

控制与决策

Control and Decision

基于多维EDA算法的低碳分布式装配流水车间调度

张梓琪, 钱斌, 胡蓉, 王凌, 向凤红

引用本文:

张梓琪, 钱斌, 胡蓉, 王凌, 向凤红. 基于多维EDA算法的低碳分布式装配流水车间调度[J]. 控制与决策, 2022, 37(5): 1367–1377.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1475>

您可能感兴趣的其他文章

Articles you may be interested in

区间数可重入混合流水车间调度与预维护协同优化

Collaborative optimization of interval number reentrant hybrid flow shop scheduling and preventive maintenance

控制与决策. 2021, 36(11): 2599–2608 <https://doi.org/10.13195/j.kzyjc.2020.0973>

超启发式交叉熵算法求解模糊分布式流水线绿色调度问题

Hyper-heuristic cross-entropy algorithm for green distributed permutation flow-shop scheduling problem with fuzzy processing time

控制与决策. 2021, 36(6): 1387–1396 <https://doi.org/10.13195/j.kzyjc.2019.1681>

基于改进蛙跳算法的分布式两阶段混合流水车间调度

An improved shuffled frog leaping algorithm for the distributed two-stage hybrid flow shop scheduling

控制与决策. 2021, 36(1): 241–248 <https://doi.org/10.13195/j.kzyjc.2019.0472>

基于深度强化学习与迭代贪婪的流水车间调度优化

Scheduling optimization for flow-shop based on deep reinforcement learning and iterative greedy method

控制与决策. 2021, 36(11): 2609–2617 <https://doi.org/10.13195/j.kzyjc.2020.0608>

基于多班教学优化的多目标分布式混合流水车间调度

Multi-class teaching-learning-based optimization for multi-objective distributed hybrid flow shop scheduling

控制与决策. 2021, 36(2): 303–313 <https://doi.org/10.13195/j.kzyjc.2020.0549>

基于多维EDA算法的低碳分布式装配流水车间调度

张梓琪^{1,2}, 钱 斌^{1,2†}, 胡 蓉², 王 凌³, 向凤红²

(1. 昆明理工大学 机电工程学院, 昆明 650500; 2. 昆明理工大学
信息与自动化学院, 昆明 650500; 3. 清华大学 自动化系, 北京 100084)

摘 要: 针对低碳分布式装配置换流水车间调度问题(LC_DAPFSP), 建立以同时最小化总能耗和总完工时间为优化目标的数学模型, 进而提出一种多维分布估计算法(MEDA)以进行求解. 首先, 采用随机方法和启发式算法共同生成初始化种群; 其次, 建立基于矩阵立方体的概率模型, 用于合理学习并积累优质解的块结构信息和序关系信息, 同时设计有效采样机制对概率模型采样以生成新种群, 从而合理引导算法搜索方向并发现可行解空间中的优质解区域; 然后, 为平衡算法的全局探索与局部开发能力, 提出基于问题特性的变邻域局部搜索方法, 可对全局搜索发现的优质解区域进行细致搜索; 最后, 通过仿真实验与算法对比验证MEDA是求解LC_DAPFSP的有效算法.

关键词: 分布估计算法; 分布式置换流水车间调度; 装配线; 低碳调度

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1475

引用格式: 张梓琪, 钱斌, 胡蓉, 等. 基于多维 EDA 算法的低碳分布式装配流水车间调度[J]. 控制与决策, 2022, 37(5): 1367-1377.

Multidimensional estimation of distribution algorithm for low carbon scheduling of distributed assembly permutation flow-shop

ZHANG Zi-qi^{1,2}, QIAN Bin^{1,2†}, HU Rong², WANG Ling³, XIANG Feng-hong²

(1. School of Mechanical and Electronic Engineering, Kunming University of Science and Technology, Kunming 650500, China; 2. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 3. Department of Automation, Tsinghua University, Beijing 100084, China)

Abstract: For the low carbon distributed assembly permutation flow-shop scheduling problem(LC_DAPFSP), a mathematical model with the goal of minimizing the total energy consumption and the makespan is established, and then a multidimensional estimation of distribution algorithm (MEDA) is proposed to solve this problem. Firstly, a population is initialized by utilizing a random method and a heuristic algorithm. Secondly, a matrix-cube-based probabilistic model is developed to reasonably learn and accumulate the information of the job blocks and the jobs' order from the superior solutions, and an effective sampling mechanism is designed to sample the probability model to generate new population, so as to reasonably guide the searching directions and find the promising regions in the solution space. Then, to balance the exploration and the exploitation capabilities of the algorithm, a problem-dependent variable neighborhood search method is developed to perform an in-depth exploitation in the promising regions found by the global search. Finally, simulations and comparisons demonstrate that the proposed MEDA can effectively solve the LC_DAPFSP.

Keywords: estimation of distribution algorithm; distributed permutation flowshop scheduling; assembly line; low carbon scheduling

0 引 言

低碳制造作为综合考虑环境影响和资源效益的可持续制造模式, 对于应对气候变化、实现绿色发展至关重要. 低碳调度问题及其优化方法是实施低碳制造的重要途径, 越来越受到研究者的关注和重视. 因此, 低碳生产调度已成为车间调度领域的研

究热点^[1-2]. 近年来, 在低碳生产调度的研究与应用方面涌现出大量成果, 例如低碳单机调度问题^[3]、低碳并行机调度问题^[4]、低碳置换流水车间调度问题(PFSP)^[5-6]、低碳模糊流水车间调度问题(FSP)^[7]、低碳混合 FSP^[8-12]、低碳零等待 PFSP^[13-14]、低碳阻塞 PFSP^[15]、低碳作业车间调度问题(JSP)^[16-17], 还有较

收稿日期: 2020-10-27; 录用日期: 2021-03-16.

基金项目: 国家自然科学基金项目(51665025, 61963022, 62173169, 61873328); 国家杰出青年科学基金项目(61525304).

责任编辑: 刘士新.

†通讯作者. E-mail: bin.qian@vip.163.com.

复杂的低碳分布式PFSP^[18-19]、低碳分布式JSP^[20]、低碳柔性FSP^[21]和低碳柔性JSP^[22-24]以及钢铁工业中存在的低碳炼钢-连铸调度问题^[25]。在经济全球化背景下,大量企业由传统集中式制造模式向跨区域协同合作制造转变,分布式制造与调度已成为趋势。

为了能有效管控产品质量,降低生产成本与管理风险,企业通常将客户订单拆分为各类标准件,分配到不同工厂加工处理,然后再统一组装各类零部件形成产品,最后按需交付。针对分布式装配系统展开研究不仅能实现资源合理配置,还能协调整合资源,进而提高生产效益,提升企业竞争力和可持续发展能力^[26]。分布式装配调度问题(DAPFSP)通常考虑优化时间成本或经济指标,较少研究节能降耗或减少碳排放,导致现有研究成果难以解决低碳分布式调度问题。因此,综合考虑环境影响和资源效益,研究面向装配制造业的低碳分布式装配流水车间调度理论与方法意义重大。LC_DAPFSP是DAPFSP在低碳节能层面的扩展,是一种典型的设备可调速且两阶段耦合的多目标优化调度问题,需要协同优化生产效率指标(总完工时间)和能耗指标(总碳排放),该问题核心难点在于可行解空间复杂且多变,很难在有限的时间内获取满意的调度方案。在计算复杂度上,DAPFSP是NP-hard问题^[27],而LC_DAPFSP又为DAPFSP中的一类问题,故LC_DAPFSP也是NP-hard问题。从问题求解层面看,该问题具有大规模、多目标、强耦合等复杂性,因此,研究LC_DAPFSP的建模与求解具有重要的学术意义和工程应用价值。

现有优化问题的求解方法主要包括数学规划算法、启发式算法和智能优化算法^[26]。数学规划算法往往依赖于问题的几何结构特性,虽然对于较简单问题可在理论层面保证解的最优性,但此类算法因其较高时间与空间复杂度的限制往往难以实际应用;启发式算法基于调度规则与问题约束来构造问题解,虽然能在较短时间内给出问题的可行解,但难以保证解的质量;智能优化算法结合自身搜索机制和高效邻域搜索策略,能够在合理的时间内给出较为满意的解,在解决非凸、强耦合的复杂非线性优化问题方面具有显著优势,近年来不仅被广泛应用于求解大量单目标优化问题,同时也成功地用于求解各类多目标优化问题。低碳流水车间调度问题不仅考虑最小化传统经济指标,同时也考虑最小化能耗或碳排放指标,属于典型的多目标优化问题。智能优化算法已成为当前有效求解该类问题的主要方法。在智能优化算法求解低碳PFSP方面,优化目标主要考虑同时最小化

最大完工时间和总能耗,Ding等^[5]提出了一种多目标NEH算法和一种改进多目标迭代贪婪(MMOIG)算法。Lu等^[6]设计了一种混合多目标回溯搜索算法(HMOBSA)。另外,Wu等^[13]针对低碳零等待PFSP,提出了一种自适应邻域下降(VND)算法。Yüksel等^[14]针对低碳零等待PFSP,设计了一种离散人工蜂群(DABC)算法。Han等^[15]针对低碳阻塞PFSP,提出了一种多目标进化算法。Chen等^[18]针对低碳分布式PFSP,提出了一种协进化优化算法。Wang等^[19]针对低碳分布式PFSP,提出了一种基于知识驱动的合作算法(KCA)。此外,在智能优化算法求解低碳FSP方面,Liu等^[7]针对优化目标为同时最小化总能耗与拖期惩罚的带状态相关设置时间的模糊FSP,提出了一种遗传算法与启发式算法相结合的混合求解算法。Lei等^[8]针对优化目标为同时最小化总能耗和总延迟时间的混合FSP,提出了一种教学优化(TLBO)算法进行求解。Li等^[9]针对优化目标为同时最小化最大完工时间和能耗的混合FSP,设计了一种能量感知优化算法进行求解。Zhang等^[10]针对优化目标为同时最小化最大完工时间和总能耗的混合FSP,设计了一种基于分解的3阶段优化算法进行求解。Jiang等^[12]针对优化目标为同时最小化总加权延迟和非加工能耗的带有限缓冲区的混合FSP,提出了一种改进MOEA/D算法进行求解。Gong等^[21]针对一类柔性FSP,提出一种混合进化算法并探讨了工人弹性作业与生产效率、总能耗和成本之间的关系。在智能优化算法求解DAPFSP方面,目前的研究主要集中在对经济指标进行优化。Hatami等^[27]最早对DAPFSP进行研究,建立了混合整数线性规划模型,并提出3种启发式算法和一种快速VND算法进行求解。随后,Wang等^[28]提出了一种基于分布估计算法的模因算法进行求解。Lin等^[29-30]分别提出了一种混合生物地理学优化算法和一种超启发式回溯搜索算法。Zhang等^[31]提出了一种基于矩阵立方的分布估计算法。纵观DAPFSP的研究进展,本文在优化目标为最小化最大完工时间的基础上,进一步考虑最小化碳排放。根据智能优化算法求解低碳PFSP、低碳FSP和DAPFSP的研究现状可知,目前尚无针对LC_DAPFSP这类问题的建模与求解研究,亟需开展这方面的工作。

分布估计算法(EDA)是一种基于统计学习的新兴智能优化算法。相较于传统进化算法,EDA从宏观角度学习种群中的优质个体特征,通过建立概率模型估计优质个体分布,通过采样概率模型产生新种群,从而引导算法的搜索方向。EDA可以通过概率模型

学习优化问题可行解的结构特征,进而实现对非线性性和变量耦合的复杂优化问题的求解. EDA 由于具有全局寻优能力强、结构简单、易实现等优点,近年来受到了众多学者的关注与研究^[28,31-33]. 到目前为止,EDA 已被成功地应用于解决诸多领域的优化问题,包括生产制造、交通物流、化工制药、电力能源等. 另外,EDA 在生产调度领域的应用也取得了较多的研究成果. Wang 等^[28]针对优化目标为最小化最大完工时间的 DAPFSP,提出了一种基于二维概率模型的 EDA 进行求解. 随后,Zhang 等^[31]提出了一种基于矩阵立方的 EDA 对 DAPFSP 进行求解,算法利用三维概率模型学习并积累优质解中工件的序信息和相似块的位置信息. Pan 等^[32]针对带设置时间的批量流水线车间调度问题,提出了一种二维 EDA 进行求解,算法利用两个二维概率矩阵记录优质解中工件的序信息并统计相似块出现的频数信息. Wang 等^[33]针对优化目标为最小化最大完工时间的分布式 PFSP,提出了一种二维 EDA 进行求解.

尽管 EDA 在各类优化调度问题的求解上展现出良好的性能,但目前大多数的研究仅考虑通过二维概率模型来学习优质解信息,并不能准确记录相似块在优质解中的具体位置信息,当采样生成新个体时,相似块可能会因放置不合理而导致算法低效. 例如,对于两个优质解 [1, 2, 3, 4] 和 [2, 3, 1, 4], 其中 [2, 3] 为 1 个相似块, [2, 3] 既出现在 [1, 2, 3, 4] 中的第 2 个位置,同时又出现在 [2, 3, 1, 4] 中的第 1 个位置. 如果采用二维概率模型只能将 [2, 3] 的“出现概率”存贮在下标为 (2, 3) 的元素中,其中下标本身使得 2 前 3 后的序信息得以保留,但无法区分 [2, 3] 在各可行解中的具体位置信息. 显然,如果采用三维概率模型,则前一个解和后一个解中 [2, 3] 的“出现概率”可分别存贮在下标为 (2, 2, 3) 和 (1, 2, 3) 的元素中,即三维概率模型的第一维下标可保留相似块的位置信息. 鉴于此,本文提出一种多维分布估计算法用于同时学习并积累种群中优质个体的工件序信息和相似块位置信息,继而在每代采样生成新个体时能较准确地确定优良相似块在调度解中的具体位置,从而可以更为合理地引导种群的进化方向,提高算法的搜索效率. 目前,尚无 EDA 求解 LC_DAPFSP 的相关研究报道.

本文针对以总能耗和总完工时间为优化目标的 LC_DAPFSP,提出一种多维 EDA(MEDA)方法. 首先,建立问题的数学模型;其次,分析问题的性质,基于性质设计节能调速策略以合理缩小可行搜索区域,提高算法搜索效率;然后,通过基于三维概率模型的全局

搜索和基于多邻域结构的局部搜索,实现对问题可行解空间的有效搜索;最后,通过在不同测试集上的大量计算实验来验证所提出 MEDA 的有效性和优越性.

1 问题描述及性质分析

1.1 LC_DAPFSP 描述

本文研究的低碳 DAPFSP 可以描述为: n 个工件 $J = \{J_1, J_2, \dots, J_n\}$ 分配到 F 个工厂加工再装配成 S 个产品,每个产品由特定工件组成并且每个工件仅属于一个产品. 生产过程分为两个阶段,即加工阶段和装配阶段. 加工阶段有 F 个工厂,每个工厂有相同的 m 台机器 $M = \{M_1, M_2, \dots, M_m\}$ 组成的一条加工流水线,每台机器都有 d 种可调的速度档位,对应的加工速度为 $V = \{v_1, v_2, \dots, v_d\}$. 每个工件 J_i 需要按顺序依次完成 m 道加工工序 $\{O_{i1}, O_{i2}, \dots, O_{im}\}$, 工序 O_{ij} 表示工件 J_i 在机器 M_j 上的加工操作,其基本加工时间为 p_{ij} . 当机器 M_j 以速度 v_k 加工工件 J_i 时,相应的实际加工时间为 $\hat{p}_{ij}^k = p_{ij}/v_k$,单位时间能耗为 E_{jk} . 如果机器上未加工工件,则该机器处于待机状态,单位时间瞬时能耗为 SE_j . 产品 h 对应的所有工件完工以后,在装配线上完成该产品的装配操作,装配时间为 p_h^A . 低碳 DAPFSP 包含 3 个子问题: 分配工件到工厂、确定工件加工顺序以及选择机器加工速度. 为了更加直观,图 1 为 LC_DAPFSP 的示意图.




图 1 LC_DAPFSP 示意图

同时假设:不考虑释放时间,即工件和机器相互独立且在零时刻即可加工;不考虑机器故障和设置时间,即机器连续可用;不考虑运输时间,即工件加工完成就可装配;每个工件分配到工厂后不能更换工厂,任一时刻工件仅在一台机器上加工,一台机器仅能加工一个工件;机器加工速度在工件加工过程中保持不变. LC_DAPFSP 的调度目标是确定工件在工厂上的分配情况、工件加工顺序与产品装配顺序以及机器加工速度设置,生产效率指标为最小化总完工时间,能耗指标为最小化总碳排放. 本文不仅在文献 [28] 问题模型的基础上进一步增加了最小化总碳排放的优化目标,而且还基于节能考虑,将加工阶段的

工件加工时间设置为可调(取决于机器实际加工速度),故求解的是较文献[28]更复杂(即具有更多决策变量)的多目标优化问题.

定义 $\pi = [\pi_1, \pi_2, \dots, \pi_n]$ 为工件序列, $\pi^f = [\pi_1^f, \pi_2^f, \dots, \pi_{n_f}^f]$ 为工厂 f 中的加工序列, n_f 为分配到工厂 f 中的工件数, $(\sum_{f=1}^F n_f = n)$, $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]$ 为产品的装配序列, C_{ij} 为工序 O_{ij} 的完工时间, S_h^A 为产品 h 的最早可装配时间, C_h^A 为产品 h 的装配完工时间. 基于以上描述,建立如下模型:

$$C_{\pi_1^f,1} = \hat{p}_{\pi_1^f,1}^k, f = 1, \dots, F, k = 1, \dots, d; \quad (1)$$

$$C_{\pi_i^f,1} = C_{\pi_{i-1}^f,1} + \hat{p}_{\pi_i^f,1}^k, \\ i = 2, \dots, n_f, f = 1, \dots, F, k = 1, \dots, d; \quad (2)$$

$$C_{\pi_1^f,j} = C_{\pi_1^f,j-1} + \hat{p}_{\pi_1^f,j}^k, \\ j = 2, \dots, m, f = 1, \dots, F, k = 1, \dots, d; \quad (3)$$

$$C_{\pi_i^f,j} = \max\{C_{\pi_{i-1}^f,j}, C_{\pi_i^f,j-1}\} + \hat{p}_{\pi_i^f,j}^k, \\ i = 2, \dots, n_f, j = 2, \dots, m, f = 1, \dots, F; \quad (4)$$

$$S_{\lambda_h}^A = \max_{\pi_i^f \in \lambda_h} C_{\pi_i^f,m}$$

$$i = 1, \dots, n_f, f = 1, \dots, F, h = 1, \dots, S; \quad (5)$$

$$C_{\lambda_1}^A = S_{\lambda_1}^A + p_{\lambda_1}^A; \quad (6)$$

$$C_{\lambda_h}^A = \max\{C_{\lambda_{h-1}}^A, S_{\lambda_h}^A\} + p_{\lambda_h}^A, h = 2, \dots, S; \quad (7)$$

$$C_{\max}(\pi, V) = C_{\lambda_S}^A; \quad (8)$$

$$\text{TCE}(\pi, V) = \\ \varepsilon \int_0^{C_{\max}} \left(\sum_{j \in M} E_{jk} x_{jk}^t + \sum_{j \in M} \text{SE}_j y_j^t \right) dt; \quad (9)$$

$$(\pi^*, V^*) = \\ \arg \min_{\pi \in \Pi, V \in \Sigma} \{C_{\max}(\pi, V), \text{TCE}(\pi, V)\}. \quad (10)$$

式(9)中: x_{jk}^t 和 y_j^t 为二进制变量,即如果机器 M_j 在 t 时刻以速度 v_k 加工工件,则 $x_{jk}^t = 1$,否则 $x_{jk}^t = 0$;若机器 M_j 在 t 时刻处于待机状态,则 $y_j^t = 1$,否则 $y_j^t = 0$. 式(10)中: C_{\max} 为最大完工时间;TCE为总碳排放; ε 为能耗与碳排放量之间的转换系数,通常取值为0.7559.

LC_DAPFSP的优化目标为,在所有可行的调度方案集 (Π, Σ) 中找到最优的调度方案 (π^*, V^*) ,使得该方案所对应的生产效率指标与总能耗指标最优. 图2为LC_DAPFSP的一个调度解甘特图.




图2 LC_DAPFSP的调度解甘特图

1.2 多目标优化相关概念

LC_DAPFSP 需要协同考虑生产效率指标和能耗指标,且两指标间存在一定的冲突关系,最优调度方案是一组非支配解而非单个解,必须通过支配关系来确定最优解集. 假设目标数为 N_G , 问题解空间为 Ω , 下面给出 Pareto 最优的几个相关概念.

1) Pareto 支配: 对于可行解 $x \in \Omega$ 和 $y \in \Omega$, 如果对于 $\forall i \in \{1, \dots, N_G\}$ 满足 $f_i(x) \leq f_i(y)$ 且 $\exists i \in$

$\{1, \dots, N_G\}$ 有 $f_i(x) < f_i(y)$, 则 x 支配 y , 记作 $x < y$.

2) Pareto 最优集 (Pareto optimal set): 对于解 $x \in \Omega$ 为 Pareto 最优解当且仅当 $\neg \exists y \in \Omega$, 有 $y < x$. Pareto 最优解所组成的集合称为 Pareto 最优集 Ω^* .

3) Pareto 最优前沿 (Pareto optimal front, PF): Pareto 最优前沿 PF 由 Pareto 最优集中所有元素构成, $\text{PF} = \{F(x) = [f_1(x), f_2(x), \dots, f_{N_G}(x)]^T | x \in \Omega^*\}$.

4) 非劣解集(non-dominated set): 对于解集 Ω'' , 若存在解集 $\Omega' \subseteq \Omega''$ 对于 $\forall \mathbf{a} \subseteq \Omega'$ 和 $\mathbf{b} \subseteq \Omega''$, 满足条件 $\neg \exists \mathbf{b} < \mathbf{a}$ 且 $\mathbf{a} \neq \mathbf{b}$, 则 Ω' 为非劣解集.

1.3 问题性质分析

LC_DAPFSP 是一类典型的机器可调速且两阶段耦合的复杂调度问题, 即机器速度决定加工方式, 加工阶段影响装配阶段, 装配阶段是建立在加工阶段结果基础之上. 不仅要考虑生产效率指标, 还要满足低碳生产要求, 这些约束限制使得该问题的可行域空间变得十分复杂, 导致在有限时间内要获取满意的调度方案难度较大. 因此, 在设计EDA求解该问题时, 不仅要建立有效的概率模型来学习优质解的特征, 以克服解空间复杂的不利因素, 还要结合问题结构性质来合理缩小搜索范围以避免无效搜索, 使算法将有限的搜索集中在问题解空间中存在优质解的区域进行, 以提高算法搜索效率. Ding 等^[5]给出了一种加工时间与能耗间关系的假设: 工件 J_i 在机器 M_j 上以更高的速度加工时, 该工件的加工时间将减小而且其总加工能耗增大, 即 $\forall v_{k1} > v_{k2}, v_{k1}, v_{k2} \in V$, 则 $\hat{p}_{ij}^{k1} < \hat{p}_{ij}^{k2}$ 且有 $\hat{p}_{ij}^{k1} \cdot E_{jk1} > \hat{p}_{ij}^{k2} \cdot E_{jk2}$. 显然, 问题优化目标 C_{\max} 与 TCE 二者之间不可避免地存在冲突关系. 在保证整体 C_{\max} 不变的情况下, 对各工厂内的机器适当降速, 可以有效降低 TCE. 根据该性质, 本节设计一种节能调速策略, 使得在保持关键路径上工件加工速度不变的前提下, 调整非关键路径上部分工件的加工速度以降低总能耗, 进而提高算法获取低能耗优质解的能力. 具体步骤如下.

step 1: 找出可行调度方案 (π, \mathbf{V}) 的关键路径. 问题的关键路径直接决定了生产效率指标 C_{\max} .

step 2: 判断非关键路径上的工件是否满足降速条件. 机器上当前工件的完工时间到下一个工件的开工时间之间存在时间余量且工件的加工速度不是最低档位速度. 若不满足则不降速, 否则进行下一步.

step 3: 将工件加工速度降低一个档位. 由于加工速度为离散值, 执行降速操作时需要保证该工件加工时间的增量不会影响 step 1 中确定的关键路径. 如果影响则不执行降速, 否则转到 step 2.

2 多维分布估计算法MEDA

2.1 编码和解码

置换流水线车间调度问题通常采用一个 n 维的加工优先级向量 π 来表示问题的可行调度解^[5-6]. 对于 LC_DAPFSP, 为了将工件按顺序依次分配到各工厂中, 得到可行且有效的调度方案, 采用文献[27]中提出的 NR2 分配规则对加工序列 π 进行解码. 同时还

要考虑各机器的加工速度, 故可行解表示为 (π, \mathbf{V}) . 具体而言, 首先对序列 π 中待分配的工件按 NR2 规则依次分配到各工厂中的机器上; 然后根据速度矩阵 \mathbf{V} 分别计算每个工厂的完工时间, 将工件分配到能够使其最早加工完成的工厂中; 最后再根据各产品所对应工件的加工完成时间确定产品的装配顺序.

2.2 块结构与矩阵立方体

对于 LC_DAPFSP 的一个解 (π, \mathbf{V}) , 工件块定义为工件序列 π 中连续相邻的两个工件. 显然, π 可由出现在不同位置上的工件块所构成. 种群内各可行解中不同位置上出现的相同工件块定义为相似块, 例如, 对于两个工件序列 $\pi' = [3, 2, 1, 4]$ 和 $\pi'' = [4, 3, 2, 1]$, 其中 $[3, 2]$ 、 $[2, 1]$ 、 $[1, 4]$ 和 $[4, 3]$ 为工件块, 而 $[3, 2]$ 和 $[2, 1]$ 为相似块, 因为 $[3, 2]$ 和 $[2, 1]$ 不仅出现在 π' 中, 同时还在 π'' 中出现. 为了研究调度问题排序模型可行解空间中解序列的块结构分布特征, 本节设计一种矩阵立方体数据结构, 该数据结构能够准确地记录工件的序关系信息和块结构的分布信息, 并通过统计的方式记录种群中优质个体的结构特征, 以此构建更加有效的 EDA 概率模型.

定义 $\mathbf{Pop}(\mathbf{G}) = \{\pi^{\mathbf{G},1}, \pi^{\mathbf{G},2}, \pi^{\mathbf{G},\text{sps}}\}$ 为算法第 G 代的种群, 最大进化代数为 $\max G$. $\mathbf{SPop}(\mathbf{G}) = \{\pi_{\text{sbest}}^{\mathbf{G},1}, \pi_{\text{sbest}}^{\mathbf{G},2}, \dots, \pi_{\text{sbest}}^{\mathbf{G},\text{sps}}\}$ 为选取的优质子种群, 其中, sps 为 $\mathbf{Pop}(\mathbf{G})$ 的规模, sps 为 $\mathbf{SPop}(\mathbf{G})$ 的规模. 令 $\pi_{\text{sbest}}^{\mathbf{G},k}$ 表示 $\mathbf{SPop}(\mathbf{G})$ 中的第 k 个个体, 其中 $\pi_{\text{sbest}}^{\mathbf{G},k} = [\pi_{\text{sbest},1}^{\mathbf{G},k}, \pi_{\text{sbest},2}^{\mathbf{G},k}, \dots, \pi_{\text{sbest},n}^{\mathbf{G},k}]$. 定义 $\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}$ 为矩阵立方体, 用以保存第 G 代优质种群的统计特征, $\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(x, y, z)$ 为 $\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}$ 中的元素, $\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}$ 的具体描述如下:

$$\text{IF}_{(x,y,z)}^{\mathbf{G},k} = \begin{cases} 1, & y = \pi_{\text{sbest},x}^{\mathbf{G},k}, z = \pi_{\text{sbest},x+1}^{\mathbf{G},k}; \\ 0, & \text{otherwise}; \end{cases}$$

$$x, y, z = 1, 2, \dots, n; x \neq n; k = 1, 2, \dots, \text{sps}. \quad (11)$$

$$\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(x, y, z) = \sum_{k=1}^{\text{sps}} \text{IF}_{(x,y,z)}^{\mathbf{G},k},$$

$$x = 1, 2, \dots, n-1; y, z = 1, 2, \dots, n. \quad (12)$$

$$\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(\mathbf{x}, \mathbf{y}) = [\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(x, y, 1), \mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(x, y, 2), \dots, \mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(x, y, n)],$$

$$x = 1, 2, \dots, n-1; y = 1, 2, \dots, n. \quad (13)$$

$$\mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(\mathbf{x}) = \begin{bmatrix} \mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(\mathbf{x}, 1) \\ \vdots \\ \mathbf{MC}_{n \times n \times n}^{\mathbf{G}}(\mathbf{x}, n) \end{bmatrix}_{n \times 1} =$$

$$\begin{bmatrix} \text{MC}_{n \times n \times n}^G(x, 1, 1) & \dots & \text{MC}_{n \times n \times n}^G(x, 1, n) \\ \vdots & \ddots & \vdots \\ \text{MC}_{n \times n \times n}^G(x, n, 1) & \dots & \text{MC}_{n \times n \times n}^G(x, n, n) \end{bmatrix}. \quad (14)$$

式(11)中 $\text{IF}_{(x,y,z)}^{G,k}$ 为示性函数,用于记录 $\text{SPop}(G)$ 中第 k 个个体 $\pi_{\text{sbest}}^{G,k}$ 的统计特征信息,即块结构 $[\pi_{\text{sbest},x}^{G,k}, \pi_{\text{sbest},x+1}^{G,k}]$ 在 $\pi_{\text{sbest}}^{G,k}$ 中第 x 位置上出现的信息;式(12)中 $\text{MC}_{n \times n \times n}^G(x, y, z)$ 用于累计块结构出现次数,即统计 $\text{SPop}(G)$ 中全部个体的块结构分布信息;式(13)和(14)给出了矩阵立方体的层次结构,其中 $\text{MC}_{n \times n \times n}^G(x)$ 用于存储 $\text{SPop}(G)$ 中全部个体的第 x 位置上的块结构 $[\pi_{\text{sbest},x}^{G,k}, \pi_{\text{sbest},x+1}^{G,k}]$ 的统计信息.显然,通过一系列基于位置关系的二维矩阵 $\text{MC}_{n \times n \times n}^G(1), \text{MC}_{n \times n \times n}^G(2), \dots, \text{MC}_{n \times n \times n}^G(n)$ 所组成的 $\text{MC}_{n \times n \times n}^G$,EDA 能够准确且有效地学习并保存每代种群中优质个体的序关系信息和相似块分布信息.图3为针对5个优质个体的块结构统计示意图.

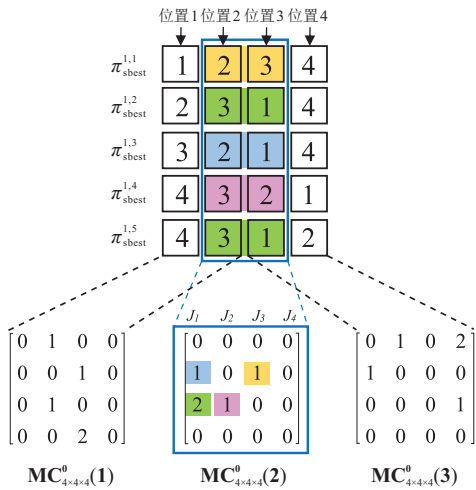


图3 矩阵立方体积累相似块的示意图

2.3 概率模型

概率模型对于EDA至关重要,设计得合理与否将直接影响算法的性能^[31].MEDA采用三维概率模型学习并积累优质个体的工件序关系信息和相似块分布信息.定义 $\text{PM}_{n \times n \times n}^G$ 为基于 $\text{MC}_{n \times n \times n}^G$ 的三维概率模型, $\text{PM}_{n \times n \times n}^G(x, y, z)$ 为 $\text{PM}_{n \times n \times n}^G$ 中的元素,调度解序列 π 中位置 x 上块结构的概率分布如下:

$$\text{PM}_{n \times n \times n}^G(x) = \begin{bmatrix} \text{PM}_{n \times n \times n}^G(x, 1) \\ \vdots \\ \text{PM}_{n \times n \times n}^G(x, n) \end{bmatrix}_{n \times 1} = \begin{bmatrix} \text{PM}_{n \times n \times n}^G(x, 1, 1) & \dots & \text{PM}_{n \times n \times n}^G(x, 1, n) \\ \vdots & \ddots & \vdots \\ \text{PM}_{n \times n \times n}^G(x, n, 1) & \dots & \text{PM}_{n \times n \times n}^G(x, n, n) \end{bmatrix}. \quad (15)$$

为了更新概率模型 $\text{PM}_{n \times n \times n}^G$,定义 $N_{\text{MC}}^G(x)$ 为

$\text{SPop}(G)$ 中优质个体位置 x 上出现的块结构总数,即

$$N_{\text{MC}}^G(x) = \sum_{y=1}^n \sum_{z=1}^n \text{MC}_{n \times n \times n}^G(x, y, z).$$

同理,定义 $N_{\text{PM}}^G(x)$ 为优质子种群 $\text{SPop}(G)$ 中不同的块结构出现在第 x 位置上概率的总和,即

$$N_{\text{PM}}^G(x) = \sum_{y=1}^n \sum_{z=1}^n \text{PM}_{n \times n \times n}^G(x, y, z).$$

具体更新步骤如下.

step 1: 当 $G = 0$ 时,按下式初始化概率模型:

$$\text{PM}_{n \times n \times n}^0(x, y, z) = \begin{cases} 1/n, & x = 1, y, z = 1, \dots, n; \\ 1/n^2, & x = 2, 3, \dots, n-1, y, z = 1, \dots, n. \end{cases} \quad (16)$$

step 2: 当 $G = 1$ 时,先按式(11)~(14)计算矩阵立方体 $\text{MC}_{n \times n \times n}^0$,再按下式更新概率模型:

$$\text{PM}_{n \times n \times n}^1(x, y, z) = \begin{cases} \text{MC}_{n \times n \times n}^0(x, y, z) / N_{\text{MC}}^0(x), & x = 1; \\ [\text{PM}_{n \times n \times n}^0(x, y, z) + \text{MC}_{n \times n \times n}^0(x, y, z)] / [N_{\text{PM}}^0(x) + N_{\text{MC}}^0(x)], & x = 2, \dots, n-1, \forall y, z = 1, 2, \dots, n. \end{cases} \quad (17)$$

step 3: 当 $G > 1$ 时,先计算 $\text{MC}_{n \times n \times n}^{G-1}$,然后再按下式迭代更新概率模型 $\text{PM}_{n \times n \times n}^G$:

$$\text{PM}_{n \times n \times n}^G(x, y, z) = \gamma \times \text{PM}_{n \times n \times n}^{G-1}(x, y, z) + (1 - \gamma) \times \text{MC}_{n \times n \times n}^{G-1}(x, y, z) / N_{\text{MC}}^{G-1}(x), \quad x = 1, 2, \dots, n-1, y, z = 1, 2, \dots, n. \quad (18)$$

step 4: 令 $G = G + 1$,若 $G < \max G$,则转 step 3.

上述步骤中,step 3 中的 γ 为概率模型更新的学习速率,其中 step 1 ~ step 3 中概率模型的计算复杂度为 $O(n^3)$.

2.4 新种群生成方法

为了保持初始种群的质量和多样性,采用启发式算法和随机方法共同产生初始种群.具体而言,初始种群中10%的解采用文献[5]中的多目标NEH算法生成,其余90%的解全部随机生成.同时,为了保证算法测试的公平性,所有算法都采用相同的初始化方法.在每次迭代中,MEDA通过采样概率模型产生新种群.令 $\pi^{G,k} = [\pi_1^{G,k}, \pi_2^{G,k}, \dots, \pi_n^{G,k}]$ 为种群 $\text{Pop}(G)$ 中的第 k 个个体.定义 $\text{SelectJob}(\pi^{G,k}, i)$ 为工件的选择函数,用以确定 $\pi^{G,k}$ 中第 i 个位置上的工件或工件块.因为 $\pi^{G,k}$ 中的块结构 $[\pi_{i-1}^{G,k}, \pi_i^{G,k}]$

被选中的概率存储在 $\mathbf{PM}_{n \times n \times n}^{G-1}(i-1)$ 中, 所以 $\text{SelectJob}(\pi^{G,k}, i)$ 针对概率模型的第 $i-1$ 层进行采样, 具体过程如下。

step 1: 产生一个范围内的随机数 p_r , 满足条件 $p_r \in \left[0, \sum_{h=1}^n \text{PM}_{n \times n \times n}^{G-1}(i-1, \pi_{i-1}^{G,k}, h)\right)$ 。

step 2: 利用轮盘赌方法选择候选工件 J_s , 如果 p_r 满足条件 $p_r \in [0, \text{PM}_{n \times n \times n}^{G-1}(i-1, \pi_{i-1}^{G,k}, 1))$, 则 $J_s=1$; 如果

$$p_r \in \left[\sum_{h=1}^t \text{PM}_{n \times n \times n}^{G-1}(i-1, \pi_{i-1}^{G,k}, h), \sum_{h=1}^{t+1} \text{PM}_{n \times n \times n}^{G-1}(i-1, \pi_{i-1}^{G,k}, h) \right)$$

且 $t \in \{1, \dots, n-1\}$, 则 $J_s = t + 1$ 。

step 3: 返回 J_s 。

对于工件序列 $\pi^{G,k}$ 中首位置上的工件选择, 需要设计一种特殊的初始采样策略, 具体描述如下。

step 1: 按下式计算 $\text{SM}_{\text{init}}^{G-1}(y)(y = 1, \dots, n)$:

$$\text{SM}_{\text{init}}^{G-1}(y) = \sum_{z=1}^n \text{PM}_{n \times n \times n}^{G-1}(1, y, z). \quad (19)$$

step 2: 利用轮盘赌方法选择首位置上工件 J'_s , 同理产生随机数 p'_r , 满足 $p'_r \in \left[0, \sum_{h=1}^n \text{SM}_{\text{init}}^{G-1}(h)\right)$ 。若 $p'_r \in [0, \text{SM}_{\text{init}}^{G-1}(1))$, 则 $J'_s=1$; 若 $p'_r \in [\text{SM}_{\text{init}}^{G-1}(t),$

$\text{SM}_{\text{init}}^{G-1}(t+1))$, 且 $t \in \{1, \dots, n-1\}$, 则 $J'_s = t + 1$ 。

step 3: 令 $\pi^{G,k}$ 中 $\pi_1^{G,k}$ 为 J'_s 。

2.5 变邻域局部搜索

根据1.3节对LC_DAPFSP的性质分析可知, 问题可行解空间复杂且多变, 大量优质非劣解分散在解空间中靠近底部的多个局部区域, 因此, 有必要对算法全局搜索发现的非劣解的近邻区域再进行细致的局部搜索。通常调度解的最大完工时间由其关键路径决定^[28,31], 通过调整关键路径上的工件能有效缩短完工时间。本节设计4种基于关键路径的工件交换与工件插入的邻域结构, 对每代非劣解集中的非劣解分别执行基于这4种邻域结构的变邻域局部搜索。具体而言, 对每个非劣解分别执行工厂内的交换操作与插入操作, 然后再分别执行工厂间的交换操作与插入操作。定义关键路径中的工件为关键工件, 关键工件所在的工厂为关键工厂 f_c , 关键工厂内分配的工件数为 n_{f_c} , 关键工厂内关键工件数为 n_c 。基于关键路径的4种邻域结构如图4所示, 具体描述如下。

1) 工厂内交换: 随机选择一个关键工件 $\pi_u^{f_c}$, 其中 $u \in \{1, 2, \dots, n_c\}$, 将关键工件 $\pi_u^{f_c}$ 与该工厂内所有的非关键工件 $\pi_v^{f_c} (v = n_c + 1, \dots, n_{f_c})$ 交换位置。

2) 工厂内插入: 随机选择一个关键工件 $\pi_u^{f_c}$, 其中 $u \in \{1, 2, \dots, n_c\}$, 将 $\pi_u^{f_c}$ 分别插入到该工厂内所有

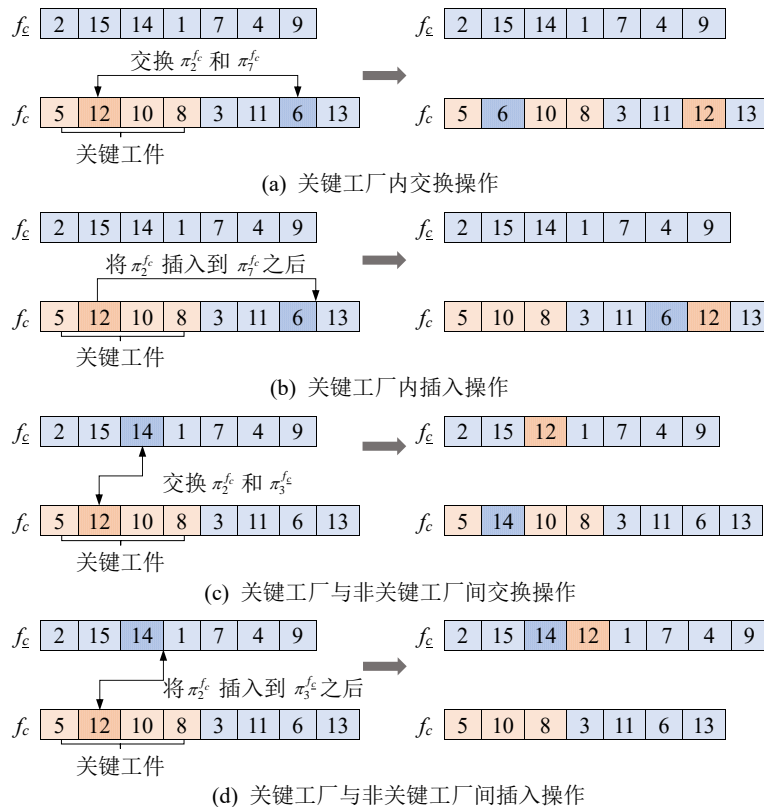


图4 4种邻域操作示意图

的非关键工件 $\pi_v^{f_c}$ ($v = n_c + 1, \dots, n_{f_c}$) 之前或之后.

3) 工厂间交换: 随机选择一个关键工件 $\pi_u^{f_c}$, 其中 $u \in \{1, 2, \dots, n_c\}$, 以及 $F-1$ 个非关键工厂 f_c 内的工件 $\pi_v^{f_c}$ ($v \in \{1, 2, \dots, n_{f_c}\}$), 交换 $\pi_u^{f_c}$ 和 $\pi_v^{f_c}$ 的位置.

4) 工厂间插入: 随机选择一个关键工件 $\pi_u^{f_c}$, 其中 $u \in \{1, 2, \dots, n_c\}$, 以及 $F-1$ 个非关键工厂 f_c 内的工件 $\pi_v^{f_c}$ ($v \in \{1, 2, \dots, n_{f_c}\}$), 将 $\pi_u^{f_c}$ 插到 $\pi_v^{f_c}$ 之前或之后.

变邻域局部搜索具体步骤如下.

step 1: 对于非劣解集中的每个解, 找出一条关键路径, 若关键路径有多条, 则随机选择一条.

step 2: 对非劣解集中的每个解依次执行基于关键路径的 4 种邻域搜索. 每执行完一种邻域操作后, 对操作前后的两个解进行比较. 若得到的新解支配旧解, 则使用新解替换旧解并确定关键路径, 重新执行所对应的邻域搜索; 若互不支配, 则将其加入非劣解集中, 继续执行剩余邻域搜索.

step 3: 对于局部搜索获得的非劣解执行文献[5]中的节能调速操作, 即保持关键路径上工件的加工速度不变, 对非关键路径上工件的加工速度进行调节, 实现在最大完工时间不变的前提下尽可能降低总碳排放, 以进一步提高调度解的质量.

step 4: 更新 Pareto 档案集. 若非劣解集中的解数量超过 ps , 则按照拥挤距离^[34] 对所有非劣解排序, 剔除拥挤距离最小的解, 直到种群中解的个数为 ps .

2.6 MEDA 算法流程

根据上述描述, MEDA 具体流程如下.

step 1: 初始化种群、概率模型及算法参数.

step 2: 评价种群中个体, 更新 Pareto 档案集.

step 3: 判断种群中个体的支配关系, 计算种群中个体所对应的支配等级与拥挤距离. 对种群排序后, 选择前 $ps \times \varphi$ 个优质个体组成优质子种群.

step 4: 分别对优质子种群中的个体执行变邻域局部搜索, 并对局部搜索得到的非劣解进行节能调速操作, 更新 Pareto 档案集.

step 5: 利用 Pareto 档案集更新概率矩阵.

step 6: 对概率矩阵采样, 生成新种群.

step 7: 判断是否满足终止条件. 若不满足, 则转 step 2, 否则终止循环.

需要说明的是, 文献[28]针对单目标优化问题, 所提算法采用二维 EDA 学习优质解信息, 同时考虑高质量解或近似最优解多分布于问题解空间中较为深入的底部区域, 故加入基于 5 种邻域结构的迭代变邻域搜索对当前种群历史最优个体执行深入的局部

搜索. 本文针对多目标优化问题, 所提出的 MEDA 采用三维 EDA 学习优质解特征信息并执行全局搜索, 可同时积累优质解中的相似块及其位置信息, 从而能更准确地引导算法全局搜索的方向; 同时, 进一步考虑多目标间相互制约导致优质非劣解更为分散地分布在问题可行解空间的中下部分区域, 采用基于关键路径的 4 种邻域结构分别对当前非劣解集中的每个解进行变邻域搜索, 从而实现搜索范围较广且有一定深度的局部搜索.

3 仿真实验与分析

3.1 实验设置

MEDA 采用 Embarcadero Delphi XE8 编译, 运行环境为 16 GB 内存、3.20 GHz 主频 Inter Core i7-8700 处理器的 PC. 本文将文献[27]中 DAPFSP 标准测试集进行扩展, 得到适用于 LC_DAPFSP 的测试集, 装配阶段不考虑机器调速, 加工阶段变速机设置 5 个可调档位, 对应速度为 $V = \{1, 1.3, 1.55, 1.75, 2.10\}$, 机器加工与待机能耗分别为 $E_{jk} = 4 \times v_k^2$ 和 $SE_j = 1$. 为了评价算法的性能, 采用如下两个评价指标^[5,23].

1) 距离指标 DI_R , 用于衡量非劣解集 Ω' 中的元素相对于参考集 Ω^* 的距离, 表示为

$$DI_R(\Omega') = \frac{1}{|\Omega^*|} \sum_{\mathbf{y} \in \Omega^*} \min\{d(\mathbf{x}, \mathbf{y}) | \mathbf{x} \in \Omega'\}, \quad (20)$$

其中 $d(\mathbf{x}, \mathbf{y})$ 表示解 $\mathbf{x} \in \Omega'$ 与解 $\mathbf{y} \in \Omega^*$ 在归一化目标空间内的距离^[35], 满足下式:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^G \left[\frac{f_i(\mathbf{x}) - f_i(\mathbf{y})}{f_i^{\max} - f_i^{\min}} \right]^2}. \quad (21)$$

f_i 为第 i 个目标函数, f_i^{\max} 和 f_i^{\min} 分别为 Ω^* 中该目标函数的最大值和最小值. 参考集 Ω^* 由所有测试算法运行获得的非劣解集所组成.

2) 非劣解占比指标 ρ_r , 用于衡量算法获得的非劣解集 Ω' 在整个参考集 Ω^* 中所占的比例.

显然, $DI_R(\Omega')$ 越小越好, 而 ρ_r 越大越好.

LC_DAPFSP 的解空间复杂且多变, 在有限时间内难以获得 Pareto 最优前沿, 因此, 将 MEDA 与重要国际期刊中的两种高效多目标算法进行比较. 一种是非劣排序遗传算法 (NSGA-II), NSGA-II 算法由 Deb 等^[34] 首次提出, 由于该算法具有高效的求解性能, 使得其在多目标优化领域得到了广泛应用, 同时, NSGA-II 算法也是求解各类多目标生产调度问题的有效方法^[13-14,18-22]. 另一种是改进多目标迭代贪婪 (MMOIG) 算法^[5]. 迭代贪婪 (IG) 算法融合了启发式算法的高效性与模拟退火算法的优势, 是一种解决复杂流水车间调度问题公认的有效算法, MMOIG 算

法是IG算法在多目标优化层面的一种扩展算法. 文献[5]还基于问题的结构性质设计了高效的搜索操作, 在求解低碳PFSP取得了令人满意的结果. 为了保证比较的公平性, 所有对比算法的运行时间均相同, 即终止条件相同. 考虑到MMOIG算法并非迭代型算法, 故将MEDA和NSGA-II的运行时间设置与MMOIG相同, 即 $n^2 \times m \times 25$ ms. 为保证算法性能的稳定性与可信度, 所有实验计算中对比算法均独立重复运行20次, 取平均结果, 以消除随机误差.

3.2 仿真结果与统计分析

MEDA有3个关键的参数: 种群规模ps、优势子种群比率 φ 和学习速率 γ . 采用实验设计方法^[33], 进行大量对比实验, 最终确定MEDA算法的最佳参数组合设置为ps = 30, $\varphi = 0.2$, $\gamma = 0.2$. 同理, NSGA-II算法的最佳参数组合设置为: 种群规模ps = 30, 交叉概率 $p_c = 0.8$, 变异概率 $p_m = 0.1$. MMOIG

算法的最佳参数组合设置为: 种群规模ps = 30, 解构工件数量 $d = 3$, 速度变异概率 $\rho = 0.4$. NSGA-II、MMOIG和MEDA分别在小规模问题和大规模问题下关于评价指标 DI_R 、 ρ_r 和SD的计算结果如表1和表2所示, 最优值以粗体表示. 不同规模测试问题所对应的参考集分别由3种算法20次独立重复运行得到的非劣解集共同组成. 对于小规模问题, MEDA的 DI_R 值在绝大部分问题上为零或接近于零, 说明MEDA所获得的非劣解集非常接近参考集. 对于大规模问题, MEDA的 DI_R 值也均小于另外两种算法, 在性能上具有明显优势. MEDA在 ρ_r 评价指标下相比NSGA-II和MMOIG显著占优, 表明算法可以获得大量的非支配解. 另外, MEDA在不同规模问题下得到的 ρ_r 的方差SD都最小, 说明MEDA具有较好的鲁棒性. 总之, MEDA是求解LC_DAPFSP的一种高效且鲁棒的算法.

表1 3种算法在小规模问题下的计算结果

$F \times n$	NSGA-II			MMOIG			MEDA		
	DI_R	ρ_r	SD	DI_R	ρ_r	SD	DI_R	ρ_r	SD
2 × 8	0.03	0.00	0.25	0.02	0.00	0.23	0.00	1.00	0.15
2 × 12	0.04	0.00	0.23	0.02	0.13	0.27	0.01	0.87	0.17
2 × 16	0.06	0.03	0.32	0.04	0.12	0.36	0.01	0.85	0.24
2 × 20	0.04	0.00	0.22	0.02	0.00	0.24	0.00	1.00	0.16
2 × 24	0.06	0.00	0.19	0.04	0.09	0.21	0.01	0.91	0.14
3 × 8	0.05	0.00	0.18	0.03	0.00	0.24	0.00	1.00	0.13
3 × 12	0.05	0.00	0.17	0.02	0.00	0.19	0.00	1.00	0.12
3 × 16	0.07	0.00	0.23	0.03	0.12	0.29	0.01	0.88	0.19
3 × 20	0.06	0.01	0.19	0.03	0.07	0.22	0.01	0.92	0.17
3 × 24	0.07	0.00	0.24	0.04	0.31	0.27	0.02	0.69	0.21
4 × 8	0.03	0.00	0.17	0.02	0.00	0.23	0.00	1.00	0.14
4 × 12	0.05	0.00	0.16	0.03	0.00	0.21	0.00	1.00	0.13
4 × 16	0.09	0.02	0.27	0.05	0.25	0.33	0.01	0.73	0.22
4 × 20	0.08	0.02	0.31	0.04	0.19	0.36	0.01	0.79	0.24
4 × 24	0.07	0.01	0.25	0.05	0.22	0.27	0.02	0.77	0.19
平均值	0.06	0.01	0.23	0.03	0.10	0.26	0.01	0.89	0.17

表2 3种算法在大规模问题下的计算结果

$F \times n$	NSGA-II			MMOIG			MEDA		
	DI_R	ρ_r	SD	DI_R	ρ_r	SD	DI_R	ρ_r	SD
4 × 100	0.06	0.05	0.31	0.05	0.16	0.37	0.03	0.79	0.25
4 × 200	0.09	0.11	0.29	0.07	0.15	0.34	0.04	0.74	0.23
4 × 500	0.15	0.08	0.37	0.11	0.27	0.42	0.08	0.65	0.32
6 × 100	0.07	0.03	0.27	0.04	0.11	0.32	0.02	0.86	0.23
6 × 200	0.11	0.07	0.33	0.08	0.12	0.36	0.05	0.81	0.28
6 × 500	0.14	0.11	0.39	0.10	0.14	0.46	0.07	0.75	0.34
8 × 100	0.09	0.00	0.26	0.07	0.09	0.31	0.04	0.91	0.19
8 × 200	0.12	0.05	0.28	0.08	0.12	0.35	0.06	0.83	0.23
8 × 500	0.16	0.06	0.37	0.11	0.22	0.47	0.08	0.72	0.34
平均值	0.11	0.06	0.32	0.08	0.15	0.38	0.05	0.78	0.27

为了更直观地表现算法的性能差异, 图5和图6给出了3种算法分别在求解小规模问题和大规模

问题时运行10次所得的非劣解分布图. 从中可以看出, MEDA在求解无论小规模还是大规模问题上,

获得的非劣解均支配另外两种对比算法所产生的解。同时, MEDA 找到的 Pareto 前沿的分布更具多样性, 解的质量相对更优, 可为决策者提供多种满意的调度方案, 实现总完工时间与总能耗之间合理折中。




图5 3种算法求解LC_DAPFSP小规模问题 $n = 24$, $m = 5$, $F = 3$, $S = 2$ 所得的非劣解分布图

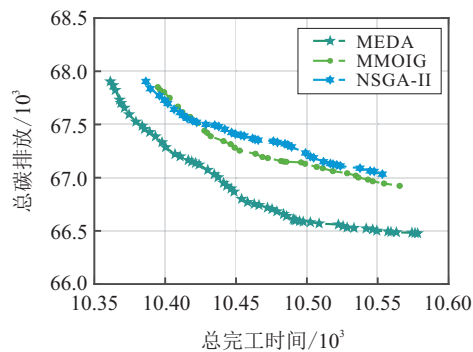


图6 3种算法求解LC_DAPFSP大规模问题 $n = 200$, $m = 20$, $F = 8$, $S = 40$ 所得的非劣解分布图

4 结论

低碳调度问题是一类非常重要的生产调度问题, 普遍存在于实际制造系统中。本文在分布式装配流水车间调度问题的基础上, 进一步考虑实际生产中设备可调速的低碳生产模式, 对优化目标为同时最小化总能耗和总完工时间的低碳分布式装配换流水车间调度问题(LC_DAPFSP)进行研究。该问题由加工、调速和装配3个耦合的子问题组成, 可行解空间复杂且多变, 对此, 本文提出了一种多维EDA(MEDA)算法求解LC_DAPFSP。首先, 设计了基于启发式和随机的种群初始化方法, 以保证初始解的质量; 其次, 分析问题的性质和解的结构特征, 设计了基于矩阵立方体的概率模型, 准确表征优质解中序关系信息和块结构的分布特征, 通过有效采样机制, 引导算法对解空间进行较广范围的全局搜索; 然后, 提出了一种基于问题特性的变邻域搜索方法, 对全局搜索发现的优质区域进行局部精细优化, 均衡算法的全局探索与局部搜索能力; 最后, 通过在不同规模标准测试问题上的仿真实验和算法比较表明了MEDA的有效性和高效性。未来的研究工作将把MEDA扩展用于求解实际

生产中更复杂的低碳调度问题, 并结合问题特征设计出更有效的算法。

参考文献(References)

- [1] 王凌, 王晶晶, 吴楚格. 绿色车间调度优化研究进展[J]. 控制与决策, 2018, 33(3): 385-391. (Wang L, Wang J J, Wu C G. Advances in green shop scheduling and optimization[J]. Control and Decision, 2018, 33(3): 385-391.)
- [2] Gahm C, Denz F, Dirr M, et al. Energy-efficient scheduling in manufacturing companies: A review and research framework[J]. European Journal of Operational Research, 2016, 248(3): 744-757.
- [3] Zhou S C, Jin M Z, Du N. Energy-efficient scheduling of a single batch processing machine with dynamic job arrival times[J]. Energy, 2020, 209: 118420.
- [4] Saberi-Aliabad H, Reisi-Nafchi M, Moslehi G. Energy-efficient scheduling in an unrelated parallel-machine environment under time-of-use electricity tariffs[J]. Journal of Cleaner Production, 2020, 249: 119393.
- [5] Ding J Y, Song S J, Wu C. Carbon-efficient scheduling of flow shops by multi-objective optimization[J]. European Journal of Operational Research, 2016, 248(3): 758-771.
- [6] Lu C, Gao L, Li X Y, et al. Energy-efficient permutation flow shop scheduling problem using a hybrid multi-objective backtracking search algorithm[J]. Journal of Cleaner Production, 2017, 144: 228-238.
- [7] Liu G S, Zhou Y, Yang H D. Minimizing energy consumption and tardiness penalty for fuzzy flow shop scheduling with state-dependent setup time[J]. Journal of Cleaner Production, 2017, 147: 470-484.
- [8] Lei D M, Gao L, Zheng Y L. A novel teaching-learning-based optimization algorithm for energy-efficient scheduling in hybrid flow shop[J]. IEEE Transactions on Engineering Management, 2018, 65(2): 330-340.
- [9] Li J Q, Sang H Y, Han Y Y, et al. Efficient multi-objective optimization algorithm for hybrid flow shop scheduling problems with setup energy consumptions[J]. Journal of Cleaner Production, 2018, 181: 584-598.
- [10] Zhang B, Pan Q K, Gao L, et al. A three-stage multiobjective approach based on decomposition for an energy-efficient hybrid flow shop scheduling problem[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(12): 4984-4999.
- [11] Liu Z F, Yan J, Cheng Q, et al. The mixed production mode considering continuous and intermittent processing for an energy-efficient hybrid flow shop scheduling[J]. Journal of Cleaner Production, 2020, 246: 119071.
- [12] Jiang S L, Zhang L. Energy-oriented scheduling for hybrid flow shop with limited buffers through efficient multi-objective optimization[J]. IEEE Access, 2019, 7: 34477-34487.
- [13] Wu X Q, Che A. Energy-efficient no-wait permutation

- flow shop scheduling by adaptive multi-objective variable neighborhood search[J]. *Omega*, 2020, 94: 102117.
- [14] Yüksel D, Tağetiren M F, Kandiller L, et al. An energy-efficient bi-objective no-wait permutation flowshop scheduling problem to minimize total tardiness and total energy consumption[J]. *Computers & Industrial Engineering*, 2020, 145: 106431.
- [15] Han Y Y, Li J Q, Sang H Y, et al. Discrete evolutionary multi-objective optimization for energy-efficient blocking flow shop scheduling with setup time[J]. *Applied Soft Computing*, 2020, 93: 106343.
- [16] Abedi M, Chiong R, Noman N, et al. A multi-population, multi-objective memetic algorithm for energy-efficient job-shop scheduling with deteriorating machines[J]. *Expert Systems with Applications*, 2020, 157: 113348.
- [17] Zhang L P, Li Z X, Królczyk G, et al. Mathematical modeling and multi-attribute rule mining for energy efficient job-shop scheduling[J]. *Journal of Cleaner Production*, 2019, 241: 118289.
- [18] Chen J F, Wang L, Peng Z P. A collaborative optimization algorithm for energy-efficient multi-objective distributed no-idle flow-shop scheduling[J]. *Swarm and Evolutionary Computation*, 2019, 50: 100557.
- [19] Wang J J, Wang L. A knowledge-based cooperative algorithm for energy-efficient scheduling of distributed flow-shop[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, 50(5): 1805-1819.
- [20] Jiang E D, Wang L, Peng Z P. Solving energy-efficient distributed job shop scheduling via multi-objective evolutionary algorithm with decomposition[J]. *Swarm and Evolutionary Computation*, 2020, 58: 100745.
- [21] Gong G L, Chiong R, Deng Q W, et al. Energy-efficient flexible flow shop scheduling with worker flexibility[J]. *Expert Systems with Applications*, 2020, 141: 112902.
- [22] Luo S, Zhang L X, Fan Y S. Energy-efficient scheduling for multi-objective flexible job shops with variable processing speeds by grey wolf optimization[J]. *Journal of Cleaner Production*, 2019, 234: 1365-1384.
- [23] 雷德明. 基于新型教学优化算法的低碳柔性作业车间调度[J]. *控制与决策*, 2017, 32(9): 1621-1627.
(Lei D M. Novel teaching-learning-based optimization algorithm for low carbon scheduling of flexible job shop[J]. *Control and Decision*, 2017, 32(9): 1621-1627.)
- [24] Li Y B, Huang W X, Wu R, et al. An improved artificial bee colony algorithm for solving multi-objective low-carbon flexible job shop scheduling problem[J]. *Applied Soft Computing*, 2020, 95: 106544.
- [25] Xu Z J, Zheng Z, Gao X Q. Energy-efficient steelmaking-continuous casting scheduling problem with temperature constraints and its solution using a multi-objective hybrid genetic algorithm with local search[J]. *Applied Soft Computing*, 2020, 95: 106554.
- [26] 王凌, 邓瑾, 王圣尧. 分布式车间调度优化算法研究综述[J]. *控制与决策*, 2016, 31(1): 1-11.
(Wang L, Deng J, Wang S Y. Survey on optimization algorithms for distributed shop scheduling[J]. *Control and Decision*, 2016, 31(1): 1-11.)
- [27] Hatami S, Ruiz R, Andrés-Romano C. The distributed assembly permutation flowshop scheduling problem[J]. *International Journal of Production Research*, 2013, 51(17): 5292-5308.
- [28] Wang S Y, Wang L. An estimation of distribution algorithm-based memetic algorithm for the distributed assembly permutation flow-shop scheduling problem[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 46(1): 139-149.
- [29] Lin J, Zhang S. An effective hybrid biogeography-based optimization algorithm for the distributed assembly permutation flow-shop scheduling problem[J]. *Computers & Industrial Engineering*, 2016, 97: 128-136.
- [30] Lin J, Wang Z J, Li X D. A backtracking search hyper-heuristic for the distributed assembly flow-shop scheduling problem[J]. *Swarm and Evolutionary Computation*, 2017, 36: 124-135.
- [31] Zhang Z Q, Qian B, Hu R, et al. A matrix-cube-based estimation of distribution algorithm for the distributed assembly permutation flow-shop scheduling problem[J]. *Swarm and Evolutionary Computation*, 2021, 60: 100785.
- [32] Pan Q K, Ruiz R. An estimation of distribution algorithm for lot-streaming flow shop problems with setup times[J]. *Omega*, 2012, 40(2): 166-180.
- [33] Wang S Y, Wang L, Liu M, et al. An effective estimation of distribution algorithm for solving the distributed permutation flow-shop scheduling problem[J]. *International Journal of Production Economics*, 2013, 145(1): 387-396.
- [34] 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.
- [35] 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.

作者简介

张梓琪(1989—), 男, 博士生, 从事智能优化调度的研究, E-mail: Albert.ziqi@hotmail.com;

钱斌(1976—), 男, 教授, 博士生导师, 从事智能优化调度理论与方法等研究, E-mail: bin.qian@vip.163.com;

胡蓉(1974—), 女, 副教授, 硕士, 从事优化方法及决策支持系统等研究, E-mail: ronghu@vip.163.com;

王凌(1972—), 男, 教授, 博士生导师, 从事智能优化调度理论与方法等研究, E-mail: wangling@tsinghua.edu.cn;

向凤红(1964—), 男, 教授, 博士, 从事智能优化方法等研究, E-mail: xiangfh5447@sina.com.

(责任编辑: 李君玲)