : الگوریتم جستجوی گرانشی [۲]

۳- الگوریتم پیشنهادی (KGSA)

۳-۱- تولید خوش‌بندی‌های مناسب از جمعیت

در این پژوهش، از دو روش تصادفی و Partition [11] برای مقداردهی اولیه جمعیت استفاده می‌شود. خوش بندی نامناسب در فاز مقداردهی اولیه، خوش بندی است که یا تک عضوی یا تهی و یا در سایر مراحل الگوریتم تهی باشد. از این رو اگر خوش بندی نامناسب باشد اگر در فاز مقداردهی اولیه باشیم مدام مقداردهی اولیه را رد نموده و دوباره مقداردهی نموده و این اعضای جدید را توسط K-means خوش بندی می‌نماییم تا بالاخره به هر خوش بندی تعداد اعضای مناسبی اختصاص یابد. ولی اگر در سایر مراحل الگوریتم باشیم، فقط خوش بندی را تکرار می‌نماییم تا اینکه هیچ کدام از خوش بندی‌ها تهی نباشند.

۳-۲- محاسبه جرم، نیرو، سرعت و ایجاد نسل بعدی

برای محاسبه جرم هر عضو از جمعیت، ابتدا همسایه‌های هر فرد از جمعیت مشخص می‌گردند. همسایه‌های هر فرد، افرادی از جمعیت هستند که در خوش آن فرد قرار گرفته‌اند. در ادامه با استفاده از فرمول‌های (۱۱-۱۳) مقدار جرم برای هر عضو از جمعیت مشخص می‌شود و سپس طبق فرمول (۵)، مجموع برآیند نیروهای وارد به جرم i مشخص می‌گردد. نیروهای وارد به

موجب حرکت همه اجسام به سمت اجسام برآزندگی می‌شود. سیستمی با N عامل را در نظر بگیرید. کل سیستم را با فرمول (۱) نمایش می‌دهیم. همچنین موقعیت و مکان ذره A_m به صورت فرمول (۲) تعریف می‌شود.

$$X = (X_1, X_2, \dots, X_i, \dots, X_N) \quad (1)$$

$$X_i = (x_i^1, x_i^2, \dots, x_i^d, \dots, x_i^n) \quad (2)$$

x_i^d موقعیت عامل A_m در بعد d برای عامل X_j است و n تعداد بعد فضای جستجو است. همچنین N همان تعداد عامل‌ها است. در زمان معین t نیروی اعمالی بر جرم j از سمت جرم i از فرمول (۳) محاسبه می‌شود.

$$F_{ij}^d = G(t) \frac{M_{pi}(t) \times M_{aj}(t)}{R_{ij}(t) + \epsilon} (x_j^d(t) - x_i^d(t)) \quad (3)$$

$$R_{ij}(t) = \|X_i(t), X_j(t)\| \quad (4)$$

جایی که M_{aj} جرم گرانشی فعال جرم j ، M_{pi} جرم گرانشی غیر فعال

جرم A_m ، $G(t)$ ثابت گرانشی در زمان t ، ϵ ثابت کوچک و R_{ij} فاصله اقلیدسی بین دو عامل i و j می‌باشد که با فرمول (۴) نشان داده شده است.

کل نیروی وارد شده به عامل i در بعد d از سوی K تا از بهترین عامل-ها از فرمول (۵) محاسبه می‌شود.

$$F_i^d(t) = \sum_{j \in Kbest, j \neq i} rand_j F_{ij}^d \quad (5)$$

جایی که $rand_j$ عددی تصادفی در بازه $[0, 1]$ می‌باشد. $Kbest$ مجموعه‌ای از K عامل با بهترین مقدار برآزندگی و تابعی از زمان است که مقدار اولیه‌اش در شروع برابر K_0 و با گذشت زمان کاهش می‌یابد.

شتاب عامل A_m در زمان t در بعد d از فرمول (۶) محاسبه می‌شود.

$$a_i^d(t) = \frac{F_i^d(t)}{M_{ii}(t)} \quad (6)$$

جرم اینرسی عامل i می‌باشد. همچنین سرعت و موقعیت عامل در زمان $t+1$ از فرمول‌های (۷) و (۸) محاسبه می‌شود.

$$v_i^d(t+1) = rand_i \times v_i^d(t) + a_i^d(t) \quad (7)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t) \quad (8)$$

جایی که $rand_i$ عددی تصادفی در بازه $[0, 1]$ است.

ثابت گرانشی G تابعی از زمان است که با مقدار اولیه G_0 شروع و برای کنترل دقیق جستجو با گذشت زمان کاهش می‌یابد. از این رو مقدار G از فرمول‌های (۹) و (۱۰) محاسبه می‌شود.

$$G(t) = (G_0, t) \quad (9)$$

$$G(t) = G_0 e^{-\alpha t} \quad (10)$$

جایی که α و G_0 مقداری ثابت هستند و T نشان دهنده کل تکرارها می‌باشد. همچنین جرم‌های اینرسی و گرانشی با استفاده از فرمول‌های (۱۱) و (۱۲) به روز می‌شوند.

$$M_{ai} = M_{pi} = M_{ii} = M_i \quad i = 1, 2, \dots, N \quad (11)$$

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)} \quad (12)$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)} \quad (13)$$

در جایی که $fit_i(t)$ مقدار برآزندگی عامل A_m را در زمان t نشان می‌دهد. (t) $best(t)$ و $worst(t)$ برای مسئله ماقریم‌سازی از فرمول‌های (۱۴) و (۱۵) محاسبه می‌شود.

$$best(t) = \max_{j \in \{1, \dots, N\}} fit_j(t) \quad (14)$$

$$worst(t) = \min_{j \in \{1, \dots, N\}} fit_j(t) \quad (15)$$

۴- نتایج آزمایشگاهی

۴-۱- توابع ارزیابی مقید و نامقید

در توابع نامقید^{۱۰} اگر دامنه این مسائل را قید ننماییم، راه حل ها از قانون خاصی تعیین نمی کنند ولی در توابع مقید راه حل ها در چهار جو布 خاصی می باشند. جدول (۱) توابع نامقید و جدول (۲) توابع مقید مورد استفاده در این پژوهش را نشان می دهد. دامنه این توابع مطابق [۱۱] می باشد.

۴-۲- معیارهای ارزیابی الگوریتم های خوشبندی

برای ارزیابی الگوریتم پیشنهادی از سه معیار نرخ موفقیت، تعداد ارزیابی مورد نیاز برای کشف بهینه ها و نرخ خطای استفاده گردیده است. در هر اجراء، اگر تمامی بهینه ها یافت شدند آن اجرا موفق، در غیر این صورت آن اجرا ناموفق است. پیک و قتنی یافته شده است که اختلاف مقدار برآزندگی از برآزندگی پیک واقعی از خطای قابل قبول بیشتر نباشد. نرخ موفقیت، حاصل تقسیم تعداد اجراهای موفق به تعداد کل اجراهای می باشد. در هر نسلی اگر الگوریتم جایگاهها را پیدا نموده باشد، از لحظه شروع الگوریتم نا آن لحظه که جایگاهها پیدا شده اند، تعداد دفعاتی که تابع ارزیابی فراخوانی شده یعنی تعداد اضافی که برآزندگی شان محاسبه شده را برای هر اجرا محاسبه نموده و از آن در نهایت میانگین گیری می نماییم. اختلاف بهینه های اصلی مساله از بهینه های کشف شده، خطای نامیده می شود و از فرمول (۱۶) محاسبه می گردد.

$$\zeta = \frac{1}{m_i} \sum_{i=1}^m \left(\sum_{j=1}^n (s_i^j - \varphi_i^j)^2 \right)^{\frac{1}{2}} \quad (16)$$

جایی که m تعداد بهینه ها و n تعداد ابعاد مسئله است. همچنین s موقعیت بهینه پیدا شده توسط الگوریتم و φ موقعیت بهینه اصلی مسئله است.

۴-۳- پارامترها و نتایج الگوریتم های دیگر

نتایج و پارامترهای سایر الگوریتم ها از جمله مقدار خطای قابل قبول ۴ از [۷] و [۱۱] قابل استخراج است. G_0 برابر ۰.۱ دامنه و α برابر ۸ است.

۴-۴- کشف بهینه ها

برای یافتن بهینه های عمومی در توابع نامقید، الگوریتم بر روی توابع F_1 تا F_{12} اجرا شده تا نتایج در جدول های (۱۱) و (۱۲) گزارش شود. در جدول (۷) پارامترهای مورد نیاز ارائه گردیده است. در این جدول تعداد حداقل ارزیابی مجاز الگوریتم ها به جز الگوریتم پیشنهادی برای توابع F_1 تا F_{12} برابر ۱۰۰۰۰ می باشد.

برای کشف بهینه های عمومی و محلی در توابع نامقید، از جمعیت های با اندازه متفاوت استفاده شده و نتایج با دو نوع مقداردهی اولیه در جدول های (۴) و (۵) با الگوریتم NGSA مقایسه گردیده اند. همچنین در جدول (۵)، خطاهای الگوریتم NGSA برای نتایج به دست آمده در جدول های (۴) و $N=20$ مقایسه گردیده اند. لازم به ذکر است در اینجا T_1 برای تمامی حالت ها برابر ۱۵ در نظر گرفته شده است. برای بررسی بیشتر، الگوریتم پیشنهادی برای کشف بهینه های عمومی و محلی در توابع نامقید بر

یک عضو، فقط از سوی همسایگانش می باشد. البته برای تسريع بخشیدن به همگرایی، فقط نیروی ۷۰ درصد نفرات هر خوشه با اولویت برآزندگی به هر عضو آن خوشه وارد می شود تا اعضاء حرکت نمایند. می توان سرعت حرکت اعضاء را از فرمول (۷) محاسبه نمود. در اثر حرکت اعضاء، جمعیتی جدید ایجاد شده که با ترکیب با نسل قبلی و انتخاب برآزنده ترها نسل بعدی را تشکیل می دهد. نحوه انتخاب اعضای نسل آینده بر اساس [۱۲] می باشد. اصلاح جمیعت در هر نسل طبق [۱۲] برای توابع مقید^{۱۱} استفاده شده تا از ایجاد راه حل های ناممکن اجتناب شود.

۴-۳- loop in Loop و کشف بهینه ها

در روش loop in Loop، جمعیت به تعداد T_1 تکرار، تکامل می باشد. بعد از پایان هر T_1 ، جمعیت جدیدی را جایگزین می نماییم که مقداردهی اولیه می گردد. این نسل نیز T_1 بار تکامل می باشد و نسل جدیدی دوباره ایجاد می گردد. این روال تکراری، آن قدر ادامه می باشد که تعداد کل تکرارها به پایان برسد و یا به تعداد ماکریتم ارزیابی مجاز رسیده باشیم. از این پس به هر کدام از این قسمت ها یک loop و به جایگاه هایی که بعد از پایان هر loop پیدا می شوند جایگاه های بالقوه می گوییم. اگر هدف پیدا کردن فقط بهینه های سراسری باشد فقط آن اعضایی برای روال انتخاب جایگاه های بالقوه، باقی می مانند که از مقدار ماکریتم حداقل فاصله مجاز را رعایت نموده باشند. البته این در صورتی است که تعداد جایگاه های باقیمانده از تعداد بهینه هایی که باید کشف شوند بیشتر باشد. چون اعضاء جمعیت بعد از هر loop به نزدیکی جایگاه های خود رسیده اند، نزدیک ترین فاصله بین دو عضو از جمعیت را پیدا نموده و هر کدام برآزندگی بهتری دارند باقی مانده و دیگری حذف می گردد. این روال تکرار می شود تا به تعداد جایگاه های برسیم که باید یافت شوند. اعضاء باقیمانده، همان جایگاه های بالقوه می باشند. در پایان هر T_1 ، جایگاه های بالقوه به انبار جایگاه های بالقوه اضافه می گردند. همچنین بهترین برآزندگی بهترین فرد را دارند، به انبار loop به همراه آن هایی که تا ۸۰ درصد برآزندگی بهترین فرد را دارند، برآزندگها اضافه می شوند تا به همراه انبار جایگاه های بالقوه به عنوان کاندیدا برای ورود به loop بعدی آماده شوند. بعد از پایان هر loop جمعیت جدیدی مقداردهی اولیه شده و کاندیداهایا با نزدیک ترین عضو از جمعیت جدید به رقابت پرداخته و اگر دارای برآزندگی بهتری باشند جایگزین آن می شوند. به این صورت جمعیت اولیه برای loop بعدی شکل می گیرد. این روال تکراری با انبیاشته شدن کاندیداهایا برای loop بعدی ادامه می باشد. لازم به ذکر است در عبور از یک نسل به نسل بعدی نیز جایگاه های هر نسل با مقایسه برآزندگی آن ها با نزدیک ترین عضو از نسل بعد به نسل بعدی اضافه می گردد. جایگاه های بین هر نسل به انبار جایگاه های موقت اضافه گردیده و به عنوان کاندیداهایی برای ورود به نسل های بعدی به همراه انبار جایگاه ها آمده می شوند. در پایان هر T_1 ، سرعت اعضاء صفر می شود و همچنین انبار موقت بین نسلی هم خالی می شود، چرا که در آن ممکن است جایگاه های مناسبی وجود نداشته باشند. در پایان برای کشف جایگاه های اصلی، بعد از اینکه loop هایا به پایان رسیدند از میان جایگاه های بالقوه و لیست برآزندگها به همان روشی که جایگاه های بالقوه یافت شدند جایگاه های اصلی را پیدا می نماییم. در الگوریتم پیشنهاد شده، تعداد نسل های تولید شده ثابت و به تعداد T می باشد. اما برای الگوریتم K-means، شرط توقف موقعي است که مرکز خوشه ها دیگر تغییر نمی کند.

جدول (۲) : توابع مقید

$$\begin{aligned}
 F_{13}(x) &= 10n + \sum_{i=1}^n [x_i^2 - 10 \cos(2nx_i)] \\
 \text{s.t. } h(x) &= \sum_{i=1}^n x_i = 0 \\
 F_{14}(x) &= \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \\
 \text{s.t. } h(x) &= \frac{1}{512(n-1)} \sum_{i=2}^n x_i^2 - |x_1| = 0 \\
 F_{15}(x) &= (x_1 + a_1)^2 + (x_2 + a_2)^2 + \dots + (x_n + a_n)^2 \\
 \text{s.t. } [(x_1 + b_1)^2 + \dots + (x_n + b_n)^2] &\geq n^2, \\
 -(n+1) \leq x_i &\leq n+1
 \end{aligned}$$

جدول (۳) : نرخ موفقیت کشف بهینه‌های سراسری و محلی با ۱۲۰ بار تکرار و مقداردهی اولیه به روش تصادفی در ۳۰ بار اجرای مستقل

F	N=۷۵		N=۵۰		N=۳۵		N=۲۰	
	KG SA	NGS A	KG SA	NGS A	KGS A	NGS A	KG SA	NGS A
F ₁	100	100	100	100	100	93	100	80
F ₂	100	100	100	100	100	96	100	73
F ₃	100	100	100	100	100	86	100	73
F ₄	100	100	100	96	100	90	100	66
F ₅	100	100	100	100	100	96	100	76

جدول (۴) : نرخ موفقیت کشف بهینه‌های سراسری و محلی با ۱۲۰ بار تکرار و مقداردهی اولیه به روش partition در ۳۰ بار اجرای مستقل

F	KG SA		KGS A		NGS A		KGS A		NGS A	
	KG	NGS	KGS	NGS	KGS	NGS	KGS	NGS	KGS	NGS
F ₁	100	100	100	100	100	100	100	100	100	100
F ₂	100	100	100	100	100	100	100	100	100	100
F ₃	100	100	100	100	100	100	100	100	100	100
F ₄	100	100	100	100	100	100	100	100	100	100
F ₅	100	100	100	100	100	100	100	100	100	100

جدول (۵) : نرخ خطاب برای نتایج جدول‌های (۴) با N=20

F	KGSA ζ random		KGSA ζ partition		NGSA ζ partition	
	KG SA	NGS A	KG SA	NGS A	KG SA	NGS A
F ₁	1.70e-6 ± 1.03e-6		1.78e-6 ± 9.41e-7		1.62e-5 ± 3.24e-5	
F ₂	4.97e-7 ± 1.05e-6		2.70e-7 ± 2.94e-7		... ± 1.66e-4	
F ₃	2.41e-6 ± 2.12e-6		2.35e-6 ± 1.29e-6		... ± 1.25 ± 0.50e-4	
F ₄	7.87e-7 ± 1.98e-6		5.32e-7 ± 6.81e-7		2.37e-4 ± 2.28e-4	
F ₅	3.09e-3 ± 2.13e-3		4.29e-3 ± 4.22e-3		... ± 0.50 ± 0.262	

جدول (۶) : نرخ موفقیت در ۳۰ اجرای مستقل

F	KGSA	DC	SN	Niche PSO	NGSA
F ₁	100	100	100	100	100
F ₂	100	93	83	93	100
F ₃	100	90	100	100	100
F ₄	100	90	93	93	100
F ₅	100	90	86	100	100

جدول (۷) : پارامترهای مورد نیاز برای جدول‌های (۱۱) و (۱۲)

F	F ₁	F ₂	F ₃	F ₄	F ₅	F ₆	F ₇	F ₈	F ₉	F ₁₀	F ₁₁	F ₁₂
N KGSA	10	10	20	10	20	10	8	30	10	40	100	500
ME KGSA	8.00	6.00	8.00	8.00	7.00	4.00	1.80	0.00	1.28	0.36	0.00	1.30
T _l	20	15	10	15	20	90	80	60	30	50	60	45
N NGSA	50	50	50	50	50	100	100	100	100	250	250	100

روی توابع F₅ تا F₉ با پارامترهای جدول (۱۰) اجرا گردیده تا این نتایج در جدول‌های (۱۴) نشان داده شوند. همچنین توابع F₆ تا F₁₀ با پارامترهای جدول (۸) برای الگوریتم پیشنهادی و برای الگوریتم‌های دیگر با پارامترهای جدول (۷) و حداکثر ۱۰۰۰۰ ارزیابی اجرا شده و نتایج در جدول (۱۳) با الگوریتم NGSa مقایسه گردیده است.

الگوریتم پیشنهادی برای کشف بهینه‌های سراسری در توابع مقید، با پارامترهای جدول (۹) اجرا شده تا نتایج جدول (۱۵) شکل گیرد. در جدول‌ها حداکثر ارزیابی مجاز با ME و تابع با F نماد شده‌اند.

۵- نتیجه‌گیری

الگوریتم KGSA با حذف پارامترهای k_i و k_f از الگوریتم NGSa همچنین حذف پارامتر شعاع جایگاه از سایر الگوریتم‌ها به نتایج بهتری از آن‌ها دست پیدا نموده است. اهمیت حذف پارامترها در NGSA به حدی است که با کمترین اختلافی در تنظیم پارامترها، برخی جایگاه‌ها پیدا نشده و یا جایگاه‌های اضافی دیگری یافته می‌شوند. علاوه بر حذف پارامترهای مهم، تاثیر نوع مقدار دهی اولیه نیز کاهش یافته است و از همه مهمنه‌تر، کارآبودن ۱۰۰ درصدی آن برای کشف جایگاه‌ها و همچنین خطای کمتر و ارزیابی کمتر با جمعیت کمتر در برخورد با مسائل بهینه‌سازی چندمدى است. با توجه به ظهور تازه‌الگوریتم جستجوی گرانشی زمینه دارویی، نظامی و اقتصادی، از جمله زمینه‌هایی است که از آن می‌توان به عنوان کارهای آینده نام برد.

جدول (۱) : توابع نامقید

F	F ₁ (x) = sin ⁶ (5πx)	F ₂ (x) = e ^{-2 log(2) × \frac{(x-0.1)^2}{0.8}} sin ⁶ (5πx)	F ₃ (x) = sin ⁶ (5π(x ^{3/4} - 0.05))	F ₄ (x) = e ^{-2 log(2) × \frac{(x-0.08)^2}{0.854}} sin ⁶ (5π(x ^{3/4} - 0.05))	F ₅ (x ₁ , x ₂) = 200 - (x ₁ ² + x ₂ ² - 11) ² - (x ₁ + x ₂ ² - 7) ²
F ₆ (x) =	$\begin{cases} \frac{160}{15}(15-x) & \text{for } 0 \leq x \leq 15 \\ \frac{200}{5}(x-15) & \text{for } 15 \leq x \leq 20 \end{cases}$	$\begin{cases} \frac{160}{10}x & \text{for } 0 \leq x \leq 10 \\ \frac{160}{5}(15-x) & \text{for } 10 \leq x \leq 15 \\ \frac{200}{5}(x-15) & \text{for } 15 \leq x \leq 20 \end{cases}$	$\begin{cases} 80(2.5-x) & \text{for } 0.0 \leq x \leq 2.5 \\ 64(x-2.5) & \text{for } 2.5 \leq x \leq 5.0 \\ 64(7.5-x) & \text{for } 5.0 \leq x \leq 7.5 \\ 28(x-7.5) & \text{for } 7.5 \leq x \leq 12.5 \\ 28(17.5-x) & \text{for } 12.5 \leq x \leq 17.5 \\ 32(x-17.5) & \text{for } 17.5 \leq x \leq 22.5 \\ 32(27.5-x) & \text{for } 22.5 \leq x \leq 27.5 \\ 80(x-27.5) & \text{for } 27.5 \leq x \leq 30 \end{cases}$	$F_9(x_1, x_2) = -4 \left[\left(4 - 2.1x_1^2 + \frac{x_1^4}{3} \right) x_1^2 + x_1 x_2 + (-4 + 4x_2^2)x_2^2 \right]$	$F_{10}(x_1, x_2) = 500 - \frac{1}{0.002 + \sum_{i=0}^{24} \frac{1}{1+i+(x_1-a(i))^6+(x_2-b(i))^6}}$ where a(i) = 16((i mod 5) - 2), and b(i) = 16([i/(5)] - 2)
F ₁₁ (x) =	$-\prod_{i=1}^n \sum_{j=1}^5 j \times \cos[(j+1)x_i + j]$	$F_{12}(x) = \frac{1}{n} \sum_{i=1}^n \sin(10 \times \log(x_i))$			

جدول (۱۵) : نرخ موفقیت، نرخ خطأ و تعداد ارزیابی مورد نیاز برای یافتن بهینه‌های سراسری در ۵۰ بار اجرای مستقل

F	ζ	تعداد ارزیابی	نرخ موفقیت (%)	روش
F_{13}	$2.1585e - 0.4 \pm 0.0 - 0.8$	510 ± 438.1082	100	r2PSO
	$6.3425e - 0.4 \pm 0.0 - 0.5$	546 ± 396.0056	100	r3PSO
	$5.5255e - 0.4 \pm 0.0 - 0.7$	474 ± 383.7569	100	r2PSO-lhc
	$1.2619e - 0.3 \pm 0.0 - 0.83$	450 ± 292.2498	100	r3PSO-lhc
	$4.3711e - 0.4 \pm 0.0 - 0.13$	1098 ± 662.8602	100	Deterministic crowding
	$3.1250e - 0.4 \pm 0.0 - 0.17$	78 ± 146.9119	100	NGSA
	$6.04e - 0.0 \pm 0.67e - 0.0$	92 ± 43	100	KGSA
F_{14}	$2.13312e - 0.2 \pm 2.2522$	2396 ± 0.1469	100	r2PSO
	$7.1531e - 0.3 \pm 0.9825$	2092 ± 0.5050	100	r3PSO
	$8.947e - 0.3 \pm 1.8314$	2476 ± 0.5123	100	r2PSO-lhc
	$1.3116e - 0.2 \pm 2.1065$	2222 ± 0.5539	100	r3PSO-lhc
	$1.6942e - 0.2 \pm 0.4956$	21502 ± 1.0056	100	Deterministic crowding
	$1.9672e - 0.2 \pm 0.3790$	$1944 \pm 1.0949e + 0.3$	100	NGSA
	$5.79e - 0.3 \pm 0.0 - 0.4 + 0.98$	1395 ± 0.587	100	KGSA
F_{15}	0.3956 ± 0.2352	788 ± 0.0849	100	r2PSO
	-0.181 ± 0.1997	792 ± 0.0849	100	r3PSO
	$4.9832e - 0.3 \pm 0.2081$	812 ± 0.396	100	r2PSO-lhc
	-0.3237 ± 0.1873	796 ± 0.0480	100	r3PSO-lhc
	$6.2571e - 0.4 \pm 0.052$	5672 ± 0.283	100	Deterministic crowding
	$5.0262e - 0.4 \pm 0.0 - 0.203$	$3116 \pm 1.0 - 135$	100	NGSA
	$3.137e - 0.4 \pm 0.37e - 0.4$	480 ± 1.03	100	KGSA

مراجع

- [10] 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.
- [11] Yazdani, S., Nezamabadi-pour, H., Kamyab, S., "A Gravitational Search Algorithm for Multimodal Optimization", Swarm and Evolutionary Computation, pp. 1-14, 2013.
- [12] Kimura, S., Matsumura, K., "Constrained multimodal function optimization using a simple evolutionary algorithm", In Evolutionary Computation (CEC), 2011 IEEE Congress on, pp. 447-454, 2011.
- زیرنویس‌ها**
-
- ¹ Multimodal
- ² Unimodal
- ³ Niching
- ⁴ Gravitational search algorithm
- ⁵ Elitism
- ⁶ Iteration
- ⁷ Clustering
- ⁸ K-means GSA
- ⁹ Constraint
- ¹⁰ Unconstraint
- [1] Rashedi, E., Nezamabadi-Pour, H., Saryazdi, S., "BGSA: binary gravitational search algorithm", Natural Computing, Vol. 9, No. 3, pp. 727-745, 2010.
- [2] Rashedi, E., Nezamabadi-Pour, H., Saryazdi ,S., "GSA: a gravitational search algorithm", Information sciences, Vol 179,No 13, pp 2232-2248, 2009.
- [3] Brits, R., Niching strategies for particle swarm optimization, PhD diss., University of Pretoria, 2002.
- [4] Streichert, F., Stein, G., Ulmer, H., Zell, A., "A clustering based niching method for evolutionary algorithms", In Genetic and Evolutionary Computation—GECCO, pp. 644-645, 2003.
- [5] Li, X., "Adaptively choosing neighbourhood bests using species in a particle swarm optimizer for multimodal function optimization", In Genetic and Evolutionary Computation—GECCO, pp. 105-116, 2004.
- [6] Seo, J. H., Im, C. H., Heo, C. G., Kim, J. K., Jung, H. K., Lee, C.-G., "Multimodal function optimization based on particle swarm optimization", Magnetics, IEEE Transactions, Vol. 42, No. 4, pp. 1095-1098, 2006.
- [7] Li, X., "Niching without niching parameters: particle swarm optimization using a ring topology," Evolutionary Computation, IEEE Transactions, Vol. 14, No. 1, pp. 150-169, 2010.
- [8] Li, X., "Multimodal function optimization based on fitness-euclidean distance ratio", In Proc. Genet. Evol. Comput. Conf, pp. 78-85, 2007.
- [9] Das, S., Maity, S., Qu, B., Ponnuthurai, N. S., "Real-parameter evolutionary multimodal optimization—A survey of the state-of-the-art", Swarm and Evolutionary Computation, Vol. 1, No. 2, pp. 71-88, 2011