

控制与决策

Control and Decision

基于增强弱交互与LJ势能引导的双种群多模态多目标进化算法

贺娟娟, 刘鸿伟, 张凯, 葛明峰

引用本文:

贺娟娟, 刘鸿伟, 张凯, 等. 基于增强弱交互与LJ势能引导的双种群多模态多目标进化算法[J]. *控制与决策*, 2026, 41(3): 651–663.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0789>

您可能感兴趣的其他文章

Articles you may be interested in

基于弱关联的自适应高维多目标进化算法

A weak association-based adaptive evolutionary algorithm for manyobjective optimization
控制与决策. 2021, 36(8): 1804–1814 <https://doi.org/10.13195/j.kzyjc.2019.1723>

混合柯西变异和均匀分布的蝗虫优化算法

Hybrid Cauchy mutation and uniform distribution of grasshopper optimization algorithm
控制与决策. 2021, 36(7): 1558–1568 <https://doi.org/10.13195/j.kzyjc.2019.1609>

基于分解的多目标多因子进化算法

A multiobjective multifactorial evolutionary algorithm based on decomposition
控制与决策. 2021, 36(3): 637–644 <https://doi.org/10.13195/j.kzyjc.2019.0525>

基于向量角分解的高维多目标进化算法

Many-objective evolutionary algorithm based on vector angle decomposition
控制与决策. 2021, 36(3): 761–768 <https://doi.org/10.13195/j.kzyjc.2019.0925>

具有重组学习和混合变异的动态多种群粒子群优化算法

Dynamic multi-population particle swarm optimization algorithm with recombined learning and hybrid mutation
控制与决策. 2021, 36(12): 2871–2880 <https://doi.org/10.13195/j.kzyjc.2020.0898>

基于增强弱交互与 LJ 势能引导的 双种群多模态多目标进化算法

贺娟娟^{1,2}, 刘鸿伟^{1,2}, 张凯^{1,2†}, 葛明峰³

- (1. 武汉科技大学 计算机科学与技术学院, 武汉 430065;
2. 武汉科技大学 智能信息处理与实时工业系统湖北省重点实验室, 武汉 430065;
3. 中国地质大学(武汉) 机械与电子信息学院, 武汉 430074)

摘要: 多模态多目标优化 (MMOP) 作为多目标优化领域的一大挑战, 要求算法不仅在目标空间获得高质量的帕累托解, 还要在决策空间捕捉多个结构明显不同但等效的解. 在这种双重需求下, 目标空间强收敛性易掩盖决策空间多样性, 导致解集结构单一化; 与此同时, 种群间交互的强弱失衡又分别引发种群同质化或协同失效等问题. MMOP 已成为制约复杂系统优化性能的关键瓶颈. 为此, 提出一种基于增强弱交互与 Lennard-Jones (LJ) 势能引导机制的双种群协同进化算法. 首先构建一种非对称信息交换机制, 在交配与子代生成阶段由收敛性种群向多样性种群建立精英引导路径, 有效兼顾多样性保持与进化效率; 其次, 环境选择策略由并行改为串行, 强化种群异质性, 减少对额外多样性策略的依赖, 提升稳定性与鲁棒性; 为提升种群在不同演化阶段的收敛性与多样性, 设计一种基于 LJ 势能模型的自适应候选解选择策略, 重新量化其交互权重, 该策略有效实现了探索与开发的动态平衡. 在多个典型 MMOP 测试函数上的实验结果表明, 所提算法在解集多样性、帕累托逼近质量和优化效率方面均优于主流方法, 展现出良好的泛化能力与工程应用潜力.

关键词: 多目标进化算法; 多模态多目标优化问题; 进化算法; 差分进化算法; 弱交互双种群协同进化; Lennard-Jones 势能

中图分类号: TP18 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0789

引用格式: 贺娟娟, 刘鸿伟, 张凯, 等. 基于增强弱交互与 LJ 势能引导的双种群多模态多目标进化算法 [J]. 控制与决策, 2026, 41(3): 651-663.

A dual-population MMOP algorithm with enhanced weak interaction and LJ potential guidance

HE Juan-juan^{1,2}, LIU Hong-wei^{1,2}, ZHANG Kai^{1,2†}, GE Ming-feng³

- (1. School of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, China; 2. Hubei Province Key Laboratory of Intelligent Information Processing and Real-time Industrial System, Wuhan University of Science and Technology, Wuhan 430065, China; 3. School of Mechanical Engineering and Electronic Information, China University of Geosciences, Wuhan 430074, China)

Abstract: Multimodal multi-objective optimization (MMOP) poses significant challenges in multi-objective optimization, as it requires algorithms to obtain high-quality Pareto-optimal solutions in the objective space while identifying multiple diverse yet equivalent solutions in the decision space. However, strong convergence in the objective space often leads to the loss of decision space diversity, causing structural degeneration of the solution set. Moreover, imbalanced interaction mechanisms may lead to population homogenization or a loss of cooperation. To overcome these issues, this paper proposes a dual-population co-evolutionary algorithm that incorporates an enhanced weak interaction mechanism and a Lennard-Jones (LJ) potential-based guidance mechanism. The proposed algorithm first establishes an asymmetric information exchange mechanism, where an elite-guided path is built from the convergence population to the diversity population during the mating and offspring generation stages, effectively

收稿日期: 2025-07-27; 录用日期: 2025-11-20.

基金项目: 国家自然科学基金项目 (62272355, 62176191, 62473349); 武汉市自然科学基金项目 (2025040601020144).

责任编辑: 徐泽水.

†通信作者. E-mail: zhangkai@wust.edu.cn.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

balancing convergence and diversity. Then, the environmental selection strategy is changed from parallel to sequential execution, which enhances population heterogeneity, reduces reliance on additional diversity maintenance strategies, and improves stability and robustness. To further improve convergence and diversity across different evolutionary stages, an adaptive candidate solution selection strategy based on the LJ potential model is designed. This strategy re-quantifies the interaction weights among individuals and effectively achieves a dynamic balance between exploration and exploitation. Experimental results on representative MMOP benchmarks show that the proposed algorithm achieves superior performance in diversity, convergence quality, and efficiency, demonstrating strong generalization ability and practical potential.

Keywords: multiobjective evolutionary algorithm; multimodal multiobjective optimization problem; evolutionary algorithm; differential evolution algorithm; weakly interacting dual-population coevolution; Lennard-Jones potential energy

0 引言

多模态多目标优化问题 (MMOPs) 是指存在多个不同决策向量映射到相同或等效目标向量的优化问题, 即具有多个帕累托最优解集但对应同一帕累托前沿的现象. 此类问题广泛存在于现实场景中, 如集装箱运输^[1]、旅行商问题^[2]、特征选择^[3]、作业车间调度^[4]以及无人机路径规划^[5]等. 近年来, 已有大量算法^[6-9]被提出以应对 MMOPs 在维持解多样性与定位多个等效最优区域方面的挑战.

求解 MMOPs 的关键在于有效挖掘结构差异显著但性能等效的多个最优解^[9], 这不仅具有重要的理论研究价值, 也在实际应用中展现出广阔前景.

尽管现有方法在提升决策空间多样性方面已取得一定进展, 但大部分多目标进化算法 (MOEAs) 仍高度依赖目标空间的支配关系与分布信息, 在环境选择中倾向于优先保留收敛性良好的非支配解. 这种以目标空间收敛性为主导的选择机制, 往往忽视了那些在目标空间性能相对较弱但在决策空间具有显著结构差异的潜在优质解. 这类解被文献^[10]称为“前景解”, 因其在探索未知帕累托解集 (PS) 区域、丰富最终解集结构以及提升决策弹性方面具有重要价值. 图1展示了前景解与非支配解之间竞争的一个简化示例.

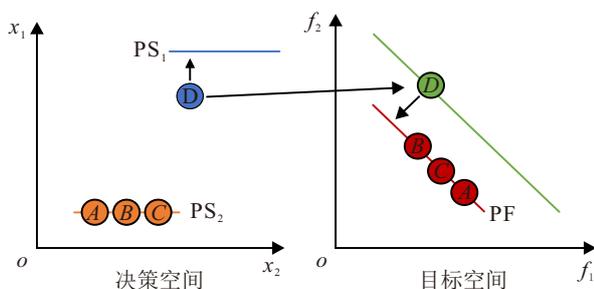


图1 前景解与非支配互相竞争举例

现有主流选择池构建^[11]与子代生成策略^[12]通常仅选用两类父代: 目标空间中收敛性优的非支配解和随机个体. 前景解因收敛性差, 难以被选为前者.

随机选择虽具探索性, 却无法确保有效挖掘其潜在 PS 区域, 导致搜索分散、效率低. 同时, 在有限种群与迭代次数下, 多数 MOEA 倾向于精化已知 PS 区域, 忽视对未知区域的探索, 当偶然生成位于未知 PS 的个体时, 常因其收敛性差且缺乏优质邻域解, 易在收敛性主导的选择压力下被过早淘汰. 因此, 前景解难以被有效保留与利用, 常在早期即被淘汰, 削弱了算法对决策空间优质区域的勘探能力, 导致最终帕累托解集分布不完整, 影响求解质量.

图1所示, 需从4个解中选择3个作为下一代种群. 显然, 解A、B和C在决策空间和目标空间中都保持了较好的收敛性和多样性. 然而, 由于 MOEA 所采用的收敛优先原则, 解D通常会被淘汰, 这种策略可能导致决策空间多样性的丧失.

当前多模态多目标优化普遍采用双种群协同进化策略, 通过引入辅助种群保留前景解, 并为主种群提供结构信息支持, 该框架主要分为强交互与弱交互两类: 前者在每次迭代中共享种群信息 (如交配选择、子代生成与环境选择), 后者则保持两群体相对独立, CMMO^[10]是弱交互的典型代表, 利用 ϵ -优势划分多样性种群, 避免前景解与非支配解直接竞争. 然而, 由于缺乏来自收敛性种群的有效引导, 多样性种群演化方向不明确, 难以将分布良好的解有效进化为高质量解, 制约其搜索能力, 强交互框架虽能加快收敛, 但持续的信息融合易导致多样性种群过早收敛, 削弱全局探索, 面对复杂帕累托集结构时, 往往难以全面覆盖解空间, 影响最终解集的完整性与分布均衡性.

为克服当前双种群协同进化框架在种群信息交互与结构多样性保持方面的不足, 本文提出一种基于增强弱交互与 Lennard-Jones (LJ) 势能引导机制的双种群协同进化算法 (DPMOEA-LJ), 以提升多模态多目标优化问题中的搜索效率与解集结构质量. 该算法的主要贡献如下:

1) 本文提出非对称信息交流的强化弱交互协同

进化框架. 首先, 设计一种非对称信息交换机制, 在交配选择与子代生成阶段, 从收敛性种群向多样性种群构建精英引导路径, 形成非对称的信息流动模式. 与传统弱交互模式相比, 该策略增强了多样性种群对收敛性信息的获取能力, 有效缓解了传统弱交互中多样性种群进化迟滞的问题. 此外, 将环境选择策略由并行调整为串行执行, 强化了种群异质性控制, 减少对附加多样性维护策略的依赖, 从而在保障决策空间多样性的同时, 提升了算法在目标空间与决策空间上的整体平衡能力.

2) 为进一步提升种群搜索过程中的引导精度与稳定性, 本文设计一种基于 LJ 势能模型的自适应候选解选择机制. 该机制通过模拟个体间的吸引-排斥关系, 并结合动态邻域半径与参数调节, 构建具有自适应特性的选择压力机制, 在维持种群多样性的同时提升搜索稳定性. 在演化初期优先选取中等距离且分布均匀的个体, 增强种群的全局搜索能力; 在演化后期转向以邻近优质解为中心的局部搜索, 以加速解集向帕累托前沿收敛. 该策略有效实现了探索与开发的动态平衡, 在多模态场景中展现出更强的鲁棒性与搜索效率, 尤其在保持多样性与定位高质量解方面优势显著.

3) 本文通过在多个典型多模态多目标优化测试函数上, 与代表性多目标进化算法进行对比实验. 结果表明, 所提出的 DPMOEA-LJ 在解集质量、目标空间逼近性与决策空间多样性保持方面均优于现有主流算法, 展现出良好的泛化能力与工程应用潜力.

1 相关工作与研究动机

1.1 基于双种群协同进化的 MOEAs

双种群协同进化算法一般分为强交互协同进化框架与弱交互协同进化框架, 这两类协同进化框架一般采用种群协作策略, 通常通过构建一个主种群与一个或多个辅助种群, 实现功能分工与协同演化. 辅助种群往往专注于探索决策空间的多样性或维护潜在的多模态结构, 而主种群则侧重于目标空间与决策空间的收敛与分布优化. 两者通过设计合理的交互机制 (如种群信息共享或竞争协作), 在保持搜索多样性的同时推动整体收敛, 从而在复杂 MMOPs 上实现更全面的解集覆盖.

1.1.1 强交互协同进化算法

基于强交互协同进化算法的大致思想是在种群协同进化过程中持续加强种群之间的信息交互, 然后通过特定策略维持决策空间的多样性. 例如, Li 等^[11]提出的 ND/DPP 针对不同种群开发了不同探

索策略, 种群 1 采用了帕累托优势原则而种群 2 采用了分解原则. Wang 等^[12]提出了 MMPICEAg, 该方法基于分解原则, 在种群信息交流阶段引入多样性感知适应度分配, 多样性更好的解获得更高奖励, 用于平衡目标空间和决策空间的收敛性和多样性. Ming 等^[13]提出的 MMEAPSL 是一个 3 种群协同进化算法, 该方法基于 Growing Neural Gas 网络的代理辅助帕累托集学习, 在求解 MMOPs 的过程中使用代理模型学习帕累托集的拓扑结构, 促进多模态多目标优化问题的求解.

1.1.2 弱交互协同进化算法

基于弱交互协同进化算法的核心思想是在协同进化过程中引入有限的信息交流机制, 使得不同种群在进化过程中保持相对独立性, 同时又能通过特定策略实现有选择的信息共享. 在此基础上, 进一步引入多样性的维护策略, 以增强多样性种群的探索能力, 并通过其补充收敛性种群在多样性方面的不足, 从而在整体上实现多样性和收敛性的更好平衡. 例如, Li 等^[14]提出的 CoMMEA 针对不同类型的种群设计了差异化的信息交流策略, 并为多样性种群引入了存档收敛指标 (ILC), 从而在保持种群多样性的同时可有效提升其收敛性能, 实现多样性与收敛性之间的良好平衡; Ming 等^[10]提出的 CMMO 则采用了一种新颖的动态 ϵ -优势机制, 专门用于维护多样性种群的分布多样性, 从而增强算法在处理复杂 Pareto 前沿问题时的能力; Zou 等^[15]提出的 CAEAD 引入了交替进化的策略, 通过在不同进化阶段动态切换种群的优化目标, 并结合 ϵ -优势机制, 分别侧重于收敛性与多样性的提升, 从而实现整体性能的优化; Li 等^[16]提出的 CDP-BCD 对种群间的信息交流机制进行了改进, 引入了基于条件选择的交互策略, 并通过局部收敛质量指标 (SLCQ) 评估多样性种群中个体的收敛性能, 从而筛选并淘汰收敛性较差的解, 进一步提升了算法在多样性与收敛性之间的平衡能力.

1.2 研究动机

在 MMOP 中, 强交互协同进化框架通过频繁的信息交换加速种群收敛, 但其收敛优先的策略容易淘汰多样性良好但当前收敛性较差的个体, 导致种群过早陷入局部区域, 削弱对决策空间中多个 PS 的覆盖能力, 进而影响解集在目标空间的分布完整性. 相比之下, 弱交互协同进化框架通过限制种群间的信息流动, 结合多样性维持机制, 能够有效保留具有潜力的非收敛性解, 缓解早熟收敛问题. 然而, 由于

缺乏足够的收敛引导, 该类方法在逼近 PF 时效率较低, 收敛速度慢, 限制了整体优化性能.

为验证信息交互强度对算法性能的影响, 本文在相同实验条件 (种群规模 200, 函数评价次数 10 000) 下对比弱交互代表算法 CMMO 与其增强信息交流版本 CMMO- α , 以及强交互代表算法 MMEAPSL 与其受限信息交流版本 MMEAPSL- α , 在测试函数 MMMOP1 上的优化结果, 如图 2 所示.

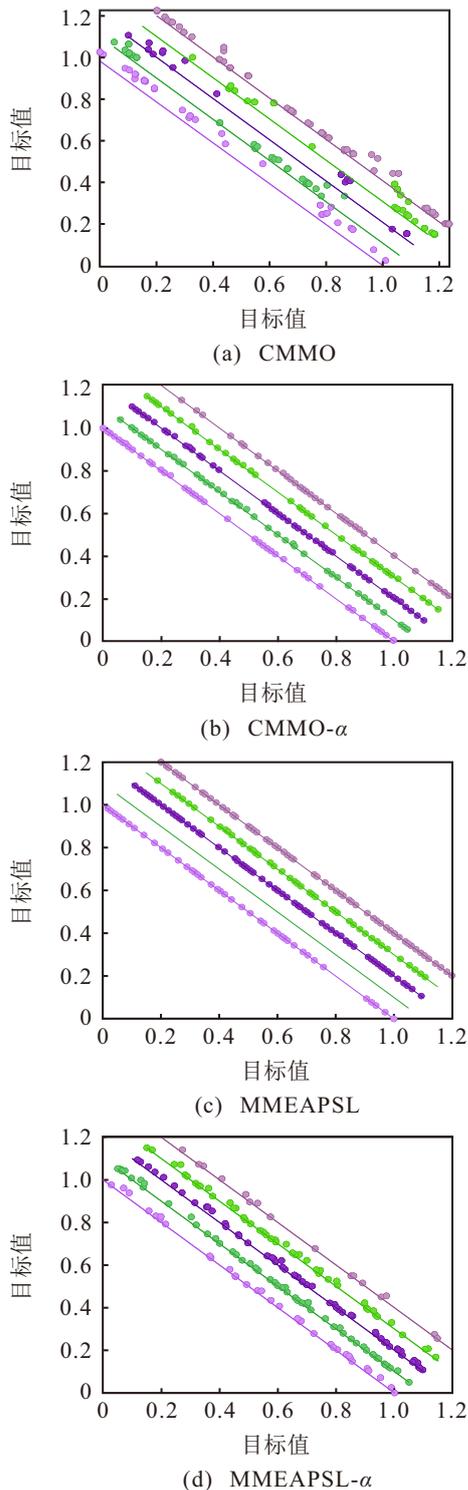


图2 不同算法获取 MMMOP1 问题的目标空间种群分布结果

MMMOP1 具有三维决策空间和多个映射至同一 PF 的等效 PS. 为直观展示解的来源分布, 将来自不同 PS 的解在目标空间中以不同颜色标识并叠加呈现, 形成复合 PF 图.

从图 2(a) 和图 2(b) 可见, CMMO- α 通过适度增强种群间的信息引导, 显著提升了对 PF 的覆盖广度与均匀性, 表明在弱交互框架中引入有限信息交流有助于兼顾多样性与收敛性. 类似地, 图 2(c) 与图 2(d) 显示, MMEAPSL- α 在限制信息交流后, 多样性明显改善, 说明强交互框架中过度的信息共享会抑制种群异质性. 上述结果表明, 无论是弱交互还是强交互框架, 适度调整信息交互强度均能有效提升算法性能: 前者可通过增强引导提升收敛效率, 后者可通过抑制交互来恢复多样性.

基于此, 本文提出一种改进的协同进化机制, 以弱交互框架为基础, 引入适度增强的信息交流策略. 具体地, 设计非对称信息流动模式, 并将环境选择由并行调整为串行执行, 以强化种群间的功能差异与协同效率, 避免多样性过早流失. 该设计旨在保留具有潜力的多样性解的同时, 逐步引导其向 PF 收敛, 防止如图 2(c) 中浅紫色区域所示的 PF 空缺现象长期存在, 从而提升解集的完整性与分布质量. 进一步地, 本文提出一种基于 LJ 势能模型的自适应候选解选择机制, 通过模拟个体间的吸引力与排斥力动态调节选择压力, 实现对收敛性与多样性的协同控制, 结合收敛解引导策略, 算法在进化初期侧重全局探索, 后期转向局部开发, 形成阶段自适应的搜索行为. 实验结果表明, 所提方法在收敛速度、解集分布均匀性及稳定性方面均优于现有主流算法, 实现了探索与开发的更好平衡, 显著提升了多模态多目标优化的整体性能.

2 所建立的 DPMOEA-LJ

2.1 DPMOEA-LJ 框架

本文所提出的 DPMOEA-LJ 的整体框架如图 3 所示, 其中种群 1 和种群 2 分别表示收敛性种群和多样性种群. 具体而言, 首先初始化两个种群 P_1 和 P_2 , 然后迭代执行以下步骤直到满足终止条件:

- 1) 适应度评估: 依据式 (1) 和 (4) 对收敛性种群 P_1 中的个体评估其适应度;
- 2) 候选解选择: P_1 采用多准则锦标赛选择机制, 种群信息仅来自 P_1 , P_2 采用所提出的 LJ 势能模型引导的选择机制, 种群信息来自 P_1 和 P_2 ;
- 3) 子代生成: 差分变异生成子代;
- 4) 串行环境选择: 将子代先与 P_1 进行联合与竞

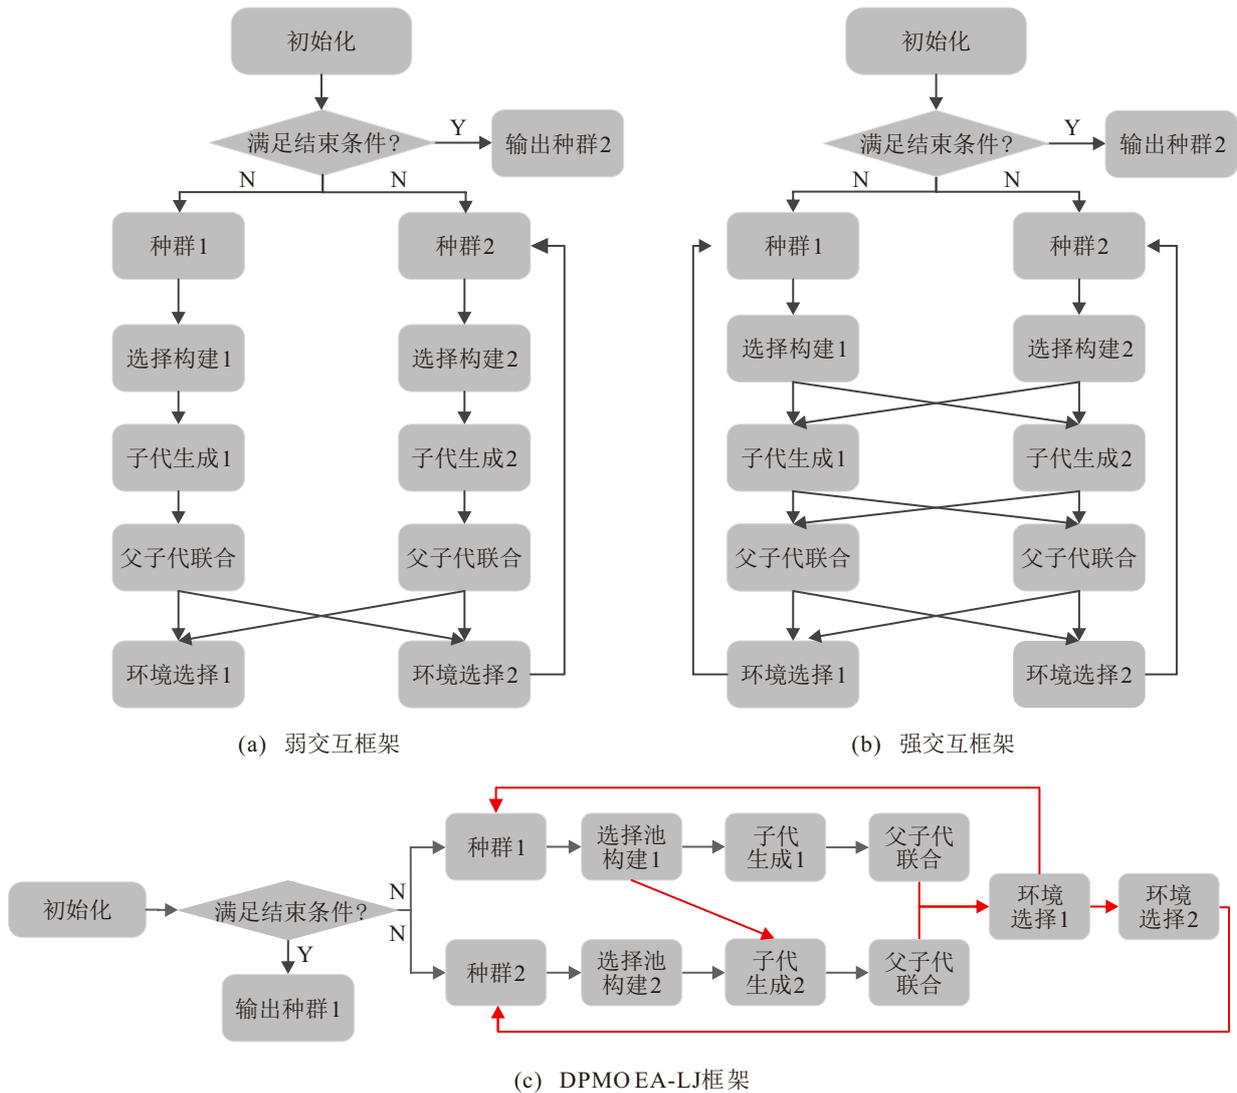


图3 传统弱交互协同进化、强交互协同进化与混合交互协同进化框架

争, 得到新一代 P_1 和未被选中的个体集合 P_2^t , 随后将 P_2^t 与 P_2 进行联合与竞争, 得到新一代 P_2 。

如图3所示, 与典型弱交互协同进化框架(图3(a))和强交互协同进化框架(图3(b))相比, DPMOEA-LJ在保持种群结构异质性的基础上, 构建了一种非对称的信息交流机制. 具体而言, 在选择池构建阶段, 引入收敛性种群中的精英个体作为引导信息, 以提升多样性种群的收敛性; 同时, 环境选择采用顺序执行方式, 先选择收敛性种群, 再利用其未被保留的个体辅助多样性种群选择, 形成了种群间的互补协同. 这一机制在提升多样性种群分布能力的同时, 也为收敛性种群提供了反馈机制, 增强其后续优化能力. 红色箭头标识了关键的信息引导路径, 突出了该框架在探索与开发之间的动态平衡机制.

整体上, DPMOEA-LJ框架融合了弱交互策略在维持解集多样性方面的优势与强交互策略在加速收敛方面的效率, 实现了二者性能的有机平衡, 尤为重要, 该策略在无需引入额外多样性维护机制

(如密度惩罚、聚类划分或显式存档控制)的情况下, 仍能有效保持多样性种群的分布质量, 显著降低了算法设计的复杂性.

2.2 非对称交配池选择

在本文提出的协同进化框架中, 收敛性种群与多样性种群采用非对称的交配选择机制, 以实现收敛性与多样性的协同优化. 对于收敛性种群, 其交配池构建仅基于内部信息, 保持独立演化路径. 本文设计多准则锦标赛选择机制, 综合评估个体的收敛性 (R)、目标空间分布性 (D_{obj}) 与决策空间稀疏性 (D_{dec}), 借鉴现有研究^[10, 14, 17], 将三者加权聚合为统一适应度函数, 即

$$Fitness = R + D_{obj} + D_{dec}. \tag{1}$$

收敛性种群解的收敛性依照如下方式计算:

$$R = \sum_{\substack{y \in P \\ y \neq x}} r(x, y). \tag{2}$$

其中 $r(x, y)$ 被定义为

$$r(x, y) = \begin{cases} 1, & y < x; \\ 0, & \text{otherwise.} \end{cases} \quad (3)$$

当 R 为零时, x 为非支配解。

为提升种群多样性维护的精度, DPMOEA-LJ 借鉴 CoMMEA^[14] 中的改进拥挤距离计算方法, 该方法采用调和平均形式, 能够更敏感地识别高密度区域中个体间的细微分布差异, 从而增强选择操作对个体分辨能力, 具体计算如下:

$$D = \frac{N}{\sum_{i=2}^N \frac{1}{\text{dis}(i)}}. \quad (4)$$

对于多样性种群, 本文采用基于 LJ 势能模型的自适应分配选择策略, 取代传统的基于适应度的锦标赛选择. 该方法不仅考虑种群内部个体间的分布关系, 还引入收敛性种群中的优质解作为外部引导, 以增强向帕累托前沿的收敛趋势. 通过计算个体间的 LJ 势能值作为选择权重, 优先选取在决策空间中分布适度、兼具潜力的个体参与变异, 从而实现种群间的信息融合与协同优化.

此外, 该策略支持基于进化阶段的自适应调整: 在演化初期, 偏向选择势能较低、分布广泛的个体以增强全局探索; 在演化中后期, 倾向于选取邻近的高质量个体以加速局部收敛. 该动态引导机制显著提升了多样性种群的搜索效率, 同时有效维持了解集在决策空间与目标空间中的分布广度.

2.3 基于 LJ 势能模型的自适应候选解选择策略

收敛性种群与多样性种群在解的分布特性上具有显著差异. 收敛性种群在进化过程中表现出良好的收敛性和较均匀的分布, 因此, 其所采用的进化算子需具备较强的局部搜索能力与精确逼近能力. 在 DPMOEA-LJ 中, 收敛性种群采用 DE/best/1 差分变异策略, 以增强对当前 PS 的逼近精度.

相比之下, 多样性种群呈现阶段性演化特征: 初期侧重全局探索, 避免遗漏潜在解区域; 中后期需引导分散解向帕累托前沿收敛, 因此其进化算子需具备自适应调节“探索-开发”权衡的能力. 其中, 候选解选择直接影响变异效果, 传统基于固定或动态邻域的选择策略易在早期陷入局部区域, 或在后期难以识别有效引导解, 影响收敛效率. 为此, 本文提出一种基于 LJ 势能模型的自适应候选解选择策略. 该策略通过模拟个体之间的吸引与排斥关系, 动态量化解之间的相互作用关系, 并据此为候选解分配选择权重, 从而在保持多样性的同时提升搜索效率与引导性.

本文采用 LJ 势能模型用于量化解之间的权重, 其表达式如下:

$$w_{ij}^{(t)} = 4 \left[\left(\frac{\sigma^{(t)}}{d_{ij}} \right)^{12} - \left(\frac{\sigma^{(t)}}{d_{ij}} \right)^6 \right]. \quad (5)$$

其中: d_{ij} 表示个体 i 与 j 在决策空间中的欧氏距离; $\sigma^{(t)}$ 为第 t 代的动态邻域半径, 为增强算法鲁棒性, $\sigma^{(t)}$ 在 $\text{median}(D) \times [0.9, 1.1]$ 范围内周期性振荡, 具体为

$$\sigma^{(t)} = \text{median}(D) \cdot \left(0.9 + 0.2 \cos \left(\frac{\pi t}{T} \right) \right). \quad (6)$$

这里: D 为当前个体与其邻近个体的距离集合, T 为最大进化代数.

此外, 参考文献 [18], 在处理低维 (2 ~ 4 维) 多模态多目标优化问题时, 邻域规模取种群大小 N 的 1/20 至 1/5 可有效评估局部拥挤程度. 本文设 $N = 200$, 初始邻居数为 10, 并采用动态调整策略

$$k = 10 + (N - 10) \cdot e^{-10(t/T)}. \quad (7)$$

该策略在进化初期 ($k \approx N$) 促进全局探索, 中后期 (k 快速下降) 转向局部开发, 实现平滑过渡.

在进化初期, $k \approx N$, 个体间近乎互为邻居, 有利于全局探索; 当进化进入中后期 ($t/T \geq 0.5$) 时, k 值迅速减小, 推动算法转向局部搜索, 提升收敛性能. 对于每个候选解, 首先计算其在决策空间中与其他个体的欧氏距离, 并按升序排列. 随后, 基于改进的 LJ 势能模型评估个体间的相互作用: 距离过近时表现为排斥 (权重小), 避免冗余, 增强多样性; 距离适中时吸引力强 (权重大), 利于保留优质解; 距离过远时权重趋近于零, 影响可忽略.

图 4 展示了个体在不同演化阶段, 其邻域解的 LJ 权重变化趋势, 直观反映了该模型在演化过程中的调控效果. 需要注意的是, 权重越低, 表示该个体被选为候选解的概率越高, 从而实现了解的反向引导选择.

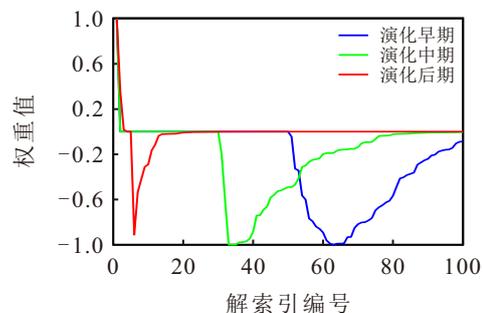


图4 演化过程中解的 LJ 势能权重变化趋势

为适应进化过程中探索与开发需求的动态变化, 本文对 LJ 势能模型计算的原始权重进行自适应调整, 以提升搜索过程的阶段适应性. 该机制在早期有

效维持种群多样性, 在后期加速向高质量解区域收敛。

在进化初期(探索阶段), 为避免早熟收敛并扩大潜在优质解的选取范围, 参考文献[19], LJ 势能的吸引极值点位于 $r = 2^{1/6}\sigma \approx 1.122\sigma$ 。为此, 以该点为中心, 将有效吸引区间 r 向两侧扩展 30%, 扩展至 $[0.8\sigma, 1.5\sigma]$, 并对该区间内的个体权重加倍, 以增强候选解的多样性:

$$w'_{ij} = 2 \times w_{ij}, d_{ij} \in (0.8\sigma, 1.5\sigma). \quad (8)$$

在进化后期(开发阶段), 种群分布趋于良好, 算法重点转向精细开发。为加快收敛并提升解集质量, 增强收敛性种群中优质解对多样性种群的引导作用, 对其影响权重进行强化:

$$w'_{ij} = w_{ij} \times \left(3 + 2 \times \frac{t}{T}\right), j \in \varepsilon. \quad (9)$$

其中: $\varepsilon = \max(2, \lfloor N \cdot r_{\text{elite}}^t \rfloor)$ 表示当前代中精选的优质解集合, $r_{\text{elite}}^t = 0.1 + 0.4 \times \frac{t}{T}$ 为随进化进程线性增长的精英比例。该设计在保持多样性的同时, 逐步增强收敛能力, 有效推动个体向真实帕累托前沿逼近。

综上, 所提机制通过动态调节个体间相互作用, 实现了从全局探索到局部开发的自适应过渡, 在无需额外多样性维护操作的前提下, 有效平衡了收敛性与多样性, 显著提升了算法在多模态多目标优化问题上的整体性能。

2.4 DPMOEA-LJ 算法时间复杂度分析

DPMOEA-LJ 的主要步骤如下: 1) 收敛性种群的适应度评估: 通过比较所有个体对在目标空间的支配关系进行非支配排序, 时间复杂度为 $O(MN^2)$; 2) 多准则选择池构建: 结合非支配层级与拥挤度距离选择父代, 复杂度为 $O(MN^2)$; 3) LJ 势能模型引导的选择策略: 基于决策空间个体间距离计算 LJ 势能, 以增强分布性, 涉及 $O(N^2)$ 次距离计算, 复杂度为 $O(DN^2)$; 4) 子代生成: 采用差分变异策略, 复杂度为 $O(DN)$; 5) 环境选择: 合并父代与子代后进行非支配排序与截断, 复杂度为 $O(MN^2)$ 。综上, DPMOEA-LJ 每代的时间复杂度为 $O((M + D)N^2)$ 。

3 实验结果与分析

3.1 实验设置

为全面评估 DPMOEA-LJ 的性能, 本文选取 5 种代表性先进多目标进化算法进行对比, 包括 3 种双种群协同进化算法和两种双存档机制算法。双种群算法包括基于强交互的 MMEAPSL^[13] 及基于弱交互的 CMMO^[10] 和 CoMMEA^[14]; 双存档算法为 TriMOEAAR^[20] 和 HREA^[17]。所有实验在 PlatEMO^[21]

平台进行, 硬件环境为: Windows 10、Intel i7-12700F CPU、32 GB 内存。各算法参数均按原始文献设置, 种群规模统一为 200, 最大函数评估次数为 20 000。测试函数选用 MMF^[22]、OMNI^[23]、SYM^[24]、IDMP^[25] 和 MMMOP^[20] 等标准多模态多目标基准问题。性能评估采用 IGD^[26] 和 IGDX^[27] 指标: IGD 衡量解集在目标空间对真实帕累托前沿的收敛性与分布性, IGDX 评估决策空间中对真实帕累托解集的逼近程度与多样性保持能力。每种算法在各类问题上独立运行 30 次, 最终结果通过统计分析对比。

3.2 时间复杂度对比

为进一步评估各算法的计算效率, 本文汇总了所对比算法的总体时间复杂度, 如表 1 所示。设种群规模为 N , 目标数为 M , 决策变量维度为 D 。

表1 各算法的总体时间复杂度

算法名称	总体时间复杂度
MMEAPSL	$O(N^3)$
TriMOEATAR	$O((M + D)N^2)$
HREA	$O((M + D)N^2)$
CoMMEA	$O(MN^2)$
CMMO	$O(MN^2)$
DPMOEA-LJ	$O((M + D)N^2)$

综上, DPMOEA-LJ 的时间复杂度为 $O((M + D)N^2)$, 与 TriMOEATAR 和 HREA 等先进算法处于同一数量级, 显著优于 MMEAPSL 的 $O(N^3)$ 。该结果表明, 尽管 DPMOEA-LJ 引入了基于 LJ 势能的自适应候选解选择机制以增强多样性维护能力, 其计算开销仍在合理范围内, 具备良好的可扩展性与实际应用潜力。

3.3 有效性实验

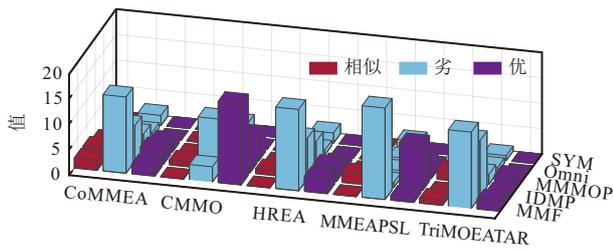
为评估性能, 各算法在测试问题上独立运行 30 次, 采用 IGD 和 IGDX 指标, 并通过 Friedman 检验与 Wilcoxon 秩和检验 ($\alpha = 0.05$) 进行统计分析, 结果以“优”“劣”“相似”表示对比算法相对于 DPMOEA-LJ 的性能。

表 2 显示了 6 种算法在 MMF、IDMP、MMMOP、OMNI 和 SYM 问题上的 IGD 与 IGDX 均值(灰色为最优)。DPMOEA-LJ 在 IGD 指标上于 MMF 和 MMMOP 问题表现最佳, 在 IDMP 与 SYM 上与其他算法相当; 在 IGDX 上, 其在 MMF、IDMP、SYM 和 OMNI 问题均取得最优, 表明其在决策空间多样性保持方面优势显著, 仅在 MMMOP 上略逊于 TriMOEATAR。

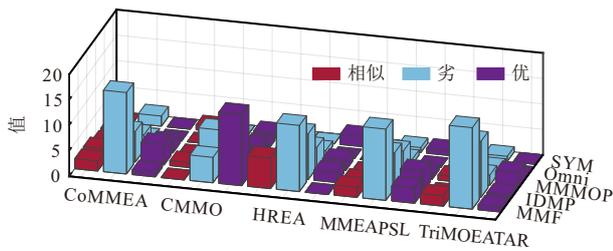
图 5 统计了各对比算法在不同问题系列上 IGD 均值相对于 DPMOEA-LJ 的“优、劣、相似”情况。红

表2 6种算法在测试问题上独立运行30次获得的IGD与IGDX均值结果

测试问题	指标	TriMOEATAR	HREA	CoMMEA	CMMO	MMEAPSL	DPMOEA-LJ
MMF	IGD	3.00e-02	2.29e-02	1.82e-02	1.73e-02	1.68e-02	1.67e-02
	IGDX	8.59e-02	3.52e-02	3.49e-02	3.40e-02	3.26e-02	3.08e-02
IDMP	IGD	1.41e-02	4.97e-03	5.04e-03	4.83e-03	5.12e-03	4.95e-03
	IGDX	7.15e-01	1.60e-01	4.85e-02	1.43e-02	1.58e-01	3.82e-02
MMMOP	IGD	6.87e-03	7.04e-03	6.29e-03	4.97e-03	6.67e-03	3.73e-03
	IGDX	6.49e-03	2.37e-02	1.94e-02	3.29e-02	4.28e-03	2.01e-02
OMNI	IGD	1.94e-02	1.29e-02	7.89e-03	1.23e-02	1.40e-02	1.15e-02
	IGDX	4.75e-01	8.02e-02	3.59e-01	8.12e-02	8.86e-02	6.66e-02
SYM	IGD	3.57e-02	1.49e-02	1.93e-02	1.42e-02	1.47e-02	1.46e-02
	IGDX	8.30e-01	4.89e-02	6.78e-02	4.60e-02	6.17e-02	3.92e-02



(a) IGD 均值优劣对比



(b) IGDX 均值优劣对比

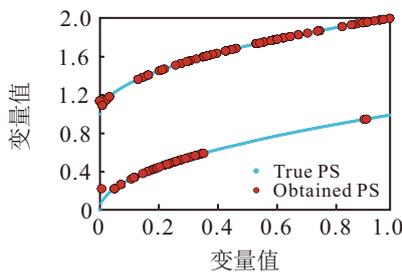
图5 各算法与DPMOEA-LJ在各系列问题获取的IGD与IGDX均值优劣对比统计结果

色柱表示性能相当的问题数,蓝色柱表示显著更差,紫色柱表示显著更优.例如,CoMMEA在19个MMF问题中,有约15个显著差于DPMOEA-LJ,2个相当,

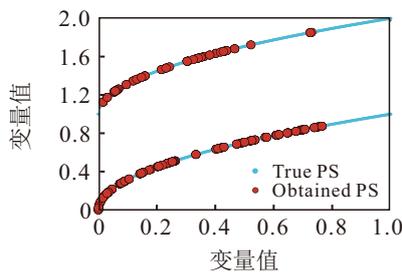
2个更优.整体表明DPMOEA-LJ在多数问题上显著优于或优于对比算法.

结果表明,DPMOEA-LJ在多数测试问题上取得了优于大多数对比算法的IGD均值,验证了其非对称种群信息交流机制与改进环境选择策略在提升收敛性能方面的有效性.如图5所示,在IGDX指标的“优/劣/相似”统计中,DPMOEA-LJ在绝大多数问题上表现更优,展现出卓越的决策空间多样性维持能力.尽管在个别问题上略逊于MMEAPSL和CMMO,但整体性能突出,且无需依赖额外的多样性维护机制,体现了其结构设计的有效性与鲁棒性.

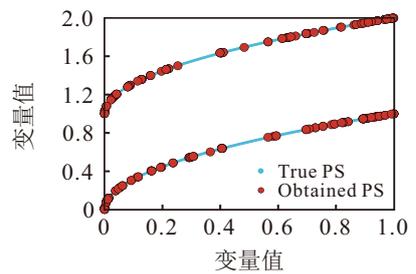
为直观展示DPMOEA-LJ的性能,图6呈现了6种算法在MMF2问题上的最终PS结果.红色点为算法所得解集,蓝色线为真实PS,覆盖越完整性能越优.结果显示,TriMOEATAR与HREA解集密集,多样性不足;而CMMO、CoMMEA、MMEAPSL及DPMOEA-LJ等双种群算法分布更均匀.其中DPMOEA-LJ凭借非对称信息交互与串行环境选择,



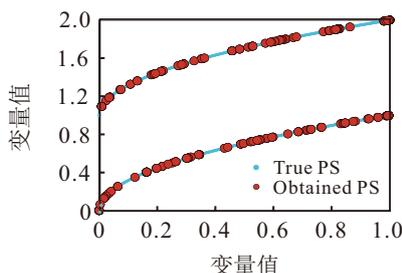
(a) TriMOEATAR



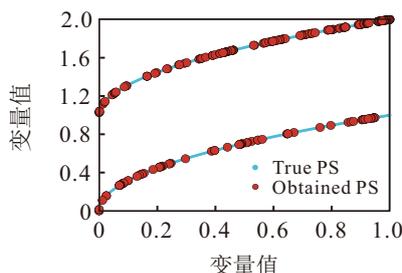
(b) HREA



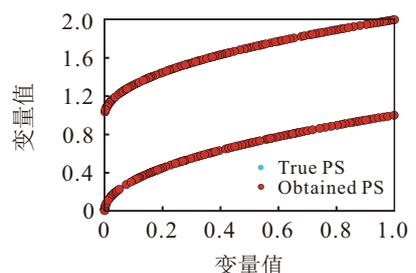
(c) CoMMEA



(d) CMMO



(e) MMEAPSL



(f) DPMOEA-LJ

图6 各算法在MMF2问题上获取的PS结果

在无需额外多样性机制的情况下, 有效平衡收敛性与多样性, 整体性能更优.

为分析算法在不同阶段的动态性能, 绘制了各算法在 MMF2 问题上 IGD 与 IGDX 随迭代的演化曲线 (图 7). 如图 7(a) 和图 7(b) 所示, DPMOEA-LJ 在收敛速度和种群多样性保持方面均表现最优, 始终领先. 其中, CMMO 为最接近的竞争对手, 中后期性能与之较为接近, 但整体仍略逊一筹.

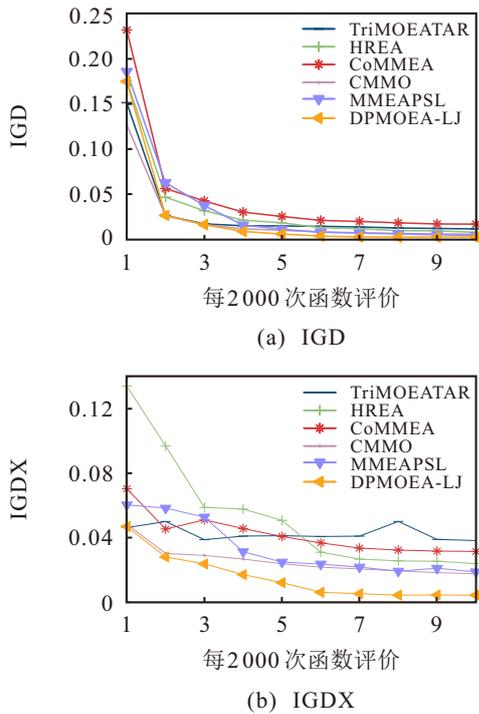


图7 各算法求解 MMF2 获取的 IGD 与 IGDX 值

3.4 讨论

综合图 5 和图 7 可知, DPMOEA-LJ 在多数测试问题上性能优越. 但在 MMF 系列问题中, 尽管 IGDX 均值最优、多样性保持能力强, 但 Wilcoxon 检验显示其未显著优于 CMMO, 部分问题甚至略差. 分析表明, 该现象与 MMF 问题复杂的 PS 结构有关. CMMO 采用基于分布信息的动态优势机制, 可保留局部分布良好但收敛性弱的个体, 在个别运行中可能偶然覆盖高密度 PS 片段, 但该机制对分布估计敏感, 易因邻域误判导致性能波动, 稳定性较差. 相比之下, DPMOEA-LJ 通过 LJ 势能模型实现探索与开发的自适应平衡, IGDX 表现更稳定. 然而, 在 MMF 极端非均匀的 PS 分布下, 固定邻域规模难以及时响应局部密度变化, 限制了其在高曲率或密集区域的精细搜索能力. 参数实验已证实邻域规模对性能影响显著.

尽管调整邻域可提升特定问题性能, 但为兼顾多场景下的通用性与整体鲁棒性, 本文采用适中且固定的邻域配置, 以确保多种类型问题的稳定表现.

3.5 参数敏感性分析

为系统评估基于 LJ 势能模型的自适应候选解选择策略中关键参数的鲁棒性与必要性, 本文在保持其他组件及实验设置与第 3.3 节一致的前提下, 开展了系统的参数敏感性分析, 通过对比不同配置下算法在 IGD 与 IGDX 指标上的表现, 深入探讨各参数对收敛性与多样性的贡献. 整体结果如表 3 所示.

表3 9 种变体算法在测试问题上独立运行 30 次获得的 IGD 与 IGDX 均值结果

测试问题	指标	DPMOEA-LJ ($k=2$)	DPMOEA-LJ ($k=40$)	DPMOEA-LJ (linear)	DPMOEA-LJ (σ_1)	DPMOEA-LJ (σ_2)	DPMOEA-LJ (SW)	DPMOEA-LJ (10p)	DPMOEA-LJ (50p)	DPMOEA-LJ
MMF	IGD	1.73e-02	2.07e-02	1.75e-02	1.94e-02	1.68e-02	1.72e-02	1.72e-02	1.92e-02	1.67e-02
	IGDX	3.01e-02	4.75e-02	5.79e-02	4.71e-02	3.31e-02	3.56e-02	3.49e-02	3.61e-02	3.08e-02
IDMP	IGD	4.18e-03	4.42e-03	4.21e-03	4.31e-03	3.96e-03	3.99e-03	4.06e-03	4.31e-03	4.95e-03
	IGDX	6.99e-02	5.76e-02	7.27e-02	9.30e-02	8.46e-02	7.83e-02	8.57e-02	9.35e-02	3.82e-02
MMMOP	IGD	5.35e-03	6.30e-03	5.69e-03	6.02e-03	2.32e-02	5.51e-03	5.80e-03	5.43e-03	3.73e-03
	IGDX	1.54e-02	1.39e-02	2.05e-02	5.65e-02	1.61e-02	1.44e-02	1.48e-02	1.47e-01	2.01e-02
OMNI	IGD	1.63e-02	2.09e-02	1.69e-02	4.73e-02	1.86e-02	1.58e-02	1.40e-02	1.47e-02	1.15e-02
	IGDX	4.65e-02	4.96e-02	4.74e-02	1.56e-01	4.71e-02	6.45e-02	6.31e-02	7.56e-02	6.66e-02
SYM	IGD	1.94e-02	2.15e-02	1.97e-02	1.50e-02	2.02e-02	1.93e-02	1.95e-02	1.86e-02	1.46e-02
	IGDX	4.00e-02	4.54e-02	3.97e-02	2.45e-01	4.06e-02	4.20e-02	4.07e-02	2.94e-01	3.92e-02

首先, 针对邻域规模 k 的设置, 依据文献 [18], 在低维多模态问题中 $k \in [10, 40]$ 有助于局部拥挤度评估. 本文取 $k=10$ 并采用指数衰减. 实验表明, $k=10$ 时, 在 MMF、MMMOP 和 OMNI 上性能最优, 平衡了局部感知与选择压力; $k=2$ 时, 因邻域过窄导致信息利用不足; $k=40$ 时, 虽在 IDMP 上 IGD 较优, 但 IGDX 显著升高, 尤其在 OMNI 上因拥挤度失

真削弱了多模态分辨能力. 采用线性衰减的变体在 IDMP 与 SYM 上 IGD 明显更差, 表明其收缩过快, 抑制早期探索, 验证了指数衰减在探索-开发协调中的优势.

接着, 为验证邻域半径 $\sigma^{(t)}$ 自适应调控的必要性, 构建固定半径 (DPMOEA-LJ(σ_1)) 与随机扰动 (DPMOEA-LJ(σ_2)) 变体. 结果表明, 固定半径在多数

问题上 IGD/IGDX 显著更差, 难以适应种群密度变化, 随机扰动策略稳定性不足. 相比之下, 基于 LJ 模型的自适应 $\sigma^{(t)}$ 显著提升了算法分布稳定性与多样性保持能力.

随后, 为评估自适应权重机制的有效性, 构建恒定权重变体 DPMOEA-LJ (SW). 实验结果显示, 其 IGD 与原始算法相近, 但 IGDX 普遍更差, 尤其在 SYM 与 MMMOP 上差异显著, 表明固定权重难以根据进化阶段调整个体作用强度, 多样性维持能力不足. 而自适应权重通过非线性响应机制, 实现了对搜索过程的阶段性引导, 更有效地协调了探索与开发的平衡.

最后, 为验证候选解选择范围 $[0.8\sigma, 1.5\sigma]$ 的合理性, 设计扩展 10% 与 50% 的变体 DPMOEA-LJ (10p) 与 DPMOEA-LJ(50p). 结果表明, 二者在所有问题上均全面劣于原始配置, 且性能随范围扩大而恶化. 原始范围精准覆盖 LJ 势能吸引力较强区域, 引入了潜在优质解, 在收敛性与多样性之间实现了

协同优化.

综上所述, 通过系统性的消融实验分析, 充分验证了 DPMOEA-LJ 中邻域规模、动态半径、自适应权重及选择范围等关键组件的设计有效性. 所提出的自适应机制能够根据进化进程动态调整搜索行为, 在探索与开发、收敛性与多样性之间实现良好平衡, 为算法的整体性能提供了坚实支撑. 参数敏感性分析系统验证了 DPMOEA-LJ 中各关键组件设计的有效性与必要性. 所提出的自适应机制在平衡探索与开发、兼顾收敛性与多样性方面发挥了关键作用, 为算法的整体性能提供了坚实支撑.

3.6 消融实验

为验证 DPMOEA-LJ 中非对称信息交流策略、基于 LJ 势能的候选解选择策略及串行环境选择机制的有效性, 本文构建 3 种变体: DPMOEA-LJ¹ (替换为弱交互协同框架)、DPMOEA-LJ² (替换为候选解随机选择策略)、DPMOEA-LJ³ (使用并行环境选择策略). 实验设置同第 3.3 节, 结果见表 4.

表4 3种 DPMOEA-LJ 变体在测试问题上独立运行 30 次获得的 IGD 与 IGDX 均值结果

测试问题	指标	DPMOEA-LJ ¹	DPMOEA-LJ ²	DPMOEA-LJ ³	DPMOEA-LJ
MMF	IGD	1.80e-02	1.85e-02	1.55e-02	1.67e-02
	IGDX	3.40e-02	3.28e-02	3.45e-02	3.08e-02
IDMP	IGD	5.32e-03	4.70e-03	7.79e-03	4.95e-03
	IGDX	5.40e-02	5.60e-02	3.43e-01	3.82e-02
MMMOP	IGD	4.45e-03	3.95e-02	4.58e-03	3.73e-03
	IGDX	2.30e-02	2.00e-02	3.92e-02	2.01e-02
OMNI	IGD	1.30e-02	1.10e-02	1.22e-02	1.15e-02
	IGDX	6.30e-02	7.50e-02	6.64e-02	6.66e-02
SYM	IGD	1.60e-02	1.30e-02	1.45e-02	1.46e-02
	IGDX	4.50e-02	4.20e-02	5.23e-02	3.92e-02

由表 4 的实验结果可见, 3 种变体的整体性能均低于 DPMOEA-LJ, 表明所提核心机制对算法性能具有关键贡献. DPMOEA-LJ¹ 性能显著退化, 说明传统弱交互协同框架难以有效协调子种群间的信息流动, 协同效率低; 而本文提出的非对称信息交流机制通过差异化引导, 显著增强了种群协作能力与全局搜索性能. DPMOEA-LJ² 在多数问题上性能与原始算法相近, 表明随机选择策略在部分场景下仍具基本有效性; 但在复杂多模态问题 (如 MMMOP、OMNI) 上, 其 IGD 与 IGDX 明显升高, 收敛性与多样性同步下降, 说明缺乏势能引导易导致搜索方向迷失和分布失衡, 验证了基于 LJ 势能的选择策略在应对复杂解结构时的引导优势. DPMOEA-LJ³ 的性能劣化则表明, 并行环境选择易引发种群同质化, 削弱多样性维持能力, 而串行机制通过有序更新更有利于保持种群异质性. 综上, 3 项消融实验共同验证了

DPMOEA-LJ 各核心组件在不同优化场景下的有效性与必要性.

接着, 为进一步评估串行环境选择机制在多样性保持方面的作用, 本文提出邻域平均距离 (ANDs) 指标

$$\text{ANDs}(P) = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{k} \sum_{j=1}^k \|x_i - x_{\pi_j(i)}\| \right). \quad (10)$$

其中: N 为种群规模, $k = 10$ 为邻域大小, $x_{\pi_j(i)}$ 表示 x_i 的第 j 个最近邻个体. ANDs 反映种群在决策空间中的分布广度, 值越大, 表明个体间平均距离越远, 多样性越高. 与依赖真实帕累托前沿 (PS) 的 IGDX 不同, ANDs 完全基于种群内部拓扑结构, 不涉及对 PS 的逼近程度, 因而可独立刻画解集的疏密特性与异质性水平. 如图 8 所示, 在 CMMO 求解 MMF1 的过程中, 区域 1 (分布均匀) 与区域 2 (高度聚集) 的

IGDX 值相近, 但前者 ANDs 显著更高, 说明该指标能有效识别 IGDX 无法反映的多样性退化问题, 具有更强的判别敏感性.

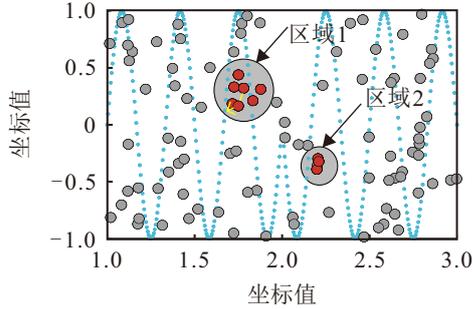
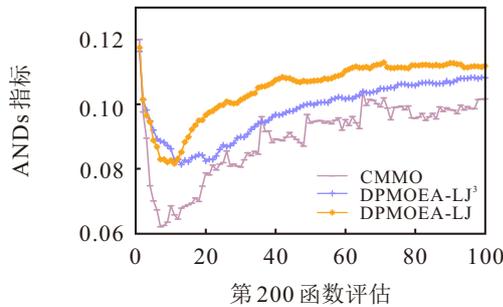
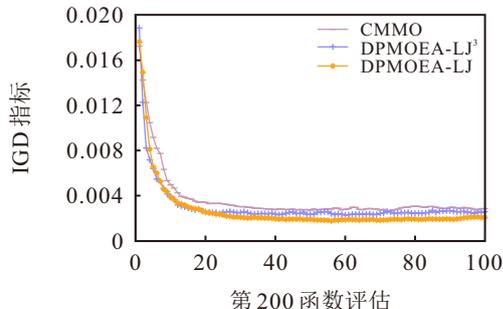


图8 ANDs 指标与 IGDX 指标在 MMF1 问题的对比情况

随后, 以求解 MMF1 问题为例分析 ANDs 的演化趋势. 如图 9 所示, DPMOEA-LJ 在 IGD 持续下降 (见图 9(b)) 的同时, ANDs 下降缓慢 (见图 9(a)), 并在进化中后期出现回升, 表明算法在持续逼近最优前沿的过程中, 仍能有效维持并逐步恢复决策空间的多样性. 相比之下, DPMOEA-LJ³ 与 CMMO 的 ANDs 在早期迅速降低且未见反弹, 说明其种群快速趋于集中, 探索能力严重受限. 其中: CMMO 的 ANDs 幅度最大, 反映出其更新机制导致严重的同质化现象. DPMOEA-LJ 的 ANDs 回升趋势进一步表明, 串行环境选择通过引入时序依赖性, 使个体更新过程形成动态反馈, 有效延缓了种群聚集.



(a) ANDs 指标



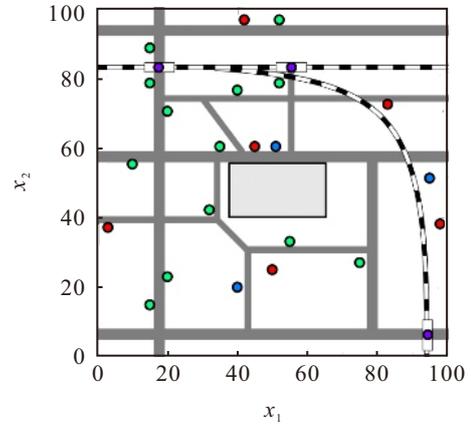
(b) IGD 指标

图9 3 种算法求解 MMF1 问题获取的 ANDs 与 IGD 值

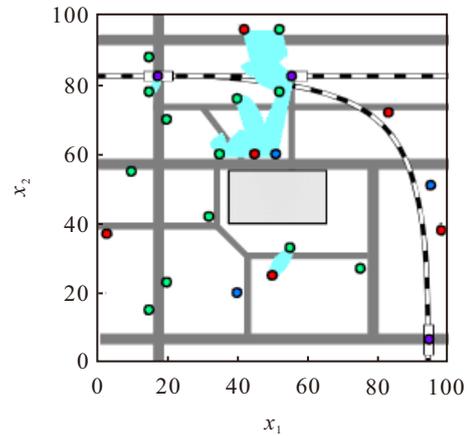
3.7 实际问题应用验证

为验证 DPMOEA-LJ 在实际场景中的适用性,

本文引入一个基于真实地图的多目标优化问题 (源自文献^[28]). 如图 10 所示, 该区域包含 6 所小学 (红)、3 所初中 (蓝)、13 家便利店 (绿) 和 3 个火车站 (紫). 目标是选址一组位置, 使其到 4 类设施的综合距离最小.



(a) 决策空间



(b) 真实问题 PS 分布

图10 真实世界问题

实验采用与第 3.3 节相同的参数设置以确保可比性. 表 5 展示了各算法在 IGD 与 IGDX 指标上的表现, DPMOEA-LJ 取得与 CMMO、MMEAPSL 相近的性能, 其中 IGDX 均值最优. 图 11 进一步展示了各算法的最终解分布, DPMOEA-LJ 的解集有效覆盖了 3 个主要帕累托子区域, 分布均匀且收敛性良好, 表现与 MMEAPSL 和 CMMO 相当, 显著优于其他算法.

表5 真实地图问题实验结果

算法名称	IGD	IGDX
TriMOEATAR	3.101 0e+0 (3.49e-1)	2.652 2e+0 (5.38e-1)
HREA	1.757 8e+0 (2.04e-1)	1.850 6e+0 (7.38e-2)
CoMMEA	1.402 1e+0 (3.05e-2)	1.483 0e+0 (5.45e-2)
CMMO	1.494 2e+0 (2.73e-1)	1.266 4e+0 (4.65e-1)
MMEAPSL	1.327 5e+0 (9.59e-2)	1.082 1e+0 (1.12e-1)
DPMOEA-LJ	1.373 9e+0 (1.69e-1)	1.115 6e+0 (2.94e-2)

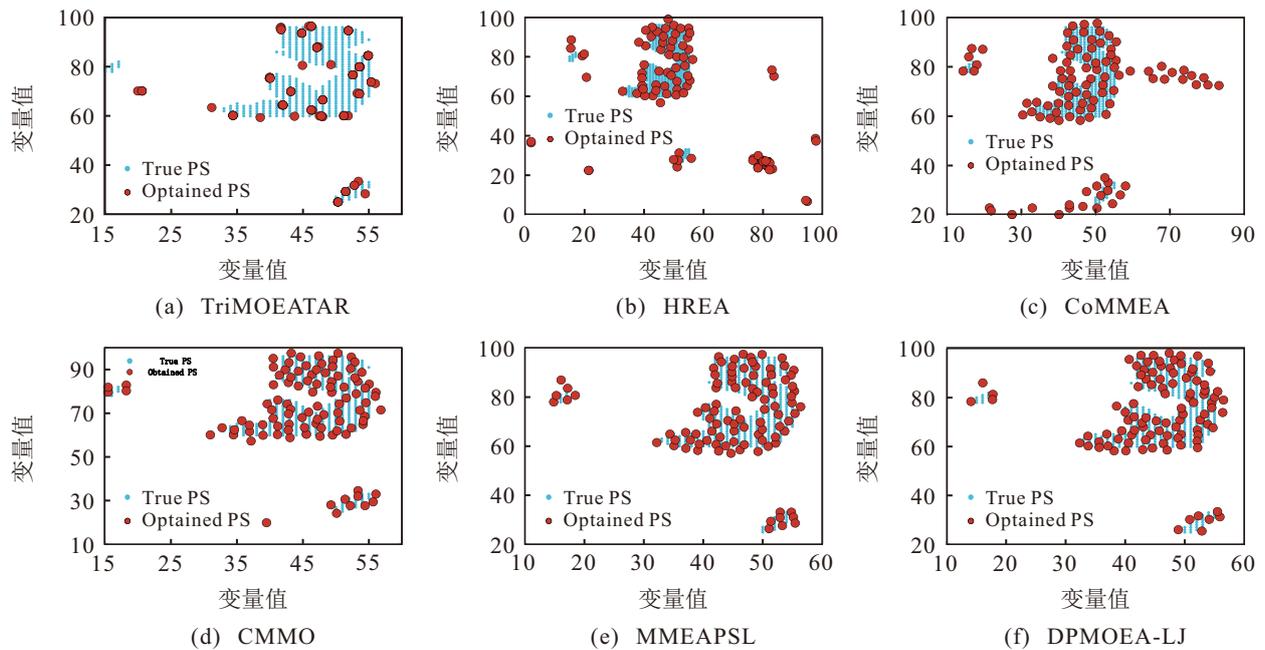


图11 各算法在真实地图问题上的表现

综上, DPMOEA-LJ 在具有复杂空间分布特征的真实地图问题中仍能保持优异性能, 验证了其在现实应用场景中的有效性与鲁棒性。

4 结论

本文提出了一种基于增强弱交互与 LJ 势能引导机制的双种群协同进化算法 DPMOEA-LJ, 旨在有效应对现有弱交互协同进化框架在求解多模态多目标优化问题 (MMOPs) 时普遍存在的收敛性差、多样性维持能力不足以及易陷入进化停滞等问题, 为此本文设计了非对称信息交换机制, 在交配选择与子代生成阶段实现精英种群对多样种群的定向引导, 有效平衡全局探索与局部开发; 同时, 将传统的并行环境选择策略改进为串行执行方式, 增强种群间的协同差异性, 降低对额外多样性维护机制的依赖, 显著提升算法的鲁棒性与收敛效率; 此外, 本文提出一种基于 LJ 势能模型的自适应候选选择策略, 结合差分变异机制, 动态评估个体间的吸引力与排斥力, 引导算子选取更具代表性的解, 从而在保持分布广度的同时加速收敛。在多个典型 MMOP 基准测试函数及一个基于地图的真实世界问题上的实验结果表明, DPMOEA-LJ 在解集多样性、帕累托前沿逼近质量及优化效率方面均优于主流对比算法, 展现出良好的泛化能力与实际应用潜力。

参考文献 (References)

- [1] 何维, 何世伟, 迟居尚, 等. 集装箱多式联运全程运输路径与接驳集卡调度协同优化[J]. 控制与决策, 2025, 40(7): 2175-2184.
(He W, He S W, Chi J S, et al. Collaborative optimization of door-to-door transport routes and drayage truck scheduling in container intermodal transport[J]. *Control and Decision*, 2025, 40(7): 2175-2184.)
- [2] Liu Y P, Xu L T, Han Y Y, et al. Evolutionary multimodal multiobjective optimization for traveling salesman problems[J]. *IEEE Transactions on Evolutionary Computation*, 2024, 28(2): 516-530.
- [3] Yue C T, Liang J J, Qu B Y, et al. Multimodal multiobjective optimization in feature selection[C]. 2019 IEEE Congress on Evolutionary Computation. Wellington, 2019: 302-309.
- [4] 张国辉, 伦伟航, 李亮, 等. 基于混合学习策略进化算法的柔性作业车间节能分批调度研究[J]. 控制与决策, 2025, 40(12): 3655-3666.
(Zhang G H, Lun W H, Li L, et al. A hybrid learning strategy evolutionary algorithm for energy-efficient flexible job shop batch scheduling problem[J]. *Control and Decision*, 2025, 40(12): 3655-3666.)
- [5] 闫李, 马佳慧, 柴旭朝, 等. 基于知识引导的自适应动态多模态差分进化算法[J]. 控制与决策, 2023, 38(11): 3048-3056.
(Yan L, Ma J H, Chai X Z, et al. Adaptive dynamic multimodal differential evolution algorithm based on knowledge guidance[J]. *Control and Decision*, 2023, 38(11): 3048-3056.)
- [6] 杨新武, 杨丽军. 基于交叉模型的改进遗传算法[J]. 控制与决策, 2016, 31(10): 1837-1844.
(Yang X W, Yang L J. An improved genetic algorithm based on crossover model[J]. *Control and Decision*, 2016, 31(10): 1837-1844.)
- [7] Zhang K, Shen C N, He J J, et al. Knee based multimodal multi-objective evolutionary algorithm for decision making[J]. *Information Sciences*, 2021, 544: 39-55.

- [8] He J J, Yang Q, Xu Z W, et al. Two-stage multimodal multi-objective evolutionary algorithm based on global density updating strategy[J]. *Scientia Sinica Informationis*, 2024, 54(10): 2385.
- [9] Zhang K, Shen C N, Yen G G, et al. Two-stage double niched evolution strategy for multimodal multiobjective optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(4): 754-768.
- [10] Ming F, Gong W Y, Wang L, et al. Balancing convergence and diversity in objective and decision spaces for multimodal multi-objective optimization[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, 7(2): 474-486.
- [11] Li K, Kwong S, Deb K. A dual-population paradigm for evolutionary multiobjective optimization[J]. *Information Sciences*, 2015, 309: 50-72.
- [12] Wang R, Ma W B, Tan M, et al. Preference-inspired coevolutionary algorithm with active diversity strategy for multi-objective multi-modal optimization[J]. *Information Sciences*, 2021, 546: 1148-1165.
- [13] Ming F, Gong W Y, Jin Y C. Growing Neural Gas Network-based surrogate-assisted Pareto set learning for multimodal multi-objective optimization[J]. *Swarm and Evolutionary Computation*, 2024, 87: 101541.
- [14] Li W H, Yao X Y, Li K W, et al. Coevolutionary framework for generalized multimodal multi-objective optimization[J]. *IEEE/CAA Journal of Automatica Sinica*, 2023, 10(7): 1544-1556.
- [15] Zou J, Sun R Q, Yang S X, et al. A dual-population algorithm based on alternative evolution and degeneration for solving constrained multi-objective optimization problems[J]. *Information Sciences*, 2021, 579: 89-102.
- [16] Li Z P, Rong H G, Yang S X, et al. A dual-population coevolutionary algorithm for balancing convergence and diversity in the decision space in multimodal multi-objective optimization[J]. *Applied Soft Computing*, 2024, 162: 111770.
- [17] Li W H, Yao X Y, Zhang T, et al. Hierarchy ranking method for multimodal multiobjective optimization with local Pareto fronts[J]. *IEEE Transactions on Evolutionary Computation*, 2023, 27(1): 98-110.
- [18] Qu B Y, Suganthan P N, Liang J J. Differential evolution with neighborhood mutation for multimodal optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2012, 16(5): 601-614.
- [19] Lennard-Jones J E. Cohesion[J]. *Proceedings of the Physical Society*, 1931, 43(5): 461-482.
- [20] Liu Y P, Yen G G, Gong D W. A multimodal multiobjective evolutionary algorithm using two-archive and recombination strategies[J]. *IEEE Transactions on Evolutionary Computation*, 2019, 23(4): 660-674.
- [21] Tian Y, Cheng R, Zhang X Y, et al. PlatEMO: A MATLAB platform for evolutionary multi-objective optimization [educational forum][J]. *IEEE Computational Intelligence Magazine*, 2017, 12(4): 73-87.
- [22] Liang J, Suganthan P N, Qu B Y, et al. Problem definitions and evaluation criteria for the CEC 2020 special session on multimodal multiobjective optimization[R]. Zhengzhou: Zhengzhou University, 2019.
- [23] Deb K, Tiwari S. Omni-optimizer: A procedure for single and multi-objective optimization[C]. *Evolutionary Multi-Criterion Optimization*. Berlin, 2005: 47-61.
- [24] Rudolph G, Naujoks B, Preuss M. Capabilities of EMOA to detect and preserve equivalent Pareto subsets[C]. *Evolutionary Multi-Criterion Optimization*. Berlin, 2007: 36-50.
- [25] Liu Y P, Ishibuchi H, Yen G G, et al. Handling imbalance between convergence and diversity in the decision space in evolutionary multimodal multiobjective optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2020, 24(3): 551-565.
- [26] Bosman P A N, Thierens D. The balance between proximity and diversity in multiobjective evolutionary algorithms[J]. *IEEE Transactions on Evolutionary Computation*, 2003, 7(2): 174-188.
- [27] Zhou A M, Zhang Q F, Jin Y C. Approximating the set of Pareto-optimal solutions in both the decision and objective spaces by an estimation of distribution algorithm[J]. *IEEE Transactions on Evolutionary Computation*, 2009, 13(5): 1167-1189.
- [28] Ishibuchi H, Akedo N, Nojima Y. A many-objective test problem for visually examining diversity maintenance behavior in a decision space[C]. *Proceedings of the 13th Annual Conference on Genetic and Evolutionary Computation*. Dublin Ireland, 2011: 649-656.

作者简介

贺娟娟 (1985-), 女, 教授, 博士, 博士生导师, 主要研究方向为仿生计算、医学图像处理, E-mail: hejuajuan@wust.edu.cn;

刘鸿伟 (2000-), 男, 硕士生, 主要研究方向为计算智能, E-mail: 1606121056@qq.com;

张凯 (1979-), 男, 教授, 博士, 博士生导师, 主要研究方向为计算智能、DNA 计算、数字孪生与虚拟现实, E-mail: zhangkai@wust.edu.cn;

葛明峰 (1986-), 男, 教授, 博士, 博士生导师, 主要研究方向为智能体强化学习与自适应控制、具身智能多模态交互系统, E-mail: gemf@cug.edu.cn.