

多目标粒子群算法在交叉培训规划中的应用

李倩, 宫俊[†], 唐加福

(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)

摘要: 为了进一步提高人力资源交叉培训规划的实用性, 增加了对于员工学习行为的考虑, 提出了在保证任务覆盖水平的基础上, 获得员工满意度最大和学习效率最高的多目标优化模型. 本文针对问题的特征, 采用多目标粒子群(MOPSO)算法对多目标优化模型进行了求解, 并设计了多种算法策略, 以适应不同的问题环境. 通过数值实验, 分析了不同问题规模下, 针对不同性能指标算法参数和策略的适用性. 最后, 以柔性单元装配生产线为例, 进行了数值实验, 实验结果表明了模型的有效性和合理性.

关键词: 交叉培训规划; 员工满意度; 学习效率曲线; 多目标粒子群算法; 柔性单元装配线

中图分类号: N945 **文献标识码:** A

Multi-objective particle swarm optimization algorithm for cross-training programming

LI Qian, GONG Jun[†], TANG Jia-fu

(State Key Laboratory of Synthetical Automation for Process Industries, School of Information Science and Engineering, Northeastern University, Shenyang Liaoning 110819, China)

Abstract: In order to improve the practicability of a cross-training programming, the factor of human learning behavior is considered. A multi-objective optimization model is presented on the basis of task redundancy policy, in which the objective functions describe the labor satisfaction and the learning efficiency. A cross-training programming based on multi-objective particle swarm optimization algorithm (MOPSO) is proposed. The MOPSO solves for the solutions of the proposed multi-objective optimization model and designs algorithm policies for different problem environments. Several flexible cell assemblies in different scales are presented for modeling the environment in a series of numerical experiments. Results in each environment are analyzed in the aspects of diversity, distribution and convergence index. The analyzed results show that the method presented in this paper can solve cross-training programming problems effectively.

Key words: cross-training programming; labor satisfaction; learning curve; multi-objective PSO; flexible assembly cells

1 引言(Introduction)

人力资源的工作效率和成本是全球制造业布局的重要影响因素. 人力资源培训是改善人力资源能力和分布状况的重要手段之一. 交叉培训规划是人力资源管理决策中的一个新的研究主题^[1], 其核心是制定交叉培训计划的策略, 这将决定将来人力资源的技能分布, 进而影响生产运营的生产效率和人力成本^[2]. 因此, 针对交叉培训规划策略的理论和研究方法研究有着重要的学术研究与应用价值. 交叉培训是一种对每个人进行多种技能的培训模式, 目的是得柔性的人力资源, 抵抗外界环境波动造成的不良影响. 目前, 交叉培训规划策略的研究受到了许多学者的关注, 并先后提出了多能工、任务覆盖和链式结构等有效的规划策略. 其中, 多能工策略^[3]是指在给一个生产线或团队进行培训规划时, 设置每个员

工掌握的技能种类的上下限. 策略制定的机理是如果员工掌握的技能较少, 当员工突然缺勤时, 由于缺少足够的后备人力资源进行补充, 会导致生产效率的降低; 如果员工掌握技能较多, 在生产运营中会出现频繁的岗位变动, 增加移动时间的消耗, 从而降低生产效率, 并影响质量的稳定性. 因此, 将多能工水平控制在合理的范围内将对生产效率有着重要的影响. 任务覆盖水平策略^[4]是从技能(设备)的角度考虑, 每个技能安排多个员工掌握, 本质上和多能工水平是一样的. 研究表明, 通过单独或联合使用多能工水平和任务覆盖水平策略指导交叉培训规划, 可以获得较好的人力资源技能分布. 链式结构策略^[5]是指在一个生产线或团队中, 每个技能被两个员工掌握, 形成一个闭环链, 通过具有一定拓扑结构的多技能分布, 保证高效地利用人力资源. 以上策略由

收稿日期: 2011-11-02; 收修改稿日期: 2012-07-30.

[†]通信作者. Tel.: +86 13019378194.

基金项目: 国家自然科学基金资助项目(70971019); 国家创新研究群体科学基金资助项目(71021061); 中央高校基本科研业务费专项资金资助项目(100404026).

于简单实用,目前在实际操作中被广泛的采用.但是,这些策略由于忽略了学员学习行为的考虑,例如员工对培训对象的喜好程度、员工的学习能力等行为因素,使得策略在实际执行中功效不能得到完全地发挥.针对这些影响因素,李倩等^[6]提出了考虑培训员工平均满意度最大化和任务平均支付工资最小化为目标的多目标优化方法,并采用了非支配排序遗传算法(non-dominated sorting genetic algorithm, NSGA-II)求解.此外,在实际工作中,存在着不同类型的员工,例如学习专注型或者学习广泛型,学习专注型的学员偏爱较少的学习内容;学习广泛型喜好涉猎多种类型技能的学习.根据不同学员类型,配置学习的技能种类的多少,可以进一步提高学员对培训计划的满意程度,避免出现抵触情绪降低学习的质量^[7].此外,一般来说,学员的学习能力会随着学习技能的个数增加,学习效率会出现不同程度的下降.因此,在培训规划中增加以上两个方面因素的考虑,将会进一步增强培训规划的实用性.本文在保证任务覆盖策略的基础上,增加了员工满意度最大和学习效率最高的培训规划策略,建立了多目标优化模型,来指派员工培训技能匹配.在此基础上,采用多目标粒子群(particle swarm optimization, PSO)算法进行求解.通过数值实验,确定了不同问题规模下的最佳算法参数和策略.最后,通过实验表明了模型的有效性和合理性.

2 交叉培训规划的多目标优化模型(Multi-objective optimization model of cross-training)

2.1 问题描述(Problem description)

假设一条柔性单元装配线,生产线可以装配多种类型的产品.根据工艺设计,生产线分解为 J 个装配任务.人力资源管理人员需要对 I 个员工进行培训规划,就是指派哪个员工接受哪个任务(技能)的培训.首先,通过任务覆盖水平策略,确定人力资源技能的需求,即任务 j 需要被 R_j 个员工学习掌握.然后,以平均员工满意度最大和平均员工学习效率最高为目标,优化员工和培训技能的配置.

1) 员工满意度.员工满意度就是员工对分配给他们的培训技能种类个数的满意程度.一般来说,每个员工对培训的任务个数的偏好程度是不一样的,当接受交叉培训的任务数,在其期望个数的区间内时,员工将非常满意,此时他的满意度为1;当交叉培训的任务数太少或太多,以至于员工无法接受时,此时他的满意度为0;当交叉培训的任务数介于员工满意和不满意之间时,他的满意度为一个线性函数.整个满意度函数是一个分段函数,见图1.图1中:满意度曲线1对应的员工类型,表现为对任务个数比较敏感,且性格较为专一;满意度曲线2对应的员工类型,

表现为对任务个数敏感性较弱,且性格爱好广泛.




图1 不同类型的员工满意度曲线

Fig. 1 Labor satisfaction curves with different labors

2) 员工学习效率.员工的学习效率就是指学习的效果.一般来说,员工整个学习的效果随着学习技能种类增多而呈现出一定程度的下降.学习效率函数如下:

$$\beta_i \times \left(\sum_{j=1}^J x_{ij} \right)^{-\delta_i}, \quad (1)$$

其中: β_i 是学习能力系数,取值范围是0~1之间,数值越大表示学员 i 的学习能力越强; δ_i 是员工 i 的学习效率随着任务个数变化的影响因子,取值范围是0~1之间,取值越大表示任务个数对学习效率影响越大.

现实生活中,存在4种类型的学员.如图2所示,类型1体现为学习能力强,爱好广泛的员工;类型2体现为学习能力强,爱好专一的员工;类型3体现为学习能力弱,爱好广泛的员工;类型4体现为学习能力弱,爱好专一的员工.




图2 不同类型的员工学习效率曲线

Fig. 2 Learning curves of different labors

2.2 多目标规划模型(Multi-objective model)

以下是模型所用到的符号: I 为候选员工总数, $i = 1, \dots, I$; J 为任务总数, $j = 1, \dots, J$; f'_i 表示员工 i 对培训任务个数不满意的下临界点; f_i 表示员工 i 对培训任务个数满意的下临界点; b_i 表示员工 i 对培训任务个数满意的上临界点; b'_i 表示员工 i 对培训任务个数不满意的的上临界点; S_i 为员工 i 对交叉培训计划的满意度; R_j 为任务 j 的覆盖水平; u_i 为员工 i 的学习效率; β_i 为员工 i 的学习效率系数; δ_i 为员工 i 的学习效率因子; c_{ij} 为员工 i 在任务 j 上进行交叉培训

的成本; C 为交叉培训成本预算额; 决策变量

$$x_{ij} = \begin{cases} 1, & \text{员工 } i \text{ 被指派接受任务 } j \text{ 培训,} \\ 0, & \text{其他,} \end{cases}$$

$$y_i = \begin{cases} 1, & \text{员工 } i \text{ 被指派接受培训,} \\ 0, & \text{其他.} \end{cases}$$

优化模型:

$$\max \sum_{i=1}^I S_i / \sum_{i=1}^I y_i, \quad (2)$$

$$\max \sum_{i=1}^I u_i / \sum_{i=1}^I y_i, \quad (3)$$

$$S_i = \begin{cases} 0, & 0 \leq \sum_{j=1}^J x_{ij} \leq f'_i, \\ \frac{\sum_{j=1}^J x_{ij} - f'_i}{f_i - f'_i} f'_i \leq \sum_{j=1}^J x_{ij} \leq f_i, \\ 1, & f_i \leq \sum_{j=1}^J x_{ij} \leq b_i, \\ \frac{b'_i - \sum_{j=1}^J x_{ij}}{b'_i - b_i} b_i \leq \sum_{j=1}^J x_{ij} \leq b'_i, \\ 0, & b'_i \leq \sum_{j=1}^J x_{ij} \leq J, \\ \forall i = 1, 2, \dots, I, \end{cases} \quad (4)$$

$$y_i \leq \sum_{j=1}^J x_{ij} \leq J \times y_i, \quad \forall i = 1, 2, \dots, I, \quad (5)$$

$$u_i = \begin{cases} \beta_i \times (\sum_{j=1}^J x_{ij})^{-\delta_i}, & \sum_{j=1}^J x_{ij} \neq 0, \\ 0, & \sum_{j=1}^J x_{ij} = 0, \end{cases} \quad (6)$$

$$\sum_{i=1}^I x_{ij} = R_j, \quad \forall j = 1, 2, \dots, J, \quad (7)$$

$$\sum_{i=1}^I \sum_{j=1}^J c_{ij} \times x_{ij} \leq C, \quad (8)$$

其中: 式(2)表示员工平均满意度水平最大化; 式(3)表示员工平均学习效率最大化; 式(4)表示员工 i 对交叉培训计划的满意度; 式(5)是决策变量 $x_{ij} = 1$ 和 $y_i = 1$ 的逻辑关系约束; 约束(6)表示交叉培训后员工 i 的学习效率; 约束(7)保证交叉培训后各个任务的覆盖水平; 约束(8)表达了所有员工的计划培训费用不大于培训总费用。

3 多目标粒子群算法(Multi-objective particle swarm optimization)

粒子群算法是由Kennedy和Eberhart在1995年提出的, 通过模拟鸟集群飞行觅食的协作行为使群体达到最优目的, 是一种基于群体智能(swarm intelligence)的优化方法。传统上, 粒子群算法的应用主要

还是针对单目标问题^[8-9]。近些年, 在多目标规划求解领域也开始受到一些关注^[10-13]。

3.1 基本概念(Basic concept)

定义 1 优势程度 s_l : 体现粒子 l 对种群 S 的支配程度^[10]。

定义 2 适应值 f_k : 种群 S 中粒子 l 的适应值 f_k 与集合 S_{pareto} 中支配的所有粒子的优势程度之和成反比, 反映其不被支配的程度^[10]。

定义 3 外部存储器 S_{pareto} : 用来存储历史最优非支配解的集合, 长度为 N_P 。

定义 4 个体动态存储器: 用来存储最新找到的非支配解, 长度为 M 。

定义 5 早晚程度 age : 粒子在迭代过程中出现的早晚程度。如果随着迭代次数的增加粒子 k 仍为非支配解, 在第 t 次迭代时 age 的计算公式为 $\text{age}_k^t = 1.02\text{age}_k^{t-1}$ 。

3.2 算法步骤(Steps of the algorithm)

此算法可以通过以下步骤实现:

步骤 1 算法初始化, 包括算法参数初始、种群粒子生成和适应值计算, p_{best} 和 g_{best} 选择, 个体和外部存储器的初始化。

步骤 2 粒子更新: 对粒子的速度和位置进行更新, 将更新后的不可行解调成可行解。

步骤 3 更新各个粒子的个体动态存储器和外部存储器。

步骤 4 计算粒子适应值 f_k 。

步骤 5 更新个体历史最优位置: 采用轮盘赌方法, 选择每个粒子的 p_{best} 。

步骤 6 更新个体动态存储器中粒子的 age 变量值: 被选作 p_{best} 粒子的 age 变量值设定为 1, 其他粒子的 age 值, 按照定义 5 的公式计算。

步骤 7 更新群体历史最优位置: 根据集合外部存储器中各个粒子的适应值和 age 变量值的加权和, 采用轮盘赌方法, 选择群体的 g_{best} 。

步骤 8 更新外部存储器中粒子的 age 变量值: 被选作粒子的 age 变量值设定为 1, 其他粒子的 age 变量值, 按照定义 5 的公式计算。

步骤 9 如果达到最大迭代次数 Iter_max , 则进入步骤 10。

步骤 10 输出实验结果。

3.3 决策变量编码(Decision variable coding)

问题的决策变量采用了二进制编码, 即粒子的位置矩阵中的维度为 $I \times J$ 。粒子速度矩阵的维度也为 $I \times J$ 中, 并且每一个元素 v_{ij} 取值为 $|v_{ij}| < V_{\text{max}}$ 。

3.4 外部存储器更新策略(External memory update strategy)

外部存储器用来记录截止到当前迭代次数的非支配解, 并且非支配解个数不多于 N_p 个, 对于多目标全局最优非劣解的获得具有重要作用, 这里采用了两个主要策略: 存档策略和划网格策略. 外部存储器更新策略的处理流程, 如图3所示.




图3 外部存储器更新策略流程图
Fig. 3 Flow chart of updating an external archive

3.5 粒子的位置更新策略(Particle location update strategy)

采用Kennedy^[11]提出的位置更新公式如下:

$$x_{kij}^{t+1} = \begin{cases} 1, & \text{random} < S(v_{kij}^{t+1}), \\ 0, & \text{其他}, \end{cases} \quad (9)$$

其中: $S(v_{kij}^{t+1}) = 1/(1 + \exp(-v_{kij}^{t+1}))$ 为S型函数, random是在[0, 1]区间内符合均匀分布的随机数, 变量 v_{kij}^{t+1} 表示粒子 k 在第 $t + 1$ 次迭代时的速度.

3.6 粒子的速度更新策略(Particle speed update strategy)

为了获得针对该问题不同环境下的最佳速度更新策略, 采用了以下3个速度更新策略进行分析比较. 它们分别是Shi等人^[12]提出的基于时变惯性权重的速度更新策略, Eberhart等人^[13]提出的基于收缩因子的速度更新策略, Ho等人^[10]提出的基于实际经验的速度更新策略.

4 算法分析(Algorithm analysis)

算法性能的评估是多目标优化问题重点研究的内容之一. 由于多目标优化不存在一个可以全面评估求解结果的指标. 本文针对大中小3个规模的问题, 采用多样性、收敛性和分布性指标来比较不同算法策略的性能, 并给出不同策略各自的优劣性和适应性.

4.1 实验设计(Experimental design)

设定种群数大小为100, 个体动态存储器长度为10, 外部存储器长度 N_p 为10, 网格数量 N^2 为 10^2 (10行, 10列), 适应值和age变量的加权系数 ω_1 和 ω_2 分别设为1和0.8; 在应用速度更新式(1)时, $c_{\max}$ 和 $c_{\min}$ 分别设置为0.9和0.1, $\omega_{\max}$ 和 $\omega_{\min}$ 分别设置为

1.8和1; 在应用速度更新式(2)时收缩因子(χ)设置为0.382, 设置 $c_1=c_2$ 为2.5.

通过采用很大迭代次数, 例如10000代, 随机运算20次, 从中获得近似Pareto前沿 PF_{true} , 作为算法评估的基准值. 下面针对大中小3个规模的问题, 在不同算法策略下分别随机运行10次实验, 运行代数均为2000代.

4.2 多样性评价指标 $|PF_{\text{know}}|$ (Diversity index evaluation $|PF_{\text{know}}|$)

对于多目标问题而言, 决策者希望可以有较多的选择, 作为可以应付不同实际情况的备选方案. 即, 希望有较多的非支配解个数($|PF_{\text{know}}|$).

定义6 PF_{know} : 算法求解问题得到的非支配解在目标函数空间映射的向量称为非支配前沿.

定义7 PF_{true} : 为了获得检验算法性能的基准数据, 针对某个问题实例, 通过多次具有很大迭代次数的实验, 得到的非支配解在目标函数空间映射的向量称为近似Pareto前沿.

根据图4和表1可知, 在多样性指标方面, 基于时变惯性权重策略更加适应小规模问题(10×20), 收缩因子和实际经验策略适合大中规模的问题, 实际经验策略得到非支配解个数增幅大于收缩因子策略的增幅.




图4 不同问题规模不同速度策略的非支配解个数
Fig. 4 Number of non-dominated solutions of different speed formulas under different scales of problem

表1 不同规模不同速度更新策略下非支配解个数
Table 1 Diversity of different speed formulas under different scales of problem

速度更新策略	问题规模 (候选员工×技能总数)	非支配解个数
v_1	10 × 20	13.9
	30 × 50	13.3
	55 × 100	12.6
v_2	10 × 20	12
	30 × 50	14.2
	55 × 100	13.5
v_3	10 × 20	13.2
	30 × 50	15.7
	55 × 100	15.9

4.3 收敛性评价指标(Convergence index evaluation)

$|PF_{\text{know}}|$ 的值越大, 说明决策者有越多的选择, 但是决策者希望在有较多选择方案的同时, 这些选择都是尽可能好方案, 或者尽可能地接近好方案. 本文采用Deb等人^[14]提出的 PF_{know} 与 PF_{true} 在目标函数空间的逼近距离 γ 作为衡量选择方案好坏的指标.

定义 8 PF_{know} 与 PF_{true} 的逼近距离: PF_{know} 中各个向量与 PF_{true} 中向量的最小欧几里德距离的平均值. 逼近距离的计算公式为: $\gamma = (1/N_1) \times \sum_{n=1}^{N_1} \min d_{nm}, \forall m=1, \dots, N_2$, 其中: N_1 表示 PF_{know} 中向量个数, N_2 表示 PF_{true} 中向量个数, d_{nm} 表示 PF_{know} 中第 n 个目标函数向量与 PF_{true} 中第 m 个目标函数向量的欧几里德距离, 逼近距离越小越好. $A(i, j)$ 和 $B(k, l)$ 两点的欧几里德距离计算公式为 $d_{AB} = \sqrt{(i-k)^2 + (j-l)^2}$.

根据图5和表2可知, 对于各个规模的问题, 均是采用时变惯性权重策略得到最好的收敛性, 并且对于小规模问题这种优势特别显著; 对于 30×50 规模问题, 采用基于搜索因子的速度更新策略得到结果的收敛性最差, 对于其他两个规模问题, 采用实际经验策略得到结果的收敛性最差; 对于各个规模问题, 采用以上3种策略实验结果的收敛性的标准差很小, 说明了算法的收敛性很稳定.




图5 不同问题规模下3种速度策略收敛性比较

Fig. 5 Compare of convergence metric of different speed formulas under different scales of problem

表2 不同问题规模不同速度策略的收敛性指标
Table 2 Convergence metric of different speed formulas under different scales of problem

问题规模	速度更新策略	收敛性指标	
		距离的均值	距离的标准差
10 × 20	v_1	0.0185889	0.00004653
	v_2	0.0373991	0.00004819
	v_3	0.0386399	0.0001346
30 × 50	v_1	0.02949	0.00003496
	v_2	0.0327451	0.00004132
	v_3	0.0314335	0.00001595
55 × 100	v_1	0.0167398	0.00001135
	v_2	0.0174851	0.00001237
	v_3	0.0188656	0.00002217

4.4 分布性评价指标(Distribution index evaluation)

有些决策者希望方案可以广泛的对应到各种不同的实际情况, 即要求 PF_{know} 中向量在目标函数空间分布得均匀并且广泛. 本文采用Deb等人^[14]提出的分布性指标 Δ , 计算公式如下:

$$\Delta = \frac{d_f + d_l + \sum_{i=1}^{N-1} |d_i - \bar{d}|}{d_f + d_l + (|PF_{\text{know}}| - 1)\bar{d}}. \quad (10)$$

根据图6和表3可知, 随着问题规模的扩大, 得到结果的分布均匀广泛性变差. 相比较而言, 带有网格(gird)的分布均匀广泛性更好些.




图6 不同问题规模下3种速度策略分布性比较

Fig. 6 Compare of distributivity metric of different speed formulas under different scales of problem

表3 不同问题规模不同速度策略的分布性指标
Table 3 Distributivity metric of different speed formulas under different scales of problem

问题规模	速度与网格技术	分布均匀广泛性	
		均值	标准差
10 × 20	v_1	0.56823	0.00606
	v_1 & grid	0.56029	0.00401
	v_2	0.61293	0.00412
	v_2 & grid	0.59118	0.00388
	v_3	0.57795	0.01089
	v_3 & grid	0.59729	0.01254
30 × 50	v_1	0.66156	0.01291
	v_1 & grid	0.66844	0.01541
	v_2	0.67448	0.00663
	v_2 & grid	0.65339	0.01050
	v_3	0.70971	0.01230
	v_3 & grid	0.61064	0.00632
55 × 100	v_1	0.66356	0.00420
	v_1 & grid	0.68620	0.00366
	v_2	0.66293	0.01221
	v_2 & grid	0.66123	0.01191
	v_3	0.70229	0.00265
	v_3 & grid	0.67037	0.01581

5 数值算例(Numerical examples)

以一条有20个任务的单元装配线为例, 培训员工为10人, 任务覆盖水平为 $R = [2 \ 3 \ 2 \ 3 \ 2 \ 2 \ 2 \ 2 \ 3 \ 2 \ 3 \ 3]$

2 2 3 3 3 3 2 2], 表4给出了10个员工的满意度函数的参数. 通过给出的多目标粒子群算法和最佳参数, 可以获得满意的一组交叉培训方案.

表4 满意度函数参数

Table 4 Satisfaction function parameters

员工编号	满意度下限	满意度上限	不满意度下限	不满意度上限
1	3	6	1	9
2	4	7	2	10
3	5	8	3	11
4	6	9	4	12
5	7	10	5	13
6	7	10	5	13
7	6	9	4	12
8	5	8	3	11
9	4	7	2	10
10	3	6	1	9

图7显示一共获得22个Pareto最优解, 解具有较好的多样性和分布性. Pareto最优解的两端的目标值分别为(1, 0.797)和(0.400, 0.987). 人力资源决策者可以根据实际情况, 从这组解选取符合自己偏好的培训方案.




图7 20任务问题的非支配解示意图(10个员工)

Fig. 7 Pareto solutions for problem 20 tasks (10 labors)

6 结论(Conclusions)

为了提高交叉培训规划的实用性, 在任务覆盖水平策略的基础上, 考虑了学习行为因素, 提出了以员工满意度和学习效率为目标的多目标优化模型. 利用粒子群存在多个全局最好位置的群体搜索策略, 给出了基于MOPSO的交叉培训规划方法. 最后, 以柔性单元装配生产产线为例, 针对大中小3个不同规模的问题, 采用多样性、分布均匀性和收敛性算法评价指标对多种算法策略进行了性能比较. 从分析结果可以看出, 为了得到较多的决策方案, 对于小规模问题应采用基于时变惯性权重的策略, 对于中规模和大规模问题采用实际经验更新策略. 要想得到结果具有良好的收敛性, 建议采用基于时变惯性权重的策略, 若希望得到的结果分布更均匀更广泛则建议采用网格技术. 最后, 本文通过一个算例说明了模

型的有效性和合理性. 总体来说, 提出的方法可有效解决交叉培训规划中的优化问题.

参考文献(References):

- [1] BOKHORST J, GAALMAN G. Cross-training workers in dual resource constrained systems with heterogeneous processing times [J]. *International Journal of Production Research*, 2009, 47(22): 6333 – 6356.
- [2] IRAVANI S M R, KOLFAL B, VAN OYEN M P. Call-center labor cross-training: it's a small world after all [J]. *Management Science*, 2007, 53(7): 1102 – 1112.
- [3] MOLLEMAN E, VAN DEN B A. Worker flexibility and its perceived contribution to performance: the moderating role of task characteristics [J]. *Human Factors and Ergonomics in Manufacturing*, 2007, 17(2): 117 – 135.
- [4] NEMBHARD D A, PRICHANONT K. Cross training in serial production with process characteristics and operational factors [J]. *IEEE Transactions on Engineering Management*, 2007, 54(3): 565 – 575.
- [5] EASTON F F. Cross-training performance in flexible labor scheduling environments [J]. *IIE Transactions*, 2011, 43(8): 589 – 603.
- [6] 李倩, 宫俊, 唐加福. 基于改进NSGA-II的交叉培训计划多目标优化 [J]. 东北大学学报(自然科学版), 2011, 32(12): 1696 – 1699. (LI Qian, GONG Jun, TANG Jiafu. Multi-objective optimal cross-training plan models using non-dominated sorting genetic algorithm-II [J]. *Journal of Northeastern University (Natural Science)*, 2011, 32(12): 1696 – 1699.)
- [7] CAMPBELL G M. Cross-utilization of workers whose capabilities differ [J]. *Management Science*, 1999, 45(5): 722 – 732.
- [8] 江友华, 廖代发, 唐忠. 混合有源滤波器多目标优化设计 [J]. 控制理论与应用, 2010, 27(7): 916-922. (JIANG Youhua, LIAO Daifa, TANG Zhong. Multi-objective optimal design for hybrid active power filter [J]. *Control Theory & Applications*, 2010, 27(7): 916 – 922.)
- [9] 王耀南, 许海霞, 朱江, 等. 平行线段对应的运动估计线性算法 [J]. 控制理论与应用, 2011, 28(2): 166 – 172. (WANG Yaonan, XU Haixia, ZHU Jiang, et al. A linear algorithm for motion estimation using parallel-line-segment correspondences [J]. *Control Theory & Applications*, 2011, 28(2): 166 – 172.)
- [10] HO S L, YANG S Y, NI G Z, et al. A particle swarm optimization-based method for multi-objective design optimizations [J]. *IEEE Transactions on Magnetics*, 2005, 41(5): 1756 – 1759.
- [11] KENNEDY J, EBERHART R C. A discrete binary version of the particle swarm algorithm [C] // *Proceedings of the 1997 IEEE International Conference on Systems, Man, and Cybernetics*. Orlando: IEEE, 1997, 41(5): 4104 – 4108.
- [12] SHI Y H, EBERHART R C. A modified particle swarm optimizer [C] // *The 1998 IEEE International Conference on Computational Intelligence*. Anchorage, AK: IEEE, 1998, 1: 69 – 73.
- [13] EBERHART R C, SHI Y H. Particle swarm optimization: developments, applications and resources [C] // *Proceedings of the 2001 Congress on Evolutionary Computation*. Seoul: IEEE, 2001, 1: 81 – 86.
- [14] 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(3): 182 – 197.

作者简介:

李倩 (1984-), 女, 博士研究生, 目前研究方向人力资源管理优化、智能计算, E-mail: happyqianqian@gmail.com;

宫俊 (1972-), 男, 副教授, 目前研究方向人力资源管理优化、智能计算和智能交通, E-mail: gongjun@ise.neu.edu.cn;

唐加福 (1965-), 男, 教授, 博士生导师, 目前研究方向服务运作管理, E-mail: jftang@mail.neu.edu.cn.