

## 一种新的混合优化算法及其 在车间调度中的应用

闫利军<sup>1</sup> 李宗斌<sup>1</sup> 卫军胡<sup>1</sup> 杜轩<sup>1</sup>

**摘要** 提出了一种解决车间调度问题的新方法, 该方法将序优化思想融入巢分区算法框架, 采用“序比较”的方法进行算法的局部寻优。“序”的指数收敛性加快了巢分区算法的局部收敛速度, 从而提高了算法整体的优化效率。最优计算量分配技术则依据在线数据对计算量进行合理的分配, 进一步提高算法的收敛速度和结果的可靠性。混合算法继承了巢分区算法的全局搜索特性以及序优化的快速收敛性。用该算法解决标准 Jobshop 调度问题, 并与序优化方法和模拟退火算法进行比较, 发现本文算法在收敛速度与优化质量方面均优于这些算法。

**关键词** 随机车间调度, 序优化, 最优计算量分配, 巢分区  
**中图分类号** TP18

## A New Hybrid Optimization Algorithm and Its Application in Job Shop Scheduling

YAN Li-Jun<sup>1</sup> LI Zong-Bin<sup>1</sup> WEI Jun-Hu<sup>1</sup>  
DU Xuan<sup>1</sup>

**Abstract** This paper proposes a new hybrid optimization algorithm for solving stochastic job shop scheduling problems, which integrates the idea of ordinal optimization into the framework of nested partitions (NP) algorithm. Ordinal comparison method is used to perform local search of NP and its exponential convergence rate improves the efficiency of local search and thereby the efficiency of global search greatly. And the optimal computing budget allocation technique further improves the convergence rate and reliability of the optimization result. The new algorithm retains the feature of global search of nested partitions and fast convergence of ordinal optimization. The algorithm is used to solve job shop scheduling benchmark problems. The results of numerical simulations, which are compared with those of other well-known algorithms, show better performance of the proposed algorithm.

**Key words** Stochastic job shop scheduling, ordinal optimization, optimal computing budget allocation, nested partitions

随机车间调度是一类困难的 NP-hard 问题。为了有效解决这类问题, 往往采用各种启发式算法, 例如遗传算法、神经网络、模拟退火等。虽然这类算法在一定条件下可以找到问题的最优解, 但它们往往存在早熟收敛、效率低及算法的参数依赖性强的缺点, 且不能适应未来并行计算技术发展的需要。随着技术的进步和各种复杂新问题的出现, 迫切需要用一种更为全局化的并行优化算法控制全局范围内的寻优运

收稿日期 2006-12-15 收修改稿日期 2007-11-09

Received December 15, 2006; in revised form November 9, 2007

陕西省科学技术研究发展计划项目 (2006K05-G20), 陕西省自然科学基金研究计划项目 (2007F41) 资助

Supported by Science and Technology Development Plan Foundation of Shaanxi Province (2006K05-G20), Natural Science Fundamental Research Plan Foundation of Shaanxi Province (2007F41)

1. 西安交通大学机械制造系统工程国家重点实验室 西安 710049

1. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049

DOI: 10.3724/SP.J.1004.2008.00604

算. 为此, 本文提出了一种解决随机车间调度问题的新方法, 即基于序优化 (Ordinal optimization, OO) 和最优计算量分配 (Optimal computing budget allocation, OCBA) 技术的巢分区算法. 该算法继承了巢分区算法的全局搜索特性以及序优化的快速收敛性, 其中最优计算量分配技术根据仿真过程的在线数据对计算量进行合理的分配, 进一步提高了算法的效率. 实验结果验证了算法的高效性和可靠性.

### 1 基于序优化和最优计算量分配技术的巢分区算法

#### 1.1 巢分区算法

巢分区算法 (Nested partitions, NP) 是一种并行的全局优化算法<sup>[1-3]</sup>, 它的基本框架包括分区 (Partitioning)、随机抽样 (Random sampling)、选择最有希望域 (Selecting promising region) 和回溯 (Backtracking) 四个过程. 其基本思想是, 对可行域进行系统性分区, 将大的可行域分成若干小的子域, 在各子域内进行随机抽样, 用抽样得到的信息评价区域并据此选择最有希望域 (即最有可能拥有最优解的区域), 然后在该区域内重复上述过程, 直到最有希望域小到一定程度为止. 每次迭代过程中, 在对最有希望域进行分区的同时亦将其他区域合并为一个域, 称为裙域 (Surrounding region). 某一时刻, 如果裙域占有了优势, 则算法回溯到上一次迭代之前的某个最有希望域, 重新进行分区与选择. 在每一步迭代中, 算法跟踪最有希望域, 并对最有希望域进行重复分区而实现重点抽样, 算法迭代进行以逐步缩小最有希望域, 然后对此最有希望域集中大量仿真计算以获得最优解的精确评价. 该算法在理论上以概率 1 收敛, 并具有自然的并行性<sup>[4]</sup>. 图 1 为巢分区示意图.

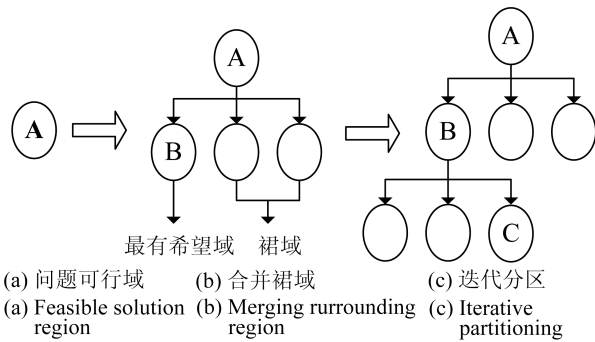


图 1 巢分区示意图

Fig.1 Sketch map of nested partitions

NP 算法的实质是针对可行解的集合, 而不是针对单个可行解, 在这点上它与遗传算法和模拟退火算法是不同的. 算法从整个可行域开始, 将其不断细分, 直到分为单解域 (只包含一个解的区域) 或达到精度要求为止. 这样, 算法经过有限步的迭代产生了一个集合分区序列, 该集合分区序列被证明是一个收敛的马氏链<sup>[5]</sup>.

#### 1.2 序优化及最优计算量分配技术

序优化是解决复杂 DEDS 优化问题的一种简单、高效和实用的方法, 以其所具有的指数收敛率而备受关注. 序优化的基本思想是“序”比“值”容易确定和目标软化<sup>[6]</sup>, 这两个准则在保证节省计算量的同时大大提高了算法的收敛性能.

文献 [7] 已经证明正确选择概率  $P(CS)$  (选择解集中至少包含一个足够好解的概率) 以指数速度收敛于 1.  $P(CS)$  一般可通过 Monte Carlo 仿真实验进行估计, 但计算量仍很大, 由此, Chen 基于贝叶斯后验概率提出了一种近似估计  $P(CS)$  的有效方法<sup>[8]</sup>

$$P(CS) = P\{J_b < J_i, i \neq b | L(\theta_i, \xi_{ij})\} = P\left\{\bigcap_{i=1(i \neq b)}^K \bar{J}_b < \bar{J}_i\right\} \geq 1 - \sum_{i=1(i \neq b)}^K P\{J_b > \bar{J}_i\} = \text{APCS} = 1 - \sum_{i=1(i \neq b)}^K \int_{-\delta_{b,i}/\sigma_{b,i}}^{\infty} \frac{e^{-t^2/2}}{\sqrt{2\pi}} dt$$

其中,  $\bar{J}_i \sim N(\bar{J}_i, \sigma_i^2/T_i)$ ,  $\bar{J}_b \leq \min \bar{J}_i$ ,  $\delta_{b,i} = \bar{J}_b - \bar{J}_i$ ,  $\sigma_{b,i}^2 = \sigma_b^2/T_b + \sigma_i^2/T_i$ ,  $K$  为可行解总数, APCS 为近似正确选择概率 (Approximate probability of correct selection). Chen 已经验证了 APCS 对  $P(CS)$  的近似是足够精确的, 因此, 可以用来代替 Monte Carlo 方法近似估计  $P(CS)$ . 一般地, 序优化通常将给定的计算量均分给各状态, 因而实现一定的正确选择概率需要较大的计算量, 而 OCBA 技术则可通过合理分配计算量 (对关键的解分配较多的计算量, 而不重要的解则分配较少的计算量) 来取得更大的正确选择概率, 或者在实现一定正确选择概率基础上大大减少仿真计算量. 用 OCBA 解决的问题描述如下

$$\max P(CS) \quad \text{s.t.} \quad N_1 + N_2 + \dots + N_k = T$$

$$\text{或} \quad \min \sum_{i=1}^k N_i \quad \text{s.t.} \quad P(CS) \geq P^* \quad (1)$$

其中,  $T$  为总计算量,  $P^*$  为给定的正确选择的概率.

**定理 1.** 给定总仿真次数 (计算量) 为  $T$ , 并将其分配给  $k$  个可行解, 其性能估计分别为  $\bar{J}_1, \bar{J}_2, \dots, \bar{J}_k$ , 相应的有限方差为  $\sigma_1^2, \sigma_2^2, \dots, \sigma_k^2$ , 令  $\delta_{b,i} = \bar{J}_b - \bar{J}_i$ ,  $\bar{J}_b \leq \min_{i \neq b} \bar{J}_i$ , 则  $T \rightarrow \infty$ , 且

$$\begin{cases} \frac{T_i}{T_j} = \left(\frac{\sigma_i}{\delta_{b,i}}\right)^2 \left(\frac{\sigma_j}{\delta_{b,j}}\right)^2, & i \neq j \neq b \\ T_b = \sigma_b \left(\sum_{i=1(i \neq b)}^k \frac{T_i^2}{\sigma_i^2}\right)^{\frac{1}{2}} \end{cases} \quad (2)$$

成立时  $P(CS)$  最大, 同时 APCS 也最大.

#### 1.3 基于 OO 与 OCBA 技术的巢分区算法

对于随机优化问题:  $\min_{\theta_i} J(\theta_i) = E[L(\theta_i, \xi)]$ ,  $\theta_i$  为可行域中的任一解,  $L(\theta_i, \xi)$  为  $\theta_i$  的一次性能评价,  $\xi$  为噪声,  $J(\theta_i)$  为  $L(\theta_i, \xi)$  的数学期望. NP 算法在进行局部搜索, 即利用各分区的抽样信息实现最有希望域间的转移时, 一般是基于对抽样解的“值”比较, 如对于最小化问题, 计算区域的品质指标  $\hat{I}(\sigma) = \min_{\theta \in \sigma} \hat{J}(\theta)$ , 该指标是一个集合性能方程, 代表区域整体性能的好坏. 由于随机因素的存在, 通常需要对  $\theta_i$  进行多次独立仿真以  $J(\theta) = (\sum_{j=1}^{T_i} L(\theta_i, \xi_{i,j}))/T_i$  作

为其性能估计,  $T_i$  为独立仿真的次数,  $T_i$  越大,  $J(\theta_i)$  对  $\theta_i$  的估计越准确, 而估计的收敛速度仅为  $O(1/\sqrt{T_i})$ .

计算区域品质指标时, 一般是分别计算每个区域的指标  $\hat{I}(\sigma) = \min_{\theta \in \sigma} J(\theta)$ , 然后通过比较确定具有最好品质指标的区域, 即  $\hat{j}_k \in \arg \min_{i=\{1,2,\dots,M(\sigma_i)+1\}} \hat{I}(\sigma_i)$ , 这是一个两步优化问题, 其本质是确定由各分区样本所构成的总样本集中的最优解, 因此, 令  $U(k)$  为算法第  $k$  步迭代的总样本集, 则问题将简化为求  $\hat{j}_k \in \arg U(k)_{i=\{1,2,\dots,|U(k)|\}}$  的一步优化问题.

考虑到 NP 的局部搜索过程具有本质上的“序比较”特征, 即只需确定样本集中解的相对性能排序, 而不苛求对其进行精确的性能评价. 换句话说, 即只需要确定解“A”是否比解“B”好, 但并不需要知道“A”比“B”具体好多少. 而且, OO 和 NP 也呈现互补的特性: OO 主要针对方案的比较, 而 NP 方法则专注于方案的选择, 由 OO 获得的结果可以为 NP 方法收敛性问题的研究以及方法的完善提供指导和帮助. 因此, 将 OO 方法融入到 NP 框架是一种自然的做法, 有助于减少各分区内的抽样次数, 降低算法对区域品质指标估值准确性的依赖, 提高最有希望域选取的准确性, 减少算法回溯的次数. 而且, 由于“序”比“值”容易确定, 因此达到局部收敛所需的计算量将大大减少, 从而加速 NP 局部搜索的收敛速度, 提高 NP 算法的全局寻优效率.

本文混合优化算法流程如下:

**步骤 1. 算法初始化.** 确定问题的可行域  $\Theta$  及每一步迭代的分区数  $M(\sigma(k))$ ,  $\sigma(k)$  为第  $k$  步迭代的最有希望域. 若可行域大小  $|\Theta| = S$ , 则  $M(\sigma(k))$ ,  $\sigma(k)$  必须满足  $M(\sigma(1)) \times M(\sigma(2)) \times \dots \times M(\sigma(k)) = S$ , 令  $k = 0$ ;

**步骤 2. 分区.** 在第  $k$  步迭代中, 将最有希望域  $\sigma(k)$  划分成  $M(\sigma(k))$  个子域  $\sigma_1(k), \sigma_2(k), \dots, \sigma_{M(\sigma)}(k)$ , 同时合并其他区域  $\Theta \setminus \sigma(k)$  为裙域  $\sigma_{M+1}(k)$ . 特别地, 如果  $|\sigma(k) = S|$ , 则  $\sigma_{M+1}(k) = 0$ , 如果  $|\sigma(k) = 1|$ , 则  $\sigma_{M+1}(k) = 1$ ;

**步骤 3. 基于 OO 与 OCBA 技术的局部搜索.** 设  $\sigma_1(k), \sigma_2(k), \dots, \sigma_{M(\sigma)}(k), \sigma_{M+1}(k)$  中的采样数分别为  $N_j$ ,  $j = 1, 2, \dots, M+1$ , 样本总数为  $K$  ( $K = \sum_{j=1}^{M+1} N_j$ ), 样本集合为  $U(k) = \theta_1, \theta_2, \dots, \theta_k$ , 重复进行下列步骤:

**步骤 3.1.** 令  $l = 0, T_1^l = T_2^l = \dots = T_K^l = n_0$ , 即对每个可行解作  $n_0$  次独立仿真;

**步骤 3.2.** 若  $\sum_{i=1}^K T_i^l \geq T$ , 则算法结束, 否则继续;

**步骤 3.3.** 令增加仿真总量为  $\Delta$ , 由定理 1 中式 (2) 计算得到  $T_1^{l+1}, T_2^{l+1}, \dots, T_K^{l+1}$ ;

**步骤 3.4.** 对解  $\theta_i$  实施  $\max(0, T_i^{l+1} - T_i^l)$  次附加仿真,  $i = 1, 2, \dots, K$ , 令  $l = l + 1$ , 返回步骤 3.2.

**步骤 4. 进一步分区或者回溯.** 设最优解所在的区域为  $\hat{j}_k \in \min_{i \in \{1,2,\dots,K\}} L(\theta_i)$ , 如果此区域为  $\sigma(k)$  的子域, 则以该子域为下一步迭代的最有希望域, 否则, 如果最优解位于裙域, 则算法回溯到  $\Theta$ .

## 2 算法收敛性分析

**定义 1.** 定义正确选择为这样一种事件: 即局部搜索到的最优解  $\theta_\alpha$  就是样本集  $U(k)$  中的真正最优解, 正确选择概率  $P(CS)$  等于目前排序第一的解  $\theta_\alpha$  是样本集  $U(k)$  中的最优解的概率.

**定义 2.** 通过某种固定的分区策略形成的一系列区域称为该策略下的可行域, 所有可行域的集合记为  $\Sigma$ , 特别地, 单解域集记为  $\Sigma_0$ .

**定义 3.** 令  $\alpha \in \Sigma \setminus \Theta$ , 定义  $\alpha$  的父分区  $s(\alpha) = \eta \in \Sigma$ , 当且仅当:  $\alpha \subset \eta$  且如果  $\alpha \subseteq \xi \subseteq \eta$ , 则  $\xi = \eta$  或  $\xi = \alpha$ .

**定理 2**<sup>[9]</sup>. 如果满足条件

$$P^{k(\eta, \sigma_{\text{opt}})}(\eta, \sigma_{\text{opt}}) \geq P^{k(\sigma_{\text{opt}}, \eta)}(\sigma_{\text{opt}}, \eta) \quad (3)$$

则巢分区算法以概率 1 收敛到全局最优, 其中  $\eta \in \Sigma_0 \setminus \sigma_{\text{opt}}$ ,  $k(\sigma, \eta)$  为从  $\sigma$  到  $\eta$  的最短 Markov 路径长度,  $P^{k(\sigma_{\text{opt}}, \eta)}(\sigma_{\text{opt}}, \eta)$  为从  $\sigma_{\text{opt}}$  到  $\eta$  的转移概率.

条件 (3) 的意义是, 要使巢分区算法收敛, 则必须满足条件: 从单解域集中任意一个不同于  $\sigma_{\text{opt}}$  的有效域  $\eta \in \Sigma_0 \setminus \sigma_{\text{opt}}$  转移到  $\sigma_{\text{opt}}$  的转移概率不能小于从全局最优  $\sigma_{\text{opt}}$  到  $\eta \in \Sigma_0 \setminus \sigma_{\text{opt}}$  的概率. 例如  $\eta_1, \eta_2 \in \Sigma_0$ , 要由  $\eta_1$  转移到  $\eta_2$  必须首先返回  $\Theta$ , 然后再由  $\Theta$  转移到  $\eta_2$ , 所以从  $\eta_1$  到  $\eta_2$  的最短路径为  $d(\eta_2) + 1$ , 这里的  $d(\eta)$  表示由  $\Theta$  到  $\eta$  的最短路径. 又因为

$$\begin{aligned} P^{k(\eta, \sigma_{\text{opt}})}(\eta, \sigma_{\text{opt}}) &= P(\eta, \Theta) \times P^{d(\sigma_{\text{opt}})}(\Theta, \sigma_{\text{opt}}) \\ P^{k(\sigma_{\text{opt}}, \eta)}(\sigma_{\text{opt}}, \eta) &= P(\sigma_{\text{opt}}, \Theta) \times P^{d(\eta)}(\Theta, \eta) \end{aligned} \quad (4)$$

且

$$\begin{aligned} P^{d(\sigma_{\text{opt}})}(\Theta, \sigma_{\text{opt}}) &= P(\Theta, \xi_1) \times P(\xi_1, \xi_2) \times \dots \times \\ &P(\xi_{d(\sigma_{\text{opt}})-1}, \sigma_{\text{opt}}) \\ P^{d(\eta)}(\Theta, \eta) &= P(\Theta, \zeta_1) \times P(\zeta_1, \zeta_2) \times \dots \times P(\zeta_{d(\eta)-1}, \eta) \end{aligned} \quad (5)$$

上式中  $\Theta = \xi_0, \xi_1, \xi_2, \dots, \xi_{d(\sigma_{\text{opt}})-1}$ ,  $\xi_{(\sigma_{\text{opt}})} = \sigma_{\text{opt}}$  是从  $\Theta$  到  $\sigma_{\text{opt}}$  的最短路径,  $\Theta = \zeta_0, \zeta_1, \zeta_2, \dots, \zeta_{d(\eta)-1}, \zeta_{d(\eta)}$  是从  $\Theta$  到  $\eta$  的最短路径, 由区域品质指标  $\hat{I}(\sigma_i)$  与转移概率之间的关系, 有下式成立

$$\begin{aligned} P(\eta, \Theta) &= P(\hat{I}(\eta) \geq \hat{I}(\Theta \setminus \eta)) \\ P(\sigma_{\text{opt}}, \Theta) &= P(\hat{I}(\sigma_{\text{opt}}) \geq \hat{I}(\Theta \setminus \sigma_{\text{opt}})) \end{aligned} \quad (6)$$

且

$$\begin{aligned} P(\Theta, \xi_1) &= P(\hat{I}(\eta) \leq \hat{I}(\xi_1), \forall \eta \neq \xi_1 : s(\eta) = \Theta) \\ P(\xi_i, \xi_{i+1}) &= P(\hat{I}(\eta) \leq \hat{I}(\xi_{i+1}), \forall \eta \neq \xi_{i+1} : \\ &s(\eta) = \xi_i \text{ 或 } \eta = \Theta \setminus \xi_i) \end{aligned} \quad (7)$$

式 (6) 是从  $\eta$  回溯到  $\Theta$  或者从  $\sigma_{\text{opt}}$  回溯到  $\Theta$  的概率, 而式 (7) 表示的是  $\xi_{i+1}$  作为下一步迭代的最有希望域的概率,  $i = 0, 1, \dots, d(\sigma_{\text{opt}}) - 1$ .

**定理 3.** 如果  $P(CS) = 1$ , 则条件 (3) 满足, 本文算法以概率 1 收敛到全局最优.

**证明.** 由于算法每次都回溯到  $\Theta$ , 且  $Pr(\hat{I}(\sigma_{\text{opt}}) \leq \hat{I}(\Theta \setminus \sigma_{\text{opt}})) = P(CS)$ , 由式 (4) 与 (7) 得到

$$\begin{aligned} P^{k(\sigma_{\text{opt}}, \eta)}(\sigma_{\text{opt}}, \eta) &= P(\sigma_{\text{opt}}, \Theta) \times P^{d(\eta)}(\Theta, \eta) = \\ &P(\hat{I}(\sigma_{\text{opt}}) \geq \hat{I}(\Theta \setminus \sigma_{\text{opt}})) \times P^{d(\eta)}(\Theta, \eta) = \\ &(1 - P(\hat{I}(\sigma_{\text{opt}}) \leq \hat{I}(\Theta \setminus \sigma_{\text{opt}}))) \times P^{d(\eta)}(\Theta, \eta) = \\ &(1 - P(CS)) \times P^{d(\eta)}(\Theta, \eta) = 0 \end{aligned}$$

□

序优化思想保证正确选择概率  $P(CS)$  以指数速度收敛于 1, 而 OCBA 通过合理分配仿真量进一步提高了  $P(CS)$  的收敛速度, 从而保证了本文混合算法的收敛性.

### 3 随机 JSP 描述

JSP 问题是一类典型的组合优化问题, 通常可以描述为: 在  $m$  台机床上对  $n$  个工件进行不间断加工, 按照工件的加工工艺要求, 每个工件在  $m$  台机器上的加工顺序和每道工序的加工时间都是已知的, 并且  $n$  个工件的加工顺序不同, 如何安排每台机器上的每个工件的加工顺序和开工时间, 使得某优化目标 (通常为最大完工时间 makespan) 达到最优。

在实际生产中, 由于各种随机因素, 如机器故障和加工时间的波动, 使得 JSP 通常成为复杂的随机组合性优化问题。设  $P_{i,j}$  为工件  $i$  在机器  $j$  加工的期望时间, 则实际加工时间服从  $U((1-\eta)P_{i,j}, (1+\eta)P_{i,j})$  上的均匀分布,  $\eta$  为噪声幅度。

### 4 作业车间调度仿真实验

用本文算法求解文献 [10] 中 11 个标准 JSP Benchmark 问题, 包括 3 个 FT 类 (FT06, FT10, FT20) 和 8 个 LA 类 (LA01, LA06, LA11, LA16, LA21, LA26, LA31, LA36)。噪声幅度  $\eta = 5\%$ 。算法采用 C++ 语言编写, 运行环境为 512M RAM, PIV 2.0G 计算机。

本文算法解决车间调度问题的实施方案如下:

1) 调度方案的编码。本文采用基于工件的编码方式, 即以工件为基本变量, 工件号的排序作为编码。一个工件的编号多次出现在编码中, 代表该工件的多个工序, 例如有 4 个工件参与加工, 编码可为 “134243132”, 表示首先加工工件 1 的第一道工序, 其次加工工件 3 的第一道工序, 第 5 位的 4 表示加工第 4 个工件的第二道工序, 工件号在编码中出现的前后次序表示工件加工的次序, 工件号在编码中出现的次数代表了工件的工序数。

2) 本文算法解决调度问题的具体操作描述。

a) 分区。基于以上编码方式, 对于  $n$  个工件,  $k_i (i = 1, 2, \dots, n)$  道工序,  $m$  台机器的 JSP, 基因编码的全排列构成问题的可行域  $\Theta$ , 算法采用如下方法分区: 第一步通过确定第一个被加工工件为  $n$  个工件之一而将  $\Theta$  分为  $n$  个子域, 第二步通过设定第二个被加工工件为  $n$  个工件之一而将最有希望域分为  $n$  个子域, 同样地, 如果  $n$  个工件均未完成其所有工序, 则下一步分区仍将通过分别设定下一个被加工工件为  $n$  个工件之一而将最有希望域分为  $n$  个子域, 否则, 若有  $l$  个工件完成其所有工序, 则分区数减少  $l (l = 1, 2, \dots, n)$ 。3 × 3 JSP 问题的分区示意图如图 2 所示。




图 2 3 × 3 JSP 分区示意图  
Fig.2 Sketch map of 3 × 3 JSP

b) 采样。尽管随机均匀采样法能满足一般的采样要求, 而且这种方法简单可行, 但它只考虑解空间本身, 而没有利用问题的结构信息以及求解目标来指导搜索, 因此, 本文提出一种基于 2-opt 变换的两步采样法。设采样总数为  $k$ , 第

1 步: 首先用随机均匀采样法采集一个样本; 第 2 步: 对第 1 步样本实施  $k - 1$  次 2-opt 变换, 得到其余  $k - 1$  个样本。如第 1 步所得样本为 “132654879”, 则对其实施一次 2-opt 变换就是在第 1 步基因编码上随机选择两个交换位置进行基因交换, 如选择的交换位置为 2 和 6, 则变换后的编码为 “142653879”。规定算法每一次迭代采样总数为 100, 各分区采样数相等。

c) 计算希望指数。以解的最优性能估计, 即最小 makespan 作为区域的品质指标。限定局部搜索的总计算量为  $T = 100 \times 20 = 2000$ 。OCBA 中取  $n_0 = 10, \Delta = 10$ 。

d) 回溯策略。局部搜索过程中, 如果裙域具有最好的品质指标, 算法将回退到第 b) 步。

对于每个 Benchmark 问题, 本文算法、OO + OCBA 算法及 SA 算法分别独立执行 20 次, OO + OCBA 算法的终止准则为以 99.99% 的概率获得解空间排序在前 0.01% 范围内的一个解, 99.99% 表示正确选择概率  $P(CS)$  的下界, 0.01% 为目标软化的程度。SA 算法中坏解的接受概率为 0.1, 退温速率为 0.9, 抽样步数取  $n \times m$ , 以最优值误差连续 10 次退温保持在 0.1% 范围内为算法终止准则。表 1 (见下页) 列出了仿真统计结果, 其中 BEM, AEM, WEM 分别表示算法执行 20 次得到的最好, 平均和最差的期望 makespan。

表 1 表明本文算法优于 OO + OCBA 算法与 SA 算法, 对 11 个 Benchmark 问题, 本文算法所得到的最优值与平均值均好于 OO + OCBA 算法, 这是因为本文算法中用巢分区算法对解空间进行系统性分区, 并通过对最有希望域进行重点采样, 指导搜索朝着有利于发现最优解的方向进行, 使得算法发掘最优解的能力更强。对于 LA11 与 LA31 问题, SA 算法得到的最优解好于本文算法得到的最优解, 但由于本文算法采用 OCBA 技术对仿真量进行合理分配, 提高了寻优置信度, 而 SA 算法则无法对个别性能好的解增加仿真量来提高估计置信度, 因此本文算法得到的结果更加可靠。图 3 为求解 FT06 问题时在一次 OCBA 评价过程中仿真计算量的分配情况。图中横轴表示解的性能排序, 即序号为 1 的为最好解, 序号为 100 的为最差解, 纵轴则表示分配的仿真量。由图可见性能最好的 1 号解被分配的仿真量最多, 从 1 号解到 100 号解, 随着解性能的逐渐降低, 被分配的仿真量也逐渐减少, 其中 20 号以后的解的仿真计算量保持在一个较低的常数水平。




图 3 OCBA 运行中的仿真量分配  
Fig.3 Computing budgets allocation during running of OCBA

表 1 本文算法与其他算法仿真结果的比较

Table 1 Comparison of simulation results of new hybrid algorithm vs. two other algorithms

Problem	$n, m$	C**	NP + OO + OCBA			OO + OCBA			SA		
			BEM	AEM	WEM	BEM	AEM	WEM	BEM	AEM	WEM
FT06	6,6	55	55	55.0	55	55	55.0	55	55	55.0	55
FT10	10,10	930	930	932.0	936	951	974.2	993	939	990.1	1043
FT20	20,5	1165	1192	1206.5	1214	1197	1209.5	1218	1227	1329.2	1342
LA01	10,5	666	666	669.1	672	695	710.6	712	666	666.0	666
LA06	15,5	926	926	930.9	935	937	941.4	949	926	926.0	926
LA11	20,5	1222	1229	1244.6	1285	1236	1245.0	1255	1222	1237.0	1259
LA16	10,10	945	948	951.3	966	966	972.3	977	979	1019.8	1032
LA21	15,10	1046	1046	1089.4	1125	1064	1129.1	1145	1083	1164.1	1295
LA26	20,10	1218	1218	1255.1	1285	1248	1312.0	1388	1253	1328.1	1395
LA31	30,10	1784	1794	1816.5	1823	1810	1819.5	1824	1784	1791.0	1806
LA36	15,15	1268	1279	1299.7	1306	1287	1326.4	1354	1321	1397.7	1417

## 5 总结

巢分区是一种通用的优化算法框架,它既可以单独使用,也可以和其他算法融合以改善性能,具有很强的柔性.巢分区算法的局部搜索过程具有本质上的序比较特征,且NP方法专注于方案的选择,而序优化方法则主要针对方案的比较,因此,这两种方法具有很强的互补性,这两种算法的融合在一定程度上改善了巢分区算法的性能,主要表现在优化解的质量明显好于其他几种算法的优化质量.序优化方法的突出优点在于能用较少的计算量获得可行域中的最优解,而巢分区方法则通过每一步都对全体可行域进行抽样来保证算法实现全局收敛,因此,本文算法非常适合解决大规模和超大规模的随机组合优化问题且能求得问题的全局最优解.

## References

- Shi L Y, Olafsson S. Nested partitions method for global optimization. *Operations Research*, 2000, **48**(3): 390–407
- Olafsson S, Shi L Y. Ordinal comparison via the nested partitions method. *Discrete Event Dynamic System*, 2002, **12**(2): 211–239
- Shi L Y, Olafsson S, Qun C. An optimization framework for product design. *Management Science*, 2001, **47**(12): 1681–1692
- Olafsson S. Two-stage nested partitions method for stochastic optimization. *Methodology and Computing in Applied Probability*, 2004, **6**(1): 5–27
- Shi L Y, Olafsson S, Sun N. New parallel randomized algorithms for the traveling salesman problem. *Computers and Operations Research*, 1998, **26**(4): 371–394
- Deng M, Ho Y C. Iterative ordinal optimization and its applications. In: Proceedings of the 36th IEEE Conference on Decision and Control. San Diego, USA: IEEE, 1997. 3562–3566
- Lau T W E, Ho Y C. Universal alignment probabilities and subset selection for ordinal optimization. *Journal of Optimization Theory and Applications*, 1997, **93**(3): 455–489
- Chen C H, Lin J W, Yucusan E, Chick S E. Simulation budget allocation for further enhancing the efficiency of ordinal optimization. *Discrete Event Dynamic Systems*, 2000, **10**(3): 251–270
- Shi L Y, Olafsson S. Convergence rate of the nested partitions method for stochastic optimization. *Methodology and Computing in Applied Probability*, 2000, **2**(1): 37–58

10 Wang Ling. *Intelligent Optimization Algorithm and Its Application*. Beijing: Tsinghua University Press, 2001  
(王凌. 智能优化算法及其应用. 北京: 清华大学出版社, 2001)

闫利军 西安交通大学机械制造系统工程国家重点实验室博士研究生. 主要研究方向为制造系统建模, 仿真与优化. 本文通信作者.

E-mail: yanlijun@stu.xjtu.edu.cn

(YAN Li-Jun Ph.D. candidate at State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University. His research interest covers modeling, simulation and optimization of manufacturing systems. Corresponding author of this paper.)

李宗斌 西安交通大学机械制造系统工程国家重点实验室教授. 主要研究方向为产品全生命周期建模与优化.

E-mail: lzb9910@mail.xjtu.edu.cn

(LI Zong-Bin Professor at State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University. His research interest covers modeling and optimization of lifecycle of mechanic products.)

卫军胡 西安交通大学机械制造系统工程国家重点实验室副教授. 主要研究方向为并行与分布式仿真. E-mail: jhwei@sei.xjtu.edu.cn

(WEI Jun-Hu Associate professor at State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University. His research interest covers parallel and distributed simulation.)

杜 轩 西安交通大学机械制造系统工程国家重点实验室博士研究生. 主要研究方向为电子产品制造与优化. E-mail: xdu@stu.xjtu.edu.cn

(DU Xuan Ph.D. candidate at State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University. His research interest covers manufacturing of electrical product and optimization.)