

一种改进的基于分解的多目标进化算法

侯 薇^{1,2} 董红斌¹ 印桂生¹

(哈尔滨工程大学计算机科学与技术学院 哈尔滨 150001)¹

(东北农业大学电气与信息学院 哈尔滨 150030)²

摘要 利用基于分解的多目标进化算法框架(MOEA/D),将混合策略的进化算法用于求解分解后的若干单目标优化子问题,提出了一种带局部搜索的基于分解的多目标混合策略进化算法(LMS-MOEA/D)。算法利用均匀设计产生子问题的聚合权重向量,混合交叉策略能够充分利用不同交叉算子的优势;同时算法针对演化过程收敛的特点,结合局部搜索策略,获得逼近 Pareto 前沿的最优解集。最后通过实验验证算法在多样性和收敛性方面的有效性。

关键词 分解,均匀设计,多目标优化,局部搜索,混合策略

中图法分类号 TP18 文献标识码 A

Enhanced Multi-objective Evolutionary Algorithm Based on Decomposition

HOU Wei^{1,2} DONG Hong-bin¹ YIN Gui-sheng¹

(College of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China)¹

(College of Electrical and Information, Northeast Agriculture University, Harbin 150030, China)²

Abstract A novel algorithm, called multi-objective mixed strategy evolutionary algorithm with local search (LMS-MOEA/D), was presented based on the frame of MOEA/D (multi-objective evolutionary algorithm based on decomposition), to solve a set of scalar optimization sub-problems. The uniform design method was applied to generate the aggregation coefficient vectors. The mixed strategy can make full use of the advantage of each crossover operator, and the algorithm combines local search strategy to approximate the Pareto-optimal set. Experimental results indicate that the proposed algorithm has the efficiency and effectiveness in terms of diversity and convergence.

Keywords Decomposition, Uniform design, Multi-objective optimization (MOP), Local search, Mixed strategy

1 引言

自从 Schaffer 的开创性工作,即向量评价遗传算法提出以来,应用进化算法(Evolutionary Algorithms, EAs)解决 MOP 问题即多目标进化算法(Multi-objective Evolutionary Algorithms, MOEAs)逐渐成为研究热点。基于种群的本质,MOEAs 能够在一轮演化中获得近似的 Pareto 最优解集而得到广泛使用。算法框架是设计 MOEA 的关键问题,绝大多数的研究和应用领域的 MOEAs 都或多或少地使用非占优排序遗传算法 II^[1](Non-dominated Sorting Genetic Algorithm II, NSGA-II)的框架:选择算子基于 Pareto 优于关系,复制算子迭代使用。随着对多目标优化问题研究的深入,一些新颖的算法框架,如粒子群优化、人工免疫系统、分布估计算法、协同进化算法、基于偏好的算法、文化进化算法和基于分解的算法等,越来越多地被引入到进化多目标优化领域^[2]。

多数的多目标进化算法都是把 MOP 问题当作一个整体

来对待,而 Zhang 和 Li 将数学规划中较为成熟的分解策略引入到多目标进化算法当中,构造了一种新颖的基于分解的多目标进化算法(MOEA/D)框架^[3],算法将逼近整个 Pareto 前沿面的问题分解为一定数量的单目标优化问题,然后利用进化算法同时求解这些问题,被认为是求解多目标优化问题的新型进化范例之一^[4]。近期出现了许多 MOEA/D 的改进算法,如 Li 和 Zhang 将差分进化操作成功地引入 MOEA/D^[5], Tan 等提出基于分解的均匀设计的多目标差分算法^[6], Deb 等提出进化多目标优化的混合框架^[7]等。实验结果表明,基于分解的多目标进化算法是一种有效方法,为求解进化多目标优化问题提供了一种新思路。

为了提高 MOEA/D 框架的绩效,本文将基于混合策略的混合交叉算子引入 MOEA/D 的框架,并利用局部搜索技术,提出了带局部搜索的基于分解的多目标混合策略的进化算法(LMS-MOEA/D)。通过对经典简单和复杂的多目标函数进行测试,说明了所使用策略的有效性,验证了所提算法的

到稿日期:2013-05-20 返修日期:2013-07-22 本文受国家自然科学基金项目(60973075, 61272186), 工信部基础科研计划资助项目(B0720110002)资助。

侯 薇(1973—),女,博士生,讲师,主要研究方向为演化计算、数据挖掘、多 agent 系统, E-mail: Source258@126. com; 董红斌(1963—),男,博士,教授,主要研究方向为人工智能、多 agent 系统、演化计算和数据挖掘;印桂生(1964—),男,博士,教授,主要研究方向为数据库系统、虚拟现实、数据挖掘和网构软件。

绩效。

2 基于分解的多目标进化算法框架

MOP 的一个 Pareto 最优解,在比较弱的条件下,也是一个标量优化问题的最优解。因此 Pareto 前沿(PF, Pareto front)的逼近可以分解为多个标量目标优化的子问题,最常用的构建聚合函数的 Tchebycheff 分解方法如下。

一个多目标优化(MOP)问题可以描述为:

$$\min F(x) = (f_1(x), \dots, f_m(x))' \quad (1)$$

其中, $x \in \Omega$, Ω 是决策(参数)空间, $F: \Omega \rightarrow R^m$ 包括 m 个待优化的目标函数, R^m 称为目标空间。Tchebycheff 分解方法将一个 MOP 问题分解为如下若干个子问题:

$$\min G(x|\lambda^j, z^*) = \max\{\lambda_i | f_i(x) - z^*\} \quad (2)$$

其中, $\lambda^j = (\lambda_1, \dots, \lambda_m)$ 是一个聚合权重向量 ($j=1, \dots, N$), 对于所有的 $i=1, \dots, m$, 有 $\sum_{i=1}^m \lambda_i = 1$, $z^* = (z_1^*, \dots, z_m^*)$ 是参考点, 对于所有的 $i=1, \dots, m$, 有 $z^* = \min\{f_i(x) | x \in \Omega\}$ 。

使用 Tchebycheff 分解的多目标演化算法 MOEA/D 的种群规模为 N , 代表每个子问题当前的解。对于每个 Pareto 最优点 x^* , 存在一个权向量 λ , 使得 x^* 是式(2)的最优解, 也是式(1)的一个 Pareto 最优解。 G 是 λ 连续的, 可以通过适当地选取 N 个均匀分布的权重向量 $\lambda^1, \dots, \lambda^N$, 将 MOP 问题转化为用 N 个子问题的最优解来估计 Pareto 前沿。

在基于分解的多目标进化算法中, 种群由每个子问题目前所发现的最好解构成, 每个子问题的优化过程通过与其近邻子问题之间的进化操作来完成。基于分解的多目标进化算法(MOEA/D)框架如下:

算法 1 基于分解的多目标进化算法。

① 初始化, 包括种群, 每个权重向量的邻域中 T 个向量以及参考点等。

② 更新, 对于第 i 个个体, 取其邻域中的两个个体进行交叉和变异, 产生一个新解 y ; 更新参考点 z^* ; 更新邻域中的解: 如果存在新解 y 的适应度优于第 i 个个体的邻域中个体的适应度, 则以 y 替代那些邻域个体。

③ 如果终止, 则输出非支配解集; 否则转②。

MOEA/D 框架成功地将数学规划中常用的分解方法引入到进化多目标领域, 而且可以直接采用进化算法求解单目标优化问题时的适应度分配和多样性保持策略。

3 带局部搜索的基于分解的多目标混合策略进化算法

3.1 均匀设计的权向量

MOEA/D-DE^[5] 中采用简单格子法(Simplex-lattice)来设置权向量, 但此方法的产生权向量的实验点分布不均匀, 而且边界上的点太多, 使子问题中部分目标的权值为零, 导致最终聚合的目标只是部分子问题而不是全部。

本文采用均匀设计^[8] (Uniform Design) 方法来生成均匀分布的权向量。均匀设计是由中国数学家王元和方开泰于 1978 年首次提出的, 基本思想是使试验点在因子空间中具有

较好的均匀分散性, 使某种均匀性度量最小化, 均匀设计表用代号 $U_n(q)$ 表示, U 表示均匀设计表, s 表示因素个数, q 为试验水平数, n 表示试验次数。本文利用好格子点法构造均匀设计表 $U_N(N^{m-1})$, 采用可卷的 L_2 偏差(WD_2)作为均匀性度量, 生成 N 个 m 维均匀分布的权重向量。

3.2 混合策略

在博弈论中, 混合策略比纯策略具有某些潜在的优点^[9]。基于混合策略的进化算法中的个体被看作博弈的参与者, 每个个体从它的策略集中根据选择概率选择一种策略, 根据这一策略产生一个或两个后代。混合策略将几个算子结合在一个算法中, 个体根据适应度的变化调整混合策略的概率分布, 在不同的阶段采用不同的策略, 将不同的策略结合起来, 这样可以在搜索过程中有效地利用各个算子的优势^[10]。

本文中提出的混合交叉策略集合由 3 种不同的交叉算子(算术交叉算子、模拟二进制交叉算子和启发式交叉算子)及其概率分布组成。下一代个体的混合策略概率更新过程如下: 选择操作之后, 个体应该来自于父代种群或子代种群, 评价下一代中每个个体使用策略的收益, 假设个体 i 在交叉中使用纯策略 h 。如果个体来自子代种群, 说明策略 h 产生了一个较好的子代, 这种纯策略将得到正收益, 则增强其采用的纯交叉策略的概率。如果个体来自父代种群, 说明策略 h 产生了一个不如父代的子代, 这种纯策略将得到负收益, 则削弱其采用的纯策略的概率, 详见文献[10]。

3.3 局部搜索策略

传统的进化算法在复杂空间上的局部搜索能力较弱, 通过引入适当的局部搜索可以保持对于搜索空间探索和开发间的平衡^[11-15]。在多个冲突的目标中确定局部搜索的目标实际上是一个困难的任务, 由于粒子群算法具有快速收敛的特性, 本文将利用粒子群算法作为局部搜索策略, 并将最小化一个达成标量化函数 ASF(achievement scalarizing function) 作为局部搜索的目标函数。ASF 的最优解总是 Pareto 最优的, 可以表示为如下形式^[16]:

$$\min \max_{i=1}^m w_i (f_i(x) - \bar{z}_i) + \rho \sum_{i=1}^m w_i (f_i(x) - \bar{z}_i) \quad (3)$$

其中, $w_i = 1/(z_i^{\max} - z_i^{\min})$, z_i^{\max} 和 z_i^{\min} 分别为种群中每个目标函数的最大值和最小值。 ρ 是一个很小的正数 ($\rho = 10^{-6}$), 称为放大系数, \bar{z} 为参考点。由适当的局部搜索算法对问题(3)求解后, 可以产生有限均衡的 Pareto 最优解。

从搜索过程的全局性考虑, 在演化全程周期性地使用局部搜索, 而在演化深入时加强使用局部搜索策略。若以概率 p_{local} 执行局部搜索, 可以通过使用 saw-tooth 概率函数来实现这种周期性。演化深入的程度可以通过平均 ASF 值 AVG_ASF 来判别, 如果 AVG_ASF 值小于某个设定的阈值, 则强化局部搜索。

3.4 带局部搜索的基于分解的多目标混合策略进化算法

本文将混合交叉策略和局部搜索策略用于 MOEA/D 的框架, 提出了带局部搜索的基于分解的多目标混合策略进化算法(LMS-MOEA/D)。

算法 2 带局部搜索的基于分解的多目标混合策略进化

算法

1) 初始化:

①利用均匀设计方法生成均匀分布的权向量。

②计算每两个权重向量间的欧氏距离,对于每个权重向量 λ^i ,用距其最近的 T 个权重向量构成其邻域,用 $B(i)$ 来保存 T 个权重的序号,即对每个个体 $x^i, i=1, \dots, N$,有 $B(i)=\{i_1, \dots, i_T\}$,其中 $\lambda^{i_1}, \dots, \lambda^{i_T}$ 是 λ^i 邻域中的 T 个权重向量。

③随机产生初始群体,并计算目标函数值 $F(x^i)$ 。

④设置初始参考点 $z=(z_1, \dots, z_m)', z_j = \min_{1 \leq i \leq N} f_j(x^i), j=1, \dots, m$ 。令演化代数 $t=1$ 。

2) 更新:对每个个体 x^i 做如下操作:

①繁殖:随机从 $B(i)$ 中选择2个序号 k 和 l ,对于邻近个体 x^k 和 x^l ,依据其策略概率的分布进行混合交叉操作,然后进行差分变异操作,产生新解 y 。

②更新参考点 z :如果 $z_j < f_j(y), j=1, \dots, m$,则令 $z_j = f_j(y)$ 。

③更新邻域中的解:如果存在一个以上个体的适应度值,有 $G(y|\lambda, z) \leq G(x^i|\lambda, z), j \in B(i)$,则令 y 只取代其中的一个个体。

④根据父代与子代的适应度提高或降低,增加或减小策略集中各纯交叉策略的概率分布。

3) 周期性局部搜索:以概率 p_{local} 从个体邻域中选择一个个体作为目标函数(3)的参考点,执行PSO算法,将得到的最优个体代替选中的个体。

4) 保存ASF最优值,计算每 $\Delta t=20$ 代的平均ASF最优值AVG ASF。

5) 强化性局部搜索:将种群中每个个体设为(3)中的参考点,执行PSO,将得到的最优个体代替原来个体。

6) 终止条件:如果 $AVG_ASF \leq \epsilon(10^{-4})$,则算法终止;否则,令 $t=t+1$,转2)。

使用ASF作为标量化函数的局部搜索为算法提供了一个自动的同时能够确保足够近地收敛到Pareto最优前沿的终止条件。

在周期性的局部搜索中,在每代只涉及一个个体作为(3)中的参考点,旨在加速算法的收敛并减少函数的评价次数;而在强化的局部搜索中,考虑全部种群个体依次作为参考点,旨在精确地找到更优解。

4 实验结果与分析

4.1 测试问题和评价指标

为了测试所提算法处理MOPs的能力,本文采用广泛用于测试的ZDT,DTLZ函数以及Li和Zhang所提出的一类复杂的测试问题(F1—F9)。

本文采用多目标优化解集的评价指标,即IGD(Inverted Generational Distance)值,估计算法的PF与理想最优解的趋近程度。设 P^* 为一个沿理想Pareto前沿均匀分布的点集, P 是算法得到的近似Pareto最优解集合。 P^* 到 P 的平均距离IGD定义为:

$$IGD(P^*, P) = \frac{\sum_{v \in P^*} d(v, P)}{|P^*|} \quad (4)$$

$d(v, P)$ 是 v 与 P 中所有点的最小欧式距离,如果 $|P^*|$ 足够大,IGD能够在某种程度上代表 P 的多样性和收敛性。IGD值越小,表示 P 与 P^* 的PF越接近。

4.2 目标问题的性能测试

首先使用简单的广泛用于测试的2目标ZDT函数进行实验。将未使用局部搜索的算法即基于分解的多目标混合策略进化算法MS-MOEA/D1与MOEA/D、NSGA-II算法进行对比,后两种算法都使用模拟二进制交叉(SBX)和多项式变异。3种算法都使用Simplex-lattice方法产生均匀分布的权向量。算法所分解的子问题数目 N 即算法的种群大小设为100,终止条件为最大演化代数250。个体邻域集合大小 T 设为20,交叉率为1,变异率为 $1/n$ (n 为决策变量维数)。各算法将每个函数测试30次。图1显示了算法MS-MOEA/D1使用纯交叉策略(SBX)和混合交叉策略的Pareto前沿面。图2显示了函数ZDT4在纯策略和混合策略下的IGD值随演化代数的收敛情况。表1显示了各算法在测试函数上的IGD均值和方差,算法MOEA/D和NSGA-II的数据来源于文献[3]。

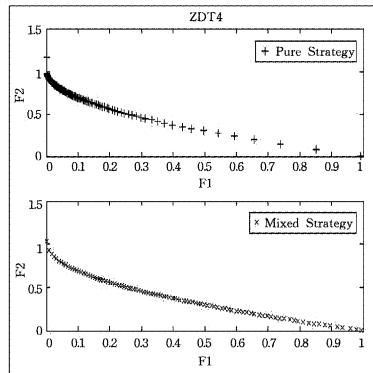


图1 不同交叉策略下的PF

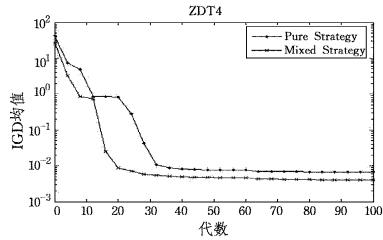


图2 不同交叉策略下的IGD收敛

表1 MS-MOEA/D1与MOEA/D,NSGA-II的IGD对比

IGD	MS-MOEA/D1		MOEA/D ^[3]		NSGA-II ^[3]	
	Mean	Std	Mean	Std	Mean	Std
ZDT1	0.0046	0.0003	0.0055	0.0039	0.0050	0.0002
ZDT2	0.0048	0.0006	0.0079	0.0109	0.0049	0.0002
ZDT3	0.0105	0.0094	0.0143	0.0091	0.0065	0.0054
ZDT4	0.0075	0.0025	0.0076	0.0023	0.0182	0.0237
ZDT6	0.0019	0.0001	0.0042	0.0003	0.0169	0.0028

混合交叉策略适应性地利用不同交叉算子的优势产生了更多样的解,同时没有增加函数的评价次数,有利于加速算法的收敛。图1显示,使用混合交叉策略的算法MS-MOEA/D1获得的Pareto解的多样性和均匀性比纯策略的算法更

好。图 2 显示,使用混合交叉策略比纯策略获得的 IGD 值收敛的速度更快。表 1 显示,对于 2 目标函数,除了 ZDT3,算法 MS-MOEA/D1 在其他所有 2 目标函数上获得的 IGD 均值均好于或近似于算法 MOEA/D 和 NSGA-II,显示了混合策略的有效性。

4.3 3 目标(以上)问题的性能测试

为了考察所提算法求解更多目标问题的能力,本节使用 2 个目标以上的 DTLZ 函数(包括 3 目标函数 3-DTLZ1—3-DTLZ6 和 4 目标函数 4-DTLZ2)进行测试。将本文所提算法 LMS-MOEA/D 与 MOEA/D、HMOEA/D^[7](混合的基于分解的多目标差分算法)进行对比,HMOEA/D 是一种结合局部搜索的混合演化多目标优化算法,与本文算法一样,HMOEA/D 的局部搜索以最小化 ASF 为目标,主要区别在于具体的局部搜索策略有所不同。各算法都采用差分演化中的变异策略,采用 Simplex-lattice 方法产生权向量,3 目标和 4 目标函数对应的种群大小分别为 210 和 220。各算法独立运行 15 次。图 3 显示了本文算法 LMS-MOEA/D 在有无局部搜索策略下函数 DTLZ1 的 IGD 值收敛速度的对比,表 2 显示了各算法在测试函数上的 IGD 均值,算法 MOEA/D 和 HMOEA/D 的数据来源于文献[7]。

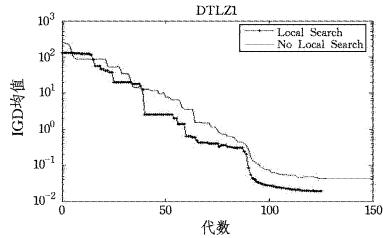


图 3 LMS-MOEA/D 中局部搜索对 IGD 的影响

表 2 LMS-MOEA/D 与 MOEA/D-DE, HMOEA/D-DE 的 IGD 对比

IGD	Function Evaluations	LMS-MOEA/D			UMODE/D ^[6]		MOEA/D-DE ^[6]	
		Mean	Mean	Mean	Mean	Std	Mean	Std
3-DTLZ1	20000	0.018132	0.018925	0.018265				
3-DTLZ2	5000	0.050499	0.054032	0.052276				
3-DTLZ3	45000	0.094014	0.093488	0.100073				
3-DTLZ4	15000	0.052943	0.055246	0.056702				
3-DTLZ5	10000	0.005429	0.006443	0.006264				
3-DTLZ6	5000	0.005578	0.005551	0.005671				
4-DTLZ2	15000	0.015455	0.160612	0.158917				

从图 3 可以看出,采用局部搜索算法所获得的 IGD 值下降得更快,而且由于使用了平均 ASF 最优值作为算法 LMS-MOEA/D 的终止条件,在没有到达最大演化代数情况下,算法提前终止,减少了算法的运算代价。表 2 表明算法 LMS-MOEA/D 在多个目标的函数上获得的 IGD 均值好于或近似于算法 MOEA/D 和 HMOEA/D,证实了本文算法中局部搜索策略的有效性。

4.4 复杂问题上的性能测试

决策(变量)空间中所有 Pareto 最优点的集合,记为 PS(Pareto Set)。现存的绝大多数 MOPs 测试问题的 PS 形状通常很简单,本节实验使用了一类任意 PS 形状的通用的连续多目标优化测试实例(F1—F9)^[5],来检验 LMS-MOEA/D 处理复杂 PS 形状问题的能力。F1—F5 和 F7—F9 是 2 目标实

例,F6 是 3 目标实例,图 4 为实例 F1—F3 在三维决策空间上的形状。

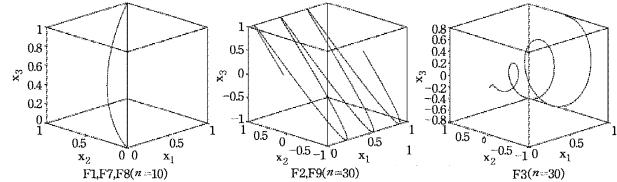


图 4 F1—F3 的 PSs 三维决策空间投影

本节实验中的对比算法为 UMODE/D^[6]、MOEA/D-DE。UMODE/D 是采用均匀设计方法产生权向量的一种基于分解的多目标差分算法。各算法的种群大小,2 目标设为 300,3 目标为 595,LMS-MOEA/D 和 UMODE/D 终止条件为最大演化代数 250,MOEA/D-DE 终止条件为最大演化代数 500。各算法交叉率为 1,变异率为 $1/n$ (n 为决策变量维数),每个函数独立测试 20 次。表 3 显示了各算法在测试函数上的 IGD 平均值和方差,对比算法的数据来源于文献[6]。图 5 显示了各实例的 IGD 值随演化代数的收敛情况。图 6 显示了 LMS-MOEA/D 和 MOEA/D-DE 在取得平均最好 IGD 值时得到的各实例的 Pareto 前沿面。图 7 是算法 LMS-MOEA/D 获得的 F1—F3 的解在三维决策空间上的分布。

表 3 MOEA/D-DE, UMODE/D 与 LMS-MOEA/D 的 IGD 对比

IGD	LMS-MOEA/D		UMODE/D ^[6]		MOEA/D-DE ^[6]	
	Mean	Std	Mean	Std	Mean	Std
F1	0.0011	0	0.0013	0	0.0015	0
F2	0.0015	0.0001	0.0062	0.0171	0.0028	0.0004
F3	0.0017	0.0015	0.0054	0.0100	0.0068	0.0099
F4	0.0019	0.0001	0.0024	0.0005	0.0040	0.0014
F5	0.0032	0.0022	0.0076	0.0029	0.0127	0.0069
F6	0.0255	0.0016	0.0266	0.0008	0.0289	0.0014
F7	0.0017	0.0018	0.0014	0	0.0049	0.0063
F8	0.0187	0.0102	0.0241	0.0354	0.0998	0.0429
F9	0.0015	0.0001	0.0020	0.0001	0.0035	0.0008

表 3 显示,除 F7 外,算法 LMS-MOEA/D 在所有实例上获得的 IGD 均值均好于其它算法,尤其对于 F2、F3 和 F8 来说,算法 LMS-MOEA/D 获得的 IGD 值有了很大的改善,其他函数的 IGD 均值和方差略好于或等价于算法 UMODE/D。算法 LMS-MOEA/D 和 UMODE/D 的绩效从整体上好于算法 MOEA/D-DE 和 NSGA-II-DE,前两种算法的 IGD 值更小,演化代数更少。

由图 5 可以看出,在 F1、F6、F7 和 F9 上算法 LMS-MOEA/D 与 UMODE/D 的收敛速度相近,在其它实例上 LMS-MOEA/D 具有更快的收敛速度。从图 6 和图 7 可以看出,在取得最好的平均 IGD 值的情况下,对于所有的实例,算法 LMS-MOEA/D 在目标空间所获得的 Pareto 解均较好收敛于最优前沿上,并且在决策空间和目标空间上的解都是均匀分布的。算法 MOEA/D-DE 的收敛速度是最慢的。算法 LMS-MOEA/D 在混合交叉策略和变异的较好的全局搜索的基础上,利用局部搜索算子能够在一个较好个体周围沿着不同的方向进行更好的探索,有利于更快地发现更好的解,降低了盲目搜索的几率,提高了搜索更优解的效率。

对复杂问题的测试结果表明,算法 LMS-MOEA/D 在多

样性和均匀性方面都表现出较好的绩效,同时也显示出较快的收敛速度。

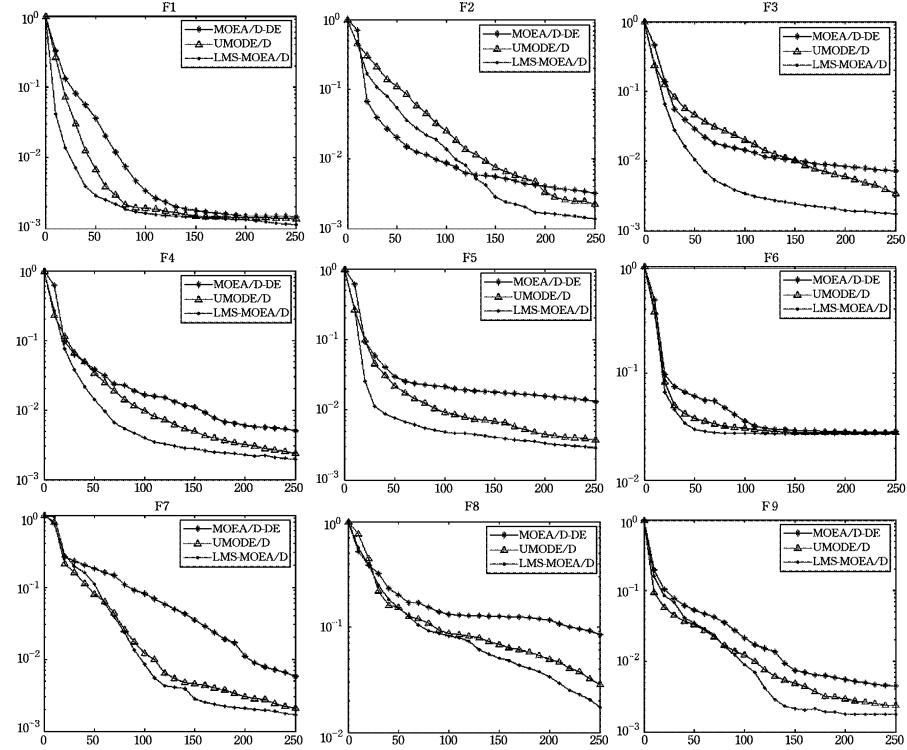


图 5 LMS-MOEA/D, MOEA/D-DE 和 UMODE/D 最好 IGD 值随代数的收敛情况

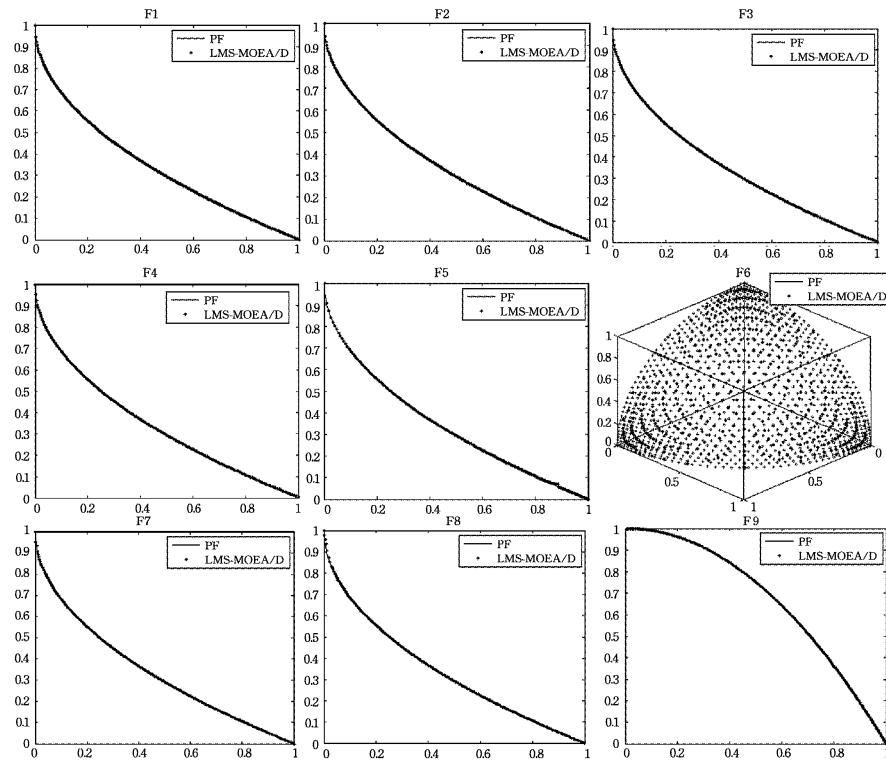


图 6 MS-MOEA/D 和 MOEA/D-DE 在最好的平均 IGD 下的 PFs

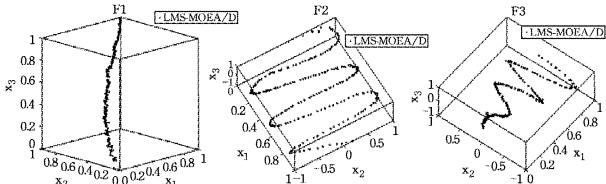


图 7 算法 LMS-MOEA/D 的 PSs 在三维决策空间上的投影

结束语 本文基于分解的多目标进化算法框架 MOEA/D, 提出了带局部搜索的基于分解的多目标混合策略进化算法 (LMS-MOEA/D), 同时算法引入局部搜索方法保持在搜索空间上深度和广度搜索的平衡, 以达到提高收敛到最优解的速度和精度的目的。对简单和复杂问题的测试结果显示了算

(下转第 152 页)

- [3] Barnich O, van Droogenbroeck M. ViBe: A powerful random technique to estimate the background in video sequences[C]// Proc. Int. Conf. Acoust, Speech Signal Process. 2009;945-948
- [4] Caseiro R, Henriques J, Martins P. Anonparametric riemannian framework on tensor field with application to foreground segmentation[C]// ICCV 2011. 2011;1-8
- [5] McIvor A. Background subtraction techniques[C]// Proc. ImageVis. Comput, Auckland, New Zealand, Nov. 2000
- [6] Benezeth Y, Jodoin P, Emile B. Review and evaluation of commonly-implemented background subtraction algorithms[C]// Proc. IEEEInt. Conf. Pattern Recognit. 2008;1-4
- [7] Parks D, Fels S. Evaluation of background subtraction algorithms with post-processing[C]// Proc. IEEEInt. Conf. Adv. VideoSignal Based Surveillance. Santa Fe, New Mexico, 2008; 192-199
- [8] Joshi K A, Thakore D G. A Survey on Moving Object Detection and Tracking in Video Surveillance System[J]. International Journal of Soft Computing and Engineering, 2012, 2(3);44-48
- [9] Pander R P, Mishra N D, Gulhane S. Detection of moving object with the help of motion detection alarm system in video surveillance[J]. Journal of Signal and Image Processing, 2012, 2(3); 118-121
- [10] Barnich O, Van Droogenbroeck M. ViBe: A universal background subtraction algorithm for video sequences [J]. IEEE Transactions on Image Processing, 2011, 20(6);1709-1724
- [11] Sonka M, Hlavac V, Boyle R. 图像处理、分析与机器视觉[M]. 艾海舟, 武勃, 等译. 北京: 人民邮电出版社, 2003
- [12] 杨益军, 赵春椿, 汪文秉. 一种适合于目标检测的图像分割方法 [J]. 信号处理, 2002, 18(2);183-185
- [13] 张新宇, 刘广智, 立建勤. 一种图像分割的目标描述方法及实现 [J]. 系统工程与电子技术, 2003, 25(2);219-222
- [14] 陈忠碧, 张启衡. 一种适合于多目标检测的图像分割方法[J]. 光电工程, 2004, 31(5);34-37
- [15] <http://cvrr.ucsd.edu/aton/shadow/>

(上接第 118 页)

法 LMS-MOEA/D 有效地处理多目标问题的能力。今后将对分解的方法、保持解的多样性等方面进行改进,并用于解决更高维的和实际的多目标优化问题。

参 考 文 献

- [1] Deb K, Agrawal S, Pratap A, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2);182-197
- [2] Zhou Ai-min, Qu B Y, Li Hui, et al. Multiobjective evolutionary algorithms: A survey of the state of the art [J]. Swarm and Evolutionary Computation, 2011, 1(1);32-49
- [3] Zhang Q F, Li H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition [J]. IEEE Transactions on Evolutionary Computation, 2007, 11(6);712-731
- [4] 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
- [5] Li H, Zhang Q F. Multiobjective optimization problems with complicated pareto sets, MOEA/D and NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2009, 13 (2); 284-302
- [6] Tan Yan-yan, Jiao Yong-chang, Li Hong, et al. A modification to MOEA/D-DE for multiobjective optimization problems with complicated Pareto sets [J]. Information Sciences, 2012, 213 (5);14-38
- [7] Sindhy K, Miettinen K, Deb K. A hybrid framework for evolutionary multi-objective optimization [J]. IEEE Transactions on Evolutionary Computation, 2013, 17(4);495-511
- [8] Fang K T, Lin D K J, Winker P, et al. Uniform design: theory and application [J]. Technometrics, 2000, 42(3);237-248
- [9] He J, Yao X. A game-theoretic approach for designing mixed mutation strategies [C]//Proceedings of the International Conference on Natural Computation. Berlin: Springer, 2005;279-288
- [10] Dong Hong-bin, He Jun, Huang Hou-kuan, et al. Evolutionary programming using a mixed mutation strategy [J]. Information Sciences, 2007, 177(1);312-327
- [11] Gong Mao-guo, Liu Chao, Jiao Li-cheng, et al. Hybrid immune

algorithm with Lamarckian local search for multi-objective optimization [J]. Memetic Computing, 2010, 2(1);47-67

- [12] Hansen M P. Use of substitute scalarizing functions to guide a local search based heuristic: The case of moTSP [J]. Journal of Heuristics, 2000, 6(3);419-431
- [13] Jaszkiewicz A. Genetic local search for multi-objective combinatorial optimization [J]. European Journal of Operational Research, 2002, 137(1);50-71
- [14] Sindhy K, Deb K, Miettinen K. A local search based evolutionary multi-objective approach for fast and accurate convergence [C]//Proceedings of the Parallel Problem Solving from Nature-PPSN X. Berlin: Springer, 2008;815-824
- [15] Talbi E G, Rahoual M, Mabed M, et al. A hybrid evolutionary approach for multicriteria optimization problems: Application to the flow shop [C]//Proceedings of the Evolutionary Multi-Criterion Optimization. Berlin: Springer, 2001;416-428
- [16] Sindhy K, Deb K, Miettinen K. Improving convergence of evolutionary multi-objective optimization with local search: A concurrent-hybrid algorithm [J]. Natural Computing, 2011, 10(4); 1407-1430
- [17] Miettinen K. Nonlinear Multiobjective Optimization [M]. Boston: Kluwer, 1999
- [18] Huband S, Hingston P, Barone L, et al. A review of multiobjective test problems and a scalable test problem toolkit [J]. IEEE Transactions on Evolutionary Computation, 2006, 10 (5); 477-506
- [19] Okabe T, Jin Y C, Olhofer M, et al. On test functions for evolutionary multi-objective optimization [C]//Proceedings of Parallel Problem Solving From Nature-PPSN VIII. Berlin: Springer, 2004;792-802
- [20] Deb K, Sinha A, Kukkonen S. Multi-objective test problems, linkages, and evolutionary methodologies [C]// Proceedings of the 8th annual conference on Genetic and Evolutionary Computation (GECCO'06). New York: ACM, 2006;1141-1148
- [21] Li H, Zhang Q F. A multi-objective differential evolution based on decomposition for multi-objective optimization with variable linkages [C] // Proceedings of Parallel Problem Solving from Nature—PPSN IX. Berlin: Springer, 2006;583-592