

基于 α 支配的高维目标进化算法研究

林梦嫒¹ 周欢² 王丽萍^{1,3}

(浙江工业大学经贸管理学院 杭州 310023)¹ (浙江工业大学信息工程学院 杭州 310023)²
(浙江工业大学信息智能与决策优化研究所 杭州 310023)³

摘要 基于 Pareto 支配的多目标进化算法能够很好地处理 2~3 维的多目标优化问题。但在处理高维多目标问题时,随着目标维数的增大,支配受阻解的数量急剧增加,导致现有的多目标算法存在选择压力不够、优化效果较差的问题。通过引入 α 支配提供严格的 Pareto 分层,在同层中挑选相对稀疏的解作为候选解,同时详细分析不同 α 对算法性能的影响,提出一种新的基于 α 偏序和拥塞距离抽样的高维目标进化算法。将该算法在 DTLZ 上进行性能测试,并采用世代距离(GD)、空间评价(SP)、超体积(HV)等多个指标评估算法的性能。实验结果表明,引入 α 支配能去除绝大部分支配受阻解(DRSs),提高算法的收敛性。与快速非支配排序算法(NSGA-II)、基于分解的多目标进化算法(MOEA/D)、基于距离更新的分解多目标进化算法(MOEA/D-DU)相比,该算法的整体解集的质量有明显提高。

关键词 高维目标优化,非支配受阻解,拥塞距离,超体积

中图分类号 TP18 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.01.049

Research of Many-objective Evolutionary Algorithm Based on Alpha Dominance

LIN Meng-man¹ ZHOU Huan² WANG Li-ping^{1,3}

(College of Economics and Management, Zhejiang University of Technology, Hangzhou 310023, China)¹

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China)²

(Institute of Information Intelligence and Decision Optimization, Zhejiang University of Technology, Hangzhou 310023, China)³

Abstract The classic multiobjective evolutionary algorithms based on the Pareto dominance solve the problems with 2 to 3 objectives effectively. However, when dealing with many-objective problems, as the number of dominance resistant solutions is rapidly increasing owing to the increase of the objectives, the existed multiobjective algorithms lack of the selection pressure towards the Pareto front, and the optimization effect becomes bad. In this paper, we analyzed the influence of different alpha values, then provided strict Pareto layer, and selected the relatively sparse solution as candidate solutions in the same layer. At last, we proposed a new many-objective evolutionary algorithm based on alpha partial order and congestion distance sampling. The performance of the algorithms was evaluated by generation distances(GD), spacing(SP), hypervolume(HV) on the DTLZ problems. The experimental results show that the convergence of the algorithm improves greatly through eliminating the DRSs. Compared with the NSGA-II, MOEA/D and MOEA/D-DU, the overall quality of the solutions by the improved algorithms increases greatly.

Keywords Many-objective optimization, Dominance resistance solutions, Congestion distance, Hypervolume

1 引言

经典的多目标进化算法能够获得收敛性和分布性较好的最优解^[1]。然而,在处理实际问题时,目标维数高达 5 维以上。此时,算法效果明显降低,随着目标个数的增加,非支配解的比例呈指数增长,由于非支配解占据种群的绝大部分,任何基于精英保留策略的多目标优化算法都难以从大量非支配解中挑选出合适的解。非支配解比例的增大,使得算法的搜索能力急剧下降^[2]。

为提高基于 Pareto 支配的多目标进化算法在优化高维目标问题时的搜索能力,部分学者提出了若干方法^[3]。文献[3]给出了几种可能提高算法性能的方法:1)改进的密度估

计^[4];2)不同排序的引入^[5,6];3)Pareto 支配定义的改进^[7]。Ishibuchi 等部分学者结合快速非支配排序(NSGA-II)尝试采用以上几种方法求解高维目标问题,实验表明,在一定程度上改进的算法能够取得对较好的性能,但求出的近似 Pareto 前沿多样性下降。

近年来,为有效求解高维目标问题,部分学者引入性能指标来评价种群中的个体优越性。常见的 IBEA (Indicator-based selection in multiobjective search)^[8]及 HypE (HypE: An algorithm for fast hypervolume-based many-objective optimization)^[9]通过引入性能指标对个体进行评价,找出相对较优的解。然而,在实际求解的过程中,个体性能指标值的计算量比基于 Pareto 支配的计算量大很多,而且消耗时间较长。

到稿日期:2016-03-28 返修日期:2016-07-11 本文受国家自然科学基金:基于多偏好与变量分解的大规模高维目标优化方法及应用研究(6147 2366),基于轮廓线段簇的隐式形状模型及其优化方法研究(6139077),浙江省自然科学基金:融合侧步爬山策略的大规模多目标协同进化算法研究(LY13F030010),基于双极偏好占优的高维目标进化算法研究(LZ13F020002)资助。

林梦嫒(1989-),女,博士生,主要研究方向为多目标优化;周欢(1991-),男,硕士生,主要研究方向为多目标优化;王丽萍(1963-),女,博士,教授,主要研究方向为多目标优化算法,E-mail:wlp@zjut.edu.cn。

与此同时,性能指标值的计算量随着目标维数的增大而急剧增加,这些缺点都阻碍了该类算法的应用。

基于标量化函数值的适应度评价方法能够有效评价种群中的每个个体,且相比引入性能指标类型的算法,该类算法计算复杂度较低,其中典型代表为 Zhang^[10]提出的 MOEA/D (Multiobjective Evolutionary Algorithm Based on Decomposition)。该算法处理 2-3 维的连续多目标问题时,能够取得较好的效果。然而,当目标个数较多时,为获得相对均匀的解集,权重向量的个数随着目标个数呈非线性增长,种群的大小不能由决策者实施自由弹性设置。因而该算法优化目标个数较多的高维问题时获得的解的均匀性较差,易出现局部收敛。

最近,为进一步提高多目标算法求解高维目标问题的能力,K. Deb^[11]提出基于偏好点的非支配排序算法 NSGA-III (An Evolutionary Many-objective Optimization Algorithm Using Reference-point-based Nondominated Sorting Approach)。该算法主要特点为结合分解的思想设置偏好点,引导种群进化,以双层模式设置较少的偏好点,获取相对均匀的解集。同时,Deb 在 3~15 维测试问题上对算法进行性能测试,实验结果表明该类算法能够获得均匀的近似 Pareto 前端。

以上研究表明,结合 NSGA-II 框架并做出改进,在某种程度上能够获得相对较好的解集,NSGA-II 框架仍在优化高维目标问题上有着较大的潜能。然而,NSGA-III 依旧采用基于 Pareto 支配的适应度评价方式,随着目标维数的增大,种群中非支配解的数量急剧增大,基于 Pareto 支配的适应度评价方式将极大地减缓种群逼近 Pareto 前沿的速度。从某种程度上讲,这种做法不利于选择相对合适的解作为候选解,降低了算法的收敛速度。本文首先结合 DRSs (Dominance Resistant Solutions) 的定义对种群中非支配解难以排除的现象做出解释,进一步提出解决该类问题的可行方案。通过引入 α 支配剔除该类型的非支配解,排除支配受阻解,提高算法的收敛性;同时研究高维目标问题中不同 α 值对算法性能的影响,结合 NSGA-II 框架,提出 α -NSAGA-II 算法。与此同时,为维持解集的均匀性,提出基于 α 偏序和拥挤距离抽样的方法,选择相对均匀的候选解参与种群进化,提升算法求解解集的分布性,进一步提高算法求解的整体性能。

2 背景知识

2.1 支配受阻解(DRSs)

多目标进化算法的研究者通常把解集分为两种类型:1)被支配的解;2)难以被支配的解,但该类解与其他解是非支配的。

正如,Kita 等所讲,部分问题的一些解在种群的进化中生存的周期很长,但这些解的质量却很差,原因在于在种群进化过程中,基于标准 Pareto 支配的选择方式很难找到可以支配该类解的候选解,导致这类解难以被排除,降低了种群的收敛速度。

支配受阻解定义如下:DRSs^[12]指的是在某一个维度上比其他非支配解差很多,其实这类解远离 Pareto 前端。能够支配 DRSs 这种类型的解却很难找到。

可想而知,假如 DRSs 在搜索空间中占据大量的比例,将导致基于 Pareto 支配的多目标算法难以求出质量相对较好的解。其主要原因在于多目标算法通常把非支配解集当作引导种群进化的候选解。下面以一组解为例说明该现象。在 DTLZ2 问题中,随机生成种群并进行分层,得出非支配解集,其中 A 解(f_1, f_2, f_3)=(0.46, 1.28, 1.84), B 解(f_1, f_2, f_3)=

(0.43, 1.34, 0.33),可以看出尽管 A 解和 B 解是同一层的非支配解,但 A 解的 f_3 明显比 B 解的 f_3 大很多。通过分析可知,与 B 解相比,A 解远离 Pareto 前端。但基于 Pareto 支配的多目标算法无法满足 A 支配 B,因此,假如能够在发现 DRSs 解时通过选择算子剪除 B 类型的解,减少该类型的解在种群进化中的存活周期,则有利于算法的收敛,提高解集质量。为解决该类问题,引入 α 支配定义,结合多目标算法对该类问题进行求解。

2.2 α 支配定义

α 支配的根本性概念是两个目标之间设置最高/最低折衷比例。尽管很难估算两个目标之间确定的折衷比例,但找出两个目标之间大概的折衷区间是相对较容易的。比如 α_{ij} 和 α_{ji} 分别为 f_i 和 f_j 的最高和最低折衷比例: $\alpha_{ij} \leq \frac{\Delta f_i}{\Delta f_j} \leq \frac{1}{\alpha_{ij}}$, 其中 Δf_i 和 Δf_j 为 f_i, f_j 的改变量。

不失一般性,以 k 个目标的最小化问题为例,对于 $f_1(x), \dots, f_k(x)$, 其中 $x \in X, X$ 为多目标优化问题的可行域。

$$g_i(\vec{x}_1, \vec{x}_2) = f_i(\vec{x}_1) - f_i(\vec{x}_2) + \sum_{j \neq i}^k \alpha_{ij} (f_j(\vec{x}_1) - f_j(\vec{x}_2))$$

其中, $\vec{x}_1, \vec{x}_2 \in X$ 。

定义 1^[12] 当 $\forall i, g_i(\vec{x}_1, \vec{x}_2) \leq 0$, 并且 $\exists i$, 使得 $g_i(\vec{x}_1, \vec{x}_2) < 0$, 此时就称 \vec{x}_1 解 α 支配 \vec{x}_2 (记为 $\vec{x}_1 \overset{\alpha}{<} \vec{x}_2$)。当 $\alpha_{ij} \equiv 0$ 时,即为标准的 Pareto 支配。当 \vec{x}_1 解的一个目标分量稍微差于 \vec{x}_2 对应的目标分量,但其他分量明显优于 \vec{x}_2 解时, α 支配允许 \vec{x}_1 解支配 \vec{x}_2 解。

定义 2^[12] $\vec{x} \in X$ 为 α -Pareto 最优集 $\Leftrightarrow \{y \in X | y \overset{\alpha}{<} x\} = \emptyset$ 。

关于上述的概念,有以下两个推论。

推论 1 假设 $\vec{x}_1 \overset{\alpha}{<} \vec{x}_2 \Rightarrow \vec{x}_1 \overset{\alpha}{<} \vec{x}_2$ 。

推论 2 α -Pareto 最优集 $X^\alpha = \{x \in X | x \text{ is } \alpha\text{-Pareto optimal}\}$ 为最优解集的子集。

使用 α 支配替换 Pareto 支配有两个优点。在多目标优化算法中使用 α 支配定义,DRSs 中较差的解将被舍弃,极大地缩短了该类解的生存周期。其次,可以为决策者提供更好的候选解。

2.3 NSGA-II 框架

NSGA-II 的框架如图 1 所示。

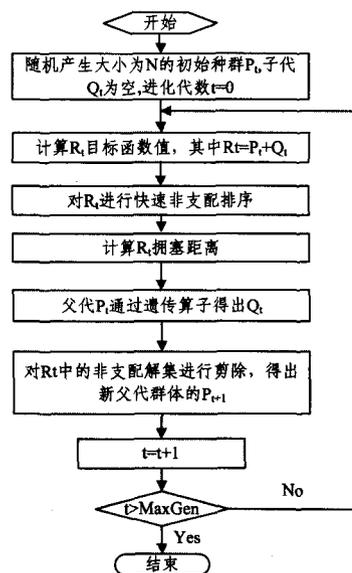


图 1

2.4 α 支配与 NSGA-II 算法相结合

此处仅做简单的结合,在非支配排序时,使用 α 支配替换 NSGA-II 中的 Pareto 支配,将其结合的算法记为 alpha-NSGA-II。其他部分保持不变。

2.5 性能评价指标

多目标算法求解目标时快速找到逼近真实 Pareto 前沿且在其上分布均匀的解集,因此评价一个多目标进化算法的性能可以从两个方面考虑^[13]:1)收敛性,评价所求 Pareto 最优解集与真实 Pareto 前沿的趋近程度;2)分布性,评价所求 Pareto 最优解集在目标空间的分布是否均匀、多样。

Zitzler 等人^[14]对多目标优化评估指标进行分类研究。下面列举 4 个目前常用的评估指标,分别为 Generational Distance(GD) 指标^[15]、Inverted Generational Distance(IGD) 指标^[16]、Spacing(SP) 指标^[17]、Highpervolume(HV) 指标^[17]。为节省篇幅,仅对以上 4 个指标作简要介绍,具体定义参考上述相关文献。GD 指标代表算法求得近似 Pareto 前沿和理想 Pareto 前沿之间的距离,该指标越低,表明算法所得解的收敛性越好。IGD 指标在一定程度上能同时反映出所求近似 Pareto 前沿的多样性和评估算法所求近似 Pareto 解在目标空间上的均匀性。如果该指标值为 0,表明所求解在目标空间上是等距分布的。HV 指标能直接精确地反映出解集的整体质量。

2.6 不同 α 值的效果

为研究在多目标进化算法中引入 α 支配后求出的近似 Pareto 解集的质量,本文选择不同的 alpha 值来测试高维目标问题的影响以及求得的近似 Pareto 最优解集的收敛性与多样性。本次实验方案为: α 取值范围为 0~0.3,间隔为 0.02,测试问题为 DTLZ1 ($g(x)$ 为 1),DTLZ2,DTLZ3,DTLZ4,目标维度为 3,变量个数与文献[11]保持一致。相关参数设置:种群数目为 100,杂交方式为二进制交叉,概率为 1,位置为 20;变异方式为多项式变异,概率为变量个数的例数,位置为 20。每个 α 独立运行 30 次,求出每组解的 IGD 指标值及 30 个指标值的均值,所得结果如下图所示。图 2—图 5 依次为 30 次测试过程中 DTLZ1,DTLZ2,DTLZ3,DTLZ4 函数的 IGD 均值随着 α 值在 0~0.3 的变化曲线图。纵坐标为 IGD 均值,横坐标为 α 值。从图 2—图 5 可以看出以下几点:1)增大 α 值,IGD 均值先变小后变大,一定程度上能够提高算法的性能;2)以上 4 个测试函数所得结果显示,存在某一个 α 使得 IGD 均值最小;3)在一定范围内增大 α 值,求得的解的 IGD 均值比原始 Pareto 支配(即 α 值为 0 时)求出的 IGD 均值小;4)对于 DTLZ1,可以看出,随着 α 值的增大,求出的解的 IGD 均值整体上呈现下降趋势,但偶尔出现回升现象,尽管如此,一定范围内增大 α 值,可以很明显地降低 IGD 指标值,获得更好的解。

从实验过程中发现,不同的 α 值对解集的收敛性和多样性有着不同的影响。为此,给出在 DTLZ2 和 DTLZ4 测试问题上不同 α 值对应的 GD 指标和 Spacing 指标值的变化曲线图(见图 6—图 9)。图 6 和图 7 分别为 DTLZ2 和 DTLZ4 的 GD 均值随着 α 值的变化曲线图,图 8 和图 9 分别为 DTLZ2

和 DTLZ4 的 SP 均值随着 α 值的变化曲线图。从图 6 和图 7 可以看出,一定范围内,若增大 α 值,GD 均值将显著减小,这表明求出的解集的收敛性更好。从图 8 和图 9 看出,当增大 α 值时,Spacing 均值将增大,这表明增大 α 值在一定程度上会导致解集多样性变差。因此,需要在引入适当的 α 值时尽可能地维持解集的多样性,才能提高算法整的体性能,以保证最终求出的解集的质量。

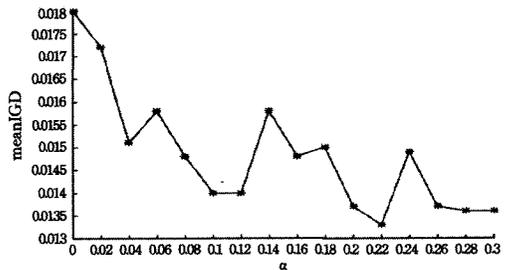


图 2 DTLZ1-3 的 IGD 变化图

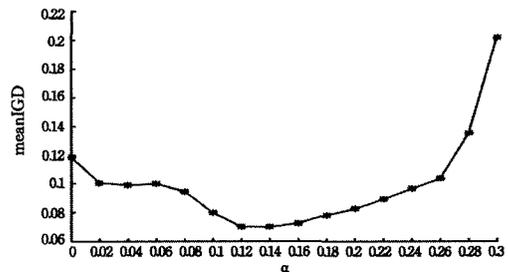


图 3 DTLZ2-3 的 IGD 变化图

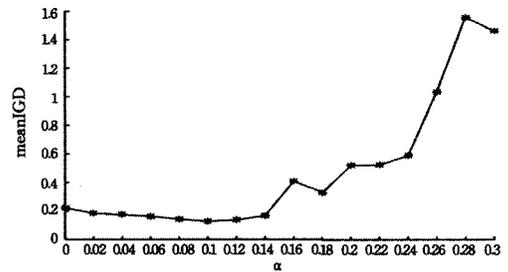


图 4 DTLZ3-3 的 IGD 变化图

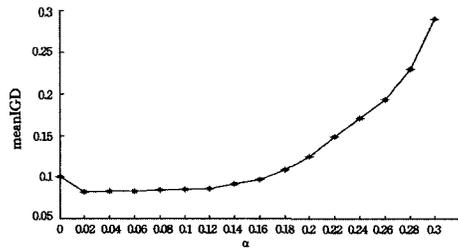


图 5 DTLZ4-3 的 IGD 变化图

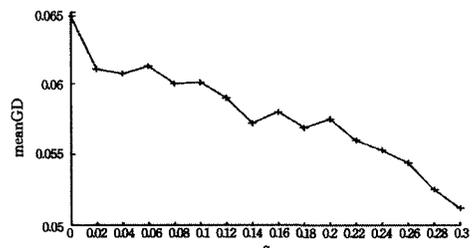


图 6 DTLZ2-3 的 GD 变化图

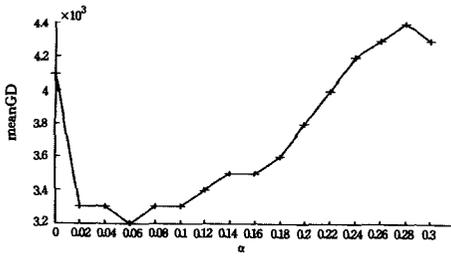


图 7 DTLZ4-3 的 GD 变化图

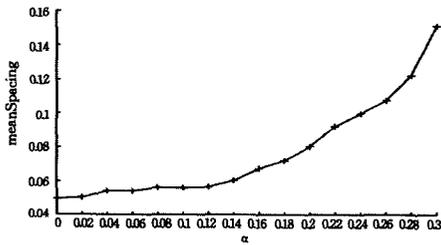


图 8 DTLZ2-3 的 SP 变化图

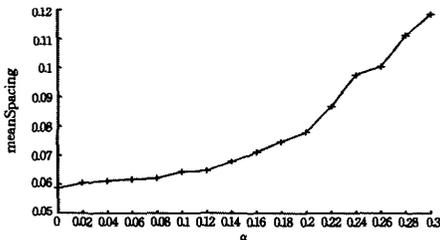


图 9 DTLZ4-3 的 SP 变化图

3 α 偏序和拥塞距离抽样

基于以上分析,增大 α 值,为保持解集良好的收敛性的同时维持解集相对较好的分布性,提出基于 α 偏序和拥塞距离抽样的改进方案,即当种群通过 2.3 节中的快速非支配排序后,为其增加一个 α 偏序,对基于 Pareto 快速非支配排序产生的每一层进行重新分层, α 偏序中采用 α 支配替换原始的定义。图 10 是 α 偏序流程图。当解集通过快速非支配排序后,产生的每一层将分别根据 α 偏序进行重新分层。以第一层为例来分析偏序分层原理。图 11 中,方框表示经过快速非支配排序后得出的 $Front=1$ 解集,重新分层的思想在于从第一层中挑选拥塞距离最大的部分解与边界点(如最上面、最下面的空心圆圈的点)放入新的第一层中,而未被选中的解自动放入 α 支配集中,与原始快速非支配排序产生的 $Front=2$ 解构成一个完整第二层解,同时采取相同的做法对这个完整的第二层解进行重新分层。挑选解的原则有以下两点:1)每层中,每一个目标维度上的最大值点将被保留下来(称为边界点);2)每层中,拥塞距离最大的部分解将被保留,剩下的解自动放入 α 支配集。依次循环,每一层的点将被分成两部分,一部分为拥塞距离抽样出的点与前沿的边界点,另一部分为拥塞距离相对较小的点,将第一部分放入新的第一层(如图 11 中的空心圆圈选中的点)中,而第二部分放入原始的第二层中,构成新的第二层(图中未被空心圆圈选中的点以及原始第二层中三角形点),并参与循环。最终可以得到基于 α 偏序的新层级结构,并用其替换原始的基于 Pareto 支配的快速非支配排序产生的层级结构,其他都保持不变。通过以上做法,尽可能地保留每一层中的前沿的极值点与分布相对均匀的点,并将分布较为密集的点转入下一层。相对好的解将获得更低

的层级序号,分布性相对较好的解集也可获得更低的层级序号,因此在种群进化时,这些被挑选出的解有更多的几率被选中作为候选解,促进种群进化,提高解集的收敛性的同时保持解集的相对均匀性。

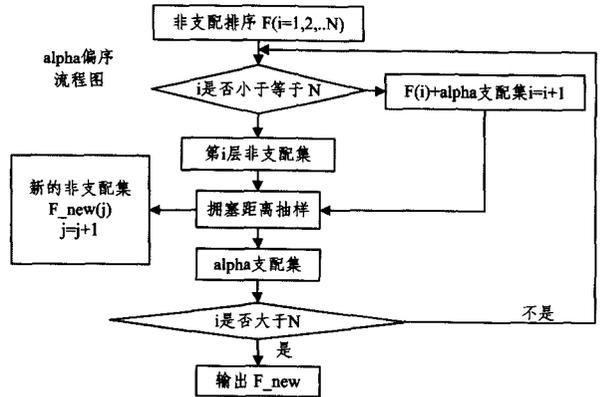


图 10 α 偏序流程图

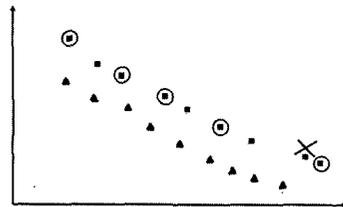


图 11 重新分层示意图

4 仿真实验

4.1 算法的整体性能分析

为验证上述提出的基于 α 偏序和拥塞距离抽样的算法与 NSGAII 算法相结合的效果,本文将在 DTLZ1, DTLZ2, DTLZ3, DTLZ4 的 3~5 维目标上进行算法性能测试。相关的参数设置如下:种群大小为 100;杂交参数与文献[11]中一致;本文算法特有参数设置为在 DTLZ1 中 $\alpha=0.26$;在 DTLZ2 中 $\alpha=0.14$;在 DTLZ3 中 $\alpha=0.01$;在 DTLZ4 中 $\alpha=0.02$;对于 4 维测试问题,算法一次运行迭代次数为 2500,5 维测试问题则为 3000;其他参数保持不变。求出每种算法在每个测试问题上独立运行 20 次的 HV 指标的最大值及均值。选择的对比算法依次为原始的 NSGA-II 算法、MOEA/D 算法、MOEA/D-DU 以及结合 α 偏序和拥塞距离抽样后的改进的 NSGA-II 算法。为叙述简便,将以上 3 种算法依次记作 NSGA-II, MOEA/D, MOEA/D-DU, NSGA-II-c。其中 DTLZn_m 含的义为第 n 个测试问题,其维度为 m 个。

分析表 1 中的数据可得出如下几点结论:1)由表 1 的第 2 列和第 3 列可知,在 DTLZ2, DTLZ3 及 DTLZ4 三维以上的测试问题上,NSGA-II 算法求出的解集的 HV 指标的均值及最大值均比 MOEA/D 算法求出的解集的对应该指标值大,原因在于对于高维测试问题,MOEA/D 算法生成的权重向量在目标空间中分布得不均匀,导致算法求出的解集的整体质量偏低;2)由表 1 的第 2-4 列可知,MOEA/D-DU 算法求出的解集的整体质量比 NSGA-II 和 MOEA/D 算法求出解集的整体质量高,表明在 MOEA/D 算法中引入基于解与方向向量的距离保留解的策略更适合求解高维测试问题,该策略可弥补原始的 MOEA/D 算法求解高维测试问题时的不足;3)观察表 1 的第 2-5 列可知,在以上几个测试问题中,本文提出

的算法求出的解集的整体质量相比前面的3个算法求出的解集的整体质量更高,证实了引入 α 支配去除难支配解的优势,同时结合偏序和拥塞距离抽样策略能尽可能提高解集的整体

质量。为直观分析以上4种算法在几种测试问题上的整体性能,给出4种算法在每个测试问题上的HV指标的盒须图,其直观反映出了以上4种算法的结论,如图12—图15所示。

表1 4种算法在DTLZ1-4测试问题上的HV指标值

Problems	NSGA-II	MOEA/D	MOEA/D-DU	NSGA-II-c
	HVmean(max)	HVmean(max)	HVmean(max)	HVmean(max)
DTLZ1_3	0.7398(0.7851)	0.8316(0.8619)	0.8714(0.8876)	0.9002(0.9236)
DTLZ1_4	0.7713(0.8070)	0.8327(0.8642)	0.9344(0.9409)	0.9466(0.9510)
DTLZ1_5	0.7711(0.8600)	0.8961(0.9375)	0.9933(0.9970)	0.9978(0.9984)
DTLZ2_3	0.5086(0.5704)	0.5225(0.5326)	0.5506(0.5554)	0.5602(0.5667)
DTLZ2_4	0.6276(0.6960)	0.6011(0.6095)	0.8669(0.9487)	0.8759(0.8926)
DTLZ2_5	0.8058(0.8589)	0.7057(0.7128)	0.9463(0.9581)	0.9638(0.9678)
DTLZ3_3	0.6285(0.8375)	0.8482(0.9799)	0.9130(0.9412)	0.9489(0.9554)
DTLZ3_4	0.8417(0.9481)	0.7992(0.9370)	0.9849(0.9981)	0.9994(0.9998)
DTLZ3_5	0.9306(0.9871)	0.7574(0.8747)	0.9999(1.0000)	1.0000(1.0000)
DTLZ4_3	0.4740(0.6133)	0.4803(0.5310)	0.5509(0.5551)	0.5944(0.6960)
DTLZ4_4	0.6965(0.8062)	0.5822(0.6183)	0.6812(0.6902)	0.8299(0.8854)
DTLZ4_5	0.8861(0.9454)	0.6418(0.7070)	0.8575(0.9186)	0.9327(0.9519)

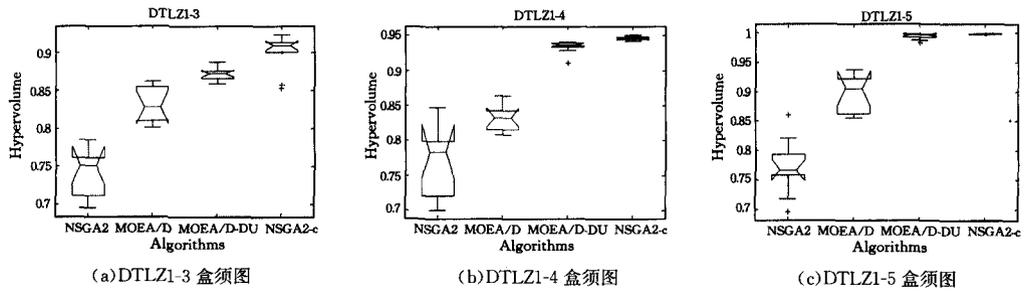


图12

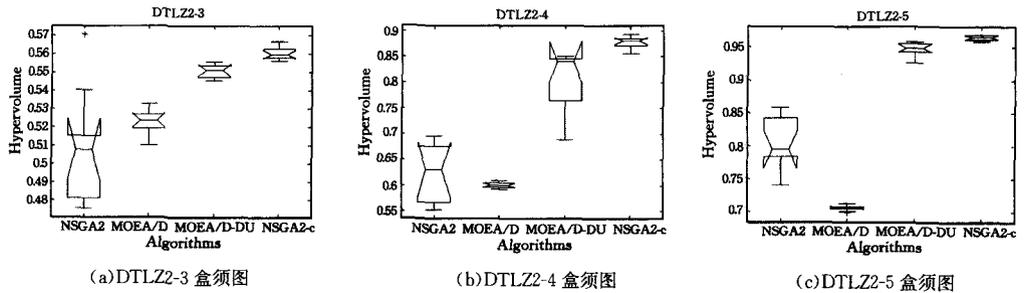


图13

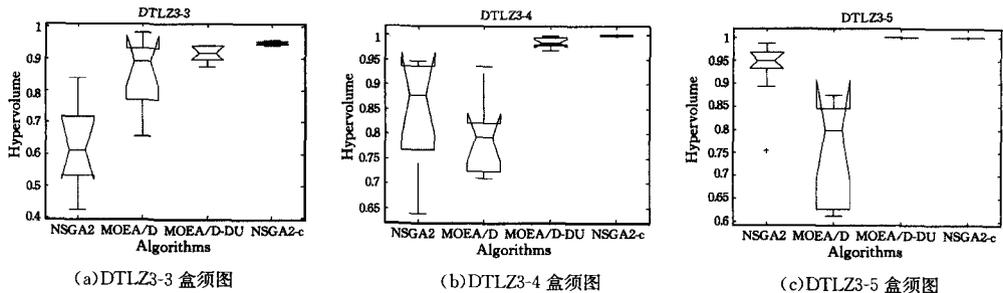


图14

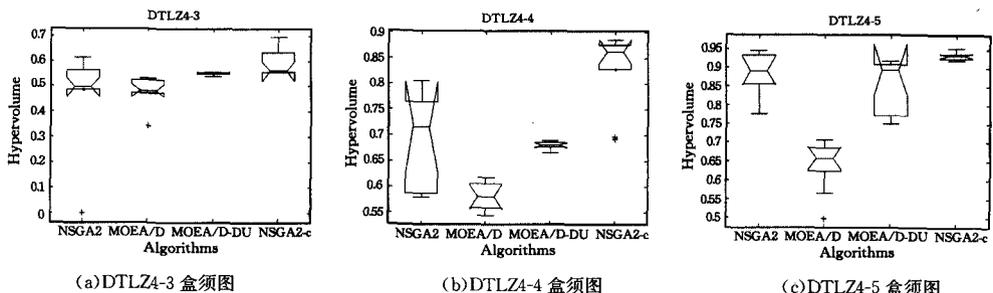


图15

表 2 3 种算法在 DTLZ2_3 和 DTLZ4_3 问题上 IGD,GD,SP 均值

	算法	α	meanIGD	meanGD	meanSP
DTLZ2_3	NSGA-II-a	0	0.1184	0.0647	0.0594
	NSGA-II-b	0.14	0.0698	0.0572	0.0605
	NSGA-II-c	0.14	0.0616	0.0560	0.059
DTLZ4_3	NSGA-II-a	0	0.1011	0.0041	0.0586
	NSGA-II-b	0.02	0.0819	0.0033	0.0605
	NSGA-II-c	0.02	0.0787	0.0031	0.0589

观察表 2 中的最后一列可以看出,NSGA-II-b 算法求出的解集的 S 均值比原始算法求出的解集的 SP 均值大,这表明单纯引入 α 支配后,当增大 α 值时,尽管能够提高算法的整体性能,但会导致求出的解的多样性变差,即 SP 指标值会增大。观察 NSGA-II-c 算法求出的解集的 3 项指标值与 NSGA-II-a 算法求出的解集的 3 项指标值可以看出,引入 α 偏序和拥塞距离抽样后,增大 α 值,能在提高算法收敛性的同时尽可能维持解集相对较优的多样性,进一步提高解集的整体性能。

4.2 算法的收敛性分析

为进一步探究采用 α 偏序和拥塞距离抽样通过排除非支配解中 DRSs 解,提高种群收敛的速度,在 DTLZ 测试函数的 3 维目标问题上做如下实验:每隔 100 代记录算法求出的非支配解集,并求出非支配解集的 GD 指标值,画出 NSGA-II 算法(即 a 算法)和 NSGA-II-c 算法(加入 α 偏序和拥塞距离抽样两种方式,即 c 算法)随着种群进化的 GD 指标值的变化情况。

图 16—图 19 依次为 NSGA-II-a 和 NSGA-II-c 两种算法在 DTLZ1,DTLZ2,DTLZ4,DTLZ5 的 3 维目标问题上,GD 指标值随着种群迭代次数的变化曲线图,其中横坐标为种群的迭代次数,每隔 100 代记录一次。可以看出,对于 4 个测试问题,最终 α 偏序和拥塞距离抽样求出的解集的 GD 指标值都比原始的 NSGA2 算法的指标值低,除 DTLZ5 测试问题,基本上加入 α 偏序和拥塞距离抽样后,算法求出的 GD 指标值一直比 NSGA2 算法求出的指标值低,再次验证了引入 α 支配,通过排除非支配解中的 DRSs 解可以为种群找出更为合适的候选解,进而促进种群的进化。观察图 16、图 17、图 19 中的前几代的变化曲线图可以看出,带星号线条下降的速率快于带圆圈线条,说明引入 α 支配后,在种群进化的初期阶段,对促进种群的收敛有着显著的效果。在图 19 中,对于 DTLZ5_3 测试问题,随着种群的进化,NSGA-II-c 算法求出的解集的 GD 指标值虽然在部分地方高于 NSGA-II 原始算法,但最终得出的 GD 指标值相对较小。以上 4 幅图表明,引入 α 支配,结合提出的两种策略,通过排除非支配解集难以排除的解,能促进种群的进化,提高算法所求解集的收敛性。

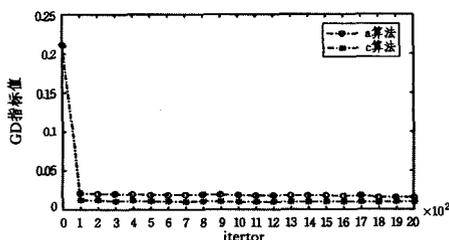


图 16 DTLZ1_3 中 GD 随着迭代次数的变化图

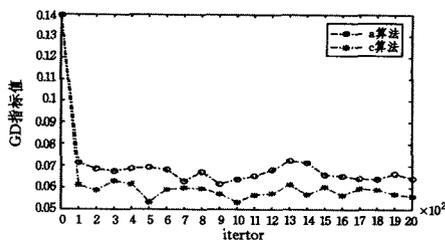


图 17 DTLZ2_3 中 GD 变化图

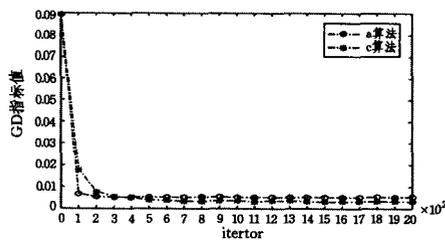


图 18 DTLZ4_3 中 GD 变化图

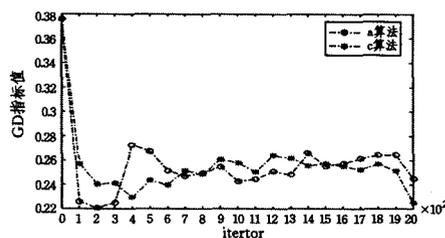


图 19 DTLZ5_3 中 GD 变化图

结束语 首先简要介绍高维目标问题中“DRSs”解存在的现象,并通过一个实例示意 DRSs 解的含义,最终结合 DRSs 含义对基于 Pareto 支配算法中非支配解难于剪除的原因做出解释。为解决上述问题,提出一种新的基于 α 支配的高维目标优化算法,通过引入 α 支配,探讨不同 α 值对算法性能的影响。进一步地,为提高引入 α 支配后维持多样性较好的解集的性能,提出基于 α 偏序和拥塞距离抽样两种方式来维持解集分布性。在仿真试验中,在 DTLZ 系列问题上对算法进行性能分析与测试,并与原始的 NSGA-II, MOEA/D 及 MOEA/D-DU 算法进行性能对比。实验结果表明,改进的基于 α 偏序的高维目标优化算法求解高维问题时,可以很好地去除绝大部分的 DRSs 解,在维持解多样性相对较好的情况下极大地提高了解的收敛性。并且,改进的算法比单纯引入 α 支配取得的效果更优,同时本文首次将 α 支配引入到多目标进化算法中,实验验证了该支配的有效性。在未来的研究中,将研究增大 α 值,通过更为先进的多样性维持策略,在提高解集的收敛性的同时维持解集相对较好的多样性,甚至提高解集多样性,从而提高解集的整体性能。

参考文献

[1] CHENG R, JIN Y, OLHOFER M, et al. A Reference Vector Guided Evolutionary Algorithm for Many-Objective Optimization[J]. IEEE Transactions on Evolutionary Computation, 2016.

[2] HOU Wei, DONG Hong-bin, YIN Gui-sheng. Enhanced Multi-objective Evolutionary Algorithm Based on Decomposition[J]. Computer Science, 2014, 41(2): 114-118. (in Chinese)

侯薇,董红斌,印桂生.一种改进的基于分解的多目标进化算法

- [J]. 计算机科学, 2014, 41(2): 114-118.
- [3] ISHIBUCHI H, TSUKAMOTO N, HITOTSUYANAGI Y, et al. Effectiveness of scalability improvement attempts on the performance of NSGA-II for many-objective problems[C]// Congerence on Genetic and Evolutionary Computation. 2008: 649-656.
- [4] KOPPEN M, YOSHIDA K. Substitute distance assignments in NSGA-II for handling Many-objective optimization problems[C]// Evolutionary Multi-Criterion Optimization. 2007: 727-741.
- [5] CORNE D, KNOWLES J. Techniques for highly multiobjective optimization; Some nondominated points are better than others [C]// Conference on Genetic and Evolutionary Computation. 2007: 773-780.
- [6] KUKKONEN S, LAMPINEN J. Ranking-dominance and many-objective optimization [C]// IEEE Congress on Evolutionary Computation. 2007: 3983-3990.
- [7] SATO H, AGUIRRE H, TANAKA K. Controlling dominance area of solutions and its impact on the performance of MOEAs [C]// Evolutionary Multi-Criterion Optimization. 2007: 5-20.
- [8] ZITZLER E, KÜNZLI S. Indicator-based selection in multiobjective search[C]// Parallel Problem Solving from Nature-PPSN VIII. Springer Berlin Heidelberg, 2004: 832-842.
- [9] BADER J, ZITZLER E. HypE: An algorithm for fast hypervolume-based many-objective optimization[J]. Evolutionary computation, 2011, 19(1): 45-76.
- [10] ZHANG Q, LI H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition[J]. IEEE Transactions on Evolutionary Computation, 2007, 11(6): 712-731.
- [11] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: Solving problems with box constraints[J]. IEEE Transactions on Evolutionary Computation, 2014, 18(4): 577-601.
- [12] IKEDA K, KITA H, KOBAYASHI S. Failure of Pareto-based MOEAs; does non-dominated really mean near to optimal?[C]// Proceedings of the 2001 Congress on Evolutionary Computation, 2001. IEEE, 2001, 2: 957-962.
- [13] 谭艳艳. 几种改进的分解类多目标进化算法及其应用[D]. 西安: 西安电子科技大学, 2013.
- [14] ZITZLER E, THIELE L, LAUMANN S, et al. Performance assessment of multiobjective optimizers; an analysis and review [J]. IEEE Transactions on Evolutionary Computation, 2003, 7(2): 117-132.
- [15] WANG Z, ZHANG Q, ZHOU A, et al. Adaptive Replacement Strategies for MOEA/D[J]. IEEE Transactions on Cybernetics, 2015(1): 1-13.
- [16] GONG Dun-wei, LIU Yi-ping, SUN Xiao-yan, et al. Parallel Many-objective Evolutionary Optimization Using Objectives Decomposition[J]. Acta Automatica Sinica, 2015, 41(8): 1438-1451. (in Chinese)
巩敦卫, 刘益萍, 孙晓燕, 等. 基于目标分解的高维多目标并行进化优化方法[J]. 自动化学报, 2015, 41(8): 1438-1451.
- [17] ZHANG Yi, WAN Xing-yu, ZHENG Xiao-dong, et al. Cellular Genetic Algorithm for Multiobjective Optimization Based on Orthogonal Design[J]. Acta Electronica Sinica, 2016, 44(1): 87-94. (in Chinese)
张屹, 万兴余, 郑小东, 等. 基于正交设计的元胞多目标遗传算法[J]. 电子学报, 2016, 44(1): 87-94.

(上接第 242 页)

- [13] AMIR E, ENGELHARDT B. Factored planning [C]// Proceedings of the 18th International Joint Conference on Artificial Intelligence, 2003. San Francisco: Morgan Kaufmann, 2003: 929-935.
- [14] KELAREVA E, BUFFET O, HUANG J B, et al. Factored planning using decomposition trees[C]// Proceedings of the 20th International Joint Conference on Artificial Intelligence, 2007. Amsterdam: Elsevier Science, 2007: 1942-1947.
- [15] CHEN Yi-xin, YAO Guo-hui. Completeness and Optimality Preserving Reduction for Planning[C]// Proceedings of the 21st International Joint Conference on Artificial Intelligence, 2009. Amsterdam: Elsevier Science, 2009: 1659-1664.
- [16] CHEN Yi-xin, XU You, YAO Guo-hui. Stratified Planning [C]// Proceedings of the 21st International Joint Conference on Artificial Intelligence, 2009. Amsterdam: Elsevier Science, 2009: 1665-1670.
- [17] CHEN Y X, WAH B W, HSU C W. Temporal planning using subgoal partitioning and resolution in SGPlan[J]. Journal of Artificial Intelligence Research, 2006, 26: 323-369.
- [18] WAH B W, CHEN Y X. Constraint Partitioning in Penalty Formulations for Solving Temporal Planning Problems[J]. Artificial Intelligence, 2006, 170(3): 187-231.
- [19] CROSBY M, ROVATSOS M, PETRICK R P A. Automated Agent Decomposition for Classical Planning [C]// The Proceedings of the 23rd International Conference on Autonomous Planning and Scheduling, 2013. Menlo Park, Calif. AAAI Press 2013: 46-54.
- [20] ASAI M, FUKUNAGA A. Solving Large-Scale Planning Problems by Decomposition and Macro Generation[C]// The proceedings of the 25th International Conference on Autonomous Planning and Scheduling, 2015. Menlo Park, Calif. AAAI Press 2015: 16-24.
- [21] WU Xiang-jun, JIANG Yun-fei, LING Ying-biao. Research and development of StepByStep planner[J]. Journal of Software, 2008, 19(9): 2243-2264. (in Chinese)
吴向军, 姜云飞, 凌应标. 智能规划器 StepByStep 的研究和开发[J]. 软件学报, 2008, 19(9): 2243-2264.
- [22] WU Xiang-jun, BIAN Rui, LING Ying-biao, et al. Research on Decomposition Strategy for Knowledge Tree of Characteristic Predicate[J]. Journal of Computer Research and Development, 2011, 48(2): 186-194. (in Chinese)
吴向军, 边芮, 凌应标, 等. 特征谓词知识树分解策略的研究[J]. 计算机研究与发展, 2011, 48(2): 186-194.