

# 基于改进遗传模拟退火算法的测试优化选择

代西超, 南建国, 黄雷, 黄金科, 张超

(空军工程大学航空航天工程学院,西安,710038)

**摘要** 针对测试优化选择这一 NP-hard 问题,提出利用改进遗传模拟退火算法对其进行求解。由于遗传模拟退火算法直接应用在测试优化选择问题时,存在算法运行到后期时搜索过程冗长和交叉操作后父代与子代的染色体相似度高。因此采用非线性加速适应度函数提高搜索速度,同时在交叉操作前先对基因进行比较,剔除无效交叉以提高交叉有效性。最后,对典型实例(超外差接收器系统)进行测试优化选择,结果表明,优化后的遗传模拟退火算法达到收敛所需代数相比于遗传模拟退火算法减少 13.3%;在满足故障检测率和隔离率的要求下,所需的测试代价与其它算法所得相比较小。因此优化后的遗传模拟退火算法可以更有效地解决测试优化选择问题。

**关键词** 测试选择;遗传模拟退火算法;故障检测;故障隔离

**DOI** 10.3969/j.issn.1009-3516.2016.02.014

**中图分类号** TN06 **文献标志码** A **文章编号** 1009-3516(2016)02-0070-06

## An Optimal Test Selection Based on Improved Genetic Simulated Annealing Algorithm

DAI Xichao, NAN Jianguo, HUANG Lei, HUANG Jinke, ZHANG Chao

(Aeronautics and Astronautics Engineering College, Air Force Engineering University, Xi'an 710038, China)

**Abstract:** Aimed at the NP-hard problem in the optimal test selection (OTS), this paper proposes to utilize the genetic simulated annealing algorithm for solving. To solve the problems that the large time-consuming of searching process and the inefficient crossover operation exist in GASA algorithm, the paper firstly uses a nonlinear accelerating fitness function to improve the searching speed, and simultaneously compares genes before crossover operation to reject the invalid cross operation, so the effectiveness of the algorithm is improved. And the proposed algorithm is applied in the super-heterodyne receiver system. The simulation results show that the iterative numbers of convergence are less 13.3% in OGASA than that in GASA. Meanwhile, the OGASA algorithm can meet the acquirements of testability and fault isolation rate. The testing cost of the algorithm is less than that of others. So the OGASA algorithm is more effective in solving OTS problem.

**Key words:** optimal test selection;genetic simulated annealing algorithm;fault detection;fault isolation

收稿日期:2015-11-09

基金项目:航空科学基金(20142896022)

作者简介:代西超(1992-),男,陕西凤翔人,硕士生,主要从事机载计算机技术测试性设计与分析研究.E-mail:791801725@qq.com

**引用格式:**代西超,南建国,黄雷,等.基于改进遗传模拟退火算法的测试优化选择[J].空军工程大学学报:自然科学版,2016,17(2):70-75. DAI Xichao, NAN Jianguo, HUANG Lei, et al. An Optimal Test Selection Based on Improved Genetic Simulated Annealing Algorithm[J]. Journal of Air Force Engineering University: Natural Science Edition, 2016, 17(2): 70-75.

设备故障检测与诊断的难度日益增大,对故障进行全面分析得到的测试集通常存在大量的冗余测试,而通过测试优化选择可以有效地提高测试效率,并降低测试代价。因此测试优化选择在测试性设计工作中得到高度重视。测试优化选择指的是从系统测试集中选取一组最佳的测试组合方案,不仅要满足测试性指标,还要将测试代价尽可能的降到最低<sup>[1]</sup>。要达到这一目的就需要对多种测试方案进行比较,来寻找出其中的最优测试集合。通过数学建模分析可以得出测试优化选择属于集合覆盖模型,而集合覆盖问题本身是一个典型的 NP-hard 问题,所以对大规模的装备系统的进行测试优化选择受到了广泛关注,许多学者提出不同的算法来进行求解。其中,针对多值故障字典的模拟电路测点选择问题已经提出了许多的测试优化选择算法<sup>[2-6]</sup>,针对二值情况的测试优化选择问题,文献[7]中提出基于布尔逻辑的测试选择方法,然而当问题规模不断增大时,布尔逻辑算法显然存在维数过大而不再适用;文献[8]中提出利用遗传算法进行测试优化选择,但遗传算法自身搜索策略的效率有限,存在收敛速度较慢的问题;刘建敏等<sup>[9]</sup>提出了基于贪婪算法的测试优化选择方法,虽然其时间复杂度得到了降低,却不一定能得到全局最优解;文献[10~12]针对遗传算法解决测试选择问题的不足进行改进,其中混沌遗传算法通过避免重复遍历能较快地得到问题的最优解,量子遗传算法和改进的量子遗传算法在收敛速度上均有一定的提高。文献[13~15]都将粒子群算法应用于测试选择问题,而粒子群算法存在可能不收敛的问题;文献[16]采用二进制粒子群-遗传算法既避免陷入局部最优,提高了搜索效率,但其稳定性下降,不易求得最优解。

## 1 测试优化选择的数学描述与建模

### 1.1 故障-测试相关矩阵

故障-测试相关矩阵是指用行向量表示故障(fault)、列向量表示测试(test)所形成的相关性矩阵,设  $F = \{f_1, f_2, \dots, f_m\}$  表示由  $m$  个故障组成的待检测与隔离的故障集合,  $T = \{t_1, t_2, \dots, t_n\}$  表示由  $n$  个可供选择的测试组成的测试集合,则故障-测试相关矩阵可记为:

$$FT_{m \times n} = \begin{bmatrix} ft_{11} & ft_{12} & \cdots & ft_{1n} \\ ft_{21} & ft_{22} & \cdots & ft_{2n} \\ \vdots & \vdots & ft_{ij} & \vdots \\ ft_{m1} & ft_{m2} & \cdots & ft_{mn} \end{bmatrix} \quad (1)$$

式中:  $ft_{ij} = \begin{cases} 1, & \text{表示故障 } f_i \text{ 可以被测试 } t_j \text{ 观测} \\ 0, & \text{表示故障 } f_i \text{ 不可以被测试 } t_j \text{ 观测} \end{cases}$ , 矩阵的第  $i$  行向量  $F_i = [ft_{i1}, ft_{i2}, \dots, ft_{in}]$  描述了故障  $f_i$  发生时对应的所有测试信息,其相应的测试集合为  $T(f_i) \in T$ ; 第  $j$  列向量  $T_j = [ft_{1j}, ft_{2j}, \dots, ft_{mj}]^T$  描述了测试  $t_j$  对所有故障的检测信息,其可观测的故障集合为  $F(t_j) \in F$ 。

### 1.2 测试性指标参数

#### 1.2.1 故障检测率

故障检测率(FDR)一般定义为:在规定时间内测试系统能正确检测出的故障数与发生的总故障数之比。设  $T_s \in T$  为备选测试集合,  $F_D \in F$  表示能被测试集合  $T_s$  检测到的故障集,则  $F_D$  可定义为:

$$F_D = \{f_i | f_i \in F, t_j \in T_s, ft_{ij} = 1\} \quad (2)$$

式中:  $i = 1, 2, \dots, m$ 。因此,故障检测率可表示为:

$$\gamma_{FD} = |F_D| / |F| = |F_D| / m \quad (3)$$

为满足规定的故障检测率  $\gamma_{FD}^*$  要求,可以数学化描述为:  $\gamma_{FD} \geq \gamma_{FD}^*$ 。

#### 1.2.2 故障隔离率

故障隔离率(FIR)一般定义为:在规定的时间内测试系统正确隔离到不大于规定的可更换单元数的总故障数与同一时间内检测到的故障总数之比。设  $T_s \in T$  为备选测试集合,  $F_I \in F$  表示能被测试集合  $T_s$  隔离的故障集,即故障  $f_x, f_y (x \neq y)$ , 如果它们均可被测试集  $T_s$  检测到,且  $ft_{xj} \neq ft_{yj}$ 。则  $F_I$  可定义如下:

$$F_I = \{f_x | f_x \in F, t_j \in T_s, ft_{xj} \neq ft_{yj}\} \quad (4)$$

式中:  $x = 1, 2, \dots, m; y = 1, 2, \dots, m; x \neq y$ 。因此,故障隔离率为:

$$\gamma_{FI} = |F_I| / |F_D| \quad (5)$$

为满足规定的故障隔离率  $\gamma_{FI}^*$  要求,其可以数学化描述为:  $\gamma_{FI} \geq \gamma_{FI}^*$ 。

#### 1.2.3 测试代价

通常将除测试结果可靠度( $r_j$ )以外的测试参数统称为测试代价  $c_j$ , 例如测试时间、测试任务复杂度和测试设备的大小等。对于给定的备选测试集合  $T_s$ , 在满足系统所给定的故障检测率和隔离率要求时,其测试代价  $C$  为:

$$C = \sum_{t_j \in T_s} c_j \quad (6)$$

### 1.3 优化模型

综合上述分析,可以得到测试优化选择模型为:

$$\begin{cases} \min & C \\ \text{s.t.} & \gamma_{FD} \geq \gamma_{FD}^* \\ & \gamma_{FI} \geq \gamma_{FI}^* \end{cases} \quad (7)$$

## 2 遗传模拟退火算法求解测试优化选择问题

### 2.1 遗传模拟退火算法

遗传模拟退火算法是在遗传算法的基础上引入模拟退火算法<sup>[17]</sup>,充分利用两种算法的不同邻域搜索结构的特点,取长补短将优点相结合而形成的一种混合优化策略,其具体流程图见图1。该算法既包括遗传算法的选择、交叉、变异操作,又包含模拟退火算法的状态产生函数等不同的领域搜索结构。主要思想是在遗传算法的操作中加入了模拟退火过程,其中选择操作有利于将优良个体基因遗传到下一代解,交叉操作可以使后代继承父代的优良模式,突变操作可以增加解的多样性,在高温时进行模拟退火操作有利于解状态的大范围迁移,在低温时进行模拟退火操作保证了在局部范围内寻优,从而提高了遗传模拟退火算法在解空间中的寻优能力和搜索效率。

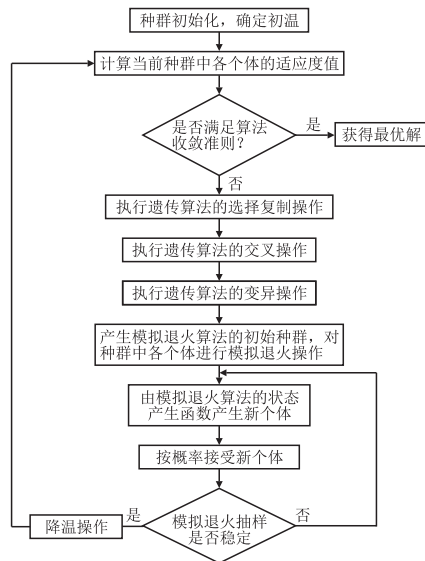


图1 遗传模拟退火算法的流程图

Fig.1 Flow chart of genetic algorithm and simulate annealing algorithm

### 2.2 测试优化选择问题的求解

采用遗传模拟退火算法求解测试优化选择问题的主要步骤可表述如下:

1)编码选择。以测试集合为变量,备选测试集合  $T_s$  中的测试个数  $n$  作为染色体长度进行二进制编码。

2)初始化参数和初始化种群。参数初始化包括种群规模  $P_{size}$ ,交叉概率  $P_c$ ,变异概率  $P_m$ ,最大迭代次数  $N_{max}$ ,初始温度  $t_0$ ,退温速率  $\lambda$ ;种群初始化是由备选测试集合随机选取测试集合作为个

体,在保证每个个体均是合法的情况下,总共选取  $P_{size}$  个个体就是一个初始种群。

3)适应度函数的构造。适应度函数是对个体的目标值的适当替换,可以体现出不同个体间的性能差异。测试选择问题的适应度函数构造应符合以下特点:故障检测率、故障隔离率等测试性指标相同的情况下,测试代价越低的测试集合越容易被选中;测试代价相同的情况下,故障检测率、故障隔离率等测试性指标越高的测试集合越容易被选中。因此适应度函数可取为检测率  $\gamma_{FD}$  和隔离率  $\gamma_{FI}$  的增函数与测试代价  $C$  的减函数,在此基础上再引入罚函数,参照文献[1]和[8]适应度函数可表示为:

$$f(T_s) = \begin{cases} \left(1 - \frac{\sum_{t_j \in T_s} c_j}{\sum_{t_j \in T} c_j}\right)^\mu + 2, & \gamma_{FD} \geq \gamma_{FD}^* \\ & \gamma_{FI} \geq \gamma_{FI}^* \\ \left(1 - \frac{\sum_{t_j \in T_s} c_j}{\sum_{t_j \in T} c_j}\right)^\mu + \left(\frac{\gamma_{FD}}{\gamma_{FD}^*}\right)^\alpha + 1, & \gamma_{FD} \leq \gamma_{FD}^* \\ & \gamma_{FI} \geq \gamma_{FI}^* \\ \left(1 - \frac{\sum_{t_j \in T_s} c_j}{\sum_{t_j \in T} c_j}\right)^\mu + \left(\frac{\gamma_{FI}}{\gamma_{FI}^*}\right)^\beta + 1, & \gamma_{FD} \geq \gamma_{FD}^* \\ & \gamma_{FI} \leq \gamma_{FI}^* \\ \left(1 - \frac{\sum_{t_j \in T_s} c_j}{\sum_{t_j \in T} c_j}\right)^\mu + \left(\frac{\gamma_{FD}}{\gamma_{FD}^*}\right)^\alpha + \left(\frac{\gamma_{FI}}{\gamma_{FI}^*}\right)^\beta, & \gamma_{FD} \leq \gamma_{FD}^* \\ & \gamma_{FI} \leq \gamma_{FI}^* \end{cases} \quad (8)$$

式中:  $\mu$ 、 $\alpha$ 、 $\beta$  均为常数。

4)遗传算法的搜索操作步骤为:①选择操作;②交叉操作;③变异操作。

5)模拟退火算法状态接受函数的构造。采用 Metropolis 接受准则,即从除去个体  $x_i$  的种群  $P$  中随机选取一个个体  $x_j \in P$ ,分别计算  $x_i$ 、 $x_j$  的适应度函数值,求其差值  $\Delta f_{ij} = f(x_j) - f(x_i)$ ,按照概率  $\min[1, \exp(-\Delta f_{ij}/t_k)]$  接受新个体。

6)退温函数的构造。采用函数  $t_k = \lambda t_{k-1}$  作为退温函数,其中  $\lambda$  为退温速率。

7)终止条件。为了使算法更有效地应用于测试选择优化问题,终止条件的设置应综合考虑优化结果和优化时间两者的性能指标。在寻优过程中如果连续 10 代最优解的适应度函数值都保持不变就进行退温,若连续进行 10 次退温仍是同一个最优解,则将其作为全局最优解,终止搜索并输出此最优解。

## 3 遗传模拟退火算法在测试优化选择具体问题中的优化

### 3.1 适应度函数的优化

测试优化选择的目标函数式(7)可变形为式

(8),并将其作为适应度函数,虽然在遗传操作的过程中计算起来比较方便,能够满足优化问题适应度函数的设计要求:即当个体满足约束条件时,则该个体的适应度比较大,使该个体能以较大的概率被选入下一代种群;当个体不满足约束条件时,则该个体的适应度将受到惩罚,其适应度比较小。但是这种由目标函数简单变形而来的适应度函数优化精度有限,在目标值近似的不同个体之间,由于概率分布相差很小,要区别更优个体变得十分困难,当模拟退火算法优化进行到后期时,将面临搜索过程过于冗长的问题。

为了遗传模拟退火算法更好地应用在测试优化选择,提高优化效率,针对上述问题可以将此适应度函数进一步转化为非线性加速适应度函数为:

$$F_{t_k}(T_s) = \exp\left\{-\frac{f(T_s) - f_{\min}}{t_k}\right\} \quad (9)$$

式中:  $f_{\min}$  为当前种群中的最小值。

以式(8)作为适应度函数时,随着种群进化,个体的适应度函数值是递增的。而当将其进一步转化为非线性加速适应度函数式(9)后,随着种群进化,在解区间上个体的适应度函数值是递减的,因而将问题由寻找具有较大的适应度值的个体转化为了寻找较小的适应度值的个体,即得到的个体适应度愈小的解则为愈优的测试集。经过这一转化,可以有效地使个体的适应度值的变化非线性地加快,当温度较高时,其加速效果一般,从而可以避免早熟现象的发生;当温度较低时,其加速效果明显,可以有效地放大个体差异得到更优的个体,进而提高了收敛速度,可以更快地收敛到全局最优解。

### 3.2 交叉操作的优化

在遗传算法中,交叉操作是新个体产生的主要途径,起着十分重要的作用,直接影响着算法的全局搜索能力以及算法收敛速度的快慢。通常按照“双亲双亲”的方法,当给定交叉概率  $P_c$ , 2 个配对染色体中同一个测试的基因位置将以概率  $P_c$  两两相互交换,得到 2 个新的个体。然而将遗传模拟退火算法应用于测试优化选择这一实际问题采用二进制编码方式时,大量的冗余测试所处的基因位置编码可能是相同的,尤其是随着种群的不断进化,迭代次数增加,这种情况还会逐渐加剧,按照传统的“双亲双亲”方法以给定交叉概率  $P_c$  进行交叉操作,容易造成父代与子代的染色体相似度较高,甚至可能出现完全相同的情况,这样势必会对算法的收敛速度和搜索范围产生不利影响。如图 2 所示,若任选 1,2,

3,4 交配位进行交配,则子代和父代的基因相同,未能达到交配产生新个体的预期效果。由此可见,如果两个父代的染色体相似度较高,即相同的基因位越多,那么进行交叉操作产生的新个体的概率就越小,很容易变成无效的交叉操作,导致迭代次数的增加从而影响了算法的收敛速度,并且很难收敛到全局最优解。



图 2 无效的交叉

Fig.2 Crossover is invalid

针对上述问题,对遗传模拟退火算法的交叉操作可以进行以下改进:当进行交叉操作选定 2 个染色体之后,先依次进行比较找出它们相同的基因,再对剩余不同的基因位置按常规方法进行交配。图 3 中,通过比较避开前 4 个基因位,选择 5,6 交配位进行交换,产生了 2 个新的个体 C 和 D。明显可以看出,先对个体的染色体进行判断然后再针对性地进行交叉的改进策略可以有效地提高交叉操作的效率,进而提高算法的收敛速度,加快收敛到全局最优解。



图 3 有效的交叉

Fig.3 Crossover is valid

## 4 实例验证

本文通过对典型实例(即超外差接收器系统)进行测试优化选择,验证了遗传模拟退火算法的有效性。该系统的先验故障为 22 个,备选测试为 36 个,不同测试的代价是一样的,且都设为 1 个标准单位,测试性指标要求为故障检测率和隔离率均达到 95%,其具体的故障与测试相关性矩阵见表 1。

算法的参数选取如下:种群规模  $P_{size} = 20$ ,交叉概率  $P_c = 0.8$ ,变异概率  $P_m = 0.02$ ,最大进化代数  $N_{max} = 100$ ,退温速率  $\lambda = 0.9$ ,  $\mu = 1$ ,  $\alpha = \beta = 1$ 。

经过在 MATLAB 上调试和运行,所得到的最优解如下:  $[0, 1, 0, 0, 1, 0, 0, 1, 0, 1, 0, 0, 0, 0, 1, 0, 1, 0, 0, 1, 1, 0, 1]$ , 即相应的测试集为  $\{t_2, t_5, t_8, t_{21}, t_{26}, t_{28}, t_{31}, t_{32}, t_{34}\}$ , 此时系统的故障检测率为  $\gamma_{FD} = 98.91\%$ , 故障隔离率为  $\gamma_{FI} = 99.16\%$ , 均满足测试性指标的既定要求,测试代价为 9。

表1 超外差式接收器故障-测试相关矩阵

Tab.1 Relationship between faults and tests for superheterodyne receiving system

	$t_1 \sim t_{36}$	故障率/%
$f_1$	000000101110100000010111100000000001	0.185
$f_2$	111111111111110111111111011111111111	0.923
$f_3$	000000000110100000010111110000000001	18.500
$f_4$	000000000000000000001010000000000000	0.185
$f_5$	00010010111011100001011110000001011	0.185
$f_6$	111111111111110110111111011111111111	0.923
$f_7$	100100100100000000010010001001001001	0.185
$f_8$	101101101110100000010111101011010011	0.923
$f_9$	101101101110100000010111100101010011	18.500
$f_{10}$	000101101110100000010111100000100011	18.500
$f_{11}$	000000101110100000010111100000000101	18.500
$f_{12}$	000000000000000000000000000000000001	0.185
$f_{13}$	000111101110100000010111100000000011	0.923
$f_{14}$	101101101111111100010111100101111111	18.500
$f_{15}$	0000000000000000000011100000000000001	0.923
$f_{16}$	000000000111100000010100000000000001	0.185
$f_{17}$	000000111110100000010111100000000101	0.923
$f_{18}$	111101101110100000010111100001010011	0.185
$f_{19}$	11111111111111111111111111111111111111	0.185
$f_{20}$	000101101110100000010111100001110011	0.185
$f_{21}$	100100100110010010010010101001001001	0.185
$f_{22}$	11111111111111011110111111111111111111	0.185

图4给出了直接采用遗传模拟退火算法进行20次实验计算,每次迭代100次的实验结果,可以看出,当迭代进行到30代左右时,算法可以收敛到全局最优解。图5是相同条件下经过对适应度函数和交叉操作进行优化后的实验结果,可以看出,在适应度函数得到优化后,最优个体适应度值由逐渐增加变为逐渐变小,由前文对适应度函数优化的讨论可得,取适应度值最小的个体作为最优解,当迭代进行到26代左右时,就可以稳定地收敛到全局最优解,且算法的收敛速度得到了提高。




图4 未优化的进化代数与适应度值关系图

Fig.4 Relationship curves between fitness and iteration times without optimization




图5 优化后的进化代数与适应度值关系图

Fig.5 Relationship curves between fitness and iteration times with optimization

同时,对于这一实例,文献[8]中遗传算法所需的测试代价为15,文献[10]中混沌遗传算法所需的测试代价为15,文献[11]中量子遗传算法所需的最小测试代价为12,而本文中所需的测试代价为9,故可以看出遗传模拟退火算法能以较小的测试代价达到故障检测率和隔离率指标的既定要求。

综合分析可以得出以下结论:遗传模拟退火算法在以较小的测试代价满足测试性指标既定要求的同时,能较快地收敛到全局最优解;并且经过对适应度函数和交叉操作进行优化后,遗传模拟退火算法的收敛速度也得到了提高,即证明了文中所提出的优化操作的有效性。

## 5 结语

本文首先通过对测试优化选择问题的数学描述与建模,介绍了遗传算法、模拟退火算法和将两种算法取长补短得到的遗传模拟退火算法。然后将遗传模拟退火算法应用于求解测试优化选择问题,并给出其主要步骤。接着,针对该算法在应用中存在的具体问题进行分析,对适应度函数和选择操作分别进行了优化。最后,采用超外差接收器系统这一典型实例进行验证。结果表明,优化后的遗传模拟退火算法在满足系统测试性指标要求的基础上,所需的测试代价较小,并能够较快地收敛到全局最优解,有效地解决了测试优化选择问题。

### 参考文献(References):

- [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.  
QIU Jing, LIU Guanjun, YANG Peng, et al. Equipment Testability Modeling And Design Technology [M]. Beijing: Science Press, 2012. (in Chinese)
- [2] PRASAD V C, BABU N S C. Selection Of Test Node For Analog Fault Diagnosis In Dictionary Approach [J]. IEEE Transactions on Instrumentation and Measurement, 2000, 49(6): 1289-1297.
- [3] GOLONEK T, RUTKOWSKI J. Genetic-algorithm-based Method For Optimal Analog Test Points Selection [J]. IEEE Transactions on Circuits and Systems- : Express Briefs, 2007, 54(2): 117-121.
- [4] YANG C L, TIAN S L, LONG B. Application Of Heuristic Graph Search To Test Points Selection For Analog Fault Dictionary Techniques [J]. IEEE Transactions on Instrumentation and Measurement, 2009, 58(7): 2145-2158.
- [5] JIANG R H, WANG H J. Multidimensional Fitness Function DPSO Algorithm For Analog Test Points Selection [J]. IEEE Transactions on Instrumentation and Measurement, 2010, 59(6): 1634-1641.
- [6] LEI H J, QIN K Y. Quantum-inspired Evolutionary Algorithm For Analog Test Point Selection [J]. Analog Integrated Circuits and Signal Processing, 2013, 75(3): 491-498.
- [7] 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.  
YANG Peng, QIU Jing, LIU Guanjun, et al. The Test Selection Algorithms Based on Boolean Logic [J]. Journal of Test and Measurement Technology, 2007, 21(5): 386-390. (in Chinese)
- [8] 苏永定. 机电产品测试性辅助分析与决策相关技术研究[D]. 长沙:国防科技大学, 2004.  
SU Yongding. Research on Relevant Technology in Analysis And Decision at The Testability Aid Design for Mechatronics Equipment [D]. Changsha: National University of Defence Technology, 2004. (in Chinese)
- [9] 刘建敏,刘远宏,冯辅周,等. 基于贪婪算法的测试优化选择[J]. 兵工学报, 2014, 35(12): 2109-2116.  
LIU Jianmin, LIU Yuanhong, FENG Fuzhou, et al. The Optimization Selection of Tests Based on Greedy Algorithm [J]. Journal of China Ordnance, 2014, 35(12): 2109-2116. (in Chinese)
- [10] 吕晓明,黄考利,连光耀. 基于混沌遗传算法的测试选择优化问题的研究[J]. 弹箭与制导学报, 2009, 29(3): 265-268.  
LÜ Xiaoming, HUANG Kaoli, LIAN Guangyao. Research on The Problem of Test Selection Optimization Based on Chaos Genetic Algorithm [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2009, 29(3): 265-268. (in Chinese)
- [11] 吴涛,叶晓慧,王红霞. 基于量子遗传算法测试选择问题的研究[J]. 计算机测量与控制, 2010, 18(11): 2508-2510.  
WU Tao, YE Xiaohui, WANG Hongxia, et al. Research on Problem of Test Selection Based on Quantum Genetic Algorithm [J]. Computer Measurement & Control, 2010, 18(11): 2508-2510. (in Chinese)
- [12] 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): 838-845.  
LEI Huajun, QIN Kaiyu. Optimal Test Selection Based on Improved Quantum-inspired Evolutionary Algorithm [J]. Chinese Journal of Scientific Instrument, 2013, 34(4): 838-845. (in Chinese)
- [13] 蒋荣华. 基于粒子群算法的电子系统可测性研究[D]. 成都:电子科技大学, 2009.  
JIANG Ronghua. Research On Testability of Electronic System Based on Binary Particle Swarm Algorithms [D]. Chengdu: University of Electronic Science and Technology of China, 2009. (in Chinese)
- [14] 马羚,李海军,王成刚,等. 基于改进粒子群算法的测试优化选择[J]. 计算机测量与控制, 2015, 23(7): 2244-2246.  
MA Ling, LI Haijun, WANG Chenggang, et al. Optimal Test Selection Based on Improved Discrete PSO Algorithm [J]. Computer Measurement & Control, 2015, 23(7): 2244-2246. (in Chinese)
- [15] 马羚,李海军,王成刚,等. 考虑换件维修代价的测试优化选择[J]. 仪器仪表学报, 2015, 36(2): 280-286.  
MA Ling, LI Haijun, WANG Chenggang, et al. Optimized Test Selection Method Considering The Cost of Alternative Maintenance [J]. Chinese Journal of Scientific Instrument, 2015, 36(2): 280-286. (in Chinese)
- [16] 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): 1675-1680.  
CHEN Xixiang, QIU Jing, LIU Guanjun. Optimal Test Selection Based on Hybrid BPSO And GA [J]. Chinese Journal of Scientific Instrument, 2009, 30(8): 1675-1680. (in Chinese)
- [17] 王凌. 智能优化算法及其应用[M]. 北京:清华大学出版社, 2001.  
WANG Ling. Intelligent Optimization Algorithms with Applications [M]. Beijing: Tsinghua University Press, 2001. (in Chinese)

(编辑:徐楠楠)