

基于改进 K 支配排序的高维多目标进化算法

肖 婧^{1a,2}, 王科俊^{1a}, 毕晓君^{1b}

(1. 哈尔滨工程大学 a. 自动化学院, b. 信息与通信工程学院, 哈尔滨 150001;

2. 辽宁省交通高等专科学校 信息工程系, 沈阳 110122)

摘要: 为提高4目标以上高维多目标优化问题的求解性能, 提出一种基于改进 K 支配排序的高维多目标进化算法(KS-MODE). 该算法针对 K 支配的支配关系和排序方法进行改进, 避免循环支配并增强选择压力; 设计新的全局密度估计方法提高局部密度估计精确性; 设计新的精英选择策略和适应度值评价函数; 采用CAO局部搜索算子加速收敛. 在4~30个目标标准测试函数上的实验结果表明, KS-MODE能够在保证解集分布性的同时大幅提升收敛性和稳定性, 能够有效求解高维多目标优化问题.

关键词: 高维多目标优化; 多目标进化算法; K 支配; 全局密度估计; 精英选择

中图分类号: TP301.6

文献标志码: A

Multi-objective evolutionary algorithm based on improved K -dominated sorting

XIAO Jing^{1a,2}, WANG Ke-jun^{1a}, BI Xiao-jun^{1b}

(1a. College of Automation, 1b. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China; 2. Department of Information Engineering, Liaoning Provincial College of Communication, Shenyang 110122, China. Correspondent: BI Xiao-jun, E-mail: bixiaojun@hrbeu.edu.cn)

Abstract: To improve the convergence performance in dealing with multi-objective optimization problems(MOPs), a multi-objective evolutionary algorithm(MOEA) based on improved K -dominated sorting(KS-MODE) is proposed. KS-MODE improves K -dominance to avoid the circular dominance and to enhance the selection pressure. The new global density estimation method, the elitist selection strategy and fitness evaluation function are also designed. In addition, the CAO operator is adopted to accelerate convergence. Simulation results on MOPs with 4-30 objectives show that, KS-MODE significantly outperforms several state-of-the-art MOEAs in terms of convergence, distribution and stability.

Key words: multi-objective optimization; multi-objective evolutionary algorithms; K -dominance; global density estimation; elitist selection

0 引言

目标函数超过4个并且需要同时处理的多目标优化问题称为高维多目标优化问题(MOPs)^[1-4]. 高维多目标优化中多个目标之间往往相互冲突, 且高维的特性使得决策空间及目标空间中的计算复杂度和搜索难度急剧增加, 从而使得MOPs成为国内外智能优化领域最难解决的问题之一^[1-4]. 目前, 解决MOPs性能的最优方法为多目标进化算法(MOEA). 最具代表性且应用范围最广的MOEA主要是以精英选择为特征的第2代多目标进化算法, 包括NSGA-II^[5]、

SPEA2^[6]、MOPSO^[7]、DEMO^[8]等. 然而, 大量实践研究表明, 现有基于Pareto支配(PD)的MOEA在求解4目标及以上MOPs时其性能通常会急剧恶化而导致求解失败, 主要原因在于目标维数的增加使MOEA种群中非支配解个体的数量指数上升, 大大削弱了MOEA的选择压力和收敛能力, 使进化搜索过程停滞或表现出随机搜索的特点^[3-4]. 此外, 高维多目标计算复杂度的急剧提升也使得MOEA的解集多样性和计算速度大幅降低.

国内外现有针对高维多目标优化的MOEA技

收稿日期: 2013-08-04; 修回日期: 2013-11-18.

基金项目: 国家自然科学基金项目(61175126); 黑龙江省博士后基金项目(LBH-Z12073); 辽宁省博士科研启动基金项目(201205118); 辽宁省教育厅科学技术研究一般项目(L2012458).

作者简介: 肖婧(1985-), 女, 讲师, 博士, 从事智能信息处理的研究; 王科俊(1962-), 男, 教授, 博士生导师, 从事模式识别、智能系统等研究.

术改进方法主要分为 4 类, 即权重系数法^[12], 降维法^[13], K 支配^[14]、 ε 支配^[15]、 E 支配^[16]、模糊支配^[17] 等宽松支配法, 平均等级 (AR)^[18]、关系偏好 (RF)^[19]、偏好顺序 (PO)^[20] 等非 Pareto 支配排序法. 然而, 上述改进方法仍存在一定缺陷, 权重系数法会导致算法寻优解集偏离真正 Pareto 前沿, 在求解准确性上存在缺陷; 降维法通常会造成本目标信息丢失, 是最小允许误差下的优化, 只适用于能够预知目标主次的问题; 非 Pareto 支配排序法获得的最优解集通常集中于 Pareto 前沿某一区域内, 无法为决策者提供多样性的决策支持.

为进一步提高现有 MOEAs 在高维多目标情况下的求解性能, 本文通过深入研究提出一种基于改进 K 支配的高维多目标差分进化算法 (KS-MODE). 该算法与 6 种国内外先进 MOEAs 在 4~30 维目标的标准测试函数上的对比实验结果表明, KS-MODE 在保证解集分布性的同时能够大幅提升 MOEAs 的收敛性和稳定性, 尤其适合于高维复杂多目标优化问题的求解.

1 基于改进 K 支配排序的高维多目标进化算法 KS-MODE

不失一般性, 一个具有 n 维决策变量和 m 维目标函数的 MOPs 可表述为如下形式 (以最小化为例):

$$\begin{aligned} \min y &= F(x) = (f_1(x), f_2(x), \dots, f_m(x)); \\ x &= (x_1, x_2, \dots, x_n) \in X \subset R^n, \\ y &= (y_1, y_2, \dots, y_m) \in Y \subset R^m. \end{aligned} \quad (1)$$

其中: x 为决策变量, X 为 n 维决策空间; y 为目标函数, Y 为 m 维目标空间; m 为目标数, $m \geq 4$. 式 (1) 的求解目标为搜索种群中所有非支配解构成的 Pareto 最优解集, 在目标空间中构成 Pareto 最优前沿.

国内外高维多目标优化技术的研究内容主要包括进化策略和高维 MOEAs 模型框架, 其中进化策略主要包括遗传算法^[5-6]、粒子群优化算法^[7]、差分进化算法^[8]、和声搜索 (HS)^[9] 及人工蜂群算法 (ABC)^[10] 等, 但前期实验研究表明, 进化策略性能的提升对于改善高维 MOEAs 的整体性能效果并不显著, 因此应重点研究高维 MOEAs 模型框架. 本文算法 KS-MODE 采用 DE/rand/2 作为进化策略, 选用目前高维 MOEAs 主流的基于 Pareto 支配的以精英保留机制为特征的第二代 MOEAs 模型框架, 通过改善精英选择策略 (涵盖支配排序方法和密度估计方法) 提升算法整体性能.

1.1 K 支配改进

K 支配是一种典型宽松支配法, 通过放宽 Pareto 支配条件来增加非支配个体数目, 从而增强选择压力^[14]. K 支配的定义如下.

定义 1 (K 支配) 任意取决策空间中的两个个体 $x_1, x_2 \in R^n$, 在 m 维目标空间中对应的适应度值分别为 $F(x_1)$ 和 $F(x_2)$, $F(x) = \{f_1(x), f_2(x), \dots, f_m(x)\}$. $B_t(x_1, x_2)$ 表示 m 维目标中 $F(x_1)$ 比 $F(x_2)$ 表现好的目标个数; $E_q(x_1, x_2)$ 表示 $F(x_1)$ 与 $F(x_2)$ 表现相同的目标个数; $W_s(x_1, x_2)$ 表示 $F(x_1)$ 比 $F(x_2)$ 表现差的目标个数. 以目标值最小化为例, 计算公式如下:

$$\begin{cases} B_t(x_1, x_2) = \text{card}\{i : f_i(x_1) < f_i(x_2)\}, \\ E_q(x_1, x_2) = \text{card}\{i : f_i(x_1) = f_i(x_2)\}, \\ W_s(x_1, x_2) = \text{card}\{i : f_i(x_1) > f_i(x_2)\}, \\ B_t + E_q + W_s = m. \end{cases} \quad (2)$$

其中: card 表示集合的规模, $i = 1, 2, \dots, m$. 当满足如下条件时:

$$\begin{cases} E_q(x_1, x_2) < m, \\ B_t(x_1, x_2) \geq \frac{m - E_q(x_1, x_2)}{K + 1}, 0 \leq K \leq 1, \end{cases} \quad (3)$$

称 x_1 K 支配 x_2 , 记为 $x_1 \succ_K x_2$.

1.1.1 K 支配关系改进及参数确定

K 支配使得个体间的支配关系不再受到目标函数数量纲和数值差异大小的影响, 并使支配关系的复杂程度不受目标数量的影响. 然而, K 支配策略仅考虑了多目标优化中目标函数的数目, 而没有考虑各目标函数上具体目标值, 这一缺陷可能导致种群中的个体陷入循环支配, 使种群中不存在非支配解, 从而导致无法确定最优解集. 为解决 K 支配中循环支配问题, 本文参考 L 支配^[4] 方法为种群中每个个体设置一个能量函数 $G(x)$, 作为个体目标函数值大小的衡量标准, 计算公式为

$$G(x) = \left(\sum_{i=1}^M (f_i(x)^p) \right)^{1/p}. \quad (4)$$

对于个体 x_1 和 x_2 只有同时满足式 (3) 和 (4) 时才可称 x_1 K 支配 x_2 . 其中参数 p 通常取 $\{1, 2, \infty\}$, 本文取值为 2. $G(x)$ 是一个具有传递性的标量值, 若满足 $G(x_1) < G(x_2)$ 且 $G(x_2) < G(x_3)$, 则一定可得到 $G(x_1) < G(x_3)$, 由此可避免循环支配的现象.

改进后 K 支配中参数 K 的取值对于支配关系是否成立具有重要影响, 对于任意个体 x_1 和 x_2 , 参数 K 取值范围为 $[0, 1]$, 当 $K = 0$ 时, 满足 K 支配条件等价于 $W_s = 0$, 此时 K 支配即为 Pareto 支配; 当 $K = 1$ 时, 满足 K 支配条件等价于 $B_t \geq W_s$ 且 $G(x_1) < G(x_2)$, 只需 x_1 相比于 x_2 , M 维目标中性能改进目标数大于性能退步目标数, 即可认定 K 支配关系成立. 因此, 改进后的 K 支配是宽松的 Pareto 支配, 参数 K 取值越大, 宽松程度越大. 为加强高维环境下算法的选择压力, 本文中参数 K 取值范围为 $[0.5, 1]$.

1.1.2 K 支配等级排序方法改进

为进一步加强改进后 K 支配的收敛性能, 采用一种新的非支配等级排序方法, 将个体受支配个体数目作为非支配等级, 个体 x_i 非支配等级 KS 的计算公式如下:

$$KS(x_i) = |\Omega_i|, 1 \leq i \leq NP. \quad (5)$$

其中: $\Omega_i = \{x_j | x_j \succ_K x_i, 1 \leq j \leq NP, j \neq i\}$, NP 为种群规模. 受支配个体数目为 0 的个体即非支配个体, 具有最小的排序等级, 受支配个体数目越多的个体其排序等级越高.

为证明改进后 K 支配排序的有效性和先进性, 实验统计改进后 K 支配与 Pareto 支配下种群非支配个体数目与目标维数的对应关系. 在 m 维目标空间中随机生成 200 个目标个体, 决策变量维数 $n = 10, m = \{3, 6, 9, \dots, 21\}$, 统计独立运行 10 次中各目标取值下的种群非支配个体所占比例, 统计结果分别如图 1 和图 2 所示. 从图 1 可以看出, Pareto 支配下的目标空间中, 当目标维数超过 12 时, 种群中非支配个体比例高达 80% 以上; 当目标维数超过 20 时, 种群中几乎所有个体均为非支配个体.




图 1 Pareto 支配下非支配个体比例




图 2 改进后 K 支配下非支配个体比例

图 2 为改进后 K 支配下的目标空间中非支配个体比例统计. 从图 2 中可看出, 各维目标下种群中非支配个体比例明显减少, 当目标维数高达 21 维时非支配个体比例仍不足 20%, 且随着目标维数的升高, 非支配个体比例并无大幅增长, 具有良好的稳定性, 能为高维多目标环境下最优解集搜索提供有力保障.

1.2 拥挤密度估计方法改进

为克服现有 MOEA 模型中第 k 个最近邻法局部密度估计法不能精确地反映个体拥挤程度^[18]的

缺陷, KS-MODE 采用 Harmonic 平均距离^[18]对种群个体进行全局密度估计, 即个体密度值的估计需考虑种群中所有个体的影响. 在此基础上提出一种基于全局最优参考点的拥挤距离估计方法. 根据当前种群中所有个体在 m 维目标上达到的最优值 $\{f_1, f_2, \dots, f_m\}$ 构造最佳参考点 X_{best} , 如图 3 所示 (以 2 目标为例). 统计当前种群中个体与该参考点 X_{best} 之间的欧式距离 $D(x_i)$, 并将其作为个体拥挤密度估计的一部分, 用于衡量个体逼近 Pareto 最优前沿的程度.




图 3 构造种群最佳参考点

1.3 精英选择策略改进

KS-MODE 设计了新的精英选择策略及相应个体适应值评价方法, 综合考虑收敛性指标和分布性指标以决定精英个体的选择. 对于种群中个体 x_i , 假设其在改进 K 支配下的排序等级为 $KS(x_i)$, Harmonic 平均距离为 $Hd(x_i)$, 且距离当前全局最优参考点距离为 $D(x_i)$, 则其全局适应度值

$$fitness(x_i) = w_1 \times KS(x_i) - w_2 \times Hd(x_i) + w_3 \times D(x_i). \quad (6)$$

其中 w_1, w_2, w_3 为取值 $[0,1]$ 之间的权系数, 用于协调收敛性和分布性的权重.

基于上述 K 支配排序、全局密度估计、精英选择和 CAO 局部搜索算子 4 个方面的改进措施, 提出基于改进 K 支配排序的高维多目标差分进化算法 KS-MODE. 算法整体流程如图 4 所示.

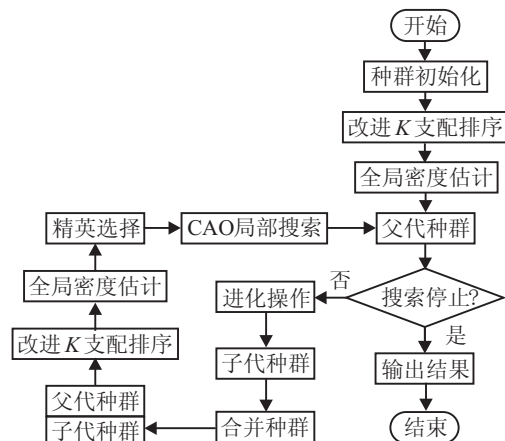


图 4 KS-MODE 算法流程

KS-MODE的收敛性能主要由进化操作和精英选择操作的收敛性能决定,一方面KS-MODE选用DE无约束的自由搜索模式“DE/rand/2”来保证解集收敛的随机性,使得子代种群的种群多样性得到最大程度的保持.另一方面,改进后的 K 支配及排序策略使种群个体等级多样性大幅提高,有效提升了精英选择压力,保证了KS-MODE的收敛性能.CAO操作的引入进一步加快了算法收敛速度.高维情况下MOEAs的稳定性主要取决于目标维数上升过程中支配排序策略的稳定性,KS-MODE中改进后的 K 支配排序策略在高维情况下能够保持良好的支配排序性能,其复杂程度与目标数目关系不密切,且不受目标函数数量纲和数值差异大小的影响,因而能够保证KS-MODE具有相对较优的稳定性.

2 仿真实验与结果分析

将KS-MODE与6种目前性能最优且最具代表性的MOEAs包括NSGA-II、DEMO、MOSAHS^[11]、MOPSO、MOGASd^[21]和MOEA/D-DE^[13]进行性能对比实验.选用4~30目标的标准测试函数集DTLZ{1, 2, 4, 5}^[21]进行算法性能测试.选取目前国内外通用的收敛性和分布性评价标准即世代距离GD和间距度量指标 S ^[18-21]衡量算法求解性能.为保证对比实验的公平性,所有算法采用统一的实验参数设置:目标数为4时,变量 x 维数为10,迭代次数为1000;目标数为

10时,变量 x 维数为20,迭代次数为2000;目标数为15时,变量 x 维数为25,迭代次数为3000;目标数为20时,变量 x 维数为30,迭代次数为4000;目标数为30时,变量 x 维数为50,迭代次数为5000.所有算法种群规模设置为100,采用5000个均匀分布的Pareto最优解作为真实Pareto前沿的近似解集.所有对比算法的控制参数设置均采用相应原文献中的推荐值.实验结果均为各算法独立运行30次对应GD和 S 的统计平均值,统计结果如表1~表4所示,各项对比实验中的最优结果均用黑体加粗表示.

从表1的实验统计结果可以看出,KS-MODE在4~20维DTLZ1函数上获得的GD值均小于其他算法,收敛性能具有一定优势,当目标数上升至30维时性能恶化较为明显.MOGASd和MOEA/D-DE在20和30目标上的解集分布性优于KS-MODE,其整体性能优于算法DEMO、MOSAHS和MOPSO、NSGA-II.

表2中实验统计结果显示,对比算法在DTLZ2函数上的求解性能相比DTLZ1均有所提升,基本能够保证成功求解DTLZ2.目标数上升至30的过程中,算法MOEA/D-DE、MOGASd、MOSAHS和MOPSO的性能优于NSGA-II和DEMO,但收敛精度及解集分布性相比于KS-MODE仍存在较大差距.KS-MODE收敛性指标GD优于对比算法近10个数量级,充分显示了改进后 K 支配策略的性能优势.KS-MODE在10

表1 测试函数DTLZ1试验统计结果

算法	4目标		10目标		15目标		20目标		30目标	
	GD	S	GD	S	GD	S	GD	S	GD	S
NSGA-II	16.8700	5.2174	372.3255	34.0728	557.1194	71.2242	611.1235	65.6097	1.2245e+03	213.78
DEMO	28.0004	2.0423	45.2192	4.3835	71.7417	7.2306	73.2667	8.2566	74.7893	9.0823
MOSAHS	11.5856	1.7251	39.3926	3.0058	48.4714	3.0446	77.3351	3.0612	87.4414	3.0853
MOPSO	6.6173	1.0744	36.9860	3.5054	38.9528	3.4543	39.5022	3.9960	63.2091	6.8991
MOGASd	1.6092	0.1912	1.6998	0.2072	1.8515	0.2098	1.8997	0.2850	18.7316	1.7823
MOEA/D-DE	0.0325	0.0273	0.0394	0.0418	1.7863	0.2008	7.9718	0.9471	12.2734	1.6152
KS-MODE	2.214e-4	0.0227	0.0014	0.0284	0.0710	0.0329	0.1602	0.8813	7.8417	2.5295

表2 测试函数DTLZ2试验统计结果

算法	4目标		10目标		15目标		20目标		30目标	
	GD	S	GD	S	GD	S	GD	S	GD	S
NSGA-II	0.2891	0.2038	2.1779	0.3552	2.2609	0.4656	2.3712	0.5777	4.0214	1.8321
DEMO	0.1627	0.0919	0.8152	0.1922	1.9974	0.3383	2.1971	0.4257	3.6880	1.0914
MOSAHS	0.1260	0.0856	0.2568	0.1194	0.2680	0.1277	0.3909	0.1433	0.5951	0.2014
MOPSO	0.0243	0.0150	0.0699	0.0211	0.0695	0.0219	0.0575	0.0202	0.1080	0.0328
MOGASd	0.0227	0.0131	0.0586	0.0222	0.0501	0.0213	0.0585	0.0225	0.0925	0.0367
MOEA/D-DE	0.0184	0.0443	0.0427	0.1356	0.0587	0.1468	0.0543	0.1433	0.0914	0.1659
KS-MODE	7.6453e-9	0.0675	1.5857e-13	1.0825e-4	1.3294e-16	9.9254e-5	9.8711e-15	2.1095e-5	1.9984e-15	8.4918e-4

表3 测试函数DTLZ1试验统计结果

算法	4目标		10目标		15目标		20目标		30目标	
	GD	S	GD	S	GD	S	GD	S	GD	S
NSGA-II	0.0011	0.0256	2.2313	0.5106	2.2259	0.5215	2.1227	0.6660	4.2120	1.5493
DEMO	0.0016	0.0593	0.0140	0.0838	0.0981	0.1017	0.1297	0.2779	0.1857	0.2850
MOSAHS	0.0149	0.0443	0.0274	0.0127	0.0756	0.0491	0.1058	0.0612	0.1553	0.0998
MOPSO	0.0058	0.0035	0.0726	0.0104	0.0805	0.0214	0.1073	0.0339	0.1407	0.0645
MOGASd	0.0130	0.0209	0.0378	0.0281	0.0442	0.0315	0.0457	0.0349	0.0781	0.0572
MOEA/D-DE	0.0101	0.0452	0.0254	0.0902	0.0388	0.0905	0.0461	0.1014	0.0942	0.1300
KS-MODE	2.3112e-06	0.0101	3.0634e-09	0.0097	2.0216e-10	0.0347	9.2410e-08	0.0418	8.0096e-08	0.0462

表 4 测试函数 DTLZ1 试验统计结果

算法	4 目标		10 目标		15 目标		20 目标		30 目标	
	GD	S	GD	S	GD	S	GD	S	GD	S
NSGA-II	0.125 6	0.069 5	0.179 1	0.033 7	0.189 2	0.049 7	0.273 8	0.061 0	0.371 3	0.087 8
DEMO	0.048 3	0.045 0	0.062 5	0.045 6	0.119 2	0.046 8	0.162 9	0.050 4	0.165 8	0.054 2
MOSAHS	0.065 2	0.050 5	0.079 7	0.054 3	0.086 7	0.048 2	0.090 1	0.043 6	0.099 3	0.062 2
MOPSO	0.012 8	0.031 1	0.032 5	0.040 6	0.050 7	0.043 1	0.072 4	0.051 9	0.092 9	0.063 2
MOGASd	0.014 0	0.022 3	0.036 1	0.032 8	0.048 2	0.044 7	0.050 2	0.045 1	0.071 6	0.053 2
MOEA/D-DE	0.107 8	0.023 1	0.100 3	0.021 5	0.078 6	0.019 5	0.070 1	0.019 1	0.066 6	0.015 9
KS-MODE	0.004 6	0.014 0	0.004 9	0.041 9	0.007 3	0.043 3	0.034 2	0.047 9	0.064 3	0.045 2


~30 目标上获得的分布性指标 S 远小于其他算法,且随着目标数目的增多分布性逐渐提升。

表 3 中实验统计结果显示, 对比算法 MOEA/D-DE、MOGASd、MOSAHS、DEMO 与 MOPSO 的求解性能较为接近, 其中 MOPSO 在分布性上具有一定优势。KS-MODE 始终保持最优的收敛性, GD 值全部达到 10^{-6} 以上, 能够保持较高的求解精度, 相比于其他算法在收敛性上优势明显。


表 4 中实验统计结果显示, KS-MODE 与对比算法在 DTLZ5 函数上的求解结果较为接近。KS-MODE 仍获得了最佳的收敛性能, 但与其他算法的差值并不明显。MOEA/D-DE 在 10~30 目标时获得了最佳的解集分布性能。

综合分析表 1~表 4 中的统计数据可看出, KS-MODE 能够在保证较为良好的解集分布性能的基础上大幅提升解集的收敛性能, 目标数上升过程中仍然保持高精度收敛, 说明 KS-MODE 具有较强的运算能力和稳定性, 受目标维数增长的影响相对较小。KS-MODE 与对比算法在 DTLZ{1, 2, 4, 5} 求解中的收敛性指标对比结果如图 5 所示, 由于对比算法的收敛性能较为接近, 为便于观察, 图中纵坐标取 GD 的对数。从图 5 中可看出, KS-MODE 在高维函数 DTLZ{2, 4} 上的性能优于 DTLZ{1, 5}, 当 DTLZ{2, 4} 的目标维数小于 15 时均属于 KS-MODE 获得最佳性能的范围, 目标维数从 5 增至 15 的过程中, KS-MODE 的收敛性指标 GD 值不增反降, 但当目标维数超过 15 时函数 DTLZ{2, 4} 的复杂度增加, 超过了 KS-MODE 获得最佳性能的范围, 因此即使实验条件中迭代次数有所增加, KS-MODE 的收敛性能还是开始急剧恶化, 对应的收敛变化曲线出现弯折。相比之下, NSGA-II 等对比算法在高维函数 DTLZ{1, 2, 4, 5} 上的收敛性能较差, 当目标维数超过 10 时对比算法基本陷入局部最优, 即使实验条件改善对其收敛性能的提升效果也并不明显, 因此其 GD 指标值始终较为平稳, 对应图 5 中的收敛变化曲线较为平滑。


综上所述, 本文提出的基于改进后 K 支配排序的 KS-MODE 算法大幅度改善了现有 MOEAs 的收敛性能, 在高维多目标优化问题求解的收敛性和稳定性




(a) DTLZ1 函数



(b) DTLZ2 函数



(c) DTLZ4 函数



(d) DTLZ5 函数

图 5 DTLZ 函数集收敛性能对比

上表现出明显优势, 尤其适合于高维多目标优化问题的求解。

3 结 论

为提高现有多目标进化算法 MOEAs 在高维多目标优化问题上的求解性能, 提出了一种基于改进 K

支配排序的高维多目标差分进化算法 KS-MODE. KS-MODE 针对 K 支配排序中的循环支配问题及传统排序方法进行改进,有效增强了算法选择压力. 设计了新的全局密度估计方法、新的精英选择策略和新的适应度值评价函数,并采用 CAO 操作加快了收敛速度. 通过在 4~30 目标测试函数 $DTLZ\{1, 2, 4, 5\}$ 上的实验证明, KS-MODE 能在保证解集分布性基础上大幅提升现有 MOEAs 的收敛精度及稳定性,取得更逼近 Pareto 前沿的最优解集,适合于高维复杂多目标优化问题的求解,为实际工程优化设计及决策问题提供了一定的理论支持.

参考文献(References)

- [1] Carlos A, Coello Coello. 20 years of evolutionary multi-objective optimization: What has been done and what remains to be done[C]. Computational Intelligence: Principles and Practice. M'exico: Springer, 2006: 73-88.
- [2] 杨咚咚, 焦李成, 公茂果, 等. 求解偏好多目标优化的克隆选择算法[J]. 软件学报, 2010, 21(1): 14-33.
(Yang D D, Jiao L C, Gong M G, et al. Clone selection algorithm to solve preference multi-objective optimization[J]. J of Software, 2010, 21(1): 14-33.)
- [3] 公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究[J]. 软件学报, 2009, 20(2): 271-289.
(Gong M G, Jiao L C, Yang D D, et al. Research on evolutionary multi-objective optimization algorithms[J]. J of Software, 2009, 20(2): 271-289.)
- [4] Zou X F, Chen Y, Liu M Z, et al. A new evolutionary algorithm for solving many-objective optimization problems[J]. IEEE Trans on Systems, Man, and Cybernetics-Part B: Cybernetics, 2008, 38(5): 1402-1412.
- [5] Deb K, Pratap A, Agarwal S. A fast and elitist multi-objective genetic algorithm: NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2002, 6(2): 182-197.
- [6] Eckart Zitzler, Marco Laumanns, Lothar Thiele. SPEA2: Improving the strength pareto evolutionary algorithm[C]. Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems. Berlin: Springer-Verlag, 2002: 95-100.
- [7] Carlos A, Coello Coello, Gregorio Toscano Pulido, et al. Handling multiple objectives with particle swarm optimization[J]. IEEE Trans on Evolutionary Computation, 2004, 8(3): 256-279.
- [8] Robic T, Filipic B. DEMO: Differential evolution for multi-objective optimization[J]. Lecture Notes in Computer Science, 2005, 3410: 520-533.
- [9] Geem Z W, Kim J H, Loganathan G V. A new heuristic optimization algorithm: Harmony search[J]. Simulation, 2001, 76(2): 60-80.
- [10] Karaboga D, Basturk B. On the performance of artificial bee colony algorithm[J]. Applied Soft Computing, 2008, 8(1): 687-697.
- [11] 陈莹珍, 高岳林. 多目标自适应和声搜索算法[J]. 计算机工程与应用, 2011, 47(31): 108-111.
(Chen Y Z, Gao Y L. Multi-objective self-adaptive harmony search algorithm[J]. Computer Engineering and Applications, 2011, 47(31): 108-111.)
- [12] 孔维健, 丁进良, 柴天佑. 高维多目标进化算法研究综述[J]. 控制与决策, 2010, 25(3): 321-325.
(Kong W J, Ding J L, Chai T Y. Survey on large-dimensional multi-objective evolutionary algorithms[J]. Control and Decision, 2010, 25(3): 321-325.)
- [13] Li H, Zhang Q F. Multiobjective optimization problems with complicated pareto sets, MOEA/D and NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2009, 13(2): 284-302.
- [14] Farina M, Amato P. A fuzzy definition of "optimality" for many-criteria optimization problems[J]. IEEE Trans on Systems, Man, and Cybernetics, 2004, 34(3): 315-326.
- [15] Hernandez Diaz A, Santana Quintero L, Coello Coello C, et al. Pareto-Adaptive ϵ -dominance[J]. Evolutionary Computation, 2007, 15(4): 493-517.
- [16] 郭思涵, 龚小胜. 正交设计的 E 占优策略求解高维多目标优化问题研究[J]. 计算机科学, 2012, 39(2): 276-310.
(Guo S H, Gong X S. Research of orthogonal E -dominance(OE) strategy to solve large-dimensional objective optimization problems[J]. Computer Science, 2012, 39(2): 276-310.)
- [17] Korudu P, Das S. Multi-objective hybrid pso using u-fuzzy dominance[C]. Genetic and Evolutionary Computation Conference. New York: ACM Press, 2007: 853-860.
- [18] Li M Q, Zheng J H, Li K, et al. Enhancing diversity for average ranking method in evolutionary many-objective optimization[J]. Lecture Notes in Computer Science, 2009, 5845: 633-645.
- [19] Drechsler N, Drechsler R, Becker B. Multi-objective optimisation based on relation favour[C]. Lecture Notes in Computer Science, 2001, 1993: 154-166.
- [20] Di P F, Khu S T, Savi' C D A. An investigation on preference order ranking scheme for multiobjective evolutionary optimization[J]. IEEE Trans on Evolutionary Computation, 2007, 11(1): 17-45.
- [21] Kim H, Liou M S. New fitness sharing approach for multi-objective genetic algorithms[J]. J of Global Optimization, 2013, 55(3): 579-595.