

混合分布估计算法求解随机 Job shop 提前/拖期调度问题

肖世昌, 孙树栋, 杨宏安

(西北工业大学 机电学院, 西安 710072)

摘要: 针对加工时间具有随机特性的 Job shop 调度问题, 提出基于分布估计算法的混合算法. 为增强分布估计算法的种群多样性, 定义了父代工序继承率并设计一种可保留父代个体优良结构特征的重组方法, 该方法在继承父代个体优良结构特征的同时避免了非法解的产生. 在个体选择评价阶段, 采用最优计算量分配策略为每个个体分配模拟量以提高个体评价的精确性. 仿真算例表明了所提出算法的有效性和鲁棒性.

关键词: Job shop 调度; 分布估计算法; 提前/拖期

中图分类号: TP18

文献标志码: A

Hybrid estimation of distribution algorithm for stochastic Job shop scheduling with earliness/tardiness penalty

XIAO Shi-chang, SUN Shu-dong, YANG Hong-an

(School of Mechanical Engineering, Northwestern Polytechnical University, Xi'an 710072, China. Correspondent: XIAO Shi-chang, E-mail: xiaoshichangx@163.com)

Abstract: A hybrid estimation of distribution algorithm(HEDA) is proposed to solve the stochastic Job shop scheduling problem with earliness/tardiness penalty. To enhance the population diversity of the HEDA, the inherit rate of the operations in parent chromosome is defined and a new recombination method is proposed base on it. This recombination method not only can make the offspring inherit the excellent characteristics of the parent effectively, but also can avoid infeasible solution. To improve the precision of the individual evaluation, the optimal computing budget allocation is adopted in the phase of individual selection. Simulation results show the effectiveness and robustness of HEDA.

Keywords: Job shop scheduling problem; estimation of distribution algorithm; earliness/tardiness

0 引言

随机 Job shop 调度问题(SJSSP)是在 Job shop 调度问题的基础上引入随机参数形成的扩展形式^[1], 如用概率分布表示的随机工时. 将加工时间作为服从概率分布的随机变量对调度问题进行优化, 更符合实际加工环境. 当前, SJSSP 已成为生产调度领域的研究热点之一.

Hornig 等^[2]将序优化与遗传算法相结合, 用于搜索 SJSSP 足够好的解. Lei^[1]为同时优化 Makespan 和拖期率的多目标 SJSSP, 提出了一种多目标遗传算法, 并取得了较好的结果. Hornig 等^[3]将进化策略(ES)嵌入到序优化算法中, 用于求解以最小化提前-拖期惩罚为调度目标的 SJSSP. Gu 等^[4-5]为求解以期

Makespan 为调度目标的 SJSSP, 提出了并行量子遗传算法和竞争-协同量子遗传算法.

分布估计算法(EDA)是一种基于统计学原理的进化计算方法, 通过建立精确概率统计模型和个体重采样在搜索空间中进行寻优^[6]. 在生产调度领域, 王圣尧等^[7]提出了求解混合流水车间调度问题的分布估计算法. Jarboui 等^[8]为置换流水车间调度问题提出了一种分布估计算法, 并采用变邻域搜索提升个体性能. Wang 等^[9]为求解加工时间随机的混合流水车间调度问题, 提出了一种有效 EDA, 同时考虑了调度的效率和鲁棒性. 通过改进概率模型, 补偿种群多样性或混合其他方法等操作, 可以有效弥补 EDA 局部搜索能力较弱和易早熟收敛的缺点^[10]. Pena 等^[11]将

收稿日期: 2014-08-17; 修回日期: 2014-11-19.

基金项目: 国家自然科学基金项目(51075337, 51475383).

作者简介: 肖世昌(1987-), 男, 博士生, 从事随机调度系统建模、生产调度优化的研究; 孙树栋(1963-), 男, 教授, 博士生导师, 从事先进制造系统及生产调度、机器人控制等研究.

遗传算法与 EDA 相结合提出了 GA-EDA 算法. Liu 等^[12]提出了 PSO-EDA 算法, 用于求解置换流水线调度问题并得到较好的结果. Pandolfi 等^[13]在标准 EDA 的基础上引入不同的混合机制以改进 EDA, 并将混合算法应用于流水车间调度问题. 周雅兰等^[14]提出了一种新的适用于求解排列问题的分布估计离散粒子群优化算法.

面向客户的 JIT 生产模式要求制造企业既要避免零件的延迟交付带来拖期惩罚, 又要避免提前完成造成库存成本的增加^[15]. 鉴于此, 本文提出一种混合分布估计算法 (HEDA), 用于求解以最小化期望提前/拖期惩罚之和为调度优化目标的 SJSSP. 采用基于工序的编码方式, 并为重组过程提出一种基于父代工序继承率的个体重组方法. 为保证个体评价的精确性, 在个体的仿真评价阶段采用 OCBA 为待评价个体分配模拟量. 仿真实验表明, HEDA 求解以 JIT 为目标的 SJSSP 问题具有较好的优化性能和算法鲁棒性.

1 SJSSP 数学模型

1.1 问题描述

首先对加工时间随机条件下 SJSSP 模型用到的数学符号进行说明, 如表 1 所示.

表 1 符号说明

符号	含义
$F(S)$	目标函数-提前/拖期惩罚之和
ξ	随机变量的标示
S	可行调度
Ω	满足工艺约束的可行调度集合
m	机器数
n	工件数
J_i	工件 i
M_j	机器 j
O_{ij}	工件 J_i 在机器 M_j 上加工工序
ξT_{ij}	工件 i 在机器 j 上的随机加工时间
X	随机加工时间的概率分布类型
μ_{ij}	随机加工时间 ξT_{ij} 的期望值
σ_{ij}^2	随机加工时间 ξT_{ij} 的方差
ξE_i	工件 i 的提前惩罚
ξT_i	工件 i 的拖期惩罚
d_i	工件 i 的交货期
M_0	一个足够大的正数
α_i	工件 i 的提前惩罚系数
β_i	工件 i 的拖期惩罚系数
α_{ijk}	工件 i 先在机器 j 加工再在机器 k 加工
x_{ihj}	机器 j 上工件 h 在工件 i 完成之后才能加工
ξC_{ij}	工件 i 在机器 j 上的完工时间
ξC_{ik}	工件 i 在机器 k 上的完工时间
ξC_{hj}	工件 h 在机器 j 上的完工时间
ξT_{ik}	工件 i 在机器 k 上的随机加工时间
ξT_{hj}	工件 h 在机器 j 上的随机加工时间

SJSSP 是 Job shop 调度问题的扩展形式, 描述如下: n 个工件在 m 台机器上加工, 每个工件需要加工 m 道工序, 工序 O_{ij} 表示工件 J_i 在机器 M_j 上加工. 每道工序的加工时间具有随机性, 其分布规律根据历史数据获得. 工件 J_i 在机器 M_j 上加工的随机加工时间用 ξT_{ij} 表示, 并假设所有工序的随机加工时间 ξT_{ij} 服从独立同分布 $X(\mu_{ij}, \sigma_{ij}^2)$.

调度模型需要同时满足以下假设: 同一时刻每台机器只能加工一个工件; 同一个工件同一时刻只能在一台机器上加工; 工序一旦开始加工不允许中断; 所有机器在 0 时刻均可用; 工件之间不允许抢占.

1.2 数学模型

提前/拖期 (E/T) 以控制生产成本为目的, 为了适应 JIT 生产模式而提出, 工件提前完工产生提前惩罚成本, 拖期完工产生拖期惩罚成本, 从而促使每个工件在交货期节点准时完工.

根据三元组表示法^[16], SJSSP 可以表示为 $J_m|SPT|\xi(E/T)_{\max}$, J_m 为加工车间, SPT 为随机加工时间, $\xi(E/T)_{\max}$ 为最小化目标. SJSSP 数学描述如下:

$$\min_{S \in \Omega} F(S) = E \left[\sum_{i=1}^n (\alpha_i \xi E_i + \beta_i \xi T_i) \right]. \quad (1)$$

$$\text{s.t. } \xi E_i = \max[(0, d_i - \xi C_i) | i = 1, 2, \dots, n]; \quad (2)$$

$$\xi T_i = \max[(0, \xi C_i - d_i) | i = 1, 2, \dots, n]; \quad (3)$$

$$\xi C_{ik} - \xi T_{ik} + M_0(1 - a_{ijk}) \geq \xi C_{ij}, \quad i = 1, 2, \dots, n \wedge j, k = 1, 2, \dots, m; \quad (4)$$

$$\xi C_{hj} - \xi T_{hj} + M_0(1 - x_{ihj}) \geq \xi C_{ij}, \quad i, h = 1, 2, \dots, n \wedge j = 1, 2, \dots, m; \quad (5)$$

$$\xi C_{ij} \geq 0, \quad i = 1, 2, \dots, n \wedge j = 1, 2, \dots, m. \quad (6)$$

其中: 式(1)为目标函数, 目标是最小化期望 E/T 惩罚的加权和; 式(2)为工件 i 的完工提前量; 式(3)为工件 i 的完工拖期量; 式(4)为工件的工艺顺序约束, 工件 i 在机器 i 上加工完成之后才能在机器 k 上加工, M_0 为一足够大的正数, 如果工件 i 先在机器 j 加工再在机器 k 加工, 则 $a_{ijk} = 1$, 否则为 0; 式(5)为机器加工顺序约束, 机器 j 上工件 h 在工件 i 完成之后才能开始加工, 如果满足约束, 则 $x_{ihj} = 1$, 否则为 0; 式(6)为所有工序的完工时间不能为负值.

1.3 评价方法

对于模型中具有随机特性的目标函数 $F(S)$, 采用 Monte Carlo 随机模拟技术根据每道工序的加工时间的概率分布和取值范围随机采样, 产生一组加工时

间称为一次模拟. HEDA 优化过程的评价函数为

$$\min_{S \in \Omega} F(S) = \frac{1}{Lr} \sum_{lr=1}^{Lr} \left\{ \sum_{i=1}^n [\alpha_i E_i^{lr}(S) + \beta_i T_i^{lr}(S)] \right\}. \quad (7)$$

其中: Lr 为随机模拟次数, 根据大数定律, 当 $Lr \rightarrow \infty$ 时可采用 Lr 次模拟的均值作为期望值的估计值; $E_i^{lr}(S)$ 、 $T_i^{lr}(S)$ 分别为第 lr 次模拟的提前惩罚和拖期惩罚.

2 混合分布估计算法

2.1 编码和解码

根据 SJSSP 问题的特点, 设计基于工序的编码方式, 对所有工件工序的排列采用实数编码. n 个工件在 m 台机器上加工, 每个工件有 m 道工序. 任意工件 i 的所有工序采用以下方式表示: $((i-1)m+1, \dots, (i-1)m+j, \dots, (i-1)m+m)$. 其中: $i=1, 2, \dots, n$, $j=1, 2, \dots, m$. 一个加工序列表示一个调度解.

令 $\pi = (\pi_1, \pi_2, \dots, \pi_k, \dots, \pi_{n \times m})$ 表示染色体的 $n \times m$ 个位置, 在此编码方式下, 若 $(i-1)m+j$ 位于加工序列中的位置 π_k , 则表示工件 i 的第 j 道工序位于排列中的第 π_k 位置.

为了描述编码方式, 以一个 3×3 调度问题为例对编码方式进行说明, $S = [1, 4, 7, 2, 5, 8, 3, 6, 9]$ 为问题的一个可行解, 其中 1、2、3 表示工件 1 的 3 道工序, 4、5、6 表示工件 2 的 3 道工序, 以此类推.

由于染色体编码采用考虑工艺约束的实数编码方式, 种群初始化过程和 HEDA 的个体重采样过程均在工艺约束下进行, 避免了非法解的产生. 鉴于编码方式的优良特性, 本文采用如下解码过程进行染色解码.

Step 1: 染色体中任意位置的所有元素分别整除总工序数 m , 即 $[(i-1)m+j]/m$, 整除后的商加 1 得到工件号, 余数 j 为工序号.

Step 2: 确定染色体中每道工序所用的机器序列和加工时间序列.

Step 3: 根据染色体中工序的排列顺序, 依次取工件的前道工序完工时间与当前机器加工工序完工时间的最大值作为该工件的开始加工时间, 直至所有工序分配至对应机器.

Step 4: 根据分配结果, 通过随机模拟计算目标函数值.

2.2 概率模型建立

EDA 根据概率模型采样产生新种群, 采用基于对优势种群统计学习的建模方法, 可以使每个子代种

群的优势个体的优良信息得到共享. 因此, 概率模型的合理性对 EDA 性能起关键作用.

王圣尧等^[7,17]设计了一种基于排列编码的概率模型, 并将此模型应用于混合流水车间^[7]和置换流水车间调度问题^[17]. 本文根据所研究的问题特点设计一种可以有效统计优势种群解空间分布特性的概率模型, 由于所解决的问题类型和设计的编码方案不同于文献 [7,17], 概率模型也进行重新设计, 两者的区别在于: 1) 概率模型维度不同, 混合流水车间调度问题的概率矩阵为 n 行 m 列, SJSSP 的概率矩阵为 $n \times m$ 行 $n \times m$ 列; 2) 概率模型中元素所表示的实际意义不同, 文献中的概率模型从数值上反映的不同工件的加工优先关系, 本文采用的概率模型表示优势种群中每个工件的每道工序位于染色体中每一位置的统计概率.

采用 $n \times m$ 行 $n \times m$ 列的矩阵 P 表示解空间的概率模型, 根据本文的染色体编码方式设计概率模型, 第 l 代概率模型 $P(l)$ 为

$$P(l) = \begin{bmatrix} p_{11, \pi_1}^l & p_{11, \pi_2}^l & \cdots & p_{11, \pi_{n \times m}}^l \\ p_{12, \pi_1}^l & p_{12, \pi_2}^l & \cdots & p_{12, \pi_{n \times m}}^l \\ \vdots & \vdots & \ddots & \vdots \\ p_{1m, \pi_1}^l & p_{1m, \pi_2}^l & \cdots & p_{1m, \pi_{n \times m}}^l \\ p_{21, \pi_1}^l & p_{21, \pi_2}^l & \cdots & p_{21, \pi_{n \times m}}^l \\ p_{22, \pi_1}^l & p_{22, \pi_2}^l & \cdots & p_{22, \pi_{n \times m}}^l \\ \vdots & \vdots & \ddots & \vdots \\ p_{2m, \pi_1}^l & p_{2m, \pi_2}^l & \cdots & p_{2m, \pi_{n \times m}}^l \\ \vdots & \vdots & \ddots & \vdots \\ p_{n1, \pi_1}^l & p_{n1, \pi_2}^l & \cdots & p_{n1, \pi_{n \times m}}^l \\ p_{n2, \pi_1}^l & p_{n2, \pi_2}^l & \cdots & p_{n2, \pi_{n \times m}}^l \\ \vdots & \vdots & \ddots & \vdots \\ p_{nm, \pi_1}^l & p_{nm, \pi_2}^l & \cdots & p_{nm, \pi_{n \times m}}^l \end{bmatrix}. \quad (8)$$

概率模型 $P(l)$ 中的元素 p_{ij, π_k}^l 表示工件 i 的第 j 道工序位于染色体中 π_k 位置的统计概率. 如 $P(l)$ 中的第 1 列分别表示工件 1~工件 n 中, 从第 1 道工序开始统计直至第 m 道工序位于染色体中位置 π_1 的概率, 后续每一列元素的意义依此类推. 注意到, 在根据概率模型 $P(l)$ 进行染色体采样的过程中, 因为受到工艺约束, 在任意工件的前道工序未出现之前, 后道工序出现概率的统计结果为 0, 所以在个体重采样时, 需先将满足工艺约束的所有工序的统计概率归一化, 利用归一化之后的概率进行个体采样.

为获得优势个体解空间的分布规律, 对优势群体

解空间结构进行统计, 有

$$p_{ij,\pi_k}^l = \sum_{s=1}^{B_{\text{size}}} \frac{I_{ij,\pi_k}^S(l)}{i \times B_{\text{size}}}, \forall i, j, k. \quad (9)$$

其中: B_{size} 为优势个体的数量; $I_{ij,\pi_k}^S(l)$ 为解空间统计函数, 且有

$$I_{ij,\pi_k}^S(l) = \begin{cases} 1, & \text{第 } l \text{ 代个体 } S \text{ 中工件 } i \text{ 的} \\ & \text{第 } j \text{ 道工序出现在位置 } \pi_k; \\ 0, & \text{otherwise.} \end{cases} \quad (10)$$

采用以上方式统计优势种群中每道工序的位置分布信息, 建立产生新染色体的概率模型. 新染色体的采样方法与第 2.4 节种群初始化的采样过程相同.

2.3 模型更新机制

概率模型 P 为 $n \times m$ 行 $n \times m$ 列矩阵, 根据本文的编码方式和概率模型的设计, 概率模型的更新是指根据第 $l+1$ 代优势群体结构空间的统计, 更新下一代染色体采样过程中每一道工序位于染色体中对应位置的概率. 根据机器学习中的 Hebb 规则更新概率矩阵中的元素, 即

$$p_{ij,\pi_k}^{l+1} = (1 - \alpha)p_{ij,\pi_k}^l + \alpha \times \frac{1}{B_{\text{size}}} \sum_{s=1}^{B_{\text{size}}} [I_{ij,\pi_k}^s(l)]. \quad (11)$$

其中: p_{ij,π_k}^{l+1} 为第 $l+1$ 代工件 i 的第 j 道工序位于位置 π_k 的概率, 所有元素组成概率模型 $P(l+1)$; $\alpha(0 < \alpha < 1)$ 为学习速率.

2.4 种群初始化

根据初始概率矩阵 $P(0)$, 采用轮盘赌进行等概率采样完成种群初始化, HEDA 优化过程新种群的采样采用同样的方法. 考虑工序约束的采样过程步骤如下.

Step 1: 初始化工序备选集合 Q ;

Step 2: 从备选工序集合 Q 中确定满足工艺约束的可选工序集合 Q_{option} , $Q_{\text{option}} \in Q$;

Step 3: 根据概率矩阵确定可选工序集合 Q_{option} 中每道工序位于 π_k 位置的概率;

Step 4: 归一化可选工序集合 Q_{option} 中每道工序的选择概率, 根据选择概率采用轮盘赌算法随机选择一个工序放在位置 π_k 处;

Step 5: 从备选集合 Q 中删除已选工序, 当 $k \leq n \times m$ ($k = 1, 2, \dots$) 时, 转入 Step 2, 否则停止, 此时备选工序集合为空;

Step 6: 返回生成的新个体.

2.5 重组方法

为了提高 HEDA 进化过程的种群多样性, 避免算

法早熟收敛, 将 ES 中的重组方法和 $(\mu + \lambda)$ 选择嵌入到 EDA 的搜索过程.

定义 1 父代工序继承率为 $\theta = N(J)/n$. 其中: J 为需从父代继承工序位置的工件集合, $N(J)$ 为需要继承工序位置的工件数量, n 为总工件数. J 中的工件随机产生, 元素数量根据 θ 确定.

为说明本文的重组算法, 对定位工件和定位工序定义如下.

定义 2 集合 J 中所有进行工序位置继承的工件称为定位工件.

定义 3 定位工件的所有工序称为定位工序.

根据设计的染色体重组方式, 本文染色体重组算法流程如下.

Step 1: 根据问题规模设置父代工序继承率 θ 值或 θ 的取值范围, 作为 $N(J)$ 随机取值的约束;

Step 2: 重组概率为 P_c , 执行重组的染色体个数为 μP_c , 从采样产生的 μ 个父代中随机选择父代 P_1 和 P_2 ;

Step 3: 随机选择 $N(J)$ 个定位工件, 查找 J 中定位工序在父代 P_1 和 P_2 中的位置, 分别赋给子代 S_1 和 S_2 染色体中的对应位置;

Step 4: 提取剩余的 $n - N(J)$ 个工件的所有工序, 将 P_1 中剩余工序按顺序插入子代 S_2 的空位, P_2 中剩余工序按顺序插入子代 S_1 的空位.

这种染色体重组方式可以避免对父代染色体结构的破坏, 并可以通过设置父代工序继承率调整重组过程对父代特征的继承性.

2.6 选择

$(\mu + \lambda)$ 选择是 ES 中采用的一种确定性排序选择方法, μ 表示父代个体数目, 即种群大小, λ 是父代个体产生的子代个体的数目. 在产生 λ 个子代后, 从父代和子代个体的并集中选择 μ 个后代. 本文目标函数值用期望值表示, 即 $E[\xi(E/T)_{\text{max}}]$, 选择期望值小的 μ 个个体参与下一代进化.

染色体评价过程中, 每个个体中工序的随机加工时间根据给出的分布规律采用 Monte Carlo 方法随机产生, 为增加被选择个体的评价精确程度, 采用最优计算量分配策略 (OCBA) 优化每个染色体的随机模拟次数^[18]. OCBA 的算法流程如下^[19].

Step 1: 参数初始化, 进化代数初值 $l = 0$, 总模拟预算为 T , 所有个体的初始模拟次数 $n_1^l = n_2^l = \dots = n_i^l = \dots = n_N^l = n_0$, N 为种群中待评价的个体数量, Δ 为下一代总模拟量的增加量.

Step 2: 如果 $\sum_{i=1}^N n_i^l \geq T$, 则停止并输出每个个体的模拟次数, 否则转至 Step 2.

Step 3: 在第 l 代模拟总量上增加模拟次数, 第 $l+1$ 代待评价个体的总模拟量为 $\sum_{i=1}^N n_i^l + \Delta$. 根据第 l 代的模拟量分配结果, 第 $l+1$ 代中间个体的模拟量分配计算如下:

$$n_j^{l+1} = \frac{\sum_{i=1}^N n_i^l + \Delta}{1 + \alpha_b^l + \sum_{i=1, i \neq j \neq b}^N \alpha_i^l}$$

其中 α_i^l 和 α_b^l 分别为第 l 代个体 i 的模拟量分配系数和最优个体 b 的模拟量分配系数. 最优个体 b 和个体 i 分配的模拟量分别为

$$n_b^{l+1} = \alpha_b^l n_j^{l+1}, n_i^{l+1} = \alpha_i^l n_j^{l+1}.$$

其中

$$\alpha_i^l = \frac{\delta_i^l [F_b^l(S_b) - F_j^l(S_j)]}{\delta_j^l [F_b^l(S_b) - F_i^l(S_i)]},$$

$$\alpha_b^l = \delta_b^l \sqrt{\sum_{i=1, i \neq b}^N \left(\frac{\alpha_i^l}{\delta_i^l}\right)^2},$$

第 i 个体的函数值为

$$F_i^l(S_i) = \frac{1}{n_i^l} \sum_{k=1}^{n_i^l} F(S_i)_k,$$

k 为第 k 次仿真, S_i 、 S_j 和 S_b 分别为候选解集中的个体 i 、 j 和 b , 第 l 代中个体 i 的标准差为

$$\delta_i^l = \sqrt{\frac{1}{n_i^l} \sum_{k=1}^{n_i^l} [F_i^l(S_i) - F(S_i)_k]^2}.$$

Step 4: 为第 $l+1$ 代的候选个体 i 增加数量为 $\max(0, n_i^{l+1} - n_i^l)$ ($i = 1, 2, \dots, N$) 的模拟量, 更新代数 $l = l + 1$, 转至 Step 2.

2.7 混合分布估计算法

EDA 的核心是通过概率模型和概率模型更新来描述解空间分布和群体进化趋势^[10]. 然而, EDA 容易对问题解空间的分布过拟合, 使算法构建的概率模型不能准确地表达解空间的信息, 在算法多次迭代后种群多样性减小, 进而造成算法早熟收敛^[11]. 因此, 需要采用一定的策略提高种群多样性.

本文将 EDA 与 ES 的重组方法和 $(\mu + \lambda)$ 选择方法相结合, 鉴于 $(\mu + \lambda)$ 选择具有精英保留的特点, 使子代更好地继承父代个体的优良结构特性. 同时, EDA 具有对优势群体结构的继承和引导性, 所设计的基于父代工序继承率的个体重组方法可在不破坏优势个体结构的基础上提高群体多样性, 从而增强

EDA 的搜索能力. HEDA 算法流程如图 1 所示.

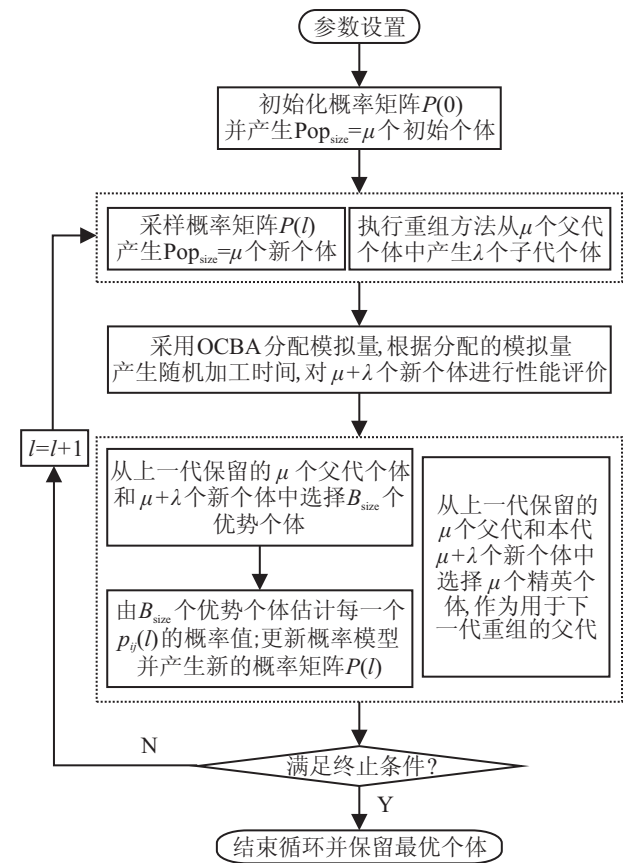


图 1 混合分布估计算法流程

3 仿真分析

3.1 实验说明

HEDA 采用 Matlab 2010b 编程实现. 仿真实验运行环境为: PC Intel G640 处理器, CPU 主频 2.8 GHz, RAM 2.00 G. 选择 ESOO^[3] 和 ESOO-OCBA^[20] 两种算法作为 HEDA 的对比算法, 在仿真条件相同的情况下与两种算法的优化性能进行比较. 根据对比文献中的参数, 3 种算法的参数设置如表 2 所示.

表 2 仿真实验算法参数

参数	ESOO	ESOO-OCBA	HEDA
种群规模	1000	1000	1000
进化代数	100	100	100
重组概率	0.8	0.8	0.8
变异概率	0.1	0.1	
平均采样次数	368	368	368
学习速率			0.2
优势群体			50
定位工件			4
μ 值	1000	1000	1000
λ 值	2000	2000	1000
惩罚系数 α, β	1	1	1

HEDA 中, 种群规模和进化代数与对比算法相同, 此外, 上一代中保留的优秀父代产生的子代个体

数目 ($\lambda = 1000$) 加上每一代个体重采样产生的新个体 ($\mu = 1000$) 之和也是 2000, 即每一代被评价的个体数目与对比算法相同。

3.2 结果分析

仿真算例采用文献 [3] 中 8 个工件 8 台机器的算例。为了分析 HEDA 的优化性能, 对 HEDA 独立运行 20 次, 每个个体平均模拟次数取 368 次, OCBA 初始模拟量 $n_0 = 33$, 模拟量增加量 $\Delta = 6600$ 。

3 种算法均采用 Monte Carlo 随机模拟产生工序随机加工时间。选择的随机加工时间分布规律分别为截断正态分布、均匀分布和指数分布。截断正态分布的均值为 μ_{ij} , 方差为 σ_{ij} , 并且限制产生的随机加工时间大于 0; 均匀分布的随机加工时间的截断区间为 $[\mu_{ij} - 3\sigma_{ij}, \mu_{ij} + 3\sigma_{ij}]$; 指数分布的均值为 μ_{ij} 。HEDA 执行 20 次, 3 种不同分布类型下的优化结果如图 2 所示。




图 2 HEDA20次优化结果

对 20 次仿真实验得到的数据进行分析, 列出最优值、平均值、中位数、标准差和所耗平均时间, 具体如表 3 所示。由表 3 可见, HEDA 可以有效求解以最小化提前/拖期惩罚为优化目标的 SJSSP。当随机加工时间服从截断正态分布和均匀分布时, 优化结果的标准差较小, 表明算法具有较好的优化性能鲁棒性; 当随机加工时间服从指数分布时, 算法的优化性能鲁棒性有所降低。当随机加工时间的分布类型不同时, 算法的平均运行时间略有差别, 对于仿真优化问题属于合理的计算时间。图 2 中, HEDA 运行 20 次的优化结果也可以反映出当随机加工时间服从截断正态分布和均匀分布时, HEDA 具有较好的性能鲁棒性。

为进一步分析 HEDA 的性能, 将 HEDA 优化得到的最优个体的目标函数值与 ESOO^[3]和 ESOO-OCBA^[20]进行对比。HEDA 的个体评价过程仅采用 OCBA^[19]改善个体模拟量分配, 未采用序优化策略。在随机加工时间服从 3 种不同类型的随机分布条件下, 由 3 种算法得到的目标函数最优值和 HEDA 相对于 ESOO^[3]、ESOOCBA^[20]的性能提升比率 Imp1、Imp2 见表 4。由表 4 可见, HEDA 的优化性能相对于 ESOO 和 ESOO-OCBA 均有明显提升, 表明 HEDA 求解不同随机分布情况下的 SJSSP 均具有较好优化性能。当加工时间服从均匀分布时, 性能提升分别为 22.79% 和 12.51%, 优化性能的提升最为显著。

表 3 HEDA 优化结果的数值

分布类型	最优值	平均值	中位数	标准差	平均时间/s
截断正态分布	1938.30	1962.43	1961.40	17.86	2456.4
均匀分布	2145.30	2174.86	2173.25	17.66	2512.6
指数分布	2338.10	2442.23	2429.95	52.20	2383.1

表 4 HEDA 与已有算法的性能比较

分布类型	ESOO ^[3]	ESOOCBA ^[20]	HEDA	Imp1/%	Imp2/%
截断正态分布	2280	2089	1938.30	14.99	7.23
均匀分布	2778	2452	2145.30	22.79	12.51
指数分布	2683	2590	2338.10	12.86	9.73

4 结 论

本文对加工时间随机条件下的 SJSSP 提前/拖期调度进行研究, 给出了问题的数学模型, 提出了一种混合分布估计算法 HEDA。该算法采用基于父代工序继承率的重组方法, 在继承优势群体特征的基础上进一步增强个体的种群多样性, 避免混合分布估计算法陷入局部最优。为提高个体评价的精确性, 采用 OCBA 为每一代待评价个体进行模拟量分配。通过 20 组仿真实验表明了所提出 HEDA 求解 SJSSP 的可行

性和优化性能的鲁棒性, 并通过与已有算法对比表明了所提出算法具有优越的优化性能。

下一步将对随机期望模型的性能评价方法作更深入研究, 局部搜索与所提出 HEDA 的混合算法也值得继续研究。

参考文献(References)

[1] Lei D M. Simplified multi-objective genetic algorithms for stochastic job shop scheduling[J]. Applied Soft Computing, 2011, 11(8): 4991-4996.

- [2] Horng S C, Lin S Y. Multi-stage ordinal optimization based approach for job shop scheduling problems[J]. *Applied Mathematics and Computation*, 2012, 219(3): 1125-1134.
- [3] Horng S C, Lin S S, Yang F Y. Evolutionary algorithm for stochastic job shop scheduling with random processing time[J]. *Expert Systems with Applications*, 2012, 39(3): 3603-3610.
- [4] Gu J W, Gu X S, Gu M Z. A novel parallel quantum genetic algorithm for stochastic job shop scheduling[J]. *J of Mathematical Analysis and Applications*, 2009, 355(1): 63-81.
- [5] Gu J W, Gu M Z, Cao C W, et al. A novel competitive co-evolutionary quantum genetic algorithm for stochastic job shop scheduling problem[J]. *Computers & Operations Research*, 2010, 37(5): 927-937.
- [6] Larranage P, Lozano J A. Estimation of distribution algorithms: A new tool for evolutionary computation[M]. Boston: Kluwer Press, 2002: 57-64.
- [7] 王圣尧, 王凌, 许焯, 等. 求解混合流水车间调度问题的分布估计算法[J]. *自动化学报*, 2012, 38(3): 437-443.
(Wang S Y, Wang L, Xu Y, et al. An estimation of distribution algorithm for solving hybrid flow-shop scheduling problem[J]. *Acta Automatica Sinica*, 2012, 38(3): 437-443.)
- [8] Jarboui B, Eddaly M, Siarry P. An estimation of distribution algorithm for minimizing the total flow time in permutation flow shop scheduling problems[J]. *Computers & Operations Research*, 2009, 36(9): 2638-2646.
- [9] Wang S, Wang L, Xu Y. An estimation of distribution algorithm for solving hybrid flow-shop scheduling problem with stochastic processing time[C]. *The 32nd Control Conf(CCC)*. Xi'an: IEEE, 2013: 2456-2461.
- [10] 王圣尧, 王凌, 方晨, 等. 分布估计算法研究进展[J]. *控制与决策*, 2012, 27(7): 961-966.
(Wang S Y, Wang L, Fang C, et al. Advances in estimation of distribution algorithms[J]. *Control and Decision*, 2012, 27(7): 961-966.)
- [11] Pena J M, Rpbles V, Larranage P, et al. GA-EDA: Hybrid evolutionary algorithm using genetic and estimation of distribution algorithms[C]. *Innovations in Applied Artificial Intelligence*. Berlin: Springer, 2004: 361-371.
- [12] Liu H C, Gao L, Pan Q K. A hybrid particle swarm optimization with estimation of distribution algorithm for solving permutation flow shop scheduling problem[J]. *Expert Systems with Applications*, 2011, 38(4): 4348-4360.
- [13] Pandolfi D, Villagra A, Leguizamon G. Hybrid estimation of distribution algorithms for the flow shop scheduling problem[C]. *IEEE Congress on Evolutionary Computation(CEC)*. Mexico: IEEE, 2013: 1694-1701.
- [14] 周雅兰, 王甲海, 黄聪. 求解排列问题的分布估计离散粒子群优化算法[J]. *电子学报*, 2014, 42(3): 561-571.
(Zhou Y L, Wang J H, Huang C. Estimation of distribution-discrete particle swarm optimization algorithm for permutation-based problems[J]. *Acta Electronica Sinica*, 2014, 42(3): 561-571.)
- [15] 杨宏安, 孙启峰, 李锦远. 求解作业车间提前/拖期调度问题的一种新解码方法[J]. *计算机集成制造系统*, 2011, 17(2): 2652-2659.
(Yang H A, Sun Q F, Li J Y. Novel decoding method for job shop earliness and tardiness scheduling problem[J]. *Computer Integrated Manufacturing Systems*, 2011, 17(2): 2652-2659.)
- [16] Graham R, Lawler E, Lenstra J, et al. Optimization and approximation in deterministic sequencing and scheduling: A survey[J]. *Annals of Discrete Mathematics*, 1979, 5: 287-326.
- [17] 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]. *Int J of Production Economics*, 2013, 145(1): 387-396.
- [18] Chen C H, Lee L H. Stochastic simulation optimization: An optimal computing budget allocation[M]. New Jersey: World Scientific, 2010: 15-28.
- [19] Horng S C, Yang F Y, Lin S S. Embedding evolutionary strategy in ordinal optimization for hard optimization problems[J]. *Applied Mathematical Modelling*, 2012, 36(8): 37-53.
- [20] Yang H A, Lv Y Y, Xia C K, et al. Optimal computing budget allocation for ordinal optimization in solving stochastic job shop scheduling problems[Z]. *Mathematical Problems in Engineering*, 2014.

(责任编辑: 郑晓蕾)