

# 改进量子行为粒子群算法智能组卷策略研究

李欣然 樊永生

(中北大学电子与计算机科学技术学院 太原 030051)

**摘要** 提出一种求解智能组卷问题的改进量子粒子群算法。首先,通过定义粒子进化速度及粒子聚集度,将惯性权重表示为粒子进化速度和粒子聚集度的函数,使惯性权重具有自适应性。其次,将慢变函数引入传统位置更新公式中,以有效地解决陷入局部最优解的问题。最后,根据项目反应原理对组卷问题进行数学建模。仿真实验表明,与标准粒子群算法和量子粒子群算法相比,所提算法在组卷成功率和组卷效率方面均具有更好的性能。

**关键词** 量子行为的粒子群优化算法(QPSO),自适应,惯性权重,慢变函数,项目反应理论(IRT),智能组卷  
**中图分类号** TP301.6 **文献标识码** A

## Study on Intelligent Test Paper Generation Strategy through Improved Quantum-behaved Particle Swarm Optimization

LI Xin-ran FAN Yong-sheng

(College of Computer Science and Technology, North University of China, Taiyuan 030051, China)

**Abstract** One improved Quantum-behaved particle swarm optimization for intelligent test paper generation was put forward. First of all, inertia weight is expressed as functions of particle evolution velocity and particle aggregation by defining them. Secondly, slowly varying function is introduced into the traditional position updating formula to effectively overcome the problem of getting into the local optimal solution. Finally, mathematical modeling is set for test paper generation problems based on item response theory. Simulation results show that, comparing with the standard particle swarm optimization algorithm and quantum particle swarm algorithm, the proposed algorithm is of better performance in the success rate and efficiency of test paper generation.

**Keywords** Quantum-behaved particle swarm optimization, Self-adaptive, Inertia weight, Slowly varying function, Item response theory(IRT), Autogenerating test paper

智能组卷是由计算机自动设计试卷内容,使生成的试卷满足各项组卷要求的一种考试改革技术。智能组卷本质上是一种多目标寻优问题,而解决组卷问题的难点是合理选择组卷算法。目前组卷算法多采用遗传算法(GA)<sup>[1-5]</sup>、鱼群算法<sup>[6]</sup>、和声搜索算法<sup>[7]</sup>及粒子群算法等。粒子群算法通过全局极值向全体粒子传递信息,是信息单向流动,所以该算法较其他进化算法能更快收敛于最优解,但是其也存在着早熟收敛现象。江南大学孙俊等人于2004年提出了具有量子行为的粒子群算法(QPSO)<sup>[8]</sup>,该算法的全局搜索能力大大增强。

但是QPSO算法中惯性权重 $\beta$ 的值是随着进化代数的增加而线性减少的,利用此种线性递减的方法来反映实际的非线性高度复杂的搜索过程,易导致算法陷入局部最优,从而影响算法的收敛速度。本文利用粒子进化速度及粒子聚集度来动态调整惯性权重,使惯性权重具有自适应性,避免陷入局部最优;同时将慢变函数引入传统位置更新公式中,以保持种群多样性,加强QPSO算法的全局搜索能力,提升算法的收敛速度;尝试利用改进的量子粒子群算法求解智能组卷问题。实验结果显示,改进算法能较好地解决智能组卷问题。

## 1 根据项目反应原理建立组卷问题模型

以教育测量理论为依据来设置题库中试题的各项指标要求,可以设计出能全面准确反映学生学习效果的试卷。并且,该理论能提供相应的方法和标准来检测组卷的可靠性和有效性。所以,依据教育测量理论来研究智能组卷问题,可以使生成的试卷更加科学规范<sup>[9]</sup>。

项目反应理论(Item Response Theory, IRT),是克服了以往测量理论的不足而产生的一种新兴的测量学理论。该理论将能力测量的估计标准误差的平方倒数定义为项目信息函数,并且利用项目信息函数作为建立、分析和检测测试效果的标准<sup>[10]</sup>。目前应用最广泛的项目反应理论模型是伯恩鲍姆(Birnbaum)提出的logistic模型中的三参数模型。

实际组卷中各种约束条件并不一定全部满足,此时就希望所选出的题目对于约束条件不满足解的总量最小。这就是Len Swanson和Martha L Stocking提出的离差加权模型(Weighted Deviations Model, WDM)思想<sup>[11]</sup>。该模型将约束条件的值设定在指定区间内,将计算结果是否属于设定的区

到稿日期:2012-06-20 返修日期:2012-10-28 本文受山西省自然科学基金(2012011011-3),国家自然科学基金项目(61004127)资助。

李欣然(1977-),女,硕士,讲师,主要研究方向为计算机应用、智能优化算法, E-mail: hexiecho@163.com; 樊永生(1967-),男,博士,教授,主要研究方向为图像处理、智能优化算法。

间作为判定约束条件是否满足的标准,当约束条件必须等于确定值时,设定区间上限等于区间下限。

本文借鉴文献[9]的做法,将测试项目信息函数值最高和离差加权值最小这两个目标相结合,来建立组卷问题数学模型。

### 1.1 模型变量及符号说明

1)  $x_i$  代表第  $i$  个试题,  $x_i$  的值为 0 表示第  $i$  题未选入组卷,  $x_i$  的值为 1 表示第  $i$  题入选组卷。

2)  $\sum_i I_i(\theta)x_i$  是目标函数,  $I_i(\theta)$  表示第  $i$  题在  $\theta$  约束条件下的信息函数值。  $I_i(\theta) = \frac{[P_i'(\theta)]^2}{P_i(\theta)Q_i(\theta)}$  ( $i=1, 2, \dots, n$ ),  $P_i(\theta)$  是唯一依赖于能力为  $\theta$  的被试正确反应的概率, 三参数 Logistic 模型中  $P_i(\theta) = c_i + (1+c_i) \frac{1}{1+e^{-d_i(\theta-b_i)}}$ ,  $P_i'(\theta)$  为  $P_i(\theta)$  在  $\theta$  点上的导数,  $Q_i(\theta) = 1 - P_i(\theta)$ 。  $\sum_i I_i(\theta)x_i$  是所组试卷在  $\theta$  点的测验信息函数值。

3)  $s_i$  表示第  $i$  题的分数,  $M$  表示试卷总分。

4)  $w_j$  表示第  $j$  个约束条件的权重。

5)  $L_j$  表示第  $j$  个约束条件的取值区间下限,  $U_j$  代表第  $j$  个约束条件的取值区间上限,  $d_{L_j}, e_{L_j}, d_{U_j}, e_{U_j}$  含义与上相同。

6)  $b_{ij}$  取值为 0 表示第  $i$  题未满足第  $j$  个约束条件,  $b_{ij}$  取值为 1 表示第  $i$  题满足第  $j$  个约束条件。

7)  $G_m$  表示题库的子集。

### 1.2 组卷问题模型

$$\min \left[ \frac{1}{\sum_i I_i(\theta)x_i + 1}, \sum_{j=1}^J w_j d_{L_j} + \sum_{j=1}^J w_j d_{U_j} \right] \quad (1)$$

首先,根据离差加权模型思想先选出试题总分、题型、难度、知识点的分数都尽可能满足组卷要求的试题,也就是选出离差加权值最小的试题;然后,对题库中满足上述约束条件并且信息贡献量大的试题进行优化选择,进而生成测验项目信息函数值最高的试题。根据上述思想将模型(1)分解为模型(I)和(II),表示如下:

$$(I) \min \left( \sum_{j=1}^J w_j d_{L_j} + \sum_{j=1}^J w_j d_{U_j} \right) \quad (2)$$

$$\begin{cases} \sum_i^N s_i x_i = M & (a) \\ \sum_i^N b_{ij} x_i + d_{L_j} - e_{L_j} = L_j & (b) \\ \sum_i^N b_{ij} x_i - d_{U_j} + e_{U_j} = U_j & (c) \\ d_{L_j}, e_{L_j}, d_{U_j}, e_{U_j} \geq 0 & (d) \end{cases}$$

$$(II) \max \sum_i I_i(\theta)x_i \quad (3)$$

$$\begin{cases} \sum_{i \in G_m} x_i = 1 \quad (m=1, 2, \dots, n) \\ x_i \in \{0, 1\} \end{cases}$$

式(3)中  $G_m$  表示题库的子集,是通过求解模型(I)选出  $n$  个试题后,将题库分成  $n$  个题型、难度、知识点等与已选出的试题相同的题库子集合。这样模型(II)就是在模型(I)已经选出试题的基础上二次选出题型、难度、知识点分布等约束条件相同、但测验信息函数值最大的若干试题。

如果需要限制连续生成的  $m$  份试卷中试题的重复率,那么可以设试卷  $X$  中试题  $x$  在试卷编号为  $A_i(x)$  的试卷中出

现,  $A_2(x)$  为本次组卷试卷编号。试题重复率的限制定义为:

$$A_2(x) - A_1(x) > m, \forall x \in X \quad (4)$$

本文实验中,约束条件重复率是通过从题库中删除不满足重复率要求的试题来去除这个约束条件,这种做法能够缩小寻优的搜索范围,提高算法的效率。

本文拟利用改进的量子粒子群算法求解组卷问题数学模型。

## 2 量子行为粒子群算法

为了提高粒子的全局搜索能力,江南大学孙俊等人于 2004 年提出具有量子行为的粒子群算法(QPSO)<sup>[8]</sup>。量子行为的粒子群算法以 DELTA 势阱为基础,将粒子看成具有量子行为的个体。由于量子空间中的粒子满足聚集态的性质是不同的,因此粒子只能按确定的轨迹移动,这使得粒子可以在整个可行解空间中探索全局最优解,因而 QPSO 算法的全局搜索能力大大优于经典的粒子群算法。由于在量子空间中不能同时确定粒子的速度和位置,因此利用波函数来描述粒子的状态,并通过求解薛定谔方程生成粒子在空间某一位置出现的概率密度函数,使用 Monte Carlo 随机模拟方式得到粒子的位置方程为:

$$X(t) = P \pm \frac{L}{2} \ln \left[ \frac{1}{u} \right]$$

式中,  $u$  是服从在  $[0, 1]$  上均匀分布的随机数;  $L$  值由式  $L(t+1) = 2b |mbest - X(t)|$  确定。最终得到 QPSO 算法的进化方程为:

$$P = \alpha * Pbest(i) + (1 - \alpha) * Gbest \quad (5)$$

$$mbest = \frac{1}{M} \sum_{i=1}^M Pbest(i) \quad (6)$$

$$b = 1.0 - generation / maxgeneration * 0.5 \quad (7)$$

$$position = P \pm b * |mbest - position| * \ln(1/\mu) \quad (8)$$

式中,  $Pbest(i)$  表示第  $i$  次迭代时粒子的最优位置;  $Gbest$  表示第  $i$  次迭代过程中群体的全局最优位置;  $P$  是位于  $Pbest(i)$  与  $Gbest$  中间的一个随机位置;  $mbest$  是粒子群  $Pbest$  的中间位置,也就是平均值;  $b$  为惯性权值,是 QPSO 算法收敛的一个重要参数,在量子行为粒子群算法收敛过程中线性递减;  $\alpha, \mu$  为 0 至 1 之间的随机数,当  $\mu$  的取值大于 0.5,式(8)取加,否则取减;  $generation$  表示当前进化代数,  $maxgeneration$  表示设定的最大进化代数<sup>[12]</sup>。

## 3 具有量子行为的粒子群算法改进策略

### 3.1 根据粒子进化速度和聚集度动态地调整惯性权值

1) 定义粒子进化速度

设  $f(Gbest(t))$  和  $f(Gbest(t-1))$  分别为第  $t$  次和第  $t-1$  次迭代的全局最佳位置值的适应度值,则定义进化速度为:

$$es = f(Gbest(t-1)) / f(Gbest(t)) \quad (9)$$

本文求适应度最大值,根据式(9)定义可知,  $0 < es \leq 1$ 。  $es$  值越小,进化速度越快。  $es$  值保持为 1,则可判定算法找到了粒子的最优解。

2) 定义粒子聚集度

设  $f(Gbest(t))$  是粒子群在第  $t$  次迭代的全局最佳位置适应度值,  $f(Gbest(t))$  必然优于个体粒子在同次迭代过程中

的最佳位置适应度值  $f(Pbest(t))$ 。定义全部粒子在第  $t$  次迭代过程中最佳位置适应度值  $f(Pbest(t))$  的平均值为：

$$Fa = \frac{1}{N} \sum_{i=1}^N f(Pbest(t)) \quad (10)$$

在极大值的寻优过程中,  $f(Gbest(t)) \geq Fa$ , 进而定义粒子聚集度为：

$$gd = Fa / f(Gbest(t)) \quad (11)$$

显然,  $0 < gd \leq 1$ ,  $gd$  能够反映粒子的聚集程度和种群的多样性。 $gd$  值增大, 说明粒子的聚集程度也增大, 同时粒子多样性降低。当  $gd$  的值为 1 时, 全部粒子具有同一性特征, 此时算法陷入局部最优。

### 3) 定义动态调整惯性权重

据粒子进化速度  $es$  和粒子聚集度  $gd$  的值来动态调整惯性权重  $b$ , 即：

$$b = \beta_0 - es\beta_1 + gd\beta_2 \quad (12)$$

式中,  $\beta_0$  是  $b$  的初始值, 一般情况  $\beta_0$  取值为 1;  $\beta_1$  是  $es$  作用下的权重;  $\beta_2$  是  $gd$  作用下的权重。 $\beta_1$ 、 $\beta_2$  的取值对算法的性能也有较大的影响。对经典测试函数 Sphere 函数  $f(y) = \sum_{i=1}^N y_i^2$  ( $i = 1, 2, \dots, N$ ) 进行比较测试。算法运行次数为 10, 粒子数为 20, 维数为 2, 精度为  $10^{-6}$ , 最大迭代次数为 100。实验结果表明,  $\beta_1$  取值为 0.5,  $\beta_2$  取值为 0.1, 时算法性能最佳。

式(12)中, 如果  $gd$  的值增大, 说明粒子群聚集程度变大, 则惯性权重  $b$  的值增大, 使粒子具有较好的全局搜索能力, 保持较好的种群多样性。如果  $es$  的值增大, 说明粒子进化速度减慢, 则惯性权重  $b$  的值减小, 这样粒子则具有较好的局部搜索能力, 利于局部寻优。

## 3.2 利用慢变函数克服早熟收敛

本文利用粒子聚集度  $gd$  值来判断是否早熟停滞, 利用慢变函数使粒子克服早熟。 $gd$  能够反映粒子的聚集程度和种群的多样性。 $gd$  值增大, 粒子的聚集程度也增大, 导致粒子多样性降低。 $gd$  的值为 1 时, 粒子群中的全部粒子特征相同, 此时算法陷入局部最优。在位置更新公式中引入了慢变函数的扰动, 增强了局部搜索能力, 有助于提高解的精度, 适用于粒子中后期保持种群多样性。

$$position = P \pm b * |mbest - position| * \ln(1/\mu) + L(x) \quad (13)$$

因为没有增加(或减小)速度最快的慢变函数, 也没有摆动(或振荡)速度最快的慢变函数<sup>[13]</sup>, 所以本文采用  $L(x) = (\lg x)^a$  形式的慢变函数, 其中  $a \in R$ 。

## 3.3 算法验证

采用标准的测试函数测试改进算法的性能, 并与具有量子行为的粒子群算法性能进行比较。测试函数取单峰二次函数标准 Sphere 函数、病态单峰二次函数 Rosenbrock 函数、具有大量局部最优点的多峰函数 Rastrigrin 函数。

在 Intel Pentium IV 2.0 GHz 的 CPU, 4GB 内存, Windows XP 平台上, MATLAB 7.0 环境下进行仿真计算。算法中利用测试函数作为粒子的适应函数, 实验运行 20 次, 计算平均值, 测试函数粒子数为 20, 最大迭代次数 100。QPSO 算法中,  $\beta$  的值在 [1.2~0.4] 范围线性递减。改进算法中,  $\beta_1$  取值 0.5,  $\beta_2$  取值 0.2,  $\beta$  在进化过程中自适应调整。实验结果

如表 1 所列。

表 1 测试函数下本文改进算法与 QPSO 算法的性能比较

测试函数	本文改进算法		QPSO 算法	
	最优适应度值	时间(ms)	最优适应度值	时间(ms)
Sphere	$2.37 \times 10^{-6}$	141.3	$2.68 \times 10^{-6}$	301.3
Rosenbrock	$0.83 \times 10^{-1}$	419.6	$8.82 \times 10^{-1}$	557.9
Rastrigrin	$3.72 \times 10^{-6}$	329.5	$4.25 \times 10^{-6}$	592.4

由表 1 可知, 对于实验中的测试函数, 本文改进算法的运行结果要明显优于 QPSO 算法, 且平均迭代时间明显缩减。实验说明, 改进算法可以明显提高粒子的收敛速度, 对于复杂函数优化问题具有较强的全局搜索能力, 能有效地解决 QPSO 算法的早熟收敛问题。

## 4 求解智能组卷问题的改进量子粒子群算法

### 4.1 粒子编码

设题库中试题数量为  $P$ , 有 5 种题型(每种题型试题数量分别是  $P_1$  至  $P_5$ )。用  $P$  位二进制字符串来表示题库中各道题的状态, 即  $(S_1 S_2 \dots S_P)$ , 其中, 若  $S_k = 1$ , 则表示第  $k$  道题被选中;  $S_k = 0$ , 则表示第  $k$  道题未被选中。对于试题数量为  $Q$  的试卷, 则应满足:  $\sum_{k=1}^P S_k = Q$ 。

根据题库中同类型试题分值相同的特征, 采用按题型分段编码的方案, 先对各题型试题分别进行独立编码, 然后再组合成  $P$  位代码, 则总编码串为  $(S_{1,1} \dots, S_{P_1,1}), \dots, (S_{1,5}, \dots, S_{P_5,5})$ 。设组卷要求的各种题型的试题数分别为  $Q_1, \dots, Q_5$ , 即  $\sum_{k=1}^5 Q_k = Q$ , 则应该满足:  $\sum_{i=1}^{P_k} S_{i,k} = Q_k$  ( $k = 1, \dots, 5$ )。这种分段独立编码方法可缩小解的搜索空间, 简化问题的求解。

### 4.2 适应度函数定义

量子粒子群算法中粒子当前位置的好坏通过适应度值进行评价。对应离差加权值最小和测验项目信息函数值最高的函数值越小, 则适应度越高。相应的适应度函数为：

$$f(p^*) = \frac{1}{\left[ \sum_i I_i(\theta) x_i + 1, \sum_{j=1}^J w_j d_{L_j} + \sum_{j=1}^J w_j d_{U_j} \right]} \quad (14)$$

式中, 向量  $p^*$  代表一个完整的编码方案。 $p^*$  为一个  $Q$  维向量, 代表试题数量为  $Q$  的组卷方案中一个可能的解。

### 4.3 求解组卷问题的改进量子粒子群算法

步骤 1 编码, 并对粒子群、粒子个体最优值  $Pbest$ 、群体最优值  $Gbest$  进行相应初始化。

步骤 2 根据目标函数式(14)计算全体粒子的适应度; 判断算法是否满足收敛条件, 如果收敛, 执行步骤 7; 否则, 执行步骤 3。

步骤 3 根据式(9)一式(11)计算出粒子进化速度和粒子聚集度, 按式(12)计算惯性权重  $b$  的值。

步骤 4 依据适应度值, 更新每个粒子的最佳位置  $Pbest(i)$  及群体最佳位置  $Gbest$ ; 根据式(5)一式(8)更新全部个体粒子的位置, 生成新的粒子群。

步骤 5 如果  $gd$  的值长时间接近 1 但不满足终止准则, 按式(13)通过慢变函数对位置更新公式进行扰动; 否则, 转向步骤 6。

步骤 6 如果达到设定的终止条件, 则执行步骤 7; 否则, 转向执行步骤 2。

步骤 7 输出全局最优位置  $Gbest$  及其适应度值。

## 5 求解智能组卷问题算法测试

本文实验采用模拟题库,题库是基于项目反应理论模型三参数 Logistic 模型( $a_i \sim N(0,1)$ ;  $b_i \sim N(0,1)$ ;  $c_i = 0.2$ )的《C 语言程序设计》题库,该题库的试题数量为 1000,题型有程序填空、选择、编程、分析程序运行结果、判断,各种题型试题数量为 200。测试目标的能力估计值为  $\theta_1 = -1, \theta_2 = 0, \theta_3 = 1$ 。利用随机函数产生试题的各种属性(如难度、知识点分布等),同时设置生成试卷的其他条件。 $\beta_1$  取值为 0.5;  $\beta_2$  取值为 0.1。种群规模为 50(试题数量),最大迭代次数为 500。生成试题能够满足各种约束条件,在测试目标能力估计值为  $\theta_1 = -1, \theta_2 = 0, \theta_3 = 1$  点上的信息量值是 24.68, 26.47, 28.52。

为了进一步验证算法的性能,让本文算法与基本粒子群算法和具有量子行为的粒子群算法进行组卷比较实验。粒子群算法参数设置设为  $c_1 = c_2 = 2$ ;  $w$  初始为 0.9,然后线性递减至 0.4。量子行为粒子群算法的惯性权重  $b$  在区间[1.2, 0.4]内均随迭代次数的增加而线性减少。本文算法  $\beta_1$  取值为 0.5;  $\beta_2$  取值为 0.1。种群规模为 50(试题数量),最大迭代次数为 500。

分别利用本文算法、基本粒子群算法和具有量子行为的粒子群算法各进行 20 次组卷实验,算法的运行结果如表 2 所列。

表 2 3 种算法仿真结果对比

算法	进化代数			CPU 运行时间(s)			组卷成功率
	max	min	ave	max	min	ave	
PSO	241	80	159	5.2541	3.4536	4.0125	92%
QPSO	179	83	129	3.1203	1.2356	2.3547	95%
本文算法	96	23	45	0.9586	0.3421	0.5468	99%

实验中,通过计算算法的进化代数和 CPU 运行时间以及组卷成功率来说明本文改进算法的有效性。“组卷成功率”为算法运行 20 次找到可行解的概率。由表 2 可知,QPSO 算法的进化代数明显比 PSO 算法少,运行时间也有所减少,采用量子行为的粒子群优化算法能够有效确保算法的收敛,并且使粒子群优化算法有了更快的收敛速度;但基于量子行为的粒子群优化算法容易陷入局部最小,且搜索精度不是很高。本文改进 QPSO 算法,将惯性权重表示为粒子进化速度和粒子聚集度的函数,使惯性权重具有自适应性。而且,将慢变函数引入传统位置更新公式中,可有效地克服陷入局部最优解的问题,从而减少无效迭代。所以本文算法的进化代数比 QPSO 算法有所减少,运行时间也有所减少。同时可见 3 种算法的组卷成功率逐步提高。表明本文算法求解本文提出的组卷模型是可行的、有效的。

项目反映理论利用测验信息函数来检测组卷效果,即利用测验信息函数在某些能力点  $\theta$  上与指定的测验信息函数 TIF 曲线相匹配的程度来检测组卷效果,使得生成试卷更加科学规范<sup>[9]</sup>。

对本文提出的模型和算法采用项目反映理论测试方法进行测试。测验要求是生成与目标测验信息函数 TIF 相匹配的测验,测验试卷包含选择题 5 个、填空题 5 个、编程题 5 个、分析程序运行结果题 5 个、判断题 5 个。分别利用本文提出的组卷算法、PSO 算法、QPSO 算法进行组卷实验。各种算法的组卷信息函数与指定能力区间的测验信息函数 TIF 曲线如图 1 所示。




图 1 目标检测信息函数 TIF 与各种算法生成测验的测验信息函数

图 1 表明,利用本文提出的算法进行组卷实验的测验信息函数值与目标测验信息函数 TIF 曲线最为接近,说明本文算法较其他两种算法组卷效果更佳;同时也表明本文提出的组卷问题模型和组卷算法是有效的。

**结束语** 本文针对量子行为粒子群算法易于陷入局部最优和早熟等缺点,定义了粒子进化速度和粒子聚集度公式,将惯性权重表示为粒子进化速度和粒子聚集度的函数,使惯性权重具有动态自适应性;并将慢变函数引入传统位置更新公式中,有效地克服了陷入局部最优解的问题。改进后的量子行为粒子群算法具有更高的全局搜索性能。根据项目反应原理,建立组卷问题数学模型,提高了组卷成功率和组卷效率。仿真试验表明,本文算法较标准粒子群算法和具有量子行为的粒子群算法具有较高的搜索性能和较快的收敛速度。组卷模型和求解模型算法的可行性、有效性均得到了验证。

## 参考文献

- [1] 杨军. 一种改进的遗传算法在自动组卷中的应用[J]. 计算机应用与软件, 2009, 26(12): 225-227
- [2] 李会民, 张仁津, 马桂英. 基于遗传算法的交规考试自动组卷方法研究[J]. 计算机工程与设计, 2009, 30(18): 1026-1030
- [3] 周艳聪, 刘艳柳, 顾军华. 小生境自适应遗传模拟退火智能组卷策略研究[J]. 小型微型计算机系统, 2011, 32(2): 323-327
- [4] 刘贝贝, 肖明, 马晓敏. 基于推理的组卷数学建模及其应用[J]. 计算机工程, 2010, 36(4): 195-197
- [5] 周艳聪, 刘艳柳. 遗传模拟退火智能组卷策略研究[J]. 计算机工程与设计, 2011, 32(3): 1066-1069
- [6] 任剑, 卞旭, 全惠云. 基于层次分析方法与人工鱼群算法的智能组卷[J]. 计算机应用研究, 2010, 27(4): 1293-1296
- [7] 王凤蕊, 王文宏, 潘全科, 等. 解决智能组卷问题的和声搜索算法研究[J]. 计算机仿真, 2010, 27(3): 298-301
- [8] Sun J, Feng B, Xu W B. Particle swarm optimization with particles having quantum behavior[C]// Proceedings of 2004 Congress on Evolutionary Computation. Piscataway, NJ: IEEE Press, 2004: 325-331
- [9] 张建国. 智能教学系统中的自动组卷算法研究[D]. 郑州: 河南大学, 2009
- [10] 漆书青, 戴海崎, 丁树良. 现代教育与心理测量学原理[M]. 北京: 高等教育出版社, 2002
- [11] Swanson L, Stoeking M L. A model and heuristic for solving very large item selection Problems[J]. Applied Psychological Measurement, 1993, 17(2): 151-166
- [12] 李欣然, 靳雁霞. 量子行为粒子群优化算法在公交调度优化中的应用[J]. 计算机系统应用, 2012, 21(7): 191-195
- [13] 杨义群. 慢变函数的特性[J]. 自然杂志, 1982, 2: 153-154
- [13] 吴文欢, 张少辉, 李巍, 等. 分阶段进化的粒子群优化算法[J]. 重庆理工大学学报: 自然科学版, 2012, 26(6): 67-70