

基于灰熵并行分析法的多目标作业车间调度优化^①

朱光宇, 杨志锋, 陈旭斌

(福州大学 机械工程及自动化学院, 福州 350108)

摘要: 提出利用信息熵理论与灰色关联分析法并行地处理多目标优化问题, 将多目标优化的目标值构成数据序列, 挖掘序列关系实现多目标优化. 首先, 并行的对目标值序列计算灰关联系数以及熵值权重, 之后将信息熵与灰关联系数结合计算灰熵并行关联度, 建立灰熵并行分析法. 最终, 利用灰熵并行关联度作为优化算法的适应值计算策略, 以该策略引导智能优化算法进化. 建立作业车间调度问题的三目标优化模型, 以灰熵并行分析法为基础, 分别应用差分算法、遗传算法解决三目标作业车间调度问题, 验证新方法的可行性. 实验表明: 新方法均能使两算法收敛且得到分布均匀的 Pareto 前端, 表明其有效和可靠. 同时, 差分算法得到的解较遗传算法的解具有明显的优势.

关键词: 多目标优化; 作业车间调度; 灰熵并行分析; 灰熵并行关联度; 差分算法

Multi-Objectives Job Shop Scheduling Optimization Based on Grey Entropy Parallel Analysis Method

ZHU Guang-Yu, YANG Zhi-Feng, CHEN Xu-Bin

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

Abstract: In this paper, the multi-objective optimization problem was solved with the theory of information entropy and gray correlation analysis method in parallel. The objective function values were used to structure a data sequence. The multi-objective optimization was complicated by using data sequence relation model. Firstly, the grey relational coefficient and the entropy weight were calculated in parallel based on multi-objective value sequence. Then, the information entropy and the grey relational coefficient were combined and used to calculate the grey entropy parallel relational degree (GEPRD), that is, the grey entropy parallel analysis method was built. Finally, the GEPRD was used as the fitness value calculation strategy to guide the evolution of the heuristic algorithm. The Tri-objectives optimization model of job shop scheduling problem was established. In order to verify the feasibility of the new method, the grey entropy parallel analysis method was testified with differential algorithm and genetic algorithm respectively to solve the Tri-objectives job shop scheduling problem. Experimental results show that this method is effective, with this method, the convergent and uniform distribution of Pareto can be obtained by this two algorithms. Indicated that it was effective and reliable. The solutions obtained by the difference algorithm are better than those of genetic algorithm.

Key words: multi-objective optimization; job shop scheduling; grey entropy parallel analysis; grey entropy parallel relation degree; differential algorithm

作业车间调度(job-shop scheduling)问题属于开环调度问题, 是个典型的NP-hard 难题. 其研究以求解单目标为主^[1]. 实际生产中调度问题一般有着多个相互

冲突的目标, 在生产过程中需考虑工件总流程时间、最大完成时间、最大延迟时间等调度性能指标^[2], 因此单目标优化对实际生产车间调度问题并不完全适用.

① 基金项目:福州市科技计划(2012-G-131);福建省教育厅科技项目(JK2013006);福建省自然科学基金(2014J01183)

收稿时间:2014-08-11;收到修改稿时间:2014-09-09

与单目标优化不同,多目标优化得到的结果是非劣解,而非劣解往往不止一个,如何取舍,需选择某种方式折中处理。目前,多目标作业车间调度求解的方法主要有:精确算法和启发式算法。精确算法包括整数规划法和分支定界法;启发式算法包括基于调度规则的方法、人工智能、神经网络、领域搜索方法等。精确算法主要解决小规模调度问题,启发式算法由于在可接受的时间内能够得到问题的较满意解为人们广泛使用^[3]。文献[4]设计了混合粒子群算法,采用变邻域搜索算法对非劣解深入搜索,从而解决作业车间调度问题。文献[5]提出了一种混合禁忌搜索算法最小化最大完工时间,机器的总工作量和关键设备的工作量三个目标。文献[6]设计了两种采用新型 Pareto 基础模块的遗传算法解决该问题。对于多目标优化问题,一方面,要解决各目标之间的冲突,另一方面,要解决如何在所求的 Pareto 解集中取得一组分布均匀和相对较好的 Pareto 最优解集和 Pareto 前端。在该领域,有研究者应用灰关联分析法来解决 Pareto 最优解集和 Pareto 前端的取舍^[7,8],即利用灰关联度评判 Pareto 解好坏,从而来选择相对较好的 Pareto 最优解集和 Pareto 前端。然而,单纯的灰关联分析存在局部关联点倾向的问题。

王娜^[9]等人采用信息熵理论来维护多目标优化的非支配解集,以保持解的多样性和分布的均匀性。周奇^[10]等人将信息熵权的 TOPSIS 排序引入多目标优化模型的求解中,对 Pareto 方案排序供决策者选择。单纯利用信息熵解决多目标优化问题忽略了对各目标之间的关联信息的有效利用。

本文将灰关联分析和信息熵理论结合,将多目标优化的目标值构成数据序列,挖掘序列间的关系建立灰熵并行分析法,既能有利于避免人为因素对权重的干扰。同时能够充分利用各目标值序列之间的关联信息。新方法的实现基础是对原始数据序列求灰关联系数,同时对该数据序列并行的计算信息熵及熵值权重,由此来确定多目标优化问题中各目标的内部关系,避免发掘数据序列关系时人为因素的直接和间接计算误差的影响。针对作业车间多目标优化问题,建立以工件总流程时间、最大完成时间、最大延迟时间为子目标的多目标作业车间模型。利用信息熵理论与灰色关联分析并行的处理各子目标数据,利用灰熵并行关联度评判 Pareto 解好坏。将基于灰熵并行分析法的

差分算法和遗传算法用于求解典型 jobshop 调度问题,通过仿真实验验证灰熵并行分析法的有效性,并对两算法的优劣进行对比。

1 问题描述

本文作业车间调度问题需要解决的是:在确定约束的条件下,调度顺序能够满足最小化以下三方面的要求,即工件总流程时间、最大完成时间及最大延迟时间。

1.1 变量

1) 给定参数

n 为工件数, m 为机器数, $t_{i,q}$ ($i=1,2,3,\dots,n,q=1,2,3,\dots,m$)表示第 i 个工件在第 q 台机器上的加工时间, S 为一个足够大的整数

2) 决策变量

$a_{i,h,q}$ 和 $x_{i,j,q}$ 分别为指示系数、指示变量。具体是:

$$a_{i,h,q} = \begin{cases} 1, & \text{如果机器 } h \text{ 先于机器 } q \text{ 加工工件 } i \\ 0, & \text{其他情况} \end{cases} \quad (1)$$

$$x_{i,j,q} = \begin{cases} 1, & \text{如果工件 } i \text{ 先于工件 } j \text{ 在机器 } q \text{ 上加工} \\ 0, & \text{其他情况} \end{cases} \quad (2)$$

1.2 作业车间调度的数学模型

采用基于时间性能的指标,即最大程度满足市场的快速需求和客户对交货期的要求,作业车间调度问题的多目标函数描述为:

$$Y = \min(f_1, f_2, f_3) \quad (3)$$

$$S.t. \quad c_{i,q} - t_{i,q} + S(1 - a_{i,h,q}) \geq c_{i,h} \quad (4)$$

$$c_{j,q} - t_{j,q} + S(1 - x_{i,j,q}) \geq c_{i,q} \quad (5)$$

$$c_{i,j} \geq 0 \quad (6)$$

$$i, j = 1, 2, \dots, n; \quad h, q = 1, 2, \dots, m$$

其中, f_1 为最大加工完成时间, $f_1 = C_{\max} = \max_{1 \leq q \leq m} (\max_{1 \leq i \leq n} c_{i,q})$, $c_{i,q}$ 表示工件 i 在机器 q 上的加工完成时间,在 $m \times n$ 的 jobshop 调度中,目标函数值为第 n 个工件的最后一道工序的完工时间,但是在 jobshop 中,第 n 个工件的完工时间不一定是所有工件的最小完成时间,需要先求出每个工件每道工序在机器上的加工完成时间,再从选定的加工机器依次计算每台机器最后工件的完成时间,取其中的最大值就是目标函数值。

f_2 为最大延迟时间, $f_2 = L_{\max} = \max_{1 \leq i \leq n} \{c_i - due(i)\}$, c_i 为工件 i 的完成时间, $due(i)$ 为工件 i 的交货期,根据

工件 i 的总流程时间和工件 i 的交货期求得工件 i 的延迟时间, 然后对 n 个工件的延迟时间求最大值.

f_3 为总流程时间. $f_3 = F_{\max} = \sum_{i=1}^n \sum_{q=1}^m c_{i,q}$, 首先累加

第 i 个工件在 m 台机器上的总加工完成时间, 得到该工件的总流程时间, 然后累加 n 个工件的总流程时间, 得到 n 个工件在 m 台机器上加工所用的总的流程时间.

式(4)为工件操作顺序约束, 即工件 i 按工艺约束必须在机器 h 上加工之后才能在机器 q 上加工. 式(5)为机器资源约束, 即同一台机器 q 只有在完成前一工件 j 的加工之后才能加工下一工件 i . 式(6)表示所有的工件的完工时间都为非负.

从多目标作业车间调度模型可知, 各目标量纲、数量级不一致, 存在一定的冲突, 且权重分配无法人为确定, 导致各目标之间的信息交互存在困难, 现有的多目标作业车间智能算法对目标的冲突往往采取人为干涉, 将各目标划分为主次要目标, 权重的分配受决策者的主观偏好影响较大^[11]. 为克服上述不足, 本文结合灰色关联度分析及信息熵理论建立灰熵关联度, 利用灰色关联度分析方法提取各目标之间的关联信息, 解决各目标之间的冲突, 保证各目标之间的信息交互, 同时引入信息熵理论, 客观地对各目标进行权重分配. 避免人为因素导致的误差.

2 灰熵并行分析法

2.1 灰色关联分析及灰色关联度

在多目标优化过程中, 灰色关联分析是对任意一个 Pareto 解 X_i 的目标函数值构成的数据序列和单目标最优解函数值构成的参考序列几何形状的接近程度进行分析, 形状越接近, 两序列之间的关联度越大, 反之则越小^[12]. 多目标作业车间调度优化时, 本文将多个目标值构成序列, 将求得的每个目标, 即函数 f_1, f_2, f_3 的单目标最优解函数值构成参考序列, 即多目标的理想解序列, 将任意一个 Pareto 解 X_i 的目标函数值序列作为比较序列, 通过比较比较序列与参考序列的关系判别解的优劣.

定义理想解目标函数值序列 $Y_0 = \{f_1(0), f_2(0), \dots, f_k(0), \dots, f_M(0)\}$, M 为目标个数. $f_M(0)$ 是第 M 个子目标作为单目标函数求得最优解的目标函数值, Y_0 为参考序列. 由任意 Pareto 解 X_i 构成比较序列 Y_i . 根据每个目标值序列提供的信息, 计算

Y_i 的第 k 个目标的灰关联系数 $r(f_k(0), f_k(i))$ ^[13].

$$r(f_k(0), f_k(i)) = \frac{\min_k (|f'_k(0) - f'_k(i)|) + \rho \max_k (|f'_k(0) - f'_k(i)|)}{(|f'_k(0) - f'_k(i)|) + \rho \max_k (|f'_k(0) - f'_k(i)|)} \quad (7)$$

其中, $f'_k(0), f'_k(i)$ 为 $f_k(0), f_k(i)$ 的规范化无量纲值. $\rho \in (0, 1)$, 一般取 $\rho = 0.5$.

利用式(7)可以进一步求出两个序列(Y_0, Y_i)的灰关联度值, 利用灰关联度值评判 Pareto 解质量的好坏. 然而, 对于多目标作业车间调度优化, 灰关联度计算会造成局部点的关联倾向和数据序列信息的丢失, 导致 Pareto 解分布不均匀.

2.2 灰熵并行关联度

为了克服上述缺陷, 本文用信息熵对目标值序列进行分析, 依据每个目标值序列提供的信息分散程度来确定其权重, 进而计算出基于熵值权重的灰熵并行关联度. 并以灰熵并行关联度值作为多目标作业车间优化的适应度值, 其中序列中信息分散程度由熵值和熵权的大小来确定, 熵值小而熵权大, 该目标提供的信息分散^[14], 即解集在该目标上较分散, 从而避免陷入局部最优解, 使多目标优化产生的 Pareto 解具有良好的分布性和均匀性, 具体过程如下:

Step 1: 对各序列 Y_0, Y_i 的值进行规范化处理.

Step 2: 计算同一比较序列 Y_i, f_1, f_2, f_3 三个子目标所占比重, 令

$$P_i(k) = f'_k(i) / \sum_{k=1}^M f'_k(i), \sum_{k=1}^M P_i(k) = 1 \quad (8)$$

Step 3: 计算 f_1, f_2, f_3 三个子目标的信息熵.

$$e_k(i) = - \frac{1}{M} \sum_{k=1}^M P_k(i) \ln P_k(i) \quad (9)$$

Step 4: 计算 f_1, f_2, f_3 三个子目标的熵值权重:

$$W_i(k) = 1 - e_i(k) / \sum_{k=1}^n 1 - e_i(k) \quad (10)$$

Step 5: 计算 Y_i 的灰熵并行关联度 $R(Y_0, Y_i)$.

$$R(Y_0, Y_i) = \sum_{k=1}^M (W_i(k) \times r(f_k(0), f_k(i))), i \in N \quad (11)$$

从计算过程可以看出, 灰熵并行关联度的计算不仅包括对作业车间调度问题的目标值序列计算灰关联系数, 还并行的对该序列计算熵值权重. 通过引入了熵值权重, 分配各个目标值的权重, 有效地解决了灰关联度计算时出现的局部点关联倾向造成的 Pareto 解不均匀的问题. 同时它从比较序列与参考序列之间各

目标的接近程度出发,进一步发掘 Pareto 解各目标之间信息,有效解决了信息丢失的问题.另外灰关联系数和熵值权重都是基于目标值序列得到的,不会引入间接误差.本文将灰熵并行关联度作为多目标作业车间调度优化的适应度值,用灰熵并行关联度引导启发式算法进化.

3 基于灰熵并行分析的差分算法实现三目标作业车间调度

以差分算法为例,结合灰熵并行分析法求解三目标作业车间调度问题,差分进化算法(Differential Evolution algorithm,DE)是一种全局并行进化算法,是针对连续空间的优化问题而提出的进化算法,是解决多目标作业车间调度优化问题常用的优化算法.本文采用 DE/rand/1/bin 模式.以整数对调度工序进行编码,通过 LOV(Largest-Order-Value)^[15]方式实现连续的实数到离散工序的转化.基于灰熵并行分析方法,利用差分算法求解三目标作业车间调度问题流程如下:

Step 1: 用差分算法求得函数 f_1, f_2, f_3 即作业车间调度三个单目标的最优解,用这些解构成多目标作业车间调度的参考序列 Y_0 ,即理想最优解.

Step 2: 初始种群,生成 NP 个个体 X_i^{gen} ($gen=0$), gen 为当前进化的代数.通过函数 f_1, f_2, f_3 求得每个个体的子目标函数值,得到 Y_i^{gen} .

Step 3: 计算灰熵并行关联度值.利用三个子目标函数值通过式(11)计算灰熵并行关联度 $R(Y_0, Y_i^{gen})$ 作为适应度值.

Step 4: 对种群进行差分变异.通过下式对第 gen 代个体 $X_{R_1}^{gen}$ 进行变异操作,得到相应的新个体 V_i^{gen+1} .

$$V_i^{gen+1} = X_{R_1}^{gen} + F(X_{R_2}^{gen} - X_{R_3}^{gen}) \quad (12)$$

其中 $R_1, R_2, R_3 \in \{1, 2, \dots, NP\}$, 且 $R_1 \neq R_2 \neq R_3 \neq i$, F 为缩放因子.

Step 5: 交叉操作.为增加群体多样性,利用下式对 X_i^{gen} 和由式(12)生成的变异个体 V_i^{gen+1} 进行交叉操作,生成实验个体 U_i^{gen+1} .

$$U_i^{gen+1} = \begin{cases} V_i^{gen+1}, & rand(q) \leq P_c \\ X_i^{gen}, & others \end{cases} \quad (13)$$

其中, $rand(q)$ 是 $[0, 1]$ 中的随机数, P_c 是交叉的概率.

Step 6: 选择操作.采用贪婪搜索策略,比较经过变异交叉后的实验个体 U_i^{gen+1} 和原个体 X_i^{gen} , 选择适

应度值较优的个体 X_i^{gen+1} 进入下一代.

$$X_i^{gen+1} = \begin{cases} U_i^{gen+1}, & R(Y_0, Y_i^{gen+1}) > R(Y_0, Y_i^{gen}) \\ X_i^{gen}, & others \end{cases} \quad (14)$$

其中, $R(Y_0, Y_i)$ 由式(11)得出的灰熵并行关联度值.

Step 7: 对外部档案进行维护和更新.通过非劣排序以及拥挤距离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 解集进行优劣比较,进行相应的删除、添加操作更新 Pareto 最优解集,即对外部档案进行更新.

Step 8: 算法的终止条件.超过最大迭代次数 $maxgen$ 或者群体的适应度值持续一定的次数不发生变化,即停止搜索,输出搜索结果.否则 $gen=gen+1$, 转到 Step 3.

4 仿真测试

4.1 参数设置

为验证用灰熵并行分析法实现三目标作业车间调度优化问题的可行性,以及将灰熵并行关联度作为适应值引导智能优化算法进化的效果,本文用 matlab8.0 编程,在 Windows XP 环境下运行,测试 15 个典型 jobshop 调度问题^[14].算法种群规模 $NP=20$, 外部档案个体规模 $W_{max}=50$, 最大迭代次数 $maxgen=100$.差分算法采用 $F=0.8*2^{namd}$ 进行自适应缩放因子^[16]的调整,

其中, $namd = e^{\frac{1 - \max gen}{\max gen + 1 - gen}}$, 交叉概率 $P_c = 0.75$. 选择遗传算法(GA)作为比较算法,其采用二元锦标赛选择、对换变异操作和单位位置次序交叉^[17], 交叉概率 $P_c = 0.75$, 变异概率 $P_m = 0.1$. 实验结果如表 1, 2.

4.2 评价指标

本论文采用如下参数作为性能评价指标:

1) 当代距离^[18](Generation Distance, GD): $GD = (\sum_{i=1}^{W_{max}} d_i^2)^{1/2} / W_{max}$ 定义为算法所得非劣解集与理想解间的远近程度的值. W_{max} 为外部档案个体数, d_i 为第 i 个非劣解与理想解间的欧氏距离.

2) 最大 Pareto 前端误差指标^[18], $ME = \max_j (\min_i (|f_1^i - f_1^j|^2 + |f_2^i - f_2^j|^2 + |f_3^i - f_3^j|^2))^{1/2}$, $i, j=1, \dots, W_{max}$; 定义一个最大的误差范围, ME 值越小,表明 Pareto 解的误差范围越小,可靠性越高.

4.3 结果分析

由前述的分析可知, 灰熵并行关联度值越接近 1, 算法得到非劣解的比较序列与理想序列的符合程度越高. 表 1 为 15 个调度问题实验结果, 由表 1 可知, 灰熵并行分析法均能使两种算法得到收敛的解. 两种算法的灰熵并行关联度值介于 0.8224-0.9823, 表明将灰熵并行关联度作为适应值引导智能优化算法进化得到的比较序列与理想序列的符合程度较高, 说明将灰熵并行分析法可以有效的引导智能优化算法进化. 同时, 两种算法的灰熵并行关联度都大于 0.8, 说明将灰熵并行关联度作为适应值引导智能优化算法进化是可靠的. 图 1-4 为两种算法得到的 Pareto 解集分布图, 由图 1-4 可知, 两种算法得到的 pareto 解分布均匀, 证明灰熵并行分析法在实现三目标作业车间调度优化问题是可行的.

从表 1 中也可看出差分算法所得到的灰熵并行关联度值比遗传算法求得值更大, 说明差分算法得到的多目标非劣解的比较序列比遗传算法更加契合参考序列, 即差分算法得到的解更接近于理想解, 优化结果更好.

表 2 为两算法性能评价结果, 由表 2 可知, 差分算法所得当代距离(GD)皆小于遗传算法, 说明其收敛性比遗传算法的好. 对于最大 Pareto 前端误差指标(ME), 除 FT06 和 LA10 外, 其它 13 个实例, 差分算法的 Pareto 解误差范围都比遗传算法的小, 可靠性更

高.

图 1 为 FT20 调度问题两种算法得到的 Pareto 解集分布图, 图 2 为 Pareto 解集的二维投影图, 由图 2 可以看出: 两算法得到解分布均匀. 在最大加工时间方向上, 由图(a), (b)可以看出差分算法的解集中于 1650-1850, 而遗传算法的解集中分布于 1800-1950, 即差分算法得到的最大加工时间分布更小; 在最大延迟时间方向上, 由图(a), (c)可以看出差分算法的解集中于 1050-1250, 而遗传算法的解集中分布于 1100-1350, 即差分算法得到的最大延迟时间分布更小; 在总流程时间方向上, 由图(b), (c)可以看出差分算法的解集中于 26000-28000, 而遗传算法的解集中分布于 28000-31000, 即差分算法得到的总流程时间分布更小. 图 3, 图 4 为 LA07 调度问题的三维分布图和二维投影图, 由图 3、4 可以看出: 与上一例子相似, 两算法得到的解分布均匀. 在最大加工时间、最大延迟时间、总流程时间三个子目标上, 差分算法能够得到更好得解.

综上所述, 基于灰熵并行分析法的两种优化算法都能够解决三目标作业车间调度问题, 两种算法均能够得到一组分布比较均匀的 Pareto 前端, 而差分算法得到的 Pareto 前端相对于遗传算法的更加靠近原点, 即差分算法得到的 Pareto 解质量更优.

表 1 典型调度问题实验结果

序号	算例类型 (n x m)	算法	理想解的函数值 $Y_0=(f_1, f_2, f_3)$	最优解函数值(f_1, f_2, f_3)	灰熵并行关联度
1	FT06 (6x6)	GA	(59, 5, 311)	(61, 8, 317)	0.9120
		DE		(60, 7, 331)	0.9414
2	FT10 (10x10)	GA	(1297, 627, 11555)	(1428, 721, 12694)	0.8650
		DE		(1316, 692, 11777)	0.9069
3	FT20 (20x5)	GA	(1611, 852, 24590)	(1722, 1094, 26490)	0.8380
		DE		(1625, 859, 25225)	0.9409
4	LA01 (10x5)	GA	(748, 36, 6098)	(818, 137, 6793)	0.8318
		DE		(838, 93, 6606)	0.8757
5	LA02 (10x5)	GA	(800, 89, 5809)	(932, 206, 6888)	0.8607
		DE		(865, 97, 5957)	0.9823
6	LA03 (10x5)	GA	(701, 80, 5760)	(810, 252, 6744)	0.8357
		DE		(902, 205, 6554)	0.8383
7	LA04 (10x5)	GA	(713, 103, 5589)	(800, 263, 6455)	0.8394
		DE		(881, 164, 6627)	0.8903
8	LA05 (10x5)	GA	(605, 94, 5012)	(749, 173, 6135)	0.8299
		DE		(621, 210, 5164)	0.8888

9	LA06	GA	(1048, 286, 12193)	(1058, 522, 13268)	0.8353
	(15×5)	DE		(1087, 430, 13284)	0.8493
10	LA07	GA	(988, 290, 12334)	(1129, 456, 13543)	0.8224
	(15×5)	DE		(1106, 367, 12511)	0.9026
11	LA08	GA	(1014, 359, 11845)	(1064, 457, 13383)	0.8668
	(15×5)	DE		(1044, 387, 12846)	0.9139
12	LA09	GA	(1041, 364, 12665)	(1115, 496, 13749)	0.8572
	(15×5)	DE		(1071, 454, 13302)	0.8573
13	LA10	GA	(978, 309, 12620)	(1075, 477, 13640)	0.8425
	(15×5)	DE		(1042, 407, 13078)	0.8967
14	LA11	GA	(1310, 669, 22334)	(1427, 742, 24024)	0.8514
	(20×5)	DE		(1339, 703, 22514)	0.8995
15	LA12	GA	(1150, 469, 19015)	(1214, 602, 20378)	0.8482
	(20×5)	DE		(1233, 529, 19859)	0.8523

表 2 两种算法评价结果

算例	当代距离(GD)		最大 Pareto 前端误差(ME)	
	GA	DE	GA	DE
FT06	6.38	5.51	34.11	36.35
FT10	349.1	225.0	1458.7	943.7
FT20	737.7	487.2	2552.0	2124.2
LA01	1318.0	872.5	5758.5	3732.6
LA02	571.3	410.0	2576.6	1981.3
LA03	780.6	582.9	3516.6	2971.9
LA04	168.70	127.05	559.70	484.75
LA05	128.49	104.97	589.67	913.61
LA06	375.5	258.7	2038.3	1456.3
LA07	170.54	134.75	788.09	415.32
LA08	259.5	214.3	1294.2	1268.0
LA09	619.0	483.8	2949.6	2397.8
LA10	274.3	237.0	1151.0	1549.9
LA11	438.7	342.3	1431.3	947.9
LA12	860.1	612.3	3086.9	2118.6




图 1 FT20 问题 Pareto 解集分布图




图 2 FT20 问题 Pareto 解集在三个子目标上的投影图




图 3 LA07 问 Pareto 解集分布图




图 4 LA07 问题 Pareto 解集在三个子目标上的投影图

5 结语

本文基于序列关系的思想，建立灰熵并行分析法，利用灰熵并行关联度作为优化算法的适应度值引导算法进化，从而可以避免人为因素和间接计算误差的影响。针对典型 jobshop 调度问题建立三个目标优化函数，构建三目标作业车间调度问题数学模型。基于灰熵并行分析法，采用差分算法及遗传算法解决三目标作业车间调度问题。实验表明基于灰熵并行分析法的两种算法，能够取得较为理想的解，同时，基于灰熵并行分析法的差分算法得到解效果更加理想。

参考文献

- 1 王伟玲,李俊芳,王晶.求解多目标作业车间调度问题的双种群遗传算法.计算机集成制造系统,2011,17(4):808-815.
- 2 张超勇,董星,王晓娟,李新宇,刘琼.基于改进非支配排序遗传算法的多目标柔性作业车间调度.机械工程学报,2010,46(11):156-164.
- 3 仁庆道尔吉.车间作业调度问题的多目标模型建立及其算法[学位论文].西安:西安电子科技大学,2013.
- 4 何启巍,张国军,朱海平等.一种多目标置换流水车间调度问题的优化算法.计算机系统应用,2013,22(9):111-118.

- 5 Li J, Pan Q, Liang YC. An effective hybrid tabu search algorithm for multi-objective flexible job-shop scheduling problems. *Computers & Industrial Engineering*, 2010, 59(4): 647–662.
- 6 Rahmati SHA, Zandieh M, Yazdani M. Developing two multi-objective evolutionary algorithms for the multi-objective flexible job shop scheduling problem. *International Journal Advance Manufacture Technology*, 2013, 64: 915–932.
- 7 Liu H, Zhang QS, Yao LG. Multi-objective particle swarm optimization algorithm based on grey relational analysis with entropy weight. *Journal of Grey System*, 2010, 22: 265–274.
- 8 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,第 25 届中国控制会议论文集(上册),哈尔滨,中国自动化学会,2006:557–560.
- 9 王娜,卫波,王晋东,等.基于混沌多目标粒子群优化算法的云服务选择.计算机工程,2014,40(3):23–27,38.
- 10 周奇,陈立,周猛猛,等.基于自适应加权的船舶操纵性能多目标优化.舰船电子工程,2014,34(2):37–40.
- 11 许秀林,胡克瑾.基于遗传算法的多目标柔性车间作业调度方法.计算机应用与软件,2012,29(7):266–270.
- 12 王凯琢,付元昌,江凌生,耿贵宁.基于改进灰色理论的威胁指标权重技术.计算机工程,2009,35(14):151–153.
- 13 陈湘涛,王爱云,谢伟平.灰关联度聚类算法在图像检索中的应用.计算机工程与应用,2009,45(16):146–148
- 14 张继国,辛格.信息熵-理论与应用.北京:中国水利水电出版社,2012:79–83.
- 15 Qian B,Wang L, Huang D, Wang W, et al.An effective hybrid DE-based algorithm for multi-objective flow shop scheduling with limited buffers. *Computers and Operations Research*, 2009, 36(1): 209–233.
- 16 Nowicki E. The permutation flow shop with buffers: A tabu search approach. *European Journal of Operational Research*, 1999, 116(1): 205–219.
- 17 王凌.车间调度及其遗传算法.北京:清华大学出版社, 2003:1–218.
- 18 崔逊学.多目标进化算法及其应用.北京:国防工业出版社, 2006:157–173.