计算机系统应用 ISSN 1003-3254, CODEN CSAOBN
Computer Systems & Applications,2020,29(10):235−241 [doi: 10.15888/j.cnki.csa.007591]

E-mail: csa@iscas.ac.cn
http://www.c-s-a.org.cn
Tel: +86-10-62661041

改进遗传算法在 MSPSP 问题中的验证①

宋　尧[1,2], 仰燕兰[1,2], 叶　桦[1,2]

[1](东南大学 自动化学院, 南京 210096)
[2](复杂工程系统测量与控制教育部重点实验室, 南京 210096)
通讯作者: 仰燕兰, E-mail: yyl@seu.edu.cn

摘　要: 为了求解多技能资源受限项目调度问题 (MSPSP), 本文提出了一种改进遗传算法. 首先根据问题的数学模型, 确立了基于优先权的实数编码方式, 并将目标函数转为适应度函数以供后续适应度的计算; 接着将基于群体共享的小生境技术融入到遗传算法的选择过程中, 并借助确定式采样选择和子种群的调整进一步提高算法的搜索能力; 然后分别在交叉和变异操作中引入基因修复和多重验证机制, 增强算法的寻优能力; 最后给出了算法的总流程. 算法在 iMOPSE 数据集上的求解效果表明本文的改进遗传算法是一种求解 MSPSP 问题的有效方法, 对相关实际问题的研究具有良好借鉴意义.

关键词: 资源受限项目调度; 多技能; 遗传算法; 小生境技术

引用格式: 宋尧,仰燕兰,叶桦.改进遗传算法在 MSPSP 问题中的验证.计算机系统应用,2020,29(10):235–241. http://www.c-s-a.org.cn/1003-3254/7591.html

Verification of Improved Genetic Algorithm in MSPSP Problem

SONG Yao[1,2], YANG Yan-Lan[1,2], YE Hua[1,2]

[1](School of Automation, Southeast University, Nanjing 210096, China)
[2](Key Laboratory of Measurement and Control of Complex Systems of Engineering, Ministry of Education, Nanjing 210096, China)

Abstract: In order to solve the Multi-Skilled resource-constrained Project Scheduling Problem (MSPSP), this study proposes an improved genetic algorithm. First, based on the mathematical model of the problem, a priority-based real number encoding method is established, and the objective function is converted into a fitness function for subsequent fitness calculations. Next, the niche technology based on group sharing is incorporated into the selection process of the genetic algorithm. In addition, with the help of deterministic sampling selection and subpopulation adjustment, the search ability of the algorithm is further improved. Then, gene repair and multiple verification mechanisms are introduced in the crossover and mutation operations to enhance the algorithm's optimization ability. Finally, the overall process of the algorithm is given. The effect of the algorithm on the iMOPSE data set shows that the improved genetic algorithm is an effective method for solving MSPSP problem, and it has a sound reference significance for the study of related practical problems.

Key words: resource-constrained project scheduling; MSPSP; genetic algorithm; niche technology

资源受限项目调度问题 (Resource-Constrained Project Scheduling Problem, RCPSP) 是一种典型的 NP-hard 问题[1], 具有约束条件严苛、组合性强、求解范围广等特点, 其基本目标是在一定资源的约束下得到合

① 基金项目: 中央高校基本科研业务费专项 (2242020K40244)
Foundation item: The Fundamental Research Funds for the Central Universities of China (2242020K40244)
收稿时间: 2020-01-15; 修改时间: 2020-02-13; 采用时间: 2020-03-24; csa 在线出版时间: 2020-09-30

理的调度方案, 使得时间或者项目成本得到最优化. 多技能资源受限项目调度问题 (Multi-Skilled Resource-Constrained Project Scheduling Problem, MS-RCPSP/MSPSP) 是在其基础上增加了技能约束的一种拓展性问题, 因其在软件开发、建筑工程、车间调度等方面的广泛应用而不断受到越来越多的学者的关注, 并衍生出许多求解方案. 比如, 任逸飞等人提出了一种包含双层决策及局部优化策略的混合算法对 MSPSP 进行求解, 并结合基于关键链的局部搜索算法提高了求解质量[2]; Skowronski 等人先后用基于调度优先级规则的元启发式算法[3]、禁忌搜索算法[4] 和进化算法[5] 研究 MSPSP, 并生成了一套专门针对 MSPSP 的基准数据集 iMOPSE[6], 为后世研究该问题提供了重要参考依据.

总的来说, 目前所使用的各种算法都仅能针对部分数据对象而不断靠近最优解, 如何提出合适的算法为 MSPSP 求出更优解是目前研究努力的一个方向. 本文在对比了各种算法之后, 考虑到发展已久的遗传算法 (Genetic Algorithm, GA)[7] 在寻优搜索能力、鲁棒性和兼容性等方面的良好表现, 选择其作为本文的基本算法. 考虑到该算法存在早熟收敛和后期收敛速度慢的问题, 学者们在其基础上进行了相关改进, 并用于求解 MSPSP 问题. 比如, Laszczyk 等人在经典的非支配遗传算法的基础上提出了一种新的选择算子, 提高了搜索效率[8]; Lin 等人提出了一种遗传规划的超启发式算法, 将遗传算法作为一种宏观策略, 统筹调度十种启发式规则进行求解[9]. 本文针对 MSPSP 的特点, 在细化遗传算法的求解过程的基础上, 对其选择、交叉和排序过程分别进行了改进.

1 MSPSP 介绍

1.1 问题描述

MSPSP 的基本概念是: 一个项目中涉及多个任务, 任务之间存在时间约束关系, 项目中的各种资源都具备一种或多种技能, 问题的目标是在满足各种约束的条件下合理调度和分配已有的资源和任务, 使得完成整个项目的总时间或总成本最小化.

一般而言, 问题中的资源都指人力资源, 以图 1 为例, J1~J4 表示任务, H1~H4 表示资源, 以 J1 为例, 它需要具备技能 S3 且技能等级达到 3.2 的人员, 在 H1~H4 中只有 H2 和 H4 是满足的, 因此对于 J1 来说 H2 和 H4 可以被分配给它. 当确定人力资源的可分配权后, 再结合相关时间约束和资源约束, 才能进一步确定最终的分配情况.

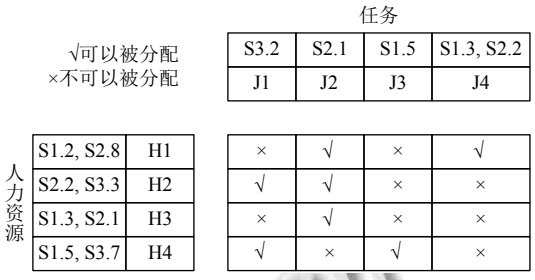

图 1 MSPSP 示意图

1.2 数学模型

为了便于描述 MSPSP 的数学模型, 首先引入如下符号定义:

J: 任务集合, $J=\{1, 2, \cdots, m\}$;

H: 资源集合, $H=\{1, 2, \cdots, n\}$;

S: 技能集合;

d_j: 完成任务 j 的工期;

b_j: 任务 j 的开始时间;

f_j: 任务 j 的结束时间;

k_{jh}: 任务 j 所需要的资源 h 的数量;

P_j: 任务 j 的前置任务集合;

K_h: 资源 h 的数量;

w_h: 资源 h 的单位成本;

S_h: 资源 h 所拥有的技能集合;

J_h: 资源 h 可完成的任务集合;

l_s: 技能 s 的等级;

q_s: 技能 s 的类别;

α: 优化目标的权重系数;

T: 工作持续时间;

Q_{jht}: 0-1 变量, 资源 h 在 t 时刻作用于任务 j 时为 1, 否则为 0.

MSPSP 的数学模型为:

目标函数:

$$\min F_s = \min \alpha F_\tau + (1-\alpha) F_c \quad \alpha \in [0,1] \tag{1}$$

其中,

$$F_\tau = \max_{j \in J} f_j \tag{2}$$

$$F_c = \sum_{j=1}^{m} \sum_{h=1}^{n} d_j w_h \theta(jh) \tag{3}$$

约束条件:

$$f_j = b_j + d_j \quad \forall j \in J \tag{4}$$

$$f_p \le f_j \quad \forall j \in J, \forall p \in P_j \tag{5}$$

$$S_h \ne \emptyset \quad \forall h \in H, S_h \in S \tag{6}$$

$$w_h \ge 0 \quad \forall h \in H \tag{7}$$

$$\sum_{j=1}^{m} Q_{jht} \le 1 \quad \forall h \in H, \forall t \in T, \forall j \in J \tag{8}$$

$$l_s \ge l_{s_i} \wedge q_s = q_{s_i} \quad \forall i \in J_h, \exists s \in S_h \tag{9}$$

$$\theta(jh) = Q_{jht} = \begin{cases} 1 & b_j \le t \le f_j \\ 0 & t \notin [b_j, f_j] \end{cases} \quad \forall j \in J, \forall h \in H, \forall t \in T \tag{10}$$

式 (1) 中的F_τ和F_c分别表示工作的总时间和总成本, 两者是相互制约的关系, 通过权重系数α关联起来, 构成总的优化目标F_s. α的取值将决定优化对象是单目标还是多目标, α=0时是成本优化, α=1时是时间优化, $\alpha \in (0,1)$是综合考虑时间和成本的多目标优化. 本文主要考虑单目标优化. 式 (4) 和式 (5) 表示任务的时间约束. 式 (6)~式 (8) 是对人力资源的约束: 式 (6) 要求每种人力资源至少具备一种技能; 式 (7) 体现了人员成本的合理性; 式 (8) 表示单个资源在同一时间内只能使用一种技能去执行一项任务. 式 (9) 是技能约束, 规定了在为各个任务节点分配资源时, 必须满足该任务对资源的技能种类和技能等级的需求. 式 (10) 的定义是为了方便计算成本消耗.

2 改进遗传算法

2.1 编解码方案

根据问题选择合适的染色体编码方式是遗传算法的第一步, 鉴于 MSPSP 是要寻找满足约束条件的任务和资源的最佳排列, 本文选择基于优先级数组的整数编码, 以更直观地展示和表达调度结果. 在遗传算法中, 每条染色体对应一个任务链, 以优先级数组进行表示时, 数组中的元素 (即染色体的基因) 是任务的权重, 数组的下标表示任务编号, 数组的长度等于任务总数.

编码之后还需要进行解码才能形成完整的调度方案. 本文选择串行调度机制[10] 实行解码操作, 主要分为两个部分:

(1) 在不考虑技能约束的情况下, 根据任务的权重生成任务序列, 当权重相等时, 任务编号小的优先;

(2) 根据技能约束和资源约束对资源进行分配, 在此过程中如果发现资源分配冲突则需要对任务序列进行调整, 如果无法通过调整满足需求则放弃该方案.

2.2 适应度函数

遗传算法一般会选择问题的目标函数作为适应度函数, 但 MSPSP 的目标函数是最小化目标, 不满足适应度函数的最大化需求, 因此需要做一定转化, 最终的适应度函数如式 (11) 所示.

$$f_g(c_k) = \frac{F_{s\_\max} - F_s}{F_{s\_\max} - F_{s\_\min}} \tag{11}$$

其中, $f_g(c_k)$是个体c_k的适应度函数, F_s是当前个体的目标值 (即目标函数值), $F_{s_\max}$和$F_{s_\min}$分别是当前群体中的最大目标值和最小目标值.

2.3 基于群体共享的小生境选择

得到种群的适应度后, 需要根据适应度大小对种群中的个体进行初步筛选, 挑选出适应度较好的一批个体, 为后续的交叉和变异做准备. 传统的直接通过比较个体适应度大小来决定生存权的方式会带来一些问题:

(1) 算法搜索初期, 适应度很好的一批个体不但拥有更长的生存时间, 而且易被视为优良父代将本身的基因传承下去, 进而影响整个种群的进化方向, 从而削弱了算法的全局搜索能力;

(2) 算法搜索后期, 经过多代的进化, 个体间的差异变小, 种群多样性降低, 演变成了近亲繁殖, 在此基础上生成的后代也很难有新的变化, 最终算法可能会陷入局部最优.

为了防止种群的多样性被破坏, 本文在遗传算法的选择阶段融入基于群体共享的小生境技术[11]. 其基本过程是: 首先将原始种群分为若干子种群, 接着从中挑选出一个优质种群作为共享种群, 然后在共享种群和普通种群内部独立进行交叉、变异操作, 生成新一代种群, 并不断重复这种操作, 直到满足终止条件为止. 将小生境技术与遗传算法相融合, 能够增强算法的全局搜索的能力, 加快算法的收敛速度.

2.3.1 定义说明

为了实现上述算法, 首先给出如下定义:

定义 1. 个体间距离

在基于群体共享机制的小生境方法中, 可以利用海明距离来辅助判断个体之间的相似程度, 相似度不高的个体才能进行交配, 以保证种群的多样性. 为了方便计算海明距离, 需要先将个体由实数编码转为二进制编码, 然后再根据式 (12) 求得个体c_i和c_j之间的海明

距离, 其中, $binLen$表示染色体二进制编码的长度, G 表示整个种群.

$$d(c_i,c_j)=\|c_i-c_j\|=\sqrt{\sum_{k=1}^{binLen}(c_{ik}-c_{jk})^2} \quad \forall c_i,c_j\in G, c_i\neq c_j \tag{12}$$

定义 2. 个体共享度

个体共享度是借助个体间海明距离来度量其相似程度的一种表达, 如式 (13) 所示, 个体之间相似度越大, 个体共享度就越大.

$$s(c_i,c_j)=1-\frac{d(c_i,c_j)}{binLen} \tag{13}$$

定义 3. 群体共享度

群体共享度是对个体在群体中的特异性的度量, 是个体与群体中的其他个体间的个体共享度之和, 如式 (14) 所示.

$$s_g=\sum s(c_i,c_j) \quad \forall c_i,c_j\in G, c_i\neq c_j \tag{14}$$

2.3.2 确定式采样选择

在各个子群体的进化过程中, 为了保证优质基因能够遗传下去, 与文献 [11] 不同的是, 本文采用确定式采样选择法[12] 进行个体选择, 避开传统轮盘赌方式带来的统计误差. 具体操作过程是:

Step 1. 计算各个子种群中的个体在下一代中的期望数目:

$$N_{exp}(c_i)=subSize\cdot\frac{f(c_i)}{\sum_{i=1}^{subSize}f(c_i)} \quad i=1,2,\cdots,subSize \tag{15}$$

Step 2. 取$\left[N_{\exp}(c_i)\right]$作为$c_i$在下一代中的生存数目, 其中$\left[N_{\exp}(c_i)\right]$表示不大于$N_{\exp}(c_i)$的最大整数;

Step 3. 根据$N_{\exp}(c_i)$的小数部分对所有个体进行排序, 选择最大的$subSize-\sum_{i=1}^{subSize}\left[N_{\exp}(c_i)\right]$个个体进入到下一代种群中.

这种方式能够确保每个子群体中适应度较大的个体都能存活到下一代.

2.3.3 子种群适应度和规模调整

为了减少算法中相似个体的不断聚合, 需要根据子群体的群体共享度不断调整其适应度和种群规模.

调整的基本规则是:

(1) 根据共享种群的群体共享度占总群体共享度的比值, 略微调高共享种群的适应度;

(2) 当普通种群的群体共享度大于共享种群的群体共享度时, 调低普通种群的适应度, 反之调高;

(3) 在总的种群规模不变的情况下, 根据种群的适应度比例重新分配子种群的规模.

对于共享种群的适应度调整:

$$f_{\text{share}}=f_{\text{share}}\cdot\exp\left(N_e\frac{s_{\text{share}}}{\sum_{j=1}^{N_{\text{sub}}}s_g(j)}\right) \tag{16}$$

对于普通种群的适应度调整:

$$f_{\text{others}}=f_{\text{others}}\exp\left(-\frac{s_g-s_{\text{share}}}{s_{\text{share}}}\right) \tag{17}$$

对于各个子种群规模的调整:

$$subSize(i)=\frac{f_g(i)}{\sum_{j=1}^{N_{\text{sub}}}f_g(j)}\cdot popSize \quad i=1,2,\cdots,N_{\text{sub}} \tag{18}$$

其中, s_{share}表示共享种群的群体共享度, $subSize(i)$表示第 i 个子种群的规模, $f_g(i)$表示第 i 个子种群的适应度值.

2.4 基于修复机制的单点交叉

遗传算法中的交叉操作能够生成继承了父代基因的新个体, 提高算法的全局搜索能力, 其中最常见的是单点交叉法. 传统的单点交叉的过程是: 在父辈个体中随机选择一个交叉点, 将该交叉点之后的基因互换, 从而生成了两个新的子个体. 本文的染色体是任务时序链, 使用基本的单点交叉后容易打破时序约束, 且新生成的子个体中可能出现重复项和缺失项. 为了保证子代个体的有效性, 本文结合随机生成的交叉概率P_c, 在基本的单点操作基础上增加了相关修复策略, 如图 2 所示.

具体的修复过程是: 经过基本的单点交叉后, 首先找到子代个体中重复的编号, 子代 c_1 中是 1 和 3, c_2 中是 4 和 6; 然后将 c_1 交叉点前的重复编号与 c_2 交叉点后的重复编号依次进行交换, 即 c_1 中交叉点前的 1 和 3 分别与 c_2 交叉点后的 4 和 6 交换, 同理, 也将 c_2 交叉点前的重复编号与 c_1 交叉点后的重复编号依次进行交换, 即 c_2 中交叉点前的 4 和 6 分别与 c_1 交叉点后的 3 和 1 交换; 最后交换后的结果即为修复的子代个体, 该子代个体都满足任务的时序约束, 且没有重复项.

但是, 交叉完后的子代个体的适应度并不一定比父代强, 为了在交叉后尽量保留适应度相对较好的个体, 在此引入父子竞争机制来进一步筛选出能够进入

下一代繁殖的个体: 对父代 c_1、c_2 和子代 c_1、c_2 四个个体的适应度进行排序, 选择适应度最好的两个作为最终的新生代个体进入下一次繁殖和进化.

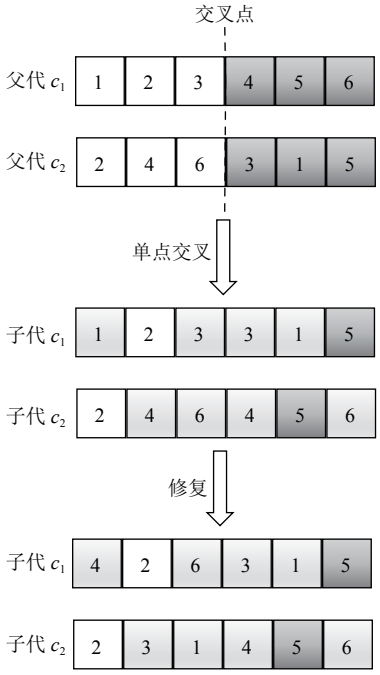

图 2 基于修复机制的单点交叉示意图

2.5 基于多重验证的变异

除了交叉外, 遗传算法中的变异操作也能生成新的个体, 辅助交叉操作维护种群的多样性, 增强算法的局部搜索能力. 与交叉不同的是, 变异是根据变异率P_m在单个染色体上对其部分基因进行突变, 从而产生新的个体.

对于 MSPSP 问题而言, 为了使变异后的个体仍旧满足约束条件, 在执行传统的变异操作后, 还需对新个体进行时序约束验证, 只有验证通过的个体才能保留下来, 否则变异失效. 另外, 如果变异后的个体适应度太低, 则表明该方案不太可取, 且会影响整个子群体的适应度, 因此还需对新个体进行适应度检验.

本文设计的基于多重验证的变异过程如下:

Step 1. 随机为子种群中的所有个体分配概率$p(c_i)$;

Step 2. 选择一个个体, 判断是否满足$p(c_i) \le P_m$, 如果是则执行变异操作, 否则另选个体进行判断;

Step 3. 在所选个体上随机选择两个任务c_i^{k1}和c_i^{k2}进行交换;

Step 4. 判断新个体是否满足时序约束, 且适应度比旧个体高, 如果都满足则用新个体代替旧个体; 否则抛弃新个体, 保留旧个体;

Step 5. 判断当前种群中的所有个体是否都检测完毕, 如果是, 则结束变异操作; 否则转到 Step 2.

2.6 算法总流程

改进遗传算法的详细步骤为:

Step 1. 设置遗传算法的相关参数 (种群规模 $popSize$, 变异概率P_m, 最大迭代次数N_{iter}), 并用贪心算法初始化种群;

Step 2. 划分子种群;

Step 3. 计算个体的适应度, 并在各个子种群内独立执行进化操作: 首先按照确定式采样规则进行个体选择, 然后执行基于修复机制的单点交叉操作, 最后完成基于多重验证的变异操作;

Step 4. 判断子群体进化次数k_{sub}是否达到上限值N_e, 如果是则先将k_{sub}清零, 再转到 Step 5; 否则转到 Step 3;

Step 5. 计算子种群的平均适应度, 选择适应度值最高的作为共享种群;

Step 6. 根据群体共享度和适应度调整所有子种群的适应度和规模;

Step 7. 淘汰连续几代表现最差的子群体, 并产生相同规模的新群体进行替换;

Step 8. 判断当前迭代次数是否达到上限, 或者连续几代的求解结果偏差是否满足收敛条件, 如果满足任意一条则结束算法, 输出结果; 否则转到 Step 3.

算法的流程图如图 3 所示.

3 实验分析

用 Python 实现了针对 MSPSP 的改进遗传算法后, 为了验证算法的性能, 本文在 iMOPSE[6] 数据集上进行了实验, 并与其他算法的求解结果进行了对比. 实验中, 算法的参数设置如表 1 所示.

在取相同参数的情况下, 改进遗传算法和传统遗传算法在 10_20_46_15 算例上的求解效果如图 4 所示, 可以看出, 改进算法的收敛速度更快, 求解结果更优.

使用改进遗传算法对整个 iMOPSE 数据集进行求解, 分别取α=1(时间最优) 和α= 0(成本最优), 每个实例运行 20 次, 将结果与文献 [13] 中的混合蚁群算法的结果进行对比, 如表 2 所示. 可以看出, 不管是以时间最优还是成本最优为目标, 改进遗传算法都能求得更优的解, 且从多次求解的标准差来看, 大部分情况下改进遗传算法都更加稳定.

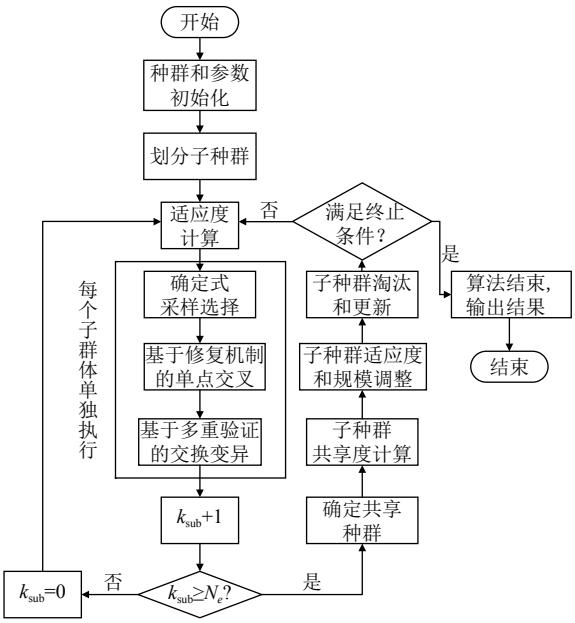

图 3　改进遗传算法流程图

表 1　改进遗传算法参数设置

参数	*popSize*	P_m	N_{iter}
值	100	0.1	500

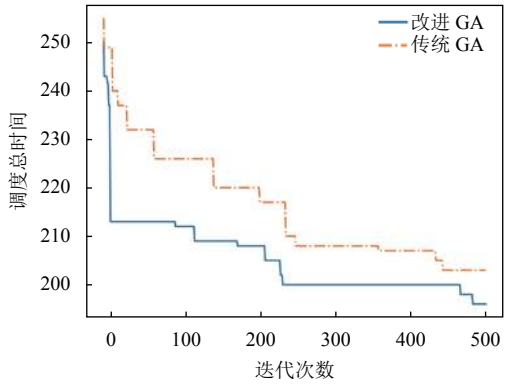

图 4　改进 GA 和传统 GA 在 10_20_46_15 上的求解对比图 (α=1)

表 2　改进遗传算法和混合蚁群算法在 iMOPSE 上的求解结果对比

实例文件	α=1				α=0			
	混合蚁群算法		改进遗传算法		混合蚁群算法		改进遗传算法	
	Best	Std	Best	Std	Best	Std	Best	Std
100_10_26_15	266	2.2	256	4	128 430	2358	80 598.7	1178
100_10_27_9_D2	294	6.7	258	4	43 614	1422	29 024.6	324
100_10_47_9	297	4	268	3	146 056	2183	105 266.4	986
100_10_48_15	278	4.4	262	2	138 194	2463	94 919	840
100_10_64_9	287	5.1	276	3	117 553	1370	80 605.7	683
100_10_65_15	281	3.5	271	3	154 450	2024	115 007.7	740
100_20_22_15	161	3.6	152	2	116 162	4760	70 643.5	773
100_20_23_9_D1	219	3	189	2	53 602	947	36 821	399
100_20_46_15	194	2.6	184	3	142 639	4358	87 821.4	1354
100_20_47_9	180	3.7	165	2	131 525	3471	78 617.5	1256
100_20_65_15	218	2.7	240	0	117 988	5842	71 870	1169
100_20_65_9	180	3.1	166	2	127 848	4458	86 209.2	1223
100_5_20_9_D3	437	5	413	3	41 505	446	31 501.9	85
100_5_22_15	504	0.8	489	1	121 577	125	112 870.6	229
100_5_46_15	604	0	554	3	209 435	698	188 142.6	232
100_5_48_9	521	1.6	498	2	195 675	302	179 370.8	355
100_5_64_15	516	2.9	498	4	147 343	765	111 994.7	306
100_5_64_9	507	3.9	482	3	105 333	949	76 043.9	381
200_10_128_15	522	3.1	526	6	182 391	2446	165 825.3	1122
200_10_135_9_D6	1115	11.4	985	12	104 292	1793	84 911.3	696
200_10_50_15	529	8	544	5	194 317	3028	122 883.8	1041
200_10_50_9	546	4.8	533	6	254 715	4725	162 591.4	2534
200_10_84_9	571	6.9	539	3	229 604	2931	176 236.5	2838
200_10_85_15	526	6.5	508	7	312 382	3617	243 069.3	1804
200_20_145_15	309	4.4	299	3	280 785	4334	212 044.7	1448
200_20_150_9_D5	1177	27.6	984	22	91 940	2300	68 917.2	700
200_20_54_15	336	6.6	335	6	291 075	6352	230 526.4	2104
200_20_55_9	313	3.1	288	4	235 503	5429	165 996.9	1605
200_20_97_15	356	4.8	361	12	296 034	4434	225 208.8	2653

续表 2

实例文件	α=1				α= 0			
	混合蚁群算法		改进遗传算法		混合蚁群算法		改进遗传算法	
	Best	Std	Best	Std	Best	Std	Best	Std
200_20_97_9	326	4.1	299	5	284 302	7969	196 043.8	1973
200_40_130_9_D4	642	19.2	517	14	106 532	3162	74 921.2	974
200_40_133_15	214	3.4	201	4	288 924	7120	195 162.7	1460
200_40_45_15	206	2.6	189	3	257 367	5703	184 510.2	2605
200_40_45_9	209	3.8	195	2	272 589	4066	187 294.4	2902
200_40_90_9	211	1.8	197	2	297 874	7032	201 990.4	2059
200_40_91_15	207	2.9	186	6.22	250 697	5777	181 352.8	6150.07

4 结束语

本文针对 MSPSP 问题的特点, 在传统遗传算法的基础上, 融入了基于群体共享的小生境技术, 提高了种群信息的利用率, 并针对 MSPSP 的时序约束, 分别为交叉和变异操作增加了修复和验证机制, 进一步确保了个体的合法性. 经实验验证分析可知, 改进后的遗传算法相较于传统遗传算法和混合蚁群算法的收敛速度更快, 求解结果更优, 稳定性更强, 且能在 iMOPSE 数据集上取得良好效果, 为研究相关实际问题提供了一定参考价值.

参考文献

1 Blazewicz J, Lenstra JK, Rinnooy Kan AHG. Scheduling subject to resource constraints: Classification and complexity. Discrete Applied Mathematics, 1983, 5(1): 11–24. [doi: 10.1016/0166-218X(83)90012-4]

2 任逸飞, 陆志强, 刘欣仪, 等. 考虑技能水平的多技能资源约束项目调度. 工学版, 2017, 51(5): 1000–1006.

3 Myszkowski PB, Skowroński ME, Podlodowski L. Novel heuristic solutions for multi-skill resource-constrained project scheduling problem. Proceedings of 2013 Federated Conference on Computer Science and Information Systems. Krakow, Poland. 2013. 159–166.

4 Skowroński ME, Myszkowski PB, Adamski M, *et al*. Tabu search approach for multi-skill resource-constrained project scheduling problem. Proceedings of 2013 Federated Conference on Computer Science and Information Systems. Krakow, Poland. 2013. 153–158.

5 Myszkowski PB, Skowroński ME. Specialized genetic operators for multi-skill resource-constrained project scheduling problem. Proceedings of the 19th International Conference on Soft Computing Mendel 2013. At Brno, Czech Republic. 2013. 57–62.

6 Myszkowski PB, Skowroński ME, Sikora K. A new benchmark dataset for multi-skill resource-constrained project scheduling problem. Proceedings of 2015 Federated Conference on Computer Science and Information Systems. Lodz, Poland. 2015. 129–138.

7 张立毅, 高杨, 费腾. 求解旅行商问题的萤火虫遗传算法. 计算机工程与设计, 2019, 40(7): 1939–1944.

8 Laszczyk M, Myszkowski PB. Improved selection in evolutionary multi-objective optimization of multi-skill resource-constrained project scheduling problem. Information Sciences, 2019, 481: 412–431. [doi: 10.1016/j.ins.2019.01.002]

9 Lin J, Zhu L, Gao KZ. A genetic programming hyper-heuristic approach for the multi-skill resource constrained project scheduling problem. Expert Systems With Applications, 2020, 140: 112915. [doi: 10.1016/j.eswa.2019.112915]

10 Kolisch R. Serial and parallel resource-constrained project scheduling methods revisited: Theory and computation. European Journal of Operational Research, 1996, 90(2): 320–333. [doi: 10.1016/0377-2217(95)00357-6]

11 包振明, 王琪, 徐一新, 等. 基于小生境遗传算法的两栖车辆车轮收放装置的优化. 汽车实用技术, 2015, (9): 41–45.

12 梁存利. 遗传算法在分配问题中的应用 [硕士学位论文]. 西安: 西安电子科技大学, 2006.

13 Myszkowski PB, Skowroński ME, Olech ŁP, *et al*. Hybrid ant colony optimization in solving multi-skill resource-constrained project scheduling problem. Soft Computing, 2015, 19(12): 3599–3619. [doi: 10.1007/s00500-014-1455-x]