

面向多目标流水车间调度的多种群多目标遗传算法

付亚平^{1,2}, 黄敏¹, 王洪峰^{1†}, 王兴伟¹

(1. 东北大学信息科学与工程学院, 流程工业综合自动化国家重点实验室, 辽宁 沈阳 110819;

2. 青岛大学复杂性科学研究所, 山东 青岛 266071)

摘要: 针对制造型企业普遍存在的流水车间调度问题, 建立了以最小化最迟完成时间和总延迟时间为目标的多目标调度模型, 并提出一种基于分解方法的多种群多目标遗传算法进行求解. 该算法将多目标流水车间调度问题分解为多个单目标子问题, 并分阶段地将这些子问题引入到算法迭代过程进行求解. 算法在每次迭代时, 依据种群的分布情况选择各子问题的最好解及与其相似的个体分别为当前求解的子问题构造子种群, 通过多种群的进化完成对多个子问题最优解的并行搜索. 通过对标准测试算例进行仿真实验, 结果表明所提出的算法在求解该问题上能够获得较好的非支配解集.

关键词: 多种群; 遗传算法; 多目标优化; 流水车间调度

中图分类号: TP13 文献标识码: A

Multipopulation multiobjective genetic algorithm for multiobjective permutation flow shop scheduling problem

FU Ya-ping^{1,2}, HUANG Min¹, WANG Hong-feng^{1†}, WANG Xing-wei¹

(1. College of Information Science and Engineering, Northeastern University; State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang Liaoning 110819, China;

2. Institute of Complexity Science, Qingdao University, Qingdao Shandong 266071, China)

Abstract: Since the permutation flow shop scheduling problem exists extensively in manufacturing enterprises, a multiobjective flow shop scheduling problem with the objectives of minimizing the makespan and the total tardiness is investigated in this paper. In order to solve it, a multipopulation multiobjective genetic algorithm based on decomposition is proposed. The proposed algorithm decomposes the investigated problem into multiple single objective subproblems introduced into the iteration course step by step. At each iteration, multiple subpopulations are constructed for the current solved subproblems based on the distribution of population, which realizes the goal of solving them simultaneously. The evolution of multiple subpopulations can be used to search the optimal solutions of multiple subproblems. Experimental results on some instances show that the proposed algorithm can get better performance in solving the multiobjective permutation flow shop scheduling problem.

Key words: multipopulation; genetic algorithm; multiobjective optimization; flow shop scheduling

1 引言(Introduction)

流水车间调度(flow shop scheduling problem, PFSP)是制造型企业普遍存在的调度问题, 已被证明为NP-hard问题^[1]. 随着制造型企业竞争愈加激烈, 生产计划人员在制定调度方案时通常需要考虑多个优化目标, 多目标流水车间调度问题受到学术界和工业界的广泛关注, 研究和设计获取该问题满意解集的优

化方法和求解技术, 逐渐成为该领域研究人员关注的焦点^[2-3].

进化算法(evolutionary algorithm, EA)作为一类群体智能优化算法, 可以通过一次运行获得多个非支配解, 适合求解多目标调度问题^[4]. Chang等^[5]采用改进的分解多目标进化算法求解多目标流水车间调度问题. Murata等^[6]提出了变权重多目标遗传局部搜索算

收稿日期: 2015-08-05; 录用日期: 2016-07-04.

†通信作者. E-mail: hfwang@mail.neu.edu.cn.

本文责任编辑: 李少远.

国家杰出青年科学基金项目(71325002, 61225012), 国家自然科学基金项目(71671032, 61673228), 流程工业综合自动化国家重点实验室基础科研业务费(2013ZCX11).

Supported by National Science Foundation for Distinguished Young Scholars of China (71325002, 61225012), National Natural Science Foundation of China (71671032, 61673228) and Fundamental Research Funds for State Key Laboratory of Synthetical Automation for Process Industries (2013 ZCX11).

法,并用于求解多目标流水车间调度问题. Zhang等^[7]设计了多目标遗传禁忌搜索算法求解多目标动态作业车间调度问题. Arroyo等^[8]针对多目标流水车间调度问题,提出了遗传局部搜索算法进行求解. 张超勇等^[9]改进非支配排序遗传算法求解柔性作业车间调度问题. 朱光宇等^[10]提出了一种基于灰熵关联分析的多目标优化算法,并用于求解多目标流水车间调度问题. 这些研究在解空间内利用一个个体对一个非支配最优解进行搜索,通过多个个体的遗传进化实现了对多个非支配最优解的同时逼近,从而获得一个满意的非支配解集.

为了进一步提高算法搜索的准确性和效率,学者们开展了一种基于多种群策略的多目标进化算法的研究,这类研究采用构造多种群的方式实现了多个个体对一个非支配最优解进行搜索,有效地改善了算法对解空间的探索能力和开发能力. 现阶段解决多目标优化问题的多种群方法可以分为基于目标向量的多种群方法和基于分解的多种群方法. 基于目标向量的多种群方法为每个优化目标构造子种群,每个子种群优化一个对应目标下的单目标优化子问题,通过多种群的进化完成对解空间的搜索. Cochran等^[11]采用基于目标向量的多种群方法,提出了一种求解多目标并行机调度问题的多种群多目标遗传算法. Zandieh等^[12]在该算法框架基础上嵌入了局部搜索算子,用于求解柔性流水车间调度问题. 基于分解的多种群方法采用分解方法将多目标优化问题分解为多个单目标子问题,通过为这些子问题分别构造子种群的方式实现对这些子问题的并行求解. Chang等^[13]采用基于分解的多种群方法,设计了一种两阶段的多目标遗传算法求解多目标并行机调度问题. 该算法在第1阶段为每个子问题分别构造子种群实现了定向搜索,而第2阶段通过为每一个体赋予随机权重的方法实现了种群的多向搜索. Chang等^[14]在该研究的基础上考虑利用进化过程中发现的有利信息对种群结构进行调整,提出了一种多种群多目标遗传算法,并用于求解多目标流水车间调度问题. Chang等^[15]对这种多种群多目标遗传算法进行改进,并用于求解多目标并行机调度问题. 该算法采用分阶段的方式对非支配解集的不同区域进行搜索,并将种群与非支配解集实施交互,以加快算法的收敛速度. Rashidi等^[16]针对混合流水车间调度问题,采用基于分解的多种群方法,提出了一种混合的多目标遗传算法进行求解. 该算法设计了权重向量和种群重新初始化策略,并采用局部搜索算法对子种群的优势个体进行优化. 这些研究采用构造多种群的方式实现多个个体对一个单目标优化问题最优解的搜索,通过多种群的进化机制对多个单目标优化问题的并行求解,从而获得一个满意的非支配解集.

上述研究采用多种群策略实现了多个个体对一个

非支配最优解的搜索,这些研究所提出的多种群策略均使子种群成员个体在迭代过程中保持不变,这种构造多种群的方式有利于提高算法的收敛速度,但子种群在迭代过程中易失去多样性,从而使得子种群陷入局部最优,这会降低算法的搜索精度. 为提高算法对非支配最优解集搜索的精度和速度,本文考虑算法在每次迭代时为每个子问题重新构造子种群的思路,进一步提出了一种基于分解方法的多种群多目标遗传算法(multipopulation multiobjective genetic algorithm based on decomposition, MPGA/D),并用于求解多目标流水车间调度问题. 该算法将多目标流水车间调度问题分解为多个单目标子问题,并将这些子问题分阶段的引入到算法的迭代过程进行求解. 算法在每次迭代时,依据种群的分布情况为当前求解的子问题分别构造子种群,通过多种群的遗传进化完成对多个子问题最优解的并行搜索. 通过对标准算例进行仿真实验,验证了本文所提出的算法在求解多目标流水车间调度问题上能够获得质量较高和分布性较好的非支配解集.

2 问题描述(Problem description)

随着制造型企业竞争愈加激烈,决策者在制定调度方案时既要考虑企业内部降低生产成本的需求,也要考虑下游客户的服务满意水平. 因此,针对流水车间调度问题,选取最小化最迟完成时间和总延迟时间为目标函数,建立了多目标调度模型. 其中,最小化最迟完成时间有利于提高设备利用率,而最小化总延迟时间考虑产品的交货期,有利于提高下游客户的服务满意水平. 考虑最小化最迟完成时间和总延迟时间的多目标流水车间调度问题可以描述为:在0时刻, n 个待加工作业按照相同的工艺路线依次在 m 台设备上加工,问题的约束有: 1) 所有作业必须完成且只能加工一次; 2) 作业的加工过程不允许中断; 3) 任一时刻每台设备只允许加工一个作业; 4) 同一时刻一个作业只能在一台设备上加工; 5) 作业在所有设备上的加工顺序相同. 该问题的参数及决策变量定义如下:

参数:

J : 作业集合, $J = \{1, 2, 3, \dots, n\}$, n 为作业数;

M : 设备集合, $M = \{1, 2, 3, \dots, m\}$, m 为设备数;

p_{ij} : 作业 j 在设备 i 上的处理时间;

d_j : 作业 j 的交货期;

G : 充分大正数;

决策变量:

S_{ij} : 作业 j 在设备 i 上的开始处理时间;

C_{ij} : 作业 j 在设备 i 上的完成时间;

C_{\max} : 最迟完成时间;

T_j : 作业 j 的延迟时间;

x_{hj} : 0-1 决策变量, 若作业 h 为作业 j 的紧前作业, 则 $x_{hj} = 1$; 否则, $x_{hj} = 0$.

该问题的数学模型如下:

$$\min C_{\max}, \tag{1}$$

$$\min \sum_{j=1}^n T_j, \tag{2}$$

s.t.

$$\begin{cases} S_{ij} + p_{ij} \leq S_{i+1,j}, \\ i = 1, 2, 3, \dots, m-1, j = 1, 2, 3, \dots, n, \end{cases} \tag{3}$$

$$\begin{cases} S_{ih} + p_{ih} \leq S_{ij} + G \times (1 - x_{hj}), \\ i = 1, 2, 3, \dots, m, h = 1, 2, 3, \dots, n, \\ j = 1, 2, 3, \dots, n, \end{cases} \tag{4}$$

$$\begin{cases} x_{hj} + x_{jh} = 1, \\ h = 1, 2, 3, \dots, n, j = 1, 2, 3, \dots, n, \end{cases} \tag{5}$$

$$C_{\max} \geq C_{mj}, j = 1, 2, 3, \dots, n, \tag{6}$$

$$T_j \geq \max\{C_{mj} - d_j, 0\}, j = 1, 2, 3, \dots, n, \tag{7}$$

$$S_{ij} \geq 0, C_{ij} \geq 0, i=1, 2, 3, \dots, m, j=1, 2, 3, \dots, n, \tag{8}$$

$$x_{hj} \in \{0, 1\}, h = 1, 2, 3, \dots, n, j = 1, 2, 3, \dots, n. \tag{9}$$

其中: 式(1)和式(2)表示目标函数为最小化最迟完成时间和总延迟时间, 式(3)表示同一时刻一个作业只能在一台设备上处理, 式(4)表示同一时刻每台设备只能处理一个作业, 式(5)表示设备上作业的顺序关系, 式(6)和(7)定义了最迟完成时间和作业 j 的延迟时间. 式(8)及式(9)定义了变量的取值范围.

3 所提出的算法(Proposed algorithm)

3.1 算法基本思想(Basic idea of algorithm)

多种群策略通过将种群划分为多个子种群实现了对解空间不同区域的搜索, 可以改善算法对解空间的探索能力和开发能力. 本文所提出的算法将多目标优化问题分解为多个单目标子问题, 这些子问题被分阶段的引入到迭代过程, 并采用构造多种群的方式对多个子问题进行并行求解. 图1给出了MPGA/D的伪代码, 在完成算法参数和种群初始化及问题分解后, 算法将进入如下迭代过程: 首先引入一部分均匀分布的子问题; 然后从种群中为当前求解的子问题分别选择最好解, 并为这些子问题构造子种群; 其次对子种群进行遗传进化操作, 并对外部档案实施更新操作; 最后将所有子种群合并为一个种群, 并进入下一个迭代过程.

Procedure Algorithm of MPGA/D:

begin

```

initialize algorithm parameters;
generate randomly and evaluate initial population as 3.2;
decompose the multiobjective optimization problem into
multiple subproblems as 3.3;
repeat
introduce some uniformly distributed subproblems as
3.3;
construct multiple subpopulations for the current solved
subproblems as 3.3;
execute genetic evolution for subpopulations as 3.4;
update the external archive as 3.4;
combine all subpopulations into a population;
until a termination condition is met.
output the nondominated solutions in external archive.
end
    
```

图 1 MPGA/D 的执行伪代码图

Fig. 1 Pseudo-code for the MPGA/D

3.2 种群的初始化方法(Method of initializing population)

多目标流水车间调度问题是典型的离散优化问题, 本文采用自然数编码表示一个完整且可行的调度方案. 以5个作业为例, 染色体(2, 4, 5, 1, 3)表示作业在各台设备上的处理顺序为 $2 \rightarrow 4 \rightarrow 5 \rightarrow 1 \rightarrow 3$. 由于维持种群的多样性有利于解决多目标优化问题, 这里采用随机的方法生成初始种群.

3.3 多种群的构造方法(Method of constructing multipopulation)

本文所提出的算法首先将多目标优化问题分解为多个单目标子问题, 这种方法首先生成 N 个均匀分布的权重向量, 然后基于这些权重向量建立 N 个单目标问题. 设 $\{\lambda^1, \lambda^2, \lambda^3, \dots, \lambda^N\}$ 为一个权重向量集合, $\lambda^j = \{\lambda_1^j, \lambda_2^j, \lambda_3^j, \dots, \lambda_k^j\}$ 表示第 j 个权重向量, $j = 1, 2, 3, \dots, N, k$ 为目标个数, 则这些单目标子问题如式(10)所示, 其中 Ω 表示解空间. 这样就可以构建 N 个单目标子问题, 并采用多种群的方式对这些子问题进行并行求解.

$$\begin{aligned} \min f((x|\lambda^j)) &= \sum_{i=1}^k \lambda_i^j \cdot f_i(x), \tag{10} \\ \text{s.t. } x &\in \Omega, j = 1, 2, 3, \dots, N. \end{aligned}$$

为了快速和准确地获得多个非支配最优解, 并在这些最优解的基础上对其他子问题最优解进行搜索. 算法在初始阶段只引入一部分子问题进行求解, 当满足预设条件(如指定的估值次数)时, 再逐步地引入其他子问题进行求解. 这种方法可以为新引入子问题构造较高质量的子种群, 有利于提高算法对各子问题最优解搜索的精度和速度. 这里以6个子问题分两个阶段引入为例说明这种方法, 其中, 6个子问题为(0.0, 1.0), (0.2, 0.8), (0.4, 0.6), (0.6, 0.4), (0.8, 0.2)和(1.0,

0.0), 算法在初始阶段将子问题(0.0, 1.0), (0.4, 0.6)和(0.8, 0.2)加入到当前求解子问题集, 并对这三个子问题分别构造子种群进行求解. 当满足预设条件时, 再将子问题(0.2, 0.8), (0.6, 0.4)和(1.0, 0.0)加入到当前求解子问题集, 并对这6个子问题采用多种群的方式并行求解.

为了提高算法对多个单目标子问题最优解搜索的精度和速度, 本文提出了一种在进化过程中为子问题重新构造多种群的策略, 这种多种群方法在算法每次迭代时, 依据种群的分布情况选择各子问题的最好解及与最好解相似的个体为当前求解的子问题分别构造子种群, 每个子种群由子问题的最好解和与该最好解相似的个体组成, 这里规定子种群的组成个体互不相交, 即每个个体仅属于一个子种群. 多种群的构造方法如图2所示, 首先对当前求解的子问题进行随机排序; 然后, 按照该顺序依次为当前求解的子问题选择最好解; 最后, 选择与最好解相似性较高的个体依次为各子问题构造子种群. 这里采用作业的完工时间差异评价两个不同个体的相似性, 如式(11)所示, 其中: $C_{mj}(p)$ 和 $C_{mj}(q)$ 分别表示个体 p 和 q 上作业 j 在最后一台设备 m 上的完成时间; $\text{Similar}(p, q)$ 表示个体 p 和 q 的相似性, 其值越小, 表示相似程度越高.

$$\text{Similar}(p, q) = \sum_{j=1}^n |C_j(p) - C_j(q)|. \quad (11)$$

这样就可以为当前求解的子问题分别构造子种群, 并通过多种群的遗传进化实现了对多个子问题最优解的并行搜索.

Procedure Algorithm of constructing multipopulation:

begin

resort weight vectors randomly in Ψ ;

for $j = 1$ to n_1 **do**

get the best individual p from P on the j th subproblem

that is generated by using the j th weight vector in Ψ ;

move p into the subpopulation P^j ;

endfor

for each subpopulation P^j **do**

get $(n_2 - 1)$ individuals from P that are the most similar to the best individual of P^j ;

move the $(n_2 - 1)$ individuals to P^j ;

endfor

end

Denotations:

P : the population;

Ψ : the set of the current subproblems to be solved;

n_1 : the number of subpopulations to be constructed;

n_2 : the number of individuals in a subpopulation.

图2 多种群的构造方法伪码图

Fig. 2 Pseudo-code for the algorithm of constructing multiple subpopulations

3.4 遗传算子的设计方法(Method of designing genetic operators)

通过上述构造多种群的策略实现了对多个子问题最优解的并行搜索, 可以获得这些子问题的近似最优解. 然而多目标优化算法的目标是获得一个质量较高且分布均匀的非支配解集, 因此, 为了获得一个满意的非支配解集, 多种群与外部档案间实施信息交互策略, 子种群的个体分别等概率地选择对应的子种群, 其他子种群或外部档案中的个体进行交叉操作, 这种交互策略有利于提高算法对解空间的探索能力. 这里外部档案用于保存算法搜索过程中发现的非支配解, 算法迭代过程采用支配规则对外部档案进行更新^[10].

遗传算法通过染色体的交叉操作实施对解空间的搜索, 文献[17]指出对于自然数编码的多目标流水车间调度问题, 两点交叉是一种有效的交叉方式, 本文选择两点交叉作为染色体的交叉方法. 变异操作有利于提高种群的多样性, 本文采用交换和移位变异方法. 其中, 交换变异是随机选择两个不同的位置, 然后交换两个位置上的作业; 而移位变异是随机选择一个位置上的作业并将其插入到另一个随机位置. 通过交叉和变异产生的新个体被放入到对应的子种群, 并在选择阶段依据精英保留策略将优势个体遗传到下一代.

4 仿真实验结果与分析(Simulation experimental results and analysis)

为了验证所提出的算法在求解多目标流水车间调度问题的有效性, 按照文献[18]的方法生成不同规模($m \times n$, m 表示设备数, $m = 10, 20$; n 表示作业数, $n = 10, 20, 30, \dots, 100$)的算例进行仿真实验, 并选择SPGAI^[15], NSGAI^[19], MOEA/D^[17], MOGLS^[18]及BMSA^[20]作为比较算法. 其中: SPGAI是采用构造多种群的方法求解多目标调度问题; NSGAI是一种基于支配规则的多目标优化算法, MOEA/D和MOGLS是基于分解的多目标优化算法, 这3种算法均已被应用于求解多目标流水车间调度问题; BMSA是近年来提出的一种基于群体的模拟退火算法, 且已被应用于求解多目标流水车间调度问题.

4.1 实验设置(Experimental setting)

MPGA/D的参数设置如下: 种群规模为100, 子问题总数量为20, 每次引入子问题数量为10, 子种群的最大规模为10, 变异率为0.6. 比较算法的算法结构及参数设置均参考原文献, 其中: SPGAI的种群规模为100, 变异率为0.6, 子问题数量为20. NSGAI及MOEA/D的种群规模为100, 变异率为1.0; MOGLS的种群规模为100, 交叉率为1.0, 变异率为0.6; BMSA的群体规模为10, 初始温度为10, 冷却系数为0.9, 每一温度下迭代40次.

为验证所提出的算法在求解多目标流水车间调度问题的性能, 选取 C 指标^[21] 及 IGD 指标^[22] 作为算法评价指标, 分别定义如下:

1) C 指标: 该指标用于评价两种算法所获得的非支配解集的相对优劣, 其定义如式(12), 其中 X, Y 分别表示两种算法获得的非支配解集. 若 $C(X, Y) = 1$ 表明对于 Y 集中的任一非支配解, X 集中都存在支配它的解; 若 $C(X, Y) = 0$ 表明对于 Y 集中的任一非支配解, X 集中都不存在支配它的解.

$$C(X, Y) = \frac{|y \in Y | \exists x \in X : x \succ y|}{|Y|}. \quad (12)$$

2) IGD 指标: 该指标为综合指标, 可以同时评价非支配解集与最优解集的逼近程度及非支配解集的分布性, 其定义如式(13)所示:

$$IGD(\bar{P}, P^*) = \frac{\sum_{v \in P^*} d(v, \bar{P})}{|P^*|}, \quad (13)$$

其中: $d(v, \bar{P})$ 表示非支配最优解 v 到非支配解集 \bar{P} 中最近点的欧式距离, P^* 为非支配最优解集. 多目标流水车间调度问题为实际应用问题, 无法获得真实的非支配最优解集, 因此, 本文将 6 种算法 30 次运行获得的非支配解集合并, 并剔除被支配解后得到的解集作为非支配最优解集 \bar{P}^* .

4.2 实验结果分析(Experimental result analysis)

为了公平合理地比较本文所提出的算法与比较算法的性能, 实验对 6 种算法均以 20000 次估值作为停止条件, 6 种算法分别对每一算例求解 30 次, 并取 30 次运行结果的均值作为评价标准. 为更好地比较和分析实验结果, 采用自由度为 58, 显著水平为 0.05 的 t 检验方法, 符号“+”、“-”及“~”分别表示 MPGA/D 的求解性能显著优于、差于及基本等同于其比较算法.

首先验证本文所提出的自适应多种群策略的性能. 本文提出的自适应多种群策略在每次迭代时, 根据种群的分布情况, 为各子问题分别构造子种群进行并行求解. 文献[13-16]同样采用多种群策略为子问题构造子种群进行并行求解, 但这些研究在迭代过程中均保持子种群的成员个体不变. 为验证两种策略在求解多目标流水车间调度问题的性能, 分别对两种策略进行仿真实验. 令 MGAa 为本文所提出的自适应多种群策略, MGA b 为文献[15]所采用的多种群策略, MGA a 和 MGA b 对所有子种群只采用遗传进化机制且独立的完成对各子问题最优解的搜索, 这样可以公平且有效的体现所提出自适应多种群策略的性能. 表 1 给出了这两种策略在 C 指标和 IGD 指标方面的实验结果. 从 C 指标及 IGD 指标的实验结果可以发现, 对于所有的实验算例, MGA a 的求解效果均显著优于 MGA b, 表明本文所提出的自适应多种群策略在解决多目标

流水车间调度问题方面具有较好的效果.

表 1 两种多种群策略的 C 指标和 IGD 指标性能比较
Table 1 Comparison of the two multipopulation strategies via C -metric and IGD-metric

算例	C 指标			IGD 指标		
	MGAa	MGA b	t -test	MGAa	MGA b	t -test
10 × 10	1.00	0.00	+	0.0895	0.3222	+
10 × 20	1.00	0.00	+	0.1250	0.3991	+
10 × 30	1.00	0.00	+	0.1126	0.4337	+
10 × 40	1.00	0.00	+	0.0766	0.5438	+
10 × 50	1.00	0.00	+	0.1369	0.4902	+
10 × 60	1.00	0.00	+	0.1448	0.4810	+
10 × 70	1.00	0.00	+	0.1682	0.5185	+
10 × 80	1.00	0.00	+	0.1961	0.5130	+
10 × 90	1.00	0.00	+	0.1686	0.5214	+
10 × 100	1.00	0.00	+	0.2239	0.5517	+
20 × 10	1.00	0.00	+	0.0747	0.1967	+
20 × 20	1.00	0.00	+	0.1703	0.2751	+
20 × 30	1.00	0.00	+	0.1395	0.3585	+
20 × 40	1.00	0.00	+	0.1749	0.4257	+
20 × 50	1.00	0.00	+	0.1465	0.4284	+
20 × 60	1.00	0.00	+	0.1707	0.4480	+
20 × 70	1.00	0.00	+	0.1513	0.4257	+
20 × 80	1.00	0.00	+	0.1826	0.4646	+
20 × 90	1.00	0.00	+	0.1746	0.4526	+
20 × 100	1.00	0.00	+	0.1994	0.4688	+

其次, 验证本文所提出的 MPGA/D 在求解多目标流水车间调度问题方面的性能. 表 2 给出了 MPGA/D 及比较算法在 C 指标方面的实验结果, 表中 A, B, C, D, E 及 F 分别表示算法 MPGA/D, SPGAI I, NSGAI I, MOEA/D, MOGLS 及 BMSA. 从表中可以看出, MPGA/D 在所有算例上的优化效果均显著优于其比较算法, 表明 MPGA/D 在 C 指标方面能够获得较好的求解效果.

表 3 给出了 MPGA/D 及比较算法在 IGD 指标方面的实验结果. 从表 3 的实验结果可以发现, MPGA/D 在所有算例的优化效果均显著优于 SPGAI I, NSGAI I 及 MOGLS. 在 17 个算例上能够显著优于 MOEA/D, 在 18 个算例上的优化效果显著优于 BMSA. 这表明 MPGA/D 在 IGD 指标方面能够取得较好的效果.

通过上述实验结果的分析可以发现, 本文提出的 MPGA/D 在 C 指标、IGD 指标方面均具有较好的优化效果. 为更好地展示所提出的算法求解效果, 图 3-5 给出了 6 种算法在求解算例 10 × 50, 10 × 80 及 20 × 80 时 30 次运行获得的最好非支配解集的分布图. 从图中可以看出, MPGA/D 获得地非支配解集具有较好的质量和分布性.

表2 6种算法的C指标实验结果对比

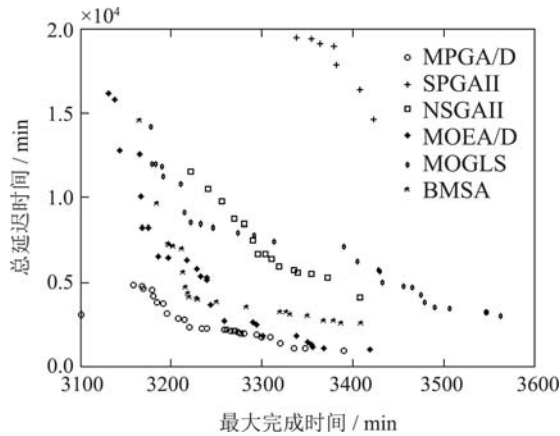
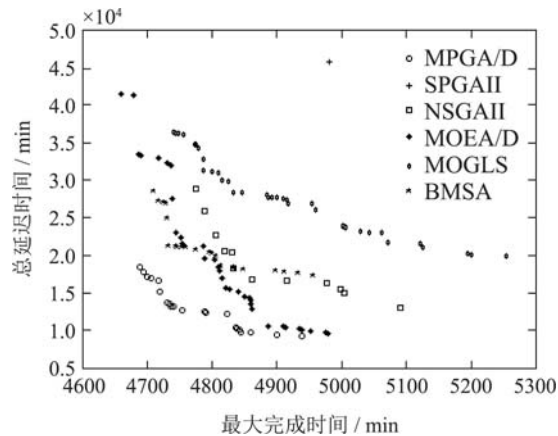
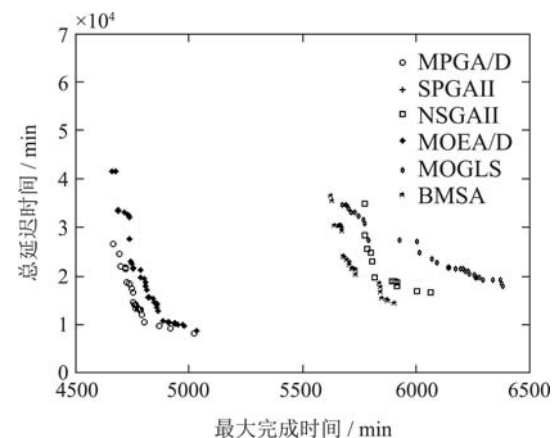
Table 2 Experimental results comparison of the six algorithms via C-metric

算例	A	B	t-test	A	C	t-test	A	D	t-test	A	E	t-test	A	F	t-test
10 × 10	1.00	0.00	+	0.99	0.00	+	0.06	0.00	+	0.53	0.00	+	0.08	0.00	+
10 × 20	1.00	0.00	+	1.00	0.00	+	0.63	0.10	+	0.94	0.00	+	0.76	0.09	+
10 × 30	1.00	0.00	+	1.00	0.00	+	0.46	0.21	+	0.98	0.00	+	0.69	0.08	+
10 × 40	1.00	0.00	+	1.00	0.00	+	0.54	0.03	+	0.98	0.00	+	0.88	0.00	+
10 × 50	1.00	0.00	+	1.00	0.00	+	0.52	0.04	+	0.96	0.00	+	0.87	0.00	+
10 × 60	1.00	0.00	+	0.99	0.00	+	0.44	0.07	+	0.93	0.00	+	0.70	0.13	+
10 × 70	1.00	0.00	+	0.93	0.00	+	0.48	0.11	+	0.95	0.00	+	0.77	0.05	+
10 × 80	1.00	0.00	+	0.88	0.00	+	0.44	0.10	+	0.99	0.00	+	0.75	0.02	+
10 × 90	1.00	0.00	+	0.92	0.00	+	0.35	0.14	+	0.96	0.00	+	0.68	0.14	+
10 × 100	1.00	0.00	+	0.89	0.01	+	0.37	0.06	+	0.96	0.00	+	0.67	0.02	+
20 × 10	1.00	0.00	+	1.00	0.00	+	0.06	0.01	+	1.00	0.00	+	1.00	0.02	+
20 × 20	1.00	0.00	+	1.00	0.00	+	0.40	0.01	+	1.00	0.00	+	0.94	0.00	+
20 × 30	1.00	0.00	+	1.00	0.00	+	0.47	0.13	+	1.00	0.00	+	0.97	0.00	+
20 × 40	1.00	0.00	+	1.00	0.00	+	0.40	0.12	+	1.00	0.00	+	0.97	0.00	+
20 × 50	1.00	0.00	+	1.00	0.00	+	0.54	0.17	+	1.00	0.00	+	0.93	0.00	+
20 × 60	1.00	0.00	+	0.98	0.00	+	0.34	0.02	+	0.99	0.00	+	0.93	0.00	+
20 × 70	1.00	0.00	+	1.00	0.00	+	0.43	0.11	+	1.00	0.00	+	1.00	0.00	+
20 × 80	1.00	0.00	+	0.81	0.00	+	0.53	0.12	+	0.97	0.00	+	0.92	0.00	+
20 × 90	1.00	0.00	+	0.91	0.00	+	0.43	0.05	+	1.00	0.00	+	1.00	0.00	+
20 × 100	1.00	0.00	+	0.96	0.00	+	0.55	0.02	+	1.00	0.00	+	1.00	0.00	+

表3 6种算法的IGD指标实验结果对比

Table 3 Experimental results comparison of the six algorithms via IGD-metric

算例	MPGA/D	SPGAI	t-test	NSGAI	t-test	MOEA/D	t-test	MOGLS	t-test	BMSA	t-test
10 × 10	0.0139	0.2076	+	0.1638	+	0.1064	~	0.1907	+	0.1117	~
10 × 20	0.0129	0.2471	+	0.0643	+	0.0324	+	0.1245	+	0.0200	+
10 × 30	0.0502	0.2476	+	0.0855	+	0.0687	+	0.1437	+	0.0583	~
10 × 40	0.0240	0.4712	+	0.1163	+	0.0673	+	0.1617	+	0.0536	+
10 × 50	0.0225	0.1645	+	0.0496	+	0.0399	+	0.0470	+	0.0386	+
10 × 60	0.0196	0.1622	+	0.0493	+	0.0344	+	0.0442	+	0.0328	+
10 × 70	0.0239	0.2643	+	0.0463	+	0.0450	+	0.0494	+	0.0358	+
10 × 80	0.0261	0.1863	+	0.0550	+	0.0451	+	0.562	+	0.0628	+
10 × 90	0.0175	0.1477	+	0.0355	+	0.0274	+	0.0477	+	0.0286	+
10 × 100	0.0165	0.2849	+	0.0315	+	0.0351	+	0.0432	+	0.0280	+
20 × 10	0.0289	0.3518	+	0.3337	+	0.1010	~	0.3113	+	0.2218	+
20 × 20	0.0118	0.4038	+	0.2323	+	0.0258	+	0.2841	+	0.1767	+
20 × 30	0.0477	0.4235	+	0.2513	+	0.0579	~	0.2802	+	0.1774	+
20 × 40	0.0210	0.5508	+	0.1998	+	0.0522	+	0.2842	+	0.1542	+
20 × 50	0.0263	0.2578	+	0.1452	+	0.0362	+	0.1454	+	0.1272	+
20 × 60	0.0193	0.2469	+	0.1460	+	0.0322	+	0.1376	+	0.1286	+
20 × 70	0.0196	0.3739	+	0.1595	+	0.0355	+	0.1681	+	0.1418	+
20 × 80	0.0157	0.2618	+	0.1223	+	0.0291	+	0.1288	+	0.1105	+
20 × 90	0.0185	0.2479	+	0.1232	+	0.0242	+	0.1327	+	0.1136	+
20 × 100	0.0187	0.3755	+	0.1410	+	0.0285	+	0.1594	+	0.1325	+

图 3 6种算法求解算例 10×50 的非支配解集对比Fig. 3 Comparison of the nondominated solution sets of 10×50 obtained by six algorithms图 4 6种算法求解算例 10×80 的非支配解集对比Fig. 4 Comparison of the nondominated solution sets of 10×80 obtained by six algorithms图 5 6种算法求解算例 20×80 的非支配解集对比Fig. 5 Comparison of the nondominated solution sets of 20×80 obtained by six algorithms

5 结论(Conclusions)

针对多目标流水线车间调度问题,考虑生产企业降低生产成本和下游客户满意水平的实际需求,建立了以最小化最迟完成时间和总延迟时间为目标的多目

标调度模型,并提出了一种算法迭代过程中多种群重新构造的多种群多目标遗传算法进行求解.该算法将多目标流水线调度问题分解为多个单目标子问题,并将这些子问题分阶段的引入到迭代过程进行求解.算法在每次迭代时,根据种群的分布信息为当前求解的子问题分别构造子种群进行求解.通过多种群与外部档案的信息交互,进一步改善和提高了非支配解集的质量和分布性.通过对一系列的标准算例进行仿真实验,结果验证了所提出的多种群策略的有效性.进一步与经典的多目标优化算法进行对比,结果表明所提出的算法在C指标及IGD指标方面能够取得较好的优化效果.

参考文献

- [1] GAREY M R, JOHNSON D S, SETHY R. The complexity of flowshop and job-shop scheduling [J]. *Mathematics of Operations Research*, 1976, 1(2): 117 – 129.
- [2] FRAMINAN J M, LEISTEN R, GARCÍA R R. *Manufacturing Scheduling Systems* [M]. London: Springer, 2014: 261 – 288.
- [3] YENISEY M M, YAGMAHAN B. Multi-objective permutation flow shop scheduling problem: Literature review, classification and current trends [J]. *Omega*, 2014, 45(2): 119 – 135.
- [4] GEN M, LIN L. Multiobjective evolutionary algorithm for manufacturing scheduling problems: state-of-the-art survey [J]. *Journal of Intelligent Manufacturing*, 2014, 25(5): 849 – 866.
- [5] CHANG P C, CHEN S H, ZHANG Q, et al. MOEA/D for flowshop scheduling problems [C] // *Proceeding of IEEE International Conference on Evolutionary Computation*, Hong Kong: IEEE, 2008: 1433 – 1438.
- [6] MURATA T, ISHIBUCHI H, TANAKA H. Multi-objective genetic algorithm and its applications to flowshop scheduling [J]. *Computers & Industrial Engineering*, 1996, 30(4): 957 – 968.
- [7] ZHANG L, GAO L, LI X. A hybrid genetic algorithm and tabu search for a multi-objective dynamic job shop scheduling problem [J]. *International Journal of Production Research*, 2013, 51(12): 3516 – 3531.
- [8] ARROYO J E C, ARMENTANO V A. Genetic local search for multi-objective flowshop scheduling problems [J]. *European Journal of Operational Research*, 2005, 167(3): 717 – 738.
- [9] ZHANG Chaoyong, DONG Xing, WANG Xiaojuan, et al. Improved NSGA-II for the multiobjective flexible job-shop scheduling problem [J]. *Journal of Mechanical Engineering*, 2010, 46(11): 156 – 164.
(张超勇, 董星, 王晓娟, 等. 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 [J]. *机械工程学报*, 2010, 46(11): 156 – 164.)
- [10] ZHU Guangyu, CHEN Xubin, LIU Yanli. Flow shop multi-objective scheduling optimization research based on grey entropy relation analysis and the algorithm realization [J]. *Control and Decision*, 2014, 29(1): 135 – 140.
(朱光宇, 陈旭斌, 刘艳立. 基于灰熵关联分析的流水线车间多目标调度优化及算法实现 [J]. *控制与决策*, 2014, 29(1): 135 – 140.)
- [11] COCHRAN J K, HORNG S M, FOWLER J W. A multi-population genetic algorithm to solve multi-objective scheduling problems for parallel machines [J]. *Computers & Operations Research*, 2003, 30(7): 1087 – 1102.
- [12] ZANDIEH M, KARIMI N. An adaptive multi-population genetic algorithm to solve the multi-objective group scheduling problem in hybrid flexible flowshop with sequence-dependent setup times [J]. *Journal of Intelligent Manufacturing*, 2011, 22(6): 979 – 989.

- [13] CHANG P C, CHEN S H, LIN K L. Two-phase sub population genetic algorithm for parallel machine-scheduling problem [J]. *Expert Systems with Applications*, 2005, 29(3): 705 – 712.
- [14] CHANG P C, CHEN S H, LIU C H. Sub-population genetic algorithm with mining gene structures for multiobjective flow shop scheduling problem [J]. *Expert Systems with Applications*, 2007, 33(3): 762 – 771.
- [15] CHANG P C, CHEN S H. The development of a sub-population genetic algorithm II (SPGA II) for multi-objective combinatorial problems [J]. *Applied Soft Computing*, 2009, 9(1): 173 – 181.
- [16] RASHIDI E, JAHANDAR M, ZANDIEH M. An improved hybrid multi-objective parallel genetic algorithm for hybrid flow shop scheduling with unrelated parallel machines [J]. *The International Journal of Advanced Manufacturing Technology*, 2010, 49(9/10/11/12): 1129 – 1139.
- [17] 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.
- [18] ISHIBUCHI H, YOSHIDA T, MURATA T. Balance between genetic search and local search in memetic algorithms for multiobjective permutation flowshop scheduling [J]. *IEEE Transactions on Evolutionary Computation*, 2003, 7(2): 204 – 223.
- [19] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182 – 197.
- [20] LIN S W, YING K C. Minimizing makespan and total flowtime in permutation flowshops by a bi-objective multi-start simulated-annealing algorithm [J]. *Computers & Operations Research*, 2013, 40(6): 1625 – 1647.
- [21] ZITZLER E, THIELE L. Multiobjective optimization using evolutionary algorithms—a comparative case study [C] // *Parallel problem solving from nature—PPSN V*. Berlin, Germany: Springer Berlin Heidelberg, 1998: 292 – 301.
- [22] ZITZLER E, THIELE L, LAUMANN M, et al. Performance assessment of multiobjective optimizers: an analysis and review [J]. *IEEE Transactions on Evolutionary Computation*, 2003, 7(2): 117 – 132.

作者简介:

付亚平 (1985–), 男, 博士研究生, 研究方向为多目标优化算法、生产计划与调度, E-mail: fuyaping@qdu.edu.cn;

黄敏 (1968–), 女, 博士, 教授, 博士生导师, 研究方向为物流与供应链管理、生产计划、调度与存储控制、风险管理和软计算等, E-mail: mhuang@mail.neu.edu.cn;

王洪峰 (1979–), 男, 博士, 副教授, 硕士生导师, 研究方向为进化计算、生产及供应链管理, E-mail: hfwang@mail.neu.edu.cn;

王兴伟 (1968–), 男, 博士, 教授, 博士生导师, 研究方向为分布式优化与决策、计算机网络、分布式多媒体系统等, E-mail: wangxw@mail.neu.edu.cn.