

doi: 10.7690/bgzdh.2021.05.016

不可靠测试条件下基于多目标粒子群的测试优化选择方法

林 云, 韩 露

(海军航空大学岸防兵学院, 山东 烟台 264001)

摘要: 针对测试条件下多目标优化的问题, 提出一种在不可靠测试条件下的测试优化选择方法。通过对测试优化选择过程进行分析, 建立多目标优化的数学模型, 利用最大似然估计法得到故障测试样本参数信息, 采用 E 占优多目标粒子群算法选取最优解, 并通过某导弹雷达组件实例验证了算法的有效性与可用性。结果表明: 该方案可在兼顾所有因素的同时, 着重关注漏检率因素。

关键词: 测试优化选择; 多目标; 不可靠测试; E 占优; 粒子群算法

中图分类号: TP206 **文献标志码:** A

Test Optimization Selection Method Based on Multi-objective Particle Swarm Optimization Under Unreliable Test Conditions

Lin Yun, Han Lu

(College of Naval Coast Defence, Navy Aviation University, Yantai 264001, China)

Abstract: Aiming at the problem of multi-objective optimization, put forward the test optimization selection method under unreliable test conditions. Through analyze the test optimization selection process, establish the math model of multi-objective optimization. Use maximum likelihood estimation method to acquire the failure test sample parameter information, and adopt E-dominant multi-objective particle swarm optimization algorithm to select optimization solution. Use certain type radar assembly test to verify the algorithm validity and availability. The results show that the test selection scheme can take into account all factors and pay attention to the miss detection rate factor.

Keywords: test optimization selection; multi-objective; unreliable test; E-dominance; particle swarm optimization

0 引言

测试优化选择的主要目的是在被选测试集中选择满足诊断隔离要求的测试子集, 并使得测试费用、测试数量等代价达到最低^[1]。测试优化选择的解决方案主要是基于测试性模型与最优化算法进行的, 通过测试性模型评价测试选择方案的优劣并反馈回最优化算法中进一步调整。吴新锋等将二进制粒子群算法与遗传算法进行有机结合, 提出了二者的改进混合算法, 并在 D 矩阵基础上, 完成了测试优化选择工作, 经验证算法收敛速度快, 不易陷入局部极值^[2]; 雷华军等提出了改进量子进化算法来解决该问题, 并顺利应用于电子设备测试性设计中^[3]; 刘建敏等采用贪婪算法求解测试优化选择这种最优化问题^[4]; 焦晓璇等基于相关性模型, 通过一种改进粒子群算法—模拟退火粒子群算法解决问题^[5]; 代西超等通过与遗传算法融合的方式对模拟退火粒子群算法进行改进, 并取得一定的应用成果^[6]; 文献[7-8]应用萤火虫算法、遗传算法来解决该问题;

在工程实践中, 著名的测试性设计软件 TEAMS 与 eXpress 亦是利用含有确定性信息的测试性模型与最优化算法来获得优化方案。

以上优化工作都是基于理想化故障-测试关系的模型开展, 随着测试性设计技术的迭代与测试性需求的增长, 在工程实践中其导致的问题也不断显现。鉴于此, S·RUAN 等^[9]针对测试不确定性进行了研究, 并改变了传统的仅含有确定性信息的测试性模型; 雷华军建立了测试不可靠条件下一种新的单目标测试选择数学模型, 并利用改进量子进化算法进行模型求解^[10]; 张士刚对非完美测试条件下的测试优选问题做了许多研究^[11]; 陈希祥则应用贝叶斯网络建立了可表征不确定信息的测试性模型, 并利用混合二进制粒子群-遗传算法求解测试优化选择问题^[11-12]。

笔者针对测试优化选择还原为多目标优化问题, 提出基于贝叶斯网络模型与多目标粒子群算法的测试优化选择方法, 并利用某装备实例验证算法的有效性。

收稿日期: 2021-01-17; 修回日期: 2021-03-09

作者简介: 林 云(1981—), 男, 山东人, 博士, 从事装备测试性设计研究。E-mail: onewest@163.com。

1 问题描述及测试性模型

1.1 测试优化选择问题

测试优化选择是测试性设计过程中重要的一环, 其目的是寻找最优的测试布置方案。测试不可靠条件下的测试优化选择问题是在满足已设定条件的前提下, 求解使得多个目标函数达到综合最优的测试方案或测试方案集。最优方案求解过程中需要计算2个数据: 1) 根据优化算法确定当前的测试方案; 2) 基于测试性模型评估当前测试方案的测试性指标。其中测试性指标是测试方案的评价标准与优化目标, 测试选择要求我们找到使得所关注的测试性指标最优的测试方案, 笔者选择虚警率、测点数目、测试成本为3个优化目标, 以故障检测率、故障隔离率为约束条件开展测试优化选择。测试优化选择问题的数学模型为

$$\left. \begin{array}{l} \min(FAR) \\ \min(D(x)) \\ \min(C(x)) \end{array} \right\} \quad (1)$$

约束条件为

$$\left. \begin{array}{l} FIR \geqslant FIR^* \\ FDR \geqslant FDR^* \end{array} \right\} \quad (2)$$

式中: FAR 为虚警率; FDR 为故障检测率; FIR 为故障隔离率; $D(x)$ 为测点数量; $C(x)$ 为测试总成本。

1.2 贝叶斯网络测试性模型

测试优化选择过程中需要对测试性指标进行评估, 以对方案做出评价。测试性模型可以迅速完成测试性指标计算, 为评价方案提供依据。现有的主流测试性模型主要是相关性模型, 具体有多信号流图模型、信息流模型等。这些模型大都假定故障、测试间的逻辑关系是确定的, 因而建模难度低; 但实际测试工作中, 故障-测试相关关系表现出明显的不确定性, 多信号流图模型由于忽略了这种不确定信息而导致模型精度低, 测试性指标计算误差大, 难以较好地评价测试方案。针对该问题, 文献[10]对多信号流图模型进行了改进, 但改进的多信号流图模型仍无法最大限度利用已有信息计算测试性指标。基于以上分析, 笔者提出采用贝叶斯网络测试性模型进行指标计算。贝叶斯网络模型对不确定信息的处理能力强、信息表达形式独特, 且具有其他模型不具备的学习更新与证据处理能力, 可以准确快速地完成指标计算。贝叶斯网络测试性模型主要由以下元素构成:

故障节点集: $F=\{f_1, f_2, \dots, f_n\}$, 其中 f_i 表示故障节点;

测试节点: $T=\{t_1, t_2, \dots, t_m\}$, 其中 t_f 表示测试节点;

有向边: E , 连接故障节点与信号节点, 用以表示二者之间的相关关系;

条件概率信息表: CPT, 含有贝叶斯网络的参数信息。贝叶斯网络测试性模型如图1所示。

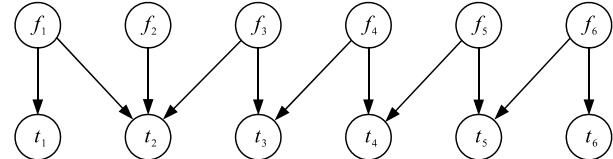


图1 贝叶斯网络模型

文中测试性模型结构由故障测试相关矩阵与测试方案决定。故障-测试相关矩阵如表1所示(其中0表示故障未发生状态, 1表示故障发生状态), 其所确定的贝叶斯网络模型结构如图1所示。之后根据测试方案, 在模型中删除未被设置的测试节点即可。

表1 故障-测试相关矩阵

故障 节点	测试节点					
	t_1	t_2	t_3	t_4	t_5	t_6
f_1	1	1	0	0	0	0
f_2	0	1	0	0	0	0
f_3	0	1	1	0	0	0
f_4	0	0	1	1	0	0
f_5	0	0	0	1	1	0
f_6	0	0	0	0	1	1

测试性模型的参数信息通过采用最大似然估计法对故障测试样本数据集进行参数学习得到, 这里不对该方法原理进行叙述。表2为对应图1贝叶斯网络的部分故障测试样本, 表3为参数学习完成后测试节点 t_1 的CPT信息。

表2 部分故障测试样本

序号	f_1	f_2	f_3	t_1	t_2	t_3
1	1	0	0	1	1	1
2	1	0	0	1	1	1
3	1	0	0	1	1	0
4	0	1	0	0	0	1

表3 CPT信息

f_1 状态	0	1
0	0.99	0.03
1	0.01	0.97

1.3 贝叶斯网络测试性模型

测试性模型建立后, 需要对测试性指标进行计算。由于所建立的模型主要针对单故障发生的情况, 且在故障无相关关系的形势下, 多故障同时发生的概率极小, 笔者假设系统任意时刻只有一个故障发

生。通过贝叶斯网络证据处理可直接计算测试性指标如下：

对故障 f_i 的检测率：

$$FDR_j = 1 - p\left(\sum_{i=1}^m t_i = 0 \mid f_j\right)。 \quad (3)$$

系统故障检测率：

$$FDR = 1 - \prod_{j=1}^q FDR_j。 \quad (4)$$

故障隔离率：

$$FIR = \sum_{j=1}^q p(f_j) * p(f_j \mid f_j) / \sum_{j=1}^q p(f_j) * FDR_j。 \quad (5)$$

虚警率：

$$FAR = 1 - p\left(\sum_{j=1}^m t_j = 0 \mid \sum_{i=1}^n f_i\right)。 \quad (6)$$

2 E 占优多目标二进制粒子群算法

对测试优化选择问题的处理通常有 2 种：1) 将不同的多个目标融合为一个综合的目标函数，最后通过单目标算法来解决问题，但该方法缺陷很大；2) 利用基于 Pareto 占优的多目标优化算法来解决问题，虽然一定程度上解决了多目标的组合优化问题，但并没有考虑研发人员偏重指标，一味寻找使得各目标的平衡最优方案，需要一种既可以处理多目标优化问题，又能考虑研发人员所偏重的指标的算法。经研究发现：E 占优多目标二进制粒子群算法可以解决此问题，并具有良好的运行速度。

E 占优多目标二进制粒子群算法是粒子群算法的一种，在粒子群算法的基础上针对多目标问题进行了优化改进，在粒子速度更新算子执行前对当前方案进行支配排序。

2.1 E 占优

多目标优化问题有许多种有关最优解的定义方法，如 Pareto 最优解、E 占优最优解。笔者选择 E 占优的原因是其可在综合考量所有因素的同时，通过权重因子着重关注某因素，毕竟在多目标优化问题中，所有因素的重要程度并不完全相同^[13]。

介绍 E 占优的概念之前，先来解释一些基础概念。若多目标函数为 $G(x)=\{g_1(x), g_2(x), \dots, g_n(x)\}$, $g_i(x)$ 表示目标函数， x_1, x_2 为测试方案， n 为目标数量。

定义 B, W, E ：

$B(x_1, x_2)$ 指多目标函数 $G(x_1)$ 比 $G(x_2)$ 好的目标的数量。

$W(x_1, x_2)$ 指多目标函数 $G(x_1)$ 比 $G(x_2)$ 差的目标的数量。

$E(x_1, x_2)$ 指多目标函数 $G(x_1)$ 与 $G(x_2)$ 表现相同的目标的数量。

建立方案评价矩阵 P ：

$$P=[g_{ij}]。 \quad (7)$$

其中 g_{ij} 表示方案 x_i 的第 j 个目标值。

由于不同目标的量纲并不相同，所以需要对目标值进行标准化处理。

标准化处理分为 2 种，原理如下：

1) 效益型目标：目标值越大越好，如故障检测率、故障隔离率等，由下式处理：

$$g'_{ij} = (\max_j \{g_{ij}\} - g_{ij}) / (\max_j \{g_{ij}\} - \min_j \{g_{ij}\})。 \quad (8)$$

2) 成本型指标：目标值越小越好，如虚警率、漏检率、测试成本、测点数量等，由下式处理：

$$g'_{ij} = (g_{ij} - \min_j \{g_{ij}\}) / (\max_j \{g_{ij}\} - \min_j \{g_{ij}\})。 \quad (9)$$

建立标准化后的方案评价矩阵 P' ：

$$P'=[g'_{ij}]。 \quad (10)$$

定义距离概念：

$$H(x) = \sqrt{\sum_{i=1}^n (g'_i(x))^2}。 \quad (11)$$

定义偏重系数 k ：

$$\sum_{j=1}^n k_j = 1。 \quad (12)$$

式中 k_j 表示目标函数 $g_j(x)$ 的偏重系数。

定义融入偏重系数的距离概念：

$$H(x) = \sqrt{\sum_{j=1}^n (k_j g_j(x))^2}。 \quad (13)$$

定义 E 占优：

x_1, x_2 为 2 种测试方案，若 $B-W > 0$ ，且 $H(x_1) < H(x_2)$ ，则 x_1 E 占优于 x_2 ，称 x_1 支配 x_2 。

依据 E 占优的定义，可以对已有的测试方案进行 E 占优排序，必然存在某些方案不被其他任何方案所支配。这些方案即是 E 占优最优解，将这些方案提取出来保存在档案中。

2.2 二进制粒子群算法

Kennedy 提出了离散二进制粒子群算法。该算法用二进制方式表示每个粒子的位置，通过 Sigmoid 函数将原有的速度转换为粒子位置的概率。粒子的速度是由粒子上一次的速度、个体极值与群体极值

决定。通过速度更新算子计算出粒子速度, 确定粒子当前位置, 经过不断迭代, 最终完成对个体经验与群体经验的学习。

粒子群的基本概念:

粒子当前位置 $X_i = \{x_{i1}, x_{i2}, \dots, x_{in}\}$, 其中 x_{ij} 为二进制, 值为 0 或 1;

粒子自身搜索到的历史最优位置 $P_{id} = \{p_{i1}, p_{i2}, \dots, p_{in}\}$;

粒子群搜索到的历史最优位置 $G_{id} = \{g_{i1}, g_{i2}, \dots, g_{in}\}$ 。

粒子的搜索速度与位置确立公式如下:

$$v_{id} = \omega \times v_{id} + c_1 \times \text{rand} \times (p_{id} - x_{id}) + c_2 \times \text{rand} \times (g_{id} - x_{id}); \quad (14)$$

$$s(v_{id}) = 1 / (1 - \exp(-v_{id})); \quad (15)$$

$$x_{id} = \begin{cases} 1, & \text{rand} \leq s(v_{id}) \\ 0, & \text{otherwise} \end{cases}. \quad (16)$$

其中: ω 为惯性常量, 默认为 0.8; c_1, c_2 为学习因子; rand 为随机数。

2.3 档案更新与粒子极值确定

2.1 节中提到, 不被其他任何方案支配的最优解将被存放在档案中, 档案依照下列规则进行更新:

- 1) 若档案中没有内容, 则将当前最优解放入档案中;
- 2) 档案中已存有方案, 若新方案可被档案中某方案支配, 则新方案无法存入档案;
- 3) 档案中已存有方案, 若新方案无法被档案中任意方案支配, 则将新方案存入档案中;
- 4) 档案中已存有方案, 若当前档案中的某个方案可被新方案支配, 则将该方案从档案中删除。

个体极值的更新:

将某粒子此次迭代对应的新方案与之前的极值方案进行比较, 若新方案能支配极值方案, 则新方案更新为极值方案; 若新方案与极值方案都无法支配对方, 则从新方案与极值方案中随机选择一种方案更新为新的极值方案; 若新方案被极值方案支配, 则极值方案不变。

群体极值的更新:

从档案中获取群体极值, 当档案中方案数量不为 1 时, 采用轮盘赌方法确定当前群体极值。

2.4 算法流程

- 1) 随机初始化粒子群, 解码粒子群得到测试选

择方案, 找到 E 占优最优解并记录在档案中; 2) 更新粒子群的速度与位置; 3) 根据档案更新规则更新档案, 并更新个体极值与群体极值; 4) 判断是否完成规定迭代次数, 若是则计算结束输出 E 占优最优解, 若否则重复步骤 2)–4)。

算法流程如图 2 所示。

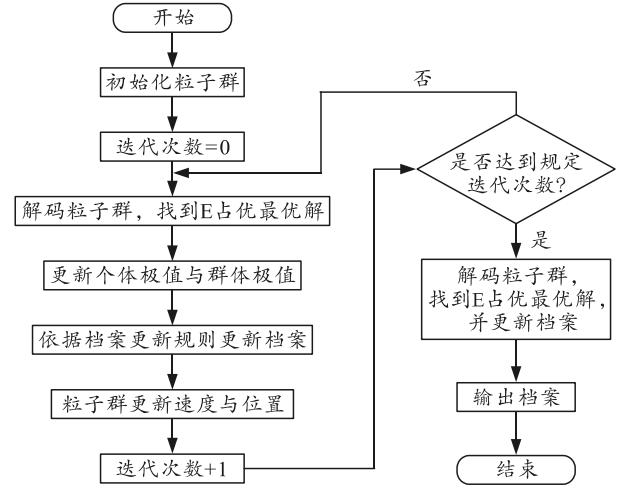


图 2 算法流程

3 实例分析

以某导弹雷达组件为对象, 建立如图 3 所示的贝叶斯网络测试性模型, 完成参数学习。利用该模型计算出含有不确定信息的故障-待选测试的相关性矩阵如表 4、5 所示。

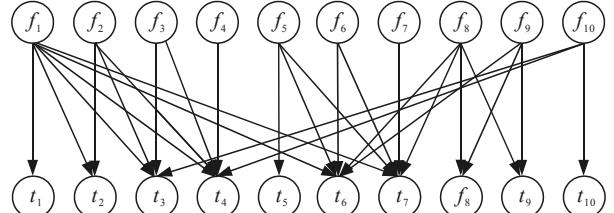


图 3 雷达组件贝叶斯网络模型

选取测试总数量、测试总成本、虚警率为优化目标, 以故障检测率、隔离率为约束条件, 建立不可靠测试条件下的多目标测试优化选择问题的数学模型:

$$\left. \begin{array}{l} \min(FAR) \\ \min(D(x)) \\ \min(C(x)) \\ FIR \geq 70\% \\ FDR \geq 90\% \end{array} \right\}. \quad (17)$$

利用笔者提出的多目标粒子群算法与贝叶斯网络模型计算出 E 占优最优解, 并从解集中选择 4 组解与普通遗传算法比较, 结果如表 6 所示。

表 4 测试费用与虚警率

测试	测试费用	测试虚警率	测试	测试费用	测试虚警率
t_1	1	0.05	t_6	5	0.01
t_2	2	0.04	t_7	3	0.03
t_3	1	0.04	t_8	2	0.02
t_4	1	0.01	t_9	3	0.05
t_5	2	0.02	T_1	1	0.02

表 5 测试故障相关性矩阵

故障	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8	t_9	T_1	故障率
f_1	0.97	0.98	0.99	0.98	0	0.95	0.95	0	0	0	0.008
f_2	0	0.96	0.98	0.95	0	0	0	0	0	0	0.009
f_3	0	0	0.99	0.99	0	0	0	0	0	0	0.006
f_4	0	0	0	0.98	0	0	0	0	0	0	0.005
f_5	0	0	0	0	0.98	0.97	0.95	0	0	0	0.004
f_6	0	0	0	0	0	0.99	0.99	0	0	0	0.008
f_7	0	0	0	0	0	0	0.98	0	0	0	0.001
f_8	0	0	0	0	0	0.96	0.98	0.99	0.98	0	0.008
f_9	0	0	0	0	0	0.99	0	0.96	0.95	0	0.002
f_{10}	0	0	0.98	0.96	0	0	0	0	0	0.98	0.019

表 6 多目标粒子群算法与遗传算法结果比较

算法	测试配置方案	测试总数量	测试成本	虚警率
多目标粒子群	0111001101	6	58	0.0876
遗传算法	0111010101	6	60	0.0987

通过上表可发现：普通遗传优化算法在优化一个目标的同时难以兼顾其他指标，造成方案短板严重，其他类似的优化算法也存在该问题；而采用多目标粒子群算法，可在兼顾所有指标的同时尽量使每个指标达到最优，且由于采纳 E 占优的最优解求解方式，可对选定指标进行重点优化。

4 结论

笔者直接将测试优化选择问题作为多目标优化问题解决，采取 E 占优多目标粒子群算法进行优化，通过多目标优化的方式综合考量各个因素，并利用 E 占优中的权重概念突出某重点因素的重要性。验证结果表明：该方法可以有效解决测试优化选择问题，E 占优最优解在兼顾所有因素的同时，着重考虑重点因素，得到的测试优化选择方案满足要求。

参考文献：

- [1] 张士刚. 非完美测试条件下的测试性设计理论与方法研究[D]. 长沙: 国防科学技术大学, 2013: 155.
- [2] 吴新锋, 段然, 周虎, 等. 基于改进二进制粒子群遗传算法的测试优选[J]. 兵器装备工程学报, 2019, 40(5): 146–150.
- [3] 雷华军, 秦开宇. 测试不可靠条件下基于量子进化算法的测试优化选择 [J]. 电子学报, 2017, 45(10): 2464–2472.
- [4] 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): 2109–2115.
- [5] 焦晓璇, 景博, 黄以锋. 基于精华蚂蚁系统的诊断策略优化 [J]. 计算机测量与控制, 2014, 22(4): 1059–1061.
- [6] 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.
- [7] 周虎, 胡海峰, 刘清竹, 等. 基于故障-测试相关模型的运载火箭测试点优化设计方法[J]. 载人航天, 2018, 24(1): 34–40.
- [8] 王鹤淇, 王伟国, 郭立红, 等. 离散萤火虫算法的复杂装备测试点优化选择[J]. 光学精密工程, 2017, 25(5): 1357–1367.
- [9] RUAN S, ZHOU Y, YU F, et al. Dynamic Multiple-Fault Diagnosis With Imperfect Test[J]. IEEE Transactions on Systems Man & Cybernetics Part A Systems & Humans, 2009, 39(6): 1224–1236.
- [10] 雷华军. 电子系统测试方案优化设计理论与关键技术研究[D]. 成都: 电子科技大学: 139.
- [11] 陈希祥. 测试不确定条件下基于贝叶斯网络的装备测试优化选择技术 [J]. 中国机械工程, 2011, 4(22): 1350–1354.
- [12] 柴志君, 欧阳中辉, 李钊. 基于 Henon 混沌映射的多目标粒子群算法改进分析[J]. 兵工自动化, 2020, 39(11): 48–52.
- [13] 姚玉海, 王增平, 郭昆亚, 等. 基于 E 占优的多目标二进制粒子群算法求解配电网故障恢复[J]. 电力系统保护与控制, 2014(23): 76–81.