

基于改进离散粒子群算法的测试优化选择

马 羚¹, 李海军¹, 王成刚², 张晓瑜³

(1. 海军航空工程学院 兵器科学与技术系, 山东 烟台 264001;

2. 海军航空工程学院 基础实验部, 山东 烟台 264001;

3. 新疆军区指挥自动化工作站, 乌鲁木齐 830042)

摘要: 为了解决复杂系统测试性设计过程中测试选择所产生的组合爆炸问题, 提出一种改进离散粒子群算法的智能方法; 首先, 为保证初始种群的多样性, 利用混沌不重复遍历的特性初始化种群的速度和位置; 其次, 根据启发式规则和罚函数的方法计算粒子适应度, 使算法具有良好的搜索性能; 最后, 通过采用自适应调整策略的惯性权重, 使粒子易于跳出局部最优解, 找到最优解; 通过仿真实例验证了文章方法的有效性, 优化结果满足系统各项测试性指标要求, 可为复杂系统的测试优化选择提供有效指导。

关键词: 测试性设计; 测试选择; 离散粒子群算法; 混沌

Optimal Test Selection Based on Improved Discrete PSO Algorithm

Ma Ling¹, Li Haijun¹, Wang Chenggang², Zhang Xiaoyu³

(1. Department of Weapon Science and Technology, Naval Aeronautical and Astronautical University, Yantai 264001, China;

2. Department of Basic Experiment, Naval Aeronautical and Astronautical University, Yantai 264001, China;

3. Command Automation Workstation, Xinjiang Military Region, Urumqi 830042, China)

Abstract: Due to the fact that the combinatorial explosion problem of test selection in the design for testability for complex system, an intelligent method of test selection based on an improved discrete particle swarm optimization algorithm (IDPSO) is put forward. First, the ergodic of chaos has been used to initialize the velocities and positions of the particles. Then, the fitness value is calculated by heuristic rule and penalty function to improve the search performance. Finally, The inertia weights were adjusted according to adaptively strategy, which can avoid the particles trapped in local optimal. The simulation results meet all system requirements and show that IDPSO algorithm can achieve global optimal solution fast and effectively, which makes it a good solution to the optimal test selection for complex system.

Keywords: design for testability; test selection; discrete particle swarm optimization; chaos

0 引言

随着航空武器装备中电子系统复杂度和集成度的急剧增加, 系统测试性与装备性能的一体化设计成为发展现代复杂航空电子设备故障检测与诊断技术的必然要求。测试优化选择是系统测试性设计的基础, 对复杂航空电子设备故障检测与诊断平台的实现具有至关重要的作用。测试优化选择需要解决以下两个问题^[1]: 1) 在保证系统故障覆盖和辨识的前提下, 确定需要采用的完备测试集; 2) 从完备的备选测试集中, 选择对应测试代价最小的最优完备测试子集。

测试优化选择问题是一个组合优化问题, 属于 NP 完全问题, 当系统规模较大时, 获取最优解的难度较大。对于此类问题国内外学者进行了广泛研究, 提出了各种求解方法, 如基于布尔逻辑的方法, 基于遗传算法的方法, 基于信息熵的方法, 基于离散粒子群优化 (DPSO, discrete particle swarm optimization) 的方法, 基于量子进化算法的方法等^[2-7], 这些算法在求解一定集合规模的问题具有良好的性能, 但随着航空电子设备复杂程度的提高, 集合规模的增大, 求解精度与运算速度都差强人意。

本文在参考粒子群算法各种改进策略的基础上, 针对测试优化选择问题, 提出一种改进的离散粒子群优化算法 (IDPSO, improved DPSO)。该算法利用混沌的遍历特性初始化粒子的速度和位置, 使初始种群分布多样化, 从而提高了算法的全局寻优能力; 结合测试选择的特点, 通过采用启发式规则和罚函数方法修正越界粒子, 避免种群随机性过强找不到可行解, 提高了算法的收敛速度和精度; 同时, 采用自适应调整策略的惯性权重, 使粒子跳出局部最优解, 避免粒子早熟现象。最后通过超外差接收器系统实例验证了算法的有效性和先进性。

1 测试优化选择问题建模

1.1 故障-测试相关性矩阵

测试优化选择的主要目的是在满足测试性指标要求的前提下, 化简故障-测试相关性矩阵 (简称相关性矩阵)。相关性矩阵是描述系统故障和测试相关关系的二值矩阵, 可通过 FMECA 分析或仿真分析获取^[5]。设系统待检测与诊断的故障集合为 $F = \{f_1, \dots, f_m\}$, 相应的故障先验概率矢量为 $\lambda = [\lambda_1, \dots, \lambda_m]^T$; 备选测试构成的集合为 $T = \{t_1, \dots, t_n\}$, 相应的测试代价矢量为 $C = [c_1, \dots, c_n]$ 。相关性矩阵是一个 $m \times n$ 维二值矩阵, 记为 $FT = [ft_{ij}]_{m \times n}$ 。矩阵的行对应故障集 F , 列对应测试集 T , 如下所示:

$$t_1 \quad t_2 \quad \dots \quad t_n$$

收稿日期: 2014-11-05; 修回日期: 2015-01-09。

基金项目: 国家部委“十二五”预先研究项目(51319040102)。

作者简介: 马 羚(1987-), 男, 博士研究生, 主要从事装备测试性建模与设计技术方向的研究。

$$\mathbf{FT}_{m \times n} = \begin{matrix} f_1 \\ f_2 \\ \vdots \\ f_m \end{matrix} \begin{bmatrix} ft_{11} & ft_{12} & \cdots & ft_{1n} \\ ft_{21} & ft_{22} & \cdots & ft_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ ft_{m1} & ft_{m2} & \cdots & ft_{mn} \end{bmatrix} \quad (1)$$

式中, 矩阵元素 ft_{ij} 为一布尔变量, 如果故障 f_i 与测试 t_j 相关 (f_i 能被 t_j 观测), 则令 $ft_{ij} = 1$; 否则令 $ft_{ij} = 0$ 。

1.2 最优完备测试集描述

测试优化选择的主要目的就是为系统选择最优完备测试。

定义 1: 如果一个测试集 $T = \{t_1, \dots, t_n\}$ 能够满足系统要求的相关测试性指标, 则该测试集是完备测试集^[10]。

定义 2: 对于完备测试集 T 的子集 T_α ($|T_\alpha| \leq |T|$, 符号 $|\cdot|$ 表示集合大小), 如果 T_α 能够满足系统要求的相关测试性指标, 则该测试集是完备测试集的完备测试子集。对于所有完备测试子集 T_k^α ($1 \leq k \leq 2^{n_\alpha} - 1, n_\alpha = |T_\alpha|$), 如果 $C(|T_k^\alpha|) = \min_k C(|T_k^\alpha|)$, 即集合 T_k^α 的测试代价最小, 则 T_k^α 为最优完备测试集^[1]。

因此, 完整的测试选择应该包含以下 3 个步骤:

- 1) 设计备选测试集, 并判断备选测试集的完备性;
- 2) 若备选测试集不完备, 则利用专家经验重新设计或增加测试使其完备;
- 3) 从完备的备选测试集中选择最优完备测试集。

1.3 数学模型的建立

假设备选测试集为 T_s , 且 $T_s \subseteq T$, 记此时的相关性矩阵为 $\mathbf{FT} = [ft_{ij}]_{m \times n}$ 。

故障 f_i 被 T_s 检测的条件为^[5]: 相关性矩阵中 f_i 所对应的行向量至少有一个元素为 1。即 $\bigcup_{t_j \in T_s} ft_{ij} = 1$ 。式中, \bigcup 为布尔变量的或运算, N_s 为集合 T_s 的个数。设 T_s 能检测的所有故障构成的集合为 F_D , 则有:

$$F_D = \{f_i \mid f_i \in F, \bigcup_{t_j \in T_s} ft_{ij} = 1\}$$

因此, 故障检测率可表示为:

$$\gamma_{FD} = \frac{\sum_{f_i \in F_D} \lambda_i}{\sum_{f_i \in F} \lambda_i} \quad (2)$$

设 T_{f_i} 为能检测故障 f_i 的所有测试组成的集合, T_{f_j} 为能检测故障 f_j 的所有测试组成的集合, 则故障 f_i 与 f_j 能被 T_s 隔离的条件为^[5]: 故障 f_i 与 f_j 均可被 T_s 检测, 且向量 T_{f_i} 与 T_{f_j} 不相同, 即 $T_{f_i} \oplus T_{f_j} \neq 0, \forall f_i, f_j \in F_D, i \neq j$ 。式中, \oplus 表示向量的异或运算, 如果两个向量的对应元素都相同, 结果为 0, 否则为 1。设 T_s 能隔离的所有故障构成的集合为 F_I , 则有:

$$F_I = \{f_i \mid f_i \in F_D, T_{f_i} \oplus T_{f_j} \neq 0, \forall f_j \in F_D, i \neq j\}$$

因此, 故障隔离率可表示为:

$$\gamma_{FI} = \frac{\sum_{f_i \in F_I} \lambda_i}{\sum_{f_i \in F_D} \lambda_i} \quad (3)$$

综合以上分析, 可得测试优化选择模型如下:

$$\begin{cases} \min \left\{ \sum_{t_j \in T_s} c_j \right\} \\ s. t. \begin{cases} \gamma_{FD} \geq \gamma_{FD}^* \\ \gamma_{FI} \geq \gamma_{FI}^* \end{cases} \end{cases} \quad (4)$$

其中: $\gamma_{FD}^*, \gamma_{FI}^*$ 为系统要求的故障检测率和隔离率。

2 基于 IDPSO 的测试优化选择方法

2.1 DPSO 算法改进策略

2.2.1 编码过程及混沌初始化

由于混沌运动具有遍历性、随机性和规律性等特点^[8]。因此, 本文采用混沌搜索的方式来产生种群的初始位置, 使得种群的分布更加均匀, 有利于种群的全局寻优。IDPSO 的编码过程及算法混沌初始化方式如下。

1) 编码过程:

首先, 通过相关性建模建立欲优化选择的故障-测试相关性矩阵。假设相关性矩阵的备选测试集数目为 n , 则可定义种群中每个粒子对应一个备选测试集, 且每个粒子是由长度为 n 的二进制码组成。

其次, 初始化种群 $X = \{x_1, x_2, \dots, x_M\}$, 其中 M 为种群规模, 以种群中的第 i 个粒子为例, 相应的二进制码为 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]$, 其中 $x_{ij} = 1$ 表示备选测试集 x_i 中第 j 个测试被选中; 而 $x_{ij} = 0$ 表示未被选中, $i = 1, 2, \dots, M, j = 1, 2, \dots, n$ 。

最后, 粒子 x_i 中的各分量通过下式转换而得到二进制编码向量。

$$x_{ij} = \begin{cases} 1, \varepsilon < \text{sigmoid}(v_{ij}) \\ 0, \varepsilon \geq \text{sigmoid}(v_{ij}) \end{cases} \quad (5)$$

其中: ε 是判断阈值, 这里取 $\varepsilon = 0.5$, 粒子速度 v_{ij} 是从区间 $[v_{\min}, v_{\max}]$ 随机产生的实数。通过计算可以发现, 当 v_{ij} 在 $[-4, 4]$ 区间内取值时, $0.018 \leq \text{sigmoid}(v_{ij}) \leq 0.982$, 且变化比较均匀。

2) 混沌初始化过程:

采用混沌搜索的方法设置种群的初始速度, 即在速度区间 $[v_{\min}, v_{\max}]$ 内产生混沌变量作为种群的初始速度。这里采用改进的 Tent 映射来产生混沌变量, 改进的 Tent 映射比 Logistic 映射具有更好的遍历均匀性, 有利于混沌的全局寻优。其映射形式如下:

$$z_{k+1} = T(z_k) = \begin{cases} 2z_k, 0 \leq z_k \leq 0.5 \\ 2(1-z_k), 0.5 < z_k \leq 1 \end{cases} \quad (6)$$

为防止 Tent 映射迭代到不动点 (例如: 0, 0.25, 0.5, 0.75), 对序列加入小扰动, 使 Tent 映射重新进入混沌状态。如下所示:

$$\begin{aligned} & \text{If } z_k = 0, 0.25, 0.5, 0.75 \text{ or } z_k = z_{k-m} \\ & \quad z_{k+1} = T(z_k) + 0.1 \cdot \text{rand}(0, 1); \\ & \quad \text{else then} \\ & \quad \quad z_{k+1} = T(z_k). \end{aligned} \quad (7)$$

其中: z_k 为混沌变量, $z_k \in [0, 1]$; $m = \{1, 2, 3, 4, 5\}$ 。改进后的 Tent 映射可使 z_k 的轨迹遍历整个值域范围。混沌初始化种群速度的过程如下:

首先, 随机产生一个各维元素取值在 (0, 1) 之间的粒子, 作为混沌初值 Z_0 ;

其次, 种群的其他粒子各维元素采用改进后的 Tent 映射

依次由 Z_0 迭代产生。以第 i 个粒子为例，利用式 (6) 和式 (7) 产生该粒子的第 j 维混沌变量，即 $z_{ij} = T(z_{i-1,j})$ ；

最后，利用下式将混沌序列中的每个变量转换为粒子速度中的每个变量。

$$v_{ij} = v_{\min} + z_{ij} \cdot (v_{\max} - v_{\min}) \quad (8)$$

通过上述粒子编码过程和混沌初始化过程，完成了粒子种群的初始化。

2.2.2 适应度计算方法

适应度值主要用于评价种群中每个粒子的优劣，其计算方法对于粒子群的性能具有重要影响。文献 [7] 根据故障检测率利用启发式规则可行化粒子，并采用罚函数的方法修正越界粒子，在解决测试优化选择问题上取得了良好的效果。因此，本文基于该方法并进行了改进，用于计算粒子的适应度。具体计算过程如下：

1) 假设种群进化至第 k 代时，当前种群为 $X(k) =$

$$\left\{ \begin{matrix} x_1^k, \\ x_2^k, \\ \dots, \\ x_M^k \end{matrix} \right\}, \text{ 种群中第 } i \text{ 个粒子 } x_i^k \text{ 选择的测试集为 } T_i, \text{ 而 } T_i \text{ 检}$$

测到的故障集为 F_i ，由公式 (1) 计算测试集 T_i 的故障检测率 $\gamma_{FD}(T_i)$ 。若 $\gamma_{FD}(T_i) \geq \gamma_{FD}^*$ ，转 5)，否则转 2)。

2) 由 T_i 得到未被选中的测试集 $\bar{T}_i = T - T_i$ ，根据 F_i 得到未被检测到的故障集 $\bar{F}_i = F - F_i$ 。

3) 对未被选中测试集 \bar{T}_i 中每个测试计算比值： $\frac{p}{c}$ ，其中 p 为 \bar{F}_i 中能被相应测试检测的故障概率之和， c 为相应测试的测试代价。选择比值最大的测试加入测试集 T_i ，并将其检测的故障加入故障集 F_i 。

4) 计算测试集 T_i 的故障检测率 $\gamma_{FD}(T_i)$ ，若 $\gamma_{FD}(T_i) \geq \gamma_{FD}^*$ ，转 5)，否则更新 \bar{T}_i 和 \bar{F}_i ，转 2)。

5) 根据式 (3) 所示模型，基于罚函数的方法构建式 (8) 所示的适应度函数，并计算 T_i 的适应度。

$$Fitness = \frac{\alpha \cdot \sum_{t_i \in T} c_i}{\sum_{t_i \in T_i} c_i + \sum_{t_i \in T} c_i} - \beta \cdot \max(0, \gamma_{FI}^* - \gamma_{FI}) \quad (9)$$

式中， c_i 表示测试 t_i 的测试代价， α 和 β 为常数，且 $\alpha, \beta \in (0, 1)$ 。当测试集 T_i 满足故障隔离率指标时，该个体的适应度由第一部分决定，当测试集 T_i 不满足故障隔离率指标时，该个体的适应度由第二部分决定，确保每次利用适应度函数值所选择的个体为当前种群中的较优个体。

2.2.3 惯性权重自适应调整策略

惯性权重的设置会影响粒子的局部搜索和全局搜索能力，如果对整个群体采用相同的惯性权重设置，则当群体已收敛到全局最优附近时，优秀粒子被破坏的概率会随着其惯性权重的增加而增加，从而使 PSO 算法的性能下降^[9]。本文提出一种惯性权重自适应调整策略，该策略根据当前所有粒子适应度值的平均值作为评价指标，将粒子群分为 3 个不同的子种群，每个子群根据粒子的适应度值采用不同的惯性权重，使群体始终保持惯性权重的多样性以提高 PSO 的局部和全局搜索能力。

设 f_g 为全局最优粒子的适应度值， f_{avg} 为当前所有粒子的适应度平均值， f_p 为优于 f_{avg} 的适应度值，本文 f_p 取 f_g 和

f_{avg} 的中间值。对于适应度值为 f_i 的粒子，其惯性权重的自适应调整策略如下：

1) 当 $f_i > f_p$ 时，

$$\omega' = \omega_a - (\omega_a - \omega_{\min}) \cdot \left| \frac{f_i - f_p}{f_g - f_p} \right| \quad (10)$$

式中， ω_{\min} 为 ω 的最小值， ω_a 为 ω 取值区间 $[\omega_{\min}, \omega_{\max}]$ 的中间值。

2) 当 $f_{ag} \leq f_i \leq f_p$ 时，

$$\omega' = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \cdot \left(\frac{CurIter}{MaxIter} \right)^2 \quad (11)$$

式中， ω_{\max} 为 ω 的最大值， $CurIter$ 和 $MaxIter$ 是算法的当前迭代次数和最大迭代次数。

3) 当 $f_i < f_{ag}$ 时，

$$\omega' = \omega_{\max} \quad (12)$$

2.3 DPSO 算法实现流程

综上所述，用于测试优化选择的 IDPSO 算法实现流程如下：

1) 参数初始化。包括种群规模 $Popsize$ ，惯性权重 ω_{\max} 、 ω_{\min} ，学习因子 c_1 、 c_2 ，常数 α 和 β ，最大迭代次数 N_{\max} 。

2) 种群初始化。设置种群迭代计数器 $i = 0$ ，根据 2.2.1 节中的混沌初始化方法产生规模为 M 的初始种群 $X(i) = \{x_1^i, x_2^i, \dots, x_M^i\}$ 。

3) 寻找初始极值。根据第 2.2.2 节中的方法计算种群 $X(i)$ 中每个粒子的适应度值，进而更新种群中的个体极值 P_{bestid} 和全局极值 G_{bestid} 。

4) 迭代寻优。根据第 2.2.3 节中的自适应策略调整惯性权重，然后按照式 (4) 分别对种群速度和位置进行更新，产生下一代种群 $X(i+1)$ ，并更新计数器 $i \leftarrow i+1$ 。

5) 算法终止判断。若迭代次数 $i > N_{\max}$ ，则算法结束，跳转 Step6；否则跳转 Step3。

6) 输出结果。输出全局极值 G_{bestid} 作为最优完备测试集。

3 仿真与验证

为了对本文所提方法的有效性进行验证，选取文献 [6] 中的超外差接收器系统的检测实例进行分析。实例中存在 22 个先验故障，36 个备选测试，故障先验概率为 $10^{-3} \times [1.85, 9.23, 1.85, 1.85, 1.85, 9.23, 1.85, 9.23, 1.85, 1.85, 1.85, 1.85, 9.23, 1.85, 9.23, 1.85, 9.23, 1.85, 1.85, 1.85, 1.85, 1.85]$ ，每个备选测试的代价相同且均为 1 个标准单位，测试性指标要求：故障检测率和故障隔离率均不低于 95%。

对超外差接收器系统进行基于 IDPSO 的测试优化选择的参数设置如下：种群规模 $Popsize = 30$ ，最大迭代次数 $N_{\max} = 300$ ，惯性权重 $\omega_{\max} = 1.2, \omega_{\min} = 0.4$ ，学习因子 $c_1 = c_2 = 1.4962$ ，常数 $\alpha = \beta = 0.5$ 。

为了验证本文提出的 IDPSO 算法的有效性，同时采用以下两种算法进行对比分析。文献 [8] 中提出的混合二进制粒子群—遗传 (HBPSOGA) 算法和文献 [9] 中提出的改进量子进化 (IQEA) 算法，两种算法的参数设置除种群规模与最大迭代次数同 IDPSO 算法，其余参数设置同相应文献。考虑到算法运行的随机性，对于实例中所采用的每种算法都重复运行 20 次，取其平均值作为最终的优化结果。

[6] Ying J, Guomao X, Jinhui S, et al. A method of automated test data generation for web service [J]. Chinese journal of computers, 2005, 28 (4): 568-577.

[7] Dong W L, Hu J H. Test method for BEPL-based Web service composition based on data flow analysis [J]. Journal of Software, 2009, 20 (8): 2102-2112.

[8] Cuif F, Qiao Y, Chang Y. Web Services Rapid Composition Framework Based on BPEL [J]. Computer Engineering, 2010, 7: 094.

[9] Zhang M H, Jiang Y. Method of test data selection for Web services composition based on mutation [J]. Journal of Computer Ap-

plications, 2011, 9: 037.

[10] Estero-Botaro A, Palomo-Lozano F, Medina-Bulo I. Mutation operators for WS-BPEL 2.0 [A]. 21th International Conference on Software & Systems Engineering and their Applications [C]. 2008.

[11] Gao J, Bai X, Tsai W T. Cloud testing - issues, challenges, needs and practice [J]. Software Engineering: An International Journal, 2011, 1 (1): 9-23.

[12] 方锦明. 云计算中虚拟资源调度的决策系统 [J]. 计算机测量与控制, 2011 (12): 3145-3148.

[13] http://www.webinject.org/[EB/OL].

(上接第 2246 页)

测试优化选择仿真结果表明: 所得最优解为 [0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0, 1, 1, 0, 1, 0, 0], 即最优完备测试集为 { $t_8, t_{26}, t_{28}, t_{31}, t_{32}, t_{34}$ }, 其系统故障检测率为 96.86%, 故障隔离率为 96.57%, 测试代价为 6.3 种算法的优化结果对比如表 1 所示。各算法在优化过程中的平均测试代价收敛曲线如图 1 所示。

从表 1 和图 1 可以看出, 在求解全局最优解上, IQEA 和 IDPSO 明显优于 HBPSOGA, 并且 IDPSO 在 20 次独立试验中都找到了最优解, 成功率为 100%。这主要是因为: IDPSO 和 IQEA 在 HBPSOGA 的基础上, 根据故障检测率利用启发式规则可行化粒子, 然后根据测试性指标构建罚函数计算粒子适应度, 从而加强了算法的求解精度。在收敛速度上, IDPSO 优于其他两种算法, HBPSOGA 虽然在算法前期收敛速度优于 IQEA, 但在后期容易陷入早熟。在运行时间上, HBPSOGA 和 IQEA 基本是 IDPSO 的两倍。

通过超外差接收器系统仿真实例结果, 表明 IDPSO 在收敛速度, 收敛精度和运行时间方面均优于 HBPSOGA 和 IQEA, 能够在满足系统测试性指标要求的前提下准确快速的获取全局最优解。

表 1 3 种算法的优化统计结果

	HBPSOGA	IQEA	IDPSO
平均最优测试代价	6.80	6.15	6
平均收敛代数	54.18	81.53	48.26
最好收敛代数	26	39	18
最差收敛代数	84	105	72
平均运行时间/s	2.825	2.481	1.148
成功率/(%)	20	85	100




图 1 平均测试代价收敛曲线

4 结论

目前, 航空电子设备的性能和规模日益增加, 其故障与测试之间的相关性变得日趋复杂, 测试优化选择问题也日益突出, 提高其优化效率和精度就显得尤为重要。本文根据测试优化选择问题的特点, 对 PSO 算法进行了一些改进, 提出了一种基于 IDPSO 的测试优化选择方法, 该方法的优势体现在:

- 1) 采用混沌搜索方式初始化粒子群的速度和位置, 克服了种群初始化的不均匀性, 使得初始种群更具有多样性, 有利于种群的全局寻优。实验结果表明, 相比随机方法, 该方法具有较高的初始寻优能力。
- 2) 根据测试性指标采用启发式规则和罚函数方法计算粒子适应度, 实验结果表明, 该方法能够有效修正越界粒子, 使算法收敛到全局最优解。
- 3) 通过采用自适应的惯性权重, 实现了粒子群全局搜索, 使粒子跳出局部最优解, 避免算法陷入早熟。

参考文献:

[1] 邱静, 刘冠军, 杨鹏, 等. 装备测试性建模与设计技术 [M]. 北京: 科学出版社, 2012.

[2] 杨鹏, 邱静, 刘冠军, 等. 基于布尔逻辑的测试选择算法 [J]. 测试技术学报, 2007, 21 (5): 386-390.

[3] Golonek T, Rutkowski J. Genetic-algorithm-based method for optimal analog test points selection [J]. IEEE Trans. on Circuits and Systems II: Express Briefs, 2007, 54 (2): 117-121.

[4] Pattipati K R, Alexandridis M G. Application of heuristic search and information theory to sequential fault diagnosis [J]. IEEE Transactions On Systems, Man, and Cybernetics, 1990, 20 (4): 872-887.

[5] 蒋荣华, 王厚军, 龙兵. 基于离散粒子群算法的测试选择 [J]. 电子测量与仪器学报, 2008, 22 (2): 11-15.

[6] 陈希祥, 邱静, 刘冠军. 基于混合二进制粒子群-遗传算法的测试优化选择研究 [J]. 仪器仪表学报, 2009, 30 (8): 1674-1680.

[7] 雷华军, 秦开宇. 基于改进量子进化算法的测试优化选择 [J]. 仪器仪表学报, 2013, 34 (4): 838-843.

[8] 王瑞琪, 张承慧, 李珂. 基于改进混沌优化的多目标遗传算法 [J]. 控制与决策, 2011, 26 (9): 1391-1397.

[9] 朱喜华, 李颖晖, 李宁, 等. 基于群体早熟程度和非线性周期振荡策略的改进粒子群算法 [J]. 通信学报, 2014, 35 (2): 182-189.