

灰熵并行分析法多目标次序敏感性研究^①

朱光宇, 贺利军

(福州大学 机械工程及自动化学院, 福州 350108)

摘 要: 针对多目标优化算法对目标次序表现敏感这一特点, 提出对灰熵并行分析法的目标次序敏感性进行分析. 以多目标流水车间调度问题为对象, 建立不同目标次序的多目标流水车间调度模型, 以基于灰熵并行分析的 GA 优化不同次序的多目标模型. 定义敏感系数, 绘制敏感系数曲线图. 实验结果表明, 灰熵并行分析法对目标次序敏感, 按目标值大小排列的升序和降序并不是最好的次序, 震荡次序敏感系数最小. 表明多目标优化时要选择合理目标次序以获得更好的优化结果. 算法适应度值同样对目标次序敏感, 对算法搜索效果影响明显.

关键词: 目标次序; 灰熵并行分析; 敏感性分析; 多目标流水车间调度; 敏感系数

Multi-Objective Order Sensitivity Study on Grey and Entropy Parallel Analysis Method

ZHU Guang-Yu, HE Li-Jun

(College of Mechanical Engineering & Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: In view of the characteristic that multi-objective optimization algorithms are sensitive to objective order, objective order sensitivity analysis based on grey and entropy parallel analysis is proposed. Taking multi-objective flow shop scheduling problem as object, flow shop scheduling model of different objective order is established, and GA based on grey and entropy parallel analysis is used to optimize the multi-objective model of different objective order. Then sensitive coefficient is defined and graphics of sensitive coefficient is drew. The experiment results show that grey and entropy parallel analysis is sensitive to objective order, ascending and descending order ordered by the size of objective value are not the best, and sensitive coefficient of shock order is the smallest. It indicates that we should select reasonable objective order to get better optimization results for multi-objective optimization. Also algorithm fitness value is sensitive to objective order, which effects significantly on the algorithm performance.

Key words: objective order; grey entropy parallel analysis; sensitivity analysis; multi-objective flow shop scheduling; sensitive coefficient

多目标优化自从被提出以来就得到了各应用领域的持续关注. 多目标优化问题中各个目标间往往相互冲突制约, 某个目标性能的上升可能会导致一个甚至几个目标性能的下降. 使所有目标都达到最优是不可能实现的, 只能找到一组相互平衡的解, 即 Pareto 最优解^[1]. 多目标优化问题的这种特性使得其比单目标优化问题实现起来更加困难.

多目标进化算法^[2](MOEA)可以有效处理不连续、非凸等复杂问题, 在多项式时间或接近多项式时间内

找到可接受的最优解或次优解, 较快的收敛到 Pareto 前端, 已经成为处理多目标优化问题的主流方法, 且已成功应用于许多工业领域^[3]. 多目标进化算法适应度分配机制是决定算法性能和区分算法种类的关键因素. 现有多目标进化算法适应度分配机制主要有基于 Pareto 优先排序关系^[4]和基于目标权重^[5]两种. 近年来出现了一些新型适应度分配策略, 如文献[6,7]采用灰关联分析中的灰色关联度分别作为 GA 和 PSO 的适应度进行多目标优化, 利用灰色关联度评判 Pareto 解好

^① 基金项目:福建省教育厅科技项目(JK2013006);福建省自然科学基金(2014J01183);福建省高端装备协同创新中心项目(00205006103)

收稿时间:2015-09-05;收到修改稿时间:2015-10-19

坏,可以得到较好的 Pareto 前端.但灰关联分析容易导致信息丢失和陷入局部关联倾向,其计算的是灰关联系数的平均值,灰色关联度倾向于灰关联系数大的目标,没有充分挖掘目标数据间的效用信息.针对这一缺点,本文作者在文献[8-10]中对灰色关联度进行了改进,以信息熵与灰关联分析结合,提出灰熵并行分析(Grey Entropy Parallel Analysis,GEPA)法,弥补单纯灰关联分析的缺点,以灰熵并行关联度(Grey Entropy Parallel Relative Grade, GEPRG)作为 PSO、DE、GA 算法的适应度,分别优化了三种不同问题的三目标优化问题.

然而多目标优化算法对目标次序往往表现得很敏感,目前多目标次序敏感性分析方面的研究还相对较少,灰熵并行分析法中目标次序的敏感性也尚未可知.本文主要研究问题是,以流水车间调度问题为研究对象,建立多目标数学模型,改变多目标模型的目标次序,以基于灰熵并行分析的 GA 优化不同目标次序的多目标调度模型,定义敏感系数,分析灰熵并行分析法多目标优化的目标次序敏感性.其研究意义在于判断灰熵并行分析法多目标优化是否对目标次序敏感,并判断哪种目标次序可以得到更优的结果,为灰熵并行分析法多目标优化选出较合理的目标次序.

1 基于灰熵并行分析的多目标优化

灰熵并行分析是灰关联分析^[11]与信息熵理论^[12]结合成的方法,以熵值对目标进行权重赋值,是一种更客观更全面的分析法.其特点在于利用灰关联分析和信息熵并行的对序列数据进行相似性分析,以 GEPRG 作为比较序列与参考序列相似程度的度量.灰熵并行分析法应用于多目标优化实现过程如下:

1.1 构造理想解序列与 Pareto 解比较序列

(1) 构造理想解序列

以启发式进化算法对问题各子目标实现 k 次单目标优化,各子目标的单目标优化解的平均值构成理想解序列 $Y_0 = \{f_1(0), f_2(0), \dots, f_M(0)\}$. M 为目标个数, $f_M(0)$ 为第 M 个子目标的单目标优化解的平均值.

(2) 构造 Pareto 解比较序列

多目标优化时计算多目标函数值,各目标值构成 Pareto 解比较序列 $Y_i = \{f_1(i), f_2(i), \dots, f_M(i)\}$, M 为目标个数, $f_M(i)$ 为 Pareto 解比较序列中第 M 个子目标的多目标优化函数值.

1.2 理想解序列与 Pareto 解比较序列的灰关联分析

灰关联分析的基本思想是根据序列曲线几何形状的相似程度来判断其联系是否紧密.曲线越接近,相应序列之间灰关联度就越大,反之就越小^[11].因此可以将灰关联分析法应用于多目标优化来分析理想解序列与 Pareto 解比较序列的相似程度.灰关联分析法对理想解序列与 Pareto 解比较序列进行关联分析的过程如下:

(1) 区间化

通过区间化算子对理想解序列与 Pareto 解比较序列的各子目标均值化处理,以消除目标间数量级和量纲的影响,区间化算子公式如下

$$f'_k(i) = \frac{\max(Y_i) - f_k(i)}{\max(Y_i) - \min(Y_i)} \quad (1)$$

$$k = 1, 2, 3, \dots, M; i = 0, 1, 2, 3, \dots, N$$

(2) 求差序列

$$\Delta_i(k) = |f'_k(0) - f'_k(i)|,$$

$$\text{则 } \Delta_i = (\Delta_i(1), \Delta_i(2), \dots, \Delta_i(n)) \quad (2)$$

$$k = 1, 2, 3, \dots, M; i = 1, 2, 3, \dots, N$$

(3) 求两级最大差和最小差

$$E = \max_i \max_k \Delta_i(k) \quad (3)$$

$$e = \min_k \min_i \Delta_i(k) \quad (4)$$

$$k = 1, 2, 3, \dots, M; i = 1, 2, 3, \dots, N$$

(4) 求灰关联系数 $r(f_k(0), f_k(i))$

$$r(f_k(0), f_k(i)) = \frac{e + \rho \times E}{|f'_k(0) - f'_k(i)| + \rho \times E} \quad (5)$$

其中 $\rho \in (0, 1)$ 为分辨系数 $k = 1, 2, 3, \dots, M; i = 1, 2, 3, \dots, N$.

1.3 熵值权重计算

(1) 计算 1.2 节(1)中 Pareto 解序列区间化后各子目标所占比重,即

$$P_k(i) = (1 + f'_k(i)) / \sum_{k=1}^M (1 + f'_k(i)), \quad (6)$$

其中 $P_k(i)$ 为第 i 个 Pareto 解序列的第 k 个目标所占比重,

$$\sum_{k=1}^M P_k(i) = 1, \quad k = 1, 2, 3, \dots, M,$$

$$i = 1, 2, 3, \dots, N.$$

(2) 计算 Pareto 解序列各子目标的信息熵

$$e_k = -\frac{1}{\ln M} \sum_{i=1}^N (P_k(i) \times \ln P_k(i)) \quad (7)$$

其中 e_k 表示所有序列第 k 个目标的信息熵值, $k = 1, 2, 3, \dots, M, i = 1, 2, 3, \dots, N$.

(3) 计算 Pareto 解序列各子目标的熵值权重

$$w_k = \frac{\sum_{i=1}^M e_i + 1 - 2e_k}{\sum_{k=1}^M (\sum_{i=1}^M e_i + 1 - 2e_k)} \quad (8)$$

其中 w_k 表示所有序列第 k 个目标的熵值权重,

$$\sum_{k=1}^M w_k = 1, \quad k=1,2,3,\dots,M, \quad i=1,2,3,\dots,N.$$

1.4 计算灰熵并行关联度 $R(Y_0, Y_i)$

$$R(Y_0, Y_i) = \sum_{k=1}^M (w_k \times r(f_k(0), f_k(i))) \quad (9)$$

式中 $R(Y_0, Y_i)$ 为第 i 个 Pareto 解序列与理想解序列的 GEPRG, $r(f_k(0), f_k(i))$ 为灰关联系数, w_k 为第 k 个目标的熵值权重, $k=1,2,3,\dots,M, i=1,2,3,\dots,N$

由以上分析可知, 灰熵并行分析的多目标优化是在以目标函数值组成的数据序列基础上计算不同序列的灰熵并行关联度, 从而以灰熵并行关联度值大小选择最优的目标函数值序列. 当目标次序改变时, 目标函数值组成的数据序列也会发生变化, 最终灰熵并行关联度值也会变化, 所以理论上灰熵并行分析的多目标优化对目标次序敏感.

2 多目标流水车间调度问题、数学模型及求解步骤

2.1 多目标流水车间调度问题描述

本文多目标流水车间调度问题具体描述如下: 制造商从销售商接到一订单, 需要加工一批数量为 n 的工件, 完工后运输到销售商. 制造商工厂为典型 Flow Shop 生产类型, 即 n 个工件由 m 台机器加工, 每个工件具有一定数量的工序, 每个工件以相同顺序访问所有机器, 工件在机器上的加工时间固定^[13]. 同一时刻一个工件只能在一台机器上加工, 一台机器只能加工一个工件, 机器无抢占无等待. 受到销售商交货期影响, 制造商必须在合理时间完成工件, 否则超过交货期完工的工件将受到拖期惩罚, 产生拖期成本. 本文问题是确定工件加工顺序, 使工件最大完工时间、最大拖期时间、总流程时间三个目标最小.

2.2 多目标数学模型

本文建立的多目标模型为 $F = \min(f_1, f_2, f_3)$, 其中

$$f_1 = \max\{C_{im} \mid i \in 1, 2, \dots, n\} \quad (10)$$

$$f_2 = \max\{(0, (C_{im} - D_i)) \mid i \in 1, 2, 3, \dots, n\} \quad (11)$$

$$f_3 = \sum_{i=1}^n C_{im} \quad (12)$$

s.t.

$$C_{11} \geq T_{11} \quad (13)$$

$$C_{1k} \geq C_{1(k-1)} + T_{1k}, \quad k=2, 3, \dots, m \quad (14)$$

$$C_{i1} \geq C_{(i-1)1} + T_{i1}, \quad i=2, 3, \dots, n \quad (15)$$

$$C_{ik} \geq \max\{C_{i(k-1)}, C_{(i-1)k}\} + T_{ik}, \quad i=2, 3, \dots, n; k=2, 3, \dots, m \quad (16)$$

f_1 为工件最大完工时间, f_2 为最大拖期时间, f_3 为总流程时间. C_{im} 、 D_i 分别为工件 i 最后完工时间、交货期; T_{ik} 为工件 i 的第 k 道工序所需加工时间; C_{ik} 表示工件 i 的第 k 道工序完工时间.

依据排列组合, 三个目标将有 $A_3^3 = 6$ 种排序, 即次序 1(S1): $F = \min(f_1, f_2, f_3)$, 次序 2(S2): $F = \min(f_1, f_3, f_2)$, 次序 3(S3): $F = \min(f_2, f_1, f_3)$, 次序 4(S4): $F = \min(f_2, f_3, f_1)$, 次序 5(S5): $F = \min(f_3, f_1, f_2)$, 次序 6(S6): $F = \min(f_3, f_2, f_1)$.

从以上分析可知, 多目标流水车间调度问题中, 多目标函数的次序会有敏感性. 一定目标数量的多目标模型可以有多种不同的目标排列方式, 不同目标次序的多目标模型最终的优化结果会有不同, 这导致多目标流水车间调度问题对目标排列次序敏感. 多目标流水车间调度问题多目标次序敏感性研究的意义在于, 可以为实际的多目标流水车间调度问题提供一种更合理的多目标优化次序, 获得更好的优化结果. 本文以灰熵并行分析的进化算法分别优化这 6 种不同次序的多目标调度模型, 并分析其敏感性.

2.3 基于 GEPA 的 GA 求解不同目标次序的多目标流水车间调度问题

GA 是一种基于自然物种进化的启发式进化算法, 由于其操作简单、易于实现及优秀的全局搜索能力等优点, GA 被广泛用于多目标流水车间调度等领域, 都取得了较好的优化结果. 所以本文以基于灰熵并行分析的 GA(GEPA_GA)求解不同目标次序的多目标流水车间调度问题, 证明 GA 进化算法可以有效地和灰熵并行分析法结合, 并可以有效地解决不同目标次序的多目标流水车间调度问题. 图 1 为 GEPA_GA 算法及敏感性分析流程图, 具体求解步骤如下:

Step1. 构造理想解序列与 Pareto 解比较序列. 利用单目标 GA 对问题的各目标单目标优化 k 次, 单目标优化解均值构成理想解序列, 依据排列组合理想解序

列有 6 种, 即 $Y_0^n, n=1, \dots, 6$, 理想解序列排序与 2.2 节多目标排序相对应, 6 种理想解序列只是排序不一样, 其各目标值大小相同。

Step2. 初始化种群, 构造 Pareto 解比较序列. 对 2.2 节每一种次序的多目标模型, 产生初始种群, 生成 NP 个个体 X_i^{gen} , gen 为种群当代代数. 利用式 (11)-(13) 计算个体的多目标函数值, 各目标值构成 Pareto 解比较序列, 得到每种多目标次序的 Pareto 解比较序列 Y_i^{gen} .

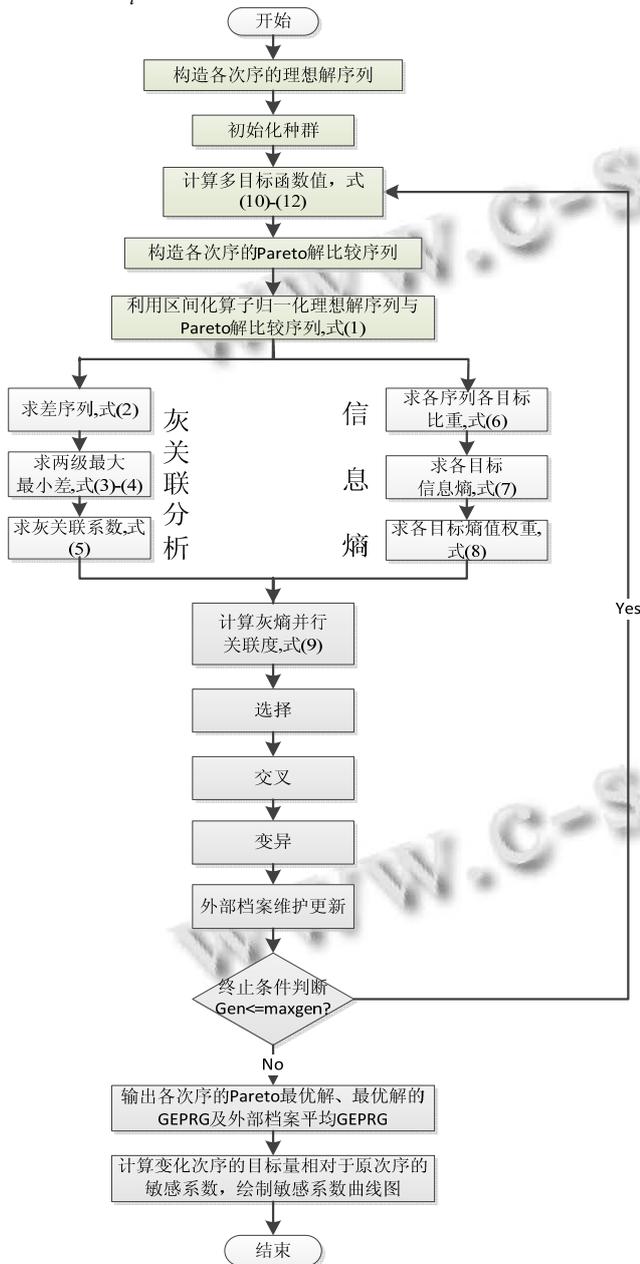


图 1 GEPA_GA 算法及敏感性分析流程

Step3. 灰熵并行分析. 对每种次序进行灰熵并行

分析, 利用式(10)计算 Pareto 解序列 Y_i^{gen} 与相对应理想解序列 Y_0 的灰熵并行关联度, 并将其作为 GA 适应度值引导算法进化。

Step4. 选择操作. 采用二元锦标赛^[14]方法进行选择。

Step5. 交叉操作. 采用部分映射交叉(PMX)^[14]方法交叉。

Step6. 变异操作. 采用互换变异(SAWP)^[14]方法变异。

Step7. 外部档案维护和更新. 通过非劣排序以及拥挤距离^[13]对每代产生的非劣解进行计算, 将每次迭代产生的解与外部档案 Pareto 解进行优劣比较, 通过精英保留策略使得种群的多样性得到提升。

Step8. 终止条件判断. 群体进化次数达到要求的最大代数 $maxgen$ 时迭代终止; 否则, $gen=gen+1$ 转 Step3。

Step9. 输出每种次序下的 Pareto 最优解、最优解对应的灰熵并行关联度以及外部档案个体的平均灰熵并行关联度。

Step10. 敏感性分析. 确定原始次序及变化次序, 分别计算变化次序的目标量相对于原始次序的敏感系数, 绘制敏感系数图。

3 敏感性系数定义

为研究灰熵并行分析法求解多目标流水车间调度问题的目标次序的敏感性, 为将目标次序的敏感性更好的量化分析, 提出以敏感系数衡量目标次序的敏感性. 不同次序的目标函数值和适应度值变化大, 则敏感系数大, 目标次序敏感性大。

敏感性分析是在确定性分析的基础上, 重复分析不确定因素变化对效益评价指标的影响程度, 其已被应用于许多不同的领域^[15,16]. 敏感性分析常以敏感系数(Sensitivity Coefficient, SC)反映敏感程度. 传统的敏感系数计算公式为: 敏感系数=目标值变动百分比/参量值变动百分比. 敏感系数越大则表示目标量对参量变化的敏感程度越高; 反之, 敏感程度越低。

本文多目标次序问题敏感性分析的目标量为模型的两个目标(f_1, f_2, f_3)最优解、最优解对应的 GEPRG 及平均 GEPRG; 参量即影响因素为目标次序变化, 而目标次序变化难以量化, 这将进一步导致敏感系数无法量化. 为了有效计算敏感系数, 本文将传统的敏感系数计算公式进行改进。

定义本文中参量值变动为目标位置的变动, 参量值变动百分比为位置发生变动的目标数与目标总数的比值. 则本文中敏感系数 $SC = \text{目标量变动百分比} / (\text{位置发生变动的目标数} / \text{目标总数})$. 如以次序 S1 为原始次序, 次序 S2~S6 为变化次序. 次序 S1: $F = \min(f_1, f_2, f_3)$ 与次序 S2: $F = \min(f_1, f_3, f_2)$, 次序 S2 相对于次序 S1 只有目标 f_2 与 f_3 位置发生变动, 则参量值变动百分比为 $2/3$, 目标 f_1, f_2, f_3 的敏感系数计算公式分别为 $SC1 = \frac{(S2 \text{中} f_1 \text{值} - S1 \text{中} f_1 \text{值}) / S1 \text{中} f_1 \text{值}}{2/3}$, $SC2 = \frac{(S2 \text{中} f_2 \text{值} - S1 \text{中} f_2 \text{值}) / S1 \text{中} f_2 \text{值}}{2/3}$, $SC3 = \frac{(S2 \text{中} f_3 \text{值} - S1 \text{中} f_3 \text{值}) / S1 \text{中} f_3 \text{值}}{2/3}$. 同样最优解的 GEPRG 敏感系数 $SC4 = \frac{(S2 \text{中最优解 GEPRG 值} - S1 \text{中最优解 GEPRG 值}) / S1 \text{中最优解 GEPRG 值}}{2/3}$ 和平均 GEPRG 敏感系数 $SC5 = \frac{(S2 \text{平均 GEPRG 值} - S1 \text{平均 GEPRG 值}) / S1 \text{平均 GEPRG 值}}{2/3}$. 同理可以计算出次序 S3~S6 相对于原次序 S1 的各个敏感系数.

4 仿真实验及结果分析

参考文献[9]方法对制造商工厂产生 1 个调度问题实例, 即 $n=20$ 工件, $m=10$ 台机器的 20×10 问题. 调度问题实例按目标函数值升序、震荡、降序产生 6 种不同次序, 即升序: S1, 震荡: S2, S3, S4, S5, 降序: S6. 以基于灰熵并行分析的 GA 优化不同目标次序的多目标流水车间调度问题, 获得多目标 Pareto 最优解、最

优解的 GEPRG 以及外部档案中所有解得平均 GEPRG 进行敏感性分析, 绘制敏感系数曲线图.

4.1 实验参数设置

算法初始种群规模 $NP = 30$, 外部档案数 $W_{\max} = 50$, 最大迭代次数 $\max gen = 300$. GA 交叉概率 $P_c = 0.8$, 变异概率 $P_m = 0.1$. 单目标优化次数 $k = 20$. 灰关联分析分辨系数 $\rho = 0.5$.

4.2 实验结果分析

表 1 为调度问题实例在 6 种不同次序下的优化结果. 从表中可以看出, 调度实例的不同次序理想解的目标值都相同, 最终以基于灰熵并行分析的 GA 优化得到的多目标 Pareto 最优解、最优解的 GEPRG 及平均 GEPRG 都不同. 表明以基于灰熵并行分析的 GA 优化多目标流水车间调度问题时, 优化结果对目标次序敏感.

为判断哪种次序下可以获得更好的优化结果, 以多目标最优解的 GEPRG 及平均 GEPRG 作为优化结果的判断标准, 因为 GEPRG 表征的是多目标 Pareto 最优解与理想解的相似程度, GEPRG 值越大, 多目标 Pareto 最优解越好. 表 1 中次序 S4 所得多目标最优解的 GEPRG 及平均 GEPRG 较大; 因此, 在用灰熵并行分析法优化多目标流水车间调度问题时, 次序 S3 和 S4 可能获得更好的优化结果. 在解决实际优化问题时, 需要对目标函数值为震荡形式的各种可能性进行仿真实验, 由此找出最好的最优解.

表 1 20x10 调度实例 6 种不同次序的优化结果

多目标次序	理想解	多目标 Pareto 最优解	最优 GEPRG	平均 GEPRG
S1: (f_1, f_2, f_3)	(744, 1804, 23644)	(740, 1932, 24889)	0.9347	0.8208
S2: (f_1, f_3, f_2)	(744, 23644, 1804)	(733, 24079, 1897)	0.9375	0.8313
S3: (f_2, f_1, f_3)	(1804, 744, 23644)	(1964, 740, 24305)	0.9458	0.8498
S4: (f_2, f_3, f_1)	(1804, 23644, 744)	(1888, 23661, 751)	0.9746	0.8657
S5: (f_3, f_1, f_2)	(23644, 744, 1804)	(24249, 731, 1840)	0.9273	0.8478
S6: (f_3, f_2, f_1)	(23644, 1804, 744)	(23891, 1881, 727)	0.9074	0.8432

图 2 为调度问题实例的敏感系数图. 以上分析已经明确震荡次序中的 S3 和 S4 可以获得更优的结果, 调度实例中都以次序 S4 为原次序, 其他 5 种次序为变化次序. 敏感系数越大或者不同次序的敏感系数变化比率越大, 则表明目标次序对目标量影响越大. 图中各次序敏感系数都是相对于原次序 S4 计算而来, 其中曲线 SC1-SC3 分别表示不同次序下目标 f_1, f_2, f_3 的敏感

系数; 曲线 SC4 表示不同次序下最优解的 GEPRG 敏感系数; 曲线 SC5 表示不同次序下平均 GEPRG 敏感系数. S1-S3 及 S5-S6 任一次序上的 5 个点表示同次序的目标 f_1, f_2, f_3 的敏感系数、最优解的 GEPRG 敏感系数、平均 GEPRG 敏感系数.

对曲线 SC1-SC3, 其敏感系数反映了不同次序对目标值的影响. 图中曲线 SC1-SC3 敏感系数值都较小,

但有的目标在不同次序的敏感系数变化较大. 如图 2 中目标 f_2 的敏感系数 SC2 峰值与谷值变化比为 $\frac{|0.0739-(-0.0254)|}{0.0254} \times 100\% = 390.6\%$; 敏感系数变化比较大反映了次序对目标值影响明显. 对曲线 SC4-SC5, 其敏感系数反映的是不同次序对算法适应度值的影响. 图 2 中最优解 GEPRG 及平均 GEPRG 的敏感系数峰值与谷值变化比分别为 $\frac{|-0.0075-(-0.0443)|}{0.0443} \times 100\% = 83.1\%$, $\frac{|0.0371-(-0.0519)|}{0.0519} \times 100\% = 171.5\%$. 适应度值敏感系数数值较大

且其变化比也大, 表明目标次序对适应度值影响明显, 对算法搜索效果影响较大.

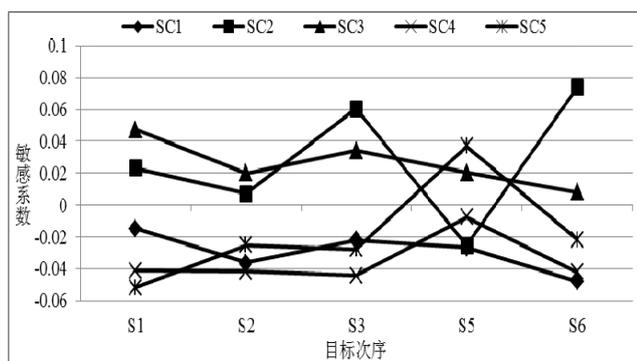


图 2 20x10 调度实例敏感系数曲线

对 S1-S3 及 S5-S6 任一次序, 其 5 个点表示同次序的 5 个敏感系数. 为进一步分析不同次序的敏感性, 取同次序平均敏感系数(5 个敏感系数绝对值的均值)作为判断标准. 平均敏感系数越大则次序敏感性越大; 反之越小. 图 2 中各次序的平均敏感系数分别为 S1: 0.0356, S2: 0.0259, S3: 0.0377, S5: 0.0234, S6: 0.0387. 总体来看, 降序的平均敏感系数较大, 而多数震荡次序的平均敏感系数较小, 说明震荡次序下敏感性较小. 进一步说明解决实际优化问题时, 需要对目标函数值为震荡形式的各种可能性进行仿真实验, 由此找出最好的最优解.

5 结论

GEPA 已经被证实可以和进化算法有效结合求解多目标优化问题. 在现有多目标流水车间调度问题研究基础上建立不同次序多目标流水车间调度模型, 以 GEPA_GA 进行求解, 分析目标次序敏感性. 主要工作归纳为以下 2 个方面: (1)建立基于 GEPA 的 GA 算法, 求解不同目标次序的多目标流水车间调度问题, 绘制流程图; (2)定义敏感系数, 绘制敏感系数曲线图, 进

行优化结果敏感性分析及算法适应度值敏感性分析, 并判断哪种目标次序可以获得更优的结果. 综上所述, 灰熵并行分析优化多目标流水车间调度问题时, 其优化结果受目标次序的影响程度明显; 进行优化多目标时, 应该选择合理的目标次序以获得更好的优化结果.

参考文献

- 1 Bosman P. On gradients and hybrid evolutionary algorithms for real-valued multiobjective optimization. *IEEE Trans. on Evolutionary Computation*, 2012, 16(1): 51-69.
- 2 Zhou AM, Qu BY, Li H, Zhao SZ, Suganthan PN, Zhang QF. Multi objective evolutionary algorithms: A survey of the state of the art. *Swarm and Evolutionary Computation*, 2011, 1(1): 32-49.
- 3 Coello CAC, Lamont GB. *Applications of Multi-Objective Evolutionary Algorithms*. Singapore: World Scientific Publisher, 2004.
- 4 Deb K, Pratap A, Agarwal S, Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Trans. on Evolutionary Computation*, 2002, 6(2): 182-197.
- 5 Murata T, Ishibuchi H. MOGA: Multi-objective genetic algorithms. *Proc. of the 1995 IEEE International Conference on Evolutionary Computation*. 1995.
- 6 李俊峰,戴文战.基于遗传算法和灰色关联度的多目标问题求解方法研究.第 25 届中国控制会议.2006.557-560.
- 7 Liu H, Zhang QS, Yao LG. Multi-objective particle swarm optimization algorithm based on grey relational analysis with entropy weight. *The Journal of Grey System*, 2010, 22: 265-274.
- 8 朱光宇,冯子超,杨志锋.灰熵并行分析引导 PSO 求解多目标优化问题.系统工程与电子技术,2014,36(11):2233-2238.
- 9 朱光宇,陈旭斌,刘艳立.基于灰熵关联分析的流水车间多目标调度优化及算法实现.控制与决策,2014,29(1):135-140.
- 10 路军营,朱光宇.基于灰熵关联分析的表面贴装多目标优化.计算机集成制造系统,2013,4:766-773.
- 11 党耀国,刘思峰.灰色预测与决策模型研究.北京:科学出版社,2009.
- 12 张继国,Vijay PS.信息熵理论与应用.北京:中国水利水电出版社,2012.
- 13 雷德明.现代制造系统智能调度技术及其应用.北京:中国电力出版社,2012.
- 14 王凌.车间调度及其遗传算法.北京:清华大学出版社,2003.
- 15 丘意书,梁金刚,余健开,王侃.RMC 程序敏感性分析功能的并行策略与验证.核动力工程,2015,(3):152-156.
- 16 余建星,刘春辉,何宁,周清基,孟庆龙,曾华章,唐必意.深水跨接管热应力计算及敏感性分析.天津理工大学学报,2015,(1):1-6.