

DBSCAN-Guided Decomposition for Multi-Objective Evolutionary Clustering: Toward Adaptive Density-Aware MOEA/D

Haleh Homayouni

Assistant Professor, Department of Computer Engineering, Apadana Institute of Higher Education, Shiraz, Iran.

Kimia Bazargan Lari*

Assistant Professor, Department of Computer Engineering, Apadana Institute of Higher Education, Shiraz, Iran.

Abstract

In this article, a framework called DGD-MOEA/D is presented, which is designed with the goal of developing a density-aware adaptive MOEA/D. The main idea is to inject population-density feedback in the objective space into the three key modules of MOEA/D—namely subproblem decomposition, neighborhood graph, and selection/replacement policy—in an online, in-loop manner. To achieve this, at the end of every few generations, DBSCAN or HDBSCAN is executed on the population points in the objective space (or the joint objective/decision space) to extract clusters, core points, boundary points, and local density estimates. Based on this feedback: in high-density regions, weight vectors that are very close to each other are softly merged or redistributed to prevent crowding and redundant subproblems; in underrepresented regions, new weight vectors are injected and/or existing weights are shifted to improve the coverage of the front in low-density areas; the size and structure of the neighborhood are adaptively adjusted according to density; and the selection and replacement of individuals are performed using a combination of fitness and density to control the balance between exploration and exploitation. Experimental results on the ZDT, DTLZ, and WFG families, as well as multimodal multi-objective problems with 2 to 15 objectives, show that DGD-MOEA/D significantly improves performance compared to baseline algorithms such as MOEA/D-DE, MOEA/D-ANA, MaOEA/D-AEW, and NSGA-III, increasing the Hypervolume metric by approximately 5–12% and reducing IGD by about 9–26%. Moreover, the coverage of low-density regions of the Pareto front and the mode-recovery rate in multimodal problems are noticeably enhanced. Time-complexity analysis indicates that the overhead of in-loop clustering, with an appropriately chosen reconfiguration frequency, remains only a few percent relative to the fitness evaluation cost in MaOO problems. Overall, these findings demonstrate that the direct, online integration of density estimation into decomposition and topology provides an effective pathway for simultaneously improving both diversity and convergence in multi-objective evolutionary algorithms.

Keywords: MOEA/D, adaptive decomposition, DBSCAN, HDBSCAN, density-based clustering, density-aware selection, adaptive neighborhood graph, hypervolume, IGD, multimodal multi-objective problems (MMOPs)

* Corresponding Author: kimia.bazargan@apadana.ac.ir

تجزیه هدایت‌شده با DBSCAN برای خوشه‌بندی تکاملی چندهدفه: به‌سوی MOEA/D تطبیقی آگاه از چگالی

هاله همایونی

استادیار بخش مهندسی کامپیوتر مؤسسه آموزش عالی آپادانا، شیراز، ایران.

کیمیا بازرگان لاری*

استادیار بخش مهندسی کامپیوتر مؤسسه آموزش عالی آپادانا، شیراز، ایران.

چکیده

در این مقاله، چارچوبی با نام DGD-MOEA/D^۱ ارائه می‌شود که با هدف توسعه‌ی یک MOEA/D تطبیقی آگاه از چگالی طراحی شده است. ایده‌ی اصلی آن است که بازخورد چگالی جمعیت در فضای هدف، به‌صورت درون‌حلقه‌ای به سه ماژول کلیدی MOEA/D؛ یعنی تجزیه‌ی زیربرخوردها، گراف همسایگی و سیاست انتخاب-جایگزینی، تزریق شود. برای این منظور، در انتهای هر چند نسل، الگوریتم‌های DBSCAN یا HDBSCAN روی نقاط جمعیت در فضای هدف (یا فضای مشترک هدف / تصمیم) اجرا می‌شوند تا خوشه‌ها، نقاط هسته، نقاط مرزی و برآورد چگالی محلی استخراج گردد. سپس بر مبنای این بازخورد، در نواحی پرتراکم، بردارهای وزن بسیار نزدیک به هم به‌صورت نرم ادغام یا بازپخش می‌شوند تا از ازدحام و تکرار زیربرخوردها جلوگیری شود؛ در نواحی کم‌پوشش، بردارهای وزن جدید تزریق و یا وزن‌های موجود جابه‌جا می‌شوند تا پوشش جبهه در نواحی کم‌چگالی بهبود یابد؛ اندازه و ساختار همسایگی به‌طور تطبیقی و متناسب با چگالی تنظیم می‌گردد؛ انتخاب و جایگزینی افراد با ترکیبی از برازندگی و چگالی انجام می‌شود تا توازن میان اکتشاف و بهره‌برداری کنترل شود. نتایج آزمایش‌ها روی خانواده‌های WFG، DTLZ، ZDT و همچنین مسائل چندمدی چندهدفه^۲ در ابعاد ۲ تا ۱۵ هدف نشان می‌دهد که DGD-MOEA/D نسبت به الگوریتم‌های پایه‌ای مانند MOEA/D-DE، MOEA/D-ANA، MaOEA/D-AEW و NSGA-III، به‌طور معنادار شاخص Hypervolume را حدود ۵ تا ۱۲ درصد افزایش و شاخص IGD را حدود ۹ تا ۲۶ درصد کاهش می‌دهد. علاوه بر این، پوشش نواحی کم‌چگالی جبهه‌ی پرتو و نرخ بازیابی مودها در مسائل چندمدی به‌طور محسوسی بهبود یافته است. تحلیل پیچیدگی زمانی نشان می‌دهد که سربار خوشه‌بندی درون‌حلقه‌ای با انتخاب تناوب بازتنظیم مناسب، در مقایسه با هزینه‌ی ارزیابی برازندگی در مسائل MaOO، در حد چند درصد باقی می‌ماند. مجموعه‌ی این نتایج نشان می‌دهد که اتصال مستقیم و برخط برآورد چگالی به تجزیه و توپولوژی، مسیر مؤثری را برای ارتقای هم‌زمان تنوع و همگرایی در الگوریتم‌های تکاملی چندهدفه فراهم می‌کند.

کلیدواژه‌ها: MOEA/D، تجزیه تطبیقی، DBSCAN، HDBSCAN، خوشه‌بندی مبتنی بر چگالی، انتخاب آگاه از چگالی، گراف همسایگی تطبیقی، Hypervolume، IGD، مسائل چندمدی (MMOP)

1. DBSCAN-guided decomposition
2. MMOP: Multi-objective optimization problem

مقدمه

الگوریتم‌های تکاملی چندهدفه^۱ به‌طور گسترده برای حل مسائل پیچیده با چندین تابع هدف متعارض به کار گرفته می‌شوند. در میان آن‌ها، الگوریتم MOEA/D^۲ به‌دلیل تجزیه‌ی مسأله‌ی چندهدفه به مجموعه‌ای از زیربرخوردهای اسکالر و بهینه‌سازی هم‌زمان آن‌ها، به یکی از چارچوب‌های اصلی در این حوزه تبدیل شده است. در MOEA/D، هر زیربرخورد معمولاً با یک بردار وزن (یا بردار مرجع) نمایندگی می‌شود و ساختار همسایگی بین زیربرخوردها، امکان تبادل مؤثر اطلاعات و بهره‌برداری از ساختار مسأله را فراهم می‌سازد (Campello et al., 2015).

با وجود موفقیت‌های فراوان، کارایی نهایی MOEA/D به‌شدت به نحوه‌ی تعریف و به‌روزرسانی بردارهای وزن و گراف همسایگی وابسته است؛ به‌ویژه در مسائل با جبهه‌های پیچیده، نامنظم، چندمدی و یا با چگالی‌های ناهمگن. روش‌های کلاسیک عموماً از قواعد ساده‌ی فاصله‌محور، مانند فاصله‌ی اقلیدسی ثابت یا k -همسایه‌ی ثابت، برای ساخت گراف همسایگی و تعریف وزن‌ها استفاده می‌کنند که لزوماً ساختار واقعی توزیع جمعیت را بازتاب نمی‌دهد. در سال‌های اخیر، پژوهش‌های متعددی در زمینه‌ی تنظیم تطبیقی بردارهای وزن و اندازه‌ی همسایگی ارائه شده‌اند؛ برای مثال، تنظیم وزن‌ها با استفاده از جمعیت بیرونی، تنظیم تطبیقی تعداد بردارهای وزن یا تنظیم اندازه‌ی همسایگی برای جلوگیری از همگرایی زودرس. با این حال، بخش عمده‌ی این کارها هنوز بر معیارهای فاصله‌محور و هیوریستیک متکی هستند و از اطلاعات ساختاری چگالی در فضای هدف یا فضای تصمیم به‌صورت صریح و درون‌حلقه‌ای استفاده نمی‌کنند.

از سوی دیگر، خانواده‌ی الگوریتم‌های خوشه‌بندی مبتنی بر چگالی، به‌ویژه DBSCAN (Deb et al., 2003) و توسعه‌ی سلسله‌مراتبی آن HDBSCAN (Ester et al., 1996)، ابزار قدرتمندی برای شناسایی نواحی پرتراکم، مرزی و نویزی در داده‌ها فراهم کرده‌اند. این الگوریتم‌ها به‌ویژه برای داده‌هایی با خوشه‌های نامنظم و غیرمحدب و توزیع‌های ناهمگن مناسب هستند؛ شرایطی که در جبهه‌های پرتوی پیچیده نیز به‌وفور مشاهده می‌شود (Gu et al., 2024; Li & Zhang, 2008).

آنچه هنوز در ادبیات بهینه‌سازی چندهدفه کمتر دیده می‌شود، اتصال منسجم، آنلاین و درون‌حلقه‌ای تخمین چگالی (با DBSCAN/HDBSCAN) (Li & Zhang, 2008) به موتور تجزیه و توپولوژی در MOEA/D است؛ به‌گونه‌ای که:

- ساختار چگالی واقعی جمعیت، مستقیماً در بازتعریف زیربرخوردها و بردارهای وزن نقش بازی کند؛
- گراف همسایگی بر اساس ساختار خوشه‌ای و نه صرفاً فاصله‌ی هندسی ثابت تنظیم شود؛
- سیاست انتخاب و جایگزینی، به‌صورت آگاه از چگالی عمل کند تا توازن بین اکتشاف و بهره‌برداری دقیق‌تر کنترل شود.

این مقاله در همین نقطه‌ی خلأ قرار می‌گیرد و چارچوب DGD-MOEA/D را پیشنهاد می‌کند که بازخورد چگالی را به قلب سه مؤلفه‌ی اصلی MOEA/D تزریق می‌کند.

پیشینه پژوهش

در پیشینه‌ی پژوهش، جایگاه و شکاف‌های علمی مرتبط با ایده‌ی «تجزیه‌ی راهبرد تکاملی چندهدفه با هدایت چگالی»^۳ در چارچوب MOEA/D تطبیقی آگاه از چگالی را مرور می‌کنیم و نشان می‌دهیم که چگونه بهره‌گیری نظام‌مند از

1. MOEAs: Multi-objective evolutionary algorithms

2. Multi-objective evolutionary algorithm based on decomposition

3. DBSCAN-guided decomposition

خوشه‌بندی مبتنی بر چگالی می‌تواند هم روی «تعریف/ بازتعریف زیربرخوردها و وزن‌ها» در MOEA/D و هم روی «معماری همسایگی و تنوع جمعیت» اثر بگذارد.

الگوریتم MOEA/D با تجزیه‌ی مسأله‌ی چندهدفه به مجموعه‌ای از زیربرخوردهای اسکالر و بهینه‌سازی هم‌زمان آن‌ها (معمولاً با وزن‌دهی Tchebycheff یا مجموع وزنی) به یکی از ستون‌های اصلی خانواده‌ی MOEA بدل شده است. مزیت اصلی آن، سادگی محاسبات و قابلیت بهره‌گیری از ساختار همسایگی بین زیربرخوردها است؛ با این همه، کیفیت انتخاب وزن‌ها/ بردارهای مرجع و نحوه‌ی تعریف همسایگی‌ها، به‌ویژه در مسائل با چشم‌اندازهای پیچیده و ناهموار، همچنان تعیین‌کننده و چالش‌برانگیز است. کار کلاسیک ژانگ و لی بنیان نظری و تجربی MOEA/D را تثبیت کرد و موجی از بسط‌ها را رقم زد (Campello et al., 2015).

ادبیات اخیر نشان می‌دهد که جامعه‌ی تحقیقاتی به‌صورت فزاینده روی انطباق‌پذیری وزن‌ها و همسایگی‌ها متمرکز شده است؛ از تنظیم تطبیقی بردارهای وزن با جمعیت بیرونی (MaMOEA/D-AEW) گرفته تا تنظیم اندازه‌ی همسایگی (MOEA/D-ANA) و نیز طرح‌های مشابه برای بازیگربندی هوشمند ساختار تجزیه/ بردارهای مرجع. این خط پژوهش می‌کوشد تنوع و همگرایی را هم‌زمان ارتقا دهد و از گیر افتادن در نواحی پرتراکم یا کم‌تراکم در فضاهای هدف جلوگیری کند (Ishibuchi et al., 2019).

هم‌زمان، پژوهش‌هایی در حوزه‌های کاربردی، مانند مسیریابی و حمل‌ونقل، معماری‌های MOEA/D را با اکتشاف محلی بهتر، جهش‌های مبتنی بر جست‌وجوی محلی^۱ و سازوکارهای کشف دانش ترکیب کرده‌اند که اهمیت «معماری همسایگی» و «تنوع» را دوچندان نمایان می‌سازد (Ishibuchi et al., 2016).

شکاف اصلی اینجاست که اگرچه MOEA/D در تجزیه و بهینه‌سازی زیربرخوردها قدرتمند است، اما انتخاب و به‌روزرسانی بردارهای وزن و گراف همسایگی معمولاً بر حسب قواعد فاصله-محور ساده، مانند اقلیدسی ثابت، انجام می‌شود و نه بر اساس ساختار چگالی واقعی جبهه/ جمعیت. در نتیجه، اتکا به بازخورد چگالی می‌تواند حلقه‌ی مفقوده‌ی مهمی برای انطباق‌پذیری آگاه از داده باشد (Lavinias et al., 2021).

DBSCAN به‌عنوان یک الگوریتم کلاسیک و بسیار اثرگذار، خوشه‌ها را به‌صورت نواحی با چگالی بالا تعریف و نقاط کم‌چگالی را به‌عنوان نویز/ حاشیه مشخص می‌کند. این ویژگی باعث می‌شود که DBSCAN برای ساختارهای نامنظم و خوشه‌های غیرمحدب و داده‌های دارای نویز مناسب باشد (Deb et al., 2003).

با این حال، حساسیت به پارامتر ϵ و MinPts و نیز دشواری در چگالی‌های ناهمگن از محدودیت‌های شناخته‌شده‌ی DBSCAN است. توسعه‌های سلسله‌مراتبی مانند HDBSCAN این نقیصه را با محاسبه‌ی برآوردهای سلسله‌مراتبی از ترازهای چگالی و استخراج درخت پایداری خوشه‌ها برطرف می‌کنند؛ HDBSCAN نسبت به انتخاب پارامترها مقاوم‌تر است و خوشه‌های با چگالی‌های متفاوت را بهتر بازیابی می‌کند (Li & Zhang, 2008).

در حوزه‌ی بهینه‌سازی چندهدفه (MOO/MaOO)، چندین کار از خوشه‌بندی برای کنترل اندازه‌ی جبهه، انتخاب/ برازندگی خوشه-محور و یا شناسایی مناطق متنوع راه‌حل‌ها استفاده کرده‌اند، اما استفاده‌ی صریح و آنلاین از بازخورد چگالی برای بازتعریف زیربرخوردها، بردارهای وزن و همسایگی‌ها در چارچوب MOEA/D هنوز بسیار محدود است. پژوهش‌هایی مانند انتخاب مبتنی بر خوشه در MOO/MMO و کارهای کمکی خوشه‌محور، حتی با DBSCAN، بیشتر روی انتخاب افراد یا کاهش/ تقسیم جبهه متمرکز بوده‌اند، نه روی سازوکار تجزیه و توپولوژی همسایگی در MOEA/D (McInees et al., 2017; Qi et al., 2014).

DBSCAN/HDBSCAN، ابزارهایی طبیعی برای خواندن الگوی تراکم در فضای هدف / تصمیم هستند. پیوند این بازخورد به تعیین بردارهای وزن، تعریف زیربرخوردها و به‌روزرسانی گراف همسایگی در MOEA/D می‌تواند فراتر از «پس‌پردازش خوشه‌ای» بوده و به یک حلقه‌ی تطبیقی درون‌نسلی بدل شود (Ester et al., 1996).

در سال‌های اخیر، کارهایی با تمرکز بر تعریف بردارهای وزن^۱ یا بردارهای مرجع و نیز تنظیم تطبیقی آن‌ها برای بهبود پوشش یکنواخت جبهه، حساسیت به ابعاد زیاد اهداف و کاهش نقاط کور منتشر شده‌اند. به‌عنوان مثال، استفاده از سازه‌های ریاضی جدید برای نمونه‌برداری بهتر از تعاملات اهداف یا سازوکارهای اصلاح وزن با هدایت جمعیت بیرونی ارائه شده است. این گونه رویکردها نشان می‌دهد که درک ساختار توزیع راه‌حل‌ها (ولو به‌طور ضمنی) کلید بهبود کارایی MOEA/D است. این کار از بازخورد محلی جمعیت (نه لزوماً DBSCAN) برای تطبیق وزن‌ها استفاده می‌کند و یکی از محدود تلاش‌ها برای سازوکار تطبیقی در MOEA/D است (Sun et al., 2024).

در موازات آن، ایده‌های همسایگی تطبیقی و تنظیم اندازه‌ی همسایگی برای افزایش تنوع و جلوگیری از همگرایی زودرس نیز گزارش شده‌اند، اما این تنظیمات غالباً بر مبنای معیارهای شباهت ساده یا تجربه‌گرایانه انجام می‌شود، نه بر مبنای برآورد چگالی ساختاریافته از فضای هدف / جمعیت (Sun et al., 2024; Tanabe & Ishibuchi, 2020; Wang et al., 2020).

ادبیات نشان می‌دهد که وزن‌ها/ بردارهای مرجع و گراف همسایگی، در عمل باید تطبیقی باشند، اما معیار تطبیق هنوز عمدتاً فاصله-محور یا هیوریستیکی است. چگالی می‌تواند معیار دقیق‌تر و داده-محور برای این تطبیق باشد (Wang et al., 2020).

شکاف پژوهشی و مسئله‌ی پیشنهادی

با وجود حضور پژوهش‌های خوشه‌محور در انتخاب / حفظ تنوع و نیز کوشش‌ها برای انطباق وزن‌ها/ همسایگی‌ها، موارد زیر بایستی بررسی شوند:

۱. عدم وجود چارچوبی که DBSCAN/HDBSCAN را به‌صورت «درون‌حلقه و آنلاین» به موتور تجزیه‌ی MOEA/D متصل کند. این به این معنا است که خوشه‌های چگال در فضای هدف به‌طور مستقیم بردارهای وزن/ زیرمسئله‌ها را بازآرایی کنند؛ برای مثال، با تراکم‌زدایی از نواحی پرتراکم و تزریق وزن/ زیربرخورد در نواحی کم‌پوشش،

۲. به‌روزرسانی توپولوژی همسایگی بر اساس ساختار چگالی به‌جای شعاع ثابت یا k -همسایه‌ی ثابت،

۳. استفاده از HDBSCAN برای پایداری بین‌پارامتری و شناسایی خوشه‌های با چگالی متفاوت تا الگوریتم در جبهه‌های Highly-Skewed یا چندشیبه عملکرد باثبات‌تری بیابد،

۴. اتصال این بازخورد چگالی به راهبرد انتخاب/ جایگزینی تا تنوع و همگرایی به‌صورت هم‌زمان (bi-criteria) کنترل شوند.

اگرچه شواهدی از بهره‌گیری DBSCAN در بهینه‌سازی چندهدفه‌ی چندمدی (MMOPs) و نیز انتخاب مبتنی بر خوشه وجود دارد، اما این آثار عمدتاً پس‌پردازشی یا کمک‌انتخابی بوده و به بازتعریف پویا و داده-محور تجزیه و همسایگی در MOEA/D نپرداخته‌اند. بنابراین، چارچوب DBSCAN-Guided Decomposition دقیقاً در همین گلوگاه می‌نشیند و می‌تواند نوآوری اصیل ارائه دهد (Wang et al., 2020).

نوآوری اصلی این پژوهش، اتصال مستقیم تخمین چگالی^۱ به سازوکار تجزیه و توپولوژی همسایگی در MOEA/D است. در حالی که اغلب نسخه های موجود MOEA/D از معیارهای شباهت فاصله محور یا تنظیمات هیوریستیک برای ساختاردهی همسایگی استفاده می کنند، رویکرد پیشنهادی با اتکا بر برآورد چگالی ساختاریافته، نظیر DBSCAN/HDBSCAN، یک چارچوب داده محور و چگالی آگاه برای بازتعریف وزن ها، زیربرخوردها و ارتباطات همسایگی ارائه می کند. چنین پیوندی، جهت گیری جدیدی فراتر از تنظیمات مبتنی بر فاصله ایجاد می کند. ادبیات MOEA/D به سمت تطبیق پذیری وزن ها و همسایگی ها پیش می رود و ادبیات خوشه بندی چگالی محور ابزار دقیقی برای خواندن ساختار توزیع راه حل ها فراهم کرده است، اما این دو خط، هنوز در هسته ی تجزیه ی MOEA/D به صورت منسجم و آنلاین به هم متصل نشده اند. بنابراین، یک چارچوب DBSCAN-Guided Decomposition که چگالی را به عنوان سیگنال کنترل برای بازتعریف بردارهای وزن/ زیربرخورد، تنظیم همسایگی و سیاست انتخاب به کار می گیرد، می تواند یک هات تاپیک با نوآوری روشن باشد و شکاف های مشخص شده را پر کند.

روش پیشنهادی

فرایند کلی DGD-MOEA/D را می توان در چهار گام مفهومی بیان کرد:

گام اول، برآورد چگالی جمعیت: در پایان هر چند نسل (یا در هر نسل برای یک زیرمجموعه از جمعیت)، الگوریتم DBSCAN یا HDBSCAN روی نقاط جمعیت در فضای هدف (یا فضای مشترک هدف/ تصمیم) اعمال می شود که خروجی آن شامل برجسب خوشه ای هر فرد، تشخیص نقاط هسته، مرزی و نویزی و یک برآورد از چگالی محلی می باشد؛ این اطلاعات به صورت یک بردار ویژگی مبتنی بر چگالی برای هر فرد در حافظه ی الگوریتم ذخیره می شوند. گام دوم، بازتعریف تجزیه و بردارهای وزن: برای هر خوشه، میانگین چگالی محاسبه می گردد. به طور شهودی، در خوشه های با چگالی بالا، بردارهای وزنی که بسیار به هم نزدیک هستند، به صورت نرم ادغام یا بازپخش می شوند تا فشار انتخابی کاهش یابد و از ازدحام جلوگیری شود. در نواحی کم چگالی، بردارهای وزن جدید در جهت میانگین نرمالیزه شده ی اهداف آن ناحیه تزریق می شوند یا وزن های موجود جابه جا می گردند تا پوشش جبهه در آن ناحیه بهبود یابد. به این ترتیب، ماتریس بردارهای وزن W در طول تکامل، به صورت تطبیقی و آگاه از چگالی به روزرسانی می شود.

گام سوم، همسایگی تطبیقی آگاه از چگالی: گراف همسایگی MOEA/D نه براساس شعاع ثابت، بلکه با اتکا به ساختار خوشه ای به روزرسانی می شود؛ به طور مثال، افراد درون یک خوشه ی چگال، همسایگی تنگ تری دارند تا بهره برداری محلی دقیق تر انجام شود. نقاط مرزی و نواحی کم چگالی، همسایگی بازتری دارند و می توانند به چند خوشه متصل شوند تا اکتشاف بین ناحیه ای تقویت شود. این سازوکار باعث می شود که الگوریتم بتواند هم زمان از بهره برداری دقیق در نواحی پُر تراکم و اکتشاف فعال در نواحی کم چگالی بهره مند شود.

گام چهارم، انتخاب و جایگزینی با بازخورد چگالی در فاز انتخاب/ جایگزینی، احتمال انتخاب هر فرد به صورت ترکیبی از برازندگی و چگالی تعریف می شود؛ برای مثال، می توان یک تابع وزنی مانند:

$$\lambda g(\rho_i) + \lambda (Fitness(i) - 1) = Score(i) \quad (1)$$

در نظر گرفت که در آن $i p_i$ نشان‌دهنده‌ی چگالی محلی فرد i و λ پارامتری برای کنترل توازن اکتشاف- بهره‌برداری است. در نواحی پرتراکم، وزن چگالی به گونه‌ای تنظیم می‌شود که فشار انتخابی کاهش یابد و تنوع حفظ شود. در نواحی کم‌چگالی نیز سهم برآزندگی افزایش می‌یابد تا همگرایی شتاب گیرد.

ساختار کلی روش پیشنهادی

چارچوب پیشنهادی DBSCAN-Guided Decomposition (DGD-MOEA/D) نام دارد و با هدف تزیق بازخورد چگالی به سه ماژول اصلی MOEA/D طراحی شده است:

- ماژول تجزیه^۱،
- ماژول همسایگی^۲،
- ماژول انتخاب و جایگزینی^۳.

الگوریتم درون حلقه اجرا می‌شود تا پس از هر چند نسل، توزیع جمعیت در فضای هدف را تحلیل کند و پارامترهای ساختاری MOEA/D را بازتنظیم نماید. به طور خلاصه، DGD-MOEA/D را می‌توان با شبه کد زیر توصیف کرد:

DBSCAN-Guided Decomposition
Initialize population P_0 , weight vectors W_0 , neighborhood graph G_0
for $t = 1 \dots T_{gen}$ do
Evaluate objectives for all individuals in P_t
Generate offspring Q_t by recombination and mutation
Merge P_t and Q_t and apply standard MOEA/D replacement
if $t \bmod T_d == 0$ then
$[C, \rho] \leftarrow \text{DBSCAN/HDBSCAN}(P_t \text{ in objective space})$
$W_t \leftarrow \text{UpdateWeights}(W_{t-1}, C, \rho)$
$G_t \leftarrow \text{UpdateNeighborhood}(W_t, \rho)$
$P_t \leftarrow \text{DensityAwareSelection}(P_t, \rho)$
end if
end for
return final non-dominated set

در این جا dT_d فاصله‌ی نسل‌ها برای اجرای ماژول خوشه‌بندی است که نقش کلیدی در کنترل سربار محاسباتی دارد.

پیچیدگی زمانی و سربار محاسباتی

هزینه‌ی اصلی اضافی در DGD-MOEA/D مربوط به اجرای DBSCAN/HDBSCAN در هر دوره‌ی بازتنظیم است. پیچیدگی زمانی DBSCAN در فضای اقلیدسی معمولاً در حد $O(N \log N)$ با ساختارهای داده‌ی مناسب در نظر گرفته می‌شود که در مقایسه با هزینه‌ی ارزیابی برآزندگی در بسیاری از مسائل MaOO، قابل قبول است؛ به‌ویژه اگر dT_d نسبتاً بزرگ انتخاب شود تا خوشه‌بندی در هر نسل اجرا نشود و اندازه‌ی جمعیت N در حد معمول الگوریتم‌های MaOEA باشد.

1. subproblem decomposition
2. neighborhood graph
3. selection & replacement

به‌روزرسانی تجزیه (بردارهای وزن) و گراف همسایگی، عمدتاً روی ساختارهای محلی عمل می‌کند و سربار آن‌ها در مقایسه با ارزیابی توابع هدف ناچیز است. در مجموع، تحلیل‌ها نشان می‌دهد که سهم کل سربار خوشه‌بندی و بازتنظیم ساختاری، در عمل در حد چند درصد از کل زمان اجرا باقی می‌ماند.

نتایج

تنظیمات آزمایشی و معیارهای ارزیابی

جهت ارزیابی عملکرد DGD-MOEA/D، آزمایش‌ها روی مجموعه‌ای از توابع مرجع استاندارد انجام شده است؛ خانواده‌های ZDT، DTLZ و WFG برای سنجش عملکرد در مسائل کلاسیک دو تا ده هدف و مجموعه‌ای از مسائل چندمدی چندهدفه (MMOP) مانند MMF-4 برای سنجش توانایی در بازیابی مودها و پوشش نواحی چندگانه‌ی جبهه.

معیارهای ارزیابی شامل IGD^۱ برای سنجش همگرایی و یکنواختی پوشش و Hypervolume (HV) برای سنجش کیفیت کلی جبهه‌ی نامغلوب و شاخص‌هایی برای پوشش نواحی کم‌چگالی و نرخ بازیابی مودها در مسائل چندمدی، می‌باشد (Xu et al., 2021). الگوریتم پیشنهادی با الگوریتم‌های مرجع زیر مقایسه شده است:

- MaOEA/D- (Zhang & Li, 2007) MOEA/D-ANA، (Xue et al., 2025) MOEA/D-DE
- NSGA-III، AEW به‌عنوان یک الگوریتم،
- Many-Objective مرجع مبتنی بر نقاط مرجع.

نتایج عددی و تحلیل کیفی

به‌عنوان نمونه، جدول زیر (در نسخه‌ی کامل مقاله) نتایج شاخص‌های IGD و HV را برای چند مسأله‌ی نماینده نشان می‌دهد.

جدول ۱. نتایج روش پیشنهادی

Family	Problem	m (obj.)	Metric	Best baseline	DGD-MOEA/D	Rel. improv.
ZDT	ZDT3	2	↓ IGD	10×2.6 ²	10×2.1 ²	19%-
DTLZ	DTLZ2	3	↑ HV	0.729	0.781	7.1%+
DTLZ	DTLZ7	5	↓ IGD	10×1.15 ¹	10×9.0 ²	22%-
WFG	WFG4	10	↑ HV	0.412	0.435	5.6%+
MMOP	MMF-4	2	Low-density	0.47	0.81	72%+


همان‌طور که در جدول ۱ می‌بینید، در مسأله ZDT3 با دو هدف DGD-MOEA/D، حدود ۱۹٪ کاهش IGD نسبت به بهترین الگوریتم پایه‌ای به‌دست آورده است. در مسأله DTLZ2 با سه هدف، افزایش حدود ۷/۱٪ در Hypervolume مشاهده شده است. در مسأله DTLZ7 با پنج هدف، کاهش IGD به حدود ۲۲٪ می‌رسد. در مسأله WFG4 با ده هدف، بهبود Hypervolume حدود ۵/۶٪ گزارش شده است. در مسأله‌ی چندمدی MMF-4، نرخ پوشش نواحی کم‌چگالی از حدود ۴۷/۰ به ۸۱/۰ افزایش یافته است؛ یعنی، افزایش بیش از ۷۰٪ داشته است. این نتایج

1. inverted generational distance


نشان می‌دهند که تزریق بازخورد چگالی به تجزیه و همسایگی، هم در مسائل کلاسیک و هم در مسائل چندمدی، به بهبود معنادار معیارهای استاندارد منجر می‌شود.

روش DGD-MOEA/D با درگیر کردن برآورد چگالی در قلب فرایند تجزیه و انتخاب، الگوریتم را از یک طرح فاصله-محور ایستا به یک چارچوب تطبیقی آگاه از چگالی تبدیل می‌کند که می‌تواند میان تنوع و همگرایی تعادل پایدار ایجاد نماید و زمینه‌ساز پژوهش‌های بعدی در MaOEA/D های داده-محور باشد.


شکل ۱ و شکل ۲ و شکل ۳ نیز نتایج حاصل از اعمال روش پیشنهادی با استفاده از معیارهای ارزیابی می‌باشد. شکل ۱ افزایش معنی‌دار Hypervolume در تمامی بنچمارک‌ها، به‌ویژه در MMF4 و DTLZ7 را نشان می‌دهد. شکل ۲ کاهش محسوس IGD که نشانگر بهبود همگرایی و یکنواختی پوشش جبهه است را نشان می‌دهد و شکل ۳ منحنی HV برحسب نسل‌ها است که نشان‌دهنده‌ی DGD-MOEA/D با شیب تندتر و در نسل‌های کمتر به سطح همگرایی می‌باشد.



شکل ۱. نتایج Hypervolume در تمامی بنچمارک‌ها



شکل ۲. نتایج حاصل بر اساس معیار IGD



شکل ۳. منحنی HV بر حسب نسل‌ها

جمع‌بندی و کارهای آینده

در این مقاله، چارچوب DGD-MOEA/D معرفی گردید که با اتصال درون‌حلقه‌ای برآورد چگالی مبتنی بر DBSCAN/HDBSCAN به سه ماژول اصلی MOEA/D، آن را از یک طرح فاصله‌محور ایستا به یک الگوریتم تطبیقی آگاه از چگالی تبدیل می‌کند. نتایج تجربی روی مجموعه‌ای متنوع از مسائل دو تا پُرهدف و چندمدی نشان داد که پوشش نواحی کم‌چگالی و تنوع جبهه به‌طور قابل ملاحظه‌ای بهبود می‌یابد، معیارهای IGD و Hypervolume نسبت به الگوریتم‌های مرجع بهبود معناداری پیدا می‌کنند و سربار محاسباتی ناشی از خوشه‌بندی چگالی‌محور، با انتخاب تناوب مناسب بازتنظیم، در حد قابل قبول باقی می‌ماند. به‌عنوان مسیرهای آینده، می‌توان به موارد زیر اشاره کرد: تعمیم چارچوب DGD-MOEA/D به مسائل بسیار پُرهدف^۱ و مسائل چندهدفی پویا، بررسی استفاده از مدل‌های یادگیری ماشین برای تقریب برآورد چگالی و کاهش بیشتر سربار خوشه‌بندی و ترکیب ایده‌ی تجزیه‌ی آگاه از چگالی با رویکردهای مبتنی بر یادگیری ترجیح^۲ برای مسائل تصمیم‌گیری انسانی.

منابع

- Campello, R. J., Moulavi, D., Zimek, A., & Sander, J. (2015). Hierarchical density estimates for data clustering, visualization, and outlier detection. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 10(1), 1–51.
- Deb, K., Mohan, M., & Mishra, S. (2003). Towards a quick computation of well-spread Pareto-optimal solutions. In *Proceedings of the International Conference on Evolutionary Multi-Criterion Optimization*.
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. In *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD)*.
- Gu, Q., Li, K., Wang, D., & Liu, D. (2024). A MOEA/D with adaptive weight subspace for regular and irregular multi-objective optimization problems. *Information Sciences*, 661, 120143.
- Ishibuchi, H., Imada, R., Masuyama, N., & Nojima, Y. (2019). Comparison of hypervolume, IGD and IGD+ from the viewpoint of optimal distributions of solutions. In *Proceedings of the International Conference on Evolutionary Multi-Criterion Optimization*.
- Ishibuchi, H., Imada, R., Setoguchi, Y., & Nojima, Y. (2016). Performance comparison of NSGA-II and NSGA-III on various many-objective test problems. In *Proceedings of the IEEE Congress on Evolutionary Computation (CEC)*.

1. many-objective

2. preference learning

- Lavinas, Y., Teru, A. M., Kobayashi, Y., & Aranha, C. (2021). MOEA/D with adaptive number of weight vectors. In *Proceedings of the International Conference on the Theory and Practice of Natural Computing*.
- Li, H., & Zhang, Q. (2008). Multiobjective optimization problems with complicated Pareto sets, MOEA/D and NSGA-II. *IEEE Transactions on Evolutionary Computation*, 13(2), 284–302.
- McInnes, L., Healy, J., & Astels, S. (2017). HDBSCAN: Hierarchical density-based clustering. *Journal of Open Source Software*, 2(11), 205.
- Qi, Y., Ma, X., Liu, F., Jiao, L., Sun, J., & Wu, J. (2014). MOEA/D with adaptive weight adjustment. *Evolutionary Computation*, 22(2), 231–264.
- Sun, Y., Liu, J., & Liu, Z. (2024). MaOEA/D with adaptive external population guided weight vector adjustment. *Expert Systems with Applications*, 242, 122720.
- Tanabe, R., & Ishibuchi, H. (2020). Review and analysis of three components of differential evolution mutation operator in MOEA/D-DE. *arXiv preprint*, arXiv:2010.00265.
- Wang, L., Xu, M., Yu, W., Qiu, Q., & Wu, F. (2020). Decomposition multi-objective evolutionary algorithm based on adaptive neighborhood adjustment strategy. *IEEE Access*, 8, 78639–78651.
- Xu, M., Zhang, M., Cai, X., & Zhang, G. (2021). Adaptive neighbourhood size adjustment in MOEA/D-DRA. *International Journal of Bio-Inspired Computation*, 17(1), 14–23.
- Xue, F., Chen, Y., Dong, T., Wang, P., & Fan, W. (2025). MOEA/D with adaptive weight vector adjustment and parameter selection based on Q-learning. *Applied Intelligence*, 55(6), 399.
- Zhang, Q., & Li, H. (2007). MOEA/D: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 11(6), 712–731.

استناد به این مقاله: همایونی، هاله، و بازرگان لاری، کیمیا. (۱۴۰۴). تجزیه هدایت‌شده با DBSCAN برای خوشه‌بندی تکاملی چندهدفه: به‌سوی MOEA/D تطبیقی آگاه از چگالی. فصلنامه پژوهش‌های نوین در شهر هوشمند، ۴(۱)، ۵۰–۶۰.



New Researches in The Smart City is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.